

基于改进残差网络的电缆终端缺陷识别方法

焦京海¹,李杰²

(1.中车青岛四方机车车辆股份有限公司,山东 青岛 266000;

2.西南交通大学 电气工程学院,四川 成都 611756)

摘要:针对动车组乙丙橡胶电缆终端缺陷局部放电识别准确率低的问题,提出一种基于改进残差网络的车载电缆终端缺陷识别方法。首先制作了含4种典型绝缘缺陷的电缆终端,搭建局部放电检测平台获取不同缺陷状态的局部放电信号、建立数据集;然后利用特征变换将局部放电一维时序信号转换为二维拓扑特征图像,从而增强缺陷类别的可区分性;最后,在残差网络 ResNet101 模型中加入注意力机制,同时融合 Center 和 Softmax 损失函数进行训练和识别分类,进一步提升准确率。测试结果表明,该诊断方法对电缆终端局部放电的识别准确率达97.3%,相比于其他传统缺陷诊断方法,模型的识别精度更高、均衡性更好。

关键词: EPR 电缆终端;绝缘缺陷;格拉姆角场;残差网络;故障诊断

中图分类号: TM28 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqcd24464

Cable Terminal Defect Diagnosis Method Based on Improved Residual Network

JIAO Jinghai¹, LI Jie²

(1. CRRC Qingdao SIFANG Co., Ltd., Qingdao 266000, Shandong, China; 2. College of Electrical

Engineering, Southwest Jiaotong University, Chengdu 611756, Sichuan, China)

Abstract: To solve the problem of low identification accuracy of partial discharge (PD) for electric multiple units ethylene propylene rubber (EPR) cable terminal defects, an on-board cable terminal defect identification method based on improved residual network was proposed. Firstly, cable terminals with four typical insulation defects were made, and the PD detection platform was built to obtain PD signals of different defect states and establish data sets. Then feature transformation was used to transform PD one-dimensional time series signals into 2D topological feature images to enhance the discriminability of defect categories. Finally, an attention mechanism was added to ResNet101 model of residual network, and Center and Softmax loss function were combined for training and recognition classification to further improve accuracy. The test results show that the identification accuracy of the proposed diagnosis method for PD at cable terminal is 97.3%. Compared with other traditional defect diagnosis methods, the model has higher identification accuracy and better balance.

Key words: ethylene propylene rubber (EPR) cable terminal; insulation defects; Gramian angular field (GAF); residual network; fault diagnosis

动车组乙丙橡胶(ethylene propylene rubber, EPR)电缆是机车电能传输的重要设备^[1],但目前车载电缆终端由人工制作与安装,受限于制作工艺,绝缘层常常存在各种细微缺陷。随着服役里程的增长,缺陷位置容易引发局部放电,使得绝缘劣化,最终导致击穿爆炸事故^[2]。因此,研究车载电缆终端缺陷的智能识别,对保障动车组的安全运行具有重要意义。

目前,基于局部放电信号对电气设备进行缺

陷识别的方法得到了广泛应用,其数据源通常为相位分辨的局部放电(phase resolved partial discharge, PRPD)谱图^[1]或局放脉冲信号^[3]。考虑到我国铁路在线监测技术还未成熟,现场测试时间较短,实际采集到的局部放电数据量十分有限,而PRPD谱图是将局部放电量在相位坐标系上进行叠加,需要一定数量的局放信号才能区分不同缺陷,因此在小样本条件下不便于进行缺陷诊断。此时考虑采用局部放电脉冲信号,结合数据

基金项目:广东省基础与应用基础研究基金(2020B1515130001)

作者简介:焦京海(1971—),男,本科,教授级高级工程师,Email:1281101157@qq.com

分析处理方法对设备缺陷进行识别更加有效。

现有基于局放脉冲信号的缺陷检测方法,通常先采用变分模态分解^[4]、小波包分解^[5]等信号分析手段做预处理,再利用神经网络模型实现缺陷分类。文献[6]基于小波时频变换对局放信号进行处理,利用方向梯度直方图算法实现变压器不同类型局部放电的模式识别;文献[7]基于线性判别分析进行数据降维,在低维样本空间中结合概率神经网络对气体绝缘全封闭组合电器的不同故障进行识别;文献[8]基于卷积神经网络对不同缺陷的直流交联聚乙烯电缆局放脉冲信号进行了缺陷识别。上述研究虽然取得了较好的应用效果,但模型的训练往往需要海量数据^[9],而目前动车组电缆局放训练数据较为匮乏,若将局部放电脉冲信号输入识别网络,将使网络出现梯度弥散的问题,提取的分类特征不充分,模型出现过拟合^[10]。

针对上述问题,本文制作了含4类典型缺陷的EPR电缆试样并采集局放脉冲信号,利用格拉姆角场(Gramian angular field, GAF)特征变换充分挖掘并可视化数据特征,增强数据的可区分性,再利用融合注意力机制和Center损失函数的残差网络构建故障诊断模型,提升网络模型识别性能,实现小样本条件下的EPR电缆终端缺陷的准确识别,为动车组电缆的科学运维提供指导。

1 试验设计

1.1 缺陷样品制作

为保证试验数据贴合实际工程背景,采用型号为QTO-J30G-25kV的动车组车顶高压电缆,根据车载电缆附件现场检修统计结果,设计了4种典型的电缆终端内部缺陷,如图1所示。

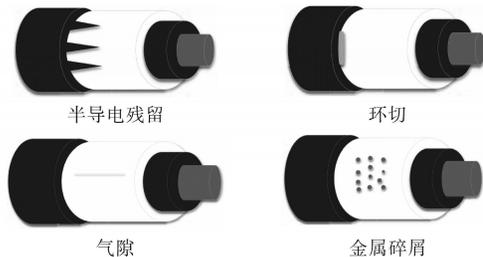


图1 典型缺陷制作

Fig.1 Typical defect fabrication

考虑到局放脉冲信号具有分散性和随机性,每类缺陷均制作了4根电缆试样。其中,各缺陷产生原因不同,制作时保持贴合实际情况。半导体残留是在外半导体层末端截断处未剥除平整而产生的三角倒刺;环切划伤是由于人工下刀力

度过大,导致刀具穿透外半导体层在主绝缘表面留下的划痕,设置为宽1 mm、深0.5 mm环状刀痕;气隙缺陷是由于应力管与主绝缘之间未严格贴合导致的空气缝隙,设置为长50 mm、宽0.5 mm、深1 mm的矩形凹槽;金属缺陷是由于现场环境复杂,在主绝缘上随机粘附的金属微粒。

1.2 试验平台搭建及数据采集

搭建的电缆终端局部放电检测平台如图2所示,试验设置在环境噪声保持为5 pC以下的高压屏蔽室内开展。其中,试验变压器容量为10 kV·A;高压电阻的阻值为400 MΩ;分压器的分压比为1 000:1;耦合电容的电容值为1 000 pF;MPD600为局放检测系统;CPL542为系统的检测阻抗;MCU502为信号处理单元,用于传输局放信号至PC终端做进一步的数据处理。

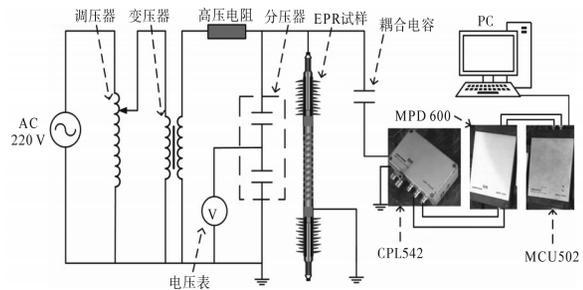


图2 局部放电试验平台

Fig.2 Partial discharge test platform

参考相关标准^[11]开展试验,局部放电采样频率设置为1 kHz。由于局部放电信号具有一定的分散性,本文对每根故障电缆样品均进行3次局放信号采集,并将每个完整的局放信号依次截取为15段由800个采样点组成的脉冲信号。以其中某段局放脉冲信号为例,其放电时序波形如图3所示。

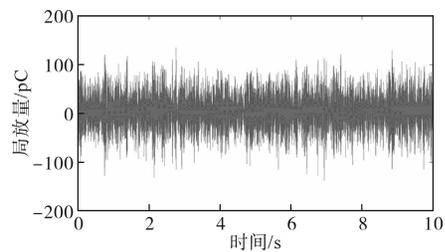


图3 局放脉冲信号

Fig.3 Partial discharge pulse signal

2 诊断方法

2.1 特征变换

本文首先采用GAF对车载EPR电缆终端的局部放电脉冲信号做预处理,增强数据分类特征,以便于后续的图像识别训练。GAF是一种将

一维序列编码转换为二维图谱的特征变换方法^[12],具体步骤如下:

1)对每个时刻的局放脉冲数据进行归一化:

$$\bar{v}_i(t) = \frac{v_i(t) - v_{\min}}{v_{\max} - v_{\min}} \quad (1)$$

式中: $\bar{v}_i(t)$ 为归一化后 t 时刻节点 i 的信号幅值; $v_i(t)$ 为节点信号的幅值; v_{\max}, v_{\min} 分别为节点信号的最大值和最小值。

2)使用极坐标系表征归一化后节点信号幅值数据:

$$\phi_i(t) = \arccos[\bar{v}_i(t)] \quad (2)$$

$$r_i = \frac{i}{N} \quad (3)$$

其中 $\phi_i(t) \in [0, \pi/2]$ $i=1, 2, \dots, N$

式中: $\phi_i(t), r_i$ 分别为 $\bar{v}_i(t)$ 在极坐标系下对应的角度和半径。

3)对极坐标系下不同节点幅值数据进行三角变换,表达式为

$$G = [\bar{v}_i(t) \oplus \bar{v}_j(t)]_{i,j=1}^N \quad (4)$$

式中: \oplus 为内积运算。

若采用两角和的余弦函数计算节点的内积,即为格拉姆角和场(Gramian angular summation field, GASF),若采用正弦函数则为格拉姆角差场(Gramian angular difference field, GADF)。

为了更好地表征局放时序信号包含的拓扑信息,增强不同缺陷间的可区分性,本文结合GASF和GADF在不同区间的单调特性,提出改进的格拉姆角场(improved Gramian angular field, IGAF)特征变换,上三角元素采用余弦函数表征相对关系,由于余弦值在区间 $[\pi/2, \pi]$ 单调递减,表明不同节点的相对关系大小随 $\phi_i(t)$ 值的增大而减弱;下三角元素采用正弦函数,由于正弦值在区间 $[0, \pi/2]$ 单调递增,表明不同节点的相对关系随 $\phi_i(t)$ 值的增大而增强。运算如下式所示:

$$\bar{v}_i(t) \oplus \bar{v}_j(t) = \begin{cases} \cos[\phi_i(t) + \phi_j(t)] & i \leq j \\ \sin[\phi_i(t) - \phi_j(t)] & i > j \end{cases} \quad (5)$$

利用IGAF将局部放电脉冲信号转换为二维特征图像,结果如图4所示。

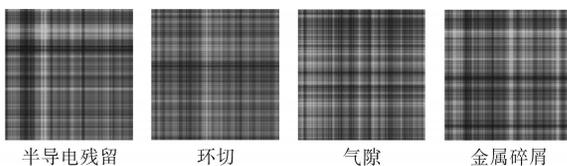


图4 典型缺陷下的拓扑特征图像

Fig.4 Topological feature images of typical defects

2.2 识别模型

2.2.1 残差网络

综合考虑网络复杂度、计算量及特征提取能力,本文基础模型选择残差网络中识别性能较好的ResNet101^[13],其核心是引入了残差模块解决网络深度增加导致的训练退化问题。其网络结构如图5所示,由一系列的Bottleneck块堆积组成,每个Bottleneck块包含残差部分与直接映射部分。输入图像经过预处理后尺寸统一为 $224 \times 224 \times 3$,首先通过卷积、池化层使输入通道数适应Bottleneck块的规格,用33个Bottleneck块完成特征提取,再经过relu激活函数和平均池化层,最后经全连接层实现类别判定。

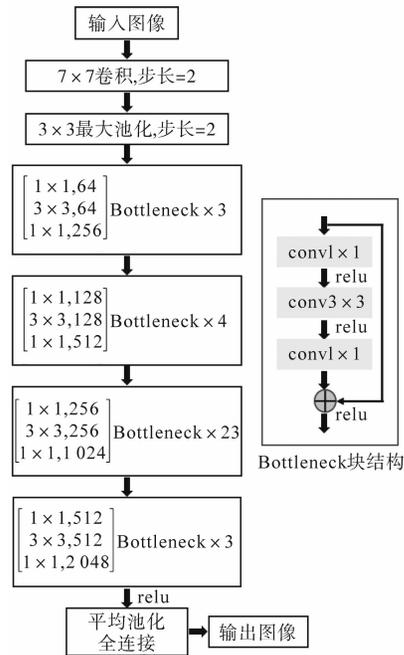


图5 ResNet101模型

Fig.5 ResNet101 model

2.2.2 改进残差模块

残差块的引入能够较好地解决梯度弥散的问题,提高网络模型性能,但是特征提取仍受到拓扑图像对比度低、纹理复杂等因素的影响。为此,本文提出改进的残差网络单元,如图6所示。在残差单元的最后一个卷积之前引入通道注意力(efficient channel attention, ECA)^[14]机制,对特征图中不同通道缺陷分类目标响应程度的依赖特性进行建模,根据响应程度的不同,不断调整特征图,计算和分配各通道权重。较高权重表示响应程度高,即特征图与识别目标相似;较低权重表示响应程度低,即特征图与识别目标差距较大。ECA模块首先利用全局均值池化对输入特

征图的尺寸进行压缩,然后通过卷积实现局部特征之间的跨通道交互,最后采用 Sigmoid 函数获取各通道的权重。其中,局部特征跨通道交互的范围由卷积核 k 决定,大小由下式自适应确定:

$$k = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \quad (6)$$

式中: $\lfloor t \rfloor_{\text{odd}}$ 为距离 t 最近的奇数; C 为特征通道的

数量; γ, b 分别取 2 和 1。

通过自适应校准不同通道之间的响应,模型学习到每个特征通道的重要程度,并增强那些有利于缺陷分类的特征权重值。在改进残差单元的最后,采用一个卷积充分学习 ECA 模块捕捉到的拓扑图像特征,最大限度发挥注意力模块的作用,提升网络模型对电缆终端缺陷的分类能力。

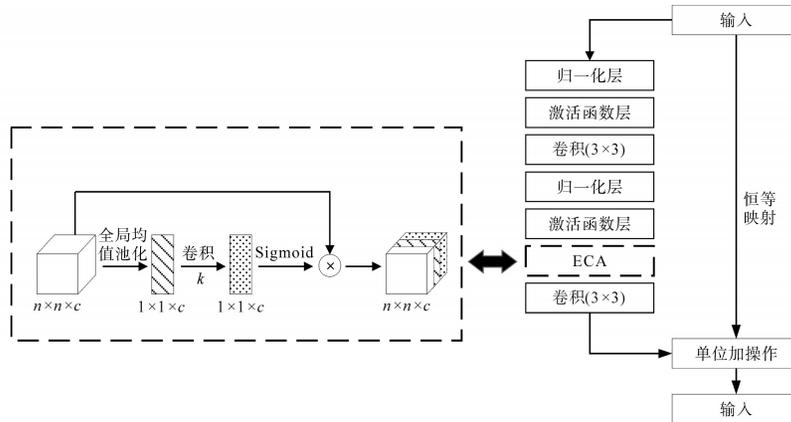


图6 融合注意力机制的残差单元

Fig.6 Residual unit that incorporates the attention mechanism

2.2.3 融合损失函数

由于不同缺陷的局放信号本身较为相似,若采用残差网络本身的 Softmax 损失函数,模型对局部放电所对应缺陷类别的分类准确率较低。为了进一步提高网络模型的缺陷识别能力,本文利用 Center 辅助损失函数具有增大类特征间距的特点,在网络的损失层融合了 Softmax Loss 与 Center Loss 两种损失函数,增强训练模型对不同缺陷的分类能力。融合损失函数计算如下式所示:

$$L = L_s + \lambda L_c$$

$$= -\sum_{i=1}^m \log \frac{e^{\mathbf{W}_{y_i}^T x_i + b_{y_i}}}{\sum_{j=1}^n e^{\mathbf{W}_{y_j}^T x_i + b_{y_j}}} + \frac{\lambda}{2} \sum_{i=1}^m \|x_i - c_{y_i}\|_2^2 \quad (7)$$

式中: \log 函数的自变量为 x_i 属于类别 y_i 的概率; \mathbf{W}_{x+b} 为全连接层的映射输出; m 为训练批次的尺寸; n 为缺陷类别数; λ 为两个损失函数的占比分配权重,经多次试验对比后取 0.2; x_i 为全连接层之前学习到的分类特征; c_{y_i} 为第 y_i 个缺陷的特征中心。

2.3 电缆终端故障诊断框架

基于改进残差网络的电缆终端故障诊断方法如图 7 所示,首先采集含不同缺陷的 EPR 电缆终端局部放电脉冲信号,然后采用 IGAF 做特征变换,建立不同缺陷的二维拓扑特征图像数据集,再利用改进残差网络模型进行训练,最后应用训练好的网络模型对电缆终端进行故障诊断,自动识别局部放电对应的缺陷类型。

集,再利用改进残差网络模型进行训练,最后应用训练好的网络模型对电缆终端进行故障诊断,自动识别局部放电对应的缺陷类型。

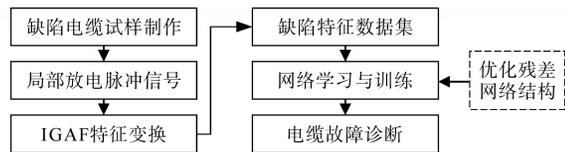


图7 故障诊断框架

Fig.7 Fault diagnosis framework

3 试验结果与分析

3.1 网络训练与分析

选取残差网络中的 ResNet101 模型作为训练网络并根据 2.2 节内容进行改进后,采用迁移学习策略进行训练,选择经典数据集 ImageNet 作为本文模型的源域,冻结部分层的权重,对剩余网络层参数进行微调。考虑到模型最初几层网络用于捕获线条等基本图像元素,这种泛性特征适用于 IGAF 预处理后的图像,因此本文保留预训练模型的前 10 层网络参数,并用两个节点数分别为 1 024 和 4 的全连接层进行替代原 ResNet101 最后的全局平均池化层及全连接层,实现本文车载电缆终端 4 种缺陷的分类。模型装配时采用 Adam 优化器和 Accuracy 精确度。模型训练过程

的准确率与损失值变化情况如图8所示。由图8可知,随着训练轮数的增加,网络的准确率逐渐提高至95%以上,损失值则不断减小并趋于稳定,模型在第10个训练轮次便达到收敛。

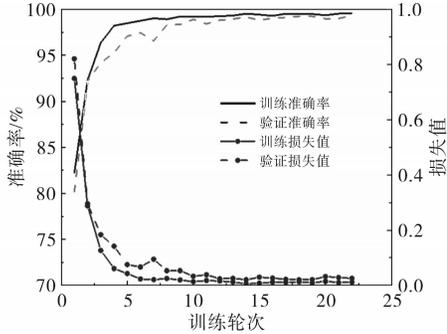


图8 训练准确率与损失值

Fig.8 Training accuracy and loss value

模型的测试结果如图9所示,标签1,2,3,4分别对应半导电残留、环切、气隙和金属碎屑4种缺陷,由混淆矩阵可知,对于112张不同电缆终端缺陷的局放信号测试图像,本文方法的识别准确率达到97.3%,仅存在3个误判缺陷图像。

		实际类别				
		1	2	3	4	
判断类别	1	28	0	0	0	100%
	2	0	27	0	0	100%
	3	0	1	27	1	93.1%
	4	0	0	1	27	96.4%
		100%	96.4%	96.4%	96.4%	97.3%

图9 测试集的混淆矩阵

Fig.9 The confusion matrix of the test set

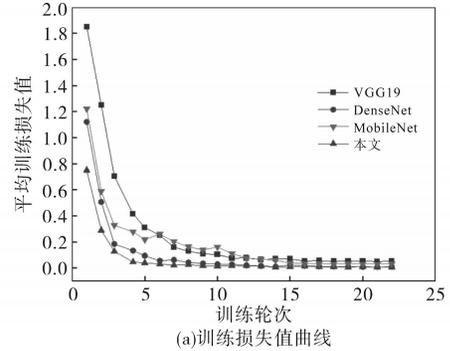
3.2 不同网络模型对比

为探究不同网络模型对本文数据集的识别能力与分类效果,针对IGAF处理后的不同缺陷电缆局部放电二维拓扑图像数据,另外更换了3种常用的卷积神经网络模型进行训练,包括VGG19, DenseNet 和 MobileNet, 迁移学习的源域和微调参数保持不变,所有模型的训练损失值与准确率变化情况如图10所示。由图10可知,4种网络模型均在较少训练轮次下完成了收敛,对比各网络训练损失值及准确率变化情况,VGG19在较少的训练轮数下达到稳定,但其训练准确率较低;DenseNet训练效果较好,但模型收敛速度仍然较慢;本文模型在收敛速度及训练准确率两方面都优于其余3个网络模型,且变化曲线更为平滑。

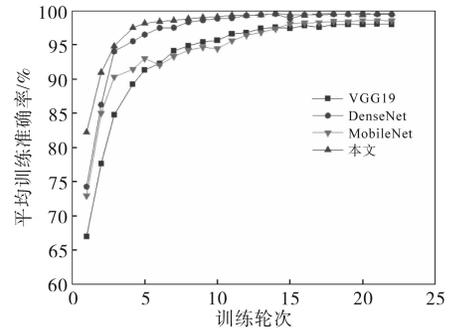
3.3 与传统方法对比结果

为了表明本文所提方法的优越性,针对本文

在第1节获取的4种缺陷下的局部放电脉冲信号数据,采用几种传统局放缺陷识别方法与本文所提方法进行对比研究。



(a)训练损失值曲线



(b)训练准确率曲线

图10 不同网络模型的训练结果对比

Fig.10 Comparison of training results of different network models

其中,第一种方法^[15]是直接基于局部放电脉冲时序信号,使用离散小波变换(discrete wavelet transform, DWT)提取分类特征,再使用支持向量机(support vector machines, SVM)进行缺陷识别,记为DWT-SVM;PRPD-ResNet方法则是将脉冲信号转为局部放电相位谱图,直接利用ResNet101网络模型进行训练和分类;IGAF-改进 ResNet方法则是基于本文所提的改进GAF做特征变换,然后采用文中加入注意力机制与Center损失函数的深度残差网络进行识别。3种方法对测试集的识别结果如表1所示,由表1可知,本文方法相比于其他两种常用的传统方法平均识别准确率更高,而且对不同缺陷的识别均衡性更好。

表1 识别准确率对比

Tab.1 Recognition accuracy comparison

识别方法	半导电残留	环切	气隙	金属碎屑	平均
DWT-SVM	85.7%	89.3%	78.6%	92.9%	86.6%
PRPD-ResNet	78.6%	82.1%	75.0%	85.7%	80.4%
IGAF-改进 ResNet	100%	96.4%	96.4%	96.4%	97.3%

4 结论

本文利用改进格拉姆角场对局放脉冲信号进行特征变换,结合加入注意力机制与Center损

失函数的残差网络模型,对车载EPR电缆终端缺陷识别方法进行了研究,研究结论如下:

1)利用改进GAF对不同缺陷电缆的局放脉冲信号做特征变换,得到相应的二维拓扑特征图像,有效增强了不同类别缺陷的可区分性,便于结合神经网络进行识别分类;

2)采用改进残差网络模型对电缆终端进行缺陷识别的准确率为97.3%;与常用的识别方法对比,所提方法的结合效果最佳,主要体现为模型平均准确率更高、对各类缺陷的识别均衡性更好。

参考文献

- [1] 郭蕾,曹伟东,白龙雷,等.热氧老化EPR电缆绝缘局部放电特性及劣化机理[J].高电压技术,2021,47(1):231-240.
GUO Lei, CAO Weidong, BAI Longlei, et al. Partial discharge characteristics and degradation mechanism of EPR cable insulation by thermo-oxygen aging[J]. High Voltage Engineering, 2021, 47(1):231-240.
- [2] 周利军,刘聪,权圣威,等.基于点对称变换的乙丙橡胶电缆终端缺陷诊断[J].电工技术学报,2022,37(9):2388-2398.
ZHOU Lijun, LIU Cong, QUAN Shengwei, et al. Defect diagnosis of EPR cable terminal based on symmetrized dot pattern[J]. Transactions of China Electrotechnical Society, 2022, 37(9): 2388-2398.
- [3] 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.
- [4] 高佳程,朱永利,郑艳艳,等.基于VMD-WVD分布与堆栈稀疏自编码网络的局放类型识别[J].中国电机工程学报,2019,39(14):4118-4129.
GAO Jiacheng, ZHU Yongli, ZHENG Yanyan, et al. Pattern recognition of partial discharge based on VMD-WVD and SSAE[J]. Proceedings of the CSEE, 2019, 39(14):4118-4129.
- [5] 牛海清,吴炬卓,郭少锋,等.奇异值分解在电缆局部放电信号模式识别中的应用[J].华南理工大学学报(自然科学版),2018,46(1):26-32.
NIU Haiqing, WU Juzhuo, GUO Shaofeng, et al. Application of singular value decomposition to pattern recognition of partial discharge in cable[J]. Journal of South China University of Technology(Natural Science Edition), 2018, 46(1):26-32.
- [6] 李平,田秋松,霍明,等.基于小波变换和HOG特征的变压器局部放电类型识别方法[J].电气传动,2021,51(24):52-56,62.
LI Ping, TIAN Qiusong, HUO Ming, et al. Recognition method of partial discharge type of transformer based on wavelet transform and hog feature[J]. Electric Drive, 2021, 51(24):52-56,62.
- [7] 李君科,李明江,李德光.基于PNN的GIS局部放电模式识别方法[J].电气传动,2021,51(15):45-52.
LI Junke, LI Mingjiang, LI Deguang. GIS partial discharge pattern recognition based on PNN[J]. Electric Drive, 2021, 51(15):45-52.
- [8] 朱煜峰,许永鹏,陈孝信,等.基于卷积神经网络的直流XLPE电缆局部放电模式识别技术[J].电工技术学报,2020,35(3):659-668.
ZHU Yufeng, XU Yongpeng, CHEN Xiaoxin, et al. Pattern recognition of partial discharges in DC XLPE cables based on convolutional neural network[J]. Transactions of China Electrotechnical Society, 2020, 35(3):659-668.
- [9] WANG Shuo, MINKU L L, YAO Xin. Resampling-based ensemble methods for online class imbalance learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2015, 27(5):1356-1368.
- [10] 聂永杰,赵现平,李盛涛. XLPE电缆状态监测与绝缘诊断研究进展[J].高电压技术,2020,46(4):1361-1371.
NIE Yongjie, ZHAO Xianping, LI Shengtao. Research progress in condition monitoring and insulation diagnosis of XLPE cable[J]. High Voltage Technology, 2020, 46(4):1361-1371.
- [11] 全国高电压试验技术和绝缘配合标准化技术委员会.局部放电测量:GB/T 7354—2003[S].北京:中国标准出版社,2003.
National Technical Committee on High Voltage Test Technology and Insulation Fit of Standardization Administration. Partial discharge measurement: GB/T 7354—2003[S]. Beijing: Standards Press of China, 2003.
- [12] 李斌,阎君宇.基于GAF-CNN的弓网电弧识别方法研究[J].电子测量与仪器学报,2022,36(1):188-195.
LI Bin, YAN Junyu. Research on recognition method of pantograph arc based on GAF-CNN[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1):188-195.
- [13] HE K M, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016:770-778.
- [14] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2020.
- [15] 秦雪,钱勇,许永鹏,等.基于2D-LPEWT的特征提取方法在电缆局部放电分析中的应用[J].电工技术学报,2019,34(1):170-178.
QIN Xue, QIAN Yong, XU Yongpeng, et al. Application of feature extraction method based on 2D-LPEWT in cable partial discharge analysis[J]. Transactions of China Electrotechnical Society, 2019, 34(1):170-178.

收稿日期:2022-07-05

修改稿日期:2022-08-17