

## 引文格式:

张立中, 刘俊, 刘思尧, 等. 基于轻量级双层金字塔结构的伞裙破损检测算法 [J]. 集成技术, 2022, 11(5): 80-87.

Zhang LZ, Liu J, Liu SY, et al. A lightweight double-layer pyramid structure based on insulator skirt damage detection algorithm [J]. Journal of Integration Technology, 2022, 11(5): 80-87.

## 基于轻量级双层金字塔结构的伞裙破损检测算法

张立中\* 刘俊 刘思尧 苏婷 刘峰

(国网宁夏电力有限公司信息通信公司 银川 750000)

**摘要** 在无人机电力线路巡检系统中, 针对伞裙破损检测的准确性和实时性, 该文提出了一种基于双层金字塔结构的轻量级伞裙破损检测算法, 通过充分提取图片中高低级语义特征, 可有效防止有用信息被过滤。同时, 利用多通道特征增加了模型特征表达能力。此外, 该文还利用深度可分离卷积来优化卷积内核性能, 使其可以在低功耗嵌入式系统上实时运行。实验结果表明, 该算法在不同光照、拍摄角度和破损模糊条件下, 对伞裙破损检测均有较好的准确性、实时性和鲁棒性。

**关键词** 深度学习; 检测识别; 伞裙破损检测; 轻量级网络

中图分类号 TP 3 文献标志码 A doi: 10.12146/j.issn.2095-3135.20220504001

### A Lightweight Double-Layer Pyramid Structure based on Insulator Skirt Damage Detection Algorithm

ZHANG Lizhong\* LIU Jun LIU Siyao SU Ting LIU Feng

(Information & Communication Company of Ningxia Electric Power Co., Ltd., Yinchuan 750000, China)

\*Corresponding Author: zhanglizhong@xt.nx.sgcc.com.cn

**Abstract** In order to meet the requirements for the accuracy and efficiency of the insulator skirt damage detection in the field of UAV power inspection, a lightweight insulator skirt damage detection algorithm based on a double-layer pyramid structure is proposed in this paper. To avoid the filtering of useful information, the proposed method utilized both high-level and low-level semantic features from images. Simultaneously, multi-channel feature extraction is used to increase the feature expression ability of the model. In addition, deep separable convolution is employed to optimize the performance of the convolution kernel for real-time operation on a low-power embedded front-end. Experimental results show that the proposed algorithm has good accuracy, real-time performance and robustness for the insulator skirt damage detection under different working conditions.

收稿日期: 2022-05-04 修回日期: 2022-05-28

基金项目: 基于可信计算 3.0 的物联网设备安全校验机制研究 (5229XT20001X)

作者简介: 张立中 (通讯作者), 高级工程师, 研究方向为新型电力系统建设与通讯技术, E-mail: zhanglizhong@xt.nx.sgcc.com.cn; 刘俊, 中级工程师, 研究方向为电力信息化建设与网络安全技术; 刘思尧, 副高级工程师, 研究方向为电力信息化建设与运维技术; 苏婷, 助理工程师, 研究方向为大数据分析及应用; 刘峰, 中级工程师, 研究方向为计算机网络与通讯技术。

**Keywords** deep learning; detection and recognition; insulator skirt damage detection; lightweight network

**Funding** This work is supported by Research on Security Verification Mechanism of Internet of Things Devices Based on Trusted Computing 3.0 (5229XT20001X)

## 1 引言

为适应电力市场发展, 满足用户对电力的需求, 智能电网需要实现可靠性、安全性、经济性和高效性。但持续的机械张力、材料老化、覆冰和人为因素等原因, 使得长期暴露的传输线设备易断裂、磨损、损坏和腐蚀, 从而给电力系统的安全性和稳定性带来了巨大的隐患。电网检查是电网传输的重要保证, 但我国的电网传输线分布广泛、地貌复杂、环境恶劣、气候多变, 使传统的人工巡检工作难度加大、危险系数增加、灵活性降低、人工成本提高, 导致人工巡检周期长、效率低。为满足大规模电网及时巡检的要求, 无人机电力巡检<sup>[1-2]</sup>成为关注热点。

近年来, 随着深度学习<sup>[3-4]</sup>技术的发展, 嵌入式前端算力的提高, 图像处理与计算机视觉技术得到了迅速发展。在此背景下, 基于边缘计算<sup>[5]</sup>的实时智能前端检测与识别, 成为智能电网未来发展的主要方向之一。

绝缘子是输电线路的重要组成部分, 其主要作用是电气绝缘和线路支撑。伞裙是绝缘子的外绝缘部分, 其主要作用是保护芯棒免受气候影响和电蚀作用, 提供所需要的爬电距离。受自然灾害或人为因素的影响, 伞裙可能出现裂纹、破损、污秽等问题, 因此, 需要定期对伞裙进行检查和维修, 从而确保供电系统安全。

伞裙破损检测需要解决两个关键问题: 从捕获的图像中检测出伞裙和确定被检测的伞裙是否有破损。在过去的几年里, 硬件设备和深度学习理论的发展, 使得目标检测取得了重大突破, 许多具有代表性的深度卷积网络, 如

Faster R-CNN<sup>[6-7]</sup>、YOLOv3<sup>[8-9]</sup>、Resnet-101<sup>[10]</sup>和 SSD<sup>[11]</sup>等模型, 都在公共数据集上被提出和验证。在这些前沿研究的推动下, 如何利用深度学习模型对无人机巡航图像中的伞裙进行定位和破损检测成为相关学者研究的热点。吴涛等<sup>[12]</sup>通过改进 YOLOv3 来定位绝缘子, 设计了一种基于轻量级网络的绝缘子故障定位方法。该方法提高了航空图像中绝缘子故障检测的质量, 但其仍需高清图像做支撑, 无法实现实时应用。Tao 等<sup>[13]</sup>将航拍图像中绝缘子故障部分粘贴到其他正常绝缘子航拍图像上, 以增强绝缘子断层数据集, 但通过模拟得到的绝缘子故障增强数据集, 容易影响神经网络的泛化能力。Shelhamer 等<sup>[14]</sup>利用 FCN 像素级别分割网络对图片中的伞裙进行像素级别的检测, 但因为样本不均衡造成模型难以训练。此外, 大多数基于人工特征的方法和基于机器学习的方法对复杂背景的干扰比较敏感, 且运行达不到实时性要求<sup>[15]</sup>。

基于上述研究, 本文通过优化单激发多盒探测器 (Single Shot MultiBox Detector, SSD) 算法, 设计了一种适合运行于嵌入式设备的轻量级卷积网络结构, 并结合多通道特征提取, 解决了模型提取特征健壮的问题。该结构采用了类似双层金字塔的结构, 可有效提取图像中高低级语义特征, 从而避免过滤掉有用的特征。与目前经典的轻量级卷积网络结构 MobilNetV2<sup>[16]</sup>相比, 本文模型具有更高的平均正确率 (Average Precious, AP) 指标。此外, 为了便于本文模型在嵌入式设备上实时运行, 需要在确保检测准确性的同时, 降低模型所需的计算资源。本文利用深度可分离卷积结构对双层金字塔模型进行优化, 在确保准

准确率的同时，进一步提升了网络模型的实时性。

## 2 基于双层金字塔结构的轻量级神经网络结构

### 2.1 目标检测概述

图 1 为目标检测任务中经典的主干特征提取算法神经网络结构，这种结构能够提取到不同分辨率的特征图组。原图中不同大小的目标经不同分辨率的特征图检测后，提取到的不同分辨率的特征图组被移送至下一阶段，进行目标检测的后续过程。

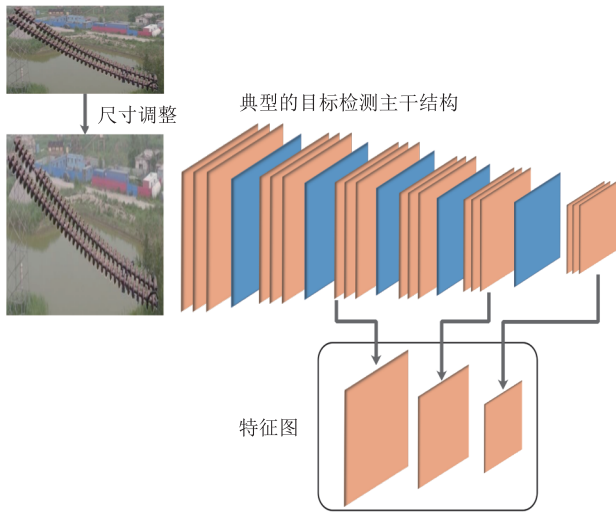


图 1 金字塔特征提取主干结构

Fig. 1 Backbone structure extraction based on pyramid feature

图 2 为目标检测中的预选框设置，在目标检测中，对于每一个特征图组中每一层特征图上的像素点，系统设置了多组预选框作为参考，预选框中心点的位置是由像素点所处特征图的相对位置映射到原图的位置所确定的；预选框的宽高则是参考原图上的坐标点设置的。当预选框被设置完成后，类似于系统的参考基准也相应被设置完成。

图 3 为目标检测汇总的像素点分类框回归，系统通过预选框作为参考，将不同分辨率的特征图合并成单一的特征点后，对特征点进行回归以




图 2 目标检测中的预选框设置

Fig. 2 Pre-selection box setting in target detection

及分类，最终得到每个特征点预测的类别及相对于原图的位置，即系统完成了目标检测过程中的定位。目标检测的过程，是系统对现有的主干特征提取网络进行优化的过程，与现有的模型相比，优化过后的模型更加精确，具有更快的预测速度。




图 3 目标检测中像素点的分类框回归

Fig. 3 Classification frame regression of pixels in target detection

### 2.2 双层金字塔模块

如图 4 所示的网络设计过程中，本文使用的网络模型如下：图片依次进入 (Plain Convolution, PC) 结构中进行采样，除首个图片经普通卷积 PC 结构采样后不利用样本归一化 (Batch Normalization, BN) 结构进行归一化，其他图片均利用 BN 结构进行归一化。在实验过程中发现，BN 层使模型具有更好的收敛性。经过上述步骤，模型提取的特征属性的水平维度分别相对于原图片为：1/2、1/4、1/8、1/16、1/32，此时提取模型类似一层金字塔模型；随后，系统对之前提取的特征集进行通道合并，然后再进行上采样，最终获得另外一层金字塔模型；最后将之前提取的不同分辨率的特征当作主干特征提取的特征图组，作为后续进行目标检测过程中的特征图组。

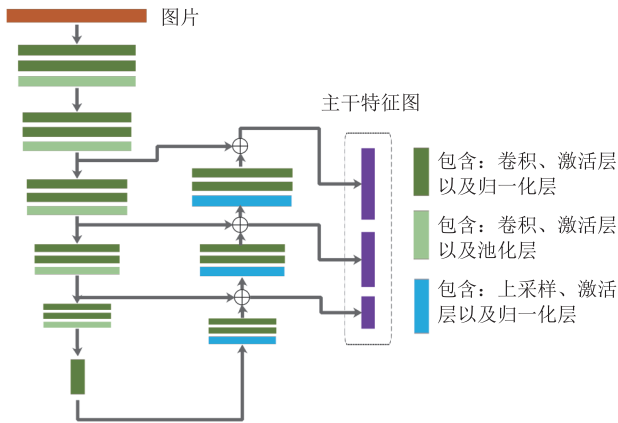


图 4 双层金字塔结构

Fig. 4 Double pyramid structure

为增强模型的表达能力, 本文设计了如图 5 所示的各种类型子模块。这些模块相当于注意力机制的模拟操作, 能使网络在通道、分辨率等维度上进行自适应学习得到相关的重要特征, 且能够过滤掉噪声等影响因素。图片分别代表 PC、上采样卷积 (Upsample Convolution, UC)、竖直卷积 (High-resolution Convolution, HC)、水平卷积 (Width-resolution Convolution, WC) 等 4 个结

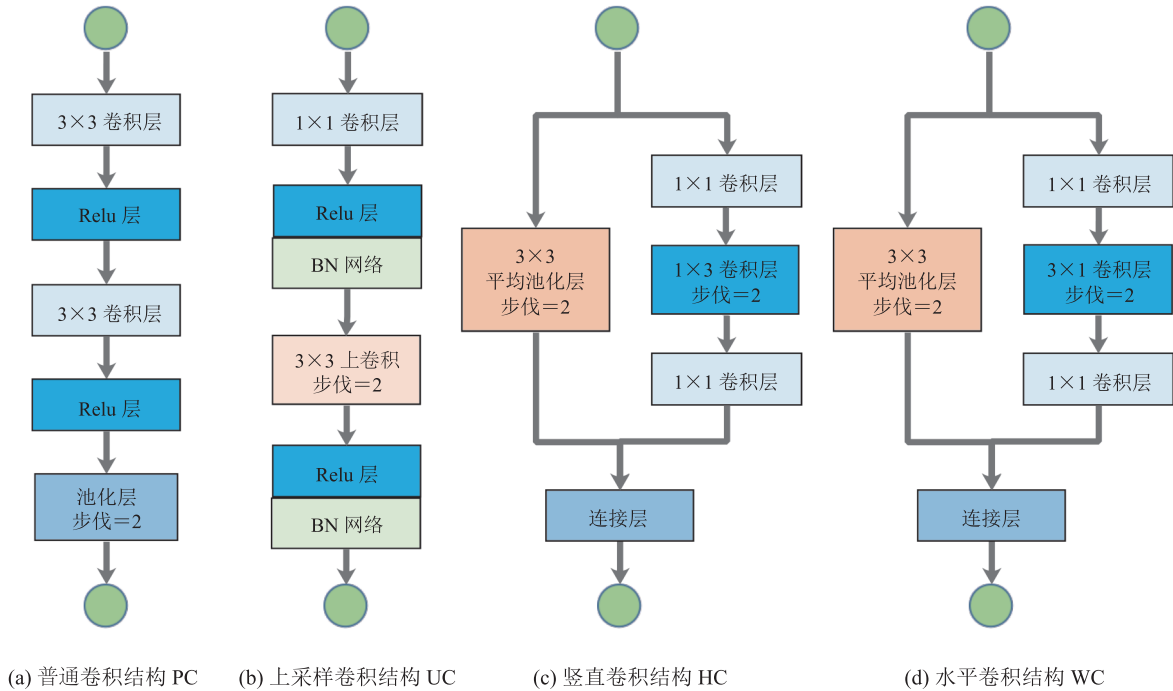


图 5 各种类型子模块

Fig. 5 Various types of sub modules

构, 其中, 普通卷积结构 PC 与上采样卷积结构 UC 主要用于主干特征结构提取, 而竖直卷积结构 HC 与水平卷积结构 WC 偏重于提取网络中的竖直特征以及水平特征。

本文结合上述 3 种模块, 设计了如图 6 所示的多通道特征提取子模块, 利用竖直卷积结构、普通卷积结构和水平卷积结构分别对原图进行特征提取, 然后通过通道合并获取最终的特征属性, 该结构是双层金字塔结构绿色模块的详细内容。

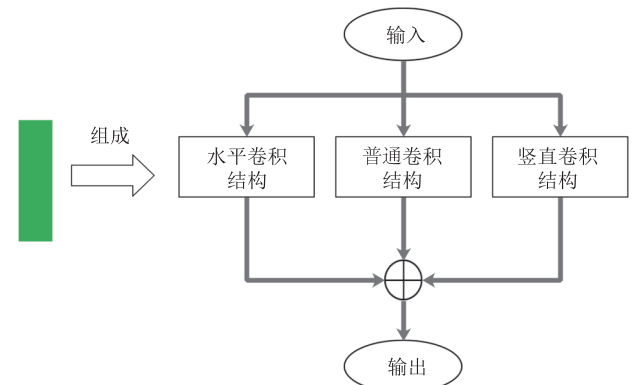


图 6 多通道特征提取子模块

Fig. 6 Multi-channel feature extraction sub module

### 2.3 深度可分离卷积

为便于网络模块实时运行在无人机嵌入式设备上, 本文使用深度可分离卷积对网络进行优化, 优化结果表明, 在损失精度可接受范围内, 深度可分离卷积能够降低计算量。卷积核优化过程如图 7 所示, 深度可分离卷积将普通卷积操作分解成逐通道卷积操作和逐点卷积操作。逐通道卷积运算得到的特征图通道数和输入通道数一致。在逐通道卷积过程中, 不同通道间的特征图是独立的, 不能利用属于不同通道的特征间联系。因此, 本文利用逐点卷积操作来进行卷积操作, 增强了不同通道之间的特征联系, 其卷积核一般设置为  $1:1:n$  ( $n$  为输入通道数量)。本文通过调节中间过程的输出通道数量及输出分辨率大小, 控制深度可分离卷积的运算量, 从而平衡检测速度与准确度。




图 7 深度可分离卷积模块

Fig. 7 Deep separable convolution module

## 3 损失函数与评价指标

### 3.1 损失函数

假定训练过程中训练每一个索引为  $i$  的预选框, 则训练过程中最小化的多层损失函数如公式(1)所示。

$$L=L_{\text{cls}}(p_i, p_i^*)+\lambda_1 p_i^* L_{\text{box}}(b_i, b_i^*)+\lambda_2 \|w\|^2 \quad (1)$$

其中,  $L_{\text{cls}}(p_i, p_i^*)$  为分类损失函数训练当前预选框的类别是前景还是背景,  $p_i$  为预测当前预选框为前景的概率值,  $p_i^*$  为标签的概率值,  $L_{\text{cls}}$  为使

用 softmax 作为损失函数训练;  $L_{\text{box}}(b_i, b_i^*)$  为伞裙破损框回归损失函数对候选框的回归预测,  $b_i=\{cx_i, cy_i, w_i, h_i\}$  为模型预测结果的中心点坐标以及长宽,  $b_i^*=\{cx_i^*, cy_i^*, w_i^*, h_i^*\}$  为伞裙破损的目标标签;  $\|w\|^2$  为权重衰减的方式, 它能使模型中的参数权重尽量接近于 0, 从而避免过拟合;  $\lambda_1, \lambda_2$  为调整训练过程中训练偏重程度的参数, 本文设置  $\lambda_1, \lambda_2$  分别为 0.5 和 0.1。

### 3.2 评估指标 AP

在目标检测算法中, 以两个矩形框面积的交集和并集的比值 (Intersection Over Union Value, IOU 值) 是否大于某个值 (通常使用 0.5), 来界定评估目标是否被检测出来, 其计算公式如下:

$$IOU_{(A,B)}=(A \cap B)/(A \cup B) \quad (2)$$

根据 IOU 可得出准确率-召回率 (Precision-Recall, P-R) 曲线图, 曲线平滑处理后, 计算曲线下的面积即可得出最终的 AP 指标。

## 4 结果

本节将介绍训练的数据集、实验环境、训练参数, 并对实验结果进行比较分析。此外, 本文还采用多种方式对样本进行数据增强, 解决了目标样本较少的问题。

### 4.1 训练数据集

本文采用无人机巡检的方式进行数据采集。首先, 直接对伞裙区域进行裁剪, 然后对伞裙区域内的破损区域进行标注。本文训练集为 248 张图片, 测试集为 24 张图片。每张伞裙图片中均有伞裙破损部分, 所使用的图片为 RGB 通道图片。图 8 为部分伞裙数据。

### 4.2 实验环境

本文训练环境为 Ubuntu 18.04, 利用单卡的 Titan XP 和深度学习框架 TensorFlow 1.14.0 进行训练, 训练时间约为 10 h。测试时则利用 CPU (型号为: i9-9880H, 8 核 16 线程) 进行测试。



图 8 部分伞裙数据

Fig. 8 Samples of insulator skirt data

### 4.3 训练参数

训练过程中, 本文使用 随机梯度下降 (Stochastic Gradient Descent, SGD) 算法作为优化器训练网络, 训练参数如表 1 所示。该模型不断利用随机梯度下降算法进行迭代优化, 如公式(3)所示, 并更新权重等参数。

$$x_{t+1} = x_t - \eta_t \nabla f(x_t) \quad (3)$$

将随机梯度看成一个平面, 那么  $x_t$  为第  $t$  步的位置;  $\nabla f(x_t)$  为导数;  $\eta_t$  为步长。

表 1 训练参数设置

Table 1 Training parameter setting

学习率	训练批次	优化器	回合	单次步长
0.01	14	SGD	100	1 000

### 4.4 实验结果分析

将上述数据在不同模型上进行训练及测试。在训练过程中, 为解决样本量过少的问题, 本文采用了随机裁剪、随机亮度、随机旋转、尺度变换(Random Scale)及随机图像差值的方式, 对图像进行裁剪、缩放(Random Crop), 以增加样本

数据。将 SSD MobileNetV1 和 SSD MobileNetV2 作为对比模型, 对本文模型性能进行测试, 测试结果如表 2 所示。

表 2 第 2 列为阈值 IOU 在 0.5~0.9 之间 AP 值的平均值(间隔为 0.05)。与轻量级网络模型 SSD MobileNetV1 和 SSD MobileNetV2 相比, 本文模型 1 (Pymidnet+ 多通道模块) 具有更好的 AP 指标, 达到 88%。在确保准确率的同时, 模型 1 的图片检测时间比 MobileNetV1 快, 仅比 MobileNetV2 多 0.001 s。此外, 为进一步提高检测速度, 本文采用双层金字塔模型及深度可分离卷积优化卷积, 与 MobileNetV1 和 MobileNetV2 相比, 该模型在 AP 略有下降的同时, 检测速度分别提升了 16% 和 8.7%。当 IOU 阈值为 0.5 时, 经过训练的两种 SSD 模型和本文模型在测试集上评估的 AP 值均为 1。通过对比表 2 的前两列可知, 随着阈值 IOU 的增加, 前两种模型的 AP 值下降明显, 而本文模型的 AP 值相对稳定。表 2 的第 4 列为 IOU 在 [0.5,0.95] 上所有召回率

表 2 模型结果对比

Table 2 Comparison of different model results

模型	0.5≤IOU≤0.9 时 AP	IOU=0.5 时 AP	0.5≤IOU≤0.95 时 AR	耗时 (s)
SSD MobileNetV1	0.851	1	0.896	0.025
SSD MobileNetV2	0.870	1	0.912	0.023
Pymidnet+ 多通道	0.880	1	0.918	0.024
Pymidnet+ 深度可分离卷积	0.850	1	0.893	0.021

的平均值 AR, 为本文模型 1 (Pymidnet+ 多通道模块) 优于 MobileNetV1 和 MobileNetV2 的准确率提供了佐证。

在测试集上对本文模型进行 mAP 评测, 评测结果如图 9 所示。当 IOU=0.5 时, 伞裙破损区域检测的 AP 指标高达 0.956 6。通过测试表明, 在不同强度光照环境、破损模糊等特殊条件下, 本文算法均能完成伞裙破损检测, 如图 10 所示。




图 9 mAP 测试集评测指标

Fig. 9 Test set evaluation index mAP

## 5 结论

本文利用深度学习算法对航拍伞裙图片进行分析, 使用正金字塔结构及倒立金字塔结构网络, 提取伞裙绝缘子图片中的不同高低级语义特征, 并将提取到的语义特征作为目标定位要素, 有效提升了伞裙破损检测的效果。本文主要的创新点如下: (1) 提出一种双层金字塔模型提取图片特征, 可有效防止网络过深而造成有用信息被过滤掉; (2) 使用多通道提取模块, 充分提取图片的各种特征图; (3) 使用深度可分离卷积优化卷积核, 减少了模型的计算量, 使得模型能够实时地运行于嵌入式设备上。

## 参考文献

- [1] 汤明文, 戴礼豪, 林朝辉, 等. 无人机在电力线路巡视中的应用 [J]. 中国电力, 2013, 46(3): 35-38.  
Tang MW, Dai LH, Lin CH, et al. Application of unmanned aerial vehicle in inspecting transmission lines [J]. Electric Power, 2013, 46(3): 35-38.
- [2] 王旭红, 李浩, 樊绍胜, 等. 基于改进 SSD 的电力设备红外图像异常自动检测方法 [J]. 电工技术学




图 10 伞裙破损检测结果

Fig. 10 Inspection results of insulator skirt damage

- 报, 2020, 35(S1): 302-310.
- Wang XH, Li H, Fan SS, et al. Infrared image anomaly automatic detection method for power equipment based on improved single shot multi box detection [J]. Transactions of China Electrotechnical Society, 2020, 35(S1): 302-310.
- [3] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [4] Schmidhuber J. Deep learning in neural networks: an overview [J]. Neural Networks, 2015, 61: 85-117.
- [5] 李子姝, 谢人超, 孙礼, 等. 移动边缘计算综述 [J]. 电信科学, 2018, 34(1): 87-101.
- Li ZS, Xie RC, Sun L, et al. A survey of mobile edge computing [J]. Telecommunication Science, 2018, 34(1): 87-101.
- [6] Ren SQ, He KM, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [7] 魏韬, 杨恒, 时磊, 等. 基于 Faster RCNN 的绝缘子自爆缺陷识别 [J]. 电瓷避雷器, 2019, (3): 183-189.
- Guo T, Yang H, Shi L, et al. Self-explosion defect identification of insulator based on Faster RCNN [J]. Insulator and Surge Arresters, 2019, (3): 183-189.
- [8] Redmon J, Farhadi A. YOLOv3: an incremental improvement [J]. arXiv Preprint, arXiv: 1804.02767, 2018.
- [9] 颜宏文, 陈金鑫. 基于改进 YOLOv3 的绝缘子串定位与状态识别方法 [J]. 高电压技术, 2020, 46(2): 423-432.
- Yan HW, Chen JX. Insulator string positioning and state recognition method based on improved YOLOv3 algorithm [J]. High Voltage Engineering, 2020, 46(2): 423-432.
- [10] 高金峰, 吕易航. 航拍图像中绝缘子串的认识与分割方法研究 [J]. 郑州大学学报(理学版), 2019, 51(4): 16-22.
- Gao JF, Lv YH. Research on recognition and segmentation of insulator string in aerial images [J]. Journal Zhengzhou University (Natural Science Edition), 2019, 51(4): 16-22.
- [11] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multibox detector [C] // Proceedings of the European Conference on Computer Vision, 2016: 21-37.
- [12] 吴涛, 王伟斌, 于力, 等. 轻量级 YOLOv3 的绝缘子缺陷检测方法 [J]. 计算机工程, 2019, 45(8): 275-280.
- Wu T, Wang WB, Yu L, et al. Insulator defect detection method for lightweight YOLOv3 [J]. Computer Engineering, 2019, 45(8): 275-280.
- [13] Tao X, Zhang DP, Wang ZH, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2020, 50(4): 1486-1498.
- [14] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [15] Jiang H, Qiu XJ, Chen J, et al. Insulator fault detection in aerial images based on ensemble learning with multi-level perception [J]. IEEE Access, 2019, 7: 61797-61810.
- [16] Sandler M, Howard A, Zhu ML, et al. MobileNetV2: inverted residuals and linear bottlenecks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.