

DOI:10.13296/j.1001-1609.hva.2020.06.021

基于主成分分析—支持向量机优化模型的断路器故障诊断方法研究

樊浩¹, 李兴文¹, 苏海博², 陈立¹, 史宗谦¹

(1. 西安交通大学电气工程学院, 西安 710049; 2. 广州供电局有限公司电力试验研究院, 广州 510410)

摘要: 为了准确实现电磁斥力机构真空断路器的故障诊断, 针对电磁斥力机构真空断路器分闸振动信号, 在正常状态、单一故障状态、多个故障共存状态下, 通过小波包分解、希尔伯特-黄变换(HHT)提取振动信号能量熵向量, 结合特征提取方法原理分析了两种方法提取特征量的有效性, 提出了主成分分析(PCA)—支持向量机(SVM)优化模型进行故障诊断, 并验证了网格搜索算法(GSA)、粒子群算法(PSO)、遗传算法(GA)3种参数寻优算法的性能。经实验测试, PCA-SVM优化模型解决了因样本特征信息存在噪声和冗余而引起的SVM识别准确率下降的问题, 有效提升了测试样本的识别准确率和模型效率, 具有较好的诊断效果。

关键词: 电磁斥力机构; 小波包分解; 能量熵; 主成分分析; 支持向量机; 故障诊断

Research on Circuit Breaker Fault Diagnosis Method Based on Principal Component Analysis-support Vector Machine Optimization Model

FAN Hao¹, LI Xingwen¹, SU Haibo², CHEN Li¹, SHI Zongqian¹

(1. Department of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. Electric Power Test Research Institute, Guangzhou Power Supply Bureau Co., Ltd., Guangzhou 510410, China)

Abstract: In order to accurately realize the fault diagnosis of electromagnetic repulsive mechanism vacuum circuit breaker, according to the breaking vibration signal of the electromagnetic repulsion mechanism vacuum circuit breaker, the energy entropy vector of the vibration signal is extracted by wavelet packet decomposition and Hilbert-Huang transform (HHT) in the normal state, single fault state and multiple fault coexistence states, combining the principle of feature extraction method, the effectiveness of the two methods for extracting feature quantities is analyzed. A principal component analysis (PCA)-support vector machine (SVM) optimization model is proposed for fault diagnosis. The performance of three parameter optimization algorithms, namely grid search algorithm (GSA), particle swarm optimization (PSO) and genetic algorithm (GA), is verified. Through experimental tests, the PCA-SVM optimization model solves the problem of SVM recognition accuracy caused by noise and redundancy of sample feature information, which effectively improves the recognition accuracy and model efficiency of test samples, and has a good diagnostic effect.

Key words: electromagnetic repulsion mechanism; wavelet packet decomposition; energy entropy; principal component analysis; support vector machine; fault diagnosis

0 引言

直流电网的发展和直流断路器的应用需求对

机械开关及其操动机构提出了快速性、可靠性和经济性的要求^[1]。电磁斥力机构由于其结构简单、分合闸速度快^[2]的特点成为目前的研究热点, 相比于

收稿日期:2020-01-20; 修回日期:2020-03-25

基金项目:广州供电局有限公司科技项目(SF₆罐式结构真空快速开关状态监测技术研究及应用)。

Project Supported by Technology Project of Guangzhou Power Supply Bureau Co., Ltd.(Monitoring Technology Research and Application of SF₆ Gas-insulated Vacuum Fast Circuit Breaker).

其他操作机构,电磁斥力机构动作时运动部件动能大,会产生较大的操作冲击和弹跳^[1],更易对断路器造成损坏从而导致故障,但目前多围绕电磁斥力机构的研制展开研究^[3-8],因此对其进行故障检测和诊断有较大的工程实用价值。

振动信号包含了断路器整个动作过程的机械特征信号,通过对振动信号进行特征量提取可以获得断路器状态表征信息,目前国内外针对振动信号进行断路器故障诊断开展了大量研究^[9-15],但大多只是通过模拟单一故障来分析振动信号,鲜有学者研究多个故障同时存在的情况,而断路器实际运行时这种情况不可避免。基于振动信号的断路器故障诊断研究主要包括特征量提取和故障识别两个方面,特征量提取主要是对断路器非平稳振动信号进行分析以获取能够表征不同状态的信息参量,近年来,由于傅里叶变换只能适用于平稳信号的局限性,小波包分解和经验模态分解(EMD)受到了广泛关注,文[10]通过小波包分解选取各节点归一化能量值作为特征量进行故障诊断研究,实验结果表明特征量提取简单有效,文[11-12]对振动信号进行了小波包分解,并计算了信号的能量熵作为特征输入向量,实验结果显示不同状态下能量熵向量各元素具有不同的分布规律,文[13]对比分析了短时傅里叶变换、小波包分解、经验模态分解3种方法提取特征量的性能,聚类分析显示小波包能量熵能够得到与事实一致的聚类结果;文[14-17]皆采用经验模态分解将振动信号分解为相互独立的内禀模态函数(IMF),其中。文[14]计算了IMF包络的能量熵向量作为特征向量,为特征量提取提供了一种新的思路;文[15-16]利用IMF分量能量总量作为特征向量,取得了较好的诊断效果;文[17]则采用近似熵作为特征向量来表征原始信号,验证了近似熵作为振动信号特征量的有效性。总的来说,小波包分解在选定合适的基函数情况下获得的特征量可以较好地表征原始信号,具有优异的多尺度时、频分辨率,EMD可以依据信号本身的局部特征信息进行自适应地分解,具有小波分解所不具备的自适应特性。然而,一方面,不同特征量提取方法的有效性研究较少,在选择特征量提取方法时缺少理论指导;另一方面,通常小波包分解和EMD提取的特征量为人为选取的某高维向量,并非每个维度都与故障诊断密切相关,可能存在噪声和冗余,从而对后续故障识别造成干扰,降低识别准确率,因此,采用合适的方法进行特征降维与特征筛选能有效降低诊断识别的难度、减小运算量。

目前,用于断路器故障识别的方法主要有神经网络^[11,18]、人工免疫网络^[19]、支持向量机^[14-15,17,20-21],其中,神经网络需要较大的训练样本,存在局部收敛问题,不适用于小样本分类问题,人工免疫网络的网络参数选择缺乏理论指导,系统效率较低。而支持向量机基于统计学习理论,适用于小样本分类,文[14]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;文[15]采用“二叉树”支持向量机分类算法,并利用利用粒子群优化算法对支持向量机参数及核函数参数进行优化;文[17]采用采用径向基核函数及“一对一”的多分类策略构建支持向量机模型;文[20]支持向量机采用“一对其余”分类策略,通过网格搜索算法进行参数优化;文[21]以径向基函数作为支持向量机分类器核函数,采用遗传算法得到最优参数。支持向量机基本思想是利用核函数将样本映射到高维特征空间,在该空间中构造最优线性分类超平面,因此,核函数及其相关参数的选取非常重要,目前已经证实采用径向基核函数具有较好的分类效果^[14],但是不同参数寻优算法的性能还有待验证。

针对以上分析,文中首先对特征量提取方法和状态诊断方法进行了理论分析,然后以电磁斥力机构真空断路器为研究对象,研究了小波包分解能量熵、希尔伯特—黄变换(HHT)能量熵的有效性,提出了主成分分析(PCA)—支持向量机(SVM)故障诊断优化模型,验证了不同参数寻优算法的性能。经实验验证,小波包分解能量熵是一种更为有效的特征量,PCA-SVM优化模型有效提升了测试样本的识别准确率和模型效率,网格搜索算法优化SVM参数效率与识别正确率均较高。

1 振动信号特征量提取方法

小波包分解和希尔伯特—黄变换是最常用的时频分析方法,结合能量熵概念便可构造出能够表征断路器状态的特征向量,本节对特征量提取方法进行了原理分析,并给出能量熵计算流程,是实验分析的理论依据。

1.1 小波包分解

小波包分析能够为信号提供一种更精细的分析方法,它将频带进行多层次划分,并能够根据被分析信号的特征,自适应地选择相应频带,使之与信号频谱相匹配,从而提高了时—频分辨率^[11,22-23]。3层小波包分解树见图1。

图1中, $X(0,0)$ 代表原始信号,其余为小波分解各分量系数。小波包分解保持了多分辨分析中的




图1 3层小波包分解树

Fig. 1 3-layer wavelet packet decomposition tree

正交分解特性, 每一个节点分解后的两个频带互不交叠, 输出两个频带的带宽减半, 随着分解层数的增加, 频域分辨率越高, 相应地时域分辨率越低。最终, 小波包分解将原始信号 $X(0,0)$ 分解为各个不同频带内信号的组合。振动信号小波包分解可以通过以下递推公式进行计算

$$\begin{cases} u_{2n}(t) = \sqrt{2} \sum_{k \in Z} h(k) u_n(2t-k) \\ u_{2n+1}(t) = \sqrt{2} \sum_{k \in Z} g(k) u_n(2t-k) \end{cases} \quad (1)$$

式(1)中, $g(k) = (-1)^k h(1-k)$, 即两系数为正交关系。

1.2 希尔伯特-黄变换(HHT)

HHT方法的核心部分为经验模态分解(EMD)。从本质上讲EMD是对一个信号进行平稳化处理。其结果是将信号中不同尺度的波动或趋势逐级分解开来, 产生一系列具有不同尺度的数据序列, 每一个序列即为一个固有模态(IMF)分量。借助于Hilbert变换便可进一步得到信号的时-频谱图, 得到的谱图能够准确地反映出系统原有的特性。对于一个非平稳的数据信号来讲, 直接进行Hilbert变换得到的结果在很大程度上失去了原有的物理意义。而由于经EMD得到的各IMF分量都是平稳化序列, 因此基于IMF分量进行Hilbert变换后的结果能够反映真实的物理过程^[22]。

可以看出, HHT包括EMD和Hilbert变换两部分。经过EMD算法可以将非平稳信号 $s(t)$ 分解为 n 个IMF的分量和一个残量 r_n 之和, 即

$$s(t) = \sum_{k=1}^n c_k(t) + r_n(t) \quad (2)$$

式(2)中, $r_n(t)$ 为残余函数, 代表信号的平均趋势。

对于式(2)中任意一个时间序列数据 $c(t)$, 都可以通过希尔伯特变换得到 $h(t)$, 即

$$h(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{c(\tau)}{t-\tau} d\tau \quad (3)$$

由此, 可以得到实信号 $c(t)$ 的复信号 $q(t)$, 即

$$q(t) = c(t) + jh(t) \quad (4)$$

则信号的包络 $A(t)$ 为

$$A(t) = \sqrt{c^2(t) + h^2(t)} \quad (5)$$

1.3 能量熵计算

能量熵是在一定状态下对系统的一种测度, 它

是对系统无序程度的一种量度。能量熵的计算步骤如下:

首先, 将信号 $x(t)$ 按照等时间分段的方式分为 N 段, 并计算每段的能量

$$W(i) = \int_{t_{i-1}}^{t_i} |x(t)|^2 dt \quad (6)$$

式(6)中: $i = 1, 2, \dots, N$; t_{i-1} 和 t_i 分别是第 i 段的开始和结束的时间点, 然后, 对每段能量进行归一化处理, 得到能量归一化值 $q(i) = \frac{W_i}{\sum W_i}$, 则信号 $x(t)$ 的能量熵为

$$H = - \sum_{i=1}^N q(i) \lg q(i) \quad (7)$$

分别将式(1)、(5)得到的信号带到式(6)-(7)中得到小波包分解各分量以及包络 $A(t)$ 的能量熵值, 通过以上步骤, 即可获得振动信号的小波包能量熵向量和希尔伯特-黄变换能量熵向量。考虑电磁斥力机构断路器的动作特点, 后续计算时 N 选择5。

2 故障诊断方法

2.1 主成分分析(PCA)

在统计学中, PCA是一种简化数据集的技术。PCA可以有效地找出数据中最“主要”的元素和结构, 去除噪声和冗余, 将原有的复杂数据降维, 解释隐藏在复杂数据背后的简单结构。

设通过式(7)得到的断路器振动信号特征向量为 $H_k = (h^{1k}, h^{2k}, \dots, h^{nk})^T$, k 为样本数目, n 为特征向量维度, 则 H_k 的协方差矩阵为

$$R_x = \sum_{k=1}^n (x_k - \bar{x})(x_k - \bar{x})^T \quad (8)$$

式(8)中, $\bar{x} = \frac{1}{n} \sum_{k=1}^n x_k$ 为各样本特征向量均值。

求解式(8)协方差矩阵的全部特征值 λ_i 和特征向量 v_i , 然后将特征值从大到小进行排列: $\lambda_1 > \lambda_2 > \dots > \lambda_m > \dots$, 为了达到降维的目的, 选取特征值大于 λ_m 的特征向量构成主向量, 样本 H_i 投影到特征向量 v_i , 可得该方向上的主分量 $y^{ij} = v^{iT}(x_j - \bar{x})$, 则前 m 个主分量的累计方差贡献率为 $H(m) = \sum_{i=1}^m \lambda_i / \sum_{k=1}^n \lambda_k$, 文中选取累计方差贡献率 $H(m) > 95\%$, 即95%以上的原始数据信息保留在前 m 个主分量中, 利用前 m 个主分量表征原始信息, 从而去除原振动信号特征向量的噪声和冗余, 实现

降维,有利于后续SVM进行诊断。

2.2 支持向量机(SVM)

SVM是Vapnik等人根据统计学习理论中提出^[24]。SVM能提高学习机的推广能力,即在数据集有限甚至较小的情况下,仍能得测试集误差较小的判别函数,这使得SVM成为一种优秀的基于数据的学习算法。

概括地说,SVM利用核函数将原始数据映射到一个高维空间,然后在这个高维空间中求取广义的最优分类面,此最优分类面就是该支持向量机对后续输入的判断标准。SVM核函数方法原理图见图2。




图2 SVM核函数方法原理示意图

Fig. 2 Schematic diagram of the SVM kernel function method

SVM的分类过程示意图见图3。SVM在形式上类似一个神经网络,但是其判别函数中只需要计算未知向量与支持向量内积的线性组合,而非要考虑原样本中所有的向量。并且,在样本数量相同的情况下,支持向量的数量可以看出计算的复杂程度:支持向量多时,分类复杂而困难,分类效果往往也不佳。




图3 支持向量机的分类示意图

Fig. 3 Schematic diagram of the classification of support vector machines

3 实验结果分析

3.1 振动信号采集

针对电磁斥力机构真空断路器,测试时将加速度传感器固定在分闸线圈上方金属板上,在无负载分闸情况下采集正常和模拟不同故障状态断路器振动信号,数据采集系统(示波器)以1 MHz采样速率采集100 ms,共计100 000个数据点,共获得8种状态80组数据,将其中40组用于训练,40组用于预测。8种状态类别见表1,实验装置图见图4, a、b、

c、d 4种状态下断路器原始振动信号图5。由图5可以看出,电磁斥力机构断路器动作时的振动信号幅值要远大于其他类型断路器,振动信号持续时间较短,这也印证了电磁斥力机构速度快、冲击大的动作特点。

表1 状态类别表

Table 1 Status category table

状态代号	状态类别
a	正常状态
b	基座固定螺丝松动
c	缓冲器卡涩
d	控制回路电阻增加(线圈老化)
e	控制回路电压过低(85%额定电压)
f	缓冲器卡涩+控制回路电压过低(85%额定电压)
g	控制回路电阻增加+控制回路电压过低(85%额定电压)
h	缓冲器卡涩+控制回路电阻增加+控制回路电压过低(85%额定电压)



图4 实验装置图

Fig. 4 Experimental device diagram




图5 a、b、c、d 4种状态下断路器原始振动信号

Fig. 5 Original vibration signal of the circuit breaker under four states a, b, c, d

3.2 特征向量提取

文中根据第一节的理论分析,分别提取了小波包分解能量熵和希尔伯特—黄变换(HHT)能量熵两种特征向量,并分析了两种特征向量的有效性。

1)小波包分解。文中采用db10小波函数^[25-26],

考虑到数据采集系统的采样速率和振动信号的特点,采用7层小波包分解,根据第7层各频段的能量分布发现第7层前8个分解分量包含了断路器机械振动信号的主要能量,原始振动信号和第7层前8个分解系数 $X(7,0)$ – $X(7,7)$ 重构后的信号分量见图6。




图6 原始信号和 $X(7,0)$ – $X(7,7)$ 重构后信号分量

Fig. 6 Original signal and $X(7,0)$ – $X(7,7)$ reconstructed signal component

由于第7层前8个分解分量包含了断路器机械振动信号的主要能量,因此根据式(6)、(7)计算出其

能量熵向量作为特征向量,小波包分解获得的不同状态能量熵向量见表2。

表2 小波包分解获得的不同状态下能量熵向量

Table 2 Energy entropy vectors in different states obtained by wavelet packet decomposition

状态	H_1	H_2	H_3	H_4	H_5	H_6	H_7	H_8	分类标签
a	1.182 857	0.701 808	0.380 939	0.359 935	0.532 024	0.666 534	0.387 651	0.918 965	1
b	1.063 326	0.662 079	0.345 861	0.202 126	0.559 027	0.432 626	0.491 123	0.872 417	2
c	1.165 313	0.656 647	0.346 423	0.337 201	0.415 537	0.537 457	0.435 031	0.974 176	3
d	1.171 331	0.715 986	0.264 264	0.362 388	0.596 715	0.763 165	0.491 323	0.667 524	4
e	1.132 193	0.480 390	0.362 153	0.449 883	0.493 430	0.759 140	0.448 600	0.651 196	5
f	1.288 626	0.272 145	0.177 255	0.302 857	0.545 379	0.361 018	0.232 799	0.701 682	6
g	1.267 095	0.698 843	0.127 195	0.304 976	0.624 344	0.396 511	0.194 070	0.349 255	7
h	1.184 897	0.706 308	0.133 860	0.292 809	0.564 165	0.442 264	0.212 393	0.286 266	8

小波包分解获得的不同状态能量熵柱状图见图7,其正常状态下10次能量熵柱状图见图8。从图7、8可以看出,断路器11种不同状态下所获得的能量熵值至少在2–3个参数上表现出较明显区别,且同一状态下能量熵值基本一致,这说明小波包能量熵向量可以有效区分不同状态,且一致性较好,有利于分类器准确地进行样本分类。

2)希尔伯特—黄变换(HHT)。首先将断路器原始振动信号进行EMD分解,得到如式(2)所示的共12个IMF分量和一个残量,忽略残量,并且由于断路器故障信息在振动信号的高频段^[27],前8个IMF分量包含了断路器机械故障振动信号的主要信息,原始振动信号和前8个IMF分量见图9。




图7 小波包分解获得的不同状态能量熵柱状图

Fig. 7 Different state energy entropy histograms obtained by wavelet packet decomposition




图8 小波包分解获得的正常状态下10次能量熵柱状图

Fig. 8 10 energy entropy histograms in the normal state obtained by wavelet packet decomposition

表3 HHT获得的不同状态能量熵向量

Table 3 Different state energy entropy vectors obtained by HHT

状态	h_1	h_2	h_3	h_4	h_5	h_6	h_7	h_8	分类标签
a	1.557 83	0.894 37	0.818 24	0.799 67	0.335 02	0.344 29	0.438 84	0.695 27	1
b	2.168 86	1.299 66	0.829 39	0.812 91	0.599 80	0.354 08	0.412 99	0.679 81	2
c	1.395 75	0.917 46	0.732 24	0.822 70	0.410 29	0.487 72	0.329 96	0.623 19	3
d	1.520 69	0.842 75	0.973 39	0.515 45	0.354 59	0.513 26	0.978 82	0.616 14	4
e	1.917 59	1.162 07	1.023 38	0.463 08	0.425 97	0.531 80	0.299 80	0.296 17	5
f	2.086 39	1.307 81	1.089 67	0.358 45	0.362 44	0.290 69	0.195 47	0.444 01	6
g	2.677 42	2.368 63	1.869 22	1.301 21	0.160 21	0.207 99	0.311 85	0.612 58	7
h	2.703 54	2.086 34	1.803 13	1.471 66	0.170 83	0.543 21	0.726 62	0.402 27	8




图10 HHT获得的不同状态能量熵柱状图

Fig. 10 HHT obtained different state energy entropy histogram




图9 原始振动信号和前8个IMF分量

Fig. 9 Original vibration signal and the first 8 IMF components

同样由式(6)、(7)计算前8个IMF分量的能量熵向量作为特征向量, HHT获得的不同状态能量熵向量见表3。

HHT获得的正常状态下10次能量熵柱状图见图10,其正常状态下10次能量熵柱状图见图11。




图11 HHT获得的正常状态下10次能量熵柱状图

Fig. 11 10 energy entropy histograms in the normal state obtained by HHT

从图 10、11 可以看出,断路器不同状态下的希伯特黄一变换能量熵虽然表现出较明显区别,但同一状态分布十分不均匀,这种情况下可能会造成分类器误判。

3.3 故障诊断及结果分析

选用“一对一”的多分类策略,以 C-SVC 模型作为支持向量机模型,以径向基函数(RBF)作为分类器核函数,首先将表 2、3 的能量熵向量通过主成分分析(PCA)进行特征降维和特征筛选,得到最终的特征量作为 SVM 的输入,将实验数据的 40 组作为训练样本,其余 40 组作为测试样本,分别通过网格搜索算法(GSA)、粒子群算法(PSO)、遗传算法(GA)3 种算法进行参数寻优,对比分析 3 种寻优算法的性能。不同特征向量、不同诊断模型、不同参数寻优算法的诊断性能见表 4,采用小波包分解能量熵作为特征向量时,SVM 模型、PCA-SVM 模型在 GSA 算法参数寻优下的预测结果分别见图 12。

表 4 不同特征向量、不同诊断模型、不同参数寻优算法的诊断性能

Table 4 Diagnostic performance of different feature vectors, different diagnostic models, and different parameter optimization algorithms					
特征向量	诊断模型	参数寻优算法	识别准确率/%	时间/s	
小波包分解能量熵	SVM	GSA	87.5	5.186	895
		GSA	95.0	4.705	529
	PCA-SVM	PSO	92.5	9.508	594
		GA	95.0	9.954	247
HHT 能量熵	PCA-SVM	GSA	47.5	5.125	233

根据表 3 的诊断性能分析可得,只有小波包分解能量熵作为特征向量输入时,PCA-SVM 才可以较准确地判断故障类型,表明小波包能量熵是一种有效的特征向量,综合图 10/11 可得,HHT 能量熵为无效特征向量的主要原因是同一状态重复实验信号下,同一 IMF 分量包络计算的能量熵一致性较差,这也反映出同一 IMF 分量的波形分散性较大,而这正是由经验模式分解的原理所决定的;由于采用主成分分析进行特征降维和特征筛选,降低了特征向量维度,使得 PCA-SVM 诊断模型在识别准确度和效率上较 SVM 诊断模型表现更加优异;虽然文[15,21,23]在 SVM 模型中尝试了 PSO 和 GA 算法进行参数寻优,但断路器故障诊断为小样本分类问题,输入到 SVM 中的数据集包含的样本点数目一般较少,在这种情况下,利用网格搜索算法优化 SVM 参数更为理想,可以提高效率且识别正确率较高。




图 12 SVM 模型、PCA-SVM 模型在 GSA 算法参数寻优下预测结果

Fig. 12 SVM model, PCA-SVM model prediction results under GSA algorithm parameter optimization

4 结论

文中基于振动信号分析理论,以新型电磁斥力机构真空断路器为研究对象,对断路器正常状态、单一故障状态、多个故障共存状态进行研究,经过实验测试得出:

- 1)小波包分解能量熵作为特征向量具有很好的类可分性能,而经验模态分解的原理决定了同一 IMF 分量波形具有较大分散性,由此得出的特征向量可能无法区分研究对象的不同状态,这不利于 EMD 的推广应用;
- 2)主成分分析解决了因样本特征信息存在噪声和冗余而引起的 SVM 识别准确率下降的问题,形成的特征向量彼此独立成正交关系,有效提升了测试样本的识别准确率,并且缩减了时间,最终的 PCA-SVM 优化模型能够实现正常状态、单一故障状态、多个故障共存状态共 8 种状态的准确识别,识别准确度达到 95%,满足实际工程需求;
- 3)断路器故障诊断为小样本分类问题,利用 GSA 算法优化 SVM 参数能有效提高效率且识别正确率较高,而 PSO 或 GA 等复杂算法虽然在识别准确度上与 GSA 没有较大区别,但会严重降低模型效率。

参考文献:

- [1] 何俊佳,袁 召,经 鑫,等.电磁斥力机构研究综述[J]. 高电压技术,2017,43(12):3809-3818.
HE Junjia, YUAN Zhao, JING Xin, et al. Review of research on repulsion mechanism[J]. High Voltage Engineering, 2017, 43(12): 3809-3818.
- [2] 董恩源,李 博,邹积岩.超高速斥力机构与永磁机构的实验性能对比分析[J]. 高压电器,2007,43(2):125-126.
DONG Enyuan, LI Bo, ZOU Jiyan. Comparison analysis of experiment performace between high - speed repulsion mechanism and permanent magnetic mechanism[J]. High Voltage Apparatus, 2007, 43(2): 125-126.
- [3] LI Y, XIA K P, LIU W Z. Design and simulation analysis of electromagnetic repulsion mechanism[C]//IEEE International Conference on Industrial Technology. Vina del Mar, Chile: IEEE, 2010: 918-948.
- [4] BISSAL A, MAGNUSSON J, ENGDAHL G. Comparson of two ultra-fast actuator concepts[J]. IEEE Transactions on Magnetics, 2012, 48(11): 3315-3318.
- [5] OTA T, MITSUTAKE Y, HASEGAWA Y. Dynamic analysis of electromagnetic impact drive mechanism using eddy current[J]. IEEE Transaction on Magnetics, 2007, 43(4): 1421-1424.
- [6] 吴益飞,郭佳豪,杨 飞,等.直流快速开关高速斥力机构运动特性分析[J]. 高电压技术, 2018, 44(5): 1641-1650.
WU Yifei, GUO Jiahao, YANG Fei, et al. Analysis of the motion characteristics of the high speed repulsion mechanism of DC fast switch[J]. High Voltage Engineering, 2018, 44(5): 1641-1650.
- [7] 武 瑾,庄劲武,庄永华.电磁斥力机构运动特性的试验研究[J]. 海军工程大学学报, 2012, 24(6): 1-5.
WU Jin, ZHUANG Jinwu, ZHUANG Yonghua. Experimental study on motion characteristic of electromagnetic repulsion mechanism[J]. Journal of Naval University of Engineering, 2012, 24(6): 1-5.
- [8] 史宗谦,贾申利,朱天胜,等.真空直流断路器高速操动机构的研究[J]. 高压电器, 2010, 46(3): 18-22.
SHI Zongqian, JIA Shenli, ZHU Tiansheng, et al. Investigations on high-speed actuator of vacuum DC circuit breaker [J]. High Voltage Apparatus, 2010, 46(3): 18-22.
- [9] 孙 抗,刘永超.基于EEMD和马氏距离的高压断路器机械故障诊断研究[J]. 高压电器, 2018, 54(12): 43-49.
SUN Kang, LIU Yongchao. Research on mechanical fault diagnosis of high voltage circuit breaker based on EEMD and mahalanobis distance discriminant[J]. High Voltage Apparatus, 2018, 54(12): 43-49.
- [10] 齐 贺,赵智忠,李振华,等.基于多传感器振动信号融合的真空断路器故障诊断[J]. 高压电器, 2013, 49(2): 43-48.
QI He, ZHAO Zhizhong, LI Zhenhua, et al. Fault diagnosis of vacuum circuit breaker based on multi-sensor for vibration signals of fusion[J]. High Voltage Apparatus, 2013, 49(2): 43-48.
- [11] 徐建源,张 彬,林 莘,等.能谱熵向量法及粒子群优化的RBF神经网络在高压断路器机械故障诊断中的应用[J]. 高电压技术, 2012, 38(6): 1299-1306.
XU Jianyuan, ZHANG Bin, LIN Xin, et al. Application of energy spectrum entropy vector method and RBF neural networks optimized by the particle swarm in high-voltage circuit breaker mechanical fault diagnosis[J]. High Voltage Engineering, 2012, 38(6): 1299-1306.
- [12] 钟建英,刘 洋,林 莘,等.基于振动信号特征的高压断路器机械故障诊断技术研究[J]. 高压电器, 2013, 49(9): 49-54.
ZHONG Jianying, LIU Yang, LIN Xin, et al. Mechanical fault diagnosis technology research of high-voltage circuit breaker based on the vibration signal characteristic[J]. High Voltage Apparatus, 2013, 49(9): 49-54.
- [13] 李 斌,李 爽,鲁旭臣.高压断路器机械特性振动信号特征提取和故障诊断方法研究[J]. 高压电器, 2015, 51(10): 138-144.
LI Bin, LI Shuang, LU Xuchen. Research on method of feature extraction and fault diagnosis based on vibration signal for high voltage circuit breaker mechanism characteristics [J]. High Voltage Apparatus, 2015, 51(10): 138-144.
- [14] 黄 建,胡晓光,巩玉楠.基于经验模态分解的高压断路器机械故障诊断方法[J]. 中国电机工程学报, 2011, 31(12): 108-113.
HUANG Jian, HU Xiaoguang, GONG Yunan. Machinery fault diagnosis of high voltage circuit breaker based on empirical mode decomposition[J]. Proceedings of the CSEE, 2011, 31(12): 108-113.
- [15] 孙一航,武建文,廉世军,等.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, et al. 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.
- [16] 冯 英,武建文,王承玉,等.基于振动信号识别的断路器故障诊断研究[J]. 高压电器, 2017, 53(2): 1-7.
FENG Ying, WU Jianwen, WANG Chengyu, et al. Research of fault diagnosis of circuit breaker based on vibration signal recognition[J]. High Voltage Apparatus, 2017, 53(2): 1-7.
- [17] 王振浩,顾欣然,孙福军.基于EMD近似熵的高压断路器故障诊断研究[J]. 高压电器, 2017, 53(2): 1-7.

- 器故障诊断[J]. 高压电器, 2018, 54(10): 151-156.
- WANG Zhenhao, GU Xinran, SUN Fujun. High voltage circuit breaker fault diagnosis based on EMD approximate entropy[J]. High Voltage Apparatus, 2018, 54(10): 151-156.
- [18] 赵科, 杨景刚, 马速良, 等. 基于神经网络集成模型在高压断路器机械故障诊断中的应用[J]. 高压电器, 2018, 54(7): 217-223.
- ZHAO Ke, YANG Jinggang, MA Suliang, et al. Application of neural network ensemble model in mechanical fault identification of high voltage circuit breaker[J]. High Voltage Apparatus, 2018, 54(7): 217-223.
- [19] 吕超, 于洪海, 王立欣. 基于人工免疫网络的断路器在线自学习故障诊断[J]. 中国电机工程学报, 2009, 29(34): 128-134.
- LÜ Chao, YU Honghai, WANG Lixin. On-line self-learning fault diagnosis for circuit breakers based on artificial immune network[J]. Proceedings of the CSEE, 2009, 29(34): 128-134.
- [20] 刘荣海, 豆龙江, 万书亭, 等. 基于EEMD样本熵和支持向量机的高压断路器故障诊断[J]. 华北电力大学学报, 2018, 45(2): 82-88.
- LIU Ronghai, DOU Longjiang, WAN Shuting, et al. Fault diagnosis of high voltage circuit breaker based on EEMD sample entropy and support vector machine[J]. Journal of North China Electric Power University, 2018, 45(2): 82-88.
- [21] 王继锋, 唐文虎, 季天瑶. 基于振动信号的SF₆高压断路器操动机构状态监测[J]. 高压电器, 2017, 53(9): 53-59.
- WANG Jifeng, TANG Wenhui, JI Tianyao. On-line condition monitoring of operating mechanism for SF₆ high voltage circuit breakers based on vibration signals[J]. High Voltage Apparatus, 2017, 53(9): 53-59.
- [22] 龚静. 小波分析在电能质量检测中的应用研究[M]. 北京: 机械工业出版社, 2018.
- GONG Jing. Application research of wavelet analysis in power quality detection[M]. Beijing: Machinery Industry Press, 2018.
- [23] COIFMAN R R, WICKERHAUSER M V. Entropy based algorithms for best basis selection[J]. IEEE Trans. on Information Theory, 1992, 38(2): 713-718.
- [24] VAPNIK V N, LERNER A Y. Recognition of patterns with help of generalized portraits[J]. Avtomat. i Telemekh., 1963, 24(6): 774-780.
- [25] LEE D S, LITHGOW B J, MORRISON R E. New fault diagnosis of circuit breakers[J]. IEEE Trans. on Power Delivery, 2003, 18(2): 454-459.
- [26] 孙来军, 胡晓光, 纪延超. 一种基于振动信号的高压断路器故障诊断新方法[J]. 中国电机工程学报, 2006, 26(6): 157-161.
- SUN Laijun, HU Xiaoguang, JI Yanchao. A new method of fault diagnosis for high voltage circuit breakers based on vibration signals[J]. Proceedings of the CSEE, 2006, 26(6): 157-161.
- [27] 陈伟根, 邓帮飞, 杨彬. 基于振动信号经验模态分解及能量熵的高压断路器故障识别[J]. 高压电器, 2009, 45(2): 90-93.
- CHEN Weigen, DENG Bangfei, YANG Bin. Fault recognition for high voltage circuit breaker based on EMD of vibration signal and energy entropy characteristic[J]. High Voltage Apparatus, 2009, 45(2): 90-93.

樊浩(1996—), 男, 硕士研究生, 研究方向为高压电力设备状态监测及故障诊断。