

基于改进 Faster-RCNN 的输电线巡检图像多目标检测及定位

林 刚,王 波,彭 辉,王晓阳,陈思远,张黎明

(武汉大学 电气工程学院,湖北 武汉 430072)

摘要:针对输电线巡检图像受光线、环境和拍摄角度等因素影响,图像中的电气设备呈现低分辨率和多形态化特征的问题,提出一种基于改进 Faster-RCNN 的巡检图像多目标检测及定位方法。该方法首先通过区域建议策略网络生成若干目标候选区域;然后基于实际巡检图像样本库,对卷积神经网络进行训练,以改善参数学习效果;最后利用正则化方法优化参数权重,提高检测速度,得到适应巡检图像多形态化特征的改进型 Faster-RCNN 模型。实际场景数据集测试结果表明,相比于数字图像处理、浅层机器学习、单阶法、双阶法、Mask-RCNN 和 Local Loss 目标检测方法,所提改进型 Faster-RCNN 能够在不同分辨率和不同位置角度的巡检图像场景下保持较高的识别精度和速度,具有较高的工程实用价值。

关键词:区域建议;目标检测;特征提取;图像样本库;正则化

中图分类号:TM 755

文献标识码:A

DOI:10.16081/j.issn.1006-6047.2019.05.032

0 引言

输电线的巡检方式主要包括人工、直升机和无人机巡线,多种巡检方式的使用为监测线路工况提供现场实时视频或图像数据^[1],其中无人机巡线操作灵活、成本较低。巡检人员通过数字图像处理技术^[2]、浅层机器学习^[3]或深度学习^[4]方法观测图像中的电气设备,提高巡检故障发现效率,具有重要的工程实用价值。

数字图像处理以图像二值化和边缘检测为基础,包括 Haar 小波^[5]、显著性检测^[6]以及图像分割^[7]等方法。该类方法预先设定特征参数提取图像中的显著目标,但受环境、光线和拍摄角度的影响,巡检图像出现不同程度的畸变、模糊失真或噪声混入,造成图像质量下降。因此对于任一待检测巡检图像,该类方法需要人工选择最佳参数,导致处理效率不高且鲁棒性较差。

对于浅层机器学习方法,文献[8]基于动态贝叶斯网络完成对输电线路主要部件的故障分类,并建立故障诊断模型,由于数据来源杂乱、差异性较大,故障分析精度受到影响;文献[9]采用 AdaBoost 算法提取图像中目标的几何特征与形状特征,虽能较好地构建数据模型,但对于检测窗融合统一的参数与潜在特征点的选择均依赖设计者的先验知识,目标检测的泛化性和精度均有待提高。

与之相比,以深度学习理论^[10]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,其可分为单阶法和双阶法 2 类^[11]。双阶法包括区域卷积神经网络 RCNN (Region-Convolutional Neural Net-

work)^[12]及其优化算法 Fast-RCNN^[13]和 Faster-RCNN^[14],双阶法与单阶法的区别在于双阶法首先通过区域建议策略 RPS (Region Proposals Strategy) 生成若干目标候选域,进行特征提取后利用支持向量机识别目标类别,最后输出图像中的目标类型并标记其位置。文献[15]基于 Faster-RCNN 模型检测巡检图像电力小部件,训练卷积神经网络 CNN (Convolutional Neural Network) 时直接采用 ImageNet 数据库而非巡检图像,导致特征提取过程出现偏差,影响最终检测效果。Faster-RCNN 对 Pascal VOC 2012 数据集的处理速度为 47 ms/张,平均准确率 mAP (mean Average Precision) 比单阶法高 18.5%。文献[16]基于 Faster-RCNN 结构引入全连接分割子网,通过分布式计算将双阶法工作模式转变分类、回归和分割三者并行的方式,提高了检测精度和效率。

单阶法包括 YOLO (You Only Look Once) 算法和 SSD (Single Shot MultiBox Detector)^[17]等,其对 Pascal VOC 2007 以及 2012 数据集的处理速度达到 25 ms/张。单阶法虽在速度上存在一定的优势,但对尺寸较小或相互靠近的物体识别效果不佳。文献[18]提出在损失函数中引入控制函数,以改善训练过程中因样本不平衡导致的单阶法检测精度不佳的问题,但上述方法对实际巡检图像样本目标检测效果的准确性还有改进空间。

针对上述数字图像处理法、浅层机器学习、单阶法和双阶法存在的适应性、泛化性和准确性等问题,同时考虑到多数巡检图像包含尺寸较小的绝缘子、金具等电力器件,本文提出基于改进型 Faster-RCNN 的输电线路巡检图像多目标检测及定位模型。为保证模型特征提取的针对性和有效性,本文建立多标记的电力巡检图像样本库,以改善参数学习效果,并通过正则化优化模型结构,加快检测速度,从而提高巡检图像目标检测的工程实用性。

收稿日期:2018-02-14;修回日期:2019-03-05

基金项目:国家自然科学基金面上项目(51777142)

Project supported by the General Program of National Natural Science Foundation of China(51777142)

1 基于 Faster-RCNN 的巡检图像目标检测框架

本文基于 Faster-RCNN 对巡检图像进行目标检测,核心思路是通过区域建议策略,从待检测的巡检图像提取含目标概率更高的若干区域,进而检测目标电气设备。基于区域建议的巡检图像目标检测 Faster-RCNN 模型如图 1 所示。

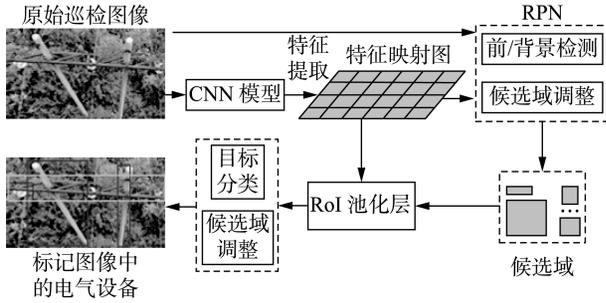


图 1 基于区域建议的巡检图像目标检测 Faster-RCNN 模型

Fig.1 Faster-RCNN model based on region proposals for inspection image target detection

对于任意 1 张/帧巡检图像,首先通过 CNN 进行特征提取,得到特征映射图;区域建议策略网络 RPN(Region Proposal Network)利用 softmax 激活函数计算映射图中每个特征点属于前景(目标)的概率,同时在原始图像的相应位置生成若干尺寸不一的候选域;感兴趣区域 RoI(Region of Interest)池化层将候选域映射为维度固定的特征向量,然后再次利用 softmax 判断候选域中的物体类别,其中,特征映射图作为位置索引,当同一设备的候选域发生合并时,特征映射图可辅助调整候选域尺寸和标记图像中的电气设备。

1.1 基于 CNN 的巡检图像特征提取

本文采用 VGG16 型 CNN 对输电线巡检图像进行特征提取,模型包括 13 个卷积层、13 个 ReLU 激活层以及 4 个池化层。

彩色巡检图像作为原始输入,假设第 l 层是卷积层,则该层的输出特征向量表示为:

$$\mathbf{x}_j^l = f\left(\sum_{i \in M_j} \mathbf{x}_i^{l-1} * \mathbf{k}_{ij}^l + \mathbf{b}_j^l\right) \quad (1)$$

其中, \mathbf{x}_j^l 为该层第 i 个输出; \mathbf{k}_{ij}^l 为该卷积层的一个卷积核; * 表示卷积操作; \mathbf{b}_j^l 为该卷积层偏置; $f(\cdot)$ 为 ReLU 激活函数,即 ReLU 层计算公式。

假设第 m 层是池化层,则输出特征向量的表达式如式(2)所示。

$$\mathbf{x}_j^m = f(\beta_j^m \text{down}(\mathbf{x}_j^{m-1}) + \mathbf{b}_j^m) \quad (2)$$

其中, β_j^m 为连接权重; $\text{down}(\cdot)$ 表示对输入矩阵求和; \mathbf{x}_j^{m-1} 为该池化层的输入; \mathbf{b}_j^m 为该池化层的偏置; $f(\cdot)$ 为 softmax 激活函数。

1.2 基于区域建议策略的候选域生成方案

基于区域建议策略的 RPN 模型如图 2 所示。

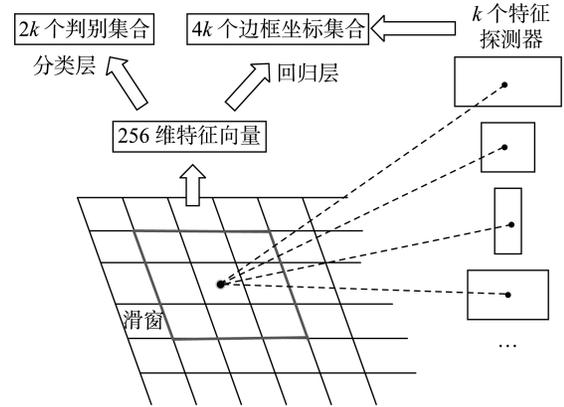


图 2 基于区域建议策略的 RPN 模型

Fig.2 RPN based on region proposals strategy

RPN 执行 2 步操作:

a. 在分类层,检测该候选区域是否包含目标电气设备,2 个输出节点分别表示属于前景或背景的概率;

b. 在回归层,使用特征探测器分别预测目标候选区域的中心点坐标 (x, y) 和候选区域的宽 w 、高 h 。

1.2.1 分类层

用 3×3 卷积核滑动窗口遍历特征图,为保证多尺度检测,本文设置卷积核类型 $k=9$,候选域的长宽比分别取 1:1、1:2 和 2:1,每种长宽比例又分别设置 3 种面积。

遍历后的信息利用 softmax 激活函数计算特征图中每个元素属于前景目标的概率 P ,选取 P 最高的前 300 个区域作为目标检测候选域。

1.2.2 回归层

本文使用交并比 IoU (Intersection over Union) 作为衡量候选域框定准确度的指标,计算公式如式(3)所示。

$$\text{IoU} = (A \cap B) / (A \cup B) \quad (3)$$

其中, A 和 B 为 2 个候选域面积。

候选域用四维向量 (x, y, w, h) 来表示, x, y 和 w, h 分别为窗口的中心点坐标和边界的宽、高, (P_x, P_y, P_w, P_h) 、 (G'_x, G'_y, G'_w, G'_h) 和 (G_x, G_y, G_w, G_h) 分别代表 RPN 标定、预测和人工标定的候选域。

IoU 窗口自回归可修正原始目标候选区域的边框,使之接近实际标定边框,调整过程包括平移缩放和尺度缩放。

a. 平移缩放:

$$G'_x = P_w d_x(P) + P_x, G'_y = P_h d_y(P) + P_y \quad (4)$$

b. 尺度缩放:

$$G'_w = P_w e^{d_w(P)}, G'_h = P_h e^{d_h(P)} \quad (5)$$

其中, $d_x(P)$ 、 $d_y(P)$ 和 $d_w(P)$ 和 $d_h(P)$ 分别为训练过程中学习到的平移缩放和尺度缩放参数。

原始区域与实际区域的误差用 $\mathbf{t}_* = (t_x, t_y, t_w,$

t_h)表示,其中:

$$\begin{cases} t_x = (G_x - P_x) / P_w, & t_y = (G_y - P_y) / P_h \\ t_w = \log(G_w / P_w), & t_h = \log(G_h / P_h) \end{cases} \quad (6)$$

故目标函数可表示为:

$$f_{\text{loss}} = \sum_{i=1}^N (t_d^i - \mathbf{w}_d^T \Phi(P^i))^2 \quad (7)$$

其中, $\Phi(P^i)$ 为输入特征向量; \mathbf{w}_d^T 为需要学习的参数; $d=x, y, w, h$; N 为样本个数。通过最小二乘法即可求解函数的优化目标。

1.3 基于空间金字塔池化算法的 RoI 池化层特征维度归一化

若将输入向量直接缩放至统一维度,会损失部分信息并影响识别精度,因此本文在 RoI 池化层采用空间金字塔池化^[19]算法 SPP (Spatial Pyramid Pooling),在保证特征信息的基础上,归一化输入向量维数。

本文采用 4×4 、 2×2 和 1×1 共 3 种空间变换因子对特征图进行池化。对于 4×4 空间变换因子,首先将特征图均分为 4×4 共 16 块区域,取该区域元素最大值表征该区域的特征;对 2×2 和 1×1 空间变换因子执行类似操作,从而将任意尺度的目标候选域转换为 21 维度的特征向量。

2 改进 Faster-RCNN 参数学习与结构优化

为适应电力系统巡检图像高精度目标检测要求,本文提出建立电力系统巡检图像样本库以提高特征提取的强鲁棒性和候选域生成的准确性,并通过正则化优化模型结构以提高检测速度。

2.1 基于选择性搜索的参数学习优化

目前输电线路巡检中采用 ImageNet 数据训练模型,虽然实验结果较为满意,但实际上该模型的特征提取过程不够准确,原因在于 ImageNet 数据库 1 000 种类别中并未包含隔离棒、金具、绝缘子等物体,导致特征提取过程发生偏差,模型无法准确找到相应电气元件的尺寸、颜色、纹理等特征,最终影响目标检测效果。

基于此,本文采用选择性搜索 SS (Selected Search) 算法^[20]辅助判别和标记样本中的目标类别和位置,构建电气设备样本库,并利用该样本库训练模型。

样本库图像标签为 2 组一维向量,其一包含 4 个元素,分别表示检测窗的中心点坐标及检测窗的宽和高,另一维向量包含 4 个元素,若图像中包含对应的类别则标注 1,否则标注 0。巡检图像样本库构建方案示例如附录 A 中的表 A1 所示。

通过 SS 算法自动搜索和人工微调结合的手段建立巡检样本图像样本库,并使用该数据库训练 CNN 模型及 RPN 层的回归候选域操作,改进 Faster-

RCNN 目标检测算法精度,同时提高图像标记效率。

2.2 基于正则化的模型结构优化

若样本过少,模型在训练时容易陷入过拟合,为保持模型复杂度与数据量之间的动态平衡,本文采用正则化降低高维参数值的权重,使参数自动适应不同拍摄角度的巡检图像,将每个卷积层的大小和滤波器参数均调谐到合理的范围,改善其泛化性能。

2.2.1 卷积层优化分析

卷积层损失函数定义如式(8)所示。

$$L_{\text{conv}}(\mathbf{W}, \mathbf{x}^{(k)}) = \frac{1}{2m} \left[\sum_{i=1}^m (y_k - \mathbf{W} * \mathbf{x}_{ik})^2 + \lambda \sum_{j=1}^n w_j^2 \right] \quad (8)$$

其中, $\mathbf{W} = [w_1, w_2, \dots, w_n]^T$ 为卷积核参数, n 为卷积核个数; $\mathbf{x}^{(k)} = [\mathbf{x}_{1k}, \mathbf{x}_{2k}, \dots, \mathbf{x}_{mk}]^T$ 为第 k 个样本输入样本, m 为样本维度; y_k 为第 k 个样本对应的实际标签; λ 为正则化惩罚因子。 L_{conv} 包括似然项和正则项,似然项的目的是通过卷积操作使得输出尽可能与输入接近,正则项通过设置惩罚因子取较大值,确保特征表达的紧凑性。

2.2.2 池化层优化分析

池化层损失函数定义如式(9)所示。

$$L_{\text{fc}}(\mathbf{U}, \mathbf{x}^{(k)}) = \frac{1}{2m} \left[\sum_{i=1}^m (y_k - \mathbf{U} \mathbf{x}_{ik})^2 + \lambda \sum_{j=1}^t u_j^2 \right] \quad (9)$$

其中,等式右边第 1 项为重构损失项,表征模型的表达能力;等式右边第 2 项是模型复杂度,表征层的复杂度; $\mathbf{U} = [u_1, u_2, \dots, u_t]^T$, 为池化因子参数, t 为池化因子个数。本文通过正则化优化模型结构,可以根据巡检图像的数量级调整滤波器组,进一步减小重构损失项。

2.2.3 确定惩罚因子

惩罚因子 λ 通常根据经验选择,为评估 λ 对检测精度的影响,本节基于改进 Faster-RCNN 模型进行重复试验验证,结果如表 1 所示。

表 1 λ 值对检测精度的影响

λ	迭代次数	候选域数量	mAP/%	速度/(ms·张 ⁻¹)
0	5 000	1 000	80.72	102
		300	80.89	79
10	5 000	1 000	80.92	95
		300	81.17	72
20	5 000	1 000	81.82	83
		300	81.90	68
50	5 000	1 000	82.72	77
		300	82.89	63
100	5 000	1 000	83.12	71
		300	84.46	59
200	5 000	1 000	84.32	65
		300	84.84	56
1 000	5 000	1 000	83.23	61
		300	83.41	55

由表 1 可见,当 $\lambda = 200$ 时, mAP 值最高,且检测速度也相对较快,故本文选取 $\lambda = 200$ 。

3 巡检图像目标检测性能仿真测试

本节对数字图像处理方法、浅层机器学习算法、单阶法、双阶法、Mask-RCNN、Local Loss 检测及本文提出的改进 Faster-RCNN 分别进行测试,从处理速度及检测精度 mAP 等方面进行对比,以验证本文所提方法的有效性。

3.1 算例描述

本文从某省获取 32 000 张巡检图像,其中 30 000 张图片作为训练样本,剩余 2 000 张作为测试样本,对图像中的架空线路、杆塔、绝缘子和金具等电气设备进行检测。样本图像均按照表 A1 规则建立巡检样本库。为快速进行数据分析,本文将不同尺寸的原始图像裁剪为 $2\ 800 \times 2\ 000$ 尺寸。本文基于 TensorFlow 深度学习框架搭建仿真模型,仿真计算机配置为: Windows 10, x64 操作系统, 8 核 Xeon CPU, GTX1080 显卡, 32 G 内存。

3.2 巡检图像目标检测方法性能测试

本节采用数字图像处理方法中的 Haar 小波变化、GBVS 显著性检测和 LoG 算子图像分割,浅层机器学习中的 AdaBoost 算法,及深度学习方法中的 Faster-RCNN 和 YOLO 模型,分别进行巡检图像目标检测性能测试对比,测试对比结果如附录 B 中的图 B1 和图 B2 所示。

图 B1 和图 B2 表明,数字图像处理方法能够提取到图像中的显著目标,但无法区分具体设备类型,且这类方法需要对每一张图像人工选取合适参数才能达到较为理想的检测效果,检测效率低且泛化性能不佳。若采用相同的参数,LoG 算子对于巡检图像 B 检测效果更佳,但对于巡检图像 A 效果不甚理想;而小波特征分析对巡检图像 A 的检测效果优于巡检图像 B。

AdaBoost 算法仍无法准确区分设备的具体类别,检测精细化程度有待提高。由于拍摄角度不同,目标检测效果也呈现不同结果,如巡检图像 A 的检测精度高于巡检图像 B。因此为达到最佳检测精度,需要人工参与调参。

从图 B1 和图 B2(e)、(f)对比可知,深度学习模型可提取图像特征,检测图像中的目标电气设备,无需人工反复调参即可对任意一张巡检图像进行目标检测,因此泛化性能较好。

本文从平均准确率、检测速度、是否需要人工参与调参 3 个角度分析数字图像处理方法、浅层机器学习方法及深度学习中的单阶法和双阶法性能,结果如表 2 所示。

表 2 巡检图像目标检测方法对比

Table 2 Inspection target image contrast detection methods

方法	mAP/%	速度/(s·张 ⁻¹)	人工调参情况
LoG 图像分割	—	18.0	需要
AdaBoost	36.70	1.4	需要
YOLO	74.75	4.4×10^{-2}	不需要
Faster-RCNN	80.89	7.9×10^{-2}	不需要

由表 2 可见:

a. 数字图像处理方法和浅层机器学习方法可提取图像中目标电气设备,但检测精细化程度不够,同时在特征提取过程中需要人工调参,泛化性不强,不利于进行大数据分析;

b. YOLO 模型可以快速检测到图像中大型设备如杆塔等,但对于尺寸较小的电气设备检测精度还需改进,这是由于模型内部的目标探测器(栅格窗)只检测其区域内边缘差异最大的目标,而忽略其他小物体的检测;

c. Faster-RCNN 与 YOLO 模型均可自动提取特征,同时 Faster-RCNN 对于巡检图像多目标的检测精度更高,但检测速度仍与 YOLO 模型有较为明显的差距。

3.3 基于计算机视觉方法的巡检图像目标检测性能测试

为测试本文所提改进 Faster-RCNN 的性能,本节对各类双阶法、单阶法、Mask-RCNN、Focal Loss 检测及本文所提改进 Faster-RCNN 共 7 种方法进行对比分析。

在双阶法检测的中间过程需选取若干候选域作为判别对象,附录 C 中的图 C1 为 Faster-RCNN 在 RPN 层得到的部分候选域。

7 种方法的对比结果如附录 C 中的图 C2 所示。从 RCNN、Fast-RCNN 到 Faster-RCNN,检测的精细化程度显著提高,三者中 Faster-RCNN 对于绝缘子、杆塔、导线和金具都具有更好的识别效果;Focal Loss 检测方法相比于 YOLO 算法在检测精细度上有一定程度的提高,但依然无法解决小尺寸物体的检测问题。

本文采用自建巡检图像样本库方案训练以及正则化优化模型后,模型的参数训练效果和数量更为合理,因此检测的精细化程度更高;而 Mask-RCNN 相比于本文提出的优化模型在检测精度上有一定提高,但平均单张图像检测速度不甚理想。

本文从 mAP 和检测速度 2 个角度分析 7 种方法的目标检测性能,结果如表 3 所示。

由表 3 可得如下结论。

a. 本文通过自建训练样本库及正则化方法,改善训练过程参数学习过程及参数权重的合理性,得到改进型 Faster-RCNN 模型,相比于 RCNN、Fast-RCNN 和 Faster-RCNN 进一步提高模型的检测速度和精度。

表 3 计算机视觉方法检测精度及速度对比

Table 3 Comparison of accuracy and speed among computer vision methods

模型	目标检测 AP 值/%				mAP/ %	速度/ (ms·张 ⁻¹)
	绝缘子	导线	金具	杆塔		
RCNN	71.50	67.48	41.41	40.76	55.29	2170
Fast-RCNN	76.47	68.14	49.24	42.48	59.08	420
Faster-RCNN	88.65	84.25	72.41	78.25	80.89	79
YOLO	76.21	80.24	70.41	72.14	74.75	44
Mask-RCNN	90.74	89.41	81.57	88.24	87.49	167
Local Loss 检测	78.54	82.68	74.57	76.39	78.05	38
改进 Faster-RCNN	90.51	86.74	76.17	85.94	84.84	56

b. Mask-RCNN 在检测精度上有较明显的提高,但其候选域搜索空间过大,若未采用分布式并行计算,该方法在速度上暂无法满足输电线巡检图像观测实时性要求;Local loss 检测相比于 YOLO 在检测精度和速度上有较大提高,但仍未解决小尺寸器件检测灵敏度的问题。

4 结论

针对目前输电线巡检图像目标检测存在的适应性、泛化性和准确性的问题,本文提出基于区域建议策略的改进 Faster-RCNN 模型的检测方法,并进行了如下工作。

a. 为改善 Faster-RCNN 训练效果不佳的问题,本文建立巡检图像样本库训练 CNN,纠正模型训练过程中的参数学习问题;采用正则化手段优化模型参数权重,避免在样本有限的情况下出现过拟合现象,使得该模型对于不同实际场景的巡检图像具有更好的泛化能力。

b. 为对比数字图像处理法、浅层机器学习法、单阶法、双阶法、Mask-RCNN、Local loss 检测法以及本文提出的改进 Faster-RCNN 法之间的性能差异,采用某省真实巡检图像数据,对 7 种目标检测方法进行了多角度的仿真测试和性能分析,验证了本文所提方法的有效性。

c. 综合考虑检测精度和速度,本文所提出的改进后 Faster-RCNN 模型更适用于巡检图像目标检测,Mask-RCNN 若能进行分布式并行计算,提高检测巡检图像速度,将达到更好的应用效果。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

[1] 李鸣. 基于无人机的电力输电线路巡检监测系统研究[D]. 北京:北京交通大学,2017.
LI Ming. Study on monitor system of power transmission line based on unmanned aerial vehicle[D]. Beijing:Beijing Jiaotong University, 2017.

[2] 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.

ZHOU Feng,REN Guixin. Image classification and feature extraction of transmission line based on color space variable[J]. Power System Protection and Control,2018,46(5):89-98.

[3] 孙舒璇. 支持向量机算法研究及其在目标检测上的应用[D]. 济南:山东大学,2017.
SUN Shuwen. SVM algorithm study and its application in object detection[J]. Jinan:Shandong University,2017.

[4] 杨帆,王干军,彭小圣,等. 基于卷积神经网络的高压电缆局部放电模式识别[J]. 电力自动化设备,2018,38(5):123-128.
YANG Fan,WANG Ganjun,PENG Xiaosheng, et al. Partial discharge pattern recognition of high-voltage cables based on convolutional neural network[J]. Electric Power Automation Equipment, 2018,38(5):123-128.

[5] THOMPSON A. The cascading Haar wavelet algorithm for computing the Walsh-Hadamard transform[J]. IEEE Signal Processing Letters, 2016,24(99):1020-1023.

[6] 钱生,陈宗海,林名强,等. 基于条件随机场和图像分割的显著性检测[J]. 自动化学报,2015,41(4):711-724.
QIAN Sheng,CHEN Zonghai,LIN Mingqiang, et al. Saliency detection based on conditional random field and image segmentation[J]. Acta Automatica Sinica,2015,41(4):711-724.

[7] 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.

[8] 张泽浩. 基于动态贝叶斯网络的无人机巡检输电线路故障诊断研究[D]. 北京:华北电力大学,2016.
ZHANG Zehao. Research on fault diagnosis of transmission line based on dynamic Bayesian network[D]. Beijing:North China Electric Power University,2016.

[9] 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.
WU Yang. Research on insulator recognition methods in aerial images based on machine learning[D]. Beijing:North China Electric Power University,2016.

[10] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015,521(7553):436-444.

[11] HUANG J, GUADARRAMA S, MURPHY K, et al. Speed/accuracy trade-offs for modern convolutional object detectors[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA:IEEE,2016:3296-3297.

[12] ROSS G, JEFF D, TREVOR D, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA:IEEE,2015:705-713.

[13] ROSS G. Fast R-CNN[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA:IEEE,2017:6517-6525.

[14] REN S, HE K, 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.

[15] 王万国,田兵,刘越,等. 基于 RCNN 的无人机巡检图像电力小部件识别研究[J]. 地球信息科学学报,2017(2):256-263.
WANG Wanguo,TIAN Bing,LIU Yue, et al. Study on the electrical devices detection in UAV images based on region based convolutional neural networks[J]. Journal of Geo-Information Science, 2017(2):256-263.

[16] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]//Inter-

- national Conference on Computer Vision. Venice, Veneto, Italy: IEEE, 2017: 2980-2988.
- [17] REDMON J, DIVVALA S, ROSS G, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 779-788.
- [18] LIN T Y, GOYAL P, ROSS G, et al. Focal loss for dense object detection[C]//International Conference on Computer Vision. Venice, Veneto, Italy: IEEE, 2017: 2999-3007.
- [19] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[C]//European Conference on Computer Vision. Zurich, Switzerland: IEEE, 2014: 346-361.
- [20] FELZENSZWALB P F, HUTTENLOCHER D P. Efficient graph-based image segmentation[J]. International Journal of Computer Vision, 2004, 59(2): 167-181.

作者简介:



林 刚

林 刚(1993—),男,福建福州人,硕士,主要研究方向为电力大数据与深度学习技术(**E-mail**:glin@whu.edu.cn);

王 波(1978—),男,河南信阳人,博士研究生导师,博士,通信作者,主要研究方向为智慧能源与人工智能在电力系统中的应用(**E-mail**:whwdwb@whu.edu.cn)。

Multi-target detection and location of transmission line inspection image based on improved Faster-RCNN

LIN Gang, WANG Bo, PENG Hui, WANG Xiaoyang, CHEN Siyuan, ZHANG Liming
(School of Electrical Engineering, Wuhan University, Wuhan 430072, China)

Abstract: Because the transmission line inspection images are influenced by light, environment, shooting angles and so on, the electrical equipment in the image presents low resolution and polymorphic characteristics. Aiming at this problem, a multi-target detection and location of transmission line inspection image based on improved Faster-RCNN (Faster-Region-Convolutional Neural Network) is proposed. Firstly, a number of target candidate regions are generated by using region proposal network. Then, the CNN (Convolution Neural Network) is trained based on the actual inspection image sample database to improve the parameter learning effect. Finally, the regularization method is used to optimize the parameter weights and improve the detection speed, then the improved Faster-RCNN model suitable for polymorphic features of inspection images is established. The test results of actual scene datasets show that compared with the digital image processing, shallow machine learning, single-stage method, double-stage method, Mask-RCNN and Local Loss target detection method, the proposed improved Faster-RCNN maintains a higher recognition accuracy and speed in inspection images of different resolution and angle, and it has high engineering value.

Key words: region proposal; object detection; feature extraction; image sample library; regularization

(上接第 212 页 continued from page 212)

Application of magnetic integrated LCL filter in high-order harmonic suppression for traction network

XU Jiazhu, BAI Ziyi

(College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: In order to suppress high-order harmonic of the locomotive converter flowing into the traction network and reduce the locomotive space occupied by filter, a new harmonic suppression scheme of magnetic integrated LCL filter is proposed. Firstly, in order to suppress the inherent resonance peak of LCL filter, an active damping transient direct current control method without capacitive current sensor is proposed. Secondly, for the problem that LCL filter occupies too much space, the traction winding port inductance is used as the first inductance, and the magnetic integration technology is employed to integrate the second inductance into the traction main transformer for reducing the air-core reactor space. Finally, the field-circuit coupled simulation of the traction drive system with magnetic integrated LCL filter is performed by Ansoft and MATLAB software. The simulative and experimental results show that the magnetic integrated LCL filter can not only effectively suppress the high-order harmonics of locomotive converter flowing into the traction network, but also overcome the shortcomings of the traditional LCL filter occupying large space.

Key words: magnetic integrated LCL filter; traction network; high-order harmonic suppression; active damping

附录 A

表 A1 巡检图像样本库构建方案

TableA1 Construction scheme of inspection image database

巡检图像示例	物体类别 (绝缘子, 导线, 金具, 杆塔)
	(1, 1, 1, 1)
	物体位置 (x, y, w, h) 绝缘子 1: (612, 344, 45, 176) 绝缘子 2: (1320, 985, 1510, 120) 导线: (1520, 310, 2320, 20) 金具: (1850, 1050, 270, 210) 杆塔: (68, 1280, 210, 20000)

附录 B

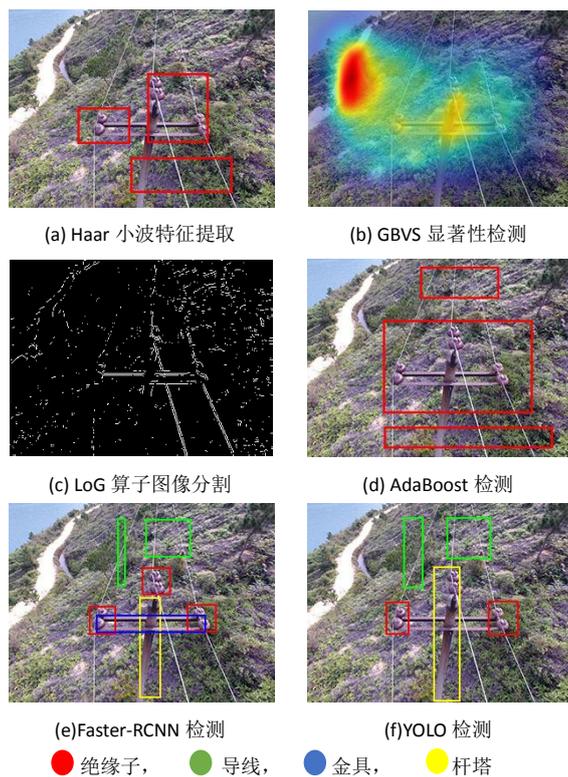


图 B1 图像 A 目标检测结果对比

Fig.B1 Comparison of object detection results of images A

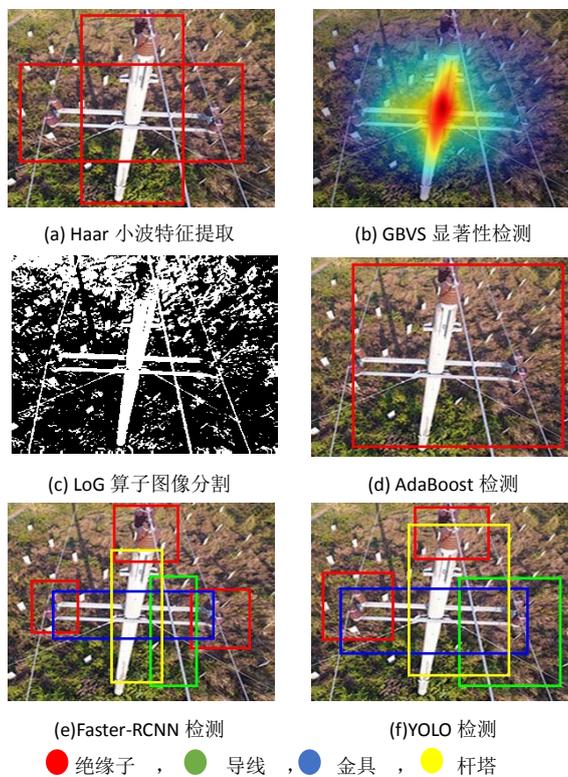


图 B2 图像 B 目标检测结果对比

Fig.B2 Comparison of object detection results of images B

附录 C



图 C1 候选域节选示意图

Fig.C1 Candidate region excerpt

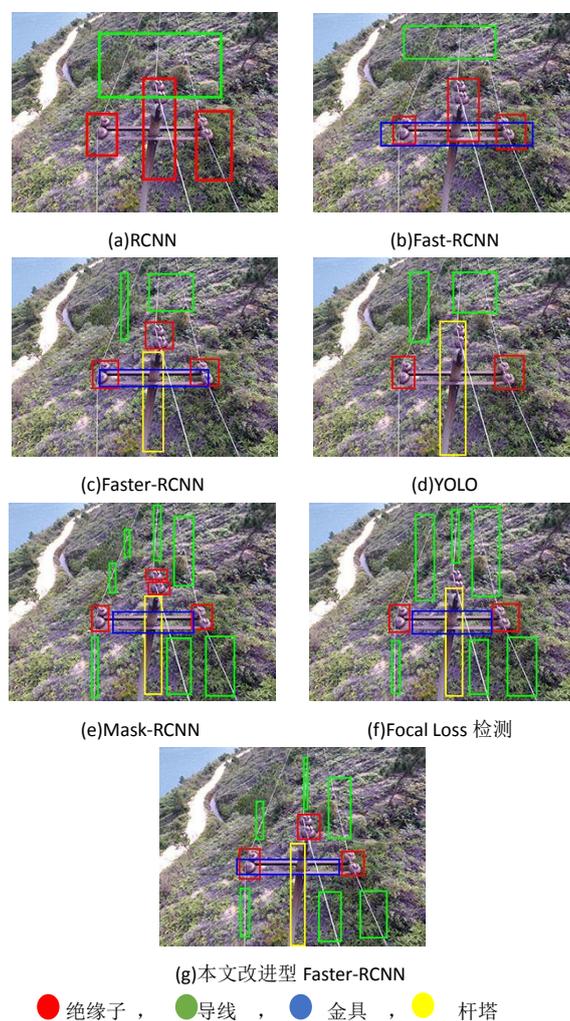


图 C2 基于计算机视觉的巡检图像目标检测结果对比

Fig.C2 Comparison of object detection results of inspection images based on computer vision