

基于改进 Hilbert-Huang 变换和支持向量机的高压断路器触头超程状态识别

杨秋玉¹, 阮江军¹, 黄道春¹, 庄志坚²

(1. 武汉大学 电气工程学院, 湖北 武汉 430072; 2. ABB(中国)有限公司中压产品技术中心, 福建 厦门 361006)

摘要:引入集合经验模态分解(EEMD)对 Hilbert-Huang 变换(HHT)方法进行改进,并将改进的 HHT 方法结合支持向量机(SVM)应用于高压断路器振动信号特征提取和触头超程状态识别中。采用 EEMD 提取反映振动信号局部特性的本征模态函数(IMF)分量,并计算 IMF 分量的 Hilbert 边际谱能量值,由此构造高压断路器触头超程状态特征量,利用得到的特征向量对 SVM 进行训练,实现高压断路器触头超程状态的自动识别。试验提取了高压断路器在不同触头超程下的振动信号并进行分析,结果表明所提方法能够有效识别高压断路器触头超程状态。

关键词:高压断路器;振动信号;触头超程;Hilbert-Huang 变换;支持向量机;状态识别

中图分类号:TM 561

文献标识码:A

DOI:10.16081/j.issn.1006-6047.2019.01.029

0 引言

高压断路器是电力系统中起保护和控制作用的重要电力设备,其运行状态与电力系统的稳定息息相关,因此,对高压断路器进行故障诊断,提前发现潜在故障,降低高压断路器故障率,对于保障电力系统的稳定和安全运行具有重要的意义^[1]。在高压断路器的机械特性参数中,触头超程(也称为触头超行程,指高压断路器在合闸过程中,动、静触头接触瞬间到合闸到底之间触头弹簧的压缩距离)是非常关键的特性参数:触头超程太小会影响高压断路器的开断能力和动热稳定性,同时合闸弹跳严重;触头超程过大则会增加操动机构的合闸功,或导致合闸极不可靠等问题。工程实践及试验研究表明,高压断路器触头超程会随着操作次数的增多及开断电流的增大而逐渐变小,且操作越频繁、开断电流越大,触头超程缩短得越快。

目前,对高压断路器触头超程的监测大多为离线监测,即在高压断路器停运检修期间,通过测试高压断路器绝缘拉杆行程曲线,采用一定的算法求取触头超程。这种间接求取触头超程的方法,受采集系统(如采集系统的稳定性、抗干扰性等)及求取算法(如触头刚接触点的确定等)的影响非常大。为此,本文提出基于振动信号的高压断路器触头超程状态识别,试图通过采用适用于高压断路器振动特性的振动信号处理方法,提取反映高压断路器触头超程状态的特征量,从而实现高压断路器触头超程状态的识别。

振动信号的处理方法有很多,包括幅值域分析法^[2]、傅里叶变换^[3]和相关分析^[4]等传统方法,以及 Wigner-Ville 分布^[5]、谱分析^[6]、小波分析^[7-8]、盲源分离^[9-10]、希尔伯特-黄变换^[11-12] HHT (Hilbert-Huang Transform) 和高阶统计量分析^[13]等现代方法。幅值域分析法是描述幅值随时间变化的时域分析方法,傅里叶变换和相关分析都是基于时域统计分析,一般用于处理平稳信号;Wigner-Ville 分布、谱分析、小波分析、盲源分离、HHT 和高阶统计量分析对非平稳信号具有很好的效果。其中,HHT 是一种根据信号的局部时变特征进行自适应时频分析的方法,具有很高的时频分辨率和时频聚集性,特别适用于对非线性、非平稳振动信号的分析。HHT 主要内容包含经验模态分解 EMD (Empirical Mode Decomposition) 和 Hilbert 谱分析 HSA (Hilbert Spectrum Analysis) 两部分。然而,EMD 在分解过程中易产生端点效应、模态混叠和本征模态函数 IMF (Intrinsic Mode Function) 的筛分迭代停止的标准等问题^[14-15]。而集合经验模态分解^[16-17] EEMD (Ensemble Empirical Mode Decomposition) 通过在 EMD 过程中加入不同强度的高斯白噪声,并反复进行多次 EMD 等处理,在很大程度上抑制了模态混叠,从而大幅提高了信号分解的准确性。

由于能量是振动信号的一个重要特征,能够反映机械运动的状态,机械状态发生变化时,振动信号各频率成分也会发生变化,而同一频带内信号能量的变化会更加明显^[18-19]。为此,本文将改进的 HHT 与 IMF 分量的 Hilbert 边际谱能量相结合,提取反映高压断路器在不同触头超程状态下的振动信号特征量,并将这些振动信号特征向量输入支持向量机^[20-22] SVM (Support Vector Machine) 实现高压断路器触头超程状态的识别。

收稿日期:2018-01-12; **修回日期:**2018-11-29

基金项目:国家重点研发计划资助项目(2017YFB0902400)
Project supported by the National Key Research and Development Program (2017YFB0902400)

本文首次提出采用振动信号实现高压断路器触头超程状态识别,揭示了高压断路器振动信号与触头超程状态之间的关系,通过提取高压断路器触头超程变化过程中的振动信号,采用 EEMD 得到反映振动信号局部特性的 IMF 分量,计算前 8 阶 IMF 分量的 Hilbert 边际谱能量值,构造反映触头超程变化的振动信号特征量,最后结合 SVM 实现高压断路器触头超程状态的自动识别。本文方法为高压断路器触头超程状态的监测与诊断提供了一种全新的思路,具有一定的工程实用价值。

1 改进的 HHT

改进 HHT 处理高压断路器振动信号的基本过程为:首先利用 EEMD 将振动信号分解为若干个 IMF,这些 IMF 是满足一定条件的分量;然后,对每个 IMF 进行 Hilbert 变换,得到相应的 Hilbert 谱,Hilbert 谱精确地描述了振动信号的幅值在整个频段上随时间和频率的变化规律(即将每个 IMF 在联合的时频域中表示);最后,分别各对 IMF 的 Hilbert 谱进行积分求取 Hilbert 边际谱,Hilbert 边际谱反映了单位频率内的幅值/能量分布,代表整个数据段幅值概率分布的累加。

1.1 EEMD 原理

HHT 在处理非线性非平稳性信号方面有着良好的表现,然而,作为 HHT 核心部分的 EMD 依然存在一些问题,其中模态混叠问题尤为突出。EEMD 将有限幅值的高斯白噪声加入待分析信号中,弥补信号中断所缺失的尺度,从而消除模态混叠效应。EEMD 算法流程可参考附录 A 中的图 A1,具体步骤及原理如下。

a. 在原始信号 $x(t)$ 中多次添加均值为 0、标准差为 ε (ε 为常数)的高斯白噪声 $n_i(t)$,即:

$$x_i(t) = x(t) + n_i(t) \quad (1)$$

其中, $x_i(t)$ 为第 i 次加入高斯白噪声的信号。

b. 对各 $x_i(t)$ 分别进行 EMD,得到若干个 IMF 分量 $c_{ij}(t)$ 和 1 个余项 $r_i(t)$ 。

c. 重复步骤 **a** 和步骤 **b** N 次,对分解出的 IMF 分量进行平均运算,消除加入的高斯白噪声对 IMF 的影响,即:

$$c_j(t) = \frac{1}{N} \sum_{i=1}^N c_{ij}(t) \quad j = 1, 2, \dots, M \quad (2)$$

其中, $c_{ij}(t)$ 为第 i 次加入高斯白噪声后,分解得到的第 j 个 IMF 分量; $c_j(t)$ 为从高频到低频的 IMF 分量。

加入高斯白噪声的次数 N 越大,对应的平均运算下的 IMF 分量高斯白噪声均值将越趋近于 0,则 EEMD 结果可以表示为:

$$x(t) = \sum_j c_j(t) + r(t) \quad (3)$$

其中, $r(t)$ 为余项,代表信号的总体变化趋势。

1.2 Hilbert 边际谱能量

对每个 IMF 分量 $c_j(t)$ 进行 Hilbert 变换:

$$\hat{c}_j(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{c_j(\tau)}{t-\tau} d\tau \quad (4)$$

构造解析函数 $z_j(t)$:

$$z_j(t) = c_j(t) + k\hat{c}_j(t) = A_j(t) e^{k\theta_j(t)} \quad (5)$$

$$A_j(t) = \sqrt{c_j^2(t) + \hat{c}_j^2(t)} \quad (6)$$

$$\theta_j(t) = \arctan \frac{\hat{c}_j(t)}{c_j(t)} \quad (7)$$

其中, $A_j(t)$ 为瞬时幅值; $\theta_j(t)$ 为瞬时相位;

由于瞬时频率 $\omega_j(t)$ 为:

$$\omega_j(t) = \frac{d\theta_j(t)}{dt} \quad (8)$$

因此可以得到:

$$x(t) = \text{RP} \left(\sum_{j=1}^n A_j(t) e^{k\theta_j(t)} \right) \quad (9)$$

其中, RP 表示取实部运算。

将式(8)代入式(9)可得 Hilbert 谱,记为:

$$H(\omega, t) = \text{RP} \left(\sum_{j=1}^n A_j(t) e^{k\int \omega_j(t) dt} \right) \quad (10)$$

Hilbert 边际谱 $h(\omega)$ 定义为:

$$h(\omega) = \int_0^t H(\omega, t) dt \quad (11)$$

Hilbert 边际谱能量 $E(\omega)$ 定义为:

$$E(\omega) = \int_{\omega_1}^{\omega_2} (h(\omega))^2 d\omega \quad (12)$$

其中, ω_1, ω_2 为 Hilbert 边际谱 $h(\omega)$ 的频率区间。

由式(12)可知, Hilbert 边际谱能量对 Hilbert 边际谱进行了平方处理,而 Hilbert 边际谱反映的是信号的实际频率成分,因此, Hilbert 边际谱能量放大了信号中的实际频率成分(在高压断路器振动信号中,表现为高频冲击信号),而噪声的影响则被进一步削弱。

2 SVM 方法的应用

SVM 算法主要从数据的空间分布来构造最优分类面(二维空间为分类线), SVM 的核心思想是将样本从原始不可分的空间映射到高维可分空间中,在高维空间中建立一个最大间隔的超平面,通过使该超平面与最近的样本之间的间隔最大,实现分类误差最小。

假设给定的训练样本集为 $\{(\mathbf{x}_i, y_i) \mid i = 1, 2, \dots, l\}$, 其中, l 为训练样本数, $\mathbf{x}_i \in \mathbf{V}^d$ 为 d 维特征向量($\mathbf{V}$ 表示特征空间), $y_i \in \{-1, +1\}$ 表示样本 $\mathbf{x}_i$ 的类别(+1 为正类, -1 为负类),根据分类间隔最大化原

则,构造最优化问题如式(13)所示。

$$\begin{aligned} \min_{\mathbf{w}, b} \quad & \frac{\|\mathbf{w}\|^2}{2} + C \sum_{i=1}^l \xi_i \\ \text{s.t.} \quad & y_i[(\mathbf{w}\mathbf{x}_i) + b] \geq 1 - \xi_i \quad i=1, 2, \dots, l \end{aligned} \quad (13)$$

其中, $\mathbf{w}$ 为最优分类面的法向量(权值); C 为误差项 ξ_i 的惩罚参数, $C > 0$; ξ_i 为样本点被错分而产生的误差(松弛变量), $\xi_i \geq 0$; b 为截距(偏差)。

利用 Lagrange 函数将上述有约束的非线性规划问题转化为对偶问题,求解出相应的 Lagrange 参数,最终得到分类决策函数为:

$$f(x) = \text{sgn}\left(\sum_{i=1}^l \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b^*\right) \quad (14)$$

其中, α_i 为 Lagrange 乘子; $K(\mathbf{x}_i, \mathbf{x})$ 为满足 Mercer 条件的核函数; b^* 为截距。

要构造出一个性能良好的 SVM, 核函数的选择是关键也是最重要的一步。常用的核函数有线性核函数、多项式核函数、径向基函数 RBF(Radial Basis Function) 和 Sigmoid 核函数。首先,就分类效果而言,非线性核函数优于线性核函数,故本文首先考虑采用非线性核函数;其次,与多项式核函数相比, RBF 需要确定的参数更少(gamma 函数 g 和惩罚系数 c),而核函数参数的数量将直接影响函数的复杂程度及分类效果;最后,核函数在数学上必须满足 Mercer 条件,而源自神经网络的 Sigmoid 核函数只有在某些特定条件(参数 a 和 r 满足一定的条件)下,才满足对称、半正定的核函数条件,故 Sigmoid 核函数在实际应用中受到了限制。综上所述,本文采用 RBF,如式(15)所示。

$$K(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma^2}\right) \quad (15)$$

3 振动信号的有效特征提取

为了能够真实地反映现场运行的高压断路器的实际工作状态,将高压断路器置于与之配套的开关柜内,并设置相关参数,使高压断路器“置身于实际工作状态”,搭建的振动信号数据采集平台见附录 A 中的图 A2(a)。经反复测试验证,将压阻式加速度传感器安装于高压断路器操动机构上方并靠近灭弧室处,可同时很好地反映灭弧室触头与操动机构的振动特性,具体参见附录 A 中的图 A2(b)。压阻式加速度传感器的主要技术参数为:量程 $\pm 6\,000\text{ g}$,灵敏度 0.08 mV/g ,响应频率 $0 \sim 5\,000\text{ Hz}$,谐振频率 $26\,000\text{ Hz}$ 。

对试验采集的高压断路器正常状态下的典型合闸、分闸振动信号进行去噪、去趋势项处理,结果分别如图 1、2 所示。

以正常合闸振动信号为例,对其进行 EEMD,得




图 1 经过处理后的正常合闸振动信号

Fig.1 Normal closing vibration signal after processing




图 2 经过处理后的正常分闸振动信号

Fig.2 Normal opening vibration signal after processing

到一系列具有不同特征尺度的 IMF 分量,如图 3 所示,不同特征尺度的 IMF 代表着原始信号中的不同频率段。




图 3 正常合闸振动信号 EEMD 结果

Fig.3 EEMD results of closing vibration signal

由分解得到的 IMF 分量可知:前几组 IMF 分量幅值较大,随着分解的进行,波形趋近平缓,幅值也越来越小。分别计算各 IMF 分量与原始振动信号的相关系数 γ_c ,结果如表 1 所示。

表 1 IMF 分量与原始振动信号的相关系数

Table 1 Correlation coefficient between IMF and original vibration signal

IMF	γ_c	IMF	γ_c
IMF ₁	0.860 7	IMF ₇	0.021 9
IMF ₂	0.828 7	IMF ₈	0.012 4
IMF ₃	0.319 9	IMF ₉	0.005 9
IMF ₄	0.224 0	IMF ₁₀	0.001 9
IMF ₅	0.023 8	IMF ₁₁	-0.000 4
IMF ₆	0.080 1	余项	—

由表 1 可知, $IMF_1—IMF_4$ 与原始振动信号的相关系数 $\gamma_c > 0.1$, 则 $IMF_1—IMF_4$ 与原始振动信号强相关; $IMF_5—IMF_8$ 与原始振动信号的相关系数 $\gamma_c \in (0.01, 0.1)$, 则 $IMF_5—IMF_8$ 与原始振动信号弱相关; $IMF_9—IMF_{11}$ 与原始振动信号的相关系数 $\gamma_c < 0.01$, 则 $IMF_9—IMF_{11}$ 与原始振动信号没有相关性。因此, 本文选择 $IMF_1—IMF_8$ 分量, 并对其进行 Hilbert 变换, 得到的 Hilbert 边际谱如图 4 所示。




图 4 $IMF_1—IMF_8$ 的 Hilbert 边际谱

Fig.4 Hilbert marginal spectrum of $IMF_i (i=1,2,\dots,8)$

由图 4 可知, 对高压断路器的振动信号进行 EEMD 后得到的 $IMF_1—IMF_8$ 反映了振动信号由高频段到低频段的变化情况, 且由 IMF_1 至 IMF_8 的频宽逐渐变窄、幅值逐渐减小。根据式 (12), 分别求取每组 IMF 分量的 Hilbert 边际谱能量, 并将其绘制成能量柱状图, 如图 5 所示。




图 5 $IMF_1—IMF_8$ 的 Hilbert 边际谱能量

Fig.5 Energy of Hilbert marginal spectrum of $IMF_i (i=1,2,\dots,8)$

4 触头超程状态识别

对高压断路器不同触头超程状态下的振动信号进行 EEMD、Hilbert 变换, 求取 IMF 分量的 Hilbert 边际谱能量值作为特征向量, 构建 SVM 分类器, 实现触头超程的状态识别, 算法具体流程如图 6 所示。

4.1 振动信号特征分析

不同触头超程状态下的典型合闸振动信号见图 7。

按照第 3 节所述步骤, 分别对 3 种不同触头超程状态下的合闸振动信号进行 EEMD、Hilbert 变换以及求取 IMF 分量的 Hilbert 边际谱能量值, 结果如






图 6 触头超程状态识别流程


Fig.6 Detection diagram of contact over-travel



(a) 触头超程偏大



(b) 触头超程正常



(c) 触头超程偏小

图 7 不同触头超程状态下合闸振动信号

Fig.7 Closing vibration signals under different over-travel states
表 2 所示。将表 2 绘制成能量柱状图, 如附录 A 中的图 A3 所示。

表 2 不同触头超程状态下 IMF 分量的 Hilbert 边际谱能量值
Table 2 Energy of Hilbert marginal spectrum for IMF's under different over-travel states

IMF	$E(\omega)$			IMF	$E(\omega)$		
	状态 a	状态 b	状态 c		状态 a	状态 b	状态 c
IMF_1	0.134	0.293	0.316	IMF_5	0.113	0.253	0.209
IMF_2	0.079	0.123	0.134	IMF_6	0.022	0.093	0.051
IMF_3	0.041	0.107	0.077	IMF_7	0.006	0.013	0.013
IMF_4	0.044	0.118	0.118	IMF_8	0.002	0.035	0.008

注: 状态 a、状态 b、状态 c 分别对应触头超程偏大、触头超程正常和触头超程偏小。

从图 A3 可以看出,不同触头超程状态下的高压断路器振动信号 IMF 分量的 Hilbert 边际谱能量具有明显的差异:同一超程状态下,各 IMF 分量的 Hilbert 边际谱能量值不同;不同超程状态下,各 IMF 分量的 Hilbert 边际谱能量值不同、总能量值不同。这进一步说明了当高压断路器触头超程状态发生变化时,振动信号的频谱和能量分布发生了改变;同时,也表明了该特征提取算法提取的振动信号特征值对于不同触头超程状态具有很好的区分度,能够很好地反映高压断路器触头超程状态的变化。

4.2 基于 SVM 的触头超程状态识别

此型号高压断路器要求触头超程不能低于 3.3 mm 且不能超过 4.2 mm。因此,可将高压断路器触头超程状态的变化划分为 3 个阶段:

- a. 正常阶段,触头超程范围为[3.3,4.2]mm;
- b. 偏大阶段,触头超程大于 4.2 mm;
- c. 偏小(失效)阶段,触头超程小于 3.3 mm。

随机选取 3 种不同触头超程状态(对应 3 个阶段)下的振动信号各 10 组,将总计 30 组振动信号的 IMF 分量 Hilbert 边际谱能量值作为 SVM 的训练样本,训练样本编号及分类标签如附录 B 中的表 B1 所示。在 SVM 训练过程中,通过网格搜索算法选择核函数中的 gamma 函数 g 和惩罚系数 c 使分类准确率最高,经优化,本文选取 $c=0.003\ 9$ 、 $g=27.857\ 6$,并采用 RBF 作为核函数。

再随机选取 3 种不同触头超程状态(对应 3 个阶段)下的振动信号各 5 组,然后将总共 15 组振动信号的 IMF 分量 Hilbert 边际谱能量值作为测试样本输入 SVM 模型中,测试样本编号及期望分类标签见附录 B 中的表 B2,SVM 预测结果如图 8 所示。




图 8 SVM 预测结果

Fig.8 SVM prediction results

从图 8 可以看出,SVM 预测结果与实际情况完全一致,准确率达到 100%,这说明本文提出的改进的 HHT 方法能够准确提取高压断路器触头超程状态信息,在此基础上采用 SVM 对高压断路器进行触头超程状态识别具有很高的准确率。

进一步地,为探究仅利用数值较大的 IMF 分量 Hilbert 边际谱能量时的分类效果,仅选取 IMF₁、IMF₂、IMF₅ 分量的 Hilbert 边际谱能量作为特征向量,训练样本和测试样本不变,分类结果如图 9 所示。由图可知,当仅选取 IMF₁、IMF₂、IMF₅ 分量的

Hilbert 边际谱能量作为特征向量时,将实际超程偏小误判为超程正常。出现误判的原因是 IMF₃、IMF₄ 在触头超程偏小的各 IMF 中所占的 Hilbert 边际谱能量比例较大(而在触头超程偏大、触头超程正常的各 IMF 中占的能量比例较小),故不能忽略 IMF₃、IMF₄ 分量的 Hilbert 边际谱能量值。




图 9 SVM 预测结果

Fig.9 SVM prediction results

观察 IMF 分量的 Hilbert 边际谱能量分布图(附录中的图 A3)可见,IMF₇、IMF₈ 分量的 Hilbert 边际谱能量在 3 种触头超程状态下所占的比例均很小,故尝试忽略 IMF₇、IMF₈ 的 Hilbert 边际谱能量值,仅选取 IMF₁—IMF₆ 的 Hilbert 边际谱能量作为特征向量,分类结果如图 10 所示。由图可见,没有出现误判现象,说明选取 IMF₁—IMF₆ 的 Hilbert 边际谱能量作为特征向量已经能够满足分类要求,分类准确率为 100%。




图 10 SVM 预测结果

Fig.10 SVM prediction results

5 结论

本文采用振动信号实现高压断路器触头超程状态识别,采用改进的 HHT 方法揭示高压断路器振动信号与触头超程状态之间的关系,并结合 SVM 实现高压断路器触头超程状态的准确识别。改进的 HHT 方法及本文其他工作具有以下特点:

- a. 采用改进的 HHT 方法提取不同触头超程状态振动信号特征量随着触头超程的不断减小,各 IMF 分量的 Hilbert 边际谱能量值逐渐增大,总能量值逐渐增大,并呈现一定的规律性;
- b. 基于改进的 HHT 和 SVM 方法准确识别了高压断路器 3 种不同触头超程状态;
- c. 同时,本文也存在一些不足之处,如只是定性分析 3 种触头超程状态,后续工作可对触头超程连续变化过程中的振动信号进行定量分析,以实现高压断路器触头超程状态的定量识别。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 段传宗, 鄢志平, 鄢志辉. 高压断路器故障检测与诊断技术 [M]. 北京: 中国电力出版社, 2014: 9-12.
- [2] 颜君凯, 马宏忠, 李凯, 等. 基于振动信号的变压器绕组松动故障诊断方法 [J]. 电力系统自动化, 2017, 41(3): 122-128.
YAN Junkai, MA Hongzhong, LI Kai, et al. Vibration signal based diagnosis method for looseness fault of transformer winding [J]. Automation of Electric Power Systems, 2017, 41(3): 122-128.
- [3] 江东, 周卫宏, 孔德善. 磁悬浮振动测试系统信号分析及振动信号的提取 [J]. 电机与控制学报, 2017, 21(10): 102-107.
JIANG Dong, ZHOU Weihong, KONG Deshan. Maglev vibration test system signals analyses and vibration signals extraction [J]. Electric Machines and Control, 2017, 21(10): 102-107.
- [4] 王建国, 吴林峰, 秦绪华. 基于自相关分析和 LMD 的滚动轴承振动信号故障特征提取 [J]. 中国机械工程, 2014, 25(2): 186-191.
WANG Jianguo, WU Linfeng, QIN Xuhua. Rolling bearing vibration signal fault feature extraction based on auto-correlation analysis and LMD [J]. China Mechanical Engineering, 2014, 25(2): 186-191.
- [5] 童基均, 李琳, 林勤光, 等. 采用平滑伪 Wigner-Ville 分布的 SSVEP 脑机接口系统 [J]. 浙江大学学报(工学版), 2017, 51(3): 598-604.
TONG Jijun, LI Lin, LIN Qingguang, et al. SSVEP Brain-Computer Interface (BCI) system using smoothed pseudo Wigner-Ville distribution [J]. Journal of Zhejiang University (Engineering Science), 2017, 51(3): 598-604.
- [6] 郭谋发, 游林旭, 洪翠, 等. 基于 LCD-Hilbert 谱奇异值和多级支持向量机的配电网故障识别方法 [J]. 高电压技术, 2017, 43(4): 1239-1247.
GUO Moufa, YOU Linxu, HONG Cui, et al. Identification method of distribution network faults based on singular value of LCD-Hilbert spectrums and multilevel SVM [J]. High Voltage Engineering, 2017, 43(4): 1239-1247.
- [7] 丁锋, 秦峰伟. 小波降噪及 Hilbert 变换在电机轴承故障诊断中的应用 [J]. 电机与控制学报, 2017, 21(6): 89-95.
DING Feng, QIN Fengwei. Application of wavelet denoising and Hilbert transform in fault diagnosis of motor bearing [J]. Electric Machines and Control, 2017, 21(6): 89-95.
- [8] 鲁军, 李侠, 王重马. 基于小波分析的 MSMA 振动传感器信号处理与故障检测 [J]. 电工技术学报, 2015, 30(10): 354-360.
LU Jun, LI Xia, WANG Chongma. Signal process and fault detection of MSMA vibration sensor based on wavelet analysis [J]. Transactions of China Electrotechnical Society, 2015, 30(10): 354-360.
- [9] 赵洪山, 李浪, 王颖. 一种基于盲源分离和流形学习的风电机组轴承故障特征提取方法 [J]. 太阳能学报, 2016, 37(2): 269-275.
ZHAO Hongshan, LI Lang, WANG Ying. Fault feature extraction method of wind turbine bearing based on blind source separation and manifold learning [J]. Acta Energaie Solaris Sinica, 2016, 37(2): 269-275.
- [10] 郭俊, 汲胜昌, 沈琪. 盲源分离技术在振动法检测变压器故障中的应用 [J]. 电工技术学报, 2012, 27(10): 68-78.
GUO Jun, JI Shengchang, SHEN Qi. Blind source separation technology for the detection of transformer fault based on vibration method [J]. Transactions of China Electrotechnical Society, 2012, 27(10): 68-78.
- [11] 段若晨, 王丰华, 周荔丹. 基于优化 HHT 算法与洛伦兹信息量度的换流变用有载分接开关机械特征提取 [J]. 中国电机工程学报, 2016, 36(11): 3101-3109.
DUAN Ruochen, WANG Fenghua, ZHOU Lidan. Mechanical features extraction of on-load tap-changer in converter transformer based on optimized HHT algorithm and Lorentz information measure [J]. Proceedings of the CSEE, 2016, 36(11): 3101-3109.
- [12] 李建鹏, 赵书涛, 夏燕青. 基于双谱和希尔伯特-黄变换的断路器故障诊断方法 [J]. 电力自动化设备, 2013, 33(2): 115-125.
LI Jianpeng, ZHAO Shutao, XIA Yanqing. Fault diagnosis based on bispectrum and Hilbert-Huang transform for circuit breaker [J]. Electric Power Automation Equipment, 2013, 33(2): 115-125.
- [13] 侯慧娟, 盛戈峰, 朱文俊, 等. 基于高阶累积量的局部放电超高频信号时延估计算法 [J]. 高电压技术, 2013, 39(2): 342-347.
HOU Huijuan, SHENG Gehao, ZHU Wenjun, et al. Time-delay estimation algorithm of partial ultra high frequency signals based on higher-order cumulant [J]. High Voltage Engineering, 2013, 39(2): 342-347.
- [14] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [15] 任宜春, 翁璞. 基于改进 Hilbert-Huang 变换的结构损伤识别方法研究 [J]. 振动与冲击, 2015, 34(18): 195-199.
REN Yichun, WENG Pu. Structural damage detection based on improved Hilbert-Huang transform [J]. Journal of Vibration and Shock, 2015, 34(18): 195-199.
- [16] WU Z H, HUANG N E. A study of the characteristics of white noise using the empirical mode decomposition method [J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2003, 460(2046): 1597-1611.
- [17] LIU Z G, CUI Y, LI W H. A classification method for complex power quality disturbances using EEMD and rank wavelet SVM [J]. IEEE Transactions on Smart Grid, 2015, 6(4): 1678-1685.
- [18] 孙一航, 武建文, 廉世军. 结合经验模态分解能量总量法的断路器振动信号特征向量提取 [J]. 电工技术学报, 2014, 29(3): 228-236.
SUN Yihang, WU Jianwen, LIAN Shijun. Extraction of vibration signal feature vector of circuit breaker based on empirical mode decomposition amount of energy [J]. Transactions of China Electrotechnical Society, 2014, 29(3): 228-236.
- [19] 陈攀, 姚陈果, 廖瑞金. 分频段能量谱及马氏聚类算法在开关柜局部放电模式识别中的应用 [J]. 高电压技术, 2015, 41(10): 3332-3341.
CHEN Pan, YAO Chenguo, LIAO Ruijin. Application of signals separated band energy spectrum and mahalanobis clustering algorithm for switchgear partial discharge pattern recognition [J]. High Voltage Engineering, 2015, 41(10): 3332-3341.
- [20] 胡伟, 李勇, 曹一家, 等. 基于 LOF 和 SVM 的智能配电网故障辨识方法 [J]. 电力自动化设备, 2016, 36(6): 7-12.
HU Wei, LI Yong, CAO Yiji, et al. Fault identification based on LOF and SVM for smart distribution network [J]. Electric Power Automation Equipment, 2016, 36(6): 7-12.
- [21] 程序, 关永刚, 张文鹏. 基于因子分析和支持向量机算法的高压断路器机械故障诊断方法 [J]. 电工技术学报, 2017, 29(7): 209-215.
CHENG Xu, GUAN Yonggang, ZHANG Wenpeng. Diagnosis method on the mechanical failure of high voltage circuit breakers based on factor analysis and SVM [J]. Transactions of China Electrotechnical Society, 2017, 29(7): 209-215.

- [22] REN L K, LV W M, JIANG S W, et al. Fault diagnosis using a joint model based on sparse representation and SVM[J]. IEEE Transactions on Instrumentations and Measurement, 2016, 65 (10): 2313-2320.

作者简介:

杨秋玉(1986—),男,福建仙游人,博士研究生,主要研究方向为电气设备在线监测与故障诊断、高电压与绝缘技术(E-mail: qiuqiyang_1025@163.com);

阮江军(1968—),男,浙江绍兴人,教授,博士研究生导师,博士,研究方向为电磁场工程应用、电磁兼容和高电压与

绝缘技术(E-mail: ruan308@126.com);



杨秋玉

黄道春(1976—),男,黑龙江齐齐哈尔人,副教授,博士研究生导师,博士,主要研究方向为输变电设备外绝缘、高压电器、电磁场数值计算及其工程应用(E-mail: huangdc99@163.com);

庄志坚(1986—),男,福建厦门人,高级工程师,硕士,主要研究方向为电气设备在线监测与故障诊断、新一代同步选相开关(E-mail: zhijian.zhuang@cn.abb.com)。

Over-travel detection of electrical contact for high-voltage circuit breaker based on improved HHT and SVM

YANG Qiuyu¹, RUAN Jiangjun¹, HUANG Daochun¹, ZHUANG Zhijian²

(1. School of Electrical Engineering, Wuhan University, Wuhan 430072, China;

2. Power Product Medium Voltage Technology Center, ABB(China) Co., Ltd., Xiamen 361006, China)

Abstract: The HHT(Hilbert-Huang Transform) is improved by EEMD(Ensemble Empirical Mode Decomposition). The improved HHT method combined with SVM(Support Vector Machine) is applied to feature extraction of vibration signal of HVCB(High-Voltage Circuit Breaker) and over-travel state recognition of HVCB's electrical contacts. The IMF(Intrinsic Mode Function) components reflecting local characteristics of HVCB's vibration signal are extracted by EEMD, then their Hilbert marginal spectrum energy is calculated to build characteristic vector of electrical contact over-travel of HVCB. The SVM is trained by the characteristic vector to realize the automatic detection of electrical contact over-travel. The vibration signals of HVCB under different over-travel states are extracted and analyzed, and the results show that the proposed method can effectively detect the electrical contact over-travel of HVCB.

Key words: high-voltage circuit breaker; vibration signal; over-travel of electrical contacts; Hilbert-Huang transform; support vector machine; state recognition

(上接第197页 continued from page 197)

Analysis of transformer oil paper insulation aging using improved Davidson-Cole dielectric model

ZHANG Tao¹, LI Linduo¹, RAN Huajun², XIAO Xia¹, ZHONG Tingting¹

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China;

2. Hubei Provincial Collaborative Innovation Center for New Energy Microgrid, China Three Gorges University, Yichang 443002, China)

Abstract: In order to accurately analyze the state of transformer oil paper insulation using FDS(Frequency-domain Dielectric Spectroscopy), an improved Davidson-Cole dielectric model considering DC conductivity and hopping conductivity is proposed. The Davidson-Cole dielectric model is improved by parameterizing the measured FDS data and then transformed into a nonlinear optimization problem. The mixed frog leaping optimization algorithm is adopted to identify the parameters of the improved Davidson-Cole dielectric model, by which, the characteristic parameters such as relaxation time τ , asymmetry of circular arc β and DC conductivity σ_{dc} are obtained. The influences of aging and moisture on the parameters of modified Davidson-Cole dielectric model for oil paper insulation samples are researched. The research results show that β has good exponential relationship with furfural content, σ_{dc} has good exponential relationship with moisture content, and τ has good logarithmic relationship with furfural content and moisture content. Quantitative functions of relationship between furfural content, moisture content and model parameters are obtained by linear fitting. These quantitative functions have high goodness of fit, so the improved Davidson-Cole dielectric model can be used to quantitatively evaluate the state of transformer oil paper insulation.

Key words: power transformers; oil-paper insulation; improved Davidson-Cole model; water content; furfural content; frequency-domain dielectric spectroscopy

附录 A




图 A1 EEMD 算法流程图

Fig.A1 Flowchart of EEMD algorithm




图 A2 现场采集图及压阻式传感器安装位置

Fig.A2 Test platform and position of piezoresistive acceleration sensor




图 A3 IMF 分量 Hilbert 边际谱能量分布

Fig.A3 Distribution of Hilbert marginal spectrum's energy for IMFs

附录 B

表 B1 训练样本编号及分类标签

TableB1 Number of training samples and classification labels

触头 超程 状态	训练样 本编号	IMF ₁	IMF ₂	IMF ₃	IMF ₄	IMF ₅	IMF ₆	IMF ₇	IMF ₈	分类 标签
		0.134	0.079	0.041	0.044	0.126	0.020	0.006	0.002	
偏大	1—10	0.135	0.084	0.043	0.028	0.083	0.020	0.004	0.008	1
					⋮					
		0.245	0.164	0.072	0.057	0.157	0.042	0.009	0.014	
正常	11—20	0.239	0.126	0.081	0.060	0.195	0.051	0.006	0.013	2
					⋮					
		0.280	0.122	0.087	0.092	0.439	0.041	0.017	0.017	
偏小	21—30	0.264	0.131	0.091	0.091	0.232	0.034	0.008	0.0	3
					⋮					

表 B2 测试样本编号及期望分类标签

TableB2 Number of test samples and classification labels

触头超程 状态	测试样本编号	IMF ₁	IMF ₂	IMF ₃	IMF ₄	IMF ₅	IMF ₆	IMF ₇	IMF ₈	分类 标签
偏大	1—5	0.1280	0.0730	0.0430	0.0370	0.0890	0.0310	0.0050	0.007	1
					⋮					
正常	6—10	0.2240	0.1450	0.0700	0.0450	0.2090	0.0420	0.0100	0.011	2
					⋮					
偏小	11—15	0.2930	0.1240	0.1090	0.1200	0.2380	0.0910	0.0120	0.030	3
					⋮					