

DOI:10.12158/j.2096-3203.2019.04.012

基于 RetinaNet 和类别平衡采样方法的销钉缺陷检测

王凯¹, 王健¹, 刘刚¹, 周文青¹, 陈佳²

(1. 华南理工大学电力学院, 广东 广州 510641;

2. 广东电网有限责任公司河源供电局, 广东 河源 517200)

摘要:传统的无人机巡检航拍图中的电力连接金具销钉缺陷检测依赖人工进行标注, 针对此问题, 借助深度学习缺陷检测算法 RetinaNet 自动提取正常、缺陷样本的特征, 完成底层特征和顶层特征的融合, 实现销钉缺陷的自动标注。考虑到现实情况中缺陷类别样本数量远少于正常类别样本数量, 首先分析了缺陷数据不足引起的类别失衡对识别结果的影响, 结果表明该情况下训练好的模型将会使得大量缺陷样本被错误地识别为正常类。于是, 在数据层面采用类别平衡采样方法, 确保每个类别参与训练的机会均衡, 实验结果表明, 所提的方法能够在维持销钉正常类的高识别率前提下, 明显提高缺陷类别的平均准确率。

关键词:深度学习; 类别失衡; 类别平衡采样; 平均准确率

中图分类号: TM933

文献标志码: A

文章编号: 2096-3203(2019)04-0080-06

0 引言

电力金具上销钉常见缺陷的检测方式主要依赖于人工作业, 不仅效率低下, 并且存在安全性的问题, 近几年, 无人机巡检作为一种新型的智能巡检方式, 在电力行业中逐步得到了广泛的应用^[1-4]。然而, 无人机巡检会产生海量的可见光图片, 依然需要大量专业人员寻找图片中缺陷部位^[5]。因此, 如何实现真正的智能检测成为了国内外学者的研究方向。

目前, 针对此类的研究主要集中于绝缘子、防震锤等关键部件, 而对于销钉级别缺陷检测技术的研究少之又少, 甚至空白。文献[6]通过融合绝缘子纹理、颜色等特征以及绝缘子串本身先验知识提取绝缘子候选区域; 文献[7-9]采用传统图像处理方法对绝缘子进行分割, 借助绝缘子不变矩特征或者正交离散变换、小波变换实现绝缘子的识别以及相应缺陷的检测。以上方法虽然取得了较好的结果, 但特征手动构建过程十分繁琐^[10], 需要借助绝缘子外形固有特征实现自爆缺陷检测。

近几年随着深度学习的兴起, 有研究人员采用 Faster R-CNN 等深度学习缺陷检测算法和深层卷积神经网络构建级联网络实现绝缘子等关键部件以及相关缺陷的智能识别^[11-13], 然而, 上述研究并未针对现实情况中相关缺陷数据样本不足问题展开进一步研究。

收稿日期: 2019-01-22; 修回日期: 2019-03-07

基金项目: 国家高技术研究发展计划(863计划)资助项目(2015AA050201)

针对以上问题, 同时考虑到“单阶段”检测算法 RetinaNet 无论是在检测实时性还是检测精度方面均优于“双阶段”的 Faster R-CNN^[14], 文中提出了一种基于 RetinaNet 的电力金具上的销钉缺陷自动标注方法。考虑到实际情况中销钉缺陷(销钉松动、销钉缺失)样本数量远少于正常类别, 文中首先分析了销钉缺陷样本不足引起的类别不平衡给销钉缺陷检测造成的影响, 之后在 RetinaNet 算法的数据层面进行改进, 采用类别平衡采样方法, 以确保每个类别参与训练的机会均衡, 最后通过实验验证文中方法的有效性。

1 缺陷智能识别算法 RetinaNet

目标检测算法主要包括两大类, 一类是以单探测器(single shot detector, SSD)为代表的“单阶段”检测算法, 而另一类是以 Faster R-CNN 为代表的“双阶段”检测器。前者由于结构简单, 在识别速度上往往要优于后者, 而无人机在巡检时对实时检测有着较高的要求, 因此, 采用“单阶段”检测算法更为合理。考虑到无人机巡检航拍图中销钉在整张图片占据很小的比例, 使得包含前景物的候选区域远远少于只包含背景的候选区域, 采用常规的“单阶段”检测算法往往无法保证较高的检测精度^[15]。针对此问题, 为了降低候选区域的类别不平衡带来的不利影响, 有学者提出以分类损失函数 Focal Loss (FL) 为核心、特征金字塔网络(feature pyramid network, FPN)为骨干网络的 RetinaNet 算法, 图1为其基本结构。

从图中可以看出 RetinaNet 是由骨干网络和 2

个特定任务的子网络组成的“单阶段检测器”。骨干网络采用了 FPN 架构,主要负责计算输入图像的卷积特征图,2 个子网络分别在主干网络的输出上执行卷积对象分类任务和边框回归任务。




图 1 RetinaNet 算法网络结构

Fig.1 Network structure diagram of RetinaNet algorithm

1.1 FPN 框架

FPN 出现之前,多数检测算法较少考虑到底层特征语义信息,单单借助顶层特征进行预测。然而,底层特征更能准确反应目标位置信息。因此 FPN 在不同的特征层采用融合后的特征进行独立预测,其结构如图 1 所示^[15]。

FPN 综合考虑了低分辨率但语义信息丰富的高层特征和语义信息不足但分辨率高的低层特征,自底向上的路线正是卷积神经网络的前向过程,该过程将连续的不改变特征图大小的层视为一个阶段,并将每一阶段的特征图作为最终输出;自顶向下的线路将顶层特征图进行 2 倍的上采样,从而保证特征图与前向过程的每一阶段输出的特征图大小一致,方便后续特征融合。其中,上采样采用的是内插值方法,在像素点之间使用合适的插值算法插入新的元素,从而扩大特征图,确保上采样的特征图和下一层的特征图大小一致。

1.2 分类损失函数 FL

之前的“单阶段”检测器直接对首次生成的候选区域进行难度较大的细分类,意图根据这些背景占据多数的候选区域直接输出结果。另外,由于销钉本身具有体积小、在图片中占比少等特点,进一步增加了包含背景的候选区域,而原有的交叉熵损失(cross entropy, CE)作为分类任务的损失函数,往往无法与之相抗衡,容易导致分类器训练失败。因此,检测速度虽然得到了保证,但检测精度却下降了。因此 RetinaNet 将原先惯用的 CE 改为 FL,其计算式如下:

$$f_{FL}(p_i) = -\alpha_i (1 - p_i)^\gamma \log p_i \quad (1)$$

式中: α_i 为平衡因子; γ 为调节因子,取值在 $[0, 5]$ 之间; p_i 定义如下:

$$p_i = \begin{cases} p & y = f(x) \\ 1 - p & \text{其他} \end{cases} \quad (2)$$

式中: y 为预测值; $f(x)$ 为真实值; p 为真实分布概率。

根据上式可知 FL 本质的改进点在于:在原本的交叉熵损失函数前面乘以权重 $(1 - p_i)^\gamma$ 。有了该权重后,数量多的类别(背景)所贡献的损失被大幅度削减,数量少的类别(检测目标)的贡献几乎不变,使得训练过程中包含目标对象的候选区域具有更大的话语权。

2 销钉缺陷检测流程

电力金具作为电力系统中不可或缺的结构连接件,负责输电导线与导线、导线与绝缘子、导线与杆塔等关键部件之间的连接^[16-19]。金具结构多样,受力情况复杂,广泛采用压接、螺栓连接等连接形式。对于螺栓连接这种形式,为了使得金具之间能够牢固的连接起来,螺栓末端常会配有一枚销钉。由于多数电力金具位于环境多变的户外,长期承受外部机械张力和内部负荷的作用,销钉容易出现缺失或者松动等缺陷。图 2 为销钉常见缺陷示例,从图中可以看出,正常情况下,金具之间的连接除了需要螺栓和螺丝外,还需要插入销钉进行固定,在外部恶劣环境长期影响下,部分销钉会处于图中所示的松动状态,久而久之,松动的销钉进一步脱落,最终使得螺栓出现松动迹象。



图 2 销钉状态示例

Fig.2 Example diagram of the state of pins

2.1 巡检航拍图特征分析

RetinaNet 采用 FL 替代常规的交叉熵损失,可以在某种程度上缓解包含背景的候选区域占优带来的不利影响,但其在数据本身层面与机器学习中多数算法一样,通常会做出如下假设^[20]:训练样本中各个类别样本的数量是大致相同的,即样本数目均衡。但就电力系统缺陷检测或者故障诊断来说,实际情况不符合这一假设。原因在于电力系统各个部件大多数时间都是处于正常运行状态,因此无人机巡检时采集到的多数样本都是正常样本,像销钉缺失,尤其是松动这种缺陷样本十分罕见,采集十分费力。

另外,无人机自身的特性以及周围线路的布局也给缺陷检测带来了不少的困难,如无人机拍摄时

的抖动使得图片携带各种噪声,影响图片的清晰度;周围线路的走势限制了无人机拍摄的角度以及拍摄的距离,即使图片具有较高的分辨率,但销钉在整张图片只能占据很小的比例,并且航拍角度的随机性使得销钉形态发生变化等等。

2.2 基于类别平衡采样的训练策略

针对上述缺陷数据样本不足引起的类别不平衡,文中在数据层面进行改进,提出一种训练策略,其策略是把样本按类别分组,从样本数较少的类别中随机抽取部分或者全部样本进行扩充,使得缺陷类与正常类别样本数量趋于一致,保证每个类别参与训练的机会均衡。图3为算法流程图,步骤如下:

(1) 排序计数。按照类别对原始数据排序后,计算每一个类别包含的样本数目;

(2) 获取样本对应的索引值。根据数据量最多的正常类样本数对每一类样本生成一个随机排列的列表,然后使用各类别的随机数对相应的样本数求余,得到相应索引值;

(3) 生成样本随机列表。根据第二步求得的索引从相应类别图像中提取数据,生成该类的样本随机列表;

(4) 得到最终图像列表。将全部类别的随机列表结合起来并且打乱次序,即可得到最终图像列表,将会发现最终的图像列表中各个类别的样本数量是相同的;

(5) 根据最终图像列表训练模型,当遍历完列表中所有数据时,重复上述步骤进行第二轮训练。

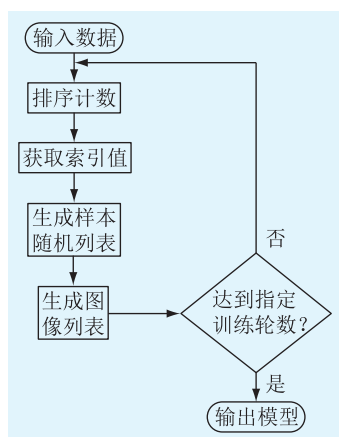


图3 基于类别平衡采样的训练策略流程
Fig.3 Flow chart of training strategy based on category balanced sampling

3 缺陷样本不足情况下的评估指标

对于一般的数据集,通常采用准确率、错误率等常规指标作为最终的评价指标,然而这对缺陷样

本严重缺乏的电力缺陷检测问题并不适用。在电力系统缺陷检测领域,正确区分缺陷类样本的意义高于整体分类的准确率,有研究表明分别以查全率(Recall)和查准率(Precision)为横坐标、纵坐标绘制而成的PR曲线以及每一条曲线对应的平均准确率(average precision, AP)更为适合此类问题^[21]。

鉴于文中根据销钉所处的状态将数据分为三类(正常、缺失和松动),因此,可根据表1所示的三类混淆矩阵对相关指标进行如下定义^[22]。

查准率:

$$P_{\text{Precision}} = \frac{a_1}{a_1 + a_2 + a_3} \quad (3)$$

查全率:

$$R_{\text{Recall}} = \frac{a_1}{a_1 + b_1 + c_1} \quad (4)$$

表1 销钉缺陷检测的三类混淆矩阵
Table 1 Three categories of confusion matrices for pin defect detection

	预测正常	预测缺失	预测松动
实际正常	a_1	b_1	c_1
实际缺失	a_2	b_2	c_2
实际松动	a_3	b_3	c_3

另外,对于每一条PR曲线,其与坐标轴围成的面积即为该类别对应的AP。

4 实验与分析

考虑到深度学习框架keras简单易用、扩展性强的特点,文中实验部分均基于此框架实现。另外,整个实验运行在配置如表2所示的计算平台上。

表2 计算机软件和硬件配置

Table 2 Computer software and hardware configuration

名称	参数和型号
CPU	Intel(R) Xeon(R) CPU E5-2660 v4 @ 2.00 GHz
显卡	NVIDIA Quadro M4000
显存	8 G
Python	3.6.6

实验数据来源于无人机巡检采集而得的目标数据集,具有较高的分辨率,另外,目标物所占比例小,拍摄图片的角度具有一定的随机性。训练数据样本根据销钉所处状态分为3类,分别记为正常(930张)、缺失(717张)和松动(137张)。测试集是从目标数据集中随机抽取而得,与训练集无任何交集,包括正常类250张,缺失类148张,松动类25张。

实验为避免神经网络权重初始化给实验结果

带来的不确定性,将在 ImageNet 数据集上经过预训练的残差神经网络 ResNet-50 作为 FPN 的主干网络,部分参数设置如下:学习率为 0.000 01,最大训练轮数为 50 轮,FL 中 $\alpha_1 = 0.25$, $\gamma = 2$ [12-14]。

为了分析数据样本不平衡对实验结果的影响,使用上述的参数训练缺陷检测模型,随后利用测试集对每一轮训练模型进行测试,得到图 4 所示的 AP 变化曲线。





图 4 对每轮模型测试得到的平均准确率的变化曲线

Fig.4 Average accuracy rate curve obtained by testing each round of trained models


由曲线图可知,首先,经过前几轮的训练,各类销钉的 AP 有较大幅度的提高,但随着训练轮数的进一步增加,检测模型趋于稳定,各类别的 AP 也逐渐趋于稳定。其中,数据占优的正常类稳定在 0.80,缺失类的平均准确率在 0.7 上下波动,松动类则在 0.6 上下波动;其次,与销钉正常类相比,由于销钉松动类别样本数量偏少,因此针对松动类别,需要经过更多几轮的训练其 AP 才能够趋于稳定,因此,可以通过适当增加训练轮数来缓解数据样本不足造成的不利影响;最后,销钉正常类的 AP 是所有类别中最高的,识别错误的样本集中于缺陷类。另外,根据测试图片的标注结果可以看出,在缺陷样本数量与正常样本数量比例严重失衡情况下,虽然整体目标检出率超过 96%,确保多数目标能够从复杂的背景中被检测出来,但训练好的模型将会更加倾向于数量占优的正常类,忽视数据偏少的缺陷类,导致大量缺陷样本被错误地识别为正常类别。然而,电力巡检人员更加关心的是有多少比例的缺陷样本被检测出来,因此,有必要针对该问题展开进一步研究。

为了验证文中训练策略的有效性,在算法参数设置不变的前提下,采用上述的训练集结合训练策略展开训练。另外,考虑到经过 50 轮训练后的模型检测性能趋于稳定,采用测试集对经过 50 轮训练的缺陷检测模型进行测试,得到每一类数据样本对应

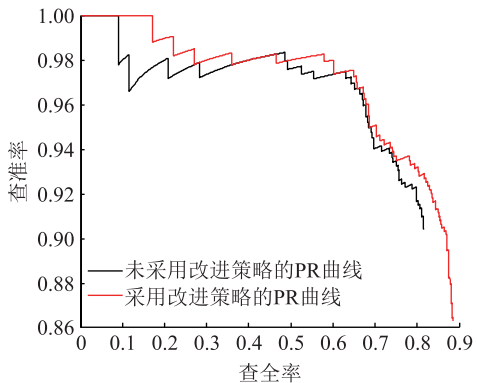
的查全率和查准率,从而绘制出如图 5 所示的 PR 曲线。



(a) 销钉松动类的PR曲线



(b) 销钉缺失类的PR曲线



(c) 销钉正常类的PR曲线

图 5 经过 50 轮训练模型测试得到的 PR 曲线

Fig.5 PR curve obtained by testing 50 rounds of trained models

从图 5(a)松动类别 PR 曲线可以看出,文中训练策略使得该类与正常类别样本数量趋于一致,确保其参与训练的机会与数量较多的正常类趋于均衡,模型训练过程中开始“重视”数据量较少的销钉松动类别,从而使得测试数据集的 AP 值由原先的 0.64 提高到 0.80,其增加幅度超过 10%,另外,极限查准值也得到了明显提高,即从 0.15 上升到 0.61;图 5(b)所示缺失类别 PR 曲线同样可以看出训练策略间接增加了该类样本的数量,使得该类部分样本所占权重有所增加,从而训练过程中对该类数据

重视程度有所提高,鉴于缺失类别样本数量远超过松动类别,使得其 AP 值提高的幅度有所下降,原先 AP 值为 0.71,经过调整后,AP 值增加了 8%,最终为 0.79,但极限查准率由原先的 0.72 下降到 0.44;同样,图 5(c)所示的正常类的 PR 曲线表明改进的策略对使得该类别平均准确率也有所提高,即由原先的 0.8 增加至 0.84,但该类别的极限查准率在原先的 0.9 的基础上下降了将近 3%。综上可知,文中改进策略在维持销钉正常类的高 AP 前提下,明显提高了缺陷类别的识别率,同时,提高了少数类别的极限查准率。

5 结语

考虑到人工标注电力金具上销钉的常见缺陷,耗时耗力,并且经常出现漏检的情况,文中借助端对端的深度学习缺陷检测算法自动提取缺陷样本特征,实现销钉缺陷的自动标注;同时,鉴于实际情况中销钉缺陷数据样本偏少,首先分析了在缺陷样本数量远少于正常类别情况下,类别失衡给检测结果带来的影响,然后针对此问题,在数据层面提出一种改进的训练策略。实验结果表明训练样本中各个类别样本的数量是大致相同的,也就是所谓的样本数目是均衡的。类别失衡容易造成少数类样本被错误地标记为数量占优的类别,为了缓解这种类别失衡给检测结果带来的不利影响,一方面,可以适当增加训练轮数,但训练次数不宜过多;另一方面,可以采用文中提出的训练策略使得缺陷类与正常类别样本数量趋于一致,保证每个类别参与训练的机会均衡。

参考文献:

- [1] 陈驰,彭向阳,宋爽,等.大型无人机电力巡检 LiDAR 点云安全距离诊断方法[J].电网技术,2017,41(8):2724-2730.
CHEN Chi, PENG Xiangyang, SONG Shuang, et al. Safety distance diagnosis of large scale transmission line corridor inspection based on LiDAR point cloud collected with UAV[J]. Power System Technology, 2017, 41(8): 2724-2730.
- [2] 王子昊.深度学习在输电铁塔关键部件缺陷检测中的应用研究[D].天津:中国民航大学,2018.
WANG Zihao. Applied research on deep learning in defect detection of key components on transmission towers[D]. Tianjin: Civil Aviation University of China, 2018.
- [3] 毛天奇,王传策,李云,等.基于 SGC 算法的复杂背景无人机巡检图像输电线提取方法[J].智慧电力,2018,46(12):105-111.
MAO Tianqi, WANG Chuance, LI Yun, et al. Transmission line extraction method based on SGC stereo matching algorithm for UAV inspection image under complex background[J]. Smart Power, 2018, 46(12): 105-111.
- [4] 薛阳,张晓宇,杨天宇,等.输电线路走廊自主巡检无人机控制逻辑设计[J].广东电力,2017,30(3):94-99.
XUE Yang, ZHANG Xiaoyu, YANG Tianyu, et al. Design on control logic for self-inspection unmanned aerial vehicle in power transmission line corridor[J]. Guangdong Electric Power, 2017, 30(3): 94-99.
- [5] 彭向阳,陈驰,饶章权,等.基于无人机多传感器数据采集的电力线路安全巡检及智能诊断[J].高电压技术,2015,41(1):159-166.
PENG Xiangyang, CHEN Chi, RAO Zhangquan, et al. Safety inspection and intelligent diagnosis of transmission line based on unmanned helicopter of multi sensor data acquisition[J]. High Voltage Engineering, 2015, 41(1): 159-166.
- [6] 姜云土,韩军,丁建,等.基于多特征融合的玻璃绝缘子识别及自爆缺陷的诊断[J].中国电力,2017,50(5):52-58.
JIANG Yuntu, HAN Jun, DING Jian, et al. The identification and diagnosis of self-blast defects of glass insulator based on multi-feature fusion[J]. Electric Power, 2017, 50(5): 52-58.
- [7] 商俊平,李储欣,陈亮.基于视觉的绝缘子定位与自爆缺陷检测[J].电子测量与仪器学报,2017,31(6):844-849.
SHANG Junping, LI Chuxin, CHEN Liang, et al. Location and detection for self-explode insulator based on vision[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(6): 844-849.
- [8] REDDY M J B, CHANDRA B K, MOHANTA D K. A dost based approach for the condition monitoring of 11 kV distribution line insulator[J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2011, 18(2): 588-595.
- [9] 郑君,诸静.基于第二代小波变换的电力设备图像特征提取[J].电工技术学报,2003,18(6):98-102.
ZHENG Jun, ZHUN Jing. Image feature extraction of electrical power equipment based on second generation wavelet transform[J]. Transactions of China Electrotechnical Society, 2003, 18(6): 98-102.
- [10] 黄新波,胡潇文,朱永灿,等.基于卷积神经网络算法的高压断路器故障诊断[J].电力自动化设备,2018,38(5):136-140.
HUANG Xinbo, HU Xiaowen, ZHU Yongchan, et al. Fault diagnosis of high-voltage circuit breaker based on convolution neural network[J]. Electric Power Automation Equipment, 2018, 38(5): 136-140.
- [11] 王万国,田兵,刘月,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,2017,19(2):257-263.
WANG Wanguo, TIAN Bing, LIU Yue, et al. Study on the electrical devices detection in UAV images based on region based convolution neural network[J]. Journal of Geo information science, 2017, 19(2): 257-263.
- [12] 汤踊,韩军,魏文力,等.深度学习在输电线路中部件识别与缺陷检测的研究[J].电子测量技术,2018,41(6):60-65.
TANG Yong, HAN Jun, WEI Wenli, et al. Research on

- pattern recognition and defect detection of transmission line in deep learning[J]. Electronic measurement technology, 2018, 41(6): 60-65.
- [13] 陈庆,闫斌,叶润,等. 航拍绝缘子卷积神经网络检测及自爆识别研究[J]. 电子测量与仪器学报, 2017, 31(6): 942-948.
- CHEN Qing, YAN Bin, YE Run, et al. Insulator detection and recognition of explosion fault based on convolutional neural networks[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(6): 942-948.
- [14] LIN T Y, PRIYAL G, HE Kaiming, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 28(5): 1-8.
- [15] LIN T Y, PIOTR D, HE Kaiming, et al. Feature pyramid networks for object detection [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Puerto Rico. USA, 2017:936-944.
- [16] 郑欣,杨迎春. 电力金具数值模拟分析中单元划分的影响[J]. 云南电力技术, 2014, 42(1): 71-73.
- ZHENG Xin, YANG Yingchun. Effect of mesh method on strain numerical simulation for electric fittings[J]. Yunnan Electric power, 2014, 42(1): 71-73.
- [17] 史腾飞,刘荣海,郑欣. 基于有限元模型的 U 型环磨损分析与实验[J]. 云南电力技术, 2017, 45(3): 106-112.
- SHI Tengfei, LIU Ronghai, ZHENG Xin. Based on the finite element model of U-ring wear analysis and experiment [J]. Yunnan Electric power, 2017, 45(3): 106-112.
- [18] 董新胜,何山. 强风致新疆输电线路金具断裂原因分析及治理[J]. 陕西电力, 2017, 45(6): 87-90.
- DONG Xingsheng, HE Shan. Reason analysis of transmission line hardware fracture induced by strong wind in Xinjiang & its treatment[J]. Shaanxi Electric Power, 2017, 45(6): 87-90.
- [19] 麦俊佳. 一起 220 kV 架空线路地线金具发热分析及对策探讨[J]. 广东电力, 2018, 31(7): 135-139.
- MAI Junjia. Analysis and countermeasure discussion on heating of fittings on grounding wire of 220 kV overhead transmission line[J]. Guangdong Electric Power, 2018, 31(7): 135-139.
- [20] IAN G, YOSHUA B, AARON C, 等. 深度学习(中文版)[M]. 北京: 人民邮电出版社, 2017.
- IAN G, YOSHUA B, AARON C, et al. Deep learning(Chinese version)[M]. Beijing: People Post Press, 2017.
- [21] 余重重, 田蕊, 谭励, 等. 非平衡样本分类的集成迁移学习算法[J]. 电子学报, 2012, 40(7): 1358-1363.
- YU Chongchong, TIAN Rui, TAN Li, et al. Integrated transfer learning algorithmic for unbalanced samples classification[J]. Acta Electronica Sinica, 2012, 40(7): 1358-1363.
- [22] 陈琼, 徐洋洋, 陈林清, 等. 不平衡数据的迁移学习分类算法[J]. 华南理工大学学报(自然科学版), 2018, 46(1): 123-129.
- CHEN Qiong, XU Yangang, CHEN Linqing, et al. Transfer learning for classification on unbalanced data[J]. Journal of South China University of Technology (Nature Science Edition), 2018, 46(1): 123-129.

作者简介:



王凯

王凯(1995),男,硕士在读,研究方向为电力系统故障诊断(E-mail: 805643915@qq.com);

王健(1965),女,博士,副教授,研究方向为电力市场;

刘刚(1969),男,博士,副教授,研究方向为高压智能输电网。

Defect detection of pins based on RetinaNet and class balanced sampling methods

WANG Kai¹, WANG Jian¹, LIU Gang¹, ZHOU Wenqing¹, CHEN Jia²

(1. School of Electric Power, South China University of Technology, Guangzhou 510641, China;

2. Heyuan Power Supply Bureau, Guangdong Power Grid Co., Ltd., Heyuan 517200, China)

Abstract: The traditional detection method for the defects of the pin on the power connection fitting in the aerial survey of the drone is dependent on manual marking. Aiming at this problem, the deep learning algorithm RetinaNet is used to automatically extract the features of normal and defective samples and complete the fusion of low-level features and top-level features to achieve automatic labeling of defects. Considering the fact that the number of defective samples is much smaller than the normal number of samples, Firstly, the influence of the category imbalance caused by the deficiency of the defect sample on the recognition result is analyzed. The results show that the trained model in this case will make a large number of defective samples be mistakenly recognized as normal classes. Therefore, at the data level of RetinaNet, class balanced sampling is proposed to ensure that each category has the same opportunity to participate in training. The experimental results show that the proposed method can significantly improve the average precision of defect categories under the premise of maintaining the high recognition rate of normal categories.

Keywords: deep learning; category imbalance; class balanced sampling; average precision

(编辑 方晶)