

基于相关系数和偏态指标的航空串联电弧故障检测

崔芮华<sup>1,2</sup>, 王 洋<sup>1,2</sup>, 李英男<sup>1,2</sup>

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

**摘要:** 针对航空串联电弧故障的检测与识别问题,提出一种基于相关系数和偏态指标的航空电弧故障检测方法。通过提取不同负载电流信号的相关系数和偏态指标,构建二维特征量,分析对比了隐含层节点数对极限学习机性能的影响,引入灰狼优化的极限学习机进行分类识别。对阻性、阻感性、阻容性和非线性负载的大量实验结果表明,所提方法能够有效提取不同负载电弧故障特征,串联电弧故障诊断率高达98%,可为开发新型的航空电弧故障断路器提供可靠参考。

**关键词:** 串联电弧故障; 相关系数; 偏态指标; 航空故障; 极限学习机

**DOI:** 10.12067/ATEEE1805077      **文章编号:** 1003-3076(2019)01-0082-07      **中图分类号:** TM501.2

1 引言

随着自动化水平的提高,飞机上的导线数量也在增加。由于导线的老化、损坏和连接松动,容易发生电弧故障<sup>[1]</sup>。电弧故障现在已成为航空供电系统安全的主要隐患,研究航空交流电弧故障检测技术对于保证供电系统的安全性和可靠性具有非常重要的意义。

串联电弧故障诊断研究主要分为三类:①基于电弧数学模型诊断电弧故障<sup>[2]</sup>;②依据电弧的物理特性检测电弧故障<sup>[3]</sup>;③基于线路电压和电流信号的波形特征识别电弧故障<sup>[4-6]</sup>。电弧信号具有随机性强、持续时间短的特征,且负载种类繁多,正常情况与电弧故障存在相似特征,给电弧的检测带来了极大的难度。时域分析方法主要采用电流平均值、峰峰值或方差来判断电弧故障。频域研究主要基于奇、偶次谐波以及谐波分量等特性的分析<sup>[7-9]</sup>。文献[10]采用时频域分析方法,使用Mallat多尺度小波算法分析低压配电线路电弧故障,获得各尺度小波变换的小波分量,并提出了一种自适应的故障特征提取方法,但该方法存在算法相对复杂、对内存需求高的问题。

本文测试了多种线性 and 非线性负载在正常运行

及所在支路发生点接触串联电弧故障时的电流波形,并首次提出采用统计学中的相关系数和偏态指标联合建立二维特征量,建立了基于灰狼优化极限学习机(Extreme Learning Machine, ELM)的电弧故障二维特征空间分类机系统。实测结果表明,该系统正确识别率高达98%,该方法能够有效检测串联电弧故障,不易造成误判,且该方法适用于多种负载类型和电流等级。

2 航空电弧故障实验

2.1 电弧模拟实验

依据航空标准 AS5692<sup>[11]</sup>和电弧故障断路器安全标准 UL1699<sup>[12]</sup>设计点接触模拟电弧故障实验平台,其示意图如图1所示。

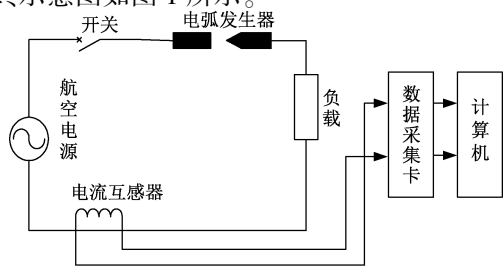


图1 点接触实验电路示意图  
Fig.1 Schematic diagram of contact test circuit

电弧发生器由固定的平头碳棒电极和可移动的尖头碳棒电极组成,利用步进电机调节电极间隙,使电极间产生稳定的电弧,线路中流过点接触串联电弧故障电流。实验采用输出电压 115V、频率 400Hz 的航空电源。选用多种负载进行实验,包括 3 种线性负载和 2 种非线性负载。每一类负载分别做大小电流两类实验。线性负载包括纯阻 (230Ω 和 10Ω)、阻感 (100Ω + 5mH 和 15Ω + 5mH)、阻容 (230Ω + 47μF 和 5Ω + 47μF);非线性负载包括变压器串联滑动变阻器 (大电流约 1A,小电流约 0.3A) 和自耦变压整流器 (ATRU),一次侧电流分别为 3.9A、2.0A。

## 2.2 实验结果

实验采集的电流信号为通过电源处的回路电流,采样频率为 400kHz。图 2 为典型线性负载 (选用纯阻 230Ω) 和非线性负载 (ATRU) 实验条件下的电流波形。其中,前 5 个周期为正常电流波形,后 5 个周期为电弧故障电流波形。




图2 由正常工作到电弧故障产生的典型电流波形图  
Fig. 2 Current waveform of classic examples from normal operation to arc fault occurring

可以看出,在图 2(a) 中,当纯阻性负载正常工作时,电流波形是较为稳定光滑的正弦波;当发生串联电弧故障时,电流幅值降低,谐波含量增加,波形发生畸变,有明显的零休现象。在图 2(b) 中,自耦变压整流器正常运行情况下,电流波形也有类似电弧电流的“零休”期,呈现出阶梯变化的趋势;当发生电弧故障时,波形产生畸变,幅值降低,零休时间

加长,随着电弧的持续燃烧畸变严重,毛刺加强。

## 3 故障特征提取

统计学中有量纲指标包括均值、方差、均方根值、峭度等,相比之下,无量纲指标只依赖于概率密度函数的形状,是一种较好的诊断参数<sup>[13,14]</sup>。根据 2.2 节实验结果,电弧故障发生时,电流信号发生畸变,使得其概率密度函数发生相应变化,因此本文采用无量纲指标,通过相关系数和偏态指标识别电弧故障。

### 3.1 相关系数

相关系数特别适用于量化两个波形之间的相似程度。 $x$  和  $y$  之间的相关系数  $r_{xy}$  定义为:

$$r_{xy} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \cdot \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (1)$$

式中

$$\begin{cases} \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \\ \bar{y} = \frac{1}{N} \sum_{i=1}^N y_i \end{cases} \quad (2)$$

$x$  和  $y$  为  $N$  个元素的信号向量。

### 3.2 偏态指标

数理统计中,偏态系数又称偏差系数,主要用来量度数据分布的不对称程度或偏斜程度。偏态的计算公式如下:

$$S = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\left[ \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \right]^{\frac{3}{2}}} \quad (3)$$

有效值定义为:

$$X_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (4)$$

偏态指标定义为:

$$PT = \left| \frac{S}{X_{rms}^3} \right| \quad (5)$$

由于偏态指标有正有负,所以采用绝对值,  $PT$  值表明了数据偏离正态分布的绝对大小。  $PT$  值越小,表明波形越接近正态,波形较稳定,畸变程度小。

### 3.3 特征提取

根据电弧故障断路器安全标准 UL1699,在航空交流线路中,当电弧故障断路器在 100ms 内察觉到

8.5 个周期的电弧故障时,断路器需要执行脱扣动作,切断电路。考虑到实验所得电弧故障持续时间短,一般为 8~10 个周期,为获取较为丰富的特征量样本来验证本文所提方法的有效性,本文选取 5 个正常周期和 5 个故障周期电流波形,分别计算采集

到的各负载电流波形  $r_{xy}$  和  $PT$  值。其中  $r_{xy}$  计算选定 1 个正常周期作为样本,然后计算其余周期同这个周期的  $r_{xy}$ ;分别计算各个周期的  $PT$  值。各负载正常电流与电弧电流计算出的相关系数和偏态指标分别如表 1、表 2 所示。其中括号中表示电流值。

表 1 负载正常电流与故障电流的  $r_{xy}$  值  
Tab. 1  $r_{xy}$  value of normal current and fault current

	编号	纯阻 (11.5A)	纯阻 (0.5A)	阻感 (5.8A)	阻感 (1A)	阻容 (11.7A)	阻容 (0.5A)	ATRU (3.9A)	ATRU (2.0A)	变压器 (1A)	变压器 (0.3A)
正常 电流	1	1	1	1	1	1	1	1	1	1	1
	2	0.999985	0.999984	0.999978	0.999989	0.99997	0.999978	0.999976	0.99999	0.99997	0.99994
	3	0.999985	0.999981	0.999978	0.999991	0.99997	0.999977	0.999971	0.99998	0.99997	0.99992
	4	0.999984	0.999979	0.999976	0.99999	0.99996	0.999951	0.99996	0.99998	0.99997	0.99993
	5	0.999984	0.999966	0.999971	0.999983	0.99996	0.999923	0.999967	0.99997	0.99996	0.9999
故障 电流	6	0.999105	0.999346	0.998481	0.998338	0.99939	0.996364	0.999806	0.99964	0.99464	0.99729
	7	0.998948	0.994921	0.998906	0.998675	0.99592	0.995344	0.998058	0.99848	0.99425	0.99759
	8	0.997879	0.995162	0.999344	0.998058	0.99535	0.995126	0.996714	0.99725	0.99023	0.99662
	9	0.997778	0.995047	0.998957	0.994312	0.99347	0.994303	0.99616	0.99725	0.97901	0.99503
	10	0.997099	0.994477	0.999143	0.986785	0.99223	0.99286	0.996242	0.99626	0.91796	0.99351

表 2 负载正常电流与故障电流的  $PT$  值  
Tab. 2  $PT$  value of normal current and fault current

	编号	纯阻 (11.5A)	纯阻 (0.5A)	阻感 (5.8A)	阻感 (1A)	阻容 (11.7A)	阻容 (0.5A)	ATRU (3.9A)	ATRU (2.0A)	变压器 (1A)	变压器 (0.3A)
正常 电流	1	0.001614	0.001101	0.000268	0.000708	0.00173	0.001576	0.002319	0.00499	0.00296	0.00994
	2	0.001301	0.00317	0.00895	0.000302	0.00439	0.000786	0.000377	0.00671	0.00213	0.00399
	3	0.000375	0.000409	0.004556	0.00025	0.00352	0.000536	0.000286	0.00336	0.00072	0.00618
	4	0.000799	0.006875	0.008192	0.003062	0.00421	0.00423	0.000309	0.00868	0.00172	0.00113
	5	0.001402	0.004171	0.008775	0.001049	0.00571	0.006602	0.00365	0.00778	0.00053	0.00045
故障 电流	6	0.087357	0.041169	0.073254	0.075684	0.07843	0.166322	0.034901	0.05547	0.04404	0.24544
	7	0.103981	0.100411	0.150763	0.052613	0.05545	0.030718	0.012147	0.00719	0.00224	0.00775
	8	0.103834	0.085693	0.066169	0.086298	0.02136	0.02054	0.013209	0.02415	0.12024	0.02252
	9	0.151362	0.025141	0.054319	0.06259	0.16959	0.015764	0.014374	0.01478	0.29854	0.18056
	10	0.16563	0.057348	0.048718	0.053749	0.07951	0.048146	0.054204	0.03338	0.08303	0.13122

3.4 数据分析

正常情况下波形相似度高,对称性良好,此时所提取的相关系数较大,偏态指标值较小;故障情况下电弧电流波形受电噪声等影响产生不同程度的畸变,相关系数有所下降,偏态指标值变大。由表 1、表 2 可以看出,负载正常工作时  $r_{xy}$  最小值为 0.9999,电弧故障时  $r_{xy}$  最大值为 0.99981;正常工作  $PT$  值最大为 0.00994,电弧故障时  $PT$  值最小为 0.00224。各负载正常与电弧故障时的特征值难以找到统一的阈值来区分,但是各负载正常与电弧故

障时所提取特征值数量级大小存在较为明显的区分。正常与故障时相关系数在  $10^{-4}$  与  $10^{-5}$  数量级有着较为明显的区分;正常与故障时偏态指标在  $10^{-2}$  与  $10^{-3}$  数量级有着较为明显的区分,尽管正常情况下由于电源频率微小波动等因素的影响, $PT$  值也变化较大,但基本稳定在  $10^{-3}$  数量级以下。由于难以找到统一的阈值直接分类,引入极限学习机分类算法对所提取特征值方法加以验证,以相关系数和偏态指标建立二维特征量对不同负载类型电弧故障进行识别。

## 4 基于灰狼算法优化的极限学习机

### 4.1 极限学习机

一个含有  $N$  个任意的不相同样本的训练样本集  $\{(\mathbf{x}_i, \mathbf{t}_i) \mid \mathbf{x}_i \in R^n, \mathbf{t}_i \in R^m, i = 1, 2, \dots, N\}$ , 隐含层节点数为  $L$ , 激励函数为  $g(\mathbf{x})$  的单隐层前馈神经网络的数学模型<sup>[15]</sup>为:

$$\sum_{i=1}^L \beta_i g(\mathbf{a}_i \mathbf{x}_j + \mathbf{b}_i) = \mathbf{t}_j \quad j = 1, 2, \dots, N \quad (6)$$

式中,  $\mathbf{a}_i = [a_{i1}, a_{i2}, \dots, a_{in}]^T$ , 为连接输入层和第  $i$  个隐含层节点的输入权值;  $\mathbf{b}_i$  为第  $i$  个隐含层节点的阈值;  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ , 为连接第  $i$  个隐含层节点和输出层的输出权值。与传统的单隐层前馈神经网络算法不同, ELM 算法输入层的输入权值和隐含层阈值不需要通过误差的反向传播进行逐步调整, 而是随机产生的<sup>[16,17]</sup>, 这样极大地提高了算法的学习速度。

式(6)可简化为:

$$\mathbf{H}\beta = \mathbf{T} \quad (7)$$

式中

$$\mathbf{H}(\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_L, \mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_L, \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N) = \begin{bmatrix} g(\mathbf{a}_1 \mathbf{x}_1 + \mathbf{b}_1) & \cdots & g(\mathbf{a}_L \mathbf{x}_1 + \mathbf{b}_L) \\ g(\mathbf{a}_1 \mathbf{x}_2 + \mathbf{b}_1) & \cdots & g(\mathbf{a}_L \mathbf{x}_2 + \mathbf{b}_L) \\ \vdots & & \vdots \\ g(\mathbf{a}_1 \mathbf{x}_N + \mathbf{b}_1) & \cdots & g(\mathbf{a}_L \mathbf{x}_N + \mathbf{b}_L) \end{bmatrix}_{N \times L}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, \quad \mathbf{T} = \begin{bmatrix} \mathbf{t}_1^T \\ \vdots \\ \mathbf{t}_N^T \end{bmatrix}_{N \times m}$$

当激励函数  $g(\mathbf{x})$  在任意区间无限可微时, 通过式(8)的最小二乘解可获得唯一的输出权值:

$$\min \|\mathbf{H}\beta - \mathbf{T}\| \quad (8)$$

式(8)的解为:

$$\beta = \mathbf{H}^+ \mathbf{T} \quad (9)$$

式中,  $\mathbf{H}^+$  为矩阵  $\mathbf{H}$  的 Moore-Penrose 广义逆。

ELM 算法的步骤归纳为:

(1) 给定一个训练集  $N = \{(\mathbf{x}_j, \mathbf{t}_j) \mid \mathbf{x}_j \in R^n, \mathbf{t}_j \in R^m, j = 1, 2, \dots, N\}$ 、激励函数  $g(\mathbf{x})$  和隐含层节点数  $L$ , 随机产生输入权值  $\mathbf{a}_i$  和阈值  $\mathbf{b}_i, i = 1, 2, \dots, N$ 。

(2) 计算隐含层输出矩阵  $\mathbf{H}$ 。

(3) 计算输出权值  $\beta = \mathbf{H}^+ \mathbf{T}$ 。

### 4.2 隐含层神经元个数的影响

虽然极限学习机克服了梯度下降算法的缺点,

但是隐含层节点数预先分配, 难以找到最优值, 而过多或过少的隐含层节点数不仅使测试集分类准确率降低而且降低了算法的泛化能力<sup>[18]</sup>。

对第2节中的10类负载分别进行3组相关系数和偏态指标特征量的提取, 每次得到正常与故障的  $r_{xy}$  和  $PT$  值各5个, 共获得300组样本。随机选取其中的200组数据作为训练样本, 其余100组作为测试样本, 采用未优化的极限学习机进行分类识别, 探讨隐含层神经元个数对分类正确率的影响。图3为隐含层神经元个数对 ELM 性能的影响。可知, 当隐含层神经元个数逐渐增加时, 测试集的分类正确率呈逐渐减小的趋势。针对这一问题, 提出了基于灰狼算法优化的极限学习机, 以期寻找到最佳的隐含层神经元个数。




图3 隐含层神经元个数对 ELM 性能的影响

Fig. 3 Influence of number of hidden layer neurons of ELM

### 4.3 灰狼优化算法

灰狼优化 (Grey Wolf Optimizer, GWO) 算法可以将整个捕猎的过程分为包围、追捕、攻击三个阶段<sup>[19]</sup>, 最终捕获猎物 (获得全局最优解)。具体算法描述如下。

#### (1) 包围

狼群在确定猎物的位置后, 首先要对猎物进行包围, 在此过程中猎物与灰狼之间的距离可表示为:

$$D = |CX_p(t) - X(t)| \quad (10)$$

$$X(t+1) = X_p(t) - AD \quad (11)$$

式中,  $D$  为灰狼和猎物之间的距离;  $t$  为迭代次数;  $X_p(t)$  为第  $t$  次迭代后猎物的位置 (即最优解的位置);  $X(t)$  为第  $t$  次迭代后灰狼的位置 (即潜在解的位置);  $A$  和  $C$  为系数因子, 其计算公式为:

$$A = 2ar_1 - a \quad (12)$$

$$C = 2r_2 \quad (13)$$

其中,  $a$  随着迭代次数的增加从2到0呈线性递减;  $r_1, r_2$  为  $[0, 1]$  间的随机数。



(2)追捕

对猎物进行包围后,β、δ 狼在 α 狼的带领下对猎物进行追捕,追捕过程中狼群个体的位置会随猎物的逃跑改变,而后可以根据 α、β、δ 更新后的位置重新确定猎物(最优解)的位置。更新方程如下:

$$\begin{cases} D_{\alpha} = |C_1 X_{\alpha}(t) - X(t)| \\ D_{\beta} = |C_2 X_{\beta}(t) - X(t)| \\ D_{\delta} = |C_3 X_{\delta}(t) - X(t)| \end{cases} \quad (14)$$

$$\begin{cases} X_1 = X_{\alpha}(t) - A_1 D_{\alpha} \\ X_2 = X_{\beta}(t) - A_2 D_{\beta} \\ X_3 = X_{\delta}(t) - A_3 D_{\delta} \end{cases} \quad (15)$$

$$X_p(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (16)$$

式中,  $D_{\alpha}$ 、 $D_{\beta}$ 、 $D_{\delta}$  分别为 α、β、δ 狼与 ω 狼(其他个体)之间的距离。

(3)攻击

攻击是捕猎过程的最后阶段,狼群对猎物进行攻击并捕获猎物,即得到最优解。该过程主要通过式(12)中  $a$  值的递减来实现,当  $a$  的值从 2 线性递减到 0 时,其对应的  $A$  值也在区间  $[-a, a]$  变化。另外,当  $A$  的取值范围在  $[-1, 1]$  时,则表明狼群的下一个位置会更加接近猎物的位置;当  $1 < |A| \leq 2$  时,狼群就会朝着远离猎物的方向分散开去,导致 GWO 算法失去最优解位置,从而陷入一个局部最优的过程。

GWO 算法步骤归纳为:

(1)初始化  $N$ 、 $D$ 、 $t$  等参数以及灰狼群体  $X = (X_1, X_2, \dots, X_N)$ , 每个灰狼的位置  $X_i = (X_{i1}, X_{i2}, \dots, X_{id})^T, i = 1, 2, \dots, N$ 。

(2)计算每个灰狼个体的适应度值  $f_i$ , 将适应度值排列前三的灰狼个体的位置分别记为  $X_{\alpha}$ 、 $X_{\beta}$ 、 $X_{\delta}$ , 并将适应度值最好的  $X_{\alpha}$  记为最优解。

(3)按照式(14)计算剩余个体 ω 与  $X_{\alpha}$ 、 $X_{\beta}$ 、 $X_{\delta}$  的距离,并根据式(15)、式(16)更新灰狼 α、β、δ 和猎物的位置。

(4)按照式(12)、式(13)更新  $a$ 、 $A$ 、 $C$  的值。

(5)若算法达到最大迭代次数  $t$ ,那么算法结束并输出最优解  $X_{\alpha}$ ;否则,返回步骤(2)。

4.4 诊断结果

文献[20]指出,狼群数量一般控制在 5~12 只,迭代次数越多,算法执行时间越长。采用试凑法确定狼群数量和迭代次数,综合考虑算法的时间复杂

度以及诊断的实时性,最终设置狼群数量为 10,最大迭代次数为 50,隐含层节点数上下界设置为  $[10, 350]$ 。从 300 组特征量样本中随机选取其中的 200 组数据作为训练样本,其余 100 组作为测试样本,以 ELM 分类错误率最小化为目标定义适应度函数,得到隐含层节点数最优值为 229。此时电气负载特征量样本测试结果如图 4 所示。其中 1 代表正常,2 代表故障;真实值代表数据实际的分类,即期望输出。若真实值与预测值重合代表分类正确。




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

此时的测试集错误率为 2.0%,串联电弧故障的准确率为 98% (98/100),达到了理想的诊断效果,表明基于灰狼优化的极限学习机能够寻找最佳隐含层节点数,从而得到较高的诊断率。

本文选取粒子群算法(PSO)、遗传算法(GA)以及灰狼算法分别对极限学习机进行参数寻优比较。同灰狼算法设置相同的种群数量、迭代次数以及隐含层节点数上下界,采用相同的特征量样本对航空电弧故障进行诊断,多次诊断结果取平均值。不同参数寻优算法诊断结果如表 3 所示。

表 3 不同算法诊断结果

Tab. 3 Diagnosis results of different algorithms			
算法	训练时间/s	测试时间/s	准确率(%)
PSO-ELM	0.063587	0.018552	97.53
GA-ELM	0.078265	0.033677	96.85
GWO-ELM	0.048115	0.014115	98.02

由表 3 可知,基于 GWO-ELM 的航空电弧故障诊断正确率最高,且测试时间和训练时间也明显优于其他两种参数寻优算法。相比 PSO-ELM、GA-ELM,GWO-ELM 有着突出优势,更适合应用于航空电弧故障检测。

## 5 结论

航空线路中发生串联电弧故障时,电流波形会发生一定的畸变,正常与故障电流波形的相关性和对称性存在一定的差异,相关系数和偏态指标可有效表征不同负载不同电流等级的特征。提取正常与故障电流波形的相关系数和偏态指标作为特征值,构建二维特征量,采用基于灰狼优化的极限学习机对电气负载电流特征量部分数据样本进行测试验证,结果显示正确分类识别率高达98%。表明该方法能够以较高的准确度有效对线路中的电弧故障进行识别,可为开发新型的航空电弧故障检测装置提供可靠参考。

## 参考文献 (References):

- [1] Nemir D, Martinez A, Diong B. Arc fault management using solid state switching [EB/OL]. <https://www.sae.org/publications/technical-papers/content/2004-01-3197/>. 2004-11-02.
- [2] 郭凤仪, 王鑫, 刘艳丽 (Guo Fengyi, Wang Xin, Liu Yanli). 基于 Mayr 模型改进的适用于串联电弧故障的新模型 (New improved model for series arc fault based on Mayr model) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2015, 34 (2): 67-71.
- [3] 陈照, 李奎, 张洋子, 等 (Chen Zhao, Li Kui, Zhang Yangzi, et al.). 基于电弧电磁辐射的故障电弧识别 (Arc fault detection based on electromagnetic radiation) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2017, 36 (3): 70-74.
- [4] 张国钢, 宋政湘, 柯春俊, 等 (Zhang Guogang, Song Zhengxiang, Ke Chunjun, et al.). 基于电流高频分量时频特征的电弧故障检测方法 (Arc fault detection method based on time frequency characteristic of high frequency current) [P]. 中国专利 (Chinese Patent): 200910218707.9.
- [5] 程红, 关晓晴, 郭立东 (Cheng Hong, Guan Xiaoqing, Guo Lidong). 串联电弧故障信号的时频特征分析 (Analysis on time frequency feature of series arc fault) [J]. 低压电器 (Low Voltage Apparatus), 2010, 18 (3): 5-7.
- [6] Yao X, Herrera L, Huang Y, et al. The detection of DC arc fault: Experimental study and fault recognition [A]. 27th Annual IEEE Applied Power Electronics Conference and Exposition [C]. Orlando, USA, 2012. 1720-1727.
- [7] Müller P, Tenbohlen S, Maier R, et al. Characteristics of series and parallel low current arc faults in the time and frequency domain [A]. 53rd IEEE Holm Conference on Electrical Contacts [C]. Charleston, USA, 2010. 1-7.
- [8] Lee Weijen, Sahni M, Methaprayoon K, et al. A novel approach for arcing fault detection for medium low voltage switchgear [J]. IEEE Transactions on Industry Applications, 2009, 45 (4): 1475-1483.
- [9] 王晓远, 高森, 赵玉双 (Wang Xiaoyuan, Gao Miao, Zhao Yushuang). 阻性负载下低压故障电弧特性分析 (Characteristic analysis of low voltage arc fault in resistive load conditions) [J]. 电力自动化设备 (Electric Power Automation Equipment), 2015, 35 (5): 106-118.
- [10] 唐金城, 缪希仁, 张丽萍 (Tang Jincheng, Miao Xiren, Zhang Liping). 基于 DSP 的低压配电线路电弧故障检测系统 (Arc fault detection on low voltage distribution line based on DSP) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2015, 34 (2): 72-75.
- [11] SAE AS5692: 2004, Arc Fault Circuit Breaker (AF-CB), aircraft, trip-free single phase 115 VAC, 400Hz-constant frequency [S].
- [12] UL Inc. UL standard for safety for arc fault circuit interrupters UL 1699 [M]. Second Edition. Northbrook: Underwriter Laboratories Inc, 2006. 16-24.
- [13] 郭庆丰 (Guo Qingfeng). 高阶统计量在滚动轴承故障诊断中的应用 (High order statistics in rolling bearing fault Diagnosis) [D]. 西安: 西安电子科技大学 (Xi'an: Xi'an University of Electronic Science and Technology), 2013.
- [14] 刘德军, 鲍光海, 孙怀平 (Liu Dejun, Bao Guanghai, Sun Huaping). 基于峰值指标和脉冲指标的串联电弧故障检测研究 (Research on fault detection of series arc based on peak index and pulse index) [J]. 电气与能效管理技术 (Electrical and Energy Management Technology), 2017, (16): 6-10, 38.
- [15] 陈绍伟, 柳光峰, 冶帅, 等 (Chen Shaowei, Liu Guangfeng, Ye Shuai, et al.). 基于蝙蝠算法优化 ELM 的模拟电路故障诊断研究 (Research for analog circuit fault diagnosis based on ELM optimized by bat algorithm) [J]. 电子测量技术 (Electronic Measurement Technology), 2015, 38 (2): 138-141.
- [16] 张英堂, 马超尹, 尹刚, 等 (Zhang Yingtang, Ma Chaoyin, Yin Gang, et al.). 基于多极限学习机在线集成的柴油机故障诊断方法研究 (Diesel engine fault diagnosis based on online ensemble of multiple extreme learning machine) [J]. 车用发动机 (Vehicle Engine), 2012, (6): 85-89.
- [17] 夏威, 张麟, 袁秋实, 等 (Xia Wei, Zhang Lin, Yuan

Qiushi, et al. ). 改进极限学习机应用于电网故障诊断 (Application of improved extreme learning machine in power system fault diagnosis) [J]. 电网与清洁能源 (Power System and Clean Energy), 2015, 31 (4): 15-19.

[18] 尹刚, 张英堂, 李志宁, 等 (Yin Gang, Zhang Yingtang, Li Zhining, et al. ). 自适应集成极限学习机在故障诊断中的应用 (Application of adaptive integrated limit learning machine in fault diagnosis) [J]. 振动、测试与诊断 (Journal of Vibration, Testing and Diagnosis), 2013, 33 (5): 897-901.

[19] Mirjalili S, Lewis A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.

[20] 白媛, 陈京荣, 展之婵 (Bai Yuan, Chen Jingrong, Zhan Zhichan). 改进灰狼优化算法的研究与分析 (Research and analysis of improved gray wolf optimization algorithm) [J]. 计算机科学与应用 (Computer Science and Application), 2017, 7 (6): 562-571.

## Aviation series arc fault detection method based on correlation coefficient and bias-normal distribution index

CUI Rui-hua<sup>1,2</sup>, WANG Yang<sup>1,2</sup>, LI Ying-nan<sup>1,2</sup>

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

**Abstract:** In response to the problem of detecting and identifying aviation series arc fault, a detection method based on correlation coefficient and bias-normal distribution index was proposed. By extracting the correlation coefficient and the bias-normal distribution index of different load current signals, the two-dimensional characteristic quantity was constructed, the influence of the number of hidden layer nodes on the performance of extreme learning machine was analyzed and compared, and the extreme learning machine for grey wolf optimization algorithm was introduced to classify and identify. Through a large number of experiments on resistive, inductive, capacitive and non-linear loads, the results show that the proposed method can effectively extract different load arc fault characteristics, and the series arc fault diagnosis rate is as high as 98%, which can provide reliable reference for developing new type of aviation arc fault detection device.

**Key words:** series-arc fault; correlation coefficient; bias-normal distribution index; aviation fault; extreme learning machine