

DOI: 10.13382/j.jemi.B2104014

基于深度学习的杆塔接地网断点诊断方法研究*

孙绍珩¹ 鲁彩江^{1,2,3} 曹中清¹ 刘子轩¹ 江雪玲¹ 李林峰¹(1. 西南交通大学 机械工程学院 成都 610031; 2. 先进驱动节能技术教育部工程研究中心 成都 610031;
3. 轨道交通运维技术与装备四川省重点实验室 成都 610031)

摘要:在使用电磁感应方法诊断杆塔接地网断点的过程中,针对人工诊断引起的误差问题,提出了一种基于一维卷积神经网络(one dimensional-convolutional neural network, 1D-CNN)的诊断模型,诊断模型以接地网正上方的一维磁场数据为输入,通过深度神经网络输出断点故障的数量和位置。首先通过实验验证了电磁感应方法在杆塔接地网断点诊断问题中的有效性,然后建立了磁场断点故障数据集,之后进行了1D-CNN诊断模型的训练。在诊断准确度验证实验中,1D-CNN诊断模型在40个故障磁场样本上达到了97.50%的诊断准确率,表现出了良好的泛化性;诊断效果对比实验表明,1D-CNN诊断模型的AUC值达0.951,在3次随机训练中对各类故障的平均识别率达到了92.08%,在15次训练中的平均测试集精度达到了94.30%,平均每代训练时间0.875 0 s,在各项指标上较DNN、RNN均有明显优势。

关键词:电磁感应方法;杆塔接地网;卷积神经网络;断点故障诊断

中图分类号: TM754; TP391.5 **文献标识码:** A **国家标准学科分类代码:** 520.20

Research on diagnosis method of tower grounding grid breakpoints based on deep learning

Sun Shaoheng¹ Lu Caijiang^{1,2,3} Cao Zhongqing¹ Liu Zixuan¹ Jiang Xueling¹ Li Linfeng¹

(1. School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China;

2. Engineering Research Center of Advanced Drive Energy Saving Technologies, Ministry of Education, Chengdu 610031, China;

3. Technology and Equipment of Rail Transit Operation and Maintenance Key Laboratory of
Sichuan Province, Chengdu 610036, China)

Abstract: In the process of using electromagnetic induction method to diagnose the breakpoint of the grounding grid of the tower, aiming at the error caused by manual diagnosis, this paper proposes a diagnosis model based on one dimensional-convolutional neural network (1D-CNN), the diagnosis model takes the one-dimensional magnetic field data directly above the grounding grid as input, and outputs the number and location of breakpoint faults through a deep neural network. This paper firstly verified the effectiveness of electromagnetic induction method in the diagnosis of tower grounding grid breakpoints through experiment, then a magnetic field breakpoint fault dataset was established and a 1D-CNN diagnosis model was trained. In the diagnostic accuracy verification experiment, the diagnostic model reached 97.50% diagnostic accuracy on 40 faulty magnetic field samples, showing good generalization. The comparison experiment of the diagnosis effect shows that the AUC value of the 1D-CNN diagnosis model reaches 0.951, the average recognition rate of various faults in three random trainings reaches 92.08%, and the average test set accuracy in 15 trainings reaches 94.30%. and the average training time per generation is 0.875 0 s, which has obvious advantages over DNN and RNN in various indicators.

Keywords: electromagnetic induction method; tower grounding grid; convolutional neural network; breakpoint fault diagnosis

收稿日期: 2021-03-01 Received Date: 2021-03-01

* 基金项目: 国家自然科学基金(61801402)、四川省杰出青年科技人才项目(2020JDJQ0038)、中央高校基本科研业务费(2682020CX26)项目资助

0 引言

作为输电线路杆塔的重要组成部分,杆塔接地网的功能是在大电流通过塔体的情况下保证接地点附近的电位稳定。埋设于野外的杆塔接地网维护不便,而传统开挖检查的方法难以快速排查接地网断点,使用一种准确、高效的诊断方法就显得尤为重要。接地网的诊断方法可根据检测原理分为电化学法、电网法、电磁感应方法(电磁法)3类^[1]。电化学法研究接地网金属导体在土壤中的腐蚀机理^[2-3]或腐蚀产生的电流^[4],为接地网腐蚀的诊断提供了理论依据;电网法通过建立接地引下线间阻抗诊断方程或分析电位差来寻找断点位置^[5-6],从理论分析的角度取得了一定的成果,但实际应用性较差;电磁法是通过分析接地网周边磁感应强度分布进行故障诊断的一种方法,具有良好的诊断效果。刘洋等^[7]通过接地引下线向接地网注入异频电流,根据地表磁场下降幅度特征实现了对接地网断点故障的无损查找,并设计了基于人工分析的析接地网故障诊断方法与系统;司文荣等^[8]对变电站接地网模型进行了测试,分析了接地网导体变细、断裂、脱焊等腐蚀故障条件下的磁感应强度分布,以断点周边磁场变化的趋势、倍数判断断点故障位置,验证了电磁诊断方法的有效性。上述研究中,依靠人工诊断的电磁法的诊断准确性受研究人员水平、经验的影响,需要一种更准确、有效的判据提高其准确性。目前,国内大部分学者对接地网故障诊断问题的精力集中在变电站接地网上,对杆塔接地网的研究仍停留在其散流特性^[9]、冲击特性^[10-11]、设计方法^[12]和降阻分析^[13]方面,因此使用电磁法对杆塔接地网断点定位方法进行研究有很大的研究意义和实用价值。

深度学习方法可以利用带有不同数据标签的原始数据训练深度神经网络,实现数据的准确、快速分类,近年来在机械故障诊断^[14-15]、电力故障诊断^[16]、医学治疗^[17]和行为识别^[18]等领域取得了丰硕的成果。本文依据深度学习的思路提出一种杆塔接地网断点诊断模型,该模型以接地网断点故障磁场数据训练的一维卷积神经网络(1D-CNN)作为电磁法诊断的判据,实现了根据原始磁场数据输出断点的数量及位置的功能。

本文首先提出杆塔接地网的诊断模型,验证了电磁法的有效性;然后,构建了接地网断点故障的磁场数据集,设计训练了基于 1D-CNN 的接地网断点诊断模型;最后,在测试数据上验证了 1D-CNN 断点诊断模型的诊断效果并与其他深度学习模型进行了对比,得出了结论并对下一步工作提出指导。

1 基于电磁法的杆塔接地网断点诊断方法

1.1 杆塔接地网诊断模型设计

杆塔接地网周边磁场由导体内轴向电流磁场 B_1^e 和土壤内泄漏电流磁场 B_2^e 两部分构成,其中 B_1^e 由毕奥-萨伐尔定律计算,其值与激励电流大小呈线性关系; B_2^e 在实际工作中由于其值微弱常忽略不计,因此本文主要研究接地网轴向电流在空间中激发的磁场。

将电磁法应用于杆塔接地网的断点诊断,需要通过接地网的拓扑结构建立诊断模型,本文根据《交流电气装置的接地设计规范 GB/T 50065-2011》设计了图 1 所示的模型。模型的拓扑结构为大小 6 m×6 m 的正方形,接地引下线距离边 1 m。规定接地引下线编号为 a、c,以点 a 为起点沿逆时针依次将接地网四角定义为 A、B、C、D。观测线设置于模型上方,位置与接地网对应。




图 1 杆塔接地网模型的结构

Fig. 1 Structure of pole tower grounding grid model

本文在接地网模型的 AB、CD 段中点各设置长度 0.5 m 的故障段,通过去除故障段模拟接地导体在自然环境中受侵蚀断裂的情况。4 种典型断裂故障的具体设置方式如图 2 所示。

1.2 电磁法诊断杆塔接地网断点实验验证

1) 实验平台搭建

课题组搭建了图 3 所示的平台进行实验,实验平台由接地网模型、电流发射机和数据采集系统 3 部分组成。接地网模型材料使用长度 6 m、截面积为 40 mm×4 mm 的热镀锌扁钢,其电阻率为 $1.78 \times 10^{-8} \Omega \cdot \text{m}$,相对磁导率为 200,导体的断裂故障由切断导体实现。

实验中使用 Loc3-10Tx 型电流发射机输出 512、1 000 Hz 的交流电。经实验分析,设置激励电流大小为 1 000 mA 可获得较强磁场。交流电产生的磁场在 0~2 kHz 频段内衰减较小^[19],将频率设置为 512 Hz 可有效减少磁场衰减,同时可避开电力系统的工频谐波干扰。




图 2 实验故障设置

Fig. 2 Experimental fault settings




图 3 实验平台示意图

Fig. 3 Schematic diagram of experimental platform


考虑到模型拓扑结构的中心对称性,实验中的磁场信号由通过接地引下线注入-抽出电流的方式产生,这样产生的磁场幅值大且易于分析,实验中由接地引下线 a 注入激励电流,接地引下线 c 抽出激励电流。

数据采集系统由 Coily-F901 三轴磁通门传感器、FDU101 数据采集单元、上位机及外围设备组成。正交磁场信号经传感器和数据采集单元传输给主机,随后在主机上由 NI Labview 程序进行处理。


2) 实验结果分析

将模型观测线上的磁场按照 $A-B-C-D-A$ 的顺序记录为一组数据,由接地引下线 a, c 将磁场数据分为 $a-A-B-c$ 和 $c-C-D-a$ 两个支路,实验所获不同故障的磁场数据如图 4 所示,其中黑色实线代表正常情况下的测得磁场,红色虚线和蓝色点虚线分别代表 $a-A-B-c$ 和 $c-C-D-a$ 支路

出现断点故障时的磁场数据。在单支路断点故障情况下,无法观测到故障支路的磁场,而正常支路的磁场增大为原磁场的 1.295 8~1.342 0 倍;两断点故障则无法记录有效磁场数据。从实验结果可以看出,当接地网模型发生断点故障时,接地网上方的磁感应强度分布会出现明显变化,使用电磁法能有效判断接地网的断点故障发生位置和数量。然而,在磁场特征不明显或人员经验不足的情况下,使用电磁法寻找接地网断点易产生错误的结果,此时应使用更准确的判据。



(a) 正常与单断点



(b) 正常与双断点

图 4 不同故障磁场实验曲线

Fig. 4 Different fault magnetic field experiment curves

2 基于 1D-CNN 的断点诊断模型设计

描述故障的磁场特征通常由诊断专家设计,其准确性受专家水平的影响。深度学习可以通过深度神经网络的隐藏层自动进行特征学习,将输入的原始磁场信号的底层特征转化为更高级、更密切的表示,通过分类器完成断点故障的分类。

2.1 1D-CNN

作为深度学习的重要模型,1D-CNN 整体结构如图 5 所示。训练过程中,卷积层每组神经元使用相同的连接权重对输入数据进行卷积操作,实现了神经网络的降采样、参数共享和稀疏连接。一维卷积操作如下:

$$x_k^{l+1} = \sum_{i=1}^{N_l} \text{conv1D}(w_{ik}^l, s_i^l) + b_k^{l+1} \quad (1)$$

式中: x_k^{l+1} 、 b_k^{l+1} 为第 $l+1$ 层第 k 个神经元的输入与偏置;

w_{ik}^l 为第 $l+1$ 层第 k 个神经元与第 l 层之间的卷积核; s_i^l 为第 l 层第 i 个神经元的输出; N_l 为第 l 层的神经元个数。CNN 从输入特征空间提取局部模式,减少了参数量,实现了训练的加速。




图 5 1D-CNN 结构
Fig. 5 Structure of 1D-CNN

通常 CNN 会在卷积层后加入池化层。池化层基于局部相关性原理对输入向量进行再采样,可以增大后层网络的感受野规模,缩减模型大小,提升模型的运算速度,增强模型的鲁棒性。CNN 通常使用感受能力更强、输出信息更准确的 $\max$ 池化,表示为:

$$p_i^{l+1} = \max_{(j-1)w+1 \leq i \leq jw} p_i^l \tag{2}$$

式中: w 为卷积核宽度。池化层从输入特征中提取窗口,输出位置 p_i^{l+1} 在前一层中对应位置相邻区域的最大值。

在 $\max$ 池化问题中,神经网络的最后一层使用的 Softmax 函数预测分类结果。Softmax 由逻辑回归扩充而来,具有正则性和非负性,在 $\max$ 池化问题中能拉大不同分类结果间的差距,常用于训练类别向量。其损失函数表达式为:

$$L_{\text{Softmax}} = -\log \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}} \tag{3}$$

诊断接地网断点故障可以充分利用 1D-CNN 的优势,利用不同尺寸的卷积核以提取故障的多尺度磁场特征,将磁场信号的幅值、梯度以及特征间的关系转换为高级表示,进而完成复杂分类的学习任务。

2.2 接地网断点故障磁场数据集的制作

基于 1D-CNN 的诊断模型的训练需要制作接地网断点故障磁场数据集。实验中,将观测点上的 200 个磁场数据按 A-B-C-D-A 的顺序记录为一个样本,并使用数字 0~3 按故障类型对数据样本进行标记。由于在接地网双断点(编号 3)的实验中无法取得有效的磁场,故在数据集中使用部分仿真数据和增强数据。增强数据 S 的合成公式如下:

$$S = (\mu S_1 + (1 - \mu) S_2) + n \tag{4}$$

式中: S_1 、 S_2 为实验数据样本和相同条件下的仿真数据,而合成权值 μ ($0 \leq \mu \leq 1$)、噪声 n 由 random 库函数

生成。

数据集包含实验采集的 723 条样本、使用 CDEGS 与 COMSOL Multiphysics 软件模拟的 600 条仿真样本以及应用数据增强方法生成 1 323 条样本。将数据集的 2 646 条数据样本按 4 : 1 : 1 的比例划分为训练集、验证集与测试集,具体数量如表 1 所示。数据集为不平衡数据集,其中 0、1、2、3 类故障的比例约为 5 : 5 : 5 : 1。

表 1 接地网断点故障磁场数据集
Table 1 Datasets of grounding grid breakpoint fault magnetic field

故障类型	标签	训练集	验证集	测试集
正常	0	550	138	135
a-A-B-c 存在断点	1	546	142	136
c-C-D-a 存在断点	2	555	133	139
a-A-B-c 和 c-C-D-a 存在断点	3	113	27	32

2.3 神经网络的参数选取

在模型的构建过程中,选取适当的参数可提高模型的准确率并有效加速训练。在 CNN 中使用 ReLU 激活函数以输出神经元变换后的非线性结果,同时加快计算的收敛速度。ReLU 激活函数的非负区间梯度为常数,对非线性函数不存在梯度消失问题,可以将模型的收敛速度维持在一个稳定状态。ReLU 激活函数的表达式为:

$$\text{ReLU} = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \tag{5}$$

深度学习方法在数据量有限的情况下易出现过拟合问题。作为一种正则化方法,Dropout 技巧可在训练过程中使一定比例 p ($0 \leq p \leq 1$) 的神经元随机失活,降低神经元在训练过程中的权重,减轻模型的过拟合。在本文提出的诊断模型中,Dropout 值为 0.4 时达到最佳效果。

将学习率控制在适当范围可有效加速深度学习过程。交叉熵损失函数通过输出误差控制学习速率,在梯度下降计算过程中使用交叉熵损失函数,可以避免学习速率随训练代数降低的问题。多分类问题下,交叉熵损失函数的表达式为:

$$L = \frac{1}{N} \sum_i L_i = \frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \log(p_{ic}) \tag{6}$$

式中: M 表示分类数量; y_{ic} 为指示类别 C 与变量 i 是否相同的变量; p_{ic} 为样本 i 属于类别 C 的预测概率。训练的过程中同时使用自适应矩估计 (adaptive moment estimation, Adam) 优化算法,使得学习率在全局最小值附近缓慢变化。

2.4 神经网络的训练

诊断模型的训练包括正向传播、反向传播过程。正向传播过程中,输入数据通过隐藏层向后传播,获得输出

值及输出值和期望值之间的误差。反向传播过程中按照误差最小化的方法更新权重和偏置矩阵。训练开始会进行权重和阈值等参数的初始化,训练过程将一直重复直到模型输出满足精度要求或达到最大训练代数。诊断模型的完整训练流程如图 6 所示。




图 6 诊断模型训练流程
Fig. 6 Flowchart of diagnostic model training

基于上述设计流程训练诊断模型。诊断模型使用 Keras 深度学习库搭建,其 Python 环境版本为 3.7.7。训练用计算机的 CPU 为 Intel Core i7 9750H,内存 16 GB,显卡型号为 GTX 1650,显存 4 GB。经训练与参数调整,诊断模型结构如表 2 所示。

表 2 诊断模型结构
Table 2 Structure of diagnostic model

编号	网络名称	输入维度	输出维度	参数
1	Input	(50,4)	(50,4)	None
2	Conv1D_1	(50,4)	(46,512)	Kernel = 5×1
3	MaxPooling1D	(46,512)	(23,512)	MaxPooling = 2
4	Conv1D_2	(23,512)	(21,128)	Kernel = 3×1
5	Activation_1	(21,128)	(21,128)	Activation = ReLU
6	Flatten	(21,128)	1024	None
7	Dropout	1024	1024	Dropout = 0.4
8	Dense_1	1024	1024	Activation = ReLU
9	Dense_2	1024	1024	Activation = ReLU
10	Dense_3	1024	6	Activation = ReLU
11	Activation_2	6	6	Activation = Softmax

3 结果与讨论

3.1 诊断准确度验证实验

为验证本文提出的 1D-CNN 诊断模型的诊断准确度,课题组利用训练完成的模型对 40 个未在数据集中出现的故障磁场数据样本进行故障类型预测,结果如表 3

所示。由于磁场数据集中双断点类型(3)故障数据明显少于其余 3 种故障类型数据,数据集中数据分布不平衡,这导致诊断模型对(3)类故障的分辨能力和诊断准确率相对其他类型故障较低,但诊断模型的平均诊断准确率可达 97.50%,具有良好的诊断效果。

表 3 诊断模型验证测试结果
Table 3 Diagnosis model verification test results

标签	磁场样本数量	分类正确数量	分类准确率/%
0	11	11	100.00
1	12	12	100.00
2	12	12	100.00
3	5	4	80.00
总计	40	39	97.50

3.2 诊断效果对比

为研究 1D-CNN 诊断模型的效果,本文使用了两种典型深度学习方法进行比较。1) 全连接深度神经网络 (deep neural network, DNN),从文献[20]有关全连接网络在轴承故障诊断中的研究来看,DNN 具有训练快速和精度高的优势,使用 DNN 和本文提出的 1D-CNN 诊断模型对比旨在研究二者在训练速度和识别率上的差别,其结构表示为 D1(512)-D2(2048)-D3(1024)-D4(512)-A(6);2) 循环神经网络 (recurrent neural network, RNN)。应用 GRU 单元的神经网络能有效学习数据的长期依赖关系^[21],对比 RNN 模型和 1D-CNN 诊断模型旨在研究二者对一维序列数据诊断效果的优劣。本节使用的 RNN 神经网络的结构表示为 GRU1(512)-GRU2(256)-D1(2048)-D2(1024)-A(6)。通过受试者工作特征 (receiver operating characteristic, ROC) 曲线、对各类故障的识别准确率、平均测试集精度和平均每代训练时间评估 3 种诊断模型的优劣。

引入 ROC 曲线评估模型诊断能力。多分类问题中,将实例通过分类器映射到特定类可以得出实例属于相应类别的概率,通过计算各阈值下的真正例率和假正例率可以绘出各类别的 ROC 曲线,对各类别的 ROC 曲线取平均即可得出诊断模型的 ROC 曲线。通常以 ROC 曲线与坐标轴形成的面积 (area under curve, AUC) 评估模型诊断能力。

本文使用 2.2 节的接地网断点故障磁场数据集对 3 种模型各进行 15 次训练,每次训练进行 60 代。将 3.1 节的 40 个故障磁场数据样本输入 3 种诊断模型,得出 3 种模型的 ROC 曲线并求解 AUC 值,结果如图 7 所示,其中蓝色实线、红色虚线和绿色点虚线分别代表 1D-CNN、DNN、RNN 诊断模型的 ROC 曲线。从结果可以看出,1D-CNN 模型的 AUC 值为 0.951,大于 DNN 的 AUC 值 (0.932)、RNN 的 AUC 值 (0.851)。通过比较各模型的




图 7 三种模型的 ROC 曲线和 AUC 值对比
Fig. 7 Comparison of ROC curve and AUC value of three models

AUC 值可以看出 1D-CNN 模型的准确性更高,分类效果优于另外两种模型。

引入混淆矩阵分析各模型对不同故障的诊断能力,每种模型随机选取 3 次训练结果。从图 8 所示的结果来看,DNN 能够准确识别正常(0)、单断点(1)、(2)的故障,平均识别率达 80.00%,但对于训练数据较少的双断点故障(3)的诊断则表现不够稳定;RNN 可以识别故障编号为(1)、(2)的梯度较为明显的单个断点故障的磁场数据序列,但对编号(0)和(3)类的故障的诊断效果较差,对各类故障的平均识别率仅为 49.33%;1D-CNN 诊断模型能够准确识别(0)、(1)、(2)类故障,且对(3)类故障的识别率稳定在 70%左右,平均识别率达 92.08%。从模型对各类故障的分类能力来看,1D-CNN 诊断模型优于 DNN 与 RNN。




图 8 三种诊断模型的混淆矩阵对比
Fig. 8 Confusion matrix comparison of three kinds of diagnostic model

在每次训练结束后使用测试集对模型进行验证,各模型的测试集精度结果如表 4 所示。基于 1D-CNN 的诊断模型平均测试集精度为 94.30%,平均每代训练时间为 0.8 750 s,相比 DNN(平均测试集精度 77.13%,均每代训练时间 0.918 6 s)、RNN(平均测试集精度 51.43%,平均每代训练时间 5.960 0 s)表现出了明显的测试集精度和训练速度优势。综上所述,基于 1D-CNN 的诊断模型的各项指标均优于 DNN、RNN,能够快速、准确识别杆塔接地网的断点的数量和位置,且在接地网故障诊断问题中对磁感应强度一维序列数据的处理能力上比 RNN 更有优势。

表 4 三种模型的测试集精度对比

Table 4 Comparison of test set accuracy of three models			
实验序号	DNN/%	RNN/%	基于 1D-CNN 的诊断模型/%
1	0.727 0	0.565 6	0.969 8
2	0.820 5	0.567 1	0.911 2
3	0.859 7	0.518 9	0.974 6
4	0.828 1	0.464 6	0.903 7
5	0.666 7	0.461 5	0.911 2
6	0.840 1	0.527 9	0.942 9
7	0.790 3	0.612 4	0.973 1
8	0.785 8	0.613 9	0.933 9
9	0.727 0	0.567 1	0.974 6
10	0.778 3	0.475 1	0.970 1
11	0.724 0	0.541 9	0.961 0
12	0.802 4	0.595 8	0.944 4
13	0.755 7	0.505 3	0.891 6
14	0.727 0	0.476 8	0.956 5
15	0.737 6	0.220 2	0.926 1
平均	0.771 3	0.514 3	0.943 0

4 结 论

本文构建了杆塔接地网的断点诊断模型,采用仿真与实验共同验证了电磁法的有效性;针对电磁法对断点故障描述不足的问题,提出了使用深度学习方法自动学习接地网断点故障磁场特征的思路;设计了一种基于 1D-CNN 的接地网断点诊断模型并通过自制磁场断点故障数据集进行了训练;进行了诊断模型的准确度验证实验和效果对比实验,通过 4 项指标分析了诊断模型的诊断效果。结果表明,电磁方法能有效描述接地网的断点数量和位置;1D-CNN 诊断模型能准确的诊断断点的数量与位置;同等条件下,1D-CNN 诊断模型的诊断效果、对各类故障的分辨能力比其他深度学习方法更佳,且具有明显的精度和速度优势。目前的工作仅对接地网的断点故障进行了分析,后续研究中将继续优化诊断模型,并进一步研究预测接地导体的腐蚀程度和位置的方法。

参考文献

- [1] FU Z H, WANG X J, WANG Q, et al. Advances and challenges of corrosion and topology detection of grounding grid [J]. Applied Sciences, 2019, 9(11): 2290.
- [2] FAN X, CHEN Y, ZHANG J, et al. Galvanic corrosion behavior of copper-drawn steel for grounding grids in the acidic red soil simulated solution[J]. Acta Metallurgica Sinica-English Letters, 2020, 33(11): 1571-1582.
- [3] 黄新波, 张晓磊, 田毅, 等. 基于电化学法的接地体腐蚀状况检测方法[J]. 广东电力, 2018, 31(4): 9-15.
HUANG X B, ZHANG X L, TIAN Y, et al. Detection method for corrosion of grounding body based on electrochemical method[J]. Guangdong Electric Power, 2018, 31(4): 9-15.
- [4] 吴育毅, 彭敏放, 黄欢, 等. 应用恒电流暂态测量的接地网腐蚀检测方法[J]. 电子测量与仪器学报, 2019, 33(7): 145-151.
WU Y Y, PENG M F, HUANG H, et al. Detection method for corrosion of grounding grid using galvanostatic transient measurement [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 (7): 145-151.
- [5] 刘渝根, 尚龙龙, 冷迪, 等. 基于连续性遗传算法的接地网腐蚀诊断优化[J]. 高电压技术, 2016, 42(5): 1503-1510.
LIU Y G, SHANG L L, LENG D, et al. Optimization of corrosion diagnosis of grounding grid based on continuous genetic algorithm[J]. High Voltage Engineering, 2016, 42(5): 1503-1510.
- [6] 张英娇, 罗先觉, 牛涛, 等. 基于约束总体最小二乘算法的接地网故障诊断新模型[J]. 西安交通大学学报, 2010, 44(10): 110-115.
ZHANG Y J, LUO X J, NIU T, et al. New model of corrosion diagnosis for grounding grids based on constrained total least squares algorithm[J]. Journal of Xi'an Jiaotong University, 2010, 44(10): 110-115.
- [7] 刘洋, 崔翔, 赵志斌. 变电站接地网结构判断与缺陷诊断方法[J]. 中国电机工程学报, 2010, 30(24): 113-118.
LIU Y, CUI X, ZHAO ZH B. Method of structure estimation and fault diagnosis of substations' grounding grids[J]. Proceedings of the Csee, 2010, 30(24): 113-118.
- [8] 司文荣, 王丰华, 穆卡, 等. 应用磁感应强度诊断接地网故障的试验研究[J]. 电气应用, 2016, 35(12): 43-48.
- SI W R, WANG F H, MU K, et al. Experimental research on diagnosis of grounding grid faults by using magnetic induction [J]. Electrotechnical Application, 2016, 35(12): 43-48.
- [9] 谢洪平, 连学森, 黄涛, 等. 矿区变电站进线段杆塔辅助接地网散流特性研究[J]. 工矿自动化, 2020, 46(11): 87-94.
XIE H P, LIAN X S, HUANG T, et al. Research on stray current characteristics of auxiliary grounding grid of incoming line tower of mine [J]. Industry and Mine Automation, 2020, 46(11): 87-94.
- [10] 孙西宁, 高振国, 李冠华. 杆塔接地体冲击特性试验研究[J]. 沈阳工程学院学报(自然科学版), 2020, 16(4): 52-55, 66.
SUN X N, GAO ZH G, LI G H. Experimental study on impulse characteristics of tower grounding body [J]. Journal of Shenyang Institute of Engineering (Natural Science), 2020, 16(4): 52-55, 66.
- [11] 周利军, 梅诚, 古维富, 等. 杆塔接地装置冲击散流的测试技术研究[J]. 仪器仪表学报, 2019, 40(1): 192-199.
ZHOU L J, MEI CH, GU W F, et al. Study on measurement technology of impulse dispersing current in tower grounding device[J]. Chinese Journal of Scientific Instrument, 2019, 40(1): 192-199.
- [12] 黄明祥. 考虑土壤腐蚀的杆塔接地网设计方法[J]. 电力设备管理, 2020(7): 154-156.
HUANG M X. Design method of pole tower grounding grid considering soil corrosion [J]. Electric Power Equipment Management, 2020(7): 154-156.
- [13] 刘兴华, 安韵竹, 咸日常, 等. 杆塔接地网垂直接地降阻及影响因素分析[J]. 山东理工大学学报(自然科学版), 2019, 33(4): 37-41, 45.
LIU X H, AN Y ZH, XIAN R CH, et al. Research on vertical grounding method of reducing transmission tower resistance and influencing fact [J]. Journal of Shandong University of Technology (Natural Science Edition), 2019, 33(4): 37-41, 45.
- [14] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. 仪器仪表学报, 2018, 39(7): 134-143.
QU J L, YU L, YUAN T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dementional convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2018, 39 (7): 134-143.
- [15] XIA M, SILVA C W D E. Gear transmission fault classification using deep neural networks and classifier level sensor fusion [J]. Instrumentation, 2019, 6(2):

- 101-109.
- [16] 魏东, 龚庆武, 来文青, 等. 基于卷积神经网络的输电线路区内外故障判断及故障选相方法研究[J]. 中国电机工程学报, 2016, 36(S1): 21-28.
WEI D, GONG Q W, LAI W Q, et al. Research on internal and external fault diagnosis and fault-selection of transmission line based on convolutional neural network[J]. Proceedings of the CSEE, 2016, 36(S1): 21-28.
- [17] 徐莹莹. 基于模式识别的生物医学图像处理研究现状[J]. 电子与信息学报, 2020, 42(1): 201-213.
XU Y Y. Review of research on biomedical Image proceeding based on pattern recognition[J]. Journal of Electronics & Information Technology, 2020, 42(1): 201-213.
- [18] XU Z, ZHAO J, YU Y, et al. Improved 1D-CNNs for behavior recognition using wearable sensor network[J]. Computer Communications, 2020, 151: 165-171.
- [19] 康云鹏. 基于磁感应强度的变电站接地网腐蚀诊断研究[D]. 西安: 西安科技大学, 2017.
KANG Y P. Research on grounding grid corrosion diagnosis of substation based on magnetic induction[D]. Xi'an: Xi'an University of Science and Technology, 2017.
- [20] 王萌, 曾艳, 刘金童, 等. 基于 FFT 和全连接层特征提取的轴承故障诊断(英文)[J]. 机床与液压, 2020, 48(24): 188-196.
WANG M, ZENG Y, LIU J T, et al. Fault diagnosis of rolling bearing based on FFT and fully connected layer feature extraction[J]. Machine Tool & Hydraulics, 2020, 48(24): 188-196.

- [21] 徐子弘, 季天瑶, 邓伟民, 等. 基于 AE 和 GRU 神经网络的电缆早期故障检测和识别方法[J]. 广东电力, 2020, 33(9): 27-34.
XU Z H, JI T Y, DENG M W, et al. S. Detection and Identification of cable incipient fault based on autoencoder and GRU neural network[J]. Guangdong Electric Power, 2020, 33(9): 27-34.

作者简介



孙绍珩, 2018 年于西南交通大学获得学士学位, 现为西南交通大学硕士研究生, 主要研究方向为智能化检测与故障诊断技术。

E-mail: 499419050@qq.com

Sun Shaoheng received his B. Sc. from Southwest Jiaotong University in 2018. Now he is a M. Sc. candidate at Southwest Jiaotong University. His main research interests include intelligent detection and fault diagnosis technology.



鲁彩江, 2014 年于重庆大学获得博士学位, 现为西南交通大学副教授、博士生导师, 主要研究方向为智能电力机器人、磁电传感器及应用、机电能量采集技术。

E-mail: lucaijiang@swjtu.cn; lucipaper@163.com

Lu Caijiang received his Ph. D. degree from Chongqing University in 2014. Now he is an associate professor and Ph. D. supervisor at Southwest Jiaotong University. His main research interests include intelligent electric robots, magnetoelectric sensors and applications, and electromechanical energy harvesting technology.