

基于经验模态分解的高压断路器 机械故障诊断方法

黄建, 胡晓光, 巩玉楠

(北京航空航天大学自动化科学与电气工程学院, 北京市 海淀区 100191)

Machinery Fault Diagnosis of High Voltage Circuit Breaker Based on Empirical Mode Decomposition

HUANG Jian, HU Xiaoguang, GONG Yunan

(School of Automation Science and Electrical Engineering, Beihang University, Haidian District, Beijing 100191, China)

ABSTRACT: To research the characteristics of mechanical vibration signals of high voltage circuit breakers, a new method for fault diagnosis was proposed based on improved empirical mode decomposition (EMD) energy entropy and support vector machine (SVM); and feasible diagnostic steps and analysis were also introduced. Firstly, the original vibration signals were decomposed into a number of intrinsic mode functions (IMF) by the EMD method. Secondly, the energy entropy vector was extracted with the segmental energy of IMF based on the theory of entropy and the method of equal energy, and was considered as the input vector of SVM. The Binary tree vector machine was used to solve the multi-class classification problem; and the gradient method and cross-validation were taken to optimize model parameters. The experiment shows that the proposed method is effective to diagnose the machinery faults of high voltage circuit breakers.

KEY WORDS: high voltage circuit breaker; vibration signal; energy entropy; support vector machine(SVM); fault diagnosis

摘要: 分析高压断路器机械振动信号的特性, 提出一种以改进的经验模态分解(empirical mode decomposition, EMD)能量熵和支持向量机(support vector machine, SVM)相结合的诊断高压断路器机械故障的方法, 并给出了可行的诊断步骤和分析。首先利用经验模态分解方法将高压断路器的振动信号分解成一些相互独立的内禀模态函数(intrinsic mode function, IMF), 然后利用正常状态标准信号所得各固有内禀模态函数包络信号的等能量分段方式, 实现对待测状态信号各 IMF 包络的时间轴分段, 计算各待测信号 IMF 包络的能量熵向量, 以此构造的经验模态分解能量熵向量作为支持向量机的输入向量。采用“次序二叉树”向量机分类, 利用梯度法和交叉检验优化支持向量机模型参数。实验结果表明, 该方法诊断

高压断路器机械故障能取得良好的效果。

关键词: 高压断路器; 振动信号; 能量熵; 支持向量机; 故障诊断

0 引言

随着电网运行自动化程度和可靠性要求的提高, 高压断路器作为电力系统中一种重要的设备, 对其故障诊断技术的研究具有重要意义。高压断路器动作产生的机械振动信号蕴含着许多重要的状态信息, 分析振动信号能够发现触头磨损、螺丝松动等许多机械故障征兆^[1-3], 因此, 基于振动信号的状态分析逐渐成为研究的焦点^[4-10]。文献[6]提出利用小波包和短时能量分析的方法处理振动信号, 得出了断路器合闸同期性; 文献[8]使用改进的动态时间规整算法(dynamic time warping, DTW)分析振动信号, 得到正常状态和测试状态的振动信号时间偏移的估计, 以此与参考相比较进行诊断, 取得良好的诊断效果; 文献[9]提出利用小波包能量熵提取振动信号包络的特征, 并对机械故障进行诊断, 也取得了较好的效果; 文献[10]研究了断路器各机构部件运动的内在机理, 分析了振动频率变化与时间偏移的关系。但这些诊断方法仍存在一些不足, 例如, 采用小波进行特征提取时, 一旦小波基和分解尺度选定, 小波分解则不随信号变化而自适应变化, 同时小波分解存在能量泄露, 这些问题严重影响故障信号的特征提取。在状态识别中, 人工神经网络具有较强的自学习、非线性模式识别能力, 但其本身有着一些无法克服的缺点: 如网络中的结构选择和

基金项目: 国家自然科学基金项目(50875011)。

Project Supported by National Natural Science Foundation of China (50875011).

权重的初值设定需要借助于经验、网络训练速度慢、易陷入局部极小点、过学习等^[11-12]。支持向量机建立在统计学习理论和结构风险最小原理基础上,该算法有效地改善了传统分类方法的缺陷,已取得比较广泛的应用^[13-18]。

近年来,huang 等提出了一种基于经验模态分解(empirical mode decomposition, EMD)的信号处理方法,基函数直接根据信号本身的特征尺度产生,把复杂信号分解成一系列内禀模态函数(intrinsic mode function, IMF),通过分析包含信号局部特性的 IMF 来准确提取原始信号的重要特性,每一个 IMF 里所包含的频率成分不与信号的采样频率相关,而与信号本身有关,此方法已被应用于非平稳信号的处理^[19-21]。针对由于机械润滑不足引起的高压断路器故障振动信号,若直接采用 EMD 分解求取能量熵进行特征提取则难以判断故障的问题,本文提出了 EMD 等能量分段方法来提取特征量。

本文将改进的 EMD 能量熵和支持向量机(support vector machine, SVM)理论相结合,提出了一种诊断高压断路器机械故障的方法。重点分析高压断路器基座螺丝松动故障、缓冲器弹簧无效超程和机械动作时间延迟类故障。

1 EMD 分解原理

假设任何复杂的信号都是由一些相互独立的 IMF 相互叠加而成,在此基础上,可以采用 EMD 方法将一个多频率分量信号分解为若干个 IMF 之和。每一个 IMF 必须满足下面 2 个条件:

1) 在整个数据段内,极值点的个数和过零点的个数必须相等或相差最多不超过一个。

2) 在任意时刻,由局部极大值点形成的上包络线和由局部极小值点形成的下包络线的平均值为零,即上、下包络线相对于时间轴对称。

EMD 方法的基本步骤如下:

1) 确定信号 $x(t)$ 的所有局部极值点。

2) 利用 3 次样条插值将所有局部极值点连接起来分别形成上、下包络线,上、下包络线应该包络所有的数据点。在求取包络的过程中,需要在信号两端采用镜像延拓极值点的方法抑制端点效应。

3) 上、下包络线的平均值记为 $m_1(t)$

$$h_1(t) = x(t) - m_1(t) \quad (1)$$

4) 如果 $h_1(t)$ 满足 IMF 的条件,则 $h_1(t)$ 就是 $x(t)$ 的第 1 个 IMF 分量,否则令 $x(t)=h_1(t)$,重复步骤 1)

—3),循环 k 次,得到 $h_{1(k-1)}(t)-m_{1k}(t)=h_{1k}(t)$,使得 $h_{1k}(t)$ 满足 IMF 的条件。记 $c_1(t)=h_{1k}(t)$,则 $c_1(t)$ 为信号 $x(t)$ 的第 1 个 IMF 分量。这种求取 IMF 分量的做法称为“筛分”。

一般通过筛分前后 2 次结果的标准差(standard deviation, SD) 作为 IMF 的判据:

$$SD = \sum_{t=0}^T \frac{[h_{k-1}(t) - h_k(t)]^2}{h_{k-1}^2(t)} \quad (2)$$

SD 的阈值通常取 0.2~0.3。

5) 将 $c_1(t)$ 从 $x(t)$ 中分离出来,得到

$$r_1(t) = x(t) - c_1(t) \quad (3)$$

把 $r_1(t)$ 作为原始信号,重复步骤 1) —4),得 $x(t)$ 的第 2 个 IMF 分量 $c_2(t)$,重复循环 n 次,得到信号 $x(t)$ 的 n 个满足 IMF 条件的分量。这样就有

$$\begin{cases} r_1(t) - c_2(t) = r_2(t) \\ \dots \\ r_{n-1}(t) - c_n(t) = r_n(t) \end{cases} \quad (4)$$

直到 $r_n(t)$ 为单调函数,不能再从中提取 IMF 分量时,循环结束,得到

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (5)$$

式中 $r_n(t)$ 为残余函数,代表信号的平均趋势。

2 SVM 原理

SVM 是实现结构风险最小化原则的一种通用学习算法,比较适合于小样本数据的分类,其基本思想如图 1 所示。图中圆点和方点分别表示 2 类训练样本, H 为把 2 类样本完全无误分开的分类线, H_1 、 H_2 分别为通过样本中离分类线最近的样本且平行于分类线的直线,他们之间的间隔为分类间隔,线上的样本点就是支持向量。该最优面不但将 2 类样本无误的分开,而且要使分类间隔最大,前者保证经验风险最小,后者使问题的真实风险最小。




图 1 SVM 两类分类

Fig. 1 Classification of two classes using SVM

SVM 最初针对模式识别中线性可分的 2 类分类问题提出。即给定训练集 $T = \{x_k, y_k\}_{k=1}^l$ ($x_k \in \mathbf{R}^n$

为输入, $y_k \in \{-1, 1\}$ 为输出), 找到一个实值函数 $g(x)$, 使得分类决策函数 $f(x) = \text{sgn}(g(x))$ 能够正确地将 \mathbf{R}^n 上的点分成 2 部分。如果函数 $g(x)$ 为线性函数, 即 $g(x) = \omega \cdot x + b$ (其中 ω 为权向量, b 为阈值), 则该问题线性可分, $\omega \cdot x + b = 0$ 为分划超平面方程。

推广至线性不可分情况, 考虑到有些样本不能被超平面正确分类, SVM 通过引入松弛变量 ξ_i 和惩罚因子 C 进行推广, 则超平面约束条件为

$$y_i[(w \cdot x) + b - 1] + \xi_i \geq 0, \quad i = 1, 2, \dots, n \quad (6)$$

式中: w 为分类面的法向量; b 为阈值。

引入拉格朗日乘数, 广义最优分类面问题可以转化为在约束条件下最小化 $\sum_i a_i \sum_{i,j} a_i a_j y_i y_j (x_i \cdot y_j)$,

其中约束条件为 $0 \leq a_i \leq C$, $i = 1, 2, \dots, n$; $\sum_i a_i y_i = 0$, $C > 0$ 为惩罚常数, 控制分类错误惩罚的程度, 实现错分样本的比例与算法复杂度之间的折中。根据泛函有关理论, 只要采用适当的内积核函数 $K(x_i, y_i)$, 并且核函数满足 Mercer 条件, 就可实现此非线性变换, 此时分类函数为

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^n a_i^* y_i K(x_i, x) + b^* \right\} \quad (7)$$

3 特征提取与故障诊断步骤

3.1 信号包络提取

信号的突变信息往往体现在信号的包络里, 高压断路器机械振动冲击所包含的高频成分就是包络信号的载波。在机械故障的诊断中经常会用到 Hilbert 方法提取信号包络^[20-21]。

某信号 $x(t)$ 的解析信号定义为

$$g(t) = x(t) + jH[x(t)] \quad (8)$$

式中 $H[x(t)]$ 为 $x(t)$ 的 Hilbert 变换。 $g(t)$ 的幅值为

$$A(t) = \sqrt{x^2(t) + H^2[x(t)]} \quad (9)$$

式中 $A(t)$ 为信号 $x(t)$ 的包络。

3.2 改进的 EMD 能量熵

能量熵是在一定的状态下定位系统的一种测度, 它是对序列未知程度的一种度量。对于高压断路器的振动而言, 各种正常状态都是一个标准正常状态的脉动, 各故障状态可认为是此标准正常状态的不同突变。本文提出的改进 EMD 能量熵提取方法是利用信号包络的分段能量计算能量熵。

首先将 IMF 包络信号沿时间轴均分成 N 段, 并对每段信号利用时间积分计算分段能量:

$$Q(i) = \int_{t_{i-1}}^{t_i} |A(t)|^2 dt \quad (10)$$

式中 $i = 1, 2, \dots, N$; t_{i-1} 、 t_i 为第 i 分段的起止时间点。将包络信号各分段能量进行归一化处理如下:

$$q(i) = \frac{Q(i)}{\sum_{i=1}^N Q(i)} \quad (11)$$

根据能量熵的基本理论^[20], 信号 $x(t)$ 的 EMD 能量熵定义为

$$H = -\sum_{i=1}^N q(i) \lg q(i) \quad (12)$$

3.3 故障诊断步骤

1) 分别对正常状态标准信号和待测信号进行 EMD 分解, 分解尺度为 k , 计算正常标准信号各 IMF 与原始信号的相关系数 μ_i ($i = 1, 2, \dots, k$)。

2) 计算阈值系数 $\lambda = \max(\mu_i) / \eta$, 一般取 $\eta = 10.0$, 相关系数大于 λ 的 IMF 保留。

3) 利用式(9)提取各保留的 IMF 信号包络。

4) 按照积分能量均等的原则将正常信号各包络分成 N 段, 将分段方式应用于待测信号对应 IMF 包络。

5) 在待测信号各 IMF 包络分别计算 EMD 能量熵, 从而得到 EMD 能量熵向量 $T_i = [H_0, H_1, \dots, H_n]$ 。

6) 根据 $\sigma = \|T_0 - T_i\|$, 计算正常向量 T_0 和故障向量 T_i 之间的欧氏距离, 评价故障程度。

7) 采用“次序二叉树”向量机策略方式分类, 利用梯度法和交叉检验优化支持向量机模型参数, T_i 作为输入向量, 支持向量机输出对应各状态实现故障诊断。

4 诊断实例分析

4.1 特征量提取与分析

本文实验以一台六氟化硫高压断路器为对象, 选用美国 PCB 公司的 M353B02 型高性能加速度传感器测量振动信号, 主要研究断路器在无负载情况下的 3 种故障类型: 1) 断路器单相基座螺丝松动故障(故障 I); 2) 缓冲器弹簧无效超程(故障 II); 3) 机械润滑不足引起动作时间延迟故障(故障 III)。利用安装于高压断路器控制箱内的数据采集器采集振动数据。数据采集器在断路器动作时以 25 kHz 的速率进行 320ms 的数据采集, 各状态条件下对断路器合闸过程进行 10 组实验, 本文仅列出各故障状态下的 2 组信号, 原始振动信号如图 2 所示, (a) —(g) 依次为正常状态标准信号、2 组缓冲器弹簧无

效超程故障信号、2 组基座螺丝松动故障信号和 2 组时间延迟故障信号。




图 2 正常与故障信号

Fig. 2 Normal and fault signals

就机械延迟信号而言，其故障信号与正常状态相比，各运动冲击事件的相对时刻未发生变化，由 EMD 基本理论可知，振动信号采用 EMD 分解后，各 IMF 信号对应包络只是时间轴的平移，直接采用 EMD 能量熵将得到相同的特征向量，无法区分故障类型，因此，本文采用改进的能量熵求取信号特征并进行分析。即首先利用小波变换分别对采集的振动数据进行小波软硬阈值折中去噪处理；后对去噪后的数据进行 EMD 分解，经过对不同故障下各 IMF 与原始信号的相关系数分析，综合考虑运算量与诊断结果，选取分解尺度为 8；然后对正常状态标准信号各 IMF 包络信号全程积分，分别求取各 IMF 包络总能量，按照能量相等的原则将对应各 IMF 包络时间轴分成 15 段(实验分析所得)，利用式(10)、(11)、(12)分别求取各包络信号分段能量，能量熵向量 T 如表 1 所示。

从表 1 中能量熵向量可以发现，正常标准信号

能量熵向量间分布比较均匀，而故障信号熵向量各元素普遍小于正常情况，且各元素分布不均匀，这说明在故障状态下各信号 IMF 包络中信号频率发生变化，频带能量分布受到干扰，此熵向量可以作为判断高压断路器有无故障的判据；同时还可发现，螺丝松动故障各信号所得能量熵普遍小于时间延迟类故障，而缓冲器弹簧无效超程故障次之。各状态能量熵向量欧式空间距离的计算结果见表 2。

表 2 能量熵向量间的欧式距离

Tab. 2 Euclidean distances of energy entropy vector

故障类型	欧式距离
故障 I 信号 1	0.820 4
故障 I 信号 2	0.790 7
故障 II 信号 1	1.150 2
故障 II 信号 2	1.180 4
故障 III 信号 1	1.253 2
故障 III 信号 2	1.378 3

从表 2 可看出，不同故障条件下，欧式空间距离不同，3 种故障下的熵向量欧式距离分别主要分布在 0.7~0.9、1.1~1.2 和 1.2~1.4。在螺丝松动条件下，振动信号能量在各 IMF 包络中发生变化，各撞击事件发生的相对时刻基本不变，螺丝松动引起振动低频成分增加；在缓冲器弹簧无效超程故障状态下，触头运动起始时刻相同，但碰撞时间滞后，增加触头运行时间，冲击阻力降低；而润滑不足时间延迟故障信号中各 IMF 包络信号中的能量基本不变，只是时间发生相对时刻后移，相对频率没有变化。从欧式空间距离也可定性的判断断路器的状况。因此，基于改进的 EMD 能量熵的信号提取方法是一种有效提取断路器故障信号的方法。

4.2 3 种分类算法比较

在故障诊断中，利用 SVM 进行状态分类，核心思想为通过核函数将低维空间中的非线性问题变为高维空间中的线性问题，核函数是 SVM 中非线性变换的关键。对于现实中存在的多类分类问题，目前主要的方法有“一对一”(one-against-one,

表 1 能量熵向量表

Tab. 1 Vectors of energy entropy

特征熵	H_0	H_1	H_2	H_3	H_4	H_5	H_6	H_7
正常信号	1.322	1.415	1.553	1.583	1.636	1.457	1.463	1.564
故障 I 信号 1	1.412	1.486	1.451	1.405	1.556	1.589	1.372	1.443
故障 I 信号 2	1.421	1.471	1.486	1.516	1.592	1.604	1.343	1.483
故障 II 信号 1	1.963	1.896	1.663	1.468	1.363	1.263	1.198	1.423
故障 II 信号 2	1.899	1.822	1.612	1.424	1.469	1.323	1.234	1.356
故障 III 信号 1	2.380	2.123	1.385	1.423	1.520	1.514	1.410	1.445
故障 III 信号 2	2.333	2.099	1.412	1.463	1.510	1.595	1.426	1.431

OAO)、“一对余”(one-against-rest, OAR)、“二叉树”(binary-tree, BT)等分类算法^[15-18]。OAO方法是采用投票法组合策略进行多分类,它具有分类精度较高的优点,但缺点是对于 K 分类问题须有 $K(K-1)/2$ 个SVM子分类器,且分类必须遍历所有训练的SVM子分类器,训练复杂,分类效率低,存在分类盲区^[16]。OAR方法是采用“最大输出”法实现多分类,该方法虽然所需训练 K 个子分类器,但是各SVM都是在全部训练集样本上进行学习的,当样本数较多时,训练速度很慢,分类时必须遍历所有 K 个SVM子分类器,效率不高,且同样存在分类盲区^[16]。BT方法克服以上2种算法的缺点,训练和分类的效率都明显提高,但是,子分类器在二叉树中的排列次序对整个分类系统的性能有一定的影响,合理地确定子分类器在二叉树中的排列次序非常重要,本文采用文献[18]提出的次序二叉树方法确定各子分类器的位置。计算3种故障训练样本的分布半径 R ,得到它们的综合排序为 $R_{故障III} > R_{故障I} > R_{故障II}$ 。所有实验结果取平均值作为最终结果。本文采用梯度法和10折交叉检验优化模型参数,使用不同的核函数与3种算法进行实验,图3为3种分类算法采用多项式核函数分类的结果,其中 d 为核函数的参数。




图3 不同 d 值时3类分类算法的分类效果比较
Fig. 3 Comparison of accuracy of three strategies with different d for polynomial kernels

依次取 $d = \{1, 2, \dots, 8\}$,从图3中可知,对于3类分类算法而言,当 $d=1$ 时,分类效果达到最差,当 $d=3$ 时,BT分类算法准确性达到96%,分类效果达到最佳。同时,识别精度随多项式次数的增加呈现先增加而后减少的趋势,这说明采用多项式核函数进行识别时,多项式的次数并非越高越好。比较OAO和OAR方法可知,BT法具有更高的准确性。图4为不同 (C, γ) 组合在RBF(radial basis function)核下BT法分类效果的比较。由于篇幅所限,本文仅列出在RBF核下的分类结果图。

惩罚因子 C 和参数 γ 是RBF核函数2个重要的




图4 不同 (C, γ) 组合在RBF内核下BT法分类效果比较
Fig. 4 Comparison of classification using BT strategy with RBF kernel in different (C, γ)

参数,对于SVM诊断的准确率影响很大, C 过大或者过小,都会使系统的泛化能力变差, γ 反映了训练数据的特性,同样对于系统的泛化能力影响也较大。在训练样本中用梯度法和10折交叉检验法在模型参数 $C = \{2^0, 2^1, \dots, 2^9\}$ 和 $\gamma = \{2^{-3}, 2^{-2}, \dots, 2^3\}$ 范围之间自动寻找分类最佳参数,然后用最佳参数对测试样本进行分类处理,由图4可知,对于相同的 C 值,识别精度却随 γ 值的增加呈现先增加而后减少的趋势,当 $C=64$ 和 $\gamma=2$ 时,该分类算法准确性效果达到99%。经实验分析,当 $C=32$ 和 $\gamma=1$ 时,OAO分类算法和OAR算法分别达到97%和95%的最大识别率,当达到最大识别率后,分类性能随着 γ 的增加而降低。

表3为采用BT法针对不同核函数识别率与分类时间比较结果。使用RBF核函数效果最好,而使用线性核时则基本上失去了识别的意义,错误率比较大,这说明在线性核映射下,各不同类别的参量混淆在一起,变得高度不可分了。Sigmoid核和多线性核函数的分类也不适合基于振动信号的高压断路器故障分类,综合识别率和分类时间的考虑,选用径向基函数作为核函数是最优选择。

表3 BT策略下不同核函数识别率与分类时间比较
Tab. 3 Comparison of classification with BT strategy for different core functions

核函数	识别率/%	分类时间/s
线性核	79	0.22
多项式核($d=3$)	96	0.53
径向基核($C=64, \gamma=2$)	99	0.34
Sigmoid核	94	0.75

4.3 BT-SVM与BP网络性能比较

为了比较二叉树支持向量机与BP神经网络的收敛速度和识别率,分别在10个训练样本和5个训练样本下进行实验,将特征量输入BP神经网络(网络结构 $8 \times 18 \times 4$,学习速率 $L_r = 0.02$,目标误差 $E_g = 0.001$),结果如表4所示。

从表4中可知,二叉树支持向量机与BP网络

相比, 具有更高的准确率且节省了大量的识别时间, 有利于故障进行在线分类。同样可知, 支持向量机在小样本情况下具有良好的推广能力。

表 4 BT-SVM 与 BP 网络性能比较

Tab. 4 Performance comparison between

BP and BT-SVM

网络类型	样本数	识别率/%	分类时间/s
BT-SVM	10/5	100/99	0.58/0.34
BP	10/5	92/88	0.93/0.62

5 结论

本文利用改进的 EMD 能量熵和 SVM 相结合进行高压断路器机械故障特征提取及状态的识别, 取得了良好的诊断效果。采用改进的 EMD 能量熵提取振动信号的特征量, 以此作为支持向量机的输入向量。分别采用 OAO、OAR、BT 策略方式对样本进行训练, 利用梯度法和交叉检验优化支持向量机模型参数。实验结果表明, 该特征提取方法能有效提取故障信号特征, 与 BP 神经网络相比, 基于该信号特征提取法的次序二叉树向量机能更快速、准确的判断高压断路器机械故障类型。

参考文献

- [1] Polycarpou A A, Soom A, Peter J W, et al. Event timing and shape analysis of vibration bursts from power circuit breakers[J]. IEEE Trans. on Power Delivery, 1996, 11(2): 848-857.
- [2] Runde M, Ottesen G E, Skyberg B, et al. Vibration analysis for diagnostic testing of circuit breakers[J]. IEEE Trans. on Power Delivery, 1996, 11(4): 1816-1823.
- [3] 沈力, 黄瑜珑, 钱家骊. 高压断路器机械状态监测的研究[J]. 中国电机工程学报. 1997, 17(2): 113-117.
Shen Li, Huang Yulong, Qian Jiali. Research on mechanical condition monitoring for HV circuit breakers[J]. Proceedings of the CSEE, 1997, 17(2): 113-117(in Chinese).
- [4] 胡晓光, 戴景民, 纪延超. 基于小波奇异性检测的高压断路器故障诊断[J]. 中国电机工程学报, 2001, 21(5): 67-70.
Hu Xiaoguang, Dai Jingmin, Ji Yanchao. The fault diagnosis of high voltage breakers based on wavelet singularity detection [J]. Proceedings of the CSEE, 2001, 21(5): 67-70(in Chinese).
- [5] Dennis S S L, Lithgow B J, Morrison R E. New fault diagnosis of circuit breakers[J]. IEEE Trans. on Power Delivery, 2003, 18(2): 454-459.
- [6] 马强, 荣命哲, 贾申利. 基于振动信号小波包提取和短时能量分析的高压断路器合闸同期性的研究[J]. 中国电机工程学报, 2005, 25(13): 149-154.
Ma Qiang, Rong Mingzhe, Jia Shenli. Study of switching synchronization of high voltage breakers based on the wavelet packets extraction algorithm and short time analysis method[J]. Proceedings of the CSEE, 2005, 25(13): 149-154(in Chinese).
- [7] 孙来军, 胡晓光, 纪延超. 基于支持向量机的高压断路器机械状态分类[J]. 电工技术学报, 2006, 21(8): 53-58.
Sun Laijun, Hu Xiaoguang, Ji Yanchao. Fault classification of high voltage circuit breakers based on support vector machine [J]. Transactions of China Electrotechnical Society, 2006, 21(8): 53-58(in Chinese).
- [8] Landry M, Lonard F, Beauchemin R. An improved vibration analysis algorithm as a diagnostic tool for detecting mechanical anomalies on power circuit breakers[J]. IEEE Transactions on Power Delivery, 2008, 23(4): 1986-1994.
- [9] 孙来军, 胡晓光, 纪延超. 改进的小波包-特征熵在高压断路器故障诊断中的应用[J]. 中国电机工程学报, 2007, 27(12): 103-108.
Sun Laijun, Hu Xiaoguang, Ji Yanchao. Fault diagnosis for high voltage circuit breakers with improved characteristic entropy of wavelet packet[J]. Proceedings of the CSEE, 2007, 27(12): 103-108(in Chinese).
- [10] Hoidalén H K, Runde M. Continuous monitoring of circuit breakers using vibration analysis[J]. IEEE Transactions on Power Delivery, 2005, 20(4): 2458-2465.
- [11] 王小华, 荣命哲, 吴翊, 等. 高压断路器故障诊断专家系统中快速诊断及新知识获取方法[J]. 中国电机工程学报, 2007, 27(12): 95-99.
Wang Xiaohua, Rong Mingzhe, Wu Yi, et al. Method of quick fault diagnosis and new knowledge obtainment for high voltage circuit breaker expert system[J]. Proceedings of the CSEE, 2007, 27(12): 95-99(in Chinese).
- [12] 桂中华, 韩凤琴. 小波包特征熵神经网络在尾水管故障诊断中的应用[J]. 中国电机工程学报, 2005, 25(4): 99-102.
Gui Zhonghua, Han Fengqin. Neural network based on wavelet packet characteristic entropy for fault diagnosis of draft tube[J]. Proceedings of the CSEE, 2005, 25(4): 99-102(in Chinese).
- [13] Ming G, Du R, Zhang G C, et al. Fault diagnosis using support vector machine with an application in sheet metal stamping operations [J]. Mechanical Systems and Signal Processing, 2004(18): 143-159.
- [14] Yang J Y, Zhang Y Y, Zhu Y S. Intelligent fault diagnosis of rolling element bearing based on SVMs and fractal dimension[J]. Mechanical Systems and Signal Processing, 2007(21): 2012-2024.
- [15] Xian G M, Zeng B Q. An intelligent fault diagnosis method based on wavelet packer analysis and hybrid support vector machines [J]. Expert Systems with Applications, 2009(36): 12131-12136.
- [16] Yuan S F, Chu F L. Support vector machines-based fault diagnosis for turbo-pump rotor[J]. Mechanical Systems and Signal Processing, 2006(20): 939-952.
- [17] 胡清, 王荣杰, 詹宜巨. 基于支持向量机的电力电子电路故障诊断技术[J]. 中国电机工程学报, 2008, 28(12): 107-111.
Hu Qing, Wang Rongjie, Zhan Yiju. Fault diagnosis technology based on SVM in power electronics circuit[J]. Proceedings of the CSEE, 2008, 28(12): 107-111(in Chinese).
- [18] 唐发明, 王仲东, 陈绵云. 支持向量机多类分类算法研究[J], 控制与决策, 2005, 20(7): 746-749
Tang Faming, Wang Zhongdong, Chen Mianyun. On multiclass classification methods for support vector machines[J]. Control and Decision, 2005, 20(7): 746-749(in Chinese).
- [19] 李天云, 赵妍, 季小慧. HHT 方法在电力系统故障信号分析中的应用[J]. 电工技术学报, 2005, 20(6): 87-91.
Li Tianyun, Zhao Yan, Ji Xiaohui. Application of hht method for analysis of fault signal in electric power system[J]. Transactions of China Electrotechnical Society, 2005, 20(6): 87-91(in Chinese).
- [20] Yang Y, Yu D J, Cheng J S. A roller bearing fault diagnosis method based on EMD energy entropy and ANN[J]. Journal of Sound and Vibration, 2006(294): 269-277.
- [21] Cheng J S, Yu D J, Tang J S, et al. Application of frequency family separation method based upon EMD and local Hilbert energy spectrum method to gear fault diagnosis[J]. Mechanism and Machine Theory, 2008(43): 712-723.



黄建

收稿日期: 2010-12-20。

作者简介:

黄建(1982), 男, 博士研究生, 研究方向为信号处理、高压电气设备在线监测与故障诊断技术, huangjian421@126.com;

胡晓光(1961), 女, 教授, 博士生导师, 研究方向为电能计量装置、高压设备在线监测与故障诊断。

(编辑 胡琳琳)