

基于深度学习的输电线挂接地线状态目标检测^{*}丁志敏¹ 邢晓敏² 董行² 陈炯¹ 蒋德州¹

(1. 贵州电网有限责任公司凯里供电局 凯里 556000; 2. 东北电力大学 电气工程学院 吉林 132012)

摘要: 针对输电线挂接临时接地线时用手持设备获取的图像存在接地线区域占比小、间隔近、不易精准识别的现场实际问题,提出了采用改进 Faster R-CNN 法实现接地线目标识别的解决办法。通过在原始 Faster R-CNN 方法的基础上将卷积网络的低层和高层特征图均送入 RPN 中实现多尺度目标检测,并对非极大值抑制进行改进,将改进后的模型移植至手持数据采集设备。经仿真验证及现场试运行测得接地线的检测精度达到 94.8%,比原始方法提高了 7.5%,表明所提出方法可有效提升目标识别整体性能。

关键词: 输电线路;接地线;改进 Faster R-CNN;全程监管

中图分类号: TM7 **文献标识码:** A **国家标准学科分类代码:** 470.40

State target detection of transmission line grounding
wirebased on deep learningDing Zhimin¹ Xing Xiaomin² Dong Hang² Chen Ke¹ Jiang Dezhou¹

(1. Guizhou Power Co., Ltd., Kaili Power Supply Bureau, Kaili 556000, China; 2. Electrical Engineering College, Northeast Electric Power University, Jilin 132012, China)

Abstract: In view of the practical problems of small proportion and close interval and difficult to identify accurately of ground wire area in the images obtained by handheld devices when the temporary ground wire is attached to the transmission line, proposes an improved Faster R-CNN method to realize ground wire target recognition. The low- and high-level feature maps of the convolutional network are fed into the RPN on the basis of the original Faster R-CNN method to achieve multi-scale target detection, and the non-maximum suppression is improved. The improved model is transplanted to the handheld data acquisition device. Through simulation and field test, the detection accuracy of grounding wire is 94.8%, which is 7.5% higher than the original method. It shows that the proposed method can effectively improve the overall performance of target recognition.

Keywords: transmission lines; grounding line; improved Faster R-CNN; full-course supervision

0 引言

临时接地线是电力线路和设备检修工作过程中必不可少的安全工器具之一。其正确的挂接可有效防止倒送电、感应电等现象的发生,对维护电网稳定运行和保障工作人员的人身安全都具有极其重要的作用。近年来,临时接地线管理系统在变电站中的研究及应用已经较为广泛^[1-3],但对于输电线路的接地线全程监管问题几乎无人问津。

随着机器视觉地不断发展,利用图像处理技术解决输电线路问题已成为研究热点。文献[4]建立基于人工鱼群的 BP 神经网络(AFSA-BPNN)预测模型,对输电线路外护

套故障图像进行处理和识别;文献[5]基于深度学习理论研究了输电线路关键部件视觉检测方法;文献[6]基于图像处理技术对输电线路导线表面损伤特征进行提取并展开深入研究。此外,图像处理技术在输电线杆塔横担处的螺栓缺陷检测^[7]、输电线路覆冰及异物智能视频检测^[8]、输电线路锈蚀检测^[9]、输电线路舞动信息提取与频谱分析^[10]等诸多方面也都得到了广泛应用。经过现场调研和多方求证,利用图像处理技术作为输电线路接地线管理系统的核心技术具有良好的可行性。工作人员通过手持设备分别对工作票中开出的工作地点处相应杆塔在接地线“挂接前”、“工作中”、“拆除后”的状态进行拍摄,随后展开目标检测及对比,

收稿日期:2020-12-02

^{*} 基金项目:南方电网贵州电网有限责任公司凯里供电局重点科技项目(0608322018040105WZ10055)、国家重点研发计划重大项目:OPLC 施工、监测、检测、运行维护技术的设备与标准(2016YFB0901204)资助

给出判断结果并存储各张图片及相应结果,不仅有效防止了误挂/拆事故的发生,而且符合现代智能电网精细化、规范化管理的要求,实现了接地线全程无盲点监测管理。

目前利用机器视觉进行目标检测的算法主要分为单阶法和双阶法,单阶法包括 SSD (single shot MultiBox detector)、YOLO (you only look once) 等,其优势是速度快^[11-14]。但对于小目标物体的检测结果并不理想。双阶算法包括 R-CNN、Fast R-CNN、Faster R-CNN 等,准确度较高。其中最具有代表性的方法是 Faster R-CNN,对 Pascal VOC 2012 数据集的处理结果的平均准确率较单阶法高 18.5%^[15],是真正实现端对端的目标检测框。

受拍摄距离、角度等诸多因素的影响,接地线图像中所呈现的目标尺寸在整个图像占比通常不超过 20%。另外,输电线路分 A、B、C 三相,检修时三相需分别挂接临时接地线,极有可能受拍摄角度等影响而造成目标区域重合,使目标区域检测难度加大,最终容易导致图像识别错误而误判接地线挂接位置的现象。因此,本文对 Faster R-CNN 的

方法进行改进,通过多尺度训练,对接地线浅层卷积的纹理特征充分利用,提高对小目标图像的检测精度,通过改进非极大值抑制 (non-maximum suppression, NMS),有效克服接地线目标区域距离较近甚至重合现象的影响,最终实现输电线路接地线图像的精确定位。鉴于本文的实验数据来源于输电线路工作人员采用手持设备现场拍摄,数量有限,不适于深层的复杂网络,因此,本文选择 ZF Faster R-CNN 作为实验的网络模型。

1 Faster R-CNN 图像目标检测原理

卷积神经网络的发展使得大量新理论、新方法被应用其中^[16-17]。Faster R-CNN 是即为较常用的方法之一,它主要由两部分组成,分别是区域建议网络 (region proposal network, RPN) 和对区域建议框进行分类并回归的 Fast R-CNN 网络,如图 1 所示。二者共享 ZF-net 网络的前 5 层卷积参数并完成图像的定位检测,ZF-net 网络参数如表 1 所示。




图 1 Faster R-CNN 网络结构

表 1 ZF-net 网络结构

层类型	卷积核数	卷积核尺寸/步长/填充
Conv1	96	7×7/2/3
Max pooling		3×3/2/1
Conv2	256	5×5/2/2
Max pooling		3×3/2/1
Conv3	384	3×3/1/1
Conv4	384	3×3/1/1
Conv5	256	3×3/1/1

1.1 区域建议网络 RPN

RPN 的实质是引入锚框机制的全卷积网络,将 ZF 网络的最后一层卷积特征图输送至 RPN 中,采用滑动窗口得到多个 256 维特征向量,再利用两个并行的 1×1 卷积层实现该向量的分类和回归。其中,每个滑动窗口中利用 9 种基本尺度分为 128×128、256×256、512×512、对应比例分别为 0.5、1、2 的锚框进行候选区域的提取,分类层输出维数为 18(2×9),确定候选区域属于前景目标或背景目标;回归层输出维数为 36(4×9),完成候选区域的坐标预

测。在该过程中,通过平移缩放和尺度缩放相结合的方式,对接地线候选区域进行修正。其中,平移缩放的表达式如式(1)所示。

$$G'_x = P_w d_x(P) + P_x, G'_y = P_h d_y(P) + P_y \quad (1)$$

将候选区域表示为一个五元组: (n, x, y, w, h) , n 表示图像数量, (x, y) 表示中心坐标, w, h 表示宽高。其中, (P_x, P_y, P_w, P_h) 为锚框标定的候选区域; (G'_x, G'_y, G'_w, G'_h) 表示预测的候选区域; $d_x(p), d_y(p)$ 为平移缩放参数。

尺度缩放表达式如式(2)所示。

$$G'_w = P_w e^{d_w(p)}, G'_h = P_h e^{d_h(p)} \quad (2)$$

式中: $d_w(p), d_h(p)$ 表示尺度缩放参数。

之后,再利用 NMS 对候选区域得分进行排序,去除冗余部分,将较高得分的候选区域作为最终感兴趣区域。

在回归过程中,通过平移缩放和尺度缩放的方式,对接地线候选区域进行修正,使之更接近实际接地线的标定区域。

1.2 Fast R-CNN 网络

以原始图像第 5 层卷积特征图和 RPN 输出的候选区

域作为 Fast R-CNN 中 ROI 池化层的输入对象,通过坐标映射和下采样实现特征维度的统一。最后利用两个全连接层得到特征向量,实现候选区域的分类和边框的回归。

1) 坐标映射

将 ROI 表示为一个五元组:

$$(n, r, c, h, w), n \in \{1, 2, \dots, N\} \quad (3)$$

式中: n 表示图像数目; (r, c) 表示左上角坐标; h, w 表示高和宽。因此, ROI 在图像中的坐标记为 $[r, c, r+h, c+w]$, (r, c) 表示左上角坐标; $(r+h, c+w)$ 表示右下角坐标。在 ZF 网络 Conv5 特征图上经 ROI 池化层映射的坐标为:

$$\left[\frac{r}{Stride_{ZF}}, \frac{c}{Stride_{ZF}}, \frac{r+h}{Stride_{ZF}}, \frac{c+w}{Stride_{ZF}} \right] \quad (4)$$

式中: $Stride_{ZF}$ 表示 ZF 网络的总步长, 等于 $16(2 \times 2 \times 2 \times 2 \times 1 \times 1 \times 1)$ 。

2) 下采样

将候选区域的位置坐标参数映射到特征图后, 采用 $(h/6+1) \times (w/6+1)$ 的池化核、 $(h/6) \times (w/6)$ 的步长, 再进行最大池化完成图像的下采样, 最终实现将输出的特征维度统一为 6×6 维。

2 Faster R-CNN 的改进

2.1 多尺度训练

在 ZF 多层卷积网络中, 低层卷积特征图能较好的表现图像的纹理信息, 高层卷积特征图表现更多的是图像的

语义信息, 如图 2 所示。但对于接地线这样的小目标图像而言, 其包含的语义信息较少, 考虑将浅层卷积特征中的纹理、边缘等信息与其进行结合, 将能够达到更好的接地线目标检测效果。




图 2 特征图可视化

因此, 与原始 Faster R-CNN 只将最后一层卷积特征图送入 RPN 中不同, 本文对 ZF 网络的第 1、2、5 层卷积后特征图均输入至 RPN 中, 采用 3×3 滑动窗口, 每个窗口分别映射到 96、256、256 维低维特征, 得到候选区域后, 将其特征图映射输送至 ROI 池化层进行维度的统一, 最后实现分类和回归, 如图 3 所示。




图 3 多尺度训练

不同层次的神经元由于感受野不同需要配备不同尺寸的锚框, 感受野的计算公式如下:

$$\begin{aligned} field_N &= size_N \\ &\vdots \\ field_i &= (field_{i+1} - 1) * Stride_i + size_i \\ &\vdots \\ field_1 &= (field_2 - 1) * Stride_1 + size_1 \end{aligned} \quad (5)$$

式中: $size_i$ 表示第 i 层卷积核大小; $Stride_i$ 表示步长; $field_i$ 表示第 i 层感受野, $field_1$ 为所求感受野。层次越低, 感受野越小, 对应的锚框尺寸越小, 得到的候选区域也越小。不同特征图对应不同的锚框尺寸, 如表 2 所示。经过多尺度训练, 对于占比小的接地线目标区域的检测精度

提高 5.2%。

表 2 改进后的锚框尺寸

卷积层	base_size	scales	基本尺度
Conv1	4	2, 4, 8	$8^2, 16^2, 32^2$
Conv2	16	4, 8, 16	$64^2, 128^2, 256^2$
Conv5	16	8, 16, 32	$128^2, 256^2, 512^2$

2.2 改进 NMS

RPN 中的锚框去除超出边界的部分后, 按照置信度由大到小排列, 选取前 6 000 个, 再通过 NMS 处理, 最终获取 2 000 个接地线候选区域进行训练。考虑到接地线挂接

时,极有可能出现间隔很近的情况,使得获取的图像由于拍摄角度原因出现目标区域重合的现象,因此需要在传统NMS基础上对其进行改进。

传统的NMS过程如式(6)所示。

$$S_i = \begin{cases} S_i, & \text{IoU}(M, b_i) < N_i \\ 0, & \text{IoU}(M, b_i) \geq N_i \end{cases} \quad (6)$$

其中, S_i 表示第 i 个候选框的置信度; M 表示置信度 S 最大的候选区域; b_i 表示剩余候选区域; N_i 表示设定的NMS阈值。其最大问题在于将相邻检测框分数强制置0, 给有重叠部分的目标区域检测带来极大困扰, 很可能出现误判接地线位置的情况。

本文通过衰减与检测框 M 有重叠的相邻检测框的检测分数对传统NMS进行改进, 如式(7)所示。

$$S_i = \begin{cases} S_i, & \text{IoU}(M, b_i) < N_i \\ S_i(1 - \text{IoU}(M, b_i)), & \text{IoU}(M, b_i) \geq N_i \end{cases} \quad (7)$$

当相邻检测框与 M 的重叠度超过本文设定的阈值 $N_i=0.7$ 后, 检测框的检测分数呈线性衰减, 但仍有保留, 针对接地线图像中目标有重合现象的检测提供了有利条件, 使其检测精度提高 2.3%, 与多尺度训练结合使用后, 相较于原始 Faster R-CNN 法, 接地线目标检测精度的提高更为明显。

3 实验仿真与结果分析

3.1 数据来源与实验结果

实验图像数据由某供电公司线路运维工作人员通过手持设备拍摄而得, 共 400 张, 通过旋转、裁剪、增强等手段将图像数量进行扩充, 样本分布如表 3 所示, 统一图像像素尺寸为 224×224 。实验环境为 Windows10、x64 操作系统、8 核 XeonCPU、GTX1080 显卡、32G 内存。

表 3 样本分布情况

数据集	样本数目
训练集	2 000
验证集	570
测试集	675
合计	3 245

本文采用交替训练的方法实现 RPN 与 Fast R-CNN 的卷积共享。训练过程中采用方向传播法 (back-propagation, BP) 和随机梯度下降法 (stochastic gradient descent, SGD) 对网络参数进行微调, 设置最小批量尺寸为 128, 数据进入网络后经前向传播计算损失值并修改网络参数权重, 再使用反向传播从后往前依次调整网络层参数, 直至网络训练次数达到预设定的值 10 000 为止。设置学习率为 0.001、权重衰减系数为 0.000 5、动量为 0.9, dropout 为 0.5 的情况下进行训练。训练过程中的损失主要来源于训练 RPN 和 Fast R-CNN 的分类和回归过程, 具

体 RPN 训练的损失计算和 Fast R-CNN 训练过程的损失计算分别如式 (8)、(9) 所示。

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (8)$$

式(8)为 RPN 训练的损失函数。其中, p_i 表示锚框预测为目标的概率; p_i^* 表示标签(当有接地线目标时取 1, 无目标时取 0); t_i 表示预测框参数(包含框的中心点坐标 x 、 y 、宽度 w 和高度 h); t_i^* 表示标定框参数; L_{cls} 表示分类损失函数; L_{reg} 表示回归损失函数; N_{cls} 表示分类数量; N_{reg} 表示回归数量; λ 表示平衡参数, 取值为 10。

$$L(p, p^*, t, t^*) = L_{cls}(p, p^*) + \lambda [P^* > 0] L_{reg}(t, t^*) \quad (9)$$

式(9)为 Fast R-CNN 训练过程的损失函数。其中 p 表示预测的候选区域置信度; p^* 表示分类标签; t 候选区域回归的预测值; t^* 表示区域回归的目标值; $[P^* > 0]$ 表达式如式(10)所示; λ 表示 FastR-CNN 与 RPN 损失间的相对权重, 取值为 1。

$$[P_i^* > 0] = \begin{cases} 1, & p_i^* > 0 \\ 0, & \text{其他} \end{cases} \quad (10)$$

图 4 所示为 Faster R-CNN 模型改进前后训练过程中的损失情况。随着迭代次数地不断增加, 损失趋于稳定, 原模型的损失约为 0.51, 改进后模型损失约为 0.28, 降低了 0.23。




图 4 训练过程的损失

图 5 为部分目标检测结果。实验证明, 本文方法可实现对输电线路接地线的目标准确定位检测。

3.2 基于改进 Faster R-CNN 的实验对比分析

本文采用召回率和平均准确率 (average precision, AP) 作为目标检测的评价标准, 证明多尺度训练、改进 NMS 分别对改进 Faster R-CNN 模型的贡献, 如式(11)、(12)所示。

$$Recall = \frac{TP}{TP + FN} \quad (11)$$

$$Precision = \frac{TP}{TP + FP} \quad (12)$$

式中: TP 表示正确分类的正样本数; FP 表示错误标记为正样本的负样本数; FN 表示错误标记为正样本的正样本数。



图 5 部分输电线路接地线图像目标检测结果

本文采用表 4 所示编号,分别对其进行测试,并绘制 PR(Precision-Recall,精度-召回率)曲线进行验证,实验结果如图 6 所示。改进后的 Faster R-CNN 算法的目标检测精度为 0.948,相比于原算法提升了 7.5%。其中,多尺度训练对图像目标检测的精度影响最大。

表 4 不同情况的测试结果

编号	不同情况	AP	Recall
1	Faster R-CNN	0.873	0.809
2	Faster R-CNN+多尺度训练	0.925	0.828
3	Faster R-CNN+多尺度训练+改进 NMS	0.948	0.912




图 6 Precision-Recall 曲线

3.3 基于机器视觉的实验对比分析

本文分别采用 R-CNN、Fast R-CNN、Faster R-CNN、本文方法、YOLO 算法对获取的输电线路接地线图像进行目标检测,检测结果如表 5 所示。

表 5 不同模型的测试结果

模型	速度/ms·张 ⁻¹	AP	Recall
R-CNN	2 017	0.532	0.698
Fast R-CNN	512	0.791	0.723
Faster R-CNN	194	0.873	0.809
YOLO	92	0.817	0.701
本文方法	114	0.948	0.912

双阶算法中,R-CNN 法由于搜索区域过大,使获取的冗余信息过大,导致检测结果较差,不能满足实时性要求,Faster R-CNN 在检测的精度和速度都具有很大优势,但相对于本文方法,仍稍显劣势,YOLO 算法的检测速度较快,但针对较小目标检测对象的精度有待进一步提高。

4 算法训练模型的移植及应用

本文所研究的图像采集/识别全部功能,最终将移植到自主研发的手持数据采集设备 APP 当中。

从 MathWorks 官方网站下载 MATLAB 工具箱组件 MATLAB Coder,将算法的 MATLAB 代码生成 C/C++ 代码,以备用于从桌面系统向手持数据采集设备硬件平台进行移植。在 Android Studio 中安装 NDK 及其它相关插件,配置好诸如源代码地址、生成文件存储目录等各编译参数后,用 NDK 将 C/C++ 代码编译为可以运行在 Android 平台上的 SO 库文件,然后用 JNI 在 Android 程序中调用该库文件,最后使用 NDK 将 SO 库和 Android 应用程序一起打包成为 APK 安装包文件,下载至手持数据采集器设备并安装。

图 7 为移植过程示意图。该手持设备的 APP 软件为自主研发,通过手持设备的摄像头拍摄采集现场工作图片,然后完成相应识别功能,并将判断结果和图片存储后通过公网实时上传给上位机管理系统,实现对输电线路临时接地线的全程无盲点监控。本系统已经在贵州电网某供电局试运行 4 个多月,现场试运行期间的识别准确率目前达 100%,设备运行状况良好。




图 7 手持设备目标检测框架移植

5 结 论

本文采用深度学习方法实现了输电线路接地线挂/拆状态的有效识别,并针对图像中接地线目标区域占比小、间隔近的特点,对原始 Faster R-CNN 法进行改进,使其目标检测精度提高 7.5%,并将该检测方法应用于手持设备中,便于输电线路现场端工作人员随时了解检修过程中接地线所处状态,防止因地线误挂、漏拆现象造成的重大事故,由人为防误转化为智能防误,实现了接地线的规范化管理。

参考文献

- [1] 邢晓敏,陈成,张鹏宇,等.无监测盲点的智能临时接地线管理系统的开发和应用[J].水电能源科学,2017,35(7):194-197.
- [2] 刘仁琪,吕晓俊,黄进,等.临时接地线综合管理系统的开发和应用[J].电力系统自动化,2010,34(22):109-112.
- [3] 刘家军,缪俊,姚李孝,等.电力检修作业挂接地线可视化监测装置[J].电力自动化设备,2010,30(7):134-136.
- [4] 朱永胜,魏巍,胡国洪,等.基于AFSA-BPNN的输电线路外护套故障图像处理[J].电工技术,2018(23):41-42.
- [5] 赵振兵,崔雅萍.基于深度学习的输电线路关键部件视觉检测方法的研究进展[J].电力科学与工程,2018,34(3):1-6.
- [6] 张新春,曹应平,韩春雨,等.基于图像处理的输电线路导线表面损伤特征研究[J].图学学报,2018,39(3):440-447.
- [7] 黄志文,张学习.输电线杆塔横担处的螺栓缺陷检测技术研究[J].工业控制计算机,2017,30(6):1-3.
- [8] 任贵新.输电线路覆冰及异物智能视频检测算法研究[D].哈尔滨:哈尔滨理工大学,2019.
- [9] 李辉,钟平,戴玉静,等.基于深度学习的输电线路锈蚀检测方法的研究[J].电子测量技术,2018,41(22):54-59.
- [10] 尹晖,张晓鸣,李小祥,等.基于视频监控的输电线路舞动信息提取与频谱分析[J].高电压技术,2017,43(9):2889-2895.
- [11] 戚银城,江爱雪,赵振兵,等.基于改进SSD模型的输电线路巡检图像金具检测方法[J].电测与仪表,2019,11(7):1-7.
- [12] GU J X, WANG Z H, KUEN J, et al. Recent advances in convolutional neural networks [J]. Pattern Recognition, 2018, 77: 354-377.
- [13] 曹红燕,沈小林,刘长明,等.改进的YOLOv3的红外目标检测算法[J].电子测量与仪器学报,2020,34(8):188-194.
- [14] 周志锋,万旺根,王旭智.基于YOLO V3框架改进的目标检测[J].电子测量技术,2020,43(18):102-106.
- [15] 胡正委,朱明.基于改进Faster RCNN与Grabcut的商品图像检测[J].计算机系统应用,2018,27(11):128-135.
- [16] 蓝金辉,王迪,申小盼.卷积神经网络在视觉图像检测的研究进展[J].仪器仪表学报,2020,41(4):167-182.
- [17] 李春,张代红,李登武.基于CNN-LSTM的配电网供电能力研究[J].国外电子测量技术,2019,38(9):16-21.

作者简介

丁志敏,硕士,工程师,从事输电线路工程相关技术研究。

邢晓敏(通信作者),硕士,教授,从事图像识别技术在电力系统相关应用的研究。

E-mail:Teacherxing@163.com