

本文全文线上首发由
上海电机系统节能工程技术
研究中心有限公司

支持

王立宪,马宏忠,戴锋.
GIL机械故障诊断与预警技术研究.
电机与控制应用,2021,48(8):106.



SEARI
上電科

NCMS
上科电机

www.nems.com.cn

掌握电机行业制造核心技术,
辐射智能制造产业发展



科技改变未来
智慧创造价值

· 业务范围 ·



异步电机装配线



永磁电机装配线



悬挂链电机喷漆线

上海电机系统节能工程技术研究中心有限公司 www.nems.com.cn

地址: 上海市武宁路505号 手机: 18918357509 电话: 021-62574990-436

传真: 021-62163904 邮箱: wangcj@seari.com.cn

GIL 机械故障诊断与预警技术研究^{*}

王立宪¹, 马宏忠¹, 戴 锋²

(1. 河海大学 能源与电气学院, 江苏 南京 211100;

2. 国网江苏省电力有限公司检修分公司, 江苏 南京 211102)

摘 要: 为了有效诊断气体绝缘金属封闭输电线路(GIL)的机械故障, 搭建了 110 kV GIL 试验平台并设计了 3 种典型机械故障, 通过互补集合经验模态分解(CEEMD)模糊熵值与鲸鱼优化极限学习机(WOA-ELM)模型联合方法对 GIL 机械故障模式进行识别与诊断。首先, 利用 CEEMD 方法对振动信号进行分解, 引入正负白噪声组对信号进行处理, 得到含有故障信息的模态分量(IMF)。其次, 利用模糊熵计算模态分量特征值, 得到能表征故障特征的模糊熵值。最后, 结合 WOA-ELM 模型对特征向量集进行模式识别, 根据聚类结果与自适应阈值对 GIL 设备机械故障进行诊断和预警。结果表明, 利用 CEEMD 与模糊熵对 GIL 振动信号特征进行分析, 可以有效避免模态混叠和冗余噪声分量的干扰, 得到能够表征故障特征的特征值; 利用 WOA-ELM 模型可以有效实现 GIL 设备机械故障诊断与预警。

关键词: 气体绝缘金属封闭输电线路; 机械故障诊断; 互补集合经验模态分解; 模糊熵; 鲸鱼优化极限学习机

中图分类号: TM 835 文献标志码: A 文章编号: 1673-6540(2021)08-0106-08

doi: 10.12177/emca.2021.059

Research on GIL Mechanical Fault Diagnosis and Early Warning Technology^{*}

WANG Lixian¹, MA Hongzhong¹, DAI Feng²

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China;

2. Maintenance Branch Company, State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211102, China)

Abstract: In order to diagnosis mechanical faults in gas insulated transmission line (GIL) effectively, the 110 kV GIL experimental platform is built and three typical mechanical faults are designed. The joint method of complementary ensemble empirical mode decomposition (CEEMD) fuzzy entropy and whale optimization algorithm-extreme learning machine (WOA-ELM) model is used to identify and diagnose the GIL mechanical fault mode. Firstly, the CEEMD method is used to decompose the vibration signal, and the positive and negative white noise is introduced to process the signal to obtain the modal component with fault information. Secondly, the fuzzy entropy is used to calculate the eigenvalues of modal component to obtain the fuzzy entropy which can represent the fault features. Finally, the WOA-ELM model is used to recognize the eigenvector set, and the clustering results and adaptive threshold are used to analyze the fault features. The mechanical fault of GIL equipment can be diagnosed and forewarned by using the value. The results show that, combining CEEMD and fuzzy entropy to analyze GIL vibration signal can effectively avoid the interference of modal aliasing and redundant noise components, and obtain the

收稿日期: 2021-04-06; 收到修改稿日期: 2021-06-07

^{*} 基金项目: 中国博士后科学基金项目(2020M671318); 中央高校基本科研任务经费项目(B200202173); 江苏省自然科学基金青年基金项目(BK20190490); 国网江苏省电力公司重点科技项目(J2020040)

作者简介: 王立宪(1997—), 男, 硕士研究生, 研究方向为电力设备状态监测与故障诊断。

马宏忠(1962—), 男, 教授, 博士生导师, 研究方向为电力设备状态监测与故障诊断、电力系统谐波分析。

eigenvalues that can characterize the fault characteristics; using WOA-ELM model can effectively realize GIL equipment mechanical fault diagnosis and early warning.

Key words: gas insulated transmission line; mechanical fault diagnosis; complementary ensemble empirical mode decomposition (CEEMD); fuzzy entropy; whale optimization algorithm-extreme learning machine (WOA-ELM)

0 引言

随着西电东送项目不断推进、区域电力能源互联速度加快,气体绝缘输电线路(GIL)以其传输容量大、传输距离长、环境兼容性好等优点先后在中国天生桥水电站、溪洛渡水电站和苏通 GIL 综合管廊等重大电力输送建设中投运^[1-3]。文献[4]统计了 GIL 设备发生故障的原因,其中机械故障占比 2/3。因为 GIL 设备应用场合多为特高压且封闭结构,一旦发生故障将造成巨大经济损失,所以对其进行故障诊断对电能安全传输和电网稳定运行具有重大意义。

振动信号是电力设备运行时的典型表征^[5],并且具有不受电磁干扰等优点。目前国内外对于 GIL 设备机械故障的研究主要依靠在 GIL 设备外部设置加速度传感器来分析正常运行状态时 GIL 设备的振动特征,利用 GIL 外壳的振动来检测内部的电磁与绝缘故障^[6-7],而对于 GIL 设备机械故障引起的异常振动信息理论与机械故障模式诊断的研究尚不充分。文献[8]结合机电融合技术,利用 GIL 设备异常振动信号对内部的绝缘故障进行故障模式识别;文献[9]以 GIL 低频信号为研究对象,对 GIL 机械故障进行诊断,但局限于是否对故障产生进行判断,并不能对机械故障类型进行识别。

在信号分析方面,经验模态分解(EMD)在处理非平稳、非线性信号方面比传统的小波变换、傅里叶变换具有一定的优越性,但是 EMD 也存在端点效应、模式混叠等问题^[10-11]。文献[12]在传统 EMD 的方法上引入白噪声进行改进,形成了新的集合经验模态分解(EEMD)算法,解决了模式混叠效应,但引入白噪声带来了噪声集总不平均的问题。互补集合经验模态分解(CEEMD)总结了 EMD 和 EEMD 的优势,既可以在 GIL 振动信号中分解出模态信号(IMF),又避免了引入白噪声的干扰。同时,样本熵、能量熵等非线性动力学方法有很多种,文献[13-14]利用奇异熵值和能量熵

对 GIL 设备局部放电故障信号进行特征值提取,但以上方法对熵值的控制、样本尺度划分以及特征优化仍有不足之处。

针对现有 GIL 设备机械故障模式识别与诊断研究的空白与信号分析存在的问题,文中以振动信号为研究对象,对 GIL 机械故障诊断进行研究。搭建 110 kV GIL 设备试验平台,模拟螺丝松动、外力冲击和导电杆嵌入不完全 3 种机械故障,利用 CEEMD 算法对 GIL 振动信号进行分解,提取模态分量;利用模糊熵提取模态分量特征值,并通过鲸鱼优化极限学习机(WOA-ELM)对特征值向量展开聚类分析,结合自适应阈值进行故障预警,实现 GIL 机械故障有效诊断与预警。

1 试验平台与方案

1.1 试验平台

GIL 试验平台包含:GIL 试验腔体,材料为铝,导体外直径 80 mm,壳体内直径 390 mm,壳体厚度 15 mm,试验电压由 GDYT-5/100 无局放耐压试验装置进行调节;GH-313A 型振动加速度传感器,检测范围 40 Hz ~ 8 kHz (-3 dB),灵敏度 100 mV/g $\pm$ 10%;LC-01A 型弹簧冲击锤,灵敏度 4.14 pC/N,测量范围 0 ~ 5 kN;Luomk 718 Series 振动信号采集仪,正负 25 V 宽电压输入,采样频率最高 102.4 kHz。试验原理图如图 1 所示,现场试验平台如图 2 所示。




图 1 试验设置示意图

1.2 故障设计

(1) 螺丝松动。螺丝松动是诱发 GIL 设备机




图2 试验现场图

械故障最普遍的原因,试验过程中通过将盆式绝缘子固定螺丝松旋 40% 来模拟故障。

(2) 外力冲击。由于 GIL 腔体在运行时安装支架松动、以及其他腔体故障等原因会产生外力冲击进而引发振动,试验采用 LC-01A 型弹簧冲击锤模拟外力冲击故障。

(3) 导电杆嵌入未完全。在国内外对于 GIL 机械振动故障的研究之中对 GIL 导电杆嵌入未完全所引发的机械故障研究较少。而在实际工程中,由于安装工艺以及导电杆的电-热伸缩效应,在 GIL 设备的端部会出现导电杆嵌入未完全的情况,这也是引起 GIL 设备出现机械故障的主要原因,如不及时进行诊断与处理,在长期的振动下还会导致绝缘子的裂解。为模拟此故障,将端部导电杆向远离盆式绝缘子方向抽离 3 cm,形成导电杆嵌入欠完全的情况。

1.3 试验方法

(1) 在每个测量点测量正常运行状态下 GIL 设备运行的振动信号,作为对比样本。

(2) 依次设置 3 种典型故障,并测取 3 种故障状态下的 GIL 设备异常振动信号。

(3) 将正常振动信号与故障振动信号进行对比,并对故障振动信号进行特征提取与分析,实现 GIL 设备机械故障模式识别与诊断。

为避免试验的偶然性,试验时间统一测取 8 s,每种故障类型测试 12 组,单组试验重复 5 次。

2 基于 CEEMD 与模糊熵的信号特征提取

2.1 CEEMD 信号分析法

EMD 方法实际上是通过选取原始信号的极大值和极小值点进行 3 次插值求出上下包络线,

并通过求平均的方法得到模态函数与余量,但其本身存在端点效应与模式混叠的问题。文献[15]提出了一种 EEMD 分解方法,即在原始信号中加入白噪声信号,解除端点效应与模式混叠。EEMD 算法在对 IMF 信号逐次平均的过程中可以减小白噪声信号,但却不能消除白噪声对原始信号的影响,在某些情况下,剩余的白噪声信号还可能产生伪分量影响分解效果。针对 EMD 方法与 EEMD 方法的不足,文中提出了一种以 EMD 原理为基础,以白噪声信号数据分析方法为辅助的 CEEMD 方法,该方法在原始信号中加入符号相反的白噪声组,平衡 EEMD 方法中造成白噪声信号残余的问题,过程如下:

步骤(1) 对于原始信号寻求极大值与极小值点,拟合出包络线,并求出上下包络线的均值 $n(t)$ 。

步骤(2) 向原始信号中加入一定对数的白噪声辅助信号组 $s(t)$,得到重组信号:

$$\begin{bmatrix} y_1^*(t) \\ y_2^*(t) \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} x(t) \\ s(t) \end{bmatrix} \quad (1)$$

步骤(3) 利用重组信号减去 $n(t)$,得到初始模态分量 IMF1,令 $IMF1=n(t)$,重复步骤(3)。

步骤(4) 直到原始函数不能继续分解,最终得到 m 阶模态函数 IMF 和一个残差,即:

$$x(t) = \sum_{i=1}^m IMF_i + \varphi_n \quad (2)$$

2.2 模糊熵

熵常用来描述一个数据集的复杂程度,作为一种特征数据提取的非线性分析方法,模糊熵这一概念由 De Luca 等^[16]提出,其核心思想是通过模糊熵值的大小来反映数据序列集的混乱程度。由于 GIL 振动信号的非平稳、非线性的特性,并考虑相邻尺度因子个元素关系,文中利用模糊熵对其进行分析与特征值提取,过程如下:

步骤(1) 定义时间序列 $[X_i] (i=1, 2, \dots, n)$ 维数(窗)为 $l (l \leq n-2)$,将时间序列划分为 $k=n-l+1$ 个序列,得到相空间:

$$X_l(i) = [x(i), x(i+1), \dots, x(i+l-1)] - x_0(i) \quad (3)$$

式中: $x_0(i) = \frac{1}{l} \sum_{j=0}^{l-1} x(i+j)$ 。

步骤(2) 用 $k_{ij}^m (i \neq j; i, j=1, 2, \dots, n-l+1)$ 表示向量 $X_m(i)$ 与 $X_m(j)$ 间的距离:

$$k_{ij}^m = \max_{\varepsilon=1,2,\dots,l-1} \{ |x(i+\varepsilon) - x(i) - x(j+\varepsilon) - x(j)| \} \quad (4)$$

步骤(3) 引入隶属度函数,令相似容忍限度为 r :

$$B_{ij}^m = \begin{cases} 1, & k_{ij}^m = 0 \\ \exp \left[-\ln 2 \left(\frac{k_{ij}^m}{r} \right)^2 \right], & k_{ij}^m > 0 \end{cases} \quad (5)$$

步骤(4) 对所有隶属度求平均:

$$\varphi^m(l, r) = \frac{1}{l - m_j + 1} \sum_{i=1, i \neq j}^{l-m+1} B_{ij}^m \quad (6)$$

步骤(5) 定义函数:

$$C^m(r) = \frac{1}{l - m + 1} \sum_{i=1}^{l-m+1} \varphi^m \quad (7)$$

步骤(6) 扩展窗 l 至 $l+1$,重复步骤(2)至步骤(4),得到对于有限数据集的模糊熵为

$$FuzzyEn(l, r, n) = \ln C^m(r) - \ln C^{m+1}(r) \quad (8)$$

2.3 振动信号的时频特征提取

通过模拟试验测取的正常运行和 3 种 GIL 机械故障时域图谱如图 3 所示,横坐标为试验时间,纵坐标为振动加速度。

由图 3 可以看出,发生机械故障时的时域图与 GIL 正常运行时的时域图存在明显区别,证明通过振动特征对机械故障进行判断具有可行性,但 3 种故障模式难以通过时域信号进行判别,需进行信号的处理与进一步分析。由文献[17]可知,故障信息多集中于振动能量分布集中的位置,故利用 CEEMD 分解法,以导电杆嵌入未完全故障为例在 3.3~5.1 s 范围内进行信号分解,引入原信号 0.15 倍标准差正负白噪声信号 20 组,集总平均 200 次,并与 EEMD 分解方法进行对比,结果如图 4 所示。

由图 4 可以看出利用 EEMD 法分解得到的模态分量虽然可以体现部分原始信号的特征,但引入的白噪声信号不能很好地消除,导致在 IMF4~IMF7 模态分量中出现了伪分量,造成了部分无序信号,此类可视为虚假模态不能用做故障分析;利用文中 CEEMD 方法分解得到的信号,比 CEEMD 分解方法更具有规律性和有效性,能够反映异常振动信号的特征,由于引入了符号相反的白噪声信号,在分解过程中也不会出现伪分量的情况,证






图3 不同工况下 GIL 时域信号图谱

明了文中 CEEMD 分解方法的有效性,图 5 利用 Teager-Kaiser 能量算子计算 CEEMD 分解下导电杆嵌入未完全故障 6 阶模态分量能量变化率。

由能量变化率图谱可以看出,随着模态分解阶数的增加,其模态分量包含的振动能量逐渐降低,为选取特征熵值时提供参考,对于阶数较大的模态函数特征熵值,需考虑其包含的振动特征信息是否丰富再将其作为识别依据。对 GIL 设备振动信号进行模态分解后,并不能直观得出不同故障下的特征,因此文中利用模糊熵对包含正常运行和 3 种故障状态的 CEEMD 模态函数进行计算,分别得出含剩余分量在内的 7 阶模态函数的



(a) EEMD分解图



(b) CEEMD分解图

图4 EEMD与CEEMD分解对比图




图5 能量变化率图谱

模糊熵值,如图6所示。




图6 不同状态下7阶IMF模糊熵值

进行模态分解之后,信号的无序程度依次降低,模糊熵值呈下降趋势。由于不同运行状态的模态函数无序度不相同,故模糊熵值也存在差异。在图6所示的7阶模态函数模糊熵值中,2、5、6、7阶4种模态函数的模糊熵值较为接近,且5、6、7阶均为阶数较大的模态函数,不适合设为特征量进行聚类分析,文中选择差异较为明显,且阶数靠前的1、3、4阶模态函数模糊熵值作为不同运行状态下的特征值,进行故障模式识别与分类诊断。

3 基于WOA-ELM的GIL机械故障诊断

3.1 极限学习机

极限学习机(ELM)作为一种改进的单隐层前馈神经网络算法^[18-19],优势在于其中唯一需要设定的只有隐藏层节点个数,在运行过程中网络的输入权值以及隐元偏置无需人为调整,并且产生的最优解有且仅有一个。因而比BP神经网络必须反向处理权值和阈值,ELM的训练参数更少、学习速度更快、泛化性能更好,其结构图如7所示。




图7 ELM结构图

ELM的反向传播过程如下:

$$T = H\beta \quad (9)$$

式中: H 是隐藏层输出矩阵,

$$H = \begin{bmatrix} g(\omega_1 \times x_1 + b_1) & \cdots & g(\omega_L \times x_1 + b_L) \\ \vdots & \cdots & \vdots \\ g(\omega_1 \times x_D + b_1) & \cdots & g(\omega_L \times x_D + b_L) \end{bmatrix}_{D \times L};$$

T 和 β 分别为训练集目标矩阵与权重矩阵, $T =$

$$\begin{bmatrix} t_1^T \\ \vdots \\ t_D^T \end{bmatrix}_{D \times m}, \quad \beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}; m \text{ 为输出数量。}$$

在算法初始化过程中随机给定输入权值与偏置, 矩阵 H 即为确定矩阵。训练过程就是利用目标函数, 不断迭代求解非线性最小二乘解的过程, 最终结果即为 ELM 的最优权值。

3.2 鲸鱼优化算法

鲸鱼优化算法 (WOA) 是一种启发式优化算法^[20], WOA 采用随机或最佳搜索代理来模拟追捕猎物 (最优解) 行为, 并使用螺旋模拟座头鲸的泡泡网攻击机制, 与其他群优化算法相比, WOA 具有操作简便、参数调整少、优化速度快等优点。WOA 优化行为可以表述如下:

(1) 搜寻猎物。因为优化算法在搜索范围的位置是未知的, 所以 WOA 假设当前候选位置是目标猎物 (最优解), 在定义了当前搜索个体之后, 接下来的搜索行为已该猎物为基准调整搜索位置。

$$D = |CX_{\text{Best}}(n) - X(n)| \quad (10)$$

$$X(n+1) = X_{\text{Best}}(n) - AD \quad (11)$$

式中: n 为当前迭代值; A 与 C 为系数向量; $X_{\text{Best}}(n)$ 和 $X(n)$ 分别是最优解位置和当前解的位置。

(2) 气泡网攻击方式。此阶段为利用阶段, 包含包围行为和螺旋更新行为。

收缩包围机制。当迭代次数不断增加时, A 的波动范围不断降低, $A \in [-a, a]$, 当 $a \rightarrow 0$ 时, $A \in [-1, 1]$, 即新的代理位置处于原位置与最优位置之间, 经过不断迭代达到缩小猎物范围的目的:

$$\begin{cases} A = 2ar_1 - a, & r_1 \in [0, 1] \\ C = 2r_2, & r_2 \in [0, 1] \end{cases} \quad (12)$$

$$a = 2 \left(1 - \frac{n}{N_{\max}} \right) \quad (13)$$

式中: $N_{\max}$ 为最大迭代次数。

螺旋更新位置。设鲸鱼位置为 (X, Y) , 猎物

位置为 (X', Y') , 在两者之间建立螺旋等式, 模拟鲸鱼的螺旋状移动:

$$\begin{aligned} X(N+1) = & \begin{cases} X_{\text{Best}} - AD, & p < 0.5 \\ D' \cdot e^{bl} \cdot \cos(2\pi l) + X(n), & p \geq 0.5 \end{cases} \end{aligned} \quad (14)$$

式中: D' 表示鲸鱼与猎物之间的距离; b 为定义对数螺旋形状的常数, $l \in [-1, 1]$, $p \in [0, 1]$ 。

3.3 WOA-ELM 模型

为了降低 ELM 权值与阈值等参数选取的随机性, 文中利用 WOA 进行优化, 适应度函数如下:

$$f_{\text{fit}} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (15)$$

式中: m 为样本容量; y_i 为实际值; $\hat{y}_i$ 为预测值。

WOA-ELM 模型优化流程如下所示:

(1) 设置 WOA-ELM 模型参数, 初始化 ELM 可调参数, 并设置为 WOA 初始位置向量, 设置种群规模 30, 迭代 100, 利用式 (15) 计算模型预测与实际之间的均方根误差。

(2) 设置初始参数后, 计算适应度值并作为 WOA 第 1 次循环最佳结果, 大于最小适应度值则进行下一次循环, 记录每次循环中的最优适应度位置, 在每次循环中将此位置作为最优个体位置。

(3) 利用式 (14) 更新鲸鱼与猎物之间的位置和个体位置, 并重新进入下一次迭代。

(4) 保留鲸鱼的最优位置, 在满足最大位置与误差精度要求后终止循环, 将最优参数赋值 ELM。

整体故障诊断与预警流程如图 8 所示。

3.4 诊断结果分析

文中采集正常运行状态与 3 种不同机械故障下 GIL 的振动信号各 60 组, 共 240 组数据, 将所有数据利用 CEEMD 方法分解并计算模糊熵值, 将 240 组数据得到的 1、3、4 阶模态的模糊熵值按训练与检验比 4:1 的比例作为特征输入 WOA-ELM 模型进行故障诊断与预警分析, 结果如图 9 所示。

由图 9 可以看出, 在经过 CEEMD 分解与模糊熵值计算之后, GIL 4 种运行模式下的特征值在 WOA-ELM 模型中得到了较好的分类效果, 各特征向量之间聚集性较强, 只有少量特征数据出现偏移聚类中心的现象, 但各聚类簇之间未出现交叉混叠现象, 说明 CEEMD 与模糊熵结合能够




图8 故障诊断流程图




图9 诊断结果聚类

准确地计算不同故障信号的特征值,且此特征值可以作为 GIL 设备机械故障模式识别的依据;利用 WOA-ELM 模型可以很好地反映 GIL 机械故障的状态,并对状态进行分类诊断,参数寻优适应度曲线如图 10 所示。

3.5 实际应用预警分析

分别测取南京 220 kV 变电站 GIL 设备 4 种工况下的现场数据,计算得到的故障监测指标和自适应阈值如图 11 所示。

由图 11 可以看出:(1)在正常工况下,GIL 设备的故障监测指标较小且分布均在自适应阈值之下,未出现故障误预警的情况;(2)在螺丝松动工况下,GIL 故障监测指标波动明显,这是由于在螺丝松动故障状态下 GIL 设备的振动具有一定的规律性,在振幅较大处,故障监测指标已越过自适应







图10 参数寻优适应度曲线




(a) GIL正常运行状态



(b) 螺丝松动



(c) 外力冲击



(d) 导电杆嵌入未完全

图11 故障监测指标及自适应阈值

阈值,模型提出预警信息;(3)在外力冲击工况下,故障监测指标出现了高峰值,此后伴随余振出现几处指标次峰值,在故障监测指标高峰值突破

自适应阈值后,模型进行反向寻优下调自适应阈值,对外力冲击后的余振监测指标也起到了预警效果;(4)在导电杆嵌入未完全工况下,伴随 GIL 固有机机械振动,其故障监测指标逐渐增大,突破自适应阈值,模型亦提出故障预警。结合实际应用与以上分析,WOA-ELM 可以有效实现 GIL 设备的故障诊断与预警。

4 结 语

文中建立试验平台对 3 种典型 GIL 机械故障进行模拟,并利用 CEEMD 模糊熵对故障振动信号进行分解与特征提取,结合 WOA-ELM 模型对 GIL 机械故障进行分类诊断与预警,最后通过 GIL 实际运行数据验证了文中方法,得到以下结论:

(1) 利用 CEEMD 方法可以实现对振动信号的有效分解,避免了 EMD 和 EEMD 方法造成的端点效应与模态混叠等弊端。

(2) 利用信号模态模糊熵值作为特征值代入 WOA-ELM 模型可以有效对故障类型进行诊断。

(3) 通过实测证明 WOA-ELM 方法可以有效实现 GIL 设备机械故障预警,为 GIL 机械故障诊断与预警提供了新方法。

【参 考 文 献】

- [1] 黄志高. 气体绝缘金属封闭输电线路(GIL)[M]. 北京: 中国电力出版社, 2018.
- [2] 肖登明, 阎究敦. 气体绝缘输电线路(GIL)的应用及发展[J]. 高电压技术, 2017, 43(3): 699.
- [3] 李鹏, 颜湘莲, 王浩, 等. 特高压交流 GIL 输电技术研究及应用[J]. 电网技术, 2017, 41(10): 3161.
- [4] KOCH H. 气体绝缘输电线路[M]. 沈威, 译. 北京: 机械工业出版社, 2017.
- [5] 李凯, 许洪华, 陈冰冰, 等. GIS 振动机理及固有频率研究[J]. 电测与仪表, 2017, 54(3): 14.
- [6] 于卓琦, 高晋文, 王克胜, 等. 基于模态分析的 GIS 盆式绝缘子裂纹缺陷检测方法研究[J]. 电测与仪表, 2020, 57(16): 23.
- [7] 臧旭, 马宏忠, 吴金利, 等. 基于改进集总经验模态近似熵的 GIS 放电故障诊断[J]. 高压电器, 2020, 56(6): 129.
- [8] BAOWEN L, HONGZHONG M, PING J, et al. Partial discharge diagnosis by simultaneous observation of discharge pulses and vibration signal [J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2017, 24(1): 288.
- [9] 蒋龙, 臧春艳, 胡学深, 等. 基于低频振动信号的 GIL 机械故障诊断[J]. 电力科学与技术学报, 2019, 34(3): 86.
- [10] 张若兵, 金森, 杜钢. 基于 EMD 与 DTW 算法的振荡波下电缆局部放电定位方法[J]. 高电压技术, 2020, 46(1): 273.
- [11] LAW L S, KIM J H, LIEW W Y H, et al. An approach based on wavelet packet decomposition and Hilbert-Huang transform (WPD-HHT) for spindle bearings condition monitoring [J]. Mechanical Systems and Signal Processing, 2012, 33: 197.
- [12] 马宏伟, 张大伟, 曹现刚, 等. 基于 EMD 的振动信号去噪方法研究[J]. 振动与冲击, 2016, 35(22): 38.
- [13] 唐炬, 董玉林, 樊雷, 等. 基于 Hankel 矩阵的复小波-奇异值分解法提取局部放电特征信息[J]. 中国电机工程学报, 2015, 35(7): 1808.
- [14] 罗沙, 田宇, 李宾宾, 等. 基于尺度-能量熵特征对的特高频局部放电辨识方法[J]. 电力工程技术, 2019, 38(4): 152-158.
- [15] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1.
- [16] DE LUCA A, TERMINI S. A definition of non-probabilistic entropy in setting of fuzzy set theory[J]. Information Control, 1971, 20: 301.
- [17] MA H, LIU B, XU H, et al. GIS mechanical state identification and defect diagnosis technology based on self-excited vibration of assembled circuit breaker [J]. IET Science Measurement & Technology, 2020, 14(1): 56.
- [18] 王亚萍, 周蓓, 白健弘, 等. 基于 PLS-ELM 的滚动轴承性能衰退预测[J]. 振动. 测试与诊断, 2020, 40(2): 397.
- [19] SAADTA B, RAHMAT H, MOEIN P. Short term electric load forecasting by wavelet transform and grey model improved by PSO (particle swarm optimization) algorithm [J]. Energy, 2014, 72(7): 434.
- [20] 王坚浩, 张亮, 史超, 等. 基于混沌搜索策略的鲸鱼优化算法[J]. 控制与决策, 2019, 34(9): 1893.