

DOI: 10.11992/tis.201805034

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.tp.20180927.0937.002.html>

BP 神经网络和支持向量机相结合的 电容器介损角辨识

赵文清, 严海, 王晓辉

(华北电力大学 控制与计算机工程学院, 河北 保定 071003)

摘要: 针对电力电容器介质损耗的计算方法稳定性较差, 频率波动对介损角的辨识有较大影响的问题, 提出了 BP 神经网络和支持向量机 (support vector machine, SVM) 相结合 (BP-SVM) 的辨识方法, 并且首次应用于电容器介损角的辨识。在辨识过程中, 首先, 对电容器工作一段时间的信号进行采样和预处理, 预处理后的信号作为训练集训练 BP-SVM 模型; 然后, 使用训练好的 BP-SVM 模型对预处理后新的采样信号进行辨识, 判断介损角的变化量。此外, 给出了基于 BP-SVM 模型的介损角表示信号 $D_{\delta}(t)$ 的计算过程, 同时分析了在讨论域内信号 $D_{\delta}(t)$ 的幅值即是介损角 δ 。仿真分析结果表明, 提出的 BP 神经网络和 SVM 相结合的电容器介损角辨识方法比基于深度学习的辨识方法具有更高的辨识准确率, 并且频率变化对 BP-SVM 方法的辨识性能无明显影响。

关键词: 电容器; 介质损耗; 正向求解; 频率; 介损角; BP 神经网络; 支持向量机; 深度学习

中图分类号: TP18 **文献标志码:** A **文章编号:** 1673-4785(2019)01-0134-07

中文引用格式: 赵文清, 严海, 王晓辉. BP 神经网络和支持向量机相结合的电容器介损角辨识[J]. 智能系统学报, 2019, 14(1): 134-140.

英文引用格式: ZHAO Wenqing, YAN Hai, WANG Xiaohui. Capacitor dielectric loss angle identification based on a BP neural network and SVM[J]. CAAI transactions on intelligent systems, 2019, 14(1): 134-140.

Capacitor dielectric loss angle identification based on a BP neural network and SVM

ZHAO Wenqing, YAN Hai, WANG Xiaohui

(School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: The stability of the calculation method for dielectric capacitor loss is poor, and the frequency fluctuation has a great influence on the identification of dielectric loss angle. To overcome this limitation, an identification method in combination with a back propagating (BP) neural network and support vector machine (SVM), BP-SVM, is proposed. For the first time, BP-SVM is applied to the identification of capacitor dielectric loss angle. In the identification process, first, the signal of a capacitor working for a period of time was sampled and preprocessed, and these signals were used as a training set to train the BP-SVM model. Then, the trained BP-SVM model was used to preprocess the newly sampled signal. The sampled signal was identified to determine the amount of change in the dielectric loss angle. In addition, the calculation process of the dielectric loss angle representation signal, $D_{\delta}(t)$, based on the BP-SVM model, is given. At the same time, the amplitude of the signal, $D_{\delta}(t)$, in the discussion section, is the dielectric loss angle δ . The simulation analysis results showed that the proposed method for identifying the dielectric loss angle of capacitors combined with a BP neural network and SVM had a higher recognition accuracy than the deep learning-based identification method, and the frequency variation had no significant effect on the identification performance of BP-SVM.

Keywords: capacitors; dielectric loss; forward solution; frequency; dielectric loss angle; BP neural network; support vector machine; deep learning

收稿日期: 2018-05-23. 网络出版日期: 2018-09-29.

基金项目: 中央高校基本科研业务专项资金项目 (2014MS131).

通信作者: 赵文清. E-mail: jbwzq@126.com.

随着电网的不断发展, 电力设备的安全性、可靠性受到了越来越多的关注, 电力设备的损坏

大部分是由绝缘损坏所引起的。因此有效地将绝缘存在的缺陷检测出来对电网的安全运行具有重要意义^[1]。电容器在电力系统无功补偿中有着广泛的应用, 电力电容器的介质损耗因数是表征其质量的重要参数^[2]。目前, 电力电容器进行维护的方式主要有定期检修和在线监测 2 种^[3-7]。然而, 定期检修存在检修周期长、试验条件与运行状态不一致等问题, 无法反映出电力电容器的真实运行状态^[6]。在线监测的方式可以及时发现电容器的早期故障, 具有更好的监测效果。正向计算和解空间搜索是计算电力电容器介损角的 2 种方式。正向计算方法主要有谐波分析法^[8-11]、异频电源法^[12-14]、正交分解法^[14-16]和自由矢量法等^[17-19]。其中, 谐波分析法使用离散傅里叶变换对电容器的电流、电压信号进行谐波分析, 进而得到二者的基波, 然后求出介损角。BP 神经网络具有较好的非线性映射能力并且适用于处理大规模的数据。支持向量机模型结构简单, 可以在少量样本情况取得较好的分类效果, 并且模型不易过拟合。因此, 本文提出了 BP 神经网络和 SVM 相结合的方法 (BP-SVM 方法) 进行电力电容器介损角的在线辨识, 通过 BP 神经网络提取信号 $D_\delta(t)$ 特征, 将原本线性不可分的信号通过提取特征向量的方式趋向于线性可分, 同时通过提取特征向量的方式降低信号 $D_\delta(t)$ 的维度, 压缩训练样本规模, 然后使用模型结构更加简单的 SVM 进行介损角辨识。

1 介损角 $D_\delta(t)$ 信号的表示

在交流电压的作用下, 电容设备的等效电路和相量图如图 1 所示。其中, 介质等效电阻为 R , 介质等效电容为 C , 介质损耗角为 δ , 电压 U 和电流 I 的相位差为 θ 。通常情况下, 介损角 δ 的测量可以转换为计算绝缘介质损耗因数 $\tan \delta$ 的值。




图 1 电容设备的等效电路和相量图

Fig. 1 Capacitance equipment equivalent circuit and phasor diagram

本文将监测到的电压、电流的信号转换为可表示介损角 δ 信号 $D_\delta(t)$ 的方法:

$$U(t) = A_U \sin(\omega t + \varphi_U) \quad (1)$$

$$I(t) = A_I \sin(\omega t + \varphi_I) \quad (2)$$

式中: $U(t)$ 为电容器的工作电压; $I(t)$ 为电容器的工作电流; A_U 为电压幅值; ω 为角频率; φ_U 为电压的初始相位; A_I 为电流幅值; φ_I 为电流的初始相位。

在电流、电压同步采样的方式下, 可忽略电流、电压的幅值, 依据 $U(t)$ 和 $I(t)$ 的相位差计算介损角 δ 。采样信号的电流、电压幅值归一化为 1。此外, 将采样信号 $I(t)$ 移相 φ_I 使其初始相角为 0, 则 $U(t)$ 和 $I(t)$ 退化为无量纲的信号 $\tilde{U}(t)$ 和 $\tilde{I}(t)$ 。

$$\tilde{I}(t) = \sin(\omega t) \quad (3)$$

$$\tilde{U}(t) = \sin[\omega t + (\varphi_U + \varphi_I)] \quad (4)$$

将采样信号 $\tilde{U}(t)$ 沿着 x 轴前移 $\frac{\pi}{2}$ 可得 $\tilde{U}_s(t)$, 即

$$\tilde{U}_s(t) = \sin\left[\omega t + (\varphi_U + \varphi_I) - \frac{\pi}{2}\right] = \sin(\omega t - \delta) \quad (5)$$

介损角 δ 可由 $\tilde{U}_s(t)$ 和 $\tilde{I}(t)$ 的信号相位差求得。 $\tilde{U}_s(t)$ 和 $\tilde{I}(t)$ 在一个周期内的信号如图 1 所示。

定义信号 $D_\delta(t)$ 为

$$D_\delta(t) = \tilde{U}_s(t) - \tilde{I}(t) = -2\sin\left(\frac{\delta}{2}\right)\cos\left(\omega t - \frac{\pi}{2}\right) \quad (6)$$

由式 (6) 可以看出, 信号 $D_\delta(t)$ 与电容器电流和电容器电压的角频率有关。此外, 信号 $D_\delta(t)$ 的幅值与被测的介损角 δ 有关。

定义信号 $D_\delta(t)$ 幅值的绝对值为 A_δ , 则 $A_\delta = 2\sin(\delta/2)$, 设 $R(\delta)$ 为 A_δ 与 δ 的比值, 即

$$R(\delta) = \frac{A_\delta}{\delta} = \frac{2\sin(\delta/2)}{\delta} = \frac{\sin(\delta/2)}{\delta/2} \quad (7)$$

在 20 °C 时, 额定电压下的高压并联电容器的介损角 δ 值应在下列范围内: 纸膜复合介质的电容器 $\delta \leq 8 \times 10^{-4}$ rad; 在全膜介质的电容器中, 有放电电阻和内熔丝的 $\delta \leq 5 \times 10^{-4}$ rad; 无放电电阻和内熔丝的 $\delta \leq 3 \times 10^{-4}$ rad。此外, 由式 (7) 可以计算得出, 当 $0 < \delta < 8 \times 10^{-4}$ rad 时, $R(\delta)$ 的值在 0.999 999 9~1。因此, 在讨论域内可将 A_δ 的值等效于介损角 δ 的值, 进而可将介损角 δ 的测量从计算电容器电流、电压的相位差转换为信号 $D_\delta(t)$ 的幅值和形状的比较。

2 BP-SVM 的 $D_\delta(t)$ 信号辨识方法

基于 BP-SVM 方法的介损角 δ 辨识过程是一种解空间搜索过程。辨识过程的核心思想是: 首先, 使用每只电容器一段时间内的 $D_\delta(t)$ 信号训练相应电容器的 BP 神经网络模型; 其次, 使用该模型提取 $D_\delta(t)$ 信号的特征, 形成新的训练样本; 然后, 采用新的训练样本和对应的标签训练 SVM 模型; 最后, 利用 BP 神经网络模型和 SVM 模型

辨识新监测到的 $D_\delta(t)$ 信号是否为期望的 δ , 或是漂移了一定量的 δ_i , 该辨识过程速度较快, 可用于

在线监测。本文辨识介损角 δ 的模型结构如图2所示。




图2 BP-SVM模型

Fig. 2 BP-SVM model

图2中左侧虚线框是一个隐含层为3层的BP神经网络模型结构, 输入为 $D_\delta(t)$ 信号集, 输入层节点个数为采样长度1600, 隐含层神经元的个数分别为200、300、200, 输出节点个数为11, 将介损角 δ 分为11类, 使用交叉熵函数作为BP神经网络训练时的损失函数。图2中右侧虚线框是本文的SVM模型, 由于SVM是二分类模型, 而本文需要将介损角 δ 分为11类, 因此本文采用SVM多分类模式中的一对一模式, 训练55个SVM模型用以对介损角 δ 进行分类。此外, 本文使用BP神经网络中隐含层第3层提取的 $D_\delta(t)$ 信号特征(维度为200)和对应的 $D_\delta(t)$ 信号标签训练本文的SVM模型。

介损角 δ 的表示和辨识过程:

1) 假设目标电容器的介损角 δ 为 3×10^{-4} rad, 记作 δ_0 , 使用式(6)计算该电容器正常状态下的介损角表示信号 $D_{\delta_0}(t)$, t 为采样间隔。

2) 当 δ_0 每次增加 1×10^{-5} rad 时, 根据式(6)计算对应 $D_{\delta_i}(t)$ 的值, $i \in \{1, 2, \dots, 10\}$, 其中, 介损角 δ_0 的 $D_\delta(t)$ 值记作 $D_{\delta_0}(t)$ 。

3) 分别对 $D_{\delta_0}(t) \sim D_{\delta_{10}}(t)$ 加入一定强度的白噪声信号形成新的训练样本 TrainSet, 使用新的训练样本训练BP神经网络, 提取特征后训练SVM模型。

4) 使用训练好的BP神经网络模型和SVM模型辨识被测信号属于哪一类 $D_{\delta_i}(t)$, 从而可以判断出当前被测信号的介损角为 $\delta_i = \delta_0 + 10^{-5}i$ 。

为了验证BP神经网络与SVM相结合的方法的有效性, 本文进行了仿真实验分析, 仿真过程为:

1) 生成介损角 δ_i 为 $\{3 \times 10^{-4}, 3.1 \times 10^{-4}, \dots, 3.9 \times 10^{-4}, 4 \times 10^{-4}\}$ rad, 频率分别为 $\{49.50, 49.75, 50.00, 50.25, 50.50\}$ Hz 条件下的介损角信号集 $D_{\delta_i}(t)$ 。

2) 对 $D_{\delta_i}(t)$ 按下述条件增加谐波: ①谐波次数

为3、5、7; ②各次谐波的初始相角与基波相角差分别为 $-\frac{\pi}{3}$ 、 π 、 $\frac{\pi}{3}$; ③各次谐波的幅值为基波幅值的0%、5%、10%。

3) 所有的训练样本加入 $\{20, 25, 30, 35\}$ dB 的4个等级的白噪声, 每个等级的白噪声等级生成10个加噪信号形成新的训练集 TrainSet。

4) 在构建训练集方法的基础上, 按照以下3个条件构建测试集 TestSet:

①对各次谐波相角增加 $-\frac{\pi}{6} \sim \frac{\pi}{6}$ 的随机漂移;

②介损角增加 $-0.5 \times 10^{-6} \sim 5 \times 10^{-6}$ rad 的随机漂移;

③频率增加 $\{-0.5, -0.25, 0, 0.25, 0.5\}$ Hz 的随机漂移;

④所有的测试样本加入 $\{20, 25, 30, 35\}$ dB 的4个等级的白噪声, 每个噪声等级生成5个加噪信号。

5) 用构建好的训练样本集 TrainSet 训练本文的BP神经网络模型, 图3为BP神经网络训练过程中的损失趋势。




图3 BP神经网络的损失趋势

Fig. 3 BP neural network loss trend

6) 基于5)中训练好的BP神经网络, 将训练样本集 TrainSet 重新输入BP神经网络中, 提取BP神经网络隐含层第3层的特征向量, 将该特征

向量和对应的类别标签组成新的训练样本 SVM-TrainSet, 使用 SVMTrainSet 训练 SVM 模型。

7) 使用 TestSet 检验本文提出的 BP-SVM 方法在不同 δ_i 下信号 $D_{\delta_i}(t)$ 的辨识能力, 检验过程分为: ①将 TestSet 输入训练好的 BP 神经网络中, 提取隐含层第 3 层的特征向量; ②将①中提取的特征向量作为 SVM 的输入, 使用训练好的 SVM 对提取的特征向量进行分类, 对介损角进行辨识。

3 实验结果与分析

基于 BP-SVM 方法的电容器介损角辨识过程本质是信号分类的问题。首先, 通过 BP 神经网络提取训练样本 TrainSet₁ 介损角的特征向量; 然后, 将提取的特征向量作为新的训练样本 TrainSet₂ 训练 SVM, 使用 SVM 辨识每个样本对应的类别。其中, 训练样本 TrainSet₁ 中均混入了不同程度的谐波、频率偏移、白噪声。本文使用的 BP 神经网络结构为 (1 600, 200, 300, 200, 11), 隐含层为 (200, 300, 200), 是一种对称结构, 学习率为 0.000 1, 激活函数为 ReLU, 训练 800 轮, 隐含层第 3 层与输出层的神经元丢失 (dropout) 概率为 0.5, 权重 w 值的初始化服从均值为 0、标准差为 0.1 的高斯分布, 偏置 b 值均初始化为 0.1。SVM 的核函数为“rbf”, 参数 C 为 50, 参数 γ 为 0.005。本文共收集了 1 008 300 条数据, 选用其中的 220 000 条数据组成训练样本 TrainSet1 训练 BP 神经网络, 使用训练完成后的 BP 神经网络提取 TrainSet1 的特征向量 (220 000 条) 后, 随机选取其中的 88 000 条特征向量训练 SVM, 形成 BP-SVM 模型。在剩余的 788 300 条数据中分别选取 220 000 条数据、440 000 条数据和 660 000 条数据组成测试样本集 TestSet₁、TestSet₂ 和 TestSet₃。

3.1 介损角辨识结果

表 1 为基于 BP-SVM 方法和 BP 神经网络的

方法在 TestSet₁、TestSet₂、TestSet₃ 测试样本下的辨识结果。由表 1 可以看出, 基于本文提出的 BP-SVM 方法在不同的测试样本下, 电容器介损角的辨识准确率均高于 BP 神经网络。此外, 随着测试样本数量的增加, 基于 BP-SVM 的方法依旧保持了较高的辨识准确率, 当测试样本数量是训练样本 3 倍时, BP-SVM 方法依旧取得了 93.40% 的辨识准确率。

表 1 BP-SVM 和 BP 神经网络在测试集上的实验结果

Table 1 BP-SVM and BP neural network experiment results on test sets %

方法	数据集		
	TestSet ₁	TestSet ₂	TestSet ₃
BP-SVM	94.03	93.65	93.40
BP	90.55	90.02	89.82

表 2 为 BP-SVM 方法和基于深度学习 (DL) 方法在 TestSet₁ 上的介损角的具体分类结果。由表 2 可以看出, 本文提出的 BP-SVM 方法比 DL 方法的辨识准确率高了 2.81%, 达到了 94.02%。当介损角为 3.2×10^{-4} rad 和 4×10^{-4} rad 时, DL 方法有较高的辨识准确率, 但是 BP-SVM 方法的辨识准确率也达到了 94% 以上。当介损角为其他值时, BP-SVM 方法辨识准确率明显高于 DL 方法, 并且辨识的稳定性也优于 DL 方法。其中, 每一类的辨识准确率均在 92.22% 以上, DL 方法在介损角 $3.5 \times 10^{-4} \sim 3.7 \times 10^{-4}$ rad 时, 辨识准确率均低于 90%, 甚至当介损角为 3.9×10^{-4} rad 时, DL 方法的辨识准确率降低到了 81.96%, 整体的辨识准确率波动幅度较大。表 3 为 BP-SVM 方法在 TestSet₁ 测试样本下的具体辨识结果, 由表 3 可以看出, 在辨识错误的介损角样本中, BP-SVM 方法易将介损角辨识为较小的值。

表 2 BP-SVM 和深度学习方法在测试集上的实验结果

Table 2 BP-SVM and deep learning method experiment results on test sets 10^{-4} rad

方法	δ_i											平均值
	3.0	3.1	3.2	3.3	3.4	3.5	3.6	3.7	3.8	3.9	4.0	
BP-SVM	0.984 5	0.933 5	0.941 9	0.947 0	0.922 2	0.936 1	0.931 6	0.927 6	0.936 3	0.934 1	0.947 8	0.940 2
DL ^[2]	0.977 1	0.902 5	0.943 6	0.923 5	0.925 1	0.862 4	0.887 8	0.892 2	0.920 0	0.819 6	0.979 5	0.912 1

图 4 为基于 BP-SVM 的方法在不同测试样本下的辨识结果和基于 BP 神经网络的方法在测试样本 TestSet₁ 下的辨识结果, 从图 4 中可以看出, 当介损角增加 0% rad 和 0.009% rad 时, BP 神

经网络的辨识结果要优于本文所提出的 BP-SVM 的方法, 但是当介损角增加 $1 \times 10^{-5} \sim 8 \times 10^{-5}$ rad 和 1×10^{-4} rad 时, BP-SVM 的方法辨识效果要明显优于 BP 神经网络。此外, 相较于 BP 神经网络

的辨识效果, BP-SVM 方法具有更高的辨识稳定性, 介损角的变化对于分类的准确率无明显

影响, 每一类的辨识准确率均保持在 91.65% 以上。

表 3 BP-SVM 在 TestSet₁ 上的实验结果
Table 3 BP-SVM experiment results on Test Set

$\delta_i/\%$	3.0	3.1	3.2	3.3	3.4	3.5	3.6	3.7	3.8	3.9	4.0	错误率	错误量
3.0×10^{-2}	19 691	309	0	0	0	0	0	0	0	0	0	0.015 5	309
3.1×10^{-2}	866	18 671	463	0	0	0	0	0	0	0	0	0.066 5	1 329
3.2×10^{-2}	0	676	18 839	485	0	0	0	0	0	0	0	0.058 1	1 161
3.3×10^{-2}	0	0	747	18 940	313	0	0	0	0	0	0	0.053 0	1 060
3.4×10^{-2}	0	0	0	1 025	18 444	531	0	0	0	0	0	0.077 8	1 556
3.5×10^{-2}	0	0	0	0	780	18 722	498	0	0	0	0	0.063 9	1 278
3.6×10^{-2}	0	0	0	0	0	786	18 633	581	0	0	0	0.068 4	1 367
3.7×10^{-2}	0	0	0	0	0	0	772	18 553	675	0	0	0.072 4	1 447
3.8×10^{-2}	0	0	0	0	0	0	0	665	18 726	609	0	0.063 7	1 274
3.9×10^{-2}	0	0	0	0	0	0	0	0	810	18 682	508	0.065 9	1 318
4.0×10^{-2}	0	0	0	0	0	0	0	0	0	1 043	18 957	0.052 2	1 043
合计	20 557	19 656	20 049	20 450	20 278	20 039	19 903	19 799	20 211	20 334	19 465	0.059 8	13 134




图 4 不同模型和不同测试样本集的测试结果

Fig. 4 Test results for different models and test sets

图 5 为基于本文提出的 BP-SVM 方法和 BP 神经网络的方法在测试样本 TestSet₁ 下的辨识准确率。此外, 图 5 也绘制出了 BP-SVM 方法和 BP 神经网络的方法在没有引入 dropout 的情况下的辨识准确率。其中, 测试样本 TestSet₁ 的辨识开始于 BP 神经网络训练 200 轮之后。由图 5 可以看出, 在没有引入 dropout 的情况下, BP-SVM 方法和 BP 神经网络的方法具有相近的辨识准确率, 并且高于引入了 dropout 的 BP 神经网络的辨识结果。但是, 这 3 个方法的辨识结果均低于本文提出的引入了 dropout 的 BP-SVM 方法。此外, 由图 5 的波形可以看出, 在引入了 dropout 的情况下, BP-SVM 方法和 BP 神经网络方法相较于没有引入 dropout 的情况下, 模型的辨识效果具有更好的鲁棒性, 辨识准确率的波动幅度较小。同时, 本文提出的 BP-SVM 方法相较于单一的 BP 神经

网络的方法对于电容器介损角的辨识具有更高的准确率, 平均辨识准确率提高了 3.48%。




图 5 有无 dropout 的测试结果

Fig. 5 Test results with or without dropout

3.2 白噪声和频率漂移对辨识结果的影响

本文按照不同的噪声等级对辨识介损角的错误样本进行了统计, 如图 6 所示, 在 TestSet₁、TestSet₂、TestSet₃ 样本下每一等级噪声的测试样本数量分别为 55 000、110 000、165 000。在 3 个不同的测试样本集下, 当白噪声为 20 dB 时, 对 BP-SVM 方法的辨识结果有较大的影响, 其辨识准确率均低于 90%, 但是当白噪声为 25、30、35 dB 时, 本文提出的 BP-SVM 的方法可以较好地辨识出介损角的变化。

此外, 本文统计了在不同频率漂移的情况下 BP-SVM 辨识的错误样本, 如图 7 所示, 在 TestSet₁、TestSet₂、TestSet₃ 样本下每一等级噪声的测试样本数量分别为 44 000、88 000、132 000。相较

于文献[2]提出的辨识方法,当频率减小或者增加0.25 Hz时,基于深度学习的方法对介损角的辨识结果有较大的影响。由图7可以看出,本文提出的BP-SVM方法在不同的频率漂移的情况下,依旧具有较高的辨识准确率,并且频率变化对于辨识效果没有明显影响。




图6 不同等级噪声下的测试结果

Fig. 6 Test results at different levels of noise




图7 不同频率下的测试结果

Fig. 7 Test results at different frequencies

4 结束语

在实际监测中,谐波分析法方法在计算介损角时存在稳定性较差的问题。虽然基于深度学习的方法对于电容器介损角辨识有较好的稳定性,但是频率的波动对其辨识效果有着较大的影响,同时该方法的辨识准确率也有待提高。因此,本文提出了BP神经网络和SVM相结合(BP-SVM)的方法用以辨识电容器的介损角。实验表明:

1) 本文所提出的BP-SVM方法具有更高的辨识准确率,并且在不同的测试样本集下均保持了较高的辨识准确率,模型具有更好的泛化能力。

2) 本文所提出的BP-SVM方法比基于深度学习的方法具有更强的抗频率变化能力,频率的变化对于本文算法的性能无明显影响。

3) 本文所提出的模型在较少的训练样本集下取得了较高的辨识准确率,当测试样本集3倍于训练样本集时,本文方法依旧将电容器介损角的辨识准确率保持在93.40%。

参考文献:

[1] 李天云,袁明哲,蔡国伟,等. 基于随机子空间和最小二

乘法的介质损耗角检测方法[J]. 高电压技术, 2011, 37(4): 828–833.

LI Tianyun, YUAN Mingzhe, CAI Guowei, et al. Measurement algorithm of dielectric loss angle based on SSI-LS[J]. High voltage engineering, 2011, 37(4): 828–833.

[2] 王晓辉,朱永利,王艳,等. 基于深度学习的电容器介损角在线辨识[J]. 电工技术学报, 2017, 32(15): 145–152.

WANG Xiaohui, ZHU Yongli, WANG Yan, et al. Online Identification method of power capacitor dielectric loss angle based on deep learning[J]. Transactions of China electrotechnical society, 2017, 32(15): 145–152.

[3] 董爽,李天云,王永,等. 在线检测介质损耗角的矩阵束方法[J]. 电工技术学报, 2015, 30(18): 229–236.

DONG Shuang, LI Tianyun, WANG Yong, et al. An On-line detection method of dielectric loss angle based on matrix pencil algorithm[J]. Transactions of China electrotechnical society, 2015, 30(18): 229–236.

[4] WANG P, RGHUVEER M R, MCDERMID W, et al. A digital technique for the on-line measurement of dissipation factor and capacitance[J]. IEEE transactions on dielectrics and electrical insulation, 2001, 8(2): 228–232.

[5] 尚勇,杨敏中,王晓蓉,等. 谐波分析法介质损耗因数测量的误差分析[J]. 电工技术学报, 2002, 17(3): 67–71, 34. SHANG Yong, YANG Minzhong, WANG Xiaorong, et al. Error analysis for the dielectric loss factor measurement based on harmonic analysis[J]. Transactions of China electrotechnical society, 2002, 17(3): 67–71, 34.

[6] 刘伟,黄新波,章云. 电容型高压设备介损在线监测系统的现场采集单元设计[J]. 计算机测量与控制, 2010, 18(1): 233–236, 242.

LIU Wei, HUANG Xinbo, ZHANG Yun. Design of field sampling unit of an on-line monitoring system of dielectric loss in capacitive high-voltage apparatus[J]. Computer measurement and control, 2010, 18(1): 233–236, 242.

[7] 陈晓宇,郑建勇,梅军. 基于LC振荡频率变化量的电容器组早期故障在线智能预警方法及其实现[J]. 电力系统保护与控制, 2015, 43(5): 144–149.

CHEN Xiaoyu, ZHENG Jianyong, MEI Jun. Power capacitor banks failure warning method based online intelligence LC oscillation frequency variation and its implementation[J]. Power system protection and control, 2015, 43(5): 144–149.

[8] 袁飞,杨震男,卢毅. 一种基于相对比较法测量容性设备介质损耗的滤波算法[J]. 电力系统保护与控制, 2015, 43(19): 95–100.

YUAN Fei, YANG Zhennan, LU Yi. A filtering algorithm for measuring capacitive device dielectric loss based on relative comparison method[J]. Power system protection and control, 2015, 43(19): 95–100.

- [9] 王楠, 律方成, 梁英, 等. 基于高精度 DFT 的介损数字测量方法[J]. 高电压技术, 2003, 29(4): 3-5, 8.
WANG Nan, LV Fangcheng, LIANG Ying, et al. Digital measurement of dielectric loss based on high accuracy DFT algorithm[J]. High voltage engineering, 2003, 29(4): 3-5, 8.
- [10] 王微乐, 李福祺, 谈克雄. 测量介质损耗角的高阶正弦拟合算法[J]. 清华大学学报(自然科学版), 2001, 41(9): 5-8.
WANG Weile, LI Fuqi, TAN Kexiong. Higher-order sine fitting algorithm for dielectric loss measurement[J]. Journal of Tsinghua University (science and technology), 2001, 41(9): 5-8.
- [11] 冯小华, 张承学. 修正的谐波分析法可提高介损在线测量准确度[J]. 高电压技术, 2004, 30(8): 36-37.
FENG Xiaohua, ZHANG Chengxue. Modified harmonics analysis approach for increasing precision in on-line measuring $\tan \delta$ [J]. High voltage engineering, 2004, 30(8): 36-37.
- [12] LI Q, ZHAO T, SIEW W H. Definition and digital algorithms of dielectric loss factor for condition monitoring of high-voltage power equipment with harmonics emphasis[J]. IEE proceedings-generation, transmission and distribution, 2005, 152(3): 309-312.
- [13] 张忠蕾, 李庆民, 陈鹏. 谐波条件下高压电气设备介损损耗因数的定义和数字化算法[J]. 高压电器, 2004, 40(5): 327-329, 332.
ZHANG Zhonglei, LI Qingmin, CHEN Peng. Definition and digital algorithms for dielectric loss factor of high voltage power apparatus under harmonics condition[J]. High voltage apparatus, 2004, 40(5): 327-329, 332.
- [14] 张介秋, 梁昌洪, 韩峰岩, 等. 介质损耗因数的卷积窗加权算法[J]. 电工技术学报, 2005, 20(3): 100-104.
ZHANG Jieqiu, LIANG Changhong, HAN Fengyan, et al. Convolution window weighted algorithm for dielectric loss Factor[J]. Transactions of China electrotechnical society, 2005, 20(3): 100-104.
- [15] 徐志钮, 律方成, 赵丽娟. 基于加汉宁窗插值的谐波分析法用于介损角测量的分析[J]. 电力系统自动化, 2006, 30(2): 81-85.
XU Zhiniu, LÜ Fangcheng, ZHAO Lijuan, et al. Analysis of dielectric loss angle measurement by Hanning windowing interpolation algorithm based on FFT[J]. Automation of electric power systems, 2006, 30(2): 81-85.
- [16] 段大鹏, 江秀臣, 孙才新, 等. 基于正交分解的介质损耗因数数字测量算法[J]. 中国电机工程学报, 2008, 28(7): 127-133.
DUAN Dapeng, JIANG Xiuchen, SUN Caixin, et al. A novel algorithm of dielectric loss measurement based on orthogonal decomposition[J]. Proceedings of the CSEE, 2008, 28(7): 127-133.
- [17] 陈楷, 胡志坚, 王卉, 等. 介损角的非同步采样算法及其应用[J]. 电网技术, 2004, 28(18): 58-61.
CHEN Kai, HU Zhijian, WANG Hui, et al. Algorithm and application of dielectric loss angle based on asynchronous sampling[J]. Power system technology, 2004, 28(18): 58-61.
- [18] WANG Kang, TENG Zhaosheng, WEN He, et al. Fast measurement of dielectric loss angle with time-domain quasi-synchronous algorithm[J]. IEEE transactions on instrumentation and measurement, 2015, 64(4): 935-942.
- [19] 王永, 滕召胜, 李建闽, 等. 基于采样序列重构的高精度介损角测量方法[J/OL]. 电工技术学报, [2018-04-24]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.171699>.
WANG Yong, TENG Zhaosheng, LI Jianmin, et al. High accuracy dielectric loss angle measurement method based on sampling sequence reconstruction[J/OL]. Transactions of China electrotechnical society, [2018-04-24]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.171699>.

作者简介:



赵文清, 女, 1973 年生, 教授, 博士, 主要研究方向为人工智能与数据挖掘。发表学术论文 50 余篇, 被 SCI、EI 检索 30 余篇。



严海, 男, 1992 年生, 硕士研究生, 主要研究方向为机器学习和深度学习目标检测。



王晓辉, 男, 1981 年生, 博士, 主要研究方向为电力系统自动化和深度学习。