基于Gammatone滤波器倒谱系数与鲸鱼算法优化随机森林的 干式变压器机械故障声音诊断

耿琪深1,王丰华2,金 霄3

(1. 上海电力大学 电气工程学院,上海 200090;2. 上海交通大学 电气工程系,上海 200240;
 3. 上海工程技术大学 电子电气工程学院,上海 201620)

摘要:为有效提取变压器声音信号中的机械状态信息并识别其典型机械故障,依据人类听觉系统优异的声音 识别能力,提出了一种基于Gammatone滤波器倒谱系数(GFCC)和鲸鱼算法优化随机森林(WA-RF)的变压器 机械故障声音诊断方法。首先计算了变压器声音信号的GFCC,引入信息熵提取了GFCC中的主要声音特征 信息。采用鲸鱼算法通过优化随机森林中决策树基分类器的规模和特征子集,构造了基于优化随机森林的 变压器典型机械故障分类模型。对以某10kV干式变压器正常与典型机械故障下声音信号的计算结果表 明,所构建的基于GFCC主要特征参数和鲸鱼算法优化随机森林的变压器典型机械故障模型具有较好的识 别效果,准确率可达95%以上,且具有优良的抗噪性能和鲁棒性。

0 引言

作为电力系统中关键的输变电设备之一,变压 器在电力系统的电力传输与分配中承担着核心任 务。研究表明,机械故障是变压器的主要故障类型, 且随着变压器容量的增大,变压器故障率居高不下, 亦是部分电气故障、发热等隐患的主要诱因^[12]。相 应地,开展变压器的机械状态监测与故障诊断研究 对确保变压器以及电力系统的安全可靠运行意义 重大。

已有的变压器故障诊断方法主要从箱壁的振动 信号入手,通过提取其特征信息对变压器的绕组变 形或松动等缺陷进行监测分析[3-5],具有较强的抗干 扰性和灵敏度高等优势。但振动信号通常由置于变 压器箱壁的压电型振动传感器获取,属于贴合式检 测,对振动传感器的安装位置、安装方式等均有一定 要求以提高前端振动信号检测的可靠性[6]。而声音 信号由运行中的变压器振动经空气传播形成,二者 相互联系且具有同源性。此外,对声音信号可利用 麦克风传感器或录音设备进行采集,属于非接触性 测量,具有简单便捷等优点,因此逐渐成为了变压器 机械状态监测分析研究的热点,如文献[7]采用小波 包分解提取了变压器声音信号的区间频带能量作为 特征值,对变压器正常、超铭牌容量运行、内部接触 不良、铁芯多点接地等状态进行了判别;文献[8]应 用稀疏分量算法将现场变压器的含噪声音信号进行 了分离,然后将声音信号的短时过零率、短时平均幅 度与最大频谱作为特征向量,对变压器的过载运行

收稿日期:2019-10-23;修回日期:2020-05-27

状态进行识别;文献[9]综合希尔伯特变换和小波轮 廓算法提取了变压器近场与远场声音信号的时频特 征,实现了变压器正常与过载状态的准确识别。显 然,现有研究大多基于变压器声音信号的时频特征 对其异常状态进行分析识别,但诸如此类的时频分 析方法存在小波基选取困难、频谱泄漏或谱间干扰 等问题,对变压器声音信号分析结果的准确性有一 定的影响,仍需进一步研究。

人类听觉系统对不同频率的语音信号具有不 同的感知能力,具有良好的声音识别能力、鲁棒性和 抗噪能力,且可在噪声及不稳定环境下有效提升说 话人识别的准确率,常用的特征参数主要有线性预 测倒谱系数LPCC(Linear Prediction Cestrum Coefficient)、Mel频率倒谱系数MFCC(Mel Frequency Cestrum Coefficient)、Gammatone 滤波器倒谱系数 GFCC (Gammatone Filter Cepstral Coefficient)等^[10-11]。考 虑到运行中的变压器声音信号与语音信号相比有一 定的共性,故可尝试将基于人耳听觉特性的特征参 数引入变压器声音信号分析中,如文献[12]计算了 变压器声音信号的 MFCC 分量并进行了优化, 据此 基于矢量量化算法有效识别了变压器铁芯的不同压 紧程度,识别效果较好。但MFCC系数计算过程中 所使用的三角滤波器存在一定程度的能量泄漏,致 使其对人耳基底膜分频特性的模拟效果较差,尤其 是在复杂噪声环境下的识别性能较差。GFCC采用 Gammatone 滤波器模拟人耳耳蜗听觉模型,能较为 完整地描述声音信号的时域与频域的联合分布特 征,且Gammatone滤波器的谱峰更加平坦,能有效改 善信号分解的能量泄漏问题,故本文引入GFCC提

取变压器的主要声音信号特征。此外,分类器的设 计是基于声音信号有效识别变压器典型机械故障的 关键,主流的识别算法有人工神经网络^[13]、支持向量 机^[14-15]、决策树等。随机森林RF(Random Forest)作 为一种新型集成分类器,具有处理高维数据、训练速 度快及抗过拟合能力强的优势,但RF中决策树基分 类器的规模和特征子集数目的选取会对分类的精度 产生较大影响。

针对上述问题,本文尝试研究基于GFCC与优 化RF的变压器典型机械故障的声音诊断方法,即 通过对变压器声音信号的GFCC进行筛选提取其 主要特征信息,然后利用鲸鱼算法WA(Whale Algorithm)对RF进行优化来提高识别准确率。以某 10kV干式变压器为试验对象,对其正常、铁芯松动 与绕组松动情况下的声音信号进行计算分析,验证 了本文方法的有效性。

1 变压器声音信号的特征提取

由变压器的机械结构可知,源于变压器绕组振动、铁芯振动及冷却装置等的声音信号与其机械状态密切相关。当运行中的变压器出现过载、过负荷及"噼啪"的高压瓷套管引线放电声等时,有经验的现场运维人员能有针对性地判别出变压器的异常状态。此外,对运行时间超过一定年限的变压器而言, 其绕组与铁芯等机械结构的变化亦将会导致变压器的可听声音信号改变。已有研究表明,变压器声音 信号的频谱分布通常为20 Hz~20 kHz,在人耳能听 到的声音频谱范围内,故本文从建立在人耳耳蜗听 觉模型上的GFCC出发,引入信息熵获取变压器声 音信号的特征参数,据此实现变压器典型机械故障 的识别分析。

图1为基于GFCC的变压器声音信号特征参数 提取过程,其中分帧的原则以一定长度的各段声音 信号能被看作平稳信号为宜,将分帧后的信号用汉 宁窗进行加窗处理。





Fig.1 Feature parameter extraction process of GFCC

Gammatone 滤波器组是用一组相互交叠的带通 滤波器来模拟人耳耳蜗特性, 仿真人耳基底膜的滤 波功能, 其中, 第*i*个滤波器可表示为^[16]:

$$G_{i}(t_{1}) = A_{f}t_{1}^{s-1} e^{-2\pi B_{i}t_{1}} \cos\left(2\pi f_{i}t_{1} + \varphi_{i}\right)u(t_{1}) \quad 1 \le i \le I \quad (1)$$

$$B_{i} = 1.019 B_{\text{FR}}(f_{i}) \qquad (2)$$

$$B_{\rm ER}(f_i) = 24.7 \left(\frac{4.37f_i}{1\,000} + 1\right) \tag{3}$$

其中,I为滤波器个数; A_i 为滤波器增益; $u(t_1)$ 为单位 阶跃函数;s为滤波器阶数; B_i 、 f_i 、 φ_i 分别为第i个滤 波器的带宽、中心频率和偏移相位; $B_{ER}(f_i)$ 为等效 矩形带宽(ERB),其决定了当前滤波器对脉冲响应 的衰减速度。

通过对式(1)进行拉氏变换、z变换及其反变换, 可得到 Gammatone 滤波器组的离散冲击响应如式 (4)所示。

$$g_{i}(s) = \frac{1}{2\pi j} \int G_{i}(z) z^{s-1} dz$$
 (4)

基于上述过程得到了 64 个通道的 Gammatone 滤波器组的频响曲线,为清晰起见,仅在图 2 中显示 4 的整数倍通道的滤波器频响曲线。由图 2 中的曲 线可见,Gammatone滤波器是一组最大幅度出现在 中心频率位置的带通滤波器,低频段的滤波器带宽 较窄,高频段的滤波器带宽较宽,即每个滤波器带宽 较窄,高频段的滤波器带宽较宽,即每个滤波器的带 宽随着中心频率的增加而增大。显然,相比 Mel滤 波器组中的三角滤波器^[17],Gammatone滤波器组的 谱峰更加平坦,能有效改善三角滤波器的能量泄漏 问题。



因运行中的变压器在正常状态与典型机械故障状态下的声音信号频谱分布大多集中在1000 Hz以内,故在计算变压器声音信号的GFCC特征参数时,需要较为完整地保留变压器声音信号的特征信息,即需要设置Gammatone滤波器组的中心频率覆盖范围超过1000 Hz。虽然带通滤波器组个数越多计算模型越精细,但同时计算复杂度也会增加,故本文综合考虑变压器声音信号的频谱特征、模型的分辨率、计算量等因素,将Gammatone滤波器组通道数和中心频率覆盖范围分别确定为64和0~8000 Hz。

对每个滤波器的输出进行对数压缩后得到一组 对数能量信号,对信号进行离散余弦变换后得到 GFCC特征参数,其中每帧声音信号的离散余弦变换 公式为:

$$c(k) = \sqrt{\frac{2}{I}} \sum_{i=1}^{I} E_i \cos\left[\frac{\pi k}{I} (i - 0.5)\right] \quad 1 \le k \le K \quad (5)$$

其中,*E*_i为第*i*个滤波器输出信号的对数能量值;*K* 为GFCC特征参数的维数。

对变压器声音信号这类低频声音信号而言,为 在降低计算复杂度的同时充分提取出变压器声音信 号中包含的设备状态信息,本文引入信息熵对GFCC 特征参数每一维度的复杂程度进行度量,根据信息 熵随GFCC特征参数各维度的变化趋势设置阈值并 选取变压器声音信号的主要特征信息。其中,信息 熵的计算公式为:

$$H = -\sum_{q=1}^{Q} h_q \ln h_q \tag{6}$$

其中,H为信息熵;GFCC特征参数每一维度有Q种取值,对应的概率分别为 h_1 、 h_2 、…、 h_{Q°

2 基于优化 RF 参数的变压器机械故障诊断 模型

2.1 RF原理

RF是一种以决策树作为基分类器的集成学习 算法,其主要包括bootstrap重采样、决策树基分类器 构建和投票表决3个步骤,如附录中的图A1所示。 RF算法中的"随机"体现在融合了自助抽样与随机 子空间2种思想,即首先采用自助法bootstrap从原 始样本集中有放回地重复随机抽取与其等容量的样 本构成一个子训练集;然后从所有特征属性中随机 选择一定数目的特征子集,并选取最佳分割属性作 为结点建立决策树;重复上述"随机"过程N次,即建 立了N棵决策树,将这N棵决策树并行连接形成森 林。最后针对输入的测试样本集由森林内的各个决 策树进行投票表决,将决策树分类结果得票数量多 的作为最终的决策,如式(7)所示。

$$Y(x) = \underset{Z}{\operatorname{argmax}} \sum_{n=1}^{N} \lambda(y_n(x) = Z)$$
(7)

其中,N为决策树个数;y_n(x)表示第n棵决策树的分 类模型;Z为分类目标变量;λ(·)为示性函数。

具体而言,RF构建过程中的原始样本集由计算 得到的变压器声音信号的GFCC特征参数组成,指 的是各帧声音信号在各维度下的能量,对应于式(5) 的输出。特征属性为GFCC特征参数的维度。

CART决策树是一种典型的二叉树,由根结点 自顶向下递归分裂而成,对于每个决策结点,其最佳 分割属性即按照基尼增益最大化原则确定用于分裂 的某个特征及其阈值^[18]。结点不断分裂,直到叶子 结点处的基尼指数为0,此时每个叶子结点代表一 种类别。其中,结点σ的基尼指数可表示为式(8)所 示的形式。

$$G(\sigma) = 1 - \sum_{j=1}^{W} w_j^2 \tag{8}$$

其中,w_i为结点σ中W类样本所占的比例。

$$\Delta G = G(\sigma_{\rm a}) - p_{\rm u}G(\sigma_{\rm b}) - p_{\rm v}G(\sigma_{\rm c})$$
⁽⁹⁾

其中, σ_a 为父结点; σ_b 与 σ_c 分别为左、右子结点; p_u 和 p_v 分别为从父结点 σ_a 拆分至左子结点 σ_b 、右子结点 σ_c 的样本在父结点样本中所占的比例。

2.2 WA及其优化模型

RF算法中决策树基分类器的规模b和特征子集数目m的选取对其最终决策结果有着较大的影响,为了提高变压器机械故障诊断模型的准确性,本文引入WA在一定时间和空间复杂度内寻找诊断模型的最优参数组合,其数学模型为^[19]:

$$\boldsymbol{D} = \left| 2 \, \boldsymbol{r} \, \boldsymbol{X}^*(t) - \boldsymbol{X}(t) \right| \tag{10}$$

$$\boldsymbol{X}(t+1) = \boldsymbol{X}^{*}(t) - A\boldsymbol{D}$$
(11)

$$A = 2\left(1 - \frac{t}{T_{\max}}\right)(2r - 1)$$
 (12)

其中, $|\cdot|$ 表示取绝对值;t为迭代次数;X(t)为座头鲸 当前的位置向量; $X^*(t)$ 为目前鲸群中的最佳觅食位 置向量; T_{max} 为最大迭代次数;r为[0,1]范围内的随 机数。

在局部开发阶段,WA在收缩包围和螺旋式位 置更新之间以50%的概率进行选择,其数学模型如 式(13)所示。

$$X(t+1) = \begin{cases} X^{*}(t) - AD & p < 0.5\\ D' e^{\zeta l} \cos(2\pi l) + X^{*}(t) & p \ge 0.5 \end{cases}$$
(13)

其中, $D' = |X^*(t) - X(t)|$ 为鲸鱼与猎物间的距离; ζ 为 对数螺旋形状定义参数;l为[-1,1]范围内的随机 数;p为鲸鱼个体选择位置更新方式的行为概率。

可以看出,随着迭代次数的增加,参数A的波动 范围不断降低。即当 $A \in [-1,1]$ 时,鲸鱼下一个搜索 代理向目标猎物位置靠近,模拟座头鲸气泡网攻击 行为,显示出局部开发能力;当 $A \in [-2,-1)$ U(1,2] 时,座头鲸搜索代理远离猎物进行搜索,从而寻找更 合适的猎物,避免陷入局部最优,显示出其在全局搜 索中的勘探功能。

在采用WA优化RF参数时,需要选择合适的目标函数评价每组参数的优劣。本文在使用RF训练每个决策树基分类器时,约有1/3的变压器声音信号GFCC特征参数未被抽取训练,称其为袋外数据OOB data(Out Of Bag data)。文献[20]指出,袋外数据可取代测试集对RF模型泛化误差进行估计,故本文选择袋外数据误分率作为WA的目标函数,用于搜寻适应于变压器机械故障声音诊断模型的最优参数,其计算公式为:

$$\begin{cases} \min O_{\text{error}}(m, b) = \frac{x_{\text{w}}}{x_{\text{r}} + x_{\text{w}}} \\ b \in [1, N_1], m \in [1, M_1] \end{cases}$$
(14)

其中,x₁、x_w分别为袋外数据中正确分类、错误分类的样本数量;*M*₁为原始样本的特征属性;*N*₁为决策 树基分类器的规模上限。

综合上述, RF及其参数优化过程可将变压器不同机械状态下声音信号的GFCC特征参数构成原始 样本集,按比例分为训练集和测试集,基于所构建的 WA-RF模型进行变压器典型机械故障的诊断,其流 程图见附录中的图A2。

3 结果分析

试验对象为型号SCB10-800/10的干式变压器, 基于循环电流法分别进行功率为 $0.8P_N$ 、 $0.9P_N$ 、 $1.0P_N$ 、 $1.1P_N$ 、 $1.2P_N$ 和 $1.3P_N$ 的负载试验,其中 P_N 为变压器的额定功率。同时,通过改变其中一台变压器铁芯和绕组的预紧力来模拟铁芯松动与绕组松动 故障,即通过调节相与相之间的旁螺栓以及拉紧螺栓来设定铁芯的预紧力为额定值的60%,调节高低压绕组顶端压板上方的可活动螺柱来设定绕组的预 紧力为额定值的60%。其中,60%这一阈值是综合变压器设计与现有变压器声音信号的分析经验选取的。

分别对试验变压器正常状态与典型机械故障状态下的声音信号进行测试,采样频率为51.2 kHz。 所使用的麦克风传感器的放置位置按照GB/T 1094.10-2003《电力变压器第10部分:声级测定》进行布置,即在距离变压器1m的轮廓线上且高度位于变压器线圈的中间位置处设置4个麦克风传感器,见附录中的图A3。试验基本过程如下:

(1)进行变压器负载试验接线;

(2)放置麦克风传感器,调试声音信号测试 系统;

(3)测试背景噪声;

(4)测试变压器正常状态下不同负载功率的声 音信号;

(5)改变变压器铁芯的松动程度,测试变压器不 同负载功率下的声音信号;

(6)恢复铁芯预紧力,改变变压器绕组的松动程 度,测试变压器不同负载功率的声音信号;

(7)恢复绕组预紧力,试验结束。

限于篇幅,以测点1处的声音信号为例进行说 明。测点1处的声音信号见附录中的图A4,图中同 时给出了变压器处于正常状态时不同负载功率下的 声音信号与不同机械状态下的声音信号。由图可 见,变压器的声音信号呈现出一定程度的时变非线 性特征,且随着变压器负载功率的变化而发生变化。 当变压器机械状态发生变化,即出现铁芯松动和绕 组松动时,声音信号的强度随之改变,从一定程度上 说明了基于声音信号对变压器典型机械故障进行识 别的可行性。

3.1 变压器声音信号的特征参数提取结果

限于篇幅,仍以测点1处的声音信号为例给出 变压器声音信号的特征参数提取结果,图3给出了 变压器在正常、铁芯松动和绕组松动3种状态下,声 音信号的GFCC特征参数的信息熵,计算时声音信 号长度设置为15 s,每帧信号长度设置为250 ms。 由图3可见,变压器在3种机械状态下,其声音信号 的GFCC维数为64,且信息熵随着GFCC维数的变化 呈现出较平稳、大幅递减、再次平稳的变化趋势,即 为GFCC特征参数中所包含的变压器声音信息特征 随着维数的变化趋势,所以本文选取信息熵的突变 点对应的35维作为后续分析中GFCC特征参数的 维数。







变压器 3 种机械状态下声音信号 GFCC 特征参数见附录中的图 A5。由图可见,在全部 35 维 GFCC 特征参数中,三维倒谱图中高维段的曲线仍较为平坦,这是由 Gammatone 滤波器组随着中心频率的增高,相应的频带带宽也增高,高频段重叠幅度增加所导致的,这一现象再次印证了选取 GFCC 特征参数中所含的主要声音信息的重要性。此外,当变压器机械状态改变时,GFCC 特征参数的幅值随着维数和帧数的变化均有着较为明显的变化,故可根据所提取的 GFCC 特征参数初步分析判断变压器是否存在机械故障。

3.2 基于WA-RF模型的故障识别

本文在基于WA-RF模型对变压器的典型机械 故障进行识别时,为增加学习训练样本和提高模型 的泛化能力,将试验中4个测点处的变压器声音信 号所提取的GFCC特征参数按帧截断扩展,共计 720×35组数据样本,随机挑选60×35组数据样本作 为测试数据,其余660×35组数据样本作为训练数 据。同时,分别将变压器正常状态、铁芯松动与绕组 松动的类别标签记为1、2和3。

计算时参数 b 和 m 的取值范围分别为[1,1000] 和[1,35],鲸鱼数量为20,最大迭代次数为50,平均 适应度为鲸鱼种群在每一代中平均的适应度值,最 优适应度为鲸鱼种群在每一代中的最大适应度值。 图4为利用WA对RF的参数 b、m进行优化时的适应 度收敛曲线。平均适应度和最优适应度曲线的趋势 表明,随着进化代数的增加,WA优化过程逐渐收 敛,并在进化代数为13时,曲线开始趋于平稳。据 此通过WA优化后得到最优的参数组合为:当决策 树基分类器的规模为146、特征子集的数目为7时, 使RF分类器模型袋外数据误分率从0.05减小到 0.002。这一结果再次说明了模型中决策树基分类 器的规模和特征子集的数目对分类模型准确性的影 响以及WA的优化性能。



图4 RF模型参数优化结果

Fig.4 Parameter optimization results of RF model

表1为WA-RF算法对上述变压器故障数据测试集进行测试时的平均识别准确率结果,表中同时给出了采用单一CART算法和未经参数优化的RF算法的测试结果,计算时每种算法取20次重复实验的平均值(其中一次的WA-RF测试分类结果见附录中的图A6)。

表1 不同分类模型对测试数据的诊断结果

 Table 1
 Diagnostic results of different classification

models for test data			
待识别	平均识别率 / %		
	单一CART	RF算法	WA-RF算法
1106	算法	(b=400, m=5)	(b=146, m=7)
正常	80.33	88.16	95.49
铁芯松动	78.56	89.54	96.43
绕组松动	76.45	86.62	95.86

由表1可见,相比单一CART算法,采用CART 基分类器集成学习的RF算法的识别率平均提高了 约10%,克服了单一CART基分类器能力弱的缺陷; 而利用WA对RF算法进行参数优化后变压器故障 诊断的识别率均到达了95%以上,相比未经参数优 化的RF算法更进一步提高了算法的泛化能力。此 外,WA-RF算法仅采用了146个CART基分类器,相 比于RF算法对400个基分类器进行集成而言,在有 效降低了存储空间的同时,显著提升了变压器典型 机械故障诊断效果。

此外,考虑到变压器不同测点处声音信号的差异,分别对测点1-4处的声音信号应用本文所提模型进行变压器典型机械故障诊断,测点1-4处的故障识别率分别为96.498%、95.058%、96.483%、94.629%,与表1的结果类似。说明本文所提出的基于GFCC和优化RF的干式变压器机械故障识别模

型的识别率受测点位置的影响较小,从而给现场应 用带来了较大的便利。

3.3 不同声学特征参数对变压器故障识别率的 影响

为了进一步说明本文采用变压器声学特征参数 识别变压器典型机械故障的有效性,并考虑试验变 压器不同负载功率下的情形,分别基于声学分析领 域中常用的LPCC、MFCC和本文采用的GFCC这3 种特征参数对变压器铁芯松动故障进行识别,结果 如图5所示。由图可见,本文所采用的GFCC特征参 数对变压器典型机械故障的识别率最高,当变压器 负载功率下降时,声音信号的信噪比随之下降,本文 所提算法的识别率有所下降,部分原因是低负载比 时背景噪声对铁芯松动故障频段的掩蔽效应,显然, 变压器声音信号中的噪声干扰对其典型机械故障的 识别效果存在一定影响,但本文所用GFCC特征提 取算法的识别率始终高于MFCC与LPCC特征参数, 可见GFCC特征参数提取算法对干扰信号更具有鲁 棒性,能显著改善变压器典型机械故障的声音诊断 效果。



图5 不同声音信号特征提取算法的识别率对比

Fig.5 Comparison of recognition rate among different feature extraction algorithms of sound signals

4 结论

本文提出了一种基于GFCC和WA-RF的变压器 机械故障声音诊断方法,所得结论如下:

(1)基于某 SCB10-800 / 10 型干式变压器正常 状态与铁芯松动、绕组松动等典型机械故障状态下声 音信号的 GFCC 主要特征参数和 WA-RF 的诊断方法 相较于单一 CART 决策树以及未经参数优化的 RF 算 法具有更好的识别效果,故障识别率可以达到 95% 以上;

(2)基于信息熵获取的变压器声音信号的GFCC 特征参数能够完整地保留其主要特征信息,且当变 压器发生典型故障时,该特征参数可以有效描述声 音信号的时频分布变化,从而初步判断变压器是否 存在机械故障;

(3)由变压器在不同负载功率下铁芯松动的识 别率分析结果可见,将声音信号的GFCC特征参数 应用在变压器典型机械故障诊断时,能够有效提升 背景噪声环境中的识别准确率,具有良好的抗噪性 与鲁棒性。

基于本文研究结果继续进行油浸式变压器典型 机械故障声音诊断的相关研究是下一步的研究 工作。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

- [1] YOON J T, YOUN B D, PARK K M, et al. Vibration-based robust health diagnostics for mechanical failure modes of power transformers [C]//2013 IEEE Conference on Prognostics and Health Management(PHM). Gaithersburg, MD, USA; IEEE, 2013;1-5.
- [2] 马宏忠,弓杰伟,李凯,等. 基于 ANSYS Workbench 的变压器 绕组松动分析及判定方法[J]. 高电压技术,2016,42(1): 192-199.
 MA Hongzhong,GONG Jiewei,LI Kai, et al. Analysis and determination method for transformer winding looseness based on ANSYS Workbench[J]. High Voltage Engineering,2016,42 (1):192-199.
- [3] 赵莉华,丰遥,谢荣斌,等. 基于交叉小波的变压器振动信号幅 频特征量提取方法[J]. 高电压技术,2019,45(2):505-511.
 ZHAO Lihua, FENG Yao, XIE Rongbin, et al. Amplitude and frequency feature extraction for transformer vibration based on cross-wavelet transform[J]. High Voltage Engineering,2019, 45(2):505-511.
- [4] 黄春梅,马宏忠,付明星,等. 基于混沌理论和KPCM聚类的变压器绕组松动状态监测[J]. 高压电器,2019,55(1):95-102.
 HUANG Chunmei, MA Hongzhong, FU Mingxing, et al. Looseness state monitoring of transformer winding based on chaos theory and KPCM clustering method[J]. High Voltage Apparatus,2019,55(1):95-102.
- [5]李长云,郝爱东,娄禹. 直流偏磁条件下电力变压器振动特性研究进展[J]. 电力自动化设备,2018,38(6):215-223.
 LI Changyun, HAO Aidong, LOU Yu. Status and progress of research on transformer vibration characteristics with DC bias
 [J]. Electric Power Automation Equipment,2018,38(6):215-223.
- [6] 杨元威,关永刚,陈士刚,等. 基于声音信号的高压断路器机械 故障诊断方法[J]. 中国电机工程学报,2018,38(22):6730-6736.

YANG Yuanwei, GUAN Yonggang, CHEN Shigang, et al. Mechanical fault diagnosis method of high voltage circuit breaker based on sound signal[J]. Proceedings of the CSEE, 2018, 38(22):6730-6736.

- [7] 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.
- [8] ZOU Liang, GUO Yongkang, LIU Han, et al. A method of abnormal states detection based on adaptive extraction of transformer vibro-acoustic signals[J]. Energies, 2017, 10(12):2076.
- [9] ZHAO Shutao, PAN Liangliang, LI Baoshu. The study of transformer fault acoustic signal processing based on HHT and wavelet contour[C]//Proceedings of 2009 WRI Global Congress on Intelligent Systems. Xiamen, China: IEEE, 2009:19-21.
- [10] MISRA S, DAS T, SAHA P, et al. Comparison of MFCC and LPCC for a fixed phrase speaker verification system, time com-

plexity and failure analysis[C]//2015 International Conference on Circuits, Power and Computing Technologies. Nagercoil, India:IEEE,2015:1-4.

- [11] MERIEM F, FARID H, MESSAOUD B, et al. Robust speaker verification using a new front end based on multitaper and Gammatone filters[C]//2014 Tenth International Conference on Signal-image Technology and Internet-based Systems. Marrakech, Morocco: IEEE, 2014:99-103.
- [12] 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.
- [13] 王德文, 雷倩. 基于贝叶斯正则化深度信念网络的电力变压器 故障诊断方法[J]. 电力自动化设备, 2018, 38(5):129-135.
 WANG Dewen, LEI Qian. Fault diagnosis of power transformer based on BR-DBN[J]. Electric Power Automation Equipment, 2018, 38(5):129-135.
- [14] 吐松江·卡日,高文胜,张紫薇,等.基于支持向量机和遗传算 法的变压器故障诊断[J].清华大学学报(自然科学版),2018, 58(7):623-629.

KARI Tusongjiang, GAO Wensheng, ZHANG Ziwei, et al. Power transformer fault diagnosis based on a support vector machine and a genetic algorithm[J]. Journal of Tsinghua University(Science and Technology Edition), 2018, 58(7):623-629.

- [15] 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 CEEM-DAN[J]. High Voltage Engineering,2018,44(8):2603-2611.
- [16] AYOUB B, JAMAL K, ARSALANE Z. Gammatone frequency cepstral coefficients for speaker identification over VoIP networks [C] //2016 International Conference on Information Technology for Organizations Development(IT4OD). Fez, Morocco: IEEE, 2016; 1-5.
- [17] ZHANG Xiaodan, HUANG Lixia, ZHANG Xueying. Optimization research on speech recognition in noisy environments [J]. Computer Simulation, 2016, 33(8): 172-176.
- [18] MENZE B H, KELM B M, MASUCH R, et al. A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data[J]. BMC Bioinformatics, 2009, 10(1):1-16.
- [19] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95:51-67.
- [20] RODRIGUEZ-GALIANO V F, GHIMIRE B, ROGAN J, et al. An assessment of the effectiveness of a random forest classifier for land-cover classification[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2012, 67:93-104.

作者简介:



耿琪深

耿琪深(1995—),男,山东威海人,硕 士研究生,主要研究方向为高电压技术 (E-mail:490988984@qq.com);

王丰华(1973—),女,河南洛阳人,副 教授,博士,主要研究方向为高电压技术 (**E-mail**:fhwang7723@sjtu.edu.cn);

金 霄(1995—),男,浙江嵊州人,硕士 研究生,主要研究方向为人工智能在电力 系统中的应用(E-mail:435667981@qq.com)。

(编辑 任思思)

(下转第224页 continued on page 224)

196

Identification method of power service packet attacks based on service logic

WANG Haixiang¹, ZHU Chaoyang¹, WANG Yu², ZHANG Ruiwen², LI Jun'e², LI Jiyuan³, YING Huan¹

(1. Information & Communication Department, China Electric Power Research Institute, Beijing 100192, China;

2. Key Laboratory of Aerospace Information Security and Trusted Computing, Ministry of Education,

School of Cyber Science and Engineering, Wuhan University, Wuhan 430072, China;

3. State Grid Zhejiang Electric Power Research Institute, Hangzhou 310014, China)

Abstract: The PSPAs (Power Service Packet Attacks) of power grid measurement and control terminals are easy to cause misoperation of primary electric equipment, thus causing electric power accidents. PSPAs usually achieve the attack purpose by interfering the normal service logic. Existing attack identification methods do not take service logic into account and have poor effectiveness. Therefore, an identification method of PSPAs based on service logic is proposed. The state chain of power service logic, blacklist and whitelist are defined. The misuse detection method and anomaly detection method are combined to evaluate the threat degree of power service based on the service logic blacklist and whitelist. Considering the time risk and service importance of power grid, the threat degree is corrected, and the effective and accurate identification of PSPAs is realized by comparing the service threat degree and the security threshold. The architecture of an attack identification system based on the proposed method is presented, and the system is tested to verify the effectiveness of the proposed method.

Key words: power service packet attacks; identification method of attacks; service logic; state chain; power grid measurement and control terminals

(上接第196页 continued from page 196)

Mechanical fault sound diagnosis based on GFCC and random forest optimized by whale algorithm for dry type transformer GENG Oishen¹, WANG Fenghua², JIN Xiao³

ENG Qisnen, wANG rengnua, jin Ala

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. Department of Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;

3. School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

Abstract: To effectively extract the mechanical condition information of power transformer and then identify the mechanical faults via acoustic signals, a mechanical fault sound diagnosis method based on GFCC(Gammatone Filter Cepstral Coefficient) and random forest optimized by whale algorithm for transformer is proposed according to the excellent sound recognition ability of human auditory system. Firstly, the GFCCs of transformer acoustic signal are calculated, and the information entropy is introduced to extract the main acoustic feature information in GFCC. Then the whale algorithm is used to optimize the scale and feature subset of decision tree-based classifier in random forest and the classification model of typical mechanical fault based on optimized random forest is constructed. The calculative results of acoustic signals of a 10 kV dry-type transformer under normal condition and typical mechanical faults show that the typical mechanical fault model of transformer based on GFCC main characteristic parameters and random forest optimized by whale algorithm has better recognition ability with high accuracy of more than 95%, and has excellent antinoise performance and robustness.

Key words: power transformers; sound signal; fault diagnosis; Gammatone filter cepstral coefficient; information entropy; whale algorithm; random forest





Fig.A2 Fault diagnosis process based on WA-RF



图A3 试验变压器声音信号采集

Fig.A3 Collection of acoustic signals of transformer

















Fig.A6 Test set classification results based on WA-RF