

电力设备局部放电声学检测分类研究

陈泓岩, 李浩然, 杨宇豪, 冯泰棋, 应 东

(国网银川供电公司, 宁夏 银川 750000)

摘要: 超声波检测技术在电力设备带电检测中具有广泛的应用前景, 针对电力变压器和 GIS 组合电器局部放电过程中产生的超声波信号进行了检测分类研究。提出了一种局部放电超声波信号多阶段多分类模型。在模型的第一阶段, 采用支持向量机将局部放电超声波信号分类为不同设备的信号; 在模型的第二阶段, 采用极限学习机对不同设备的局部放电超声波信号进行详细的多分类, 还采用了粒子群算法对支持向量机与极限学习机的参数进行了优化。实验结果表明, 所提模型取得了较好的分类结果, 实现了多种局部放电超声波信号的精细分类。

关键词: 电力设备; 带电检测; 局部放电; 超声波; 机器学习

Research on classification of partial discharge acoustic detection in power equipment

CHEN Hongyan, LI Haoran, YANG Yuhao, FENG Taiqi, YING Dong

(State Grid Yinchuan Power Supply Company, Yinchuan 750001, China)

Abstract: Ultrasonic detection technology has a wide range of application prospects in the live detection of power equipment. In this paper, the detection and classification of ultrasonic signals generated in the partial discharge process of power transformers and GIS combined appliances is studied. This paper proposes a multi-stage multi-classification model for partial discharge ultrasonic signal classification. In the first stage of the model, the support vector machine was used to classify the partial discharge ultrasonic signals into signals of different devices. In the second stage of the model, the extreme learning machine was used to carry out detailed multi-classification of the partial discharge ultrasonic signals of different devices. In this paper, particle swarm algorithm is also used to optimize the parameters of support vector machine and extreme learning machine. The experimental results show that the model proposed in this paper achieves good classification results and realizes the fine classification of various partial discharge ultrasonic signals.

Key words: power equipment; live detection; partial discharge; ultrasound; machine learning

0 引言

目前, 随着诊断技术与检测设备的发展与成熟, 也促进着电力设备带电检测技术的发展^[1-3]。在众多电力设备局部放电检测技术中, 声学检测已广泛用于电力设备局部放电检测, 具有非常广阔的应用前景。通过在电力设备上放置检测设备

检测局部放电超声波信号, 能够实现局部放电的在线监测与放电位置的定位^[4-6]。

本文提出了一种局部放电超声波信号多阶段多分类模型, 对变压器与组合电器的局部放电超声波信号进行分类, 通过在两个阶段对两个电力设备的局部放电超声波信号进行分类, 可以实现

对不同电力设备、不同类型局部放电超声波信号的精细分类。

1 局部放电信号研究基础

本文研究了变压器与组合电器中八种类型的超声波信号，对应于变压器与组合电器中出现的八种局部放电超声波信号^[7-10]。在这八种局部放电导致的超声波信号中，其中的四种类型是变压器局部放电产生的超声波信号，其他的四种类型是组合电器局部放电产生的超声波信号。

1.1 变压器局部放电产生的超声波信号

1) 针针放电。变压器内部部件需要圆整化，不能有任何尖角，因为在高场强情况下，电荷会聚集在尖角处，进而引起局部放电。根据模拟针针间隙放电超声波信号的能量谱与小波包分解的结果可知，针针放电超声波信号的特征频率区间为90~125 kHz。

2) 针板放电。根据模拟针板间隙放电超声波信号的能量谱与小波包分解的结果可知，针板放电的超声波信号的特征频率区间为125~150 kHz。

3) 悬浮放电。悬浮放电通常是由于变压器内部部件松动或连接不良引起的放电。根据模拟针板间隙放电超声波信号的能量谱与小波包分解的结果可知，悬浮放电的超声波信号的特征频率区间为30~60 kHz。

4) 沿面放电。沿面放电通常发生于绝缘体表面，由绝缘体表面的污垢、水分或灰尘颗粒引起。根据模拟沿面放电超声波信号的能量谱与小波包分解的结果可知，沿面放电的超声波信号的特征频率区间为60~90 kHz。

1.2 组合电器局部放电产生的超声波信号

1) 内部放电。多为绝缘件内部气隙放电，这类放电现象是由于绝缘材料缺陷导致。组合电器中此类放电的超声波信号的特征频率区间主要集中于30 kHz。

2) 沿面放电。与变压器沿面放电的产生原因类似。组合电器中此类放电的超声波信号的特

征频率区间主要集中于90~110 kHz。

3) 悬浮放电。与变压器悬浮放电的产生原因类似。组合电器中此类放电的超声波信号的特征频率区间主要集中于70~90 kHz。

4) 尖端放电。与变压器尖端放电的产生原因类似。组合电器中此类放电的超声波信号的特征频率集中于22 kHz、38 kHz处。

2 特征提取与分类算法

2.1 小波包变换特征提取算法

小波变换仅对信号低频段进行分解，然而，变压器局部放电超声波信号与组合电器局部放电超声波信号的特征频率区间均处于数千赫兹频段^[11]。因此，本文采用小波包变换算法对变压器超声波信号进行特征提取。小波包变换在小波变换的基础上，对未分解的高频段信号进行迭代分解，更有利于对变压器与组合电器局部放电超声波信号的特征进行提取。

对于一个连续时域信号 $f(t)$ ，连续小波变换可以表示为

$$\text{CWT}(\tau, a) = \int_{-\infty}^{+\infty} f(t) \overline{\psi_{\tau,a}(t)} dt = \langle f(t), \psi_{\tau,a}(t) \rangle \quad (1)$$

式中， $\psi_{\tau,a}(t)$ 为连续小波基函数，可以表示为

$$\psi_{\tau,a}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-\tau}{a}\right), \quad a > 0 \quad (2)$$

式中， τ 与 a 分别为平移因子和尺度因子。

在进行小波变换时，可以将小波基函数认为是倍频滤波器组，则带通滤波器的小波函数 $\psi(t)$ 可以表示为

$$\psi(t) = \sqrt{2} \sum_{n=-\infty}^{+\infty} g(n) \phi(2t-n) \quad (3)$$

式中， $\phi(t)$ 为尺度函数，在时域上，可以通过使用半带低频滤波器表示，即

$$\phi(t) = \sqrt{2} \sum_{n=-\infty}^{+\infty} h(n) \phi(2t-n) \quad (4)$$

其中，冲激响应 $h(n)$ 可以表示为

$$h(n) = \frac{\sin(\pi n/2)}{\sqrt{2}\pi n/2} \quad (5)$$

而 $g(n)$ 可以表示为

$$g(n) = (-1)^n h(1-n) \quad (6)$$

进行小波包变换时,通过定义新空间 U_j^l 的分解来表征小波空间 W_j 和尺度空间 V_j 的正交分解, U_j^l 的分解可以表示为

$$U_{j+1}^l = U_j^{2l} \oplus U_j^{2l+1}, j=0,1,2,\dots; l=1,2,\dots \quad (7)$$

其中

$$V_j = U_j^{2l} \quad (8)$$

$$W_j = U_j^{2l+1} \quad (9)$$

则根据式(7),小波包的分解可以表示为

$$U_j^0 = U_{j-1}^0 \oplus U_{j-1}^1 \quad (10)$$

$$U_{j-1}^0 = U_{j-2}^0 \oplus U_{j-2}^1 \quad (11)$$

$$U_{j-1}^1 = U_{j-2}^3 \oplus U_{j-2}^4 \quad (12)$$

以一个3层小波包分解为例,对于分解的第 j 层,将原始信号分解为 2^j 等带宽的频带,并缩短频带内的信号长度为未分解信号的 $1/2^j$ 。对时域信号进行分解的示意图如图1所示。




图1 3层小波包分解示意图

Fig. 1 3-layer wavelet packet decomposition diagram

2.2 分类算法

在对超声波信号进行特征提取后,需要对提取出的信号特征进行分类。前文中将超声波信号分为变压器与组合电器局部放电产生的超声波信号,随后再分别将局部放电超声波信号进行多分类,因此本文分别采用用于二分类的支持向量机与可以用于多分类的极限学习机对局部放电超声波信号特征进行分类。

(1) 支持向量机

支持向量机使用核函数将多维数据投影至高维空间,并寻找能够划分两类样本的最优超平面,以实现样本的分类^[12]。设给定训练样本集 $(x_i, y_i), i=1,2,\dots,m$,其中 x_i 为训练样本, y_i 为训练

样本的标签, m 为训练样本的数量。计算最优超平面的目标函数与约束条件,即

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1} \xi_i \quad (13)$$

$$\text{s.t. } y_i (\mathbf{w} \cdot x_i + b) \geq 1 - \xi_i$$

式中, $\mathbf{w}$ 为惯性权重; b 为偏置; ξ_i 为松弛度; C 为惩罚因子。

支持向量机的分类决策函数为

$$f(x) = \text{sign}(\mathbf{w} \cdot x_i + b) \quad (14)$$

(2) 极限学习机

极限学习机为一种单隐层前馈神经网络^[13],具有 L 个隐含层节点的极限学习机的网络模型可表示为

$$\sum_{j=1}^L \beta_j G(a_j, b_j, x_i) = y_i \quad (15)$$

式中, a_j 为输入层的输入权值; b_j 为隐含层节点阈值; β_j 为输出权值向量; $G(\cdot)$ 为激活函数。

式(15)也可以表示为矩阵形式,即

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{Y} \quad (16)$$

式中, $\mathbf{H}$ 为隐含层矩阵; $\boldsymbol{\beta}$ 为输出权值矩阵; $\mathbf{Y}$ 为标签矩阵。

在极限学习机中,输入权值 a_j 与隐含层节点阈值 b_j 是随机生成的。输出权值矩阵的最优解 $\hat{\boldsymbol{\beta}}$ 可由下式计算得到

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^\dagger \mathbf{Y} \quad (17)$$

式中, $\mathbf{H}^\dagger$ 为隐含层矩阵 $\mathbf{H}$ 的Moore-Penrose转置。

2.3 粒子群优化算法

由于支持向量机中的参数为人为选择,因此选择不同的参数会导致不同的分类结果;此外,由于极限学习机中的输入权值与阈值为随机生成,也会导致极限学习机的分类结果不确定。为了更好地提升分类效果,本文采用粒子群优化算法对支持向量机与极限学习机中的参数进行优化。

粒子群算法为一种全局最优算法,其具体思路为:随机产生的一组初始粒子为可行解的集合,这些粒子通过速度更新公式来决定其运动方向以及最终位置,并通过求解适应度函数来判断粒子的好坏程度,对比单个粒子的最优解与粒子

群的最优解，经过一系列迭代计算后找到全局最优解^[14]。粒子群算法的步骤：

- 1) 初始化参数。设定搜索范围、速度范围、迭代次数以及收敛范围等。
- 2) 评价粒子。通过适应度函数计算每个粒子的适应度值，并根据适应度值更新全局最优解。
- 3) 更新粒子状态。根据设定的速度范围和搜索范围更新粒子状态。
- 4) 判断迭代次数。若搜索次数达到设定的迭代次数或当前最优解已达到收敛范围要求，则输出最优解；若搜索次数未达到设定的迭代次数，则跳转至步骤2)继续搜索。

3 局部放电超声波信号的多分类研究

本文提出了一种局部放电超声波信号的多阶段多分类模型，该模型的流程图如图2所示。




图2 局部放电超声波信号多阶段多分类模型流程

Fig. 2 Multi stage and multi classification model flow of partial discharge ultrasonic signal

局部放电超声波信号的多阶段多分类流程如下。

(1) 训练阶段

- 1) 采用小波包变换对八种局部放电超声波

信号的训练样本进行特征提取，并根据变压器局部放电超声波信号与组合电器局部放电超声波信号两种类型，将提取出的训练特征样本划分为两个部分（每个部分包含四种类型）。

- 2) 使用变压器局部放电超声波信号与组合电器局部放电超声波信号的训练特征样本训练二分类支持向量机分类器，并使用粒子群优化算法对支持向量机的参数进行优化。

- 3) 使用变压器局部放电超声波信号的四种训练特征样本训练第一个多分类极限学习机分类器；使用组合电器局部放电超声波信号的四种训练特征样本训练第二个多分类极限学习机分类器。同时，使用粒子群优化算法对两个极限学习机分类器的参数进行优化。

(2) 测试阶段

- 1) 采用小波包变换对变压器超声波信号与组合电器超声波信号的测试样本进行特征提取。

- 2) 将提取出的测试特征样本送入支持向量机分类器进行分类。

- 3) 将分类结果为变压器局部放电超声波信号的测试特征样本送入第一个极限学习机分类器，得到四种分类结果；将分类结果为组合电器局部放电超声波信号的测试特征样本送入第二个极限学习机分类器，得到另外四种分类结果。

4 仿真结果与分析

4.1 仿真数据说明

仿真实验采用的数据数量以及其类别标签见表1。

表1 采用数据设置

Tab. 1 Using data settings

超声波信号	标签	样本量
变压器针针放电	1	1 329
变压器针板放电	2	1 560
变压器悬浮放电	3	1 079
变压器沿面放电	4	1 032
组合电器内部放电	5	1 068
组合电器沿面放电	6	1 132
组合电器悬浮放电	7	1 461
组合电器尖端放电	8	1 339

本文采用的变压器与组合电器局部放电超声波信号样本总数为10 000, 其中变压器局部放电超声波信号样本量为5 000, 组合电器局部放电超声波信号样本量为5 000。

4.2 仿真参数设置

本文采用MATLAB软件进行仿真分析, 在仿真实验验证方面, 进行五折交叉验证以消除随机误差。

在小波包变换特征提取方面, 分别设置小波分解层数为2~5以进行对比分析。在分类器参数设置方面, 对于支持向量机的参数, 使用粒子群算法对参数进行优化, 设置粒子数为30, 随机设置每个粒子的位置与速度, 并设置迭代范围上限为1 000次, 收敛准确度为0.001; 对于极限学习机的参数, 使用粒子群算法对参数进行优化, 设置隐含层节点数量为60。

4.3 仿真结果与分析

本文分别从不同小波包分解层数、模型参数优化情况和不同训练样本数量三个方面对提出的模型进行仿真对比分析。

(1) 小波包分解层数对分类结果的影响

在进行不同小波包分解层数下的仿真实验时, 使用每类样本的50%作为训练样本, 其余样本作为测试样本进行测试。此外, 对模型的参数进行粒子群优化。不同小波包分解层数下的分类结果如图3所示。




图3 不同小波包分解层数下的分类正确率

Fig. 3 Classification accuracy under different wavelet packet decomposition levels

根据图3结果可知, 随着小波包分解层数的增加, 分类正确率也逐渐提升。这是由于不同类别的超声波信号分别处于不同频段, 低层数的小波包分解构造出的特征样本维度较低, 会造成模型的过拟合, 导致分类器分类性能降低; 而高层数的小波包分解能够更加细化分割超声波信号频段, 构造出更高维度的特征样本, 避免分类器的过拟合, 进而提升分类器的分类性能, 提高分类正确率。

(2) 模型参数优化情况对分类结果的影响

在进行不同模型参数优化情况下的仿真实验时, 同样使用每类样本的50%作为训练样本, 其余样本作为测试样本进行测试, 此外, 设置小波包分解层数为5。不同模型参数优化情况下的分类结果见表2。

表2 不同模型参数优化情况下的分类正确率

Tab. 2 Classification accuracy under different model parameter optimization

参数优化情况	正确率 (%)
不优化参数	91.42
优化参数	95.83

(3) 不同训练样本数量对分类结果的影响

在进行不同训练样本数量下的仿真实验时, 分别使用每类样本的20%、40%和60%作为训练样本, 其余样本作为测试样本进行测试。此外, 设置小波包分解层数为5, 对模型的参数进行粒子群优化。不同训练样本数量下的分类结果如图4所示。




图4 不同训练样本数量下的分类正确率

Fig. 4 Classification accuracy under different training sample numbers

根据图4结果可知,随着训练样本数量的增加,分类正确率也逐渐提升。此外,当训练样本数量从总样本数量的20%增长至40%时,其分类正确率有较大提升;而当训练样本数量从总样本数量的40%增长至60%时,其分类正确率的提升较少。这是由于在训练样本数量较少(20%)时,训练出的分类器性能较差,无法有效完成多分类任务;而当训练样本数量较多(60%)时,用于分类器训练的样本数量已经足够多,训练出的分类器性能趋近完善且有陷入欠拟合的风险。

5 结束语

发展电力设备带电检测技术是未来检修技术发展的重要方向。本文针对变压器与组合电器局部放电过程中出现的超声波现象,对变压器与组合电器的局部放电超声波信号进行了分类研究。首先,本文采用小波包变换对变压器与组合电器的局部放电超声波信号进行提取;随后,本文提出了一种局部放电超声波信号多阶段多分类模型,在第一阶段将局部放电超声波信号分类为变压器局部放电超声波信号与开关柜局部放电超声波信号,在第二阶段对变压器局部放电超声波信号与开关柜局部放电超声波信号进行详细的多分类,实现了对两种电力设备不同局部放电超声波信号的详细分类。本文分别从不同小波包分解层数、模型参数优化情况和不同训练样本数量三个方面对提出的模型进行仿真对比分析。实验结果表明,本文提出的多阶段多分类模型取得了较高的分类正确率,证明了本文提出的方法可行有效。

参考文献

- [1] 吴松. 基于声学特征的变压器故障诊断研究[D]. 武汉: 华中科技大学, 2012.
- [2] 蒋英圣, 伍志荣, 聂德新, 等. 声测法检测GIS中局部放电的初步研究[J]. 高压电器, 1995(1): 21-24.
- [3] 苑舜. 全封闭组合电器局部放电超声传播特性及监测问题的研究[J]. 中国电力, 1997(1): 7-10.

- [4] 宋雨轩, 陈伟根, 张知先, 等. 基于光纤迈克尔逊干涉仪的GIS内置局部放电超声传感技术[J]. 高压技术, 2022, 48(8): 3088-3097.
- [5] 郭雪婷. 变压器局部放电研究综述[J]. 电声技术, 2022, 46(2): 114-117.
- [6] 潘超, 戚革庆, 王旷, 等. 变电设备局部放电故障非接触式带电检测方法研究[J]. 机械与电子, 2020, 38(11): 60-65.
- [7] 吴国鑫. 变压器故障声纹检测与诊断方法研究[D]. 北京: 华北电力大学, 2021.
- [8] 季坤, 朱太云, 李坚林, 等. 基于声纹信号的变压器故障在线监测装置设计[J]. 电气自动化, 2022, 44(3): 97-99, 106.
- [9] 杨光辉, 杨光粲, 黎宏锐. 声信号特征融合的变压器故障判断方法[J]. 北京理工大学学报, 2022, 42(3): 233-241.
- [10] 苏淼, 陆颖杰. 基于声电联合技术的组合电器局部放电分析[J]. 通信电源技术, 2019, 36(12): 262-263.
- [11] 黄道友, 任丽佳, 康健. 小波包变换与支持向量机的电力变压器故障诊断方法[J/OL]. 电源学报: 1-14. <http://kns.cnki.net/kcms/detail/12.1420.TM.20220706.1324.002.html>
- [12] 李淑锋, 李加, 张玉峰, 等. 基于粒子群优化的支持向量机停电预测研究[J]. 南京理工大学学报, 2022, 46(4): 460-466.
- [13] 程蓉, 白艳萍, 胡红萍, 等. 含类信息的极限学习机自动编码器特征学习方法[J/OL]. 电子测量技术: 1-9. <http://kns.cnki.net/kcms/detail/11.2175.TN.20220810.1022.004.html>
- [14] 李淑锋, 李加, 张玉峰, 等. 基于粒子群优化的支持向量机停电预测研究[J]. 南京理工大学学报, 2022, 46(4): 460-466.

作者简介

陈泓岩(1987—), 男, 高级工程师, 主要从事变电检修工作。

(收稿日期: 2022-09-09)