

DOI:10.12158/j.2096-3203.2019.05.005

基于无人机图像与迁移学习的线路绝缘子状态评价方法

罗建军¹, 刘振声^{2,3}, 龚翔¹, 黄绍川¹, 欧阳业¹, 魏征²

(1. 广东电网有限责任公司清远供电局, 广东 清远 511515; 2. 上海启亦电子科技有限公司, 上海 201499; 3. 华中科技大学电气与电子工程学院, 湖北 武汉 430074)

摘要:针对目前绝缘子运维过程存在着规程过于繁杂, 过于依赖运维人员的人工识别等问题, 文中提出了一种绝缘子状态评价方法, 该方法采用历史绝缘子缺陷图像作为训练样本, 通过迁移学习在小样本数据处理的优异性能实现基于深度卷积神经网络绝缘子的缺陷识别模型训练, 并借助卷积神经网络的特征提取能力实现绝缘子缺陷量化评分, 结合历史样本与专家经验实现考虑运行年限、外界环境等因素实现绝缘子综合状态评价。通过实例分析表明文中迁移学习模型训练后绝缘子缺陷识别准确率可达到90%以上, 而采用全新学习在同样的样本条件下识别准确率仅为70%, 且文中建立的评价模型在日常运维中能够更为灵敏地体现绝缘子的缺陷状态, 说明文中评价方法具有相当可靠性, 可为运维人员的日常维护安排提供经验。

关键词:无人机巡检; 迁移学习; 绝缘子; 缺陷识别; 状态评价

中图分类号: TM755

文献标志码: A

文章编号: 2096-3203(2019)05-0030-07

0 引言

绝缘子作为架空输电线路重要组成部分之一, 准确把握其运行状态, 确保其安全稳定运行对于保护电力系统稳定性具有重要意义^[1-3]。随着电力系统对于可靠性要求的日益增高, 长巡线周期的人工巡检方式已经难以适应电力部门的要求。借由无人机技术的发展, 相关电力科研工作者研究了用于架空输电设备状态获取的无人机巡线平台, 尽可能直观、更短周期地掌握电力设备的运行状态^[4-5]。

通过无人机图像进行绝缘子状态评价, 其关键点在于通过图片获取绝缘子运行缺陷信息。在无人机巡线系统初步投入使用时, 一般采用人工校对的方法进行缺陷识别, 但随着无人机巡线的普及, 巡线系统获得的图片不断增多, 传统的人工处理方法已经难以应对。随着机器学习的发展, 部分学者开始采用聚类算法、支持向量机等机器学习算法进行绝缘子的缺陷分类^[6-8]。机器学习算法能够通过历史样本进行模型训练, 可较好地实现对历史缺陷样本的挖掘, 最终通过计算机实现对绝缘子图像的缺陷分类。但机器学习算法的准确性依赖于训练样本的数目, 需要大量的缺陷样本进行训练才能保证一定的准确性, 且在模型训练前需要对图像进行边缘提取、RGB调整等图像处理操作。深度卷积神经网络是近几年在图像处理领域热度较高的算法,

其网络模型按照仿生学视觉机制进行构建, 具有较高的图像识别效果且对数据没有额外的处理要求^[9-10]。迁移学习则是一种基于速度卷积神经网络的训练方法, 其特点在于在训练前已经对相关数据库进行初步学习, 得到预训练模型, 可以减少训练样本的数目要求和模型训练时间。目前常用的迁移学习模型包括 AlexNet、GoogleNet 与 VGG-16 等, 在图像识别领域各有应用, 但在网络结构上各有差别^[11-13]。目前迁移学习在电力设备图像缺陷识别中初步得以运用, 具有较好的发展前景^[14-15]。

文中采用 AlexNet 作为预训练模型, 建立了基于无人机图像的绝缘子缺陷识别网络。结果表明采用迁移学习方法进行模型训练相较于全新学习能够在更少的训练样本条件下达到更高的识别准确率, 为进一步开发电力设备的缺陷识别模型提供了模型支持。

1 无人机巡线系统的数据获取

结合输电线路运维的需求, 目前电力系统采用了基于多传感器的低空数据采集无人机作为传统人工巡线的补充方案。采用无人机巡线具有成本低、操作灵活、可实现监测数据的实时传输、可进入地势复杂区域探测等优点。目前在电力系统中应用搭载多传感器的无人机作为巡线装置, 以满足对输电设备进行测温、测距、电晕放电等多维度测量要求。无人机数据采集系统如图1所示。

针对文中所提及的绝缘子状态评价, 目前大多通过无人机搭载的可见光相机对绝缘子进行拍摄,

收稿日期: 2019-03-07; 修回日期: 2019-04-13

基金项目: 国家自然科学基金资助项目(51777082); 广东电网有限责任公司科技项目(GDKJXM20173082)

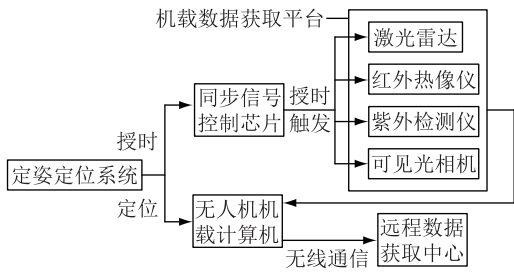


图1 无人机数据采集系统结构

Fig.1 Structure of UAV data acquisition system

再将照片通过通信系统传送给后端工作人员,从而对照片进行分析,确定绝缘子的运行状态。通过长时间的发展,目前已初步积累了绝缘子运行缺陷的历史缺陷图像样本库。绝缘子的典型运行图片如图2所示。

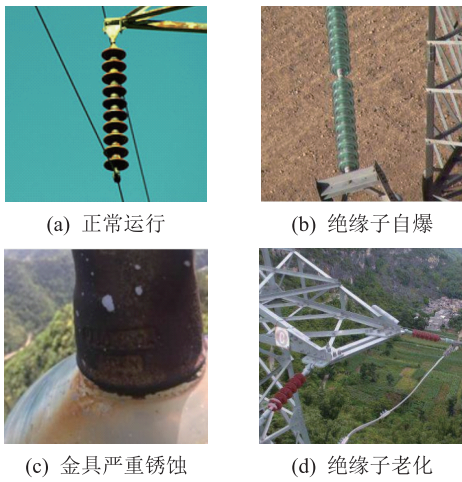


图2 无人机拍摄绝缘子典型运行图片

Fig.2 Insulator pictures taken by UAV

2 基于迁移学习的状态诊断模型

2.1 迁移学习

迁移学习是一种卷积神经网络模型搭建的训练方法,该方法利用目前建立的分类成功率较为理想的图像分类预训练卷积神经网络模型的相关知识,经过相关修正与补充得到目标模型。该方法充分考虑任务之间的相关性,通过来自相似域的数据来解决目标域数据不足的问题,在小样本数据的处理中具有较优性能。

目前已通过大型在线图像数据库中大量的数据样本建立了成功率较高的图像分类预训练模型,在文中所关注的绝缘子缺陷分类领域,输入绝缘子图像时已能较好地实现绝缘子的提取。因此,在建立绝缘子缺陷分类模型时,可以将重点放在各缺陷的分类方法上,避免全新网络模型训练时对绝缘子进行特征提取的过程,能够减少模型训练时间并尽

可能避免训练样本不足的问题。图3为文中采用的预训练模型的典型网络结构,主要由卷积层、池化层与全链接层组成。

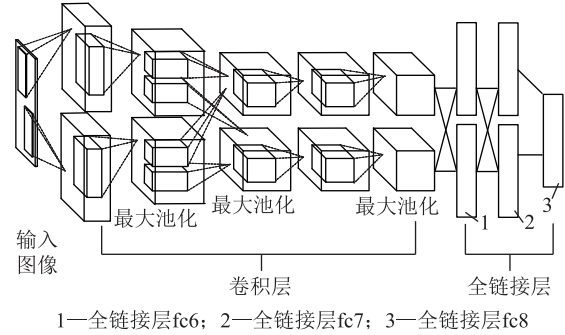


图3 AlexNet 预训练模型的典型结构

Fig.3 Typical structure of AlexNet pre-training model

(1) 卷积层。通过卷积滤波器对上一层输出的图像或特征图进行卷积加偏置运算,并通过相应的非线性激活特征函数进一步提取出该卷积层的局部特征图,计算公式如下。

$$X_o^l = f \left(\sum_{i \in m} X_i^{l-1} K_{io}^l + B^l \right) \quad (1)$$

式中: l 为该卷积层在整个网络模型的层数; m 为神经元对应的卷积滤波器; X_i^{l-1} 为该卷积层上一层输出的特征图; X_o^l 为该卷积层的输出特征图; K 为卷积核; B^l 为第 l 层的偏置。

(2) 池化层。其作用是对前一层特征图进行缩放降维映射减少数据维度,防止模型的过拟合。该层采用均值池化等采样法对滤波器中的值取均值,再通过式(2)的神经元算法进行二次特征提取。

$$X_o^l = f \left(\frac{1}{k} \sum_{i \in m} X_i^{l-1} + B^l \right) \quad (2)$$

(3) 全链接层。对于卷积神经网络的全链接层,大多直接采用多层神经网络的权值计算方法进行计算。

$$X_o^l = f \left(\sum_{i \in l-1} \omega_{ji} X_i^{l-1} + B^l \right) \quad (3)$$

式中: ω_{ji} 为第 l 层节点 j 到下一层节点 i 的权值。

图3所示的预训练模型中,包括5个卷积模块与3个全链接模块,最后一个全链接层的输出数为对应的分类目标类别数。卷积模块与全链接模块的神经元激活函数均采用ReLU函数,该函数是一种线性整流函数,通过其单侧抑制特性解决训练时的梯度弥散问题,增大神经元稀疏激活性。池化层均采用最大池化进行采样,核大小为 3×3 像素,滑

动步长为 2。全链接层 fc6 与 fc7 通过具有深度结构的对人工神经网络进行优化的随机失活 (dropout) 层进行部分连接的随机丢弃。池化降采样、重叠池化与全链接层的 dropout 可尽可能地保证样本的平移不变性,避免网络模型的过拟合。

2.2 模型优化

对于卷积神经网络的训练,需要尽可能迭代最小化损失函数从而提高分类成功率,采用基于指数衰减的随机梯度下降法实现学习率的更新优化。指数衰减法的随机率更新方法如下:

$$l_r = l_0 d_r^{\lfloor g_s / d_s \rfloor} \quad (4)$$

式中: l_r 为每次衰减更新后的学习率; l_0 为初始学习率; d_r 为学习率的衰减系数; g_s 为当前网络的迭代次数; d_s 为学习率的衰减步长; $\lfloor \cdot \rfloor$ 为向下取整符。采用学习率的指数衰减其目的在于网络初始训练阶段通过设置较大的学习率快速到达最优解,而在后期避免较大学习率产生的激烈振荡。

采用基于 L2 正则化权值惩罚系数的交叉熵损失函数计算分类损失从而避免网络模型训练中的过拟合,计算方法如下:

$$J_\theta = - \sum_x p(x, \theta) \log_q(x, \theta) + \lambda \|\theta\|^2 \quad (5)$$

式中: J 为训练样本的分类损失; x 为网络模型的训练样本; p 为期望类别概率; q 为模型预测类别概率,由 Softmax 计算; λ 为正则化系数; θ 为网络权重参数。

2.3 缺陷样本的扩充

完备的缺陷样本历史记录是实现绝缘子缺陷检测模型建立的基础,深度卷积神经网络需要采用足量样本进行网络训练以保证模型准确率。但考虑到无人机巡线投入到电力系统中时间较短,输电线路缺陷情况较少等客观原因,目前对于绝缘子缺陷照片的样本采集还较为缺乏,尚未建成完备的绝缘子缺陷图像数据库。为了提高模型的泛化能力,减少模型训练时过拟合的风险,在训练之前需要对数据样本进行预处理。

采用图像增强算法对图像进行数据增强处理,包括对原始图像进行平移变换、翻转变换、透视变换、颜色抖动、叠加噪声、对比度变化等,将原有缺陷样本扩充。

在样本扩充时,通过对无人机可见光图像依次采用随机裁剪、旋转变换以及透视变换进行缺陷样本数据库的扩充。对于文中所采用的 AlexNet 模型,当将尺寸为 256×256 的缺陷图像随机裁剪为 224×224 的图像时,可以使得缺陷图像数据库扩充 1024 倍,加上图像的随机旋转以及随机透视变换,

可以进一步扩充绝缘子的缺陷图像数据库。

3 绝缘子状态评价模型

表 1 为可采用无人机图像识别的绝缘子串部分缺陷的状态评价评估标准。在绝缘子所处缺陷情况的基础上,可引入其他与绝缘子运行状态相关的参量实现对绝缘子运行状态的评价。

表 1 绝缘子串状态评估标准(部分)
Table 1 State evaluation criteria for insulator strings(part)

指标	注意	异常	严重
绝缘子破损/自爆片数	1(110 kV) 2(≥ 220 kV)	2(110 kV) 3(≥ 220 kV)	3(110 kV) 4(≥ 220 kV)
污秽爬电	观察到间隙性放电	观察到明显火花放电	观察到严重爬电现场
锈蚀损伤	绝缘子金具出现锈蚀	绝缘子金具出现严重锈蚀	
异物缠绕		绝缘子串挂有异物,不危及运行	绝缘子串挂有异物,危及运行
连接部位异常		连接部分存在滑移、变形等	各部件连接部分裸露

深度学习网络可以通过各卷积层提取的相应局部特征,实现将以上定性数据的量化评分,得到无人机图像记录的绝缘子在各缺陷下的量化评分值。此外,绝缘子的部分运行缺陷状态需要在人工巡线时进行相应评估,如绝缘子的零值片数、复合绝缘子的憎水性变化等,以上缺陷的状态评分由工作人员根据相关缺陷定级标准得到。

在进行绝缘子的状态评价时,由于采用无人机巡线频率相较于人工巡线更高,每次进行状态评价时,若没有人工巡线数据更新,则仍然采用上一次的数据作为评价指标。最终以各缺陷状态下的最低得分作为绝缘子的运行状态评分 H_0 。

以绝缘子运行状态评分为基础,考虑绝缘子运行年限、气象状态、历史缺陷记录与绝缘子运行状态的影响。式(6)为不同运行役龄绝缘子与故障率的分布函数关系。

$$\lambda(t) = \beta t^\beta / \eta^\beta \quad (6)$$

式中: η 为尺度参数; β 为形状参数; t 为运行年限; λ 为设备故障率。

根据相关历史记录进行拟合,得到绝缘子不同运行年限下故障率的拟合曲线如图 4 所示。由图可知,随着绝缘子役龄的增大,其对应的故障率有着较为明显的变化,特别是在运行年限超过 10 a 之后,故障率上升的陡度有着明显增大。因此在状态评价时应当适当考虑绝缘子役龄的影响。式(7)为设备状态评分与故障率的分布函数关系,通过相应

历史故障记录对其进行拟合,并与式(6)进行联立,得到式(8)所示的绝缘子役龄与状态评分之间的关系。




图4 绝缘子不同运行年限的故障率变化趋势

Fig.4 Change trend of insulator failure rate in different operating years

$$\lambda = Ke^{CH} \quad (7)$$

$$H(t) = \left(\ln \frac{\beta t^\beta}{K\eta^\beta} \right) / C \quad (8)$$

定义绝缘子的年限变权系数为 k_1 :

$$k_1 = H(t_{eq}) / H(1) \quad (9)$$

式中: $H(t_{eq})$ 为在绝缘子实际运行年限时式(8)拟合曲线的取值; $H(1)$ 为在绝缘子运行年限1 a时式(8)拟合曲线的取值; $k_1 \in (0, 1]$ 。

台风、暴雨、雾霾等恶劣天气会对绝缘子的安全运行造成威胁,考虑绝缘子运行地段的恶劣天气情况,根据专家经验引入相关扣分系数 k_2 [16]。恶劣天气对绝缘子运行状态的具体扣分系数见表2。

表2 恶劣天气对绝缘子运行状态的影响

Table 2 Effect of severe weather on insulator operation

恶劣天气类型	程度	扣分系数
暴雨	降雨量(0.1~ 9.9 mm/d)	2
	降雨量(10~ 24.9 mm/d)	4
	降雨量(25~ 49.9 mm/d)	6
	降雨量(50~ 99.9 mm/d)	8
	降雨量 100 mm/d 以上	10
雾霾	三级(重度污染)	4
	二级(严重污染)	6
	一级(极重污染)	8
台风	8级以下	2
	8~10级	4
	10~12级	8
	12级以上	12

进一步考虑绝缘子历史缺陷情况对绝缘子状态评价的影响,考虑多种外部因素的绝缘子状态评价方法如式(10)所示。

$$H = k_1 H_0 - k_2 - k_3 n \quad (10)$$

式中: H 为绝缘子最终状态评分; H_0 为在状态评价时尚未考虑外界因素的初始评价价值; k_2 为恶劣天气扣分值; k_3 为历史缺陷情况变权系数,根据专家经验在式中取5; n 为被测绝缘子的历史缺陷次数。根据以上标准,得到的绝缘子运行状态与最终评分的关系如表3所示。

表3 绝缘子运行状态与最终评分关系

Table 3 Relations between insulator operation status and final scoring

评分	运行状态	评分	运行状态
90~100	正常	50~70	异常
70~90	注意	0~50	严重

4 实验与结果分析

采用广东电网公司清远供电局的机巡图片数据与生产管理系统数据作为数据来源,所取得的图像样本个数为1 208个,通过文中提及的缺陷样本扩充方法将其扩充为10 000个缺陷样本,生产管理系统中的数据包括设备的运行年限、缺陷时的气象条件、历史缺陷次数数据。

文中网络模型的建立与训练在谷歌的开源软件库Tensorflow框架下进行,采用Python语言进行编译。考虑训练平台的硬件性能,采用分批次训练的方式对网络进行训练,每次采用100个样本对模型进行训练,将最大训练轮数设置为100次。每进行完一轮训练,采用测试集对模型进行测试,测试集的样本数同样设置为100。图5为分别采用迁移学习与全新学习的方法进行网络训练的模型的绝缘子提取能力变化曲线。




图5 迁移学习与全新学习的绝缘子识别率比较

Fig.5 Comparison of insulator recognition rate between transfer learning and new learning

如图5所示,由于迁移学习在进行训练之前已经对图片数据库进行了初步训练,训练开始之前网络结果已经接近最优解。因此在训练之前已经可以较好地识别图片中的绝缘子,随着训练轮数的增

高,其识别准确率也有相应的提高;而采用全新学习的方法进行网络训练则仍然需要经过一定的训练轮数才能达到较大的识别准确率。

进一步考虑采用迁移学习与全新学习模型对绝缘子缺陷的提取能力。考虑到迁移学习方式下网络模型以得到了初步训练,为了避免采用过大的学习率导致网络模型错过最优解,在采用迁移学习时,设置初始学习率为 0.001,正则项系数 0.001;在全新学习模型下,可考虑设置较大的初始学习率使得网络更快地接近最优解,全新学习时采用初始学习率为 0.01,正则项系数仍取 0.001。

采用迁移学习与全新学习的绝缘子缺陷的识别准确率曲线如图 6 所示。由图可知,采用迁移学习进行绝缘子缺陷识别模型训练相较于全新学习在训练集与测试集的识别上均能更快地达到较高的识别准确率。考虑到网络模型内部参数取值由训练集进行模型训练得到,因此在训练初期 2 种方法均能够保持较高的训练集识别准确率。虽然迁移学习在初期准确率略高于全新学习,且能够更快达到稳定解,但整体而言,两者均能较快实现对训练集的准确判断。对于测试集的分类,测试集对网络模型而言是全新的样本,在训练初期迁移学习的优势更为明显,当训练轮数较少时,其缺陷识别准确率远优于全新学习的缺陷识别准确率,且能够在较少的训练轮数下达到较高的识别准确率,而采用全新学习则需要更多的训练样本对模型进行训练。

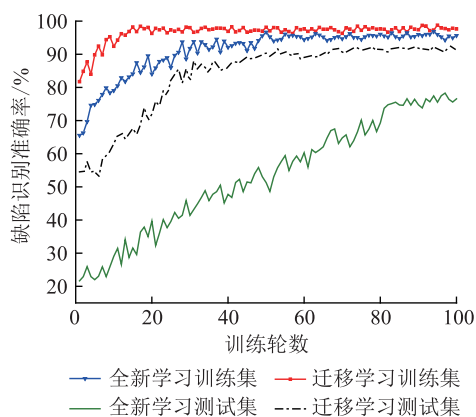


图 6 迁移学习与全新学习的缺陷识别率比较
Fig.6 Comparison of defect recognition rates between transfer learning and new learning

除 AlexNet 之外,还存在 VGG、GoogleNet 等预训练模型可用于迁移学习之中。文中比较了 AlexNet、VGG-16 及 GoogleNet 模型对绝缘子缺陷识别上的差异,结果如图 7 所示。

GoogleNet 和 VGG-16 结构相较于 AlexNet 结构具有更复杂的网络模型,对于在线图像数据库的初

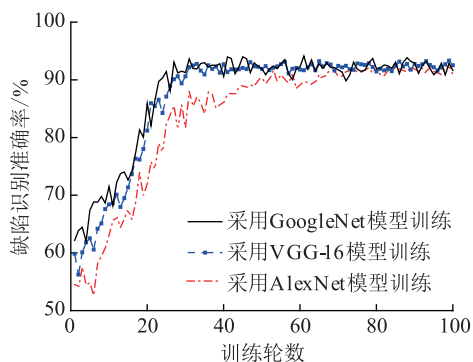


图 7 不同迁移学习网络模型的缺陷识别率对比
Fig.7 Comparison of defect recognition rates of different transfer learning network models

始学习更为充分,预训练模型具有更优的分类准确率。由图 7 可知,在文中绝缘子缺陷识别模型训练初期,采用 VGG-16 和 GoogleNet 模型相较于 AlexNet 模型缺陷识别准确率有着微弱的优势,且能够更快地达到稳定值。但 AlexNet 经过较少的训练轮数后同样也能够达到稳定值,且 3 种网络结构的稳定值差异不大,AlexNet 的缺陷识别准确率略低于其他 2 种模型。通过分析 3 种模型的网络结构,VGG-16 模型与 GoogleNet 模型分别具有 16 层与 22 层网络结构,而 AlexNet 仅具有 8 层结构,深度学习网络层数越多,其网络的表达能力更强,特别是在图像识别方面,能够提取更多的特征信息,因此可以认为在网络学习初期,VGG-16 与 GoogleNet 对于在线图像数据库的学习效果较优。随着绝缘子缺陷数据的不断迭代学习,由于样本具有更为明显的特征,3 种算法的差异也不断减小。考虑到 AlexNet 的网络结构更为简单,对于计算机硬件要求较低,因此采用 AlexNet 进行模型训练是较优的方法。

表 4 为文中模型针对不同绝缘子缺陷类型的识别率,包括伞裙自爆、金具锈蚀、表面污秽等 6 种缺陷。每种缺陷各选取 50 个缺陷图像作为测试样本进行缺陷识别测试,取 10 次测试的平均值作为识别准确率的参考值。由表可知,对于不同类型的缺陷,模型的识别成功率具有较为明显的差距。分析不同缺陷的缺陷特征,发现该差异可能是由于缺陷特征的明显程度所致,模型识别成功率较高的缺陷类型均具有较高的辨识度,而识别率相对较低的缺陷类型其辨识度就相对较低。

选取部分绝缘子故障记录作为文中状态评价方法的比较样本。根据文中方法与传统导则得出的评价结果如表 5 所示。通过样本 1 对文中方法得到的状态评分值进行说明,在进行网络训练时,样本评分的输出标签包括运维人员记录的样本评分,

表4 测试集不同缺陷类型识别率
Table 4 The recognition rate of different defect types in the test set

缺陷类型	识别准确率/%	缺陷类型	识别准确率/%
伞裙自爆	95.2	护套破损	89.3
金具锈蚀	89.4	表面老化	82.3
表面污秽	83.6	异物缠绕	94.8

该评分采用导则得到,因此通过网络模型得到的运行状态评分 H_0 与导则评分类似,在本例中,网络模型得到的评分为65.5分。此外,该样本故障时投运12 a,此时年限变权系数 k_1 为0.83,缺陷记录当日为雷暴天气,降雨量为74.2 mm/d,取恶劣天气扣分值 k_2 为8,且根据台账信息该绝缘子尚未有过历史缺陷记录,根据式(10)综合设备役龄、气象条件与历史缺陷记录得到文中方法的状态评分值为46.4分。

表5 部分故障样本的状态评分结果

Table 5 State scoring results of partial fault samples

编号	缺陷类型	故障类型	评价结果	
			文中方法	导则评分
1	伞裙自爆	击穿	46.4/严重	68/异常
2	金具锈蚀	掉串	45.6/严重	76/注意
3	表面污秽	污闪	62.1/异常	68/异常
4	表面老化	击穿	42.8/严重	60/严重
5	护套破损	闪络	40.3/严重	60/严重

进一步比较文中方法与导则评分的差异性,以评价结果不一致的样本1与样本2为例,通过导则对样本1扣分标准为220 kV绝缘子自爆3片,扣32分为异常状态;该样本故障时投运12 a,当日为雷暴天气,考虑到该样本故障时的气候条件与运行年限,文中算法评价其为严重状态。通过导则对样本2的扣分标准为绝缘子钢脚、钢帽出现变形锈蚀,扣24分为注意状态;该样本故障时投运15 a,当日为超强台风天气,文中算法评价其为严重状态。总体而言,通过文中方法进行状态评价对于绝缘子缺陷的告警更为灵敏,能够更好地反映恶劣天气下运行绝缘子的缺陷情况。

5 结论

文中以线路绝缘子为研究对象,结合在小样本图像识别中性能优异的迁移学习方法,建立了一套绝缘子缺陷分类与状态评价方法。

(1) 迁移学习在绝缘子缺陷识别中相较于全新学习具有更好的缺陷识别准确率与更短的训练时间,同时对于训练样本的数量要求也更低;

(2) 迁移学习的识别准确率在训练轮数较低时

受到网络模型的差异性影响,缺陷样本具有更明显的特征,随着训练轮数的迭代,不同训练方法的差异性也随之降低;

(3) 文中引入运行年限、恶劣天气以及历史缺陷次数对绝缘子运行状态的影响,在状态评价时能够更灵敏地反映绝缘子的缺陷状态。

参考文献:

- [1] 邱志斌,阮江军,黄道春,等. 输电线路悬式瓷绝缘子老化形式分析与试验研究[J]. 高电压技术, 2016, 42(4):1259-1267.
QIU Zhibing, RUAN Jiangjun, HUANG Daochun, et al. Study on aging modes and test of transmission line porcelain suspension insulators [J]. High Voltage Engineering, 2016, 42(4): 1259-1267.
- [2] 褚双伟,华奎,卢明,等. 特高压线路大吨位绝缘子挂网运行情况[J]. 广东电力, 2018, 31(4):27-33.
CHU Shuangwei, HUA Kui, LU Ming, et al. Analysis on operation of large tonnage insulators on UHV transmission lines [J]. Guangdong Electric Power, 2018, 31(4): 27-33.
- [3] 黄振,许志海,彭向阳,等. 输电线路复合绝缘子运行状态抽样检测试验[J]. 广东电力, 2017, 30(5):114-118.
HUANG Zhen, XU Zhihai, PENG Xiangyang, et al. Sampling inspection experiment on operating state of transmission line composite insulator [J]. Guangdong Electric Power, 2017, 30(5): 114-118.
- [4] 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.
- [5] 梁文勇,赵淳,王海涛,等. 架空输电线路固定翼无人机巡检航线计算方法研究[J/OL]. 高电压技术:1-5 [2018-12-21]. <https://doi.org/10.13336/j.1003-6520.hve.20180615005>.
LIANG Wenyong, ZHAO Chun, WANG Haitao, et al. Calculation method of inspection route of fixed-wing UAVs for overhead transmission lines [J/OL]. High Voltage Engineering: 1-5 [2018-12-21]. <https://doi.org/10.13336/j.1003-6520.hve.20180615005>.
- [6] 刘云鹏,纪欣欣,裴少通,等. 基于稀疏表示的绝缘子紫外图谱闪络状态分类评估方法[J]. 高电压技术, 2018, 44(10):3352-3358.
LIU Yunpeng, JI Xinxin, PEI Shaotong, et al. Method for evaluating flashover state of insulator ultraviolet image based on sparse representation [J]. High Voltage Engineering, 2018, 44(10): 3352-3358.
- [7] 王淼,杜毅,张忠瑞. 无人机辅助巡视及绝缘子缺陷图像识别研究[J]. 电子测量与仪器学报, 2015(12):1862-1869.
WANG Miao, DU Yi, ZHANG Zhongrui. Study on power transmission lines inspection using unmanned aerial vehicle and

- image recognition of insulator defect[J]. Journal of Electronic Measurement and Instrumentation, 2015(12): 1862-1869.
- [8] 黄新波, 刘新慧, 张焯, 等. 基于红蓝色差和改进 K-means 算法的航拍绝缘子分类识别方法[J]. 高电压技术, 2018, 44(5): 1528-1534.
- HUANG Xinbo, LIU Xinhui, ZHANG Ye, et al. Classification recognition method of insulator in aerial image based on the red-blue difference and developed K-means algorithm [J]. High Voltage Engineering, 2018, 44(5): 1528-1534.
- [9] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300-1312.
- CHANG Liang, DENG Xiaoming, ZHOU Mingquan, et al. Convolutional neural networks in image understanding [J]. Acta Automatica Sinica. 2016, 42(9): 1300-1312.
- [10] 程嘉晖. 基于深度卷积神经网络的飞行器图像识别算法研究[D]. 杭州: 浙江大学, 2017.
- CHENG Jiahui. Aircraft image recognition based on deep convolution neutral network [D]. Hangzhou: Zhejiang University, 2017.
- [11] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge & Data Engineering, 2010, 22(10): 1345-1359.
- [12] TAYLOR M E, STONE P. Transfer learning for reinforcement learning domains: a survey [J]. Journal of Machine Learning Research, 2009, 10(10): 1633-1685.
- [13] 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26-39.
- ZHUANG Fuzhen, LUO Ping, HE Qing, et al. Survey on transfer learning research [J]. Journal of Software, 2015, 26(1): 26-39.
- [14] 侯春萍, 章衡光, 张巍, 等. 输电线路绝缘子自爆缺陷识别方法[J]. 电力系统及其自动化学报, 2019, 31(6): 1-6.
- HOU Chunping, ZHANG Hengguang, ZHANG Wei, et al. Self-explosion defect identification method for transmission line insulator [J]. Proceedings of the CSU-EPSA, 2019, 31(6): 1-6.
- [15] 李军锋, 王钦若, 李敏. 结合深度学习和随机森林的电力设备图像识别[J]. 高电压技术, 2017, 43(11): 3705-3711.
- LI Junfeng, WANG Qinruo, LI Min. Electric equipment image recognition based on deep learning and random forest [J]. High Voltage Engineering, 2017, 43(11): 3705-3711.
- [16] 张杨. 架空输电线路状态评估系统研究与实现[D]. 杭州: 浙江大学, 2017.
- ZHANG Yang. Research and implementation of state evaluation system for overhead transmission lines [D]. Hangzhou: Zhejiang University, 2017.

作者简介:



罗建军

罗建军(1977),男,硕士,高级工程师,从事输变电设备状态检测工作;

刘振声(1996),男,硕士在读,研究方向为电力系统智能状态评价(E-mail: zhensheng-0310@hust.edu.cn);

龚翔(1986),男,学士,工程师,从事电力系统运行维护工作。

Insulator state evaluation method based on UAV image and migration learning

LUO Jianjun¹, LIU Zhensheng², GONG Xiang¹, HUANG Shaochuan¹, OUYANG Ye¹, WEI Zheng²

(1. Qingyuan Power Supply Bureau of Guangdong Power Grid Corporation, Qingyuan 511515, China;

2. Shanghai Qiyi Electronics Technology Co., Ltd., Shanghai 201499, China; 3. School of Electrical and

Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: In view of the problems existing in the process of insulator operation and maintenance, such as too complicated regulations and too dependent on manual identification of operators, this paper presents an insulator condition evaluation method, which uses historical insulator defect images as training samples and realizes the basis of excellent performance of small sample data processing through migration learning. Based on the training of defect recognition model of deep convolution neural network and the feature extraction ability of convolution neural network, the quantification score of insulator defect can be achieved, and the comprehensive state evaluation of insulator can be realized by considering the operation life and external environment with the help of historical samples and expert experience. An example shows that the recognition accuracy of the proposed transfer learning model can reach more than 90% after training, while the recognition accuracy of the new learning model is only 70% under the same sample conditions, and the evaluation model established in this paper can more sensitively reflect the defect status of insulators in daily operation and maintenance. It shows that the evaluation method established in this paper is quite reliable and can provide experience for the daily maintenance arrangement of operation and maintenance personnel.

Keywords: UAV image; transfer learning; insulator; defect recognition; status evaluation

(编辑 方晶)