

基于多声纹和卷积网络的电缆故障诊断方法

张杰¹, 陈强¹, 罗远峰¹, 秦际明¹, 韦举仁¹, 吴北星²

(1. 中国南方电网有限责任公司 超高压输电公司 百色局, 广西 百色 533000;

2. 华北电力大学 河北省输变电设备安全防御重点实验室, 河北 保定 071003)

摘要:电力电缆是电力输送的重要载体, 针对传统的卷积网络模型在采用电缆声纹诊断时存在准确率低、计算量较大的问题, 提出一种基于多声纹特征和轻量化卷积网络的电缆故障诊断方法。首先, 提取三种声纹特征谱图, 包括时频谱图、梅尔谱图和梅尔频率倒谱系数; 其次, 构建轻量化卷积神经网络模型用于多声纹特征提取和融合; 最后, 制作电缆典型缺陷模型, 利用采集的声纹数据进行验证。验证结果表明, 所提方法对电缆三种典型故障类型均能够实现可靠诊断, 平均准确率为 97.6%。本方法相较于仅使用单一的时频谱图、梅尔谱图或梅尔频率倒谱系数特征诊断方法, 在准确率上分别提升约 1.3%, 3.1% 和 3.1%。同时, 与 AlexNet, MobileNetV2 和 GoogleNet 模型相比, 本方法的准确率分别提高 1.3%, 0.7% 和 4.4%, 每批次训练时间分别减少 172.3 s, 18.2 s 和 69.4 s, 模型文件大小分别减少 193.4 MB, 14.6 MB 和 25.7 MB。

关键词:电力电缆; 声纹; 卷积神经网络; 局部放电; 多特征融合

中图分类号: TM855 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed25920

Cable Fault Diagnosis Method Based on Multiple Vowels and Convolutional Networks

ZHANG Jie¹, CHEN Qiang¹, LUO Yuanfeng¹, QIN Jiming¹, WEI Juren¹, WU Beixing²

(1. Baise Bureau, CSG EHV Power Transmission Company, Baise 533000, Guangxi, China;

2. Hebei Provincial Key Laboratory of Power Transmission Equipment Security Defense,
North China Electric Power University, Baoding 071003, Hebei, China)

Abstract: Power cable is an important carrier of power transmission. To solve the problems of low accuracy and large computation in voicing diagnosis with traditional convolutional neural network model, a novel cable fault diagnosis method based on multiple voicing features and lightweight convolutional neural network was proposed. Firstly, three feature maps were extracted, including spectrogram, mel spectrum and mel-frequency cepstral coefficients. Secondly, a lightweight convolutional neural network model was constructed for multi-feature extraction and fusion. Finally, the typical defect model of cable was made and verified by the voiceprint data collected on site. The verification results show that the proposed method can achieve reliable diagnosis of three typical fault types with an average accuracy of 97.6%. Compared with only using a single spectrogram, mel spectrum or mel-frequency cepstral coefficients feature diagnosis method, the accuracy of this method was improved by about 1.3%, 3.1% and 3.1% respectively. Meanwhile, compared with AlexNet, MobileNetV2 and GoogleNet, the accuracy of the proposed method was increased by 1.3%, 0.7% and 4.4%, the training time of each batch was reduced by 172.3 s, 18.2 s and 69.4 s, and the model file size was reduced by 193.4 MB, 14.6 MB and 25.7 MB respectively.

Key words: power cable; voice print; convolutional neural network (CNN); partial discharge; multi-feature fusion

随着社会经济飞速发展, 电力电缆在电网输电运行中, 因其本身的质量问题、安装工艺以及外
配电建设中的使用占比逐年增加。在电缆长期界外力的作用下可能导致电缆本体以及附件的

基金项目: 中国南方电网有限责任公司科技项目 (CGYKJXM20220153)

作者简介: 张杰 (1981—), 男, 硕士研究生, 高级工程师, 主要研究方向为变电设备运维及管理工作, Email: 635121351@qq.com

通讯作者: 吴北星 (2000—), 男, 硕士研究生, 主要研究方向为电气设备在线监测与故障诊断, Email: 1842119198@qq.com

绝缘性能下降,最终致使绝缘击穿产生故障^[1-2]。针对故障初期的电缆,对电缆局部放电信号进行监测是评估电缆绝缘状态和缺陷情况的有效手段^[3-4]。

目前,局部放电的检测方法主要有脉冲电流法、超高频检测法以及超声检测法等^[5]。脉冲电流法是局部放电检测中最准确的方法,但其抗干扰能力较差,在电缆现场复杂环境中往往无法满足技术要求。超高频检测法通过超宽频带天线检测电缆局部放电产生的超高频电磁波,但由于超高频信号在电缆的金属护套和半导体层中存在较严重的衰减,因此检测范围有限^[6]。超声检测法通过超声传感器捕获局部放电产生的超声信号,受电磁干扰较小并且安装便利,得到了广泛关注。超声检测法中,文献[7]采用主成分分析法从声音信号的频谱特征中提取关键信息,并通过支持向量机分类识别,以判断变压器的运行状态。但传统的机器学习算法(如支持向量机),对复杂的抽象特征提取能力较差,诊断准确率往往不高,需要考虑其他方法。因此,本文采用超声检测方法对电缆局部放电进行检测,对采集的电缆声音信号进行声纹特征提取,并采用深度学习技术对提取的特征进行分类与识别。

深度学习技术具有强大的特征提取能力,其中以卷积神经网络(convolutional neural network, CNN)为代表的深度学习模型在电力设备故障辨识和检测中的应用逐步扩大^[8-9]。文献[10]针对设备振动信号距离映射递归图,采用CNN对其进行故障识别。文献[11]采用基于改进CNN的深度残差收缩网络对高噪声环境下的电缆进行故障识别。文献[12]在对超声信号进行预处理时,提出了盲源分离技术,然后采用CNN对提取的局部放电特征量进行局部放电模式识别。然而,目前很多方法一般采用单一声纹特征,如使用梅尔谱图或梅尔频率倒谱系数(mel-frequency cepstral coefficients, MFCC)特征进行故障诊断识别,因此可能会无法充分利用声音信息,降低诊断准确率。同时,传统的CNN模型面临参数较大、计算速度慢的缺陷,在嵌入式系统研发和在线监测领域难以充分发挥其性能。

针对上述问题,本文提出一种基于多声纹特征和轻量化卷积神经网络的电缆故障诊断方法。首先,从多个角度分别提取电缆故障声纹特征,包括时频谱图、梅尔谱图和MFCC特征。然后对

MoblieNetV3模型进行改进以实现多特征提取,并构建了一个融合多特征的轻量化卷积网络。最后,制作电缆典型缺陷模型,通过实验采集的声纹数据进行验证。结果显示,与其他经典神经网络相比,该模型在拥有较高准确率的同时,还具有更快的训练速度和更少的内存空间占用。

1 多声纹特征谱图构建

电缆在运行中产生的声音数据包含大量的状态信息,不同类型的电缆局部放电故障会产生不同特性的声音信号。通过构建声纹特征谱图,可以分析这些信号的幅度、频率、时间间隔等参数的变化情况,从而识别出局部放电类型。传统基于声纹的故障诊断方法仅采用某一种声纹特征,难以充分利用声音数据,在进行故障诊断时准确率较低。本节从多角度分别提取时频谱图、梅尔谱图以及MFCC等声纹特征并保存为图片,为后续采用MobileNetV3轻量化卷积网络进行多声纹特征的融合与电缆的故障诊断提供数据。

1.1 时频谱图

时频谱图是一种表示声音的频谱随时间变化的图形,综合了时域图像和频域图像的信息,反映故障声音信号在时间和频率两个维度上的特征。不同类型的局部放电故障会在不同的频率范围内产生显著的能量集中,并且具有特定的时间分布规律,比如放电的持续时间以及放电时间间隔等。图1是时频谱图的提取流程图。




图1 声纹时频谱图绘制流程图

Fig.1 Flow chart of voicing time spectrogram drawing

时频谱图的提取流程包括预加重、分帧、加窗、离散傅里叶变换、求对数功率和拼接等步骤。

1.1.1 预加重

预加重是声音信号处理的第一步操作,能够保持信号的低频部分不变,提升信号的高频部

分。本文采用一阶高通滤波器实现:

$$H(z) = 1 - \mu z^{-1} \quad (1)$$

其中, μ 的值一般接近于 1, 本文取 0.95。

1.1.2 分帧

虽然声音信号具有时变特性, 但在一个短时间范围内, 其特性基本保持不变, 即认为其具有短时平稳性。因此可以将声音信号分为一个个片段进行处理, 每一段称为一帧。为了使帧与帧之间平滑过渡, 保持其连续性, 帧与帧之间存在重叠。本文声音信号每帧长度为 512, 每帧移动长度为 256。

1.1.3 加窗

加窗即将每帧声音信号与一个窗函数相乘, 加窗的目的包括以下两点: 1) 使声音信号在全局更加连续, 避免出现吉布斯效应^[13]; 2) 原本没有周期性的声音信号呈现出周期函数的部分特征。

加窗的代价是每帧信号的两端部分被削弱, 所以在分帧时要求每帧之间存在重叠。本文的窗函数采用汉明窗:

$$W(a) = \begin{cases} 0.54 - 0.46 \cos\left(\frac{2\pi a}{A-1}\right) & 0 \leq a \leq A-1 \\ 0 & \text{其他} \end{cases} \quad (2)$$

式中: A 为汉明窗的长度, 本文取 512。

1.1.4 离散傅里叶变换

离散傅里叶变换能够将离散的时域信号转换为其在离散频域上的表示。对每一帧声音信号进行离散傅里叶变换, 得到 $S_i(k)$ 如下式所示:

$$S_i(k) = \sum_{n=0}^{N-1} s_i(n) e^{-\frac{j2\pi kn}{N}} \quad 0 \leq k \leq N-1 \quad (3)$$

式中: N 为傅里叶变换点数, 本文取 512。

1.1.5 求功率对数

对一帧声音信号计算离散傅里叶变换后, 根据 $S_i(k)$ 计算能量密度函数 $P_i(k)$:

$$P_i(k) = |S_i(k)|^2 \quad (4)$$

根据 $P_i(k)$ 计算对数功率, 得到频谱的幅度值如下:

$$P_i^{\text{dB}}(k) = 10 \lg P_i(k) \quad (5)$$

由此得到每帧信号的频谱, 其数值表示该帧信号中不同频率分量的功率。

1.1.6 拼接

按照上述步骤计算得到的是一帧信号的频谱, 对于得到的每帧信号的功率谱, 按照时间顺序拼接, 就构成整段声音信号的时频谱图。对于

时频谱图, 纵轴表示频率信息, 横轴是当前帧对应的的时间信息, 坐标点数值表示对应时刻与频率下的功率大小。

1.2 梅尔谱图

梅尔谱图是将经傅里叶变换得到的数据计算能量密度后, 再经过梅尔滤波器组计算得到的频谱图。梅尔谱图在声音识别领域能够很好地模拟人耳的听觉特性, 由于人耳对低频变化比高频变化更敏感, 因此梅尔谱图将原本的线性谱图转化为对数谱图^[14]。梅尔谱图在处理音频信号时强调低频部分信息, 这对于提取超声信号中可能存在的低频特征尤为重要, 这些低频特征可能包含与电缆故障相关的信息。在超声信号中, 由于环境噪声的干扰, 可能导致信号质量下降, 梅尔谱图能够在一定程度上降低这些噪声对故障特征提取的影响, 梅尔谱图的提取也是后续提取 MFCC 特征的重要环节。梅尔频率与实际频率之间的转换公式为

$$f_{\text{Mel}} = 2595 \lg\left(1 + \frac{f}{700}\right) \quad (6)$$

式中: f 为实际频率; f_{Mel} 为转换后的梅尔频率, 实际频率越大, 转换后就变得越平缓。

梅尔谱图的提取流程如图 2 所示。




图 2 梅尔谱图、MFCC 特征提取的流程图

Fig.2 The extraction flow chart of Mel spectrum and MFCC feature

梅尔滤波采用一个等高的三角滤波器组, 每个滤波器的起始点在上一个滤波器的中点处^[15]。其对应的频率在梅尔尺度上是线性的, 因此称之为梅尔滤波器组。

梅尔滤波器组的公式为

$$H_m(K) = \begin{cases} 0 & k < f(m-1) \\ \frac{k-f(m-1)}{f(m)-f(m-1)} & f(m-1) \leq k \leq f(m) \\ 1 & k = f(m) \\ \frac{f(m+1)-k}{f(m+1)-f(m)} & f(m) \leq k \leq f(m+1) \\ 0 & k > f(m+1) \end{cases} \quad (7)$$

式中: m 为滤波器的序号; $f(m-1)$ 、 $f(m)$ 和 $f(m+1)$ 分别对应第 m 个滤波器的起始位置、中间位置和结束位置。

1.3 MFCC 梅尔频率倒谱系数

梅尔频率倒谱系数是对进行对数运算后的梅尔频谱进行离散余弦变换得到的结果^[16]。实质上,这相当于将本来处于频域的信号视作时域信号,然后强制进行频域变换,得到频域信号在伪频域上的幅度-频率响应。倒谱分析可用于信号的分解,将两个信号的卷积转化为两个信号的相加^[17],进而实现信号处理与分析的目的。在倒谱系数中,前2~13个系数描绘了信号的包络特征,这些系数在伪频域中对应信号的低频部分^[18],而后续系数反映了伪频域的高频部分。在声音识别中,低频部分更为重要,与设备的故障状态密切相关。同时,低频成分在信号中较为稳定,受噪声等干扰因素的影响较小,能够在复杂的诊断环境中保持较高的故障检测率和诊断准确性。

梅尔频率倒谱系数计算步骤见图2。由于人耳对声音的感知并不是线性的,用对数这种非线性关系更好描述^[19],计算每个滤波器组输出的对数为

$$s(m) = \ln \left[\sum_{k=0}^{N-1} |X_a(k)|^2 H_m(k) \right] \quad 0 \leq m \leq M$$

(8)

进行对数运算后再进行倒谱分析,在这一步的基础上进行离散余弦变换,可看作特殊的傅里叶变换,计算公式如下:

$$C(n) = \sum_{m=0}^{N-1} s(m) \cos \frac{\pi n(m-0.5)}{M} \quad n = 1, 2, \dots, L$$

(9)

式中: L 为MFCC系数阶数,通常取2~13; M 为三角滤波器个数。

2 基于多声纹和轻量化卷积的电缆故障诊断方法

2.1 轻量化卷积网络模型

本文采用MobileNetV3轻量化卷积神经网络对多声纹特征进行提取。该网络基于MobileNetV1和MobileNetV2模型进行改进,采用深度可分离卷积来替代传统的卷积操作,以减少计算量,以线性瓶颈的逆残差结构作为基本卷积模块扩张通道数,使得高维信息在经过激活函数后丢失的信息更少。模型网络结构具体参数如表1

所示。

表1 模型参数结构

Tab.1 Model parameter structure

输入	操作	输出矩阵深度	步长	激活函数
224 ² ×3	Conv2d	16	2	h-swish
112 ² ×16	Bneck, 3×3	16	1	Relu
112 ² ×16	Bneck, 3×3	24	2	Relu
56 ² ×24	Bneck, 3×3	24	1	Relu
56 ² ×24	Bneck, 5×5	40	2	Relu
28 ² ×40	Bneck, 5×5	40	1	Relu
28 ² ×40	Bneck, 5×5	40	1	Relu
28 ² ×40	Bneck, 3×3	80	2	h-swish
14 ² ×80	Bneck, 3×3	80	1	h-swish
14 ² ×80	Bneck, 3×3	80	1	h-swish
14 ² ×80	Bneck, 3×3	80	1	h-swish
14 ² ×80	Bneck, 3×3	112	1	h-swish
14 ² ×112	Bneck, 3×3	112	1	h-swish
14 ² ×112	Bneck, 5×5	160	2	h-swish
7 ² ×160	Bneck, 5×5	160	1	h-swish
7 ² ×160	Bneck, 5×5	160	1	h-swish
7 ² ×160	Conv2d, 1×1	960	1	h-swish
7 ² ×960	Pool, 7×7	—	1	—
1 ² ×960	Conv2d, 1×1	1 280	1	h-swish
1 ² ×1 280	Conv2d, 1×1	n	1	—

表1中,每个Bneck结构采用深度可分离卷积、注意力机制和非线性激活函数等对特征进行提取。在网络的前几层采用Relu激活函数快速学习并提取重要特征,同时减少计算成本,随着网络深度的增加,特征变得更加复杂和抽象,有助于提高模型的非线性表达能力,从而更好地捕捉复杂特征和细节。

2.2 基于轻量化卷积的多声纹特征融合模型

基于轻量化卷积的多声纹特征融合模型采用MobileNetV3轻量化卷积神经网络架构进行构建,对声纹的时频谱图、梅尔谱图以及MFCC特征进行特征提取,并对提取的特征进行融合,以实现电缆故障的准确识别。为了实现上述操作,本文对MobileNetV3网络进行了改进。具体的模型结构如图3所示,图中Conv为卷积层,pool为池化层,FC为全连接层。该模型由3个子MobileNetV3网络构成,每个子网络的结构和参数数量相同。对于上述3种声纹谱图,分别采用3个子网络对各种声纹谱图进行特征提取。在每个子网络的最后一层,并不是直接使用1×1的卷积层直接对故障类型进行分类,而是添加一个特征融

合模块,将3个子 MobileNetV3 网络提取的特征向量进行拼接,从而实现多声纹特征的融合。最后使用一个全连接层和 softmax 层对融合后的特

征向量进行分类,得到每种电缆故障的概率值,并选择最大的概率值所对应的故障类型作为诊断结果。




图3 模型结构图

Fig.3 Model structure diagram

3 故障样本集的构建

3.1 典型缺陷设置

本文根据电缆的绝缘材料分别设计了毛刺放电模型、气隙放电模型和沿面放电模型进行实验。3种电缆模型如图4所示,单层绝缘板厚度为2 mm,高压电极与地电极材料为金属铜。




图4 放电模型示意图

Fig.4 Discharge model diagram

图4a为毛刺放电模型,地电极直径为80 mm,钢针针尖曲率半径为48.2 μm ,顶在单层绝缘材料表面,但不与地电极接触。图4b为内部气隙放电模型,高压电极和地电极直径均为80 mm,将单层绝缘材料中心位置打通一个直径为2 mm的圆孔,将有圆孔的绝缘材料放在中间层,使用环氧树脂将三层绝缘材料粘合。图4c为沿面放电模型,高压电和地电极直径分别为25 mm和90 mm,在两电极间是单层绝缘材料,直径为80 mm。

3.2 声纹谱图预处理

在进行深度学习训练之前,还需将提取的3种故障缺陷对应的时频谱图、梅尔谱图以及 MFCC 特征按以下的流程进行预处理:1)归一化幅值;2)去除能量条;3)灰度化。采用预处理后的谱图制作声纹识别样本库,图5展示了部分电缆故障声纹样本。后续训练使用的数据集选自该样本库中的27 000张图像,每种故障缺陷均选取3 000张时频谱图、梅尔谱图和 MFCC 图片。训练集和测试集按4:1比例划分。数据集的具体划分结果如表2所示。

表2 数据集划分结果

Tab.2 Division of data sets

数据集	训练集数量/个	测试集数量/个	标签
毛刺放电	7 200	1 800	0
气隙放电	7 200	1 800	1
沿面放电	7 200	1 800	2




图5 处理后的样本集

Fig.5 Sample set after processing

4 实验验证

4.1 实验流程

基于多声纹特征和轻量化卷积的电缆故障诊断模型实验流程如图6所示,具体步骤如下:

- 1) 获取电缆在不同局部放电类型下的声音数据,对数据进行预处理并提取多种声纹特征谱图,将获得的数据集划分为训练集和测试集。
- 2) 搭建轻量化卷积神经网络并使用训练集对其进行训练,保存训练完成的模型。
- 3) 将测试集输入到训练好的模型,对模型进行验证。




图6 实验流程示意图

Fig.6 Diagnostic process diagram

4.2 模型训练与结果分析

利用前面预处理得到的数据集对改进后的模型进行训练,以最小化交叉熵损失作为目标函数,选择 Adam 优化器进行优化,学习率设为 0.001。网络训练过程的准确率与损失值变化情况如图7所示。由图7可知,随着迭代次数的增加,网络的准确率逐渐提高并稳定在 97.6% 附近,损失值则不断减小并趋于稳定,迭代批次达到 20

时,模型便基本收敛。




图7 模型训练过程

Fig.7 Model training process

为了确定模型对电缆局部放电故障的具体诊断情况,以混淆矩阵的形式展示了模型在测试集上的诊断结果,如图8所示。

实际值	毛刺	0.978	0.014	0.008
	气隙	0.014	0.971	0.015
	沿面	0.007	0.015	0.978
		预测值		

图8 混淆矩阵

Fig.8 Confusion matrix

在混淆矩阵中,纵轴表示样本的实际值,横轴表示样本的预测值,主对角线上的数值为对应故障诊断正确的概率。由图8可知,对于毛刺放电故障,诊断准确率为 97.8%;对于气隙放电故障,诊断准确率为 97.1%;对于沿面放电故障,诊断准确率为 97.8%;综合诊断准确率为 97.6%。

4.3 不同深度学习模型对比分析

为了验证本文所提模型的优越性,并深入探究不同声纹特征提取模块对模型性能的影响,将所提模型分别与采用单一时频谱图、梅尔谱图或 MFCC 声纹特征的模型计算结果进行了对比,其中每个模型均采用 MobileNetV3 网络,结构参数均相同。图9和图10展示了不同模型计算准确率与损失值随迭代次数的变化关系。

从图中可以发现,采用基于多声纹特征融合模型准确率约为 97.6%,高于采用单声纹特征的模型。对于采用单声纹特征进行故障诊断时,在模型最终收敛时,采用时频谱图进行诊断的模

型准确率最高,约为96.3%;采用梅尔谱图和MF-CC作为声纹特征进行故障诊断的模型准确率接近,约为94.5%。从收敛速度方面看,本文所采用的模型收敛速度最快,在迭代20个批次后就已经基本收敛,而采用单一特征的模型收敛速度相对较慢。由此也可推断,所提多声纹特征融合的模型中,时频谱图提取子模块对电缆故障诊断的贡献最大。

为直观对比所提模型较其他模型的优越性,本文所提模型分别与 AlexNet, MobileNetV2 及 GoogleNet 等模型进行了参数文件大小、训练速度以及在测试集上的准确率结果三个方面的对比,结果如表3所示。

相较于其他三种模型,本文模型在准确率、参数文件大小以及训练速度等方面均较优。在准确率方面,本文模型比 AlexNet, MobileNetV2 及 GoogleNet 模型分别提高 1.3%, 0.7% 和 4.4%; 每批次训练时间分别减少 172.3 s, 18.2 s 和 69.4 s; 模型文件大小分别减少 193.4 MB, 14.6 MB 和 25.7 MB。

表3 模型准确率、参数文件大小与训练速度对比

Tab.3 Comparison of model accuracy, parameter file size and training speed

模型名称	前50次训练平均准确率/%	参数文件/MB	训练速度/(s·step ⁻¹)
本文网络	97.6	19.6	21.2
AlexNet	96.3	213	193.5
MobileNetV2	96.9	34.2	39.4
GoogleNet	93.2	45.3	90.6

5 结论

针对传统基于单一声纹特征的电缆故障诊断模型所存在的问题,本文提出了一种基于多声纹特征和 MobileNetV3 网络的电缆故障缺陷诊断方法。所提方法具有如下优势:

1) 所提方法对电缆缺陷声纹的时频谱图、梅尔谱图和 MFCC 特征进行提取,弥补了单一声纹特征包含特征不足的缺陷,提高了对电缆缺陷故障声音的利用率。

2) 对 MobileNetV3 网络模型进行改进,实现时对频谱图、梅尔谱图和 MFCC 的多声纹特征融合,提高了对故障缺陷的诊断效果。

3) 经实验对比,本文所提基于多声纹特征和 MobileNetV3 网络的电缆故障缺陷诊断方法在准确率、模型文件大小以及迭代速度等方面与传统

深度学习模型相比具有较大优势。在电缆故障在线监测或嵌入式系统设备开发等方面具有较大的应用场景。

参考文献

- [1] 王明海. 高压电缆局部放电在线监测技术研究[D]. 北京: 北京交通大学, 2019.
WANG Minghai. Study on partial discharge on-line monitoring technology of high voltage cable[D]. Beijing: Beijing Jiaotong University, 2019.
- [2] 王昊月, 李成榕, 王伟, 等. 高压频域介电谱诊断 XLPE 电缆局部绝缘老化缺陷的研究[J]. 电工技术学报, 2022, 37(6): 1542-1553.
WANG Haoyue, LI Chengrong, WANG Wei, et al. Local aging diagnosis of XLPE cables using high voltage frequency domain dielectric spectroscopy[J]. Transactions of China Electrotechnical Society, 2022, 37(6): 1542-1553.
- [3] 马鑫, 张怀垠, 吴继岩, 等. 温度对交联聚乙烯电缆尖刺缺陷局部放电特性的影响[J]. 高压电器, 2021, 57(5): 151-156.
MA Xin, ZHANG Huaiyin, WU Jiyan, et al. Effect of temperature on partial discharge characteristics of needle defects in cross-linked polyethylene cable[J]. High Voltage Apparatus, 2021, 57(5): 151-156.
- [4] 罗海静, 柳赞. 10 kV XLPE 电缆中局部放电声波衰减规律研究[J]. 电力科学与技术学报, 2023, 38(2): 186-195.
LUO Haijing, LIU Yun. Study on the acoustic wave attenuation of partial discharge in 10 kV XLPE cable[J]. Journal of Electric Power Science and Technology, 2023, 38(2): 186-195.
- [5] 李军浩, 韩旭涛, 刘泽辉, 等. 电气设备局部放电检测技术述评[J]. 高电压技术, 2015, 41(8): 2583-2601.
LI Junhao, HAN Xutao, LIU Zehui, et al. Review on partial discharge measurement technology of electrical equipment[J]. High Voltage Engineering, 2015, 41(8): 2583-2601.
- [6] 魏力强, 王东林, 齐锦涛, 等. 电力电缆局部放电试验及在线监测技术分析[J]. 河北电力技术, 2018, 37(6): 54-57.
WEI Liqiang, WANG Donglin, QI Jintao, et al. Analysis on partial discharge test method and on-line detection technology for power cable[J]. Hebei Electric Power, 2018, 37(6): 54-57.
- [7] 侯增起. 基于声音特征的变电设备故障分类与定位方法研究[D]. 保定: 华北电力大学, 2018.
HOU Zengqi. Research on fault classification and location method of transformer equipment based on sound features[D]. Baoding: North China Electric Power University, 2018.
- [8] 刘云鹏, 许自强, 李刚, 等. 人工智能驱动的数据分析技术在电力变压器状态检修中的应用综述[J]. 高电压技术, 2019, 45(2): 337-348.
LIU Yunpeng, XU Ziqiang, LI Gang, et al. Review on applications of artificial intelligence driven data analysis technology in condition based maintenance of power transformers[J]. High Voltage Engineering, 2019, 45(2): 337-348.

- [9] 张毅斌,李梦诗,徐子弘,等. 基于轨迹图像与卷积神经网络的电缆早期故障识别[J]. 广东电力,2022,35(8):86-94.
ZHANG Yibin, LI Mengshi, XU Zihong, et al. Cable incipient fault identification based on trajectory image and convolutional neural network[J]. Guangdong Electric Power, 2022, 35(8): 86-94.
- [10] 曾全昊,王丰华,郑一鸣,等. 基于卷积神经网络的变压器有载分接开关故障识别[J]. 电力系统自动化,2020,44(11):144-151.
ZENG Quanhao, WANG Fenghua, ZHENG Yiming, et al. Fault recognition of transformer on-load tap-changer based convolutional neural network[J]. Automation of Electric Power Systems, 2020, 44(11): 144-151.
- [11] 吴卫堃,宫士营,郑耀华,等. 基于DRSN的高噪声环境下XLPE电缆故障识别[J]. 电气传动,2022,52(16):75-80.
WU Weikun, GONG Shiyong, ZHENG Yaohua, et al. Fault identification of XLPE cable in high noise environment based on DRSN[J]. Electric Drive, 2022, 52(16): 75-80.
- [12] 张重远,岳浩天,王博闻,等. 基于相似矩阵盲源分离与卷积神经网络的局部放电超声信号深度学习模式识别方法[J]. 电网技术,2019,43(6):1900-1906.
ZHANG Chongyuan, YUE Haotian, WANG Bowen, et al. pattern recognition of partial discharge ultrasonic signals based on similar matrix BSS and deep learning CNN[J]. Power System Technology, 2019, 43(6): 1900-1906.
- [13] 罗相林,秦雪佩,贾年. 基于MFCC及其一阶差分特征的语音情感识别研究[J]. 现代计算机,2019(11):20-24.
LUO Xianglin, QIN Xuepei, JIA Nian. Research on speech emotion recognition based on MFCC and its first-order difference features[J]. Modern Computer, 2019(11): 20-24.
- [14] 万可力,马宏忠,崔佳嘉,等. 基于Mel-GADF与ConvNeXt-T的变压器铁心松动故障诊断方法[J]. 电力自动化设备,2024,44(3):217-224.
WAN Keli, MA Hongzhong, CUI Jijia, et al. Fault diagnosis method of transformer core loosening based on Mel-GADF and ConvNeXt-T[J]. Electric Power Automation Equipment, 2024, 44(3): 223-230.
- [15] 李大鹏,周晓彦,王基豪,等. 基于Mel频谱值和深度学习的鸟声识别算法[J]. 应用声学,2023,42(4):825-832.
LI Dapeng, ZHOU Xiaoyan, WANG Jihao, et al. Bird voice recognition algorithm based on Mel spectrum value and deep learning network[J]. Journal of Applied Acoustics, 2023, 42(4): 825-832.
- [16] 崔丽霞,许利显. 基于Bi LSTM-CTC的语音识别系统研究[J]. 自动化与仪器仪表,2023(10):90-94.
CUI Lixia, XU Lixian. Research on speech recognition system based on Bi LSTM-CTC[J]. Automation & Instrumentation, 2023(10): 90-94.
- [17] 苏力,李阳,庞宇辰. 基于Labview软件的MFCC特征参数提取程序设计[J]. 科学技术创新,2018(5):80-81.
SU Li, LI Yang, PANG Yuchen. Design of MFCC feature parameter extraction program based on Labview software[J]. Scientific and Technological Innovation, 2018(5): 80-81.
- [18] 张衡,刘海江. 基于MFCC与PNN的高精密航天器多余物材质特征识别方法[J]. 航天器环境工程,2023,40(5):522-530.
ZHANG Heng, LIU Haijiang. A method for feature identification of remainder material in high precision spacecraft based on MFCC and PNN[J]. Spacecraft Environment Engineering, 2023, 40(5): 522-530.
- [19] 于达,张玮,王辉. 基于LSTM神经网络的油浸式变压器异常声纹诊断方法研究[J]. 智慧电力,2023,51(2):45-52.
YU Da, ZHANG Wei, WANG Hui. Abnormal voiceprint diagnosis method of oil-immersed transformer based on LSTM neural network[J]. Smart Power, 2023, 51(2): 45-52.

收稿日期:2024-05-09

修改稿日期:2024-06-22