

基于改进 Faster R-CNN 输电线穿刺线夹及螺栓的检测

薛阳, 吴海东*, 张宁, 俞志程, 叶晓康, 华茜

上海电力大学自动化工程学院, 上海 200090

摘要 针对输电线上穿刺线夹及螺栓易受光照、遮挡、环境背景、拍摄角度等因素影响, 提出了一种基于改进 Faster R-CNN 的检测方法。对获取的数据采用翻转、平移、角度旋转等方式增强数据集; 再对比不同数量训练集对模型的影响; 由于螺栓体积很小, 使用网络深度更深、运算量更小的深度残差网络(ResNet50)代替 VGG-16 (Visual Geometry Group 16) 网络并对图像进行特征提取; 分析不同模型和参数对识别精确度的影响。结果表明, 改进 Faster R-CNN 模型的 mAP 值达到 92.4%, 与未改进的 Faster R-CNN 模型相比提高 2.8 个百分点。利用深度学习目标检测模型能更好地检测不同分辨率和不同位置角度的穿刺线夹及螺栓, 该模型具有较高的工程实用价值。

关键词 图像处理; 穿刺线夹; 目标检测; 改进 Faster R-CNN; 残差网络

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP57.081008

Detection of Insulation Piercing Connectors and Bolts on the Transmission Line Using Improved Faster R-CNN

Xue Yang, Wu Haidong*, Zhang Ning, Yu Zhicheng, Ye Xiaokang, Hua Xi

School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China

Abstract In this study, we propose a method based on improved Faster R-CNN with respect to the influence of light penetration, occlusion, environmental background, and shooting angle on the insulation piercing connectors and bolts on the transmission line. First, we enhanced the acquired datasets via flipping, panning, and angle rotation. Second, we compared the influences of different training sets on the model. Finally, we used a deep residual network (ResNet50) having a considerable network depth and less amount of computation to replace the VGG-16 (Visual Geometry Group 16) network for extracting the image features owing to the small size of the bolt. Further, we analyzed the influences of different models and parameters on the identification accuracy. The result proves that the improved Faster R-CNN model has an mAP value of 92.4%, which is 2.8 percentage higher than that of the unmodified Faster R-CNN model. The deep learning target detection model can be used to appropriately detect and identify the insulation piercing connectors as well as bolts having different resolutions and position angles. Therefore, this model has a high engineering application value.

Key words image processing; insulation piercing connectors; target detection; improved Faster R-CNN; residual network

OCIS codes 100.3008; 100.3005; 100.4996

收稿日期: 2019-07-16; 修回日期: 2019-08-15; 录用日期: 2019-09-10

基金项目: 国网浙江省电力有限公司科技项目(5211HZ17000F)、国家自然科学基金青年基金(51405286)、上海市电站自动化技术重点实验室(13DZ2273800)

* E-mail: 15221167190@163.com

1 引言

随着电力技术的不断发展以及社会对供电安全和稳定性的要求不断提高,安全作业在各电力技术行业中越来越重要。绝缘杆作业法是在传统高压输电线上使用绝缘穿刺线夹固定引线和母线,作业人员需戴绝缘手套,穿绝缘靴,使用绝缘工具进行作业,该方法存在劳动强度大、效率低和自动化水平低等问题。目标识别和检测技术及机器人技术在替代人工作业部分显得极其重要,其中目标检测技术可用于识别和检测绝缘穿刺线夹,为后续操作提供准确定位,因此研究目标识别技术替代人工作业部分具有重要意义。

目前,目标检测技术在电力方面的应用主要是高压输电线的巡检,搭载摄像头的无人机巡线通过摄像头采集电气设备图片,具有操作灵活、成本低的特点。检测和识别电气设备的常用方法有数字图像处理技术^[1]、机器学习^[2]和深度学习^[3-4]。其中数字图像处理方法作为传统图像处理方法,以图像二值化和边缘检测为基础,包括正交归一化小波即 Haar 小波^[5]、显著性检测^[6-7]以及图像分割^[8]等方法,如基于数字图像处理提取绝缘子的图像边缘,进而识别绝缘子^[9],基于绝缘子的纹理特征进行绝缘子的定位^[10]。虽然上述方法在一定范围内能识别绝缘子,但该方法受外部环境、背景、光线等影响,采集的图像易受噪声干扰,泛化能力不强。对于机器学习方法,采用 AdaBoost (Adaptive Boosting) 算法提取图像中目标的几何特征与形状特征,能够建立较好的模型,但参数的设置以及特征点的选择都依赖于设计者的经验,因而泛化性以及识别精度均有待提高^[11]。近年来,

由于深度学习不需要进行人工特征提取,算法自动学习获得目标特征,适用性强、目标检测效率更高,以深度学习理论为支撑的计算机视觉类方法已成为图像目标检测的研究热点,常用的目标检测算法有区域卷积神经网络 (R-CNN)^[12]、Fast R-CNN^[13]、YOLO (You Only Look Once)^[14]、SSD (Single Shot multiBox Detector)^[15]和 Faster R-CNN^[16-17]。

综上所述,本文在 Faster R-CNN 模型的基础上提出基于改进 Faster R-CNN 的模型,用于检测输电线穿刺线夹及螺栓。通过对数据的采集以及数据的增强,建立了穿刺线夹及螺栓图像的样本库。由于螺栓体积很小,使用网络深度更深、运算量更小的深度残差网络 (ResNet50) 代替 VGG-16 (Visual Geometry Group 16) 网络对图像进行特征提取,使网络更好地收敛。

2 基于 Faster R-CNN 的检测原理

基于 Faster R-CNN 的输电线穿刺线夹及螺栓的检测流程为:1) 将穿刺线夹及螺栓图像输入模型中,经 VGG-16 卷积神经网络提取得到特征图;2) 将特征图传入区域生成网络 (RPN) 中,提取包含目标概率更高的若干区域;3) 感兴趣区域 (RoI) 池化层将不同大小的输入特征转换为固定长度的输出特征;4) 通过分类和回归层实现对穿刺线夹的分类和检测。第一组分类和回归在 RPN, 分类检测是否有穿刺线夹或螺栓,属于二分类问题,回归进行候选区域的初步选取;第二组分类和回归在 RoI 池化层后的预测网络,分类为目标物体的分类,第一类是穿刺线夹,第二类是螺栓,回归为确定候选区域在图像中的精确位置。Faster R-CNN 模型如图 1 所示。

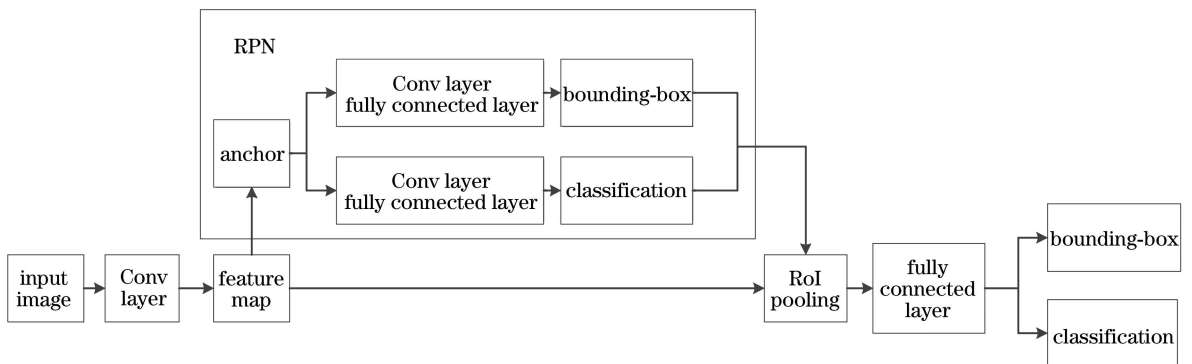


图 1 穿刺线夹及螺栓图像检测的 Faster R-CNN 模型

Fig. 1 Faster R-CNN model for detecting images of insulation piercing connectors and bolts

2.1 基于 RPN 生成候选区域

基于 RPN 生成候选区域的模型如图 2 所示,其

中 NMS 为非极大值抑制。feature map 为卷积神经网络输出的最后一层特征图,在此基础上再作一

次卷积,生成的 256 个特征图;RPN 对生成 256 个特征图分别作分类和回归;分类层(classification)输出预测属于前景或背景的概率;候选框回归层输出预测框(bounding box)的 4 个参数。训练 RPN 的损失函数为

$$L(\{p_i\}, \{t_i\}) = \sum_i L_{cls}(p_i, p_i^*) / N_{cls} + \lambda \sum_i p_i^* L_{reg}(t_i, t_i^*) / N_{reg}, \quad (1)$$




图 2 RPN 模型

Fig. 2 RPN model

Faster R-CNN 传入 RPN 特征图上的每一个滑动窗口均使用 9 个锚点,每一个锚点又可以由一个比例,一个长宽比及滑动窗口中的锚点唯一确定,产生的 9 个锚点由 3 种尺度和 3 种长宽比组合而成。9 个锚点映射回输入图的效果如图 3 所示。




图 3 不同尺度和长宽的锚点

Fig. 3 Anchors of different scales and lengths

2.2 基于 RoI 池化层特征维度归一化

RoI 池化层是在空间金字塔池化(SPP)^[18]层的基础上进行改进,最后一层卷积层得到的 256 个特征图下采样到大小为 7×7 的网络中,对每个网格进行最大池化(max pooling)处理,再将不同大小的特征变成统一大小的特征向量,如图 4 所示,确保每个不同大小的窗口具有相同的维度,形成固定大小的特征图以便进行全连接操作。

3 改进 Faster R-CNN 输电线穿刺线夹及其螺栓的检测

在 Faster R-CNN 目标检测模型的基础上进行改进,Faster R-CNN 模型和改进 Faster R-CNN 模型结构如图 5 所示。针对穿刺线夹螺栓体积小、图像分辨率较低的特点,利用卷积层深度残差神经网络(ResNet)替换 VGG-16 网络,因 ResNet50 深度

式中: i 为批量梯度下降(mini-batch)中第 i 个锚点(anchor); p_i 为第 i 个锚点是前景的概率,当第 i 个锚点是前景时 p_i^* 为 1,反之则为 0; t_i 为预测候选框的坐标; t_i^* 为真实框的坐标; L_{cls} 为分类损失函数; L_{reg} 为回归损失函数,其中 $p_i^* L_{reg}$ 表示只对正样本进行回归; N_{cls} 为一次传入锚点的数量; N_{reg} 为锚点位置的数量; λ 为权重参数。




图 4 RoI 池化网络

Fig. 4 RoI pooling network

更深,运算量更小,可提取丰富的特征传给后面的网络。

ResNet50 残差块结构如图 6 所示,其中 x 为残差块输入, $F(x)$ 为残差映射,ReLU 为激活函数。在标准的前向传播神经网络上,加一个跳跃绕过一些层的连接,直接将输入信息 x 绕道传到输出,每绕过一层就产生一个残差块。ResNet50 在一定程度上解决信息传递时,出现信息丢失、梯度爆炸和梯度消失等情况。

残差块可用公式表示为

$$y = F(x, W_i) + x, \quad (2)$$

式中: y 为残差块的输出; $F(x, W_i)$ 为学习到的残差映射; W_i 为第 i 层的权重,若包含第 2 层,则表示为

$$F = W_2 \sigma(W_1 x), \quad (3)$$

式中: W_1 为第 1 层的权重; W_2 为第 2 层的权重; σ 为非线性函数,即 ReLU。

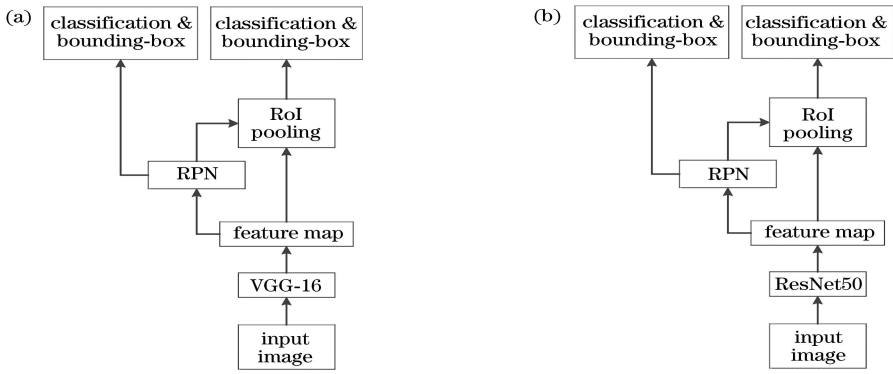


图5 模型结构。(a)Faster R-CNN 模型;(b)改进 Faster R-CNN 模型

Fig. 5 Model structure diagram. (a) Faster R-CNN model; (b) improved Faster R-CNN model




图6 ResNet 残差块结构

Fig. 6 Residual block structure diagram of ResNet

4 巡检图像目标检测性能仿真测试

4.1 实验环境

实验采用 TensorFlow 作为深度学习框架,使用 GPU 对训练过程进行加速,其使用的硬件配置为 i5 处理器、16 G 内存、NVIDIA TITAN RTX 显卡;软件环境为 Windows10 系统 Python3.6;GPU 加速库采用 CUDA10.0 和 CUDNN7.4。

4.2 数据集和评价指标

对获取的数据集采用翻转、平移、角度旋转等方式增强数据集,其中 3000 张图像样本作为训练集,300 张图像样本作为测试集。采用精确度均值 (AP)来衡量单个类别检测效果,精确度为标记正确的边界框个数与标记出的所有边界框个数之比。对比不同主流卷积神经网络与设计模型的检测效果,分析不同参数对均值平均精度 (mAP)的影响。

4.3 实验结果与分析

卷积神经网络在提取特征时,输入的样本数量对网络训练影响很大,则采用不同数量的训练样本

训练改进 Faster R-CNN 模型,实验使用的图片数量分别为 1500 张和 3000 张,最大迭代次数为 20000 次,测试集图片数量为 300 张,结果对比如表 1 所示。比较不同训练集数量的 mAP 值,发现 1500 张训练的模型和 3000 张训练的模型的 mAP 值由 91.0% 提高到 92.4%,提高了 1.4 个百分点。可以看到,训练集数量越大,模型检测精度越高。

表 1 不同训练样本数量结果对比

Table 1 Comparison of results obtained from different training sample amount

Number of images	AP of insulation piercing connector / %	AP of bolt / %	mAP / %
1500	91.8	90.2	91.0
3000	93.3	91.5	92.4

采用不同卷积神经网络训练 Faster R-CNN 模型,分别基于 ZFNet(Zeiler & Fergus Net)、VGG-16 和 ResNet50 卷积神经网络提取特征。训练集数量为 3000 张,最大迭代次数为 20000 次,其他参数不变,结果对比如表 2 所示。比较 3 种不同神经网络结构的 Faster R-CNN 模型发现,ZFNet 深度最小,mAP 值为 87.3%,VGG-16 网络深度较深,mAP 值为 89.6%,ResNet50 最深,mAP 值为 92.4%,可以看到基于 ResNet50 的 Faster R-CNN 检测模型的检测精度高于基于 ZFNet 和 VGG-16 的 Faster R-CNN 检测模型,使用 ResNet50 替换 VGG-16 网络作为基础网络改进 Faster R-CNN,mAP 值提高了 2.8 个百分点。因此,网络深度越大,特征的提取效果越好,检测精度越高。

第一阶段候选框是使用 NMS 方法生成。保持一次训练所选取批量大小(batch size)不变,减少候选框数量时,mAP 值逐渐降低,由 92.4% 降到 88.5%,如表 3 所示。使用 NMS 方法抑制交并比 (IoU) 值低的候选框,再从结果选取 IoU 值高的候选框,经 NMS

表2 基于三种不同网络的 Faster R-CNN 模型结果对比

Table 2 Comparison of Faster R-CNN model results based on three different networks

Model	AP of insulation piercing connector / %	AP of bolt / %	mAP / %
Faster R-CNN+ ZFNet	88.2	86.4	87.3
Faster R-CNN+ VGG-16	90.3	88.9	89.6
Faster R-CNN+ ResNet50	93.3	91.5	92.4

表3 第一阶段 NMS 后不同候选框个数对 mAP 的影响对比

Table 3 Comparison of effects of different number of proposals after first stage NMS on mAP

Model	Number of proposals	Batch size in RPN stage	Batch size in 2 nd stage	mAP / %
Faster R-CNN+ ResNet50	300	128	64	92.4
	250	128	64	91.1
	200	128	64	90.3
	150	128	64	88.5

表4 不同批量大小对 mAP 的影响对比

Table 4 Comparison of effects of different batch sizes on mAP

Model	Number of proposals	Batch size in RPN stage	Batch size in 2 nd stage	mAP / %
Faster R-CNN+ ResNet50	300	128	64	92.4
	300	64	32	91.6
	300	32	16	89.4

Faster R-CNN+ResNet50 与目前流行的目标检测模型 SSD 和 YOLO v3 进行对比,在训练集数量为 3000 张,最大迭代次数为 20000 次,其他参数不变的条件下训练模型,并对测试集进行测试,结果如表 5 所示。改进 Faster R-CNN 模型的 mAP 值

表5 不同目标检测模型对 mAP 的影响对比

Tab 5 Comparison of effects of different object detection models on mAP

Model	AP of insulation piercing connector / %	AP of bolt / %	mAP / %	Time per image / ms
Faster R-CNN+ ResNet50	93.3	91.5	92.4	2639
SSD	84.5	80.3	82.3	68
YOLO v3	85.6	83.5	84.6	44

改进 Faster R-CNN 模型对穿刺线夹和螺栓的部分检测结果如图 7 所示。图 7(a)中螺栓垂直向里,图 7(b)中螺栓向下,图 7(c)中螺栓向上,图 7(d)中螺栓受自身线夹遮挡,在不同拍摄角度下,模型均能准确地检测出输电线上的穿刺线夹和螺栓。

基于改进 Faster R-CNN 输电线穿刺线夹及其

后的候选框数目减少,导致预测框不能很好地框出线夹和螺栓,从而使 mAP 值降低,当候选框数目过多时,计算量大,此时选取 300 个候选框为宜。

保持候选框个数不变,改变批量大小,采用随机梯度下降法进行训练,由表 4 可以看到,随着批量大小的减小,mAP 值逐渐减小,由 92.4% 降到 89.4%。这是因为当批量大小越大,一次运算所使用的样本越多,随机梯度下降算法的随机性会降低,就越接近梯度下降算法,从而使 mAP 值增大,但这样会导致计算量大,耗时长。因此选取适中的批量大小,既能保证速度又能保证高 mAP 值。

为 92.4%,与 SSD 模型(82.3%)和 YOLO v3 模型(84.6%)相比 mAP 值最高,但每张图片的检测速度最慢。可以看到,改进模型有较高的 mAP 值,但识别速度有待提高,说明模型在实时检测任务上存在一定缺陷,还需要提高模型的检测速度。

螺栓的检测网络结构和流程,如图 8 和图 9 所示。将穿刺线夹及其螺栓图像输入模型中,经 ResNet50 提取得到特征图;再将特征图传入 RPN 进行前景背景分类以及对矩形框进行回归生成候选区域;再对候选区域进行对应特征图提取并传入回归分类网络,通过分类和回归层实现对穿刺线夹的分类和检测。




图 7 改进 Faster R-CNN 模型检测螺栓的不同情况。(a)螺栓垂直向里;(b)螺栓向下;(c)螺栓向上;(d)螺栓受自身线夹遮挡
 Fig. 7 Detection results of improved Faster R-CNN model for connectors and bolts under different conditions.
 (a) Vertically inward bolt; (b) downward bolt; (c) upward bolt; (d) bolt shielded by its own wire clip

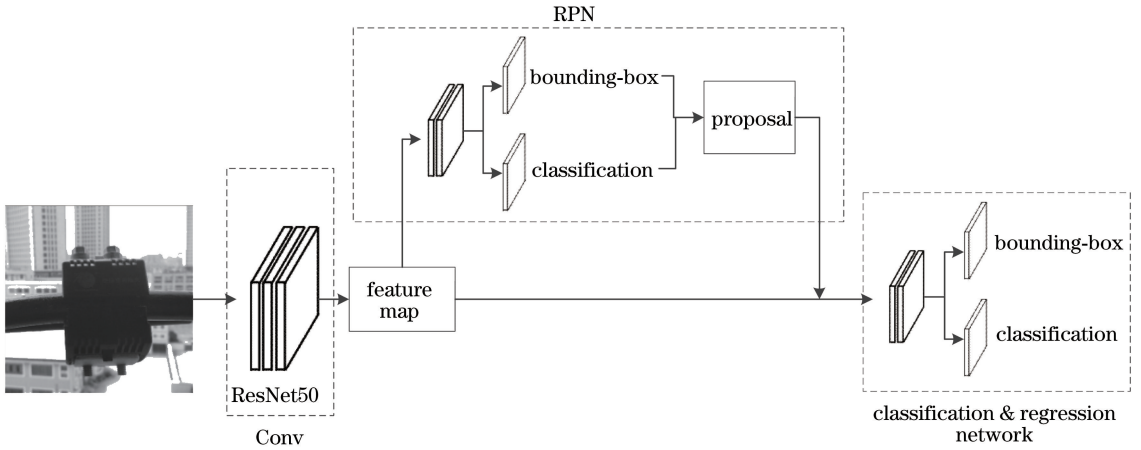


图 8 基于改进 Faster R-CNN 的输电线穿刺线夹及其螺栓的检测网络结构
 Fig. 8 Detection network structure of insulation piercing connectors and bolts on the transmission line based on improved Faster R-CNN




图 9 基于改进 Faster R-CNN 的输电线穿刺线夹及其螺栓的检测流程
 Fig. 9 Detection flow chart of insulation piercing connectors and bolts on the transmission line based on improved Faster R-CNN

5 结 论

针对输电线上穿刺线夹及螺栓易受光照、遮挡、环境背景、拍摄角度等因素影响,提出了一种基于改进 Faster R-CNN 的检测方法。该方法利用卷积神经网络自动提取特征,从各个角度对穿刺线夹及螺栓进行特征提取,更好地检测在不同分辨率和不同位置角度下的穿刺线夹及螺栓。实验获取的数据集采用翻转、平移、角度旋转等方式增强数据集,对比不同训练集数量训练模型的 mAP 值,结果表明,3000 张训练集图像比 1500 张训练集图像的训练效果更好,mAP 值更大;将 Faster R-CNN 检测模型

与 3 种卷积神经网络模型结合,结果表明,基于 ResNet50 的 Faster R-CNN 检测模型的 mAP 值高于基于 ZFNet 和 VGG-16 网络的 Faster R-CNN 检测模型,检测效果更好;对比了经 NMS 的候选框数目减少后的 mAP 值,结果表明,候选框数量减少导致 mAP 值降低;对比了不同批量大小,采用随机梯度下降法进行训练,结果表明,随着批量大小的减小,mAP 值逐渐减小;对比了改进 Faster R-CNN 模型与 SSD、YOLO v3 模型的识别准确率,结果表明,改进 Faster R-CNN 模型有较高的 mAP 值,但识别速度有待提高,说明模型在实时检测任务上存在一定缺陷,下一步还需要提高模型的检测速度。

参 考 文 献

- [1] Zhou F, Ren G X. Image classification and feature extraction of transmission line based on color space variable[J]. Power System Protection and Control, 2018, 46(5): 89-98.
周封, 任贵新. 基于颜色空间变量的输电线图像分类及特征提取[J]. 电力系统保护与控制, 2018, 46(5): 89-98.
- [2] Guo M W, Zhao Y Z, Xiang J P, et al. Review of object detection methods based on SVM[J]. Control and Decision, 2014, 29(2): 193-200.
郭明玮, 赵宇宙, 项俊平, 等. 基于支持向量机的目标检测算法综述[J]. 控制与决策, 2014, 29(2): 193-200.
- [3] Zhang H, Wang K F, Wang F Y. Advances and perspectives on applications of deep learning in visual object detection[J]. Acta Automatica Sinica, 2017, 43(8): 1289-1305.
张慧, 王坤峰, 王飞跃. 深度学习在目标视觉检测中的应用进展与展望[J]. 自动化学报, 2017, 43(8): 1289-1305.
- [4] Huang K Q, Ren W Q, Tan T N. A review on image object classification and detection[J]. Chinese Journal of Computers, 2014, 37(6): 1225-1240.
黄凯奇, 任伟强, 谭铁牛. 图像物体分类与检测算法综述[J]. 计算机学报, 2014, 37(6): 1225-1240.
- [5] Thompson A. The cascading Haar wavelet algorithm for computing the Walsh-Hadamard transform[J]. IEEE Signal Processing Letters, 2017, 24(7): 1020-1023.
- [6] Li Z M, Zhou C C, Gong Y H, et al. Saliency object detection based on domain transform and contour detection[J]. Journal of Computer-Aided Design & Computer Graphics, 2018, 30(8): 1457-1465.
李宗民, 周晨晨, 宫延河, 等. 结合域变换和轮廓检测的显著性目标检测[J]. 计算机辅助设计与图形学学报, 2018, 30(8): 1457-1465.
- [7] Dou Y, Chen M H, Duan L L. Salient region detection based on element contrast and boundary prior[J]. Chinese High Technology Letters, 2015, 25(2): 163-170.
窦燕, 陈美奂, 段亮亮. 结合基元对比度与边界先验的显著性区域检测[J]. 高技术通讯, 2015, 25(2): 163-170.
- [8] Jung H G. Analysis of reduced-set construction using image reconstruction from a HOG feature vector[J]. IET Computer Vision, 2017, 11(8): 725-732.
- [9] 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.
- [10] Yang C R. A detection method for insulators based on texture features[J]. Electrical Engineering, 2010(7): 46-48, 52.
杨翠茹. 基于纹理特征的绝缘子检测方法[J]. 电气技术, 2010(7): 46-48, 52.
- [11] Wu Y. Research on insulator recognition methods in aerial images based on machine learning[D]. Beijing: North China Electric Power University, 2016: 9-23.
伍洋. 基于机器学习的航拍图像绝缘子识别方法研究[D]. 北京: 华北电力大学, 2016: 9-23.
- [12] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE, 2014: 580-587.
- [13] Girshick R. Fast R-CNN [C] // Proceedings of the IEEE International Conference on Computer Vision, December 13-16, 2015, Santiago, Chile. New York: IEEE, 2015: 1440-1448.
- [14] Wei Y M, Quan J C, Hou Y Q Y. Aerial image location of unmanned aerial vehicle based on YOLOv2 [J]. Laser & Optoelectronics Progress, 2017, 54(11): 111002.
魏湧明, 全吉成, 侯宇青阳. 基于 YOLO v2 的无人机航拍图像定位研究[J]. 激光与光电子学进展, 2017, 54(11): 111002.
- [15] Hua X, Wang X Q, Wang D, et al. Multi-objective detection of traffic scenes based on improved SSD[J]. Acta Optica Sinica, 2018, 38(12): 1215003.
华夏, 王新晴, 王东, 等. 基于改进 SSD 的交通大场景多目标检测 [J]. 光学学报, 2018, 38(12): 1215003.
- [16] 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.
- [17] Feng X Y, Mei W, Hu D S. Aerial target detection based on improved faster R-CNN [J]. Acta Optica Sinica, 2018, 38(6): 0615004.
冯小雨, 梅卫, 胡大帅. 基于改进 Faster R-CNN 的

空中目标检测 [J]. 光学学报, 2018, 38 (6):
0615004.

[18] He K, Zhang X, Ren S, et al. Spatial pyramid

pooling in deep convolutional networks for visual
recognition [J]. IEEE transactions on pattern analysis
and machine intelligence, 2015, 37(9): 1904-1916.