

基于连续小波 Tsallis 奇异熵的航空 交流电弧故障检测

崔芮华^{1,2}, 李锋锋^{1,2}, 李英男^{1,2}, 王传宇^{1,2}

(1. 河北工业大学 省部共建电工装备可靠性与智能化国家重点实验室, 天津 300130;
2. 河北工业大学 河北省电磁场与电器可靠性重点实验室, 天津 300130)

摘要: 为了有效提取航空交流电弧故障的电流信号特征, 提出连续小波变换 Tsallis 奇异熵与极限学习机相结合的航空交流电弧故障判别新方法。对发生电弧故障线路的电流信号进行连续小波变换分解, 对获得的时频系数矩阵进行奇异值分解(SVD), 得到被测线路电流信号的 Tsallis 奇异熵, 构建特征向量, 采用极限学习机对 TSE 特征向量进行训练, 得到适用于航空交流电弧故障检测的分类模型, 应用该模型对不同负载下的特征数据进行识别分类。根据试验结果可以看出, 连续小波变换 Tsallis 奇异熵结合极限学习机能够准确识别电弧故障状态与正常运行状态。

关键词: 电弧故障; 连续小波变换; Tsallis 奇异熵; 极限学习机; 特征参量

中图分类号: TM512 **文献标识码:** B **DOI:** 10.19457/j.1001-2095.dqcd20299

AC Arc-fault Detection Based on Continuous Wavelet Tsallis Singular Entropy in Airplane

CUI Ruihua^{1,2}, LI Fengfeng^{1,2}, LI Yingnan^{1,2}, WANG Chuanyu^{1,2}

(1. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300130, China; 2. Key Laboratory of Electromagnetic Field and Electrical Apparatus Reliability of Hebei Province, Hebei University of Technology, Tianjin 300130, China)

Abstract: In order to effectively extract the current signal characteristics of aviation AC arc fault, a new fault identification method based on continuous wavelet transform Tsallis singular entropy (TSE) and extreme learning machine (ELM) was proposed. The continuous wavelet transform was performed on the current signal of the arc fault line, and the obtained time-frequency coefficient matrix was subjected to singular value decomposition (SVD) to obtain the Tsallis singular entropy of the measured line current signal, and the eigenvector was constructed. The extreme learning machine was used for the TSE. The eigenvectors were trained to obtain a classification model suitable for aeronautical AC arc fault detection. The model was used to identify and classify the feature data under different loads. According to the experimental results, it can be seen that the continuous wavelet transform Tsallis singular entropy combined with the limit learning machine can accurately identify the arc fault state and normal operating state.

Key words: arc fault; continuous wavelet transformation; Tsallis singularity entropy (TSE); extreme learning machine; characteristic parameter

近几年,随着航空电气技术发展带动自动化水平的不断提高,航空领域中的电气系统也逐渐增加,因而线缆的数量也不断增加,线缆间产生电弧故障的概率就会变大,电弧故障会导致电气

系统毁坏,影响飞机的正常运行。许多航空电气系统损坏事件显示^[1],持续电弧故障对这些事故的产生有着直接或间接的关系。对航空电弧故障准确诊断是航空电气系统安全和可靠运行的

基金项目: 河北省自然科学基金项目(E2016202106)

作者简介: 崔芮华(1962—),女,博士,教授,硕士生导师,Email:710667045@qq.com

前提。

对于一般的阻性、阻感性、阻容性负载,航空电弧故障与低压电弧故障在时域波形上有着相似特征,但两者还是有一定区别。主要是由于航空交流电源频率一般是 360~800 Hz^[2],而低压交流电源频率一般为 50 Hz,可见航空交流电弧的电源周期远小于低压交流电弧的电源周期。再加上航空电气负载种类繁多,一些负载下的故障电弧特征与一般低压交流电弧故障有所不同。因此,低压交流电弧故障检测方法不一定适用于航空交流电弧故障检测。对航空交流电弧故障检测方法的研究需要考虑更多方面的因素。

针对电弧故障检测的方法,一般通过时域、频域、时频域分析方法处理采集到的原始信号。时域分析一般通过比较相邻周期电压、电流波形^[3]、高阶累积量^[4]等统计学方法提取电弧故障特征,这种方法一般原理都不复杂,实现过程比较方便;频域分析方法一般通过 FFT 分析,比较正常周期与电弧故障周期电流、电压信号的频域信息,如各次谐波含量^[5]、间谐波含量^[6]。由于时域方法在线路中的信号存在扰动时会被干扰,从而导致识别准确率较低;而频域方法缺少时间尺度^[7],因此,既具有时间尺度又可以反映频域信息的时-频域方法得到了应用。时-频域方法一般有小波变换、短时傅里叶变换、HHT 变换^[8]等。小波变换在故障分析检测方面有较多的使用^[9]。但由于小波分解的子带之间存在频谱混叠现象,仅依靠小波变换不能有效提取电弧故障特征^[10-11]。近年来,许多学者通过将信息熵理论引入小波分解中用于故障特征提取,期待解决上述问题。

为了更加准确且智能地识别电弧故障并对其进行分类,对智能分类器的运用逐渐增加。常见的智能分类器有神经网络、模糊决策树等。目前,将智能分类器与电弧故障检测结合的案例有很多,且具有较好的识别效果^[12-15]。一般的分类器,如神经网络,存在训练速度慢、容易陷入局部最优点及过拟合等问题。支持向量机由于需要通过结合一些优化算法寻找核函数及核参数,因此限制了这种分类器的使用。极限学习机(extremely learning machine, ELM)由于其设置参数少、学习能力强、处理速度快以及效率高等特点,因此广泛应用于模式识别中^[16]。

自 Haar 提出第一个小波基以来,小波变换不断改进创新。连续小波变换(continuous wavelet

transform, CWT)对非平稳信号具有较好的分析能力^[17]。同时, Tsallis 信息熵使能量泄露和频率混叠问题得到了解决^[18]。鉴于连续小波变换(CWT)、Tsallis 奇异熵(tsallis singular entropy, TSE)和极限学习机(ELM)的优点,本文提出一种将三者相结合的航空交流电弧故障检测的方法。该方法应用连续小波变换计算发生电弧故障线路电流时域信号的时频系数矩阵,并通过 Tsallis 奇异熵提取电弧故障特征,构建特征向量。利用极限学习机学习能力以及分类能力对特征向量进行分类。

1 连续小波 Tsallis 奇异熵

1.1 连续小波变换

设 $x(t)$ 是待处理信号,则连续小波变换的时频系数矩阵可表示为

$$\begin{aligned} CWT_x(a, \tau) &= \langle x(t), \Psi_{a,\tau}(t) \rangle = \int_{-\infty}^{+\infty} x(t) \Psi_{a,\tau}^*(t) dt \\ &= \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \Psi\left(\frac{t-\tau}{a}\right) dt \end{aligned} \quad (1)$$

式中: τ 为时间参数; a 为频率参数, $a > 0$; $\Psi(t)$ 为小波函数; $\Psi_{a,\tau}(t)$ 为小波基函数。

连续小波变换通过对信号进行时间和尺度上操作,将其分解为不同尺度下的细节信号系数和逼近信号系数。

1.2 Tsallis 熵—Shannon 熵延拓

B-G 熵是一种广延熵, Shannon 熵建立在 B-G 熵的基础上,所以 Shannon 熵也会体现出 B-G 熵所具有的广延性^[18]。对任意两个相互独立的系统 A 和 B , 具有以下可加性:

$$S_s(A + B) = S_s(A) + S_s(B) \quad (2)$$

式中: $S_s(A)$ 为系统 A 的 Shannon 熵; $S_s(B)$ 为系统 B 的 Shannon 熵。

然而现实问题中,有相当一部分被测系统不具有上述可加性,即为非广延性系统。

Tsallis 熵能够较好地刻画非广延性系统的物理特性。给定一个离散概率集: $\{p(i)\}$, 条件为 $\sum_{i=1}^n p(i) = 1$, 则 Tsallis 熵可表示为

$$S_q^{(d)} = \frac{k}{q-1} \left[1 - \sum_{i=1}^n p(i)^q \right] \quad q \in \mathbf{R} \quad (3)$$

式中: k 为 Boltzmann 常数。

Tsallis 熵应用了非广延参数 q , 该参数能够很

好地体现系统的非广延程度,使系统熵 $S_q(A+B)$ 满足伪可加性:

$$S_q(A+B) = S_q(A) + S_q(B) + (1-q) \frac{S_q(A)S_q(B)}{k} \quad (4)$$

通过选择合适的 q 实现 Tsallis 熵求解,可以更加准确地度量系统内在信息。相较于 Shannon 熵, Tsallis 熵更加灵活且应用更广泛。

1.3 Tsallis 奇异熵

设被测信号经连续小波变换后生成的时频系数矩阵为 $D_{m \times n}$, 根据矩阵奇异值分解理论(singular value decomposition, SVD), 将 $D_{m \times n}$ 分解为

$$D_{m \times n} = U_{m \times m} A_{m \times n} V_{n \times n} \quad (5)$$

式中: $U_{m \times m}$ 为 $m \times m$ 维左奇异矩阵; $A_{m \times n}$ 为 $m \times n$ 维奇异值矩阵, 其对角线元素为奇异值, $V_{n \times n}$ 为 $n \times n$ 维左奇异矩阵。

对角线矩阵 A 的主对角线元素 λ_{ii} 是 $D_{m \times n}$ 的奇异值, 其中, $i=1, 2, \dots, l; l=\min(m, n)$, 且 $\lambda_{11} \geq \lambda_{22} \geq \dots \geq \lambda_{ll} \geq 0$ 。当线路中发生电弧故障时, 其信号的连续小波变换矩阵所含的特征成分就会随着相应改变, 对应的非零奇异值的多寡及大小也会有所不同。为了量化这一变化特征, 本文运用了 Tsallis 奇异熵, 其表达式为

$$W_{TSE} = \frac{1}{q-1} \left(1 - \sum_{i=1}^n \Delta P_i^q \right) \quad q \in \mathbf{R} \quad (6)$$

$$\text{其中} \quad \Delta P_i = - \left(\frac{\lambda_i}{\sum_{j=1}^l \lambda_j} \right) \log \left(\frac{\lambda_i}{\sum_{j=1}^l \lambda_j} \right)$$

式中: q 为广延参数, 本文取 $q=1.1$ 。

为了获取更为丰富的特征量样本来验证本文所提方法的识别能力, 本文随机选取了电流信号正常工作与故障状态下各 5 个周期进行 Tsallis 奇异熵特征提取, 从而生成特征向量, 作为分类器输入向量。

2 极限学习机

极限学习机的理论思路为: 假设存在 N 个任意的互不相同的样本 (x_i, y_i) , 其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbf{R}^n$, $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in \mathbf{R}^m$, 则一个基于前馈单隐层神经网络的极限学习机的模型可以统一表示为

$$f_L(x) = \sum_{i=1}^L \beta_i g(x) (w_i x_i + b_i) \quad (7)$$

若该前馈神经网络满足条件: 以零误差逼近样本 (x_i, y_i) , 则说明具有 w_i, b_i, β_i , 使下式成立:

$$f_L(x) = \sum_{i=1}^L \beta_i g(x) (w_i x_i + b_i) = y_i \quad i = 1, 2, \dots, L \quad (8)$$

可以简写为

$$H\beta = Y$$

其中 $H(w_1, \dots, w_L; b_1, \dots, b_L; x_1, \dots, x_N) =$

$$\begin{bmatrix} g(a_1 \cdot x_1 + b_1) & \cdots & g(a_L \cdot x_1 + b_L) \\ \vdots & \cdots & \vdots \\ g(a_1 \cdot x_N + b_1) & \cdots & g(a_L \cdot x_N + b_L) \end{bmatrix}_{N \times L}$$

$$Y = \begin{bmatrix} y_1^T \\ \vdots \\ y_L^T \end{bmatrix}_{N \times M}$$

式中: H 为极限学习机的隐含层输出矩阵。

从而输出权值矩阵能够由下式获取:

$$\bar{\beta} = H^+ Y \quad (9)$$

式中: H^+ 为 H 通过一些计算方法计算的广义逆矩阵。

通常采用正交投影法、正交法和奇异值分解等方法来计算矩阵的广义逆。

3 航空串联交流电弧故障实验

3.1 实验装置

本文依据 UL1699 设计了符合航空电气系统下的电弧故障发生装置, 并进行航空交流电弧故障点接触试验^[19], 其原理电路图如图 1 所示。其中电弧故障发生器的一极为固定的平头碳棒, 另一极为可移动的尖头铜棒, 利用步进电机缓慢移动调节电极间隙, 使电极间产生稳定的电弧。通过电流互感器和自制原理样机对线路电流信号进行采集, 将数据存入计算机。

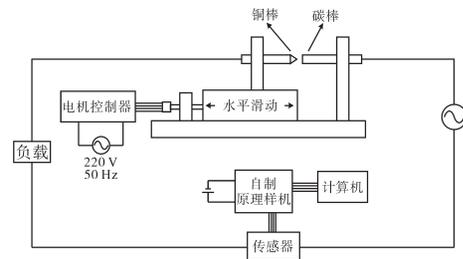


图1 点接触试验电路示意图

Fig.1 Schematic diagram of contact test circuit

3.2 实验方案

为了更好地模拟航空电气系统, 本文采用航空负载以及电阻、电容和电感进行实验, 其中负载包括自耦变压整流器(auto transformer rectifier units, ATRU)和变压器。本文设计了不同的电流等级, 丰富了数据的多样性。为提高实验数据的

准确性,减少实验发生的偶然性,需要进行多组实验并获取更多的原始数据,对同一负载同一电流等级在相同实验条件下分别进行5组试验。所采用的负载类型及电流大小如表1所示。

表1 电流大小改变的电弧实验
Tab.1 Arcing tests with different current amplitudes

	负载类型	电流大小/A
线性负载	纯阻 5 Ω	23
	纯阻 115 Ω	1
	阻感 15 Ω+5 mH	6.4
	阻感 100 Ω+5 mH	1.12
	阻容 5 Ω+23 μF	17.5
	阻容 100 Ω+47 μF	1.15
非线性负载	变压器(串联滑动变阻器)	1
	变压器(串联滑动变阻器)	0.3
	ATRU + 57.5 Ω	3.9
	ATRU + 115 Ω	2.0

3.3 串联交流电弧故障诊断流程

连续小波 Tsallis 奇异熵结合极限学习机进行故障识别的流程图如图2所示,具体操作如下:首先依据图1所示原理图,进行试验,根据3.2节中的实验方案模拟航空交流电弧故障,采用电流互感器以及原理样机采集发生电弧故障线路的电流信号;通过连续小波变换对发生电弧故障线路电流信号进行处理,得到时频系数矩阵,通过Tsallis 奇异熵提取特征样本,将其构建特征向量;最后将这些特征样本值输入到极限学习机分类器中,对线路中的工作状况进行诊断识别。

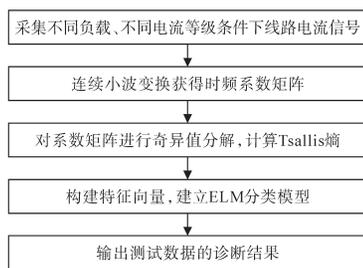


图2 故障诊断流程

Fig.2 Flow chart of fault diagnosis

3.4 电弧故障特征提取

根据表1所列的负载进行航空交流电弧故障实验,通过连续小波变换对原始电流信号处理分析,分别得到每个电流信号的连续小波时频系数矩阵。统一随机选取正常工作状态与电弧故障状态下各5个周期进行分析,由于文章篇幅限制,本文选取了具有代表性的电流信号数据:线性负载纯阻 115 Ω 和非线性负载 ATRU(一次侧电流

2.0 A)的电流波形及其连续小波时频系数矩阵等高线图,如图3所示。其中 $t=12.5$ ms时刻的竖直线是正常电流与电弧电流的分界线。

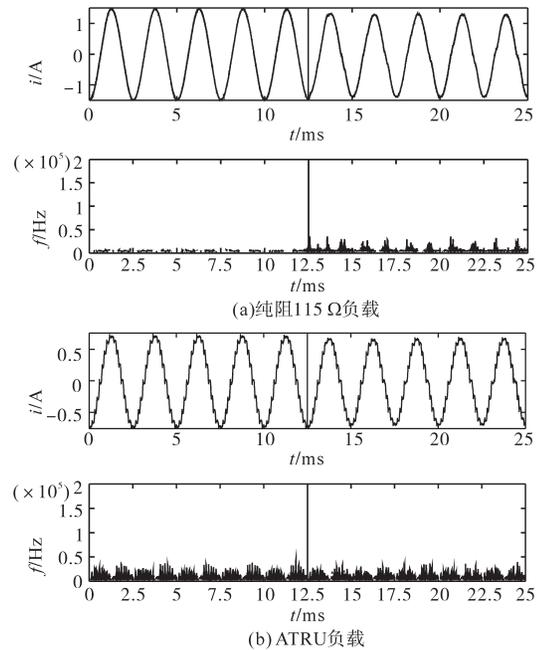


图3 部分负载电流波形及其连续小波时频系数等高线

Fig.3 Partial load current waveform and continuous wavelet coefficient contours

对比观察两组负载的连续小波时频系数等高线。由图3a可以看出,线性负载正常与电弧故障状态的时频系数等高线图区别较为明显,可以直接从时频域上观察到正常状态与电弧故障状态下的差别:航空交流电弧故障状态下,连续小波时频系数等高线峰值要高于正常状态下的峰值;图3b非线性负载正常与故障状态下的时频域特征存在很大的相似性,其电弧故障情况下没有明显的幅值变化,因此简单的依靠连续小波变换,不易于识别本负载下的航空交流电弧故障。但通过计算 Tsallis 奇异熵可以观察到故障与正常周期的熵值存在差异,从而说明了本文所采用的 Tsallis 奇异熵可以较为良好的凸显正常与故障状态下的区别。

由于连续小波变换系数矩阵维数较高且包含较多的冗余信息,直接运用分类器进行识别处理,必然会导致分类器训练时间过长,准确度降低。因此,本文采用滑动时间窗模式计算每周期电流时域信号的时频系数矩阵的 Tsallis 奇异熵,进一步构建特征向量。正常与故障各随机选取5个周期加以计算,对每个周期求取一个特征值,将所得结果列于表2中。

表2 正常电流与电弧故障的Tsallis奇异熵值
Tab.2 Tsallis singular entropy of normal current and fault current

负载 电流/A	纯阻 23	纯阻 1	阻感 6.4	阻感 1.12	阻容 17.5	阻容 1.15	变压器 1	变压器 0.3	ATRU 3.9	ATRU 2.0	
正常电流	1	7.834	7.653	7.873	7.368	7.843	7.460	7.974	7.741	8.765	8.764
	2	7.847	7.545	7.784	7.471	7.870	7.503	7.984	7.759	8.773	8.763
	3	7.873	7.533	7.693	7.693	7.770	7.682	7.858	7.752	8.781	8.764
	4	7.882	7.564	7.831	7.302	7.790	7.530	7.803	7.775	8.786	8.769
	5	7.889	7.548	7.996	7.698	7.824	7.606	7.864	7.740	8.770	8.768
故障电流	6	8.623	8.728	8.195	8.178	8.854	8.648	8.576	8.365	8.964	8.993
	7	8.635	8.645	8.292	8.237	8.777	8.755	8.643	8.387	9.011	8.998
	8	8.643	8.849	8.242	8.315	8.918	8.669	8.594	8.391	8.992	8.976
	9	8.660	8.739	8.358	8.275	8.884	8.870	8.301	8.368	8.935	8.941
	10	8.667	8.816	8.435	8.333	8.926	8.868	8.864	8.432	8.948	8.958

3.5 极限学习机故障诊断

对上文提到的10类负载分别进行3组连续小波Tsallis奇异熵的分析,各组负载下的实验数据分别可以得到5个正常周期与5个故障周期的Tsallis奇异熵值,以此来构建特征向量。对300组特征量样本进行分类并进行标记,随机选取200组特征量样本,将其输入到ELM的训练集中;剩余100组特征量样本输入到ELM的预测集中。通过实践观察,将ELM的隐含层节点数赋值为50适用于该分类模型。图4为ELM测试集的分类结果,其中正常运行状况用1表示,电弧故障状况用2表示。○代表数据实际的分类情况,*代表ELM预测分类情况。若实际情况与分类器分类情况重合代表分类正确。

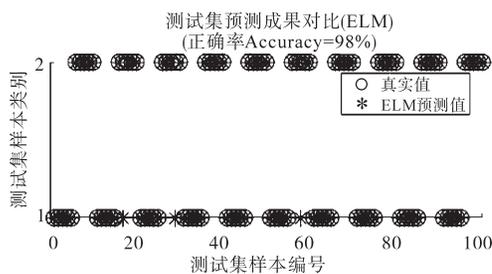


图4 电气负载特征量样本测试结果
Fig.4 Sample testing results of electrical load characteristic quantity

采用ELM对100个测试集样本进行识别分类,识别结果为:测试集误判率为2.0%,能正确识别出电弧故障与正常状态的概率为 $Ac=98\%$ (98/100),识别准确率较高。根据实验应用结果可以看出,ELM分类器能够较好地区分正常情况与电弧故障。

为寻找识别准确率高的分类器算法,本文选

择了几种常用的智能分类器算法结合3.4节中获得的特征向量进行故障识别,不同算法诊断结果如下:BP神经网络^[12]的准确率为95.85%,PSO-SVM的准确率为97.25%,ELM的准确率为98%。其中粒子群优化算法(particle swarm optimization, PSO)结合支持向量机(support vector machines, SVM)分类模型中,将初始种群规模赋值为10,最大迭代次数赋值为100,设置局部搜索参数 $c_1=1.6$,设置全局搜索参数 $c_2=1.7$,根据这些初始参数,对SVM的各个参数进行最优化解。经计算分析,得到PSO-SVM分类的准确率为97.25%。

通过以上分类器对Tsallis奇异熵进行分类处理,得到各分类器分类准确率。由不同算法诊断结果看出,应用PSO-SVM和ELM进行故障识别时,提取的特征区分效率较好。相比于SVM及其他分类器,ELM设置参数相对较少,实现较为方便且测试时间及训练时间很短,适合在线故障检测。

4 结论

为了提高航空交流电弧故障识别诊断的可靠性,本文综合运用连续小波变换,Tsallis奇异熵和ELM分类器,提取串联电弧故障特征样本并构建故障诊断多分类器,进而实现对航空交流电弧故障的识别诊断。主要结论如下:

1)Tsallis奇异熵能够较好地应对小波变换中存在的频谱混叠和能量泄露现象。利用连续小波Tsallis奇异熵对航空线路的正常工作状态与电弧故障状态进行刻画,有很好的识别效果。

2)对Tsallis小波奇异熵的非广延参数 q 的合理调节,能够更好地刻画电信号谐波的复杂度,

反映出电弧故障的特征信息。

3)本文提出的连续小波 Tsallis 奇异熵结合 ELM 电弧故障检测方法,无论在故障特征提取上,还是在分类器的性能上均具有优势。

参考文献

- [1] Barry C Brusso. History of Aircraft Wiring Arc-fault Protection[J]. IEEE Industry Applications Magazine, 2017, 23(3): 6-11.
- [2] Zeng K, Xing L, Zhang Y, *et al.* Characteristics Analysis of AC Arc Fault in Time and Frequency Domain[C]//2017 Prognostics and System Health Management Conference (PHM-Harbin), Harbin, 2017: 1-5.
- [3] 王希彬,肖楚琬,万彬,等.飞机故障电弧检测技术研究[J].飞机设计,2018,38(6):62-65.
- [4] 崔芮华,李思思,耿丽恺.3阶累积量在航空串联故障电弧检测中的应用[J].电气传动,2018,48(8):88-92.
- [5] Artale G, Cataliotti A, Cosentino V, *et al.* Arc Fault Detection Method Based on CZT Low-frequency Harmonic Current Analysis[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(5): 888-896.
- [6] 崔芮华,曹欢,耿丽恺,等.基于峭度和间谐波分析的故障电弧识别方法[J].电气传动,2018,48(10):79-84.
- [7] 吴春华,黄宵宵,李智华,等.光伏系统直流微弱电弧信号检测研究[J/OL].中国电机工程学报,2019-05-20[2019-01-28]http://kns.cnki.net/kcms/detail/11.2107.TM.20190125.1137.007.html.DOI:10.13334/j.0258-8013.Psee.181363.
- [8] Liu W, Zhang X, Dong Y, *et al.* Arc Fault Detection for AC SSPC Based on Hilbert-huang Transform[C]//IECON 2017-43rd Annual Conference of the IEEE Industrial Electronics Society, Beijing, 2017:4104-4109.
- [9] 缪希仁,郭银婷,唐金城,等.负载端电弧故障电压检测与形态小波辨识[J].电工技术学报,2014,29(3):237-244.
- [10] 孙鹏,郑志成,闫荣妮,等.采用小波熵的串联型故障电弧检测方法[J].中国电机工程学报,2010,30(S1):232-235.
- [11] Long Y, He Y, Yuan L. Fault Dictionary Based Switched Current Circuit Fault Diagnosis Using Entropy as a Preprocessor[J]. Analog Integrated Circuits and Signal Processing, 2011, 66(1):93-102.
- [12] 张士文,张峰,王子骏,等.一种基于小波变换能量与神经网络结合的串联型故障电弧辨识方法[J].电工技术学报,2014,29(6):290-302.
- [13] 韩旭,王蒙.基于遗传算法优化BP神经网络的故障电弧识别[J].测控技术,2016,35(12):21-25.
- [14] 刘晓明,赵洋,曹云东,等.基于小波变换的交流系统串联电弧故障诊断[J].电工技术学报,2014,29(1):10-17.
- [15] 杨凯,张认成,杨建红,等.基于分形维数和支持向量机的串联电弧故障诊断方法[J].电工技术学报,2016,31(2):70-76.
- [16] He Xing, Wang Hongli, Lu Jinghui, *et al.* Analog Circuit Fault Diagnosis Method Based on Preferred Wavelet Packet and ELM[J]. Chinese Journal of Scientific Instrument, 2013, 34(11):2614-2619.
- [17] 冯秋实,陈剑云,林鹏,等.基于连续小波变换的输电线路故障行波测距方法的研究[J].电测与仪表,2016,53(2):40-44.
- [18] Wu Y Q, Ji Y, Shen Y. Marine Spill Oil SAR Image Segmentation Based on Tsallis Entropy and Improved Chan Vese Model[J]. Journal of Remote Sensing, 2012, 16(4):678-690.
- [19] UL Standard for Safety for arc Fault Circuit Interrupters[S]. US-UL, 2008.

收稿日期:2019-05-21

修改稿日期:2019-07-14