

DOI: 10.12158/j.2096-3203.2023.05.006

基于声纹特征和集成学习的变压器缺陷诊断方法

陆云才¹, 廖才波², 李群¹, 王同磊¹, 邵剑¹, 张一³

(1. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211102; 2. 南昌大学信息工程学院, 江西 南昌 330031; 3. 南京土星视界科技有限公司, 江苏 南京 210019)

摘要: 变压器运行过程中产生的振动噪声与其运行状态及内部缺陷情况直接相关, 对其声纹信号开展特征分析, 有助于进一步了解设备运行工况, 保障电力系统安全稳定运行。文中以声纹特征分析为基础, 兼顾诊断效率与准确性, 提出一种基于卷积神经网络及集成学习模型的变压器缺陷诊断方法。该方法以变压器声纹数据的时域及频域信号为多通道输入混合特征, 构建了基于卷积神经网络模型和声纹特征分析法的集成学习模型, 可实现变压器声纹特征的有效识别, 并通过由多个基学习器组成的集成学习模型提高了变压器缺陷诊断的准确性。基于文中所构建的变压器声纹样本库, 可得到该方法对变压器单一缺陷的识别准确率为 99.2%, 对变压器混合缺陷的识别准确率为 99.7%。研究结果表明该方法可有效识别变压器的运行状态, 为变压器运维检修提供技术参考。

关键词: 变压器; 声纹特征; 缺陷诊断; 深度学习; 集成学习; 局部放电

中图分类号: TM41

文献标志码: A

文章编号: 2096-3203(2023)05-0046-10

0 引言

作为电力系统的重要连接设备, 变压器在电力系统中起着电压、电流变换以及电能分配和传输的重要作用^[1-2]。随着电网容量的增大, 现场在运变压器的数量快速增长, 而新型电力系统的建设对变压器的稳定运行提出了更高的要求。因此, 积极开展变压器运行状态监测和带电检测, 及时发现故障隐患, 对电网的安全、优质、稳定及经济运行具有重要意义^[3-4]。

近年来, 随着语音识别技术的发展, 变压器声纹识别技术已成为变压器缺陷及故障诊断的研究热点^[5-12]。变压器的声纹信号中包含了反映变压器内部缺陷及故障的特征信息。但变压器运行工况复杂多变, 其声纹信号的波长、频率及强度等特征均会出现一定的变化, 运维人员仅凭现场经验难以准确识别其声纹特征反映的运行状态^[13-18]。因此, 如何根据声纹信号准确评估变压器运行状态, 实现其内部缺陷辨识及故障诊断是当前研究重点关注的问题。文献[5]基于压缩感知技术, 采用判别字典学习方法实现了干式变压器绕组及铁心松动等缺陷识别, 准确率超过 90%。文献[7]针对低信噪比环境下的变压器铁心及绕组松动等缺陷识别问题, 采用基于快速增量式支持向量的数据描述和门控逻辑单元方法, 显著降低了诊断结果的误报率。文献[8]针对绕组短路冲击瞬间的声纹信号, 提出

基于占比时频谱熵值和频谱成分欧式距离这 2 种声纹特征的变压器抗短路能力评估方法, 可用于辅助识别变压器绕组变形情况。文献[12]通过对变压器声纹信号进行梅尔时频谱降维处理, 实现了基于卷积神经网络(convolutional neural network, CNN)的变压器直流偏磁识别, 识别准确率达到 99.7%。文献[15]提出一种梅尔倒谱系数与长短期记忆递归神经网络相结合的变压器声纹识别方法, 可实现变压器内部放电和过载缺陷的精准识别。

综上所述, 现有基于声纹特征的变压器缺陷诊断技术在一定程度上可有效识别变压器运行状态, 但其在模型构建及现场应用方面仍存在以下问题: (1) 现有研究大多针对变压器某一类缺陷展开, 且主要集中在机械缺陷或绝缘缺陷的诊断识别上, 如绕组松动变形^[5-11]、直流偏磁^[12-14]或绝缘放电^[15-17]等, 所构建的诊断模型的识别结果并未涵盖变压器所有潜在运行状态, 一定程度上限制了声纹诊断技术的现场应用; (2) 变压器声纹样本数据多数来源于试验结果^[5, 9-11], 并未考虑变电站现场环境噪声及其他输变电设备的干扰、影响等问题, 声纹样本的局限性一定程度上将增大诊断结果的误判率; (3) 现有缺陷诊断方法大多仅考虑了变压器存在单一缺陷的情况^[6, 12, 15], 并未考虑多种缺陷并发情况下的变压器声纹识别。

针对上述问题, 文中以时频域声纹信号为基础, 构建了一种基于 CNN 和声纹特征分析的集成学习模型, 用于变压器单一缺陷或并发缺陷诊断。该方法利用 CNN 挖掘小样本变压器故障数据的深层

收稿日期: 2023-08-06; 修回日期: 2023-09-08

基金项目: 国家重点研发计划资助项目(2022YFF0708400)

特征,结合特征分析方法,提高了诊断模型识别变压器缺陷类型的准确率和可靠性。其中,使用时域数据和频域数据组合的多通道模型输入,可提高模型同时提取稳态信号和暂态信号特征的能力。

1 变压器声纹特征分析

1.1 基本声纹特征

变压器的工作原理是电磁感应。当交流电流通过变压器绕组时,铁心内部将会产生变化的磁通。随着磁通的交变,铁心的磁化状态也会发生变化,导致铁心发生磁致伸缩。同时,在交变电流的作用下,变压器绕组线圈会产生电磁力,导致线圈位移,从而引发线圈的振动或变形。因此,可基于变压器在运行过程中产生的振动信号进行声纹信号检测。当变压器运行状态异常时,其声纹信号将发生变化,即变压器声纹信号在一定程度上可反映设备状态信息。但在变压器声纹检测中,受现场运行环境的影响,传感器同样可能接收到外部环境信息,即传感器接收到的声纹信号包括变压器运行状态信息和部分运行环境信息,导致基于声纹特征的变压器故障诊断难度加大。因此,以变压器正常运行状态下的声纹特征作为基准,将监测获取的声纹信号与基准特征值进行比较,定性诊断变压器故障状态,是声学故障诊断的基础和依据^[19-21]。

变压器声纹诊断从声纹信号中提取有用特征,以检测和诊断变压器内部可能存在的缺陷。这些特征可分为时域特征、频域特征和时频域特征。其中,时域波形一般较为复杂,可结合频域特征对变压器运行状态进行描述。频域特征大多通过傅里叶变换或其他频谱分析方法从时域信号中提取得到,其频率以 100 Hz 基频为主,同时包含部分高倍频分量,主要能量分布在 1 000 Hz 以内。常用的频域特征值有以下 4 种:

(1) 基频幅值与基频能量占比,基频一般是工作电流频率的 2 倍,变压器声纹信号基频为 100 Hz。

(2) 主频幅值与主频能量占比,主频为频谱中振幅最高的频率。

(3) 振动熵,表征频谱中频率成分的复杂度。该值越低,能量越集中在频谱中的某些特征频率;该值越高,频谱中的能量越分散。其计算公式如下:

$$H = \left| \sum_{f=100 \text{ Hz}}^{f_{\max}} p_f \log_2 p_f \right| \quad (1)$$

式中: p_f 为频率比重,表征频率 f 处谐波分量的能量占比; f_{\max} 为最大频率值,文中取 1 200 Hz。

(4) 奇偶次谐波比,其与变压器运行状态存在

一定的关联。如当变压器存在直流偏磁问题时,声纹信号中 50 Hz 的奇次谐波分量将显著增多,因此可利用奇偶次谐波比判断变压器直流偏磁问题的严重程度。

结合变压器典型缺陷,文中对变压器运行状态与声纹特征的关系进行了对比分析。图 1 为某变压器正常运行状态下声纹信号的时域和频域波形,其中 A 为幅值。该变压器正常运行状态下主频为 200 Hz,同时可计算得到其振动熵为 1.16,奇偶次谐波比为 0.005。当变压器运行状态发生变化时,其声纹信号的时域和频域特性将发生变化。对于存在铁心夹件松动缺陷的某变压器,其声纹信号如图 2 所示,主频由 200 Hz 增大至 700 Hz,振动熵增大至 2.68,各频率的能量分布发生显著变化。图 3 为存在直流偏磁问题的变压器的声纹信号,其频域特征分析表明:主频由 200 Hz 增大为 550 Hz,奇偶次谐波比增大至 1.13。

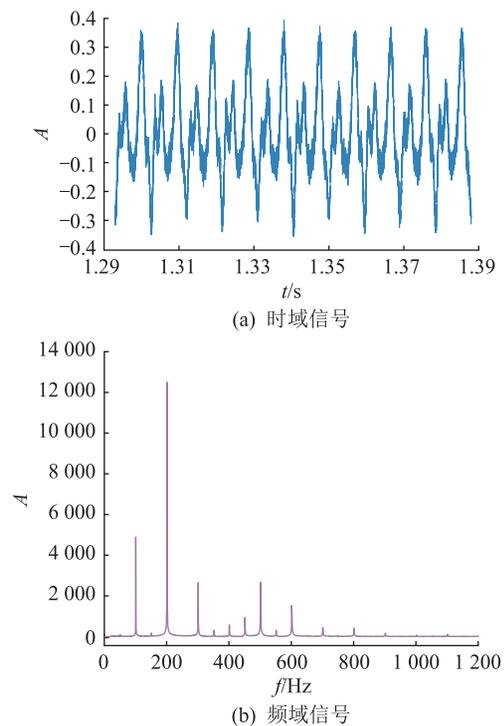


图 1 正常运行的变压器的声纹信号

Fig.1 The voiceprint signals of a normally operating transformer

频域特征可以较为直观地反映变压器本体的声纹特性,但频域特征是一段时间内声纹信号的整体响应,反映的是变压器的全局特征,对暂态信号的识别能力较差;而时域信号可以拾取到明显的暂态异常,但很难直接用于变压器故障诊断。时频域分析方法结合了时域和频域分析的优势,可采用短时傅里叶变换、小波变换或其他时频分析方法,分析声纹信号在时间和频率上的变化规律。但是,时

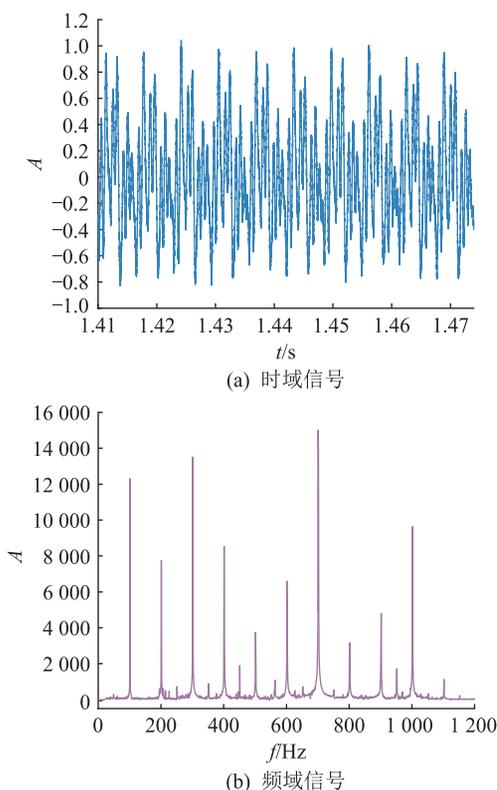


图2 振动熵偏大的变压器的声纹信号
Fig.2 The voiceprint signals of transformers with high vibration entropy

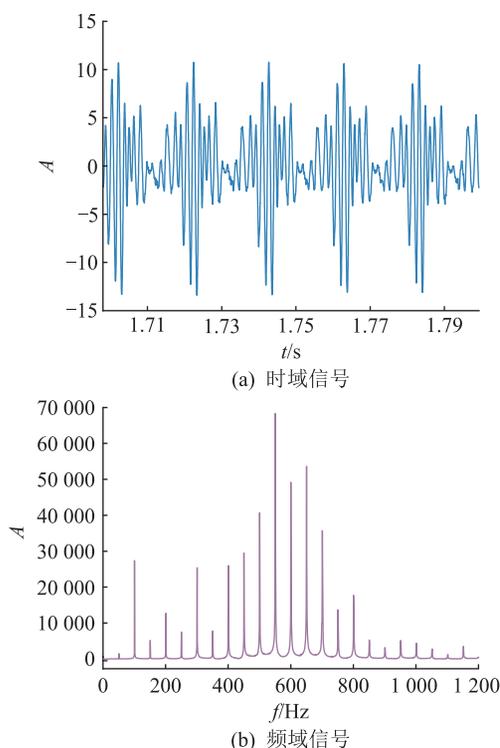


图3 奇偶次谐波比偏大的变压器的声纹信号
Fig.3 The voiceprint signals of transformers with high odd to even harmonic ratios

频谱是二维图像谱,其数据量巨大,难以直接使用。综合考虑诊断准确性、时间及模型大小等因素,文

中采用的特征分析法以基频幅值与基频能量占比、主频幅值与主频能量占比、振动熵和奇偶次谐波比这4个特征量为主。该方法基于声纹样本的统计分析确定各类缺陷所对应的特征阈值,并根据特征值与阈值之间的距离得出变压器各缺陷类型的对应概率,从而实现变压器运行状态的评估。

1.2 异常声纹特征

文中所分析的变压器典型异常声纹主要包括短路冲击、局部放电、夹件松动、冷却器异响、重过载、直流偏磁6类缺陷以及雷声、鸟鸣、汽笛声、人声、雨声5种环境噪声。其中,局部放电包括沿面放电、电晕放电、间歇性放电和悬浮放电,冷却器异响包括油泵异响和风扇异响。部分典型缺陷的声纹信号如图4—图7所示。

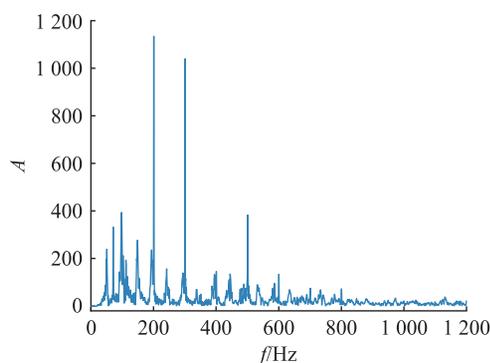


图4 短路冲击的声纹信号
Fig.4 The voiceprint signal of short circuit impulse

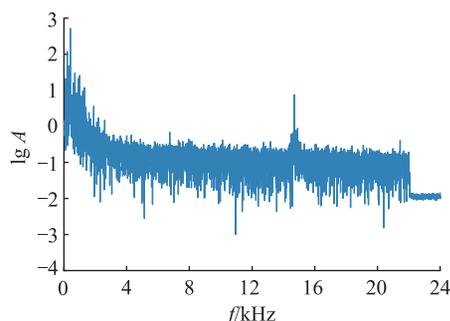


图5 局部放电的声纹信号
Fig.5 The voiceprint signal of partial discharge

变压器短路冲击声纹信号的频域特征主要表现为100 Hz及其倍频处出现局部的宽频带响应,其与变压器正常运行状态下的频域特征具有一定的相似性,但其在时域特征上会出现一个明显的短时强信号。局部放电声纹信号在时域上与正常运行状态下变压器的声纹信号极为相似,难以通过时域特征进行区别;而在频域上,其频率显著增大,且可以看出其在15 kHz附近有较强的能量。其中,为了更好地显示中高频段的能量分布,图5中纵坐标采用以10为底的对数表示。夹件松动在频域的低频

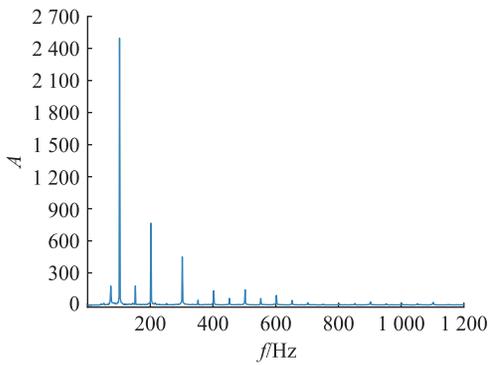


图6 重过载的声纹信号

Fig.6 The voiceprint signal of heavy overload

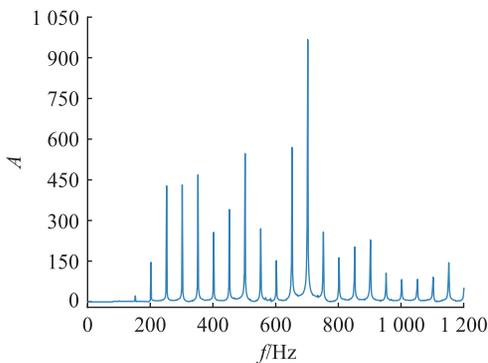


图7 直流偏磁的声纹信号

Fig.7 The voiceprint signal of direct current bias magnetism

段表现出 100 Hz 倍频的分布特征。冷却器异响则是一个具有周期性的强信号,从频谱来看,其表现为在 1 200~4 000 Hz 的频率范围内出现多个强峰。重过载的特征是基频能量占比较大,其振动熵值将显著增大。存在直流偏磁问题的变压器的声纹信号的频域特征是奇偶次谐波比相对较大。

除此之外,环境噪声对变压器声纹诊断的影响也不可忽略。如电磁干扰的频率以 50 Hz 或 150 Hz 为主,人声的频率以 800~1 500 Hz 为主,鸟鸣的频率以 2 000~5 000 Hz 为主,上述噪声均会对变压器声纹诊断造成影响。

时频域特征分析法可用于识别变压器典型缺陷的声纹信号,但受缺陷类型、严重程度及环境噪声干扰等因素影响,其准确性难以满足现场对缺陷的诊断精度要求,如过载和短路冲击在某些情况下容易出现误判。因此,须结合人工智能算法进一步挖掘声纹信号的时频域特征,区分变压器的运行状态,从而实现变压器内部缺陷或故障的精确诊断。

2 基于集成学习的变压器声纹识别算法

2.1 CNN

CNN 是一种深度学习算法,在图像和语音处理

方面应用广泛^[22-25],其基本原理是通过卷积操作在输入数据中查找局部空间模式。每个卷积层都由一组可学习的滤波器(或称为卷积核)组成,这些滤波器在输入数据上进行滑动以进行卷积操作,从而检测和学习空间模式。

CNN 的一个重要特性是平移不变性,这意味着无论模式在哪里出现,模型都可有效检测。这个特性使得 CNN 非常适合处理图像和音频等具有空间或时间结构的数据。此外,CNN 通过逐层堆叠卷积层,可以构建从简单模式到复杂模式学习特征的层次结构。

2.2 多通道输入混合特征

将音频信号转化为频谱图或梅尔频谱图,是采用 CNN 模型实现音频识别的常用输入特征。如前文所述,变压器声纹信号的时频谱特征丰富,有利于深度网络从中提取有效特征以用于故障检测,但二维时频谱需要很高的分辨率,对内存要求很高。梅尔频谱虽然可以对频率轴进行压缩,在一定程度上减轻这一负担,但是梅尔频谱主要用于人声识别,和变压器这一场景并不完全相符,不利于提取变压器基频和高次倍频的信号特征。

考虑到 CNN 模型在声纹信号特征提取方面的优势,通常可以直接使用时域信号作为输入,由深度网络提取特征并进行故障类型判断。但在现场变压器声纹信号的采集过程中,为全面掌握变压器运行状态,其声纹信号的采样率非常高,因此须增大卷积核的大小或者增加网络深度,这导致 CNN 中的待求参数大大增加,降低了模型的识别效率。另一种思路是将频谱作为网络输入,相当于替网络完成部分特征提取工作,大大提高网络的收敛速度,但这也降低网络识别暂态信号特征的能力。

因此,为了使 CNN 模型同时具备处理周期稳态特征和识别暂态异常特征的能力,文中提出将时域信号和频域信号组成多通道输入数据,既可以提供时域和频域信息,所需的内存还处于同一量级。

2.3 注意力机制

时域和频域多通道输入数据有利于提升网络的识别精度,但其同样引入了更多的干扰信息,为了避免网络迷失,文中在神经网络模型中引入了注意力机制。

注意力机制是一种用于提升 CNN 性能的关键技术,该机制可对不同空间位置或特征通道进行加权,使网络能够集中注意力于最重要的信息^[26]。在传统 CNN 中,每个卷积层的输出都是通过对输入图像的固定窗口进行卷积运算得到的。这种方法对

于图像中的所有位置都采取相同的权重,无法区分不同位置的重要性。注意力机制引入可学习的权重,能够在不同空间位置或特征通道上进行自适应的加权处理。采用结合注意力机制的 CNN 技术,可以使模型针对性地关注异常特征,从而减少不同电压等级变电站变压器运行工况、环境干扰对信号的影响。因此,变压器声纹识别中的注意力机制可在众多的时频域特征中聚焦对当前任务更为关键的信息,降低对其他信息的关注度,提高任务处理的效率和准确性。

2.4 集成学习算法

集成学习是指用多种兼容的学习算法或模型来执行单个任务的技术,其基本理念是:构建多个模型,每个模型能捕获数据中的某种特定模式,并将这些模型的结果合并^[27]。与使用单一算法或模型相比,集成学习往往能获得更佳的预测表现。集成学习的主要方法可归为三大类:堆叠、提升和装袋。其优势主要体现在以下两个方面:一是提高预测的准确性,通过整合多个模型的预测结果,集成学习可以有效地平衡偏差和方差,获得更准确的预测结果;二是提高模型的稳定性,由于集成学习算法涉及到多个子模型,因此,其对于单个模型的变化和噪声具有较强的鲁棒性。

2.5 变压器声纹信号诊断模型

兼顾 CNN 在音频识别方面的优势及特征分析法直观、可解释性强的特点,考虑变压器声纹信号与型号、工况、环境等因素的关联性,文中基于集成学习的堆叠方法,构建基于集成学习模型的变压器声纹信号诊断模型,如图 8 所示。该模型将特征分析法和 CNN 模型(即基学习器)的预测向量作为输入,传递给由多层感知机模型构建的元学习器进行综合预测。为兼顾模型识别效率及准确性,将特征分析法的结果作为补充。该方法结合了深度学习模型的非线性特性和特征分析的描述性,为声纹信号的识别诊断提供更加准确和稳定的预测结果。

文中基于采样时间为 10 s、采样率为 48 000 Hz 的变压器声纹数据,构建诊断模型的时频域混合输入,具体方法为:(1) 通过傅里叶变化得到频域信号,同时将时域信号进行均值方差归一化、抽稀至与频域信号长度一致,两者并联形成双通道数据;(2) 采用窗口长度为 4 s、滑动距离为 2 s 的时间窗将双通道信号分为 4 段,并重新并联,最终形成长度为(8,96 000)的多通道输入数据。

图 8 中,由 CNN 构建的基学习器共包含 4 个一维卷积层(包含最大池化层和线性整流激活层),且每个卷积层后面紧跟着一个注意力模块,用于提高特征提取的性能;之后是 2 个全连接层(包含 Dropout 层和线性整流激活层),建立深层特征与故障分类的映射关系。其中,CNN 模型的卷积核大小分别为 $64 \times 11 \times 8$ 、 $192 \times 5 \times 64$ 、 $384 \times 3 \times 192$ 和 $256 \times 3 \times 384$ 。元学习器是多层感知机,其输入是由基学习器和特征分析法得到的预测向量串联而成的特征向量,包含 2 个隐藏层,每一层由一个全连接层和 ReLU 激活函数组成,所采用的损失函数为交叉熵。

文中所采用的注意力模块是卷积块注意力模块(convolutional block attention module, CBAM),由通道注意力模块和空间注意力模块串联组成。其中,通道注意力模块由池化层(包含最大池化层和平均池化层)、多层感知机(由全连接层、ReLU 激活函数、连接层组成)、堆叠层、Sigmoid 层组成,用于得到通道注意力特征,再将其与输入特征图相乘,获取通道注意力机制作用的特征图,并输入后续的空间注意力机制模块。空间注意力机制模块由沿通道维度的池化层(包含最大池化层和平均池化层)、卷积层、Sigmoid 层组成,用于获取空间注意力特征,再将其与输入特征图相乘,给出空间注意力机制作用的特征图。

2.6 变压器缺陷诊断模型应用流程

基于文中所构建的变压器声纹信号诊断模型,变压器缺陷及故障诊断流程如图 9 所示。

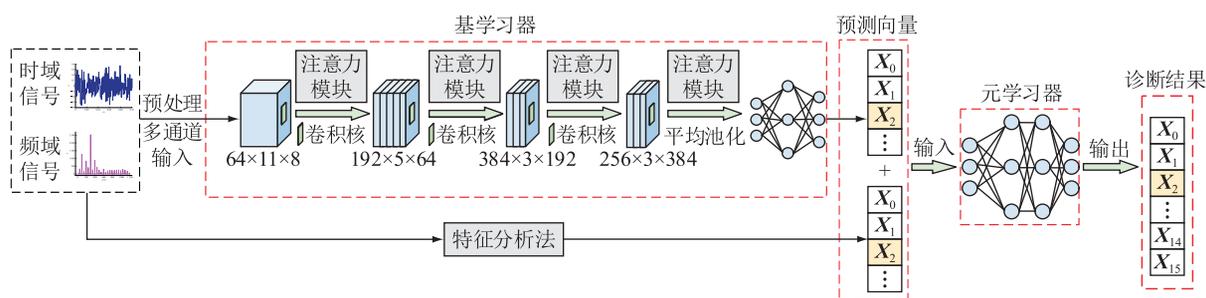


图 8 基于集成学习的变压器声纹信号诊断模型

Fig.8 The diagnostic model of transformer voiceprint based on ensemble learning

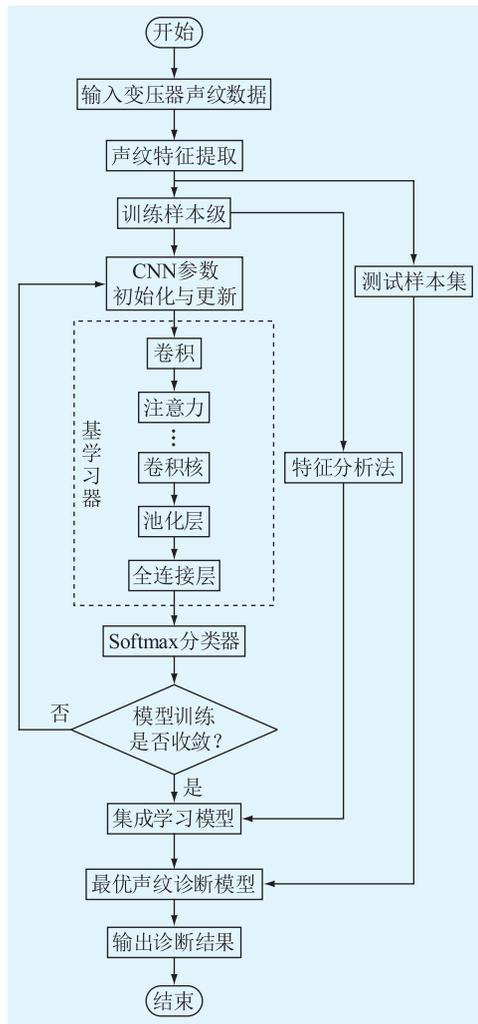


图9 诊断模型应用流程

Fig.9 Application flowchart of diagnostic model

(1) 样本库构建以及变压器声纹数据预处理。采用在线监测、带电检测、模拟试验等手段采集变压器声纹数据,结合时域及频域特征处理方法,形成声纹信号的多通道输入混合特征,建立变压器声纹样本库。

(2) 基学习器模型训练。将变压器声纹样本库按照 7:3 划分为训练样本和测试样本,将训练样本数据导入变压器声纹信号诊断模型,设置模型预训练参数。训练过程中,对比模型预测结果与真实结果的误差,当模型达到收敛条件时保存参数,并停止模型训练。

(3) 集成学习模型训练。针对部分缺陷类型评估准确性较差的情况,将基学习器中 CNN 与特征分析法的预测结果作为元学习器的输入向量,开展集成学习模型训练,形成最优声纹诊断模型。

(4) 变压器缺陷故障诊断。基于测试样本数据,通过特征提取与识别,评估最优声纹诊断模型的准确率,最终输出缺陷诊断结果。

3 算法验证

3.1 声纹样本数据

为验证变压器声纹识别算法的准确性,文中收集整理了 19 类共 6 400 条变压器声纹数据样本。其中,涵盖 9 类不同电压等级变压器和环境噪音的正常样本数据 4 800 条,涵盖 6 大类、10 小类变压器缺陷的异常样本数据 1 600 条,样本分布情况如表 1 所示。

表 1 变压器声纹样本分布情况

Table 1 Distribution of transformer voiceprint samples

样本类型	声纹分类	数量	样本类型	声纹分类	数量
正常 样本	110 kV 主变噪声	960	异常 样本	短路冲击	160
	220 kV 主变噪声	960		沿面放电	150
	500 kV 主变噪声	960		电晕放电	150
	±800 kV 主变噪声	960		间歇性放电	140
	变电站噪声+雷声	192		悬浮放电	150
	变电站噪声+鸟鸣	192		重过载	300
	变电站噪声+汽笛	192		直流偏磁	150
	变电站噪声+人声	192		夹件松动	100
	变电站噪声+雨声	192		油泵异响	150
				风扇异响	150

3.2 单一缺陷诊断效果分析

结合上述样本库,文中依次针对变压器正常与异常声纹样本识别、单一缺陷识别及混合缺陷识别问题分别开展了验证分析,以评估集成学习模型的诊断效果。

针对表 1 所示的变压器正常及异常样本分类,文中按照 7:3 将样本数据划分为测试集和训练集。基于训练样本数据,文中首先针对 CNN 模型开展验证,在经过 20 次迭代后,CNN 模型的准确率达到 92.0%,如图 10 所示。进一步分析识别错误的样本数据,发现传统的 CNN 模型在正常样本中的 220 kV 主变噪声和异常样本中的重过载缺陷之间易出现误判,显著降低了模型诊断结果的准确性。

为兼顾模型的准确性和识别效率,文中在异常样本识别的基础上,引入集成学习算法,并对样本标签进行细化,样本涵盖了表 1 中 19 类声纹数据。为节省模型识别时间,文中针对 CNN 模型易出现的 220 kV 主变噪声及重过载缺陷混淆问题,仅在两者内部引入集成学习算法,即当 CNN 预测样本标签不是 220 kV 主变噪声或重过载时,将其结果映射为正常或缺陷;当预测标签为 220 kV 主变噪声或重过载时,不输出预测结果,而是将预测向量和特征分析法的预测结果一起输入到集成学习模型的元学习

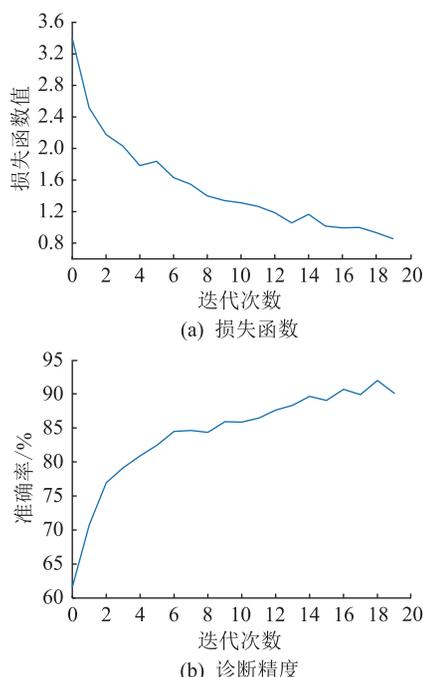


图 10 基于 CNN 的变压器单缺陷异常声纹识别结果

Fig.10 Abnormal voiceprint recognition results of single defect in transformers based on CNN

器中,实行样本数据的二次诊断,并得到最终的预测结果。

基于训练样本数据,经过 15 次迭代,集成学习模型的准确率达到 98.7%,如图 11 所示。集成学习模型准确率显著高于 CNN 模型,说明在集成学习框架下,采用特征分析方法有效提高了 CNN 模型在处理 220 kV 主变噪声和重过载缺陷时的分类准确率。基于测试样本数据,文中进一步验证了集成学习模型的有效性及准确性,以其中的 6 大类缺陷样本为例,该模型的预测精度如图 12 所示。结果表明,集成学习模型对缺陷样本的识别准确率达到 99.2%,其中,对变压器局部放电和短路冲击 2 类样本的识别准确率达到 100%,在重过载样本的识别上准确率相对较低。

3.3 混合缺陷诊断效果分析

在单一缺陷样本识别的基础上,文中进一步分析了变压器内部存在多缺陷情况下的模型识别效果。当变压器存在多个并发缺陷时,不同缺陷所对应的声纹信号量级不同,且两者混合之后将破坏其原有特征,影响诊断的准确性。不考虑变压器正常声纹样本,文中构建了由 6 类缺陷中任意 2 种相互融合而成的 15 类混合缺陷样本,并采用 CNN 进行混合缺陷样本的分类测试,经过 20 次迭代,CNN 的诊断准确率达到 97.1%,如图 13 所示。

进一步分析识别错误的样本数据,发现所有涉及夹件松动和局部放电缺陷的混合样本都出现了

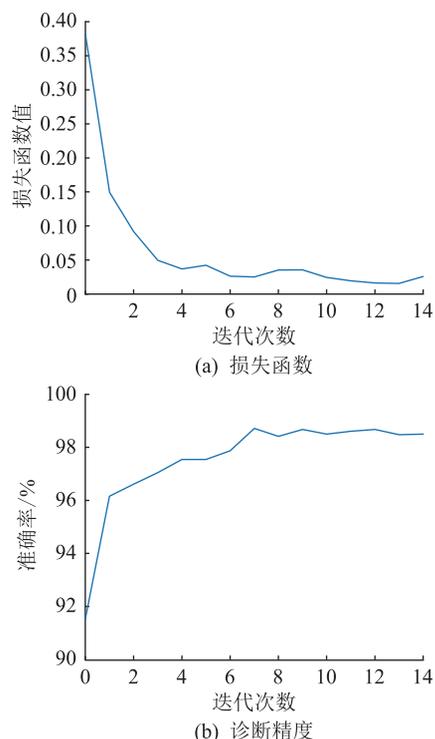


图 11 基于集成学习模型的变压器单缺陷异常声纹识别结果

Fig.11 Abnormal voiceprint recognition results of single defect in transformers based on ensemble learning model

重过载	0.98	0	0	0.02	0	0
局部放电	0	1.00	0	0	0	0
夹件松动	0	0	0.99	0	0.01	0
冷却器异响	0.01	0	0	0.99	0	0
直流偏磁	0	0	0.01	0	0.99	0
短路冲击	0	0	0	0	0	1.00
	重过载	局部放电	夹件松动	冷却器异响	直流偏磁	短路冲击

诊断故障

图 12 基于集成学习模型的单缺陷样本预测精度

Fig.12 Prediction accuracy of single defect samples based on ensemble learning model

一定程度的混淆现象,其可能原因为两者的频率及能量分布影响了诊断模型的识别效果。针对上述问题,文中建立了 4 个二分类集成学习模型,当 CNN 预测样本标签中不含夹件松动和局部放电时,直接输出预测结果;当预测标签中任一项为夹件松动或局部放电时,CNN 模型不输出预测结果,而是将预测向量和特征分析的预测结果一起输入到对应的集成学习模型的元学习器中,实行二次诊断识别,并输出最终的识别结果。经验证,在由 CNN 及 4 个集成学习模型组成的诊断模型框架下,声纹识

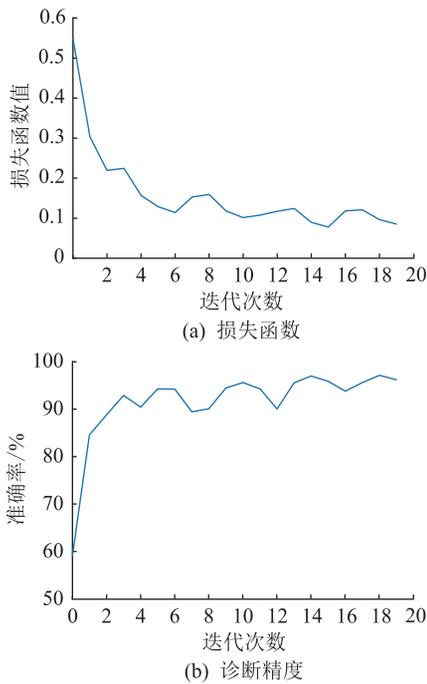


图 13 基于 CNN 的变压器混合缺陷异常声纹识别结果

Fig.13 Abnormal voiceprint recognition results of mixed defects in transformers based on CNN

别结果的准确率达到 99.7%,如图 14 所示。相比于仅采用 CNN 模型,预测精度提高了 2.6%,说明了融合 CNN 算法与特征分析法的集成学习模型在变压器混合缺陷诊断中的有效性和实用性。

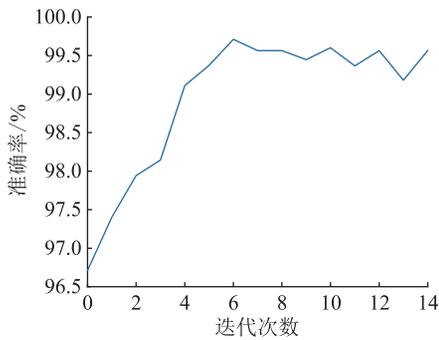


图 14 基于集成学习模型的变压器混合缺陷异常声纹识别结果

Fig.14 Abnormal voiceprint recognition results of mixed defects in transformers based on ensemble learning model

3.4 不同诊断模型对比研究

为进一步说明文中方法的有效性,文中以单一缺陷识别为例,对比了以梅尔时频谱为输入的 CNN 模型的诊断效果,如图 15 所示。其中,CNN 模型采用 ResNet50 框架,输入数据的像素为 640×480 ,损失函数采用交叉熵。结果表明,该模型的收敛速度快于集成学习模型,但准确率仅在 90%左右,且模型出现了明显的过拟合现象,其可能原因为正常样本数据的环境噪声干扰影响了模型的识别精度。

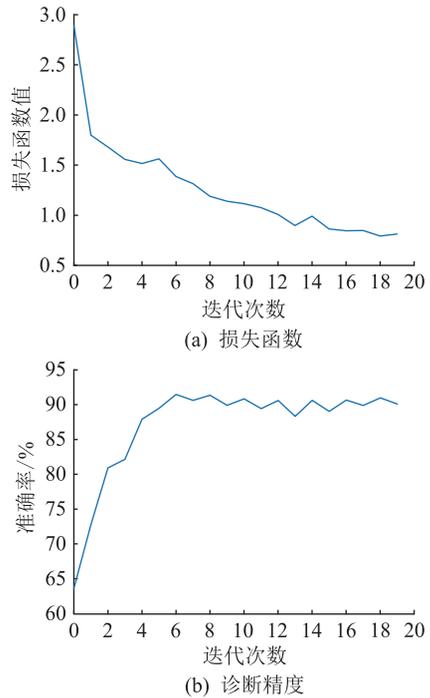


图 15 基于梅尔时频谱-CNN 的变压器异常声纹识别结果

Fig.15 Recognition results of abnormal transformer voiceprint based on Mel frequency cepstrum-CNN

4 结论

结合变压器声纹样本数据,文中采用时域信号和频域信号组成多通道输入特征,提出了一种基于集成学习的变压器缺陷诊断方法,实现了变压器单一或混合缺陷的诊断识别。主要结论如下:

(1) CNN 模型可有效挖掘变压器声纹信号中的时频域特征,但受外界环境以及变压器个体之间差异的影响,在部分样本识别中易出现误判,如存在 220 kV 主变噪声与重过载缺陷样本混淆的问题。

(2) 融合特征分析法和 CNN 模型的集成学习模型可显著改善传统 CNN 模型在部分样本识别上的混淆问题,且仅针对部分样本实行基于集成学习模型的二次诊断,其准确率仍有显著提升。

(3) 单一缺陷及混合缺陷诊断结果表明,基于集成学习模型的变压器缺陷诊断算法的准确性可达 99%。

参考文献:

- [1] 李鹏,毕建刚,于浩,等. 变电设备智能传感与状态感知技术及应用[J]. 高电压技术,2020,46(9):3097-3113.
LI Peng, BI Jiangan, YU Hao, et al. Technology and application of intelligent sensing and state sensing for transformation equipment[J]. High Voltage Engineering, 2020, 46(9): 3097-3113.
- [2] 盛戈皞,钱勇,罗林根,等. 面向新型电力系统的数字化电力设备关键技术及其发展趋势[J]. 高电压技术,2023,49(5): 1765-1778.

- SHENG Gehao, QIAN Yong, LUO Lingen, et al. Key technologies and development trends of digital power equipment for new type power system [J]. High Voltage Engineering, 2023, 49(5):1765-1778.
- [3] 廖瑞金, 王有元, 刘航, 等. 输变电设备状态评估方法的研究现状[J]. 高电压技术, 2018, 44(11):3454-3464.
LIAO Ruijin, WANG Youyuan, LIU Hang, et al. Research status of condition assessment method for power equipment [J]. High Voltage Engineering, 2018, 44(11):3454-3464.
- [4] 廖才波, 杨鑫鑫, 胡雄, 等. 数据与经验混合驱动下的变压器故障分层诊断方法[J]. 高电压技术, 2023, 49(5):1841-1850.
LIAO Caibo, YANG Jinxin, HU Xiong, et al. Hierarchical diagnosis method for transformer faults driven by mixed data and experience [J]. High Voltage Engineering, 2023, 49(5):1841-1850.
- [5] 周东旭, 王丰华, 党晓婧, 等. 基于压缩观测与判别字典学习的干式变压器声纹识别[J]. 中国电机工程学报, 2020, 40(19):6380-6390.
ZHOU Dongxu, WANG Fenghua, DANG Xiaojing, et al. Dry type transformer voiceprint recognition based on compressed observation and discrimination dictionary learning [J]. Proceedings of the CSEE, 2020, 40(19):6380-6390.
- [6] 王丰华, 王邵菁, 陈颂, 等. 基于改进 MFCC 和 VQ 的变压器声纹识别模型[J]. 中国电机工程学报, 2017, 37(5):1535-1543.
WANG Fenghua, WANG Shaojing, CHEN Song, et al. Voiceprint recognition model of power transformers based on improved MFCC and VQ [J]. Proceedings of the CSEE, 2017, 37(5):1535-1543.
- [7] 王荣昊, 李喆, 孙正, 等. 基于 FISVDD 与 GRU 的变压器声纹识别技术[J]. 高电压技术, 2022, 48(11):4546-4556.
WANG Ronghao, LI Zhe, SUN Zheng, et al. Transformer voiceprint recognition technology based on FISVDD and GRU [J]. High Voltage Engineering, 2022, 48(11):4546-4556.
- [8] 刘云鹏, 王博闻, 李欢, 等. 结合载纤绕组形变测量法的大型变压器绕组多次短路冲击暂态声纹特征[J]. 中国电机工程学报, 2022, 42(1):434-447.
LIU Yunpeng, WANG Bowen, LI Huan, et al. Transient acoustics characteristics of large transformer windings under multiple short-circuit impulse combined with fiber-carrying winding deformation measurement [J]. Proceedings of the CSEE, 2022, 42(1):434-447.
- [9] 马宏忠, 李楠, 杨启帆, 等. 基于多特征声纹图谱的变压器绕组松动在线故障诊断方法[J]. 电机与控制学报, 2023, 27(5):76-87.
MA Hongzhong, LI Nan, YANG Qifan, et al. On-line fault diagnosis method of transformer winding looseness based on multi-characteristic voiceprint maps [J]. Electric Machines and Control, 2023, 27(5):76-87.
- [10] 崔佳嘉, 马宏忠. 基于改进 MFCC 和 3D-CNN 的变压器铁心松动故障声纹识别模型[J]. 电机与控制学报, 2022, 26(12):150-160.
CUI Jiajia, MA Hongzhong. Voiceprint recognition model of transformer core looseness fault based on improved MFCC and 3D-CNN [J]. Electric Machines and Control, 2022, 26(12):150-160.
- [11] 李楠, 马宏忠, 张玉良, 等. 基于特征筛选和改进深度森林的变压器内部机械状态声纹识别[J]. 电机与控制应用, 2022, 49(9):57-65, 74.
LI Nan, MA Hongzhong, ZHANG Yuliang, et al. Voiceprint recognition of transformer internal mechanical state based on feature screening and improved deep forest [J]. Electric Machines & Control Application, 2022, 49(9):57-65, 74.
- [12] 张重远, 罗世豪, 岳浩天, 等. 基于 Mel 时频谱-卷积神经网络的变压器铁芯声纹模式识别方法[J]. 高电压技术, 2020, 46(2):413-423.
ZHANG Zhongyuan, LUO Shihao, YUE Haotian, et al. Pattern recognition of acoustic signals of transformer core based on Mel-spectrum and CNN [J]. High Voltage Engineering, 2020, 46(2):413-423.
- [13] 刘云鹏, 王博闻, 岳浩天, 等. 基于 50 Hz 倍频倒谱系数与门控循环单元的变压器偏磁声纹识别[J]. 中国电机工程学报, 2020, 40(14):4681-4694, 4746.
LIU Yunpeng, WANG Bowen, YUE Haotian, et al. Identification of transformer bias voiceprint based on 50 Hz frequency multiplication cepstrum coefficients and gated recurrent unit [J]. Proceedings of the CSEE, 2020, 40(14):4681-4694, 4746.
- [14] 刘建华, 王钢, 骆钊, 等. 换流站变压器端到端偏磁声纹识别研究[J]. 高压电器, 2022, 58(11):53-60.
LIU Jianhua, WANG Gang, LUO Zhao, et al. Study on identification of end-to-end biased voice print of transformer in converter station [J]. High Voltage Apparatus, 2022, 58(11):53-60.
- [15] 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.
- [16] 舒畅, 金潇, 李自品, 等. 基于 CEEMDAN 的配电变压器放电故障噪声诊断方法[J]. 高电压技术, 2018, 44(8):2603-2611.
SHU Chang, JIN Xiao, LI Zipin, et al. Noise diagnosis method of distribution transformer discharge fault based on CEEMDAN [J]. High Voltage Engineering, 2018, 44(8):2603-2611.
- [17] 余长厅, 黎大健, 陈梁远, 等. 基于声纹及振动的变压器故障诊断技术研究[J]. 高压电器, 2019, 55(11):248-254.
YU Changting, LI Dajian, CHEN Liangyuan, et al. Transformer fault diagnosis technique based on voiceprint and vibration [J]. High Voltage Apparatus, 2019, 55(11):248-254.
- [18] CAI R, WANG Q A, HOU Y C, et al. Event monitoring of transformer discharge sounds based on voiceprint [J]. Journal of Physics: Conference Series, 2021, 2078(1):012066.

- [19] ZHAO S T, PAN L L, LI B S. The study of transformer fault acoustic signal processing based on HHT and wavelet contour [C]//2009 WRI Global Congress on Intelligent Systems. Xiamen, China. IEEE, 2009: 262-266.
- [20] 潘亮亮, 赵书涛, 李宝树. 基于区间能量提取的变压器声测诊断[J]. 变压器, 2010, 47(4): 61-65.
PAN Liangliang, ZHAO Shutao, LI Baoshu. Transformer acoustic emission diagnosis based on interval energy extraction[J]. Transformer, 2010, 47(4): 61-65.
- [21] SHI Y H, JI S C, ZHANG F, et al. Multi-frequency acoustic signal under short-circuit transient and its application on the condition monitoring of transformer winding[J]. IEEE Transactions on Power Delivery, 2019, 34(4): 1666-1673.
- [22] 陈文通, 盛骏, 钱肖, 等. 基于相空间张量分解的有载分接开关故障诊断[J]. 电力工程技术, 2023, 42(4): 248-255.
CHEN Wentong, SHENG Jun, QIAN Xiao, et al. Intelligent diagnosis of mechanical fault of on-load tap-changer based on tensor decomposition in phase space[J]. Electric Power Engineering Technology, 2023, 42(4): 248-255.
- [23] 李腾飞, 郝玉杰, 袁方, 等. 基于多源特征信息融合的油浸式变压器故障智能诊断模型[J]. 电工电能新技术, 2023, 42(1): 48-57.
LI Tengfei, HAO Yujie, YUAN Fang, et al. Intelligent transformer fault diagnosis model based on multi-source feature information fusion[J]. Advanced Technology of Electrical Engineering and Energy, 2023, 42(1): 48-57.
- [24] 孙中华, 傅正财, 刘亚坤, 等. 基于卷积神经网络的典型雷暴云下地面电场识别研究[J]. 电瓷避雷器, 2022(4): 155-161, 168.
SUN Zhonghua, FU Zhengcai, LIU Yakun, et al. Recognition of ground electric field under typical thunderstorm clouds based on convolutional neural network[J]. Insulators and Surge Arresters, 2022(4): 155-161, 168.
- [25] 张欣, 王红星, 陈玉权, 等. 基于改进 Cascade R-CNN 算法的多类型绝缘子缺陷图像联合检测[J]. 电瓷避雷器, 2022(1): 189-196.
ZHANG Xin, WANG Hongxing, CHEN Yuquan, et al. Multi-type insulator defect joint detection based on improved Cascade R-CNN algorithm[J]. Insulators and Surge Arresters, 2022(1): 189-196.
- [26] 崔宇, 侯慧娟, 胥明凯, 等. 基于双重注意力机制的变压器油中溶解气体预测模型[J]. 中国电机工程学报, 2020, 40(1): 338-347, 400.
CUI Yu, HOU Huijuan, XU Mingkai, et al. A prediction method for dissolved gas in power transformer oil based on dual-stage attention mechanism[J]. Proceedings of the CSEE, 2020, 40(1): 338-347, 400.
- [27] GHONEIM S S M, TAHA I B M. A new approach of DGA interpretation technique for transformer fault diagnosis[J]. International Journal of Electrical Power & Energy Systems, 2016, 81: 265-274.

作者简介:



陆云才

陆云才(1982),男,硕士,研究员级高级工程师,从事高电压技术研究和设备状态评价工作(E-mail:15105168845@163.com);

廖才波(1989),男,博士,副教授,研究方向为输变电设备多物理场仿真分析及设备状态评估;

李群(1967),男,博士,研究员级高级工程师,从事柔性输电、FACTS在电力系统中的应用、新能源并网、电力设备缺陷光纤检测、分布式光纤测温等相关研究工作。

Transformer fault diagnosis method based on voiceprint feature and ensemble learning

LU Yuncai¹, LIAO Caibo², LI Qun¹, WANG Tonglei¹, SHAO Jian¹, ZHANG Yi³

(1. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211102, China;

2. School of Information Engineering, Nanchang University, Nanchang 330031, China;

3. Nanjing Saturn Technology Co., Ltd., Nanjing 210019, China)

Abstract: The vibration and noise generated during the operation of the transformer are directly related to its operating state and internal defects. The analysis of its voiceprint characteristics is helpful to further understand the operating conditions of the equipment, and ensure the safety and stability of the power system. Based on the analysis of voiceprint features, a transformer defect diagnosis method based on deep neural network and ensemble learning model is proposed. Taking the time-domain and frequency-domain features of transformer voiceprint data as multi-channel input, an integrated learning model is constructed based on a deep neural network model, and the effective recognition of transformer voiceprint features is realized. An ensemble learning model improves the accuracy of transformer defect diagnosis. Based on the transformer voiceprint sample library constructed in this paper, the recognition accuracy rate of the method for single transformer defects is 99.2%, and the recognition accuracy rate for transformer mixed defects is 99.7%. The research results show that the method can effectively identify the operating state of the transformer, and can provide technical reference for the operation and maintenance of the transformer.

Keywords: transformer; voiceprint feature; fault diagnosis; deep learning; ensemble learning; partial discharge

(编辑 方晶)