

DOI:10.13296/j.1001-1609.hva.2026.02.028

基于鲁棒局部均值分解与声纹特征的变压器典型缺陷辨识方法

王磊磊¹, 张壮壮¹, 王东晖¹, 佟建炜², 张阳³, 王枭³

(1. 国网河南省电力公司电力科学研究院, 郑州 450052; 2. 国网河南省电力公司鹤壁供电公司, 河南 鹤壁 458030;
3. 上海睿深电子科技有限公司, 上海 200237)

摘要:为实现现场运行环境下电力变压器运行状态的可靠辨识,提出了一种基于鲁棒局部均值分解(robust local mean decomposition, RLMD)与声纹特征的变压器典型缺陷辨识方法。该方法首先利用RLMD方法实现原始采集声纹信号的降噪处理,再借助皮尔逊相关系数保留与原始声纹信号相关性强的子带分量;其次提取每个子带分量的声纹特征值组成变压器不同状态的特征参量矩阵;最后利用随机森林算法进行状态辨识。搭建了包含3种电力变压器设备典型故障的试验模拟系统,试验结果表明:所提方法实现了电力变压器不同工作状态的可靠表征,且辨识精度较常规方法提升约7%。

关键词: 变压器; 鲁棒局部均值分解; 声纹特征; 缺陷辨识

Typical Defect Identification Method of Transformer Based on Robust Local Mean Decomposition and Voiceprint Features

WANG Leilei¹, ZHANG Zhuangzhuang¹, WANG Donghui¹, TONG Jianwei²,
ZHANG Yang³, WANG Xiao³

(1. State Grid Henan Electric Power Research Institute, Zhengzhou 450052, China; 2. Hebi Power Supply Company, State Grid Henan Electric Power Company, Henan Hebi 458030, China; 3. Shanghai Ruishen Electronic Technology Co., Ltd., Shanghai 200237, China)

Abstract: For achieving reliable identification of operating status of power transformer in the on-site operating environment, a typical defect identification method of transformer based on robust local mean decomposition (RLMD) and voiceprint features is proposed. Firstly, the RLMD method is used to achieve noise reduction processing of the original collected voiceprint signal, and the sub-band components with strong correlation with the original voiceprint signal are retained with the Pearson correlation coefficient. Then, the voiceprint feature values of each sub-band component are extracted to form the feature parameter matrix of the transformer in different status. Finally, the random forest algorithm is used for status identification. A simulation system containing three typical faults of power transformer is set up, and the test results show that the proposed method realizes reliable characterization of power transformer in different working status, and the identification accuracy is improved by about 7% compared with conventional methods.

Key words: transformer; robust local mean decomposition; voiceprint feature; defect identification

0 引言

随着电力行业的快速发展,变压器作为电力系统的核心设备,在电力输配系统中起着至关重要的

作用。由于电力变压器设备繁多、运行环境复杂,一旦发生故障则会影响其正常运行、进而引发大规模停电等重大事故^[1]。因此,研究一种可靠高效的变压器运行状态在线监测技术,对于及时发现变压

器潜在缺陷、进而提升电网运行的稳定性意义重大。

由于电力变压器运行时会因振动产生相应的噪声,因此可根据噪声信号的变化程度以检测设备是否异常。同时,基于声纹信号的设备状态检测技术具备非侵入式测量、实时监测等优势,在安全检测的情况下也能够得到检测设备丰富的状态信息参量。但限于现场环境与多振源耦合的复杂性,常规信号处理方法对于模式单一的简单信号具备较好的识别效果,但对于复杂工况下的非周期、非平稳的“双非”信号特征提取效果不佳,通常难以实现早期机械缺陷特征的有效提取^[2]。

鲁棒局部均值分解技术(robust local mean decomposition, RLMD)是一种可靠的信号分解技术^[3],其凭借分解效果好、计算速度快等优势在轴承故障诊断领域得到了广泛的应用。唐贵基等^[4]为转子故障特征的准确提取,提出一种自适应噪声完备集合鲁棒局部均值分解的特征提取方法,并借助实验表明所提方法不仅具有良好的分解效果,且在抑制模态混叠的同时能够更准确地识别出故障类型;陈志刚等^[5]提出一种基于鲁棒局部均值分解以及二阶瞬态提取变换的故障特征提取方法,并利用实验证明了所提方法的有效性;柯伟等^[6]提出一种基于鲁棒局部均值分解和同步提取小波变换的故障诊断方法,并利用仿真和试验表明所提方法的可靠性。然而,目前该技术在电力设备故障诊断领域中的应用并未见过多文献研究。

基于上述问题,文中针对电力变压器开展了一系列试验,提出了一种基于鲁棒局部均值分解与声纹特征的变压器典型缺陷辨识方法。首先利用鲁棒局部均值分解技术实现原始声纹信号的降噪处理,再借助皮尔逊相关系数保留与原始声纹信号相关性强的子带分量,接着提取每个子带分量的声纹特征值组成变压器不同状态的特征参量矩阵,最后基于随机森林分类算法实现变压器不同状态的可靠辨识。并利用实验表明了所提方法对于变压器不同状态辨识的可行性与有效性。

1 原理介绍

1.1 声信号降噪方法介绍

1.1.1 RLMD 算法介绍

鲁棒局部均值分解(robust local mean decomposition, RLMD)^[7]是一种可靠的信号分解技术,其凭借鲁棒性强、计算收敛速度快、分解精度高等诸多特点在信号去噪、信号分解以及特征提取等领域得到了广泛的应用^[8-10]。

该方法的具体步骤如下^[7]:假设有一离散采样信号向量 $\mathbf{x}(t)$, $t=1,2,\dots,N_t$, N_t 表示离散采样点总数。在确定信号 $\mathbf{x}(t)$ 中所有的极值点 x_i , $i=1,2,\dots,N_e$, N_e 表示极值点总数。则信号 $\mathbf{x}(t)$ 的局部幅值 a_i 和均值 \bar{m}_i 可表示为

$$\begin{cases} a_i = (x_i + x_{i+1})/2 \\ \bar{m}_i = |x_{i+1} - x_i|/2 \end{cases} \quad (1)$$

式(1)中, x_i 、 x_{i+1} 分别为第 i 个和第 $i+1$ 个极值点。

采用移动平均法处理式,利用 RSI 算法构造上下包络函数 $E_h(t)$ 和 $E_l(t)$,经处理得到对应的局部均值函数 $m_{11}(t)$ 和局部包络函数 $a_{11}(t)$

$$\begin{cases} m_{11}(t) = [E_h(t) + E_l(t)]/2 \\ a_{11}(t) = |E_h(t) - E_l(t)|/2 \end{cases} \quad (2)$$

将 $m_{11}(t)$ 从原始信号 $\mathbf{x}(t)$ 分离,即有

$$h_{11}(t) = \mathbf{x}(t) - m(t) \quad (3)$$

并将 $h_{11}(t)$ 除以包络函数 $a_{11}(t)$ 进而得到解调后的 $s_{11}(t)$,并重复以下步骤直到出现纯调频信号 $s_{1n}(t)$,其计算公式为

$$\begin{cases} s_{11}(t) = h_{11}(t)/a_{11}(t) \\ \vdots \\ s_{1n}(t) = h_{1n}(t)/a_{1n}(t) \end{cases} \quad (4)$$

可得该分量的包络信号 $a_i(t)$ 为

$$a_i(t) = \prod_{j=1}^n a_{ij}(t) \quad (5)$$

式(5)中, $\prod(\cdot)$ 为累乘。

则有乘积函数

$$pf_i(t) = a_i(t) \cdot s_{1n}(t) \quad (6)$$

令 $u_1(t) = \mathbf{x}(t) - pf_1(t)$ 代入式(7),直至 $u_d(t)$ 满足相应条件后停止。

$$\begin{cases} u_1(t) = \mathbf{x}(t) - pf_1(t) \\ u_2(t) = u_1(t) - pf_2(t) \\ \vdots \\ u_d(t) = u_{d-1}(t) - pf_d(t) \end{cases} \quad (7)$$

式(7)中, d 为分解得到的子带分量个数。

则信号 $\mathbf{x}(t)$ 表示为

$$\mathbf{x}(t) = \sum_{i=1}^d pf_i(t) + u_d(t) \quad (8)$$

文中针对电力变压器声纹信号的特点,设定分解的子带分量个数 $d=10$ 。

1.1.2 皮尔逊相关系数—RLMD 信号分量选择方法

在得到变压器声纹信号的若干个分量后,借助衡量两个变量之间线性关系强度和方向的皮尔逊相关系数^[11]指标选择合适的分量个数来重构声纹信号。

皮尔逊相关系数 r_{xy} 的计算式为

$$r_{xy} = \left(\sum_{i=1}^N (x_i - \bar{x}) \cdot (y_i - \bar{y}) \right) / \left(\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2} \right) \quad (9)$$

式(9)中： x_i 和 y_i 为两组进行计算的数据； N 为数据离散点总个数； \bar{x} 和 \bar{y} 为对应数据的平均值。显然，相关系数的绝对值越大，则表示这两组数据相关性越强。

1.2 声纹特征提取方法

选取能够充分表征信号状态参量的功率谱熵 E_1 (power spectral entropy)、幅值谱熵 E_2 (amplitude spectral entropy)^[12]和频率复杂度 E_3 (frequency complexity)^[13]进行声纹信号的特征提取。

1)功率谱熵 E_1 ，用于描述信号的频率特征。它是指信号功率谱密度函数的熵，表示声纹信号能量在频域上的分布均匀程度。其计算式为^[12]

$$E_1 = - \sum_{i=1}^{N_f} b_i \ln(b_i) \quad (10)$$

式(10)中： N_f 为离散谱点总数； b_i 表示第 i 个功率谱值对于整体功率谱值的占比。

2)幅值谱熵 E_2 ，与功率谱熵类似，也是描述信号频率特征的指标。不同之处在于该特征参量是指信号在频域上幅度谱密度函数的熵，反映了信号能量在不同频率上的分布均匀程度，其更侧重于信号在频域上的振幅变化，能够有效揭示信号的周期性和非周期性特征。其计算式为^[12]

$$E_2 = - \sum_{i=1}^{N_f} c_i \ln(c_i) \quad (11)$$

式(11)中： N_f 为离散谱点总数； c_i 为第 i 个频谱信号幅值对于整体幅值的占比。

3)频率复杂度 E_3 ，用于描述信号的复杂性，其能够有效揭示信号的动态变化程度、非线性特征和时空耦合特性等。其计算式为^[13]

$$E_3 = - \sum_{i=1}^{N_s} p_{fi} \ln(p_{fi}) \quad (12)$$

式(12)中： N_s 为计算频段下信号的谐频数， p_{fi} 为频率为 f 时的谐波占比。

1.3 随机森林分类方法

在利用上述步骤提取得到变压器声纹信号各子带分量的特征矩阵后，借助随机森林分类算法实现变压器设备不同工作状态的可靠辨识。随机森林分类算法一种可靠的分类技术，其凭借算法鲁棒性强、计算精度高等优势，在数据挖掘、机器学习等领域得到了广泛应用^[14]。该技术实现步骤可分为随机采样和建立决策树，其主要实现步骤为^[15]：

步骤1)，从训练数据集中随机选择一定数量的

样本和特征，用于构建每个决策树。这种随机选择可以避免决策树过度拟合。

步骤2)，使用选择的样本和特征构建决策树模型。在构建树的过程中，对于每个节点，使用某些指标(如信息增益或基尼指数)选择最佳的特征来分割数据，并将数据划分为更小的子集。

步骤3)，重复步骤1)和步骤2)，直到构建足够数量的决策树。使用构建的所有决策树对测试数据进行分类，最终将所有分类结果进行投票或平均，得到最终分类结果。其实现流程见图1。

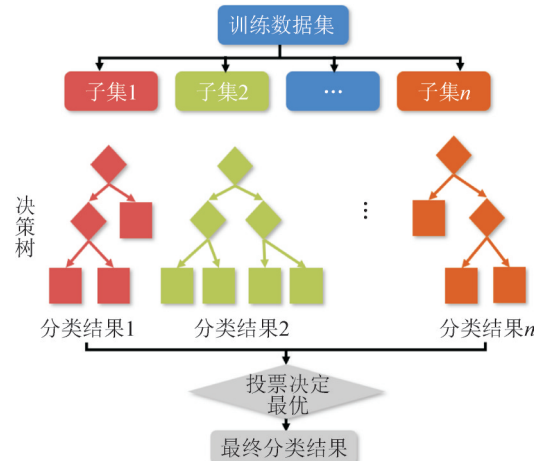


图1 随机森林算法实现流程

Fig. 1 Implementation process of random forest algorithm

1.4 基于鲁棒局部均值分解与声纹特征的变压器典型缺陷辨识方法实现流程

基于鲁棒局部均值分解与声纹特征的变压器典型缺陷辨识方法实现流程见图2，首先利用鲁棒局部均值分解方法实现原始声纹信号的降噪处理，再根据皮尔逊相关系数指标选择、保留与原始声纹信号相关性强的子带分量；然后提取每个子带分量的功率谱熵、幅值谱熵和频率复杂度特征值组成变压器不同状态下的特征参量矩阵；最后利用随机森林分类算法实现变压器不同工作状态的可靠辨识。

2 试验分析

2.1 试验设置

变压器在运行时由于受过度振动、温度变化等因素的影响，都有可能引起绕组松动。绕组松动缺陷会导致噪声增大、设备短路进而加速绝缘老化甚至可能导致设备损坏等危害^[16]。因此，及早发现和解决变压器绕组松动问题，对设备的正常运行和安全都至关重要。绕组松动的常见原因有绝缘层减少、垫块脱落、短路电流对绕组造成的冲击等，上述松动故障对绕组振动的影响可以等效为不同预紧力对绕组振动的影响。因此，文中通过采集变压器

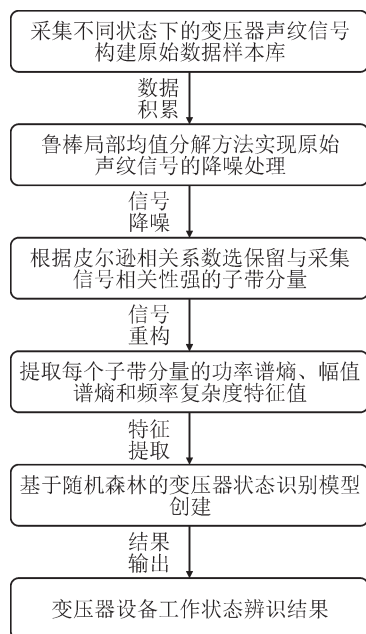


图2 基于鲁棒局部均值分解与声纹特征的变压器典型缺陷辨识方法实现流程

Fig. 2 Implementation process of transformer typical defect identification method based on robust local mean decomposition and voiceprint features

绕组不同程度的松动状态下的声纹数据来验证所提方法的可行性与有效性,现场采集布置示意图3(a)。在试验中通过控制变压器上铁轭穿心螺杆的预紧力来模拟不同松动程度,进而模拟实际中的变压器绕组松动缺陷,缺陷示意图3(b)。其中,原始声纹数据样本库包括了变压器在60%、100%、140%预紧力工作条件下的声纹数据。变压器型号为SCB10-800/10,额定电压为10 kV。




图3 试验现场布置示意

Fig. 3 Schematic layout of test site

2.2 数据分析

使用鲁棒局部均值分解方法实现正常运行状态下变压器声纹信号的降噪处理。只对声纹信号的前10个子带分量进行研究,见图4。每个子带分量与原始声纹信号的皮尔逊相关系数见表1,结合图表可知,前5个子带分量包含了变压器声纹信号的绝大部分信息,即皮尔逊相关系数分别为0.924、0.796、0.651、0.475、0.364,相较于第6个子带的相关

系数0.121具有较为显著的区别,故文中选取前5个子带分量进行计算。

2.3 状态辨识

基于上述试验平台采集得到变压器在60%、100%、140%预紧力工作条件下的声纹数据,并选取每组状态各200个样本,共计600组数据进行训练。同时,将得到的数据集随机分为训练集和测试集,其比例为8:2(即有480组数据被用来进行训练,剩余120组数据被用作测试)。将数据输入随机森林分类器进行训练、学习,最后将所提方法得到的状态分类精度与常规方法进行比较,以验证所提方法对于变压器缺陷辨识方面的有效性与优越性。

为验证所提方法对于电力变压器不同状态进行特征提取的有效性,利用流形学习理论中的t-分布随机临域嵌入算法^[17](t-sne)、将15维特征矩阵(如前文所述,由于文中选取了声纹信号的前5个子带、每个子带分别计算功率谱熵、幅值谱熵和频率复杂度3个特征值,故变压器每个状态对应了15个特征值参量)降维至二维进行聚类效果可视化展示。利用t-sne算法对于电力变压器3种状态提取得到的特征向量聚类效果示意,见图5。由图5可知,变压器设备不同状态下的特征值在二维平面具备良好的聚集效果,表明了文中所选特征值对于变压器不同状态辨识的有效性。

同时为定量评价分类模型的泛化能力,利用混淆矩阵和多分类评价指标进行分类模型辨识效果的评价^[18]。利用所提方法得到的混淆矩阵与评价指标计算结果见图6和表2。图6和表2中横纵坐标的数字1~3分别表示变压器设备在60%、100%、140%预紧力下的3种状态,混淆矩阵的对角线数字分别表示每种状态下识别正确的样本数。结合图6和表2可知,在全部120个测试集中只有3个被错误分类,测试样本集的分类正确率为97.50%。由表2可知所提方法的精度、召回率、F₁值分别为97.56%、97.50%、97.50%,均具备良好的准确率,证明了所提方法的有效性。

2.4 结果对比

为进一步表明所提方法的优越性,还将文中方法与基于原始声纹信号提取的声纹特征值(未进行RLMD处理)和随机森林算法的对比方法1、基于RLMD处理后的声纹特征值和极限学习机^[19]的对比方法2进行了对比。对比方法1与所提方法的区别仅在于对比方法1所用的数据集为未经RLMD处理的数据;对比方法2中与所提方法的区别仅在于所选择的分类器不同,在使用极限学习机进行分类时,

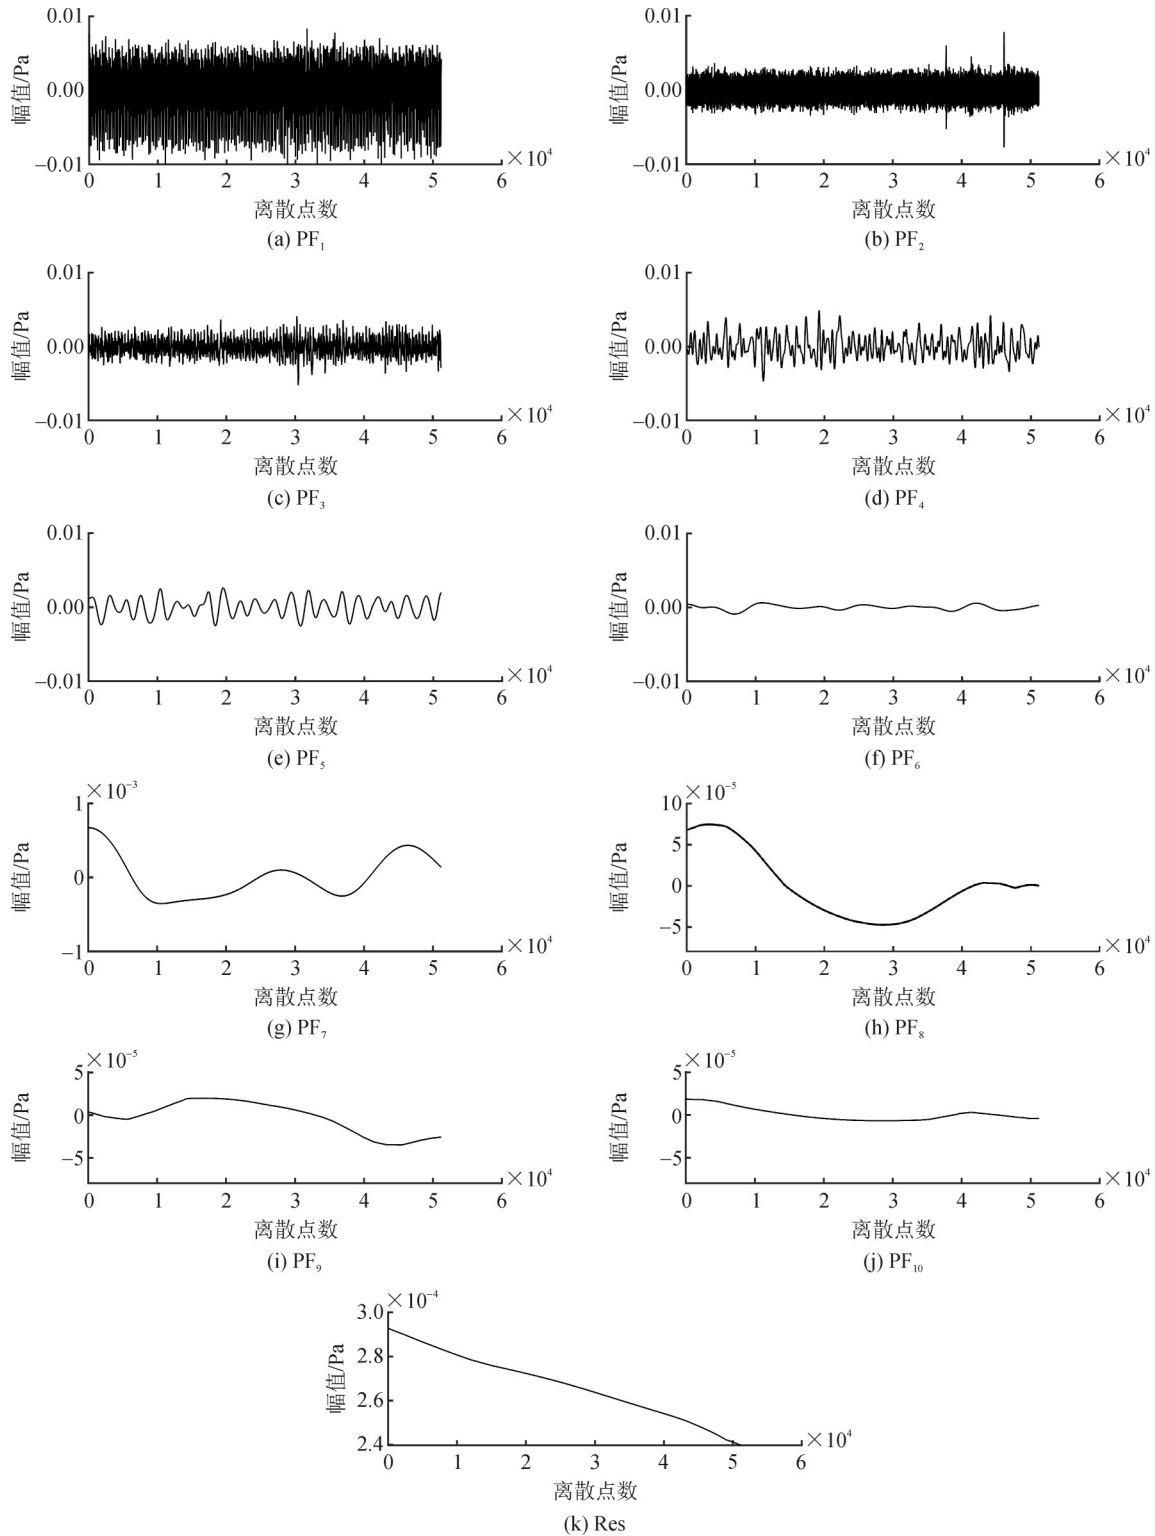


图4 鲁棒局部均值信号分解示意

Fig. 4 Schematic diagram of robust local mean signal decomposition

设置该分类模型的激活函数为Sigmoid函数^[20],随机抽取480个样本进行训练,120个样本进行测试。

基于原始声纹信号提取的声纹特征值(未进行RLMD处理)的聚类效果示意图7,从图7中可以看出,其特征向量聚簇效果较差,且出现了明显的重叠现象,故利用对比方法1的特征值难以有效表针

电力变压器的不同状态,因此得到的3种状态辨识结果皆不理想、识别精度均低于90%;而对比方法2中由于采用了RLMD处理后的声纹特征、更有效地表征了变压器设备的工作状态,因此相较于对比方法1,其在各个状态下的识别精度均有一定程度的提升,但总体识别效果仍低于所提方法,这是由于

表1 原始信号与各个子带的皮尔逊相关系数

Table 1 Pearson correlation coefficient between original signal and each subband

子带	PF ₁	PF ₂	PF ₃	PF ₄	PF ₅	PF ₆	PF ₇	PF ₈	PF ₉	PF ₁₀
相关系数	0.924	0.796	0.651	0.475	0.364	0.121	0.082	0.026	0.018	0.009




图5 所提方法的特征矩阵二维可视化效果展示

Fig. 5 Two-dimensional visualization effect of the feature matrix of the proposed method

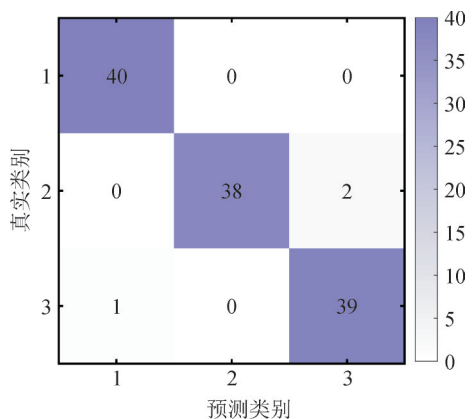


图6 混淆矩阵示意

Fig. 6 Confusion matrix schematic

表2 评价参数表

Table 2 Evaluation parameters %

参数	类别1	类别2	类别3	平均值
精度	97.56	100.00	95.12	97.56
召回率	100.00	95.00	97.50	97.50
F ₁ 值	98.77	97.44	96.30	97.50

极限学习机分类方法相较于随机森林算法存在泛化性较差、易产生过拟合以及对于异常值过于敏感等不足,因此识别精度不高,见表3。

3 结语

为实现电力变压器工作状态的可靠辨识,提出一种基于鲁棒局部均值分解与声纹特征的变压器典型缺陷辨识方法。首先利用鲁棒局部均值分解方法实现原始声纹信号的降噪处理,并依据皮尔逊




图7 对比方法的特征矩阵二维可视化效果展示

Fig. 7 Two-dimensional visualization of the characteristic matrix of the comparison method

表3 3种方法的识别精度对比

Table 3 Comparison of recognition accuracy of three methods %

方法	类别1	类别2	类别3	平均值
所提方法	97.56	100.00	95.12	97.56
对比方法1	89.47	80.00	86.49	85.32
对比方法2	92.31	86.05	92.11	90.15

相关系数保留与原始声纹信号相关性强的子带分量;其次提取每个子带分量的功率谱熵、幅值谱熵和频率复杂度特征值组成变压器不同状态的特征参量矩阵;最后基于随机森林分类算法进行状态辨识和分类。试验结果表明:所提方法可以有效表征电力变压器的不同工作状态,且状态辨识精度相较于常规方法有显著提升,提升约7%。

参考文献:

- 王署东. 基于传感器阵列的变电站局部放电定位关键技术研究[D]. 合肥:合肥工业大学,2021.
WANG Shudong. Research on key technologies of partial discharge localization in substation based on sensor array[D]. Hefei: Heifei University of Technology, 2021.
- 李旭,王文森,郭丽,等.基于多传感器融合的电力变压器内部放电定位与辨识技术[J]. 电网与清洁能源,2024,40(3):22-31.
LI Xu, WANG Wensen, GUO Li, et al. Internal discharge location and identification for power transformers based on multi-sensor fusion[J]. Power System and Clean Energy, 2024, 40(3):22-31.
- 尚海昆,张冉喆,黄涛,等.基于CEEMDANTQWT方法的变压器局部放电信号降噪[J]. 电力科学与技术学报,2024(1):272-284.
SHANG Haikun, ZHANG Ranzhe, HUANG Tao, et al. Partial discharge signal denoising based on CEEMDANTQWT method for power transformers[J]. Journal of Electric Power Science and Technology, 2024(1):272-284.
- 唐贵基,李树才,卢盛阳,等.基于CERLMDAN的转子故障诊断[J]. 动力工程学报,2020,40(9):720-727.
TANG Guiji, LI Shucai, LU Shengyang, et al. Rotor fault diagnosis

- based on CERLMDAN[J]. Journal of Chinese Society of Power Engineering, 2020, 40(9):720-727.
- [5] 陈志刚, 赵志川, 钟新荣, 等. 基于鲁棒局部均值分解与二阶瞬态提取变换的滚动轴承故障诊断[J]. 科学技术与工程, 2022, 22(1): 157-165.
- CHEN Zhigang, ZHAO Zhichuan, ZHONG Xinrong, et al. Fault diagnosis of rolling bearing based on robust local mean decomposition and second-order transient-extracting transform[J]. Science Technology and Engineering, 2022, 22(1):157-165.
- [6] 柯伟, 金仲平, 吕信策, 等. 基于RLMD和WSET的变转速下滚动轴承故障诊断[J]. 机电工程, 2022, 39(3): 300-308.
- KE Wei, JIN Zhongping, LYU Xince, et al. Fault diagnosis method of variable speed rolling bearing based on RLMD and WSET[J]. Mechanical & Electrical Engineering Magazine, 2022, 39(3): 300-308.
- [7] LU X, ZHU A, SONG Y, et al. Application of improved robust local mean decomposition and multiple disturbance multi-verse optimizer-based MCKD in the diagnosis of multiple rolling element bearing faults[J]. Machines, 2022(10): 883.
- [8] NGOC-LAN HUYNH A, DEO R C, ALI M, et al. Novel short-term solar radiation hybrid model: Long short-term memory network integrated with robust local mean decomposition[J]. Applied Energy, 2021(298): 117193.
- [9] LI Yongbo, SI Shubin, LIU Zhiliang, et al. Review of local mean decomposition and its application in fault diagnosis of rotating machinery[J]. Journal of Systems Engineering and Electronics, 2019, 30(4): 799-814.
- [10] JIANG Yan, LIU Shuoyu, PENG Liuliu, et al. A novel wind speed prediction method based on robust local mean decomposition, group method of data handling and conditional kernel density estimation[J]. Energy Conversion and Management, 2019(200): 112099.
- [11] YU Kui, LIU Lin, LI Jiuyong, et al. Multi-source causal feature selection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(9):2240-2256.
- [12] POWELL G E, PERCIVAL I C. A spectral entropy method for distinguishing regular and irregular motion of Hamiltonian systems [J]. Journal of Physics A: Mathematical and General, 1979, 12(11): 2053.
- [13] HONG Kaixing, HUANG Hai, FU Yaqiong, et al. A vibration measurement system for health monitoring of power transformers[J]. Measurement, 2016(93):135-147.
- [14] PAUL A, MUKHERJEE D P, DAS P, et al. Improved random forest for classification[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2018, 27(8): 4012-4024.
- [15] BELGIU M, DRĂGUȚ L. Random forest in remote sensing: A review of applications and future directions[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016(114):24-31.
- [16] 杨金鑫, 廖才波, 胡雄, 等. 基于DGA与TPELightGBM的变压器故障诊断[J]. 电力科学与技术学报, 2024, 39(4): 70-77.
- YANG Jinxin, LIAO Caibo, HU Xiong, et al. Transformer fault diagnosis based on DGA and TPELightGBM[J]. Journal of Electric Power Science and Technology, 2024, 39(4): 70-77.
- [17] 戚沁雅, 曹伯仲, 安义, 等. 基于改进Prony算法的配电变压器群励磁涌流多特征综合辨识方法[J]. 电力科学与技术学报, 2024, 39(6): 69-78.
- QI Qinya, CAO Bozhong, AN Yi, et al. Comprehensive multifeature identification method of magnetizing inrush current in distribution transformers based on improved Prony algorithm[J]. Journal of Electric Power Science and Technology, 2024, 39(6): 69-78.
- [18] XU Jianfeng, ZHANG Yuanjian, MIAO Duoqian. Three-way confusion matrix for classification: A measure driven view[J]. Information Sciences, 2020(507): 772-794.
- [19] HUANG Guangbin, ZHU Qinyu, SIEW C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1/3): 489-501.
- [20] ILIEV A, KYURKCHIEV N, MARKOV S. On the approximation of the step function by some sigmoid functions[J]. Mathematics and Computers in Simulation, 2017(133): 223-234.

王磊磊(1991—),男,硕士研究生,工程师,主要研究方向为输变电设备电磁环境监测及评价技术(E-mail: 1515439909@qq.com)。

张阳(1995—),男,硕士研究生,工程师,主要研究方向为噪声与振动控制、电力设备状态监测及故障诊断(通信作者)(E-mail: jiezhizhang1995@gmail.com)。