

基于MPE和改进K-means算法的分接开关机械故障诊断方法

马宏忠¹, 徐艳², 魏海增¹

(1. 河海大学能源与电气学院, 南京 211100; 2. 国网安徽省电力有限公司滁州供电公司, 安徽 滁州 239000)

摘要: 随着有载调压变压器在电网应用的增多以及有载分接开关(on-load tap-changer, OLTC)频繁地调节, 分接开关的故障率在不断增加。为更有效进行OLTC机械故障诊断, 提出一种基于MPE和改进K-means算法的OLTC机械故障诊断方法。首先, 模拟OLTC的不同机械故障, 采集振动信号; 其次, 为实现非线性振动信号下OLTC的故障诊断, 采用多尺度排列熵(MPE)进行OLTC机械故障状态的特征提取; 再次, 采用粒子群(PSO)优化的K-means聚类算法诊断OLTC机械故障; 最后, 将该方法用于OLTC的机械故障诊断, 并与传统K-means算法以及BP网络的诊断效果进行对比。结果表明, 提出的基于MPE和改进K-means算法适用于OLTC机械故障诊断, 诊断效果优于传统K-means算法以及BP网络, 且其稳定性较高。

关键词: OLTC; K-means算法; 粒子群优化的K-means算法; 多尺度排列熵

Mechanical Fault Diagnosis of On-load Tap Changer Based on MPE and Improved K-means Algorithm

MA Hongzhong¹, XU Yan², WEI Haizeng¹

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China; 2. Chuzhou Power Supply Company, State Grid Anhui Electric Power Company, Anhui Chuzhou 239000, China)

Abstract: A mechanical fault diagnosis method of on-load tap-changer (OLTC) is proposed based on MPE and improved K-means algorithm. First, different mechanical faults of OLTC are simulated, and the vibration signals are collected. Second, in order to realize the fault diagnosis of OLTC under nonlinear vibration signals, the multi-scale permutation entropy (MPE) is used to extract the features of OLTC mechanical fault state. Third, the K-means clustering algorithm optimized by particle swarm is used to diagnose the mechanical fault of OLTC. Finally, the proposed method is applied to the mechanical fault diagnosis of OLTC, and is compared with the methods based on traditional K-means algorithm and BP neural network. The results show that the proposed diagnosis method based on MPE and improved K-means algorithm is suitable for mechanical fault diagnosis of OLTC, and it has high stability and better diagnosis effect than the both methods based on traditional K-means algorithm and BP network.

Key words: on-load tap changer; K-means algorithm; particle swarm optimized K-means algorithm; multi-scale permutation entropy

0 引言

随着有载调压变压器在电网应用的增多, 有载分接开关(on-load tap-changer, OLTC)的故障也在增

加。现有OLTC的故障率高且呈上升趋势, 国内外平均统计数据表明, OLTC的故障占变压器故障的20%以上^[1]。例如, 近几年, 江苏省南京市在运的536台变压器共发生严重及以上故障217起, 变压器分接

收稿日期: 2020-02-06; 修回日期: 2020-04-17

基金项目: 国家自然科学基金项目(51577050); 国网江苏省电力有限公司2018年重点科技项目(J2018063)。

Project Supported by National Natural Science Foundation of China(51577050), State Grid Jiangsu Electric Power Company Key Science and Technology Project in 2018(J2018063).

开关故障 72 起, 占比 33.2%。经分析, 机械故障是有载分接开关的主要故障。若及时发现和处理, 其故障会严重破坏 OLTC 和变压器的固有结构, 影响电力设备和系统的正常安全运行并造成严重后果。因此, 为了确保分接开关安全可靠地运行, 有必要开展分接开关机械故障诊断方法的相关研究。

有载分接开关作为一种带电切换的机械动合部件, 在其切换过程中, 会产生振动信号, 这些振动信号包含着丰富的设备状态信息。目前, 基于振动信号分析已成为 OLTC 机械故障诊断的重要手段。已有的振动信号分析方法有小波奇异性检测^[2]、自组织映射法^[3-4]、EMD^[5-6]和小波包^[7]等。这些方法大多是将非平稳信号分解为若干个简单的平稳信号之和, 然后对每个分量进行处理, 提取时频特征。然而, 研究表明, OLTC 切换过程中的振动信号表现出明显的非线性行为, 采用时频分析的方法, 将信号分解为平稳信号, 难免有一定的局限性。

针对 OLTC 机械振动信号的非线性特点, 文中从 OLTC 振动信号的时间序列随机性和动力学突变特性出发, 将多尺度排列熵应用于 OLTC 的故障特征的提取, 在 MPE 提取故障特征的基础上, 结合基于 PSO 的 K-means 算法, 提出一种基于 MPE 和改进 K-means 的有载分接开关机械故障诊断方法, 并将其应用于 OLTC 实验数据的分析。

1 OLTC 振动信号的 MPE

1.1 排列熵算法

排列熵(PE)是 Bandt 等提出的一种检测时间序列复杂程度和动力学突变的方法^[8], 具有算法简单, 抗噪声能力强, 计算速度快等优点, 其具体的算法如下^[9-11]。

假设一组时间序列 $\{x_i | i = 1, 2, \dots, N\}$, 对其进行相空间重构, 得到

$$X_i = [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}] \quad (1)$$

式(1)中: m 为嵌入维数; τ 为延迟时间。将 X_i 中的 m 个数据点按升序排列, 即 $X_i = [x_i | x_i < x_{i+r_1\tau} < \dots < x_{i+r_m\tau}]$ 。当存在 $x_{i+r_j\tau} = x_{i+r_k\tau}$ 时, 按 r 的大小进行排列, 若 $r_j < r_k$, 则 $x_{i+r_j\tau} < x_{i+r_k\tau}$ 。

任意 X_i 都有 $m!$ 中排列方式, 对任一种排列方式 ω , $T(\omega)$ 表示其出现的次数, 则其出现的概率为

$$P(\omega) = \frac{T(\omega)}{N - (m-1)\tau} \quad (2)$$

于是, 排列熵可定义为

$$H_{PE} = -\sum P(\omega) \ln P(\omega) \quad (3)$$

归一化后得到

$$PE = \frac{H_{PE}}{\ln(m!)} \quad (4)$$

PE 值的大小反映了时间序列信号的复杂性和随机性, 其值越大, 说明时间序列信号越复杂, 反之, 则越规则。因此, PE 值的变换反映和放大了时间序列的局部细微变换。

1.2 多尺度排列熵算法

多尺度排列熵的定义是由 Aziz 在多尺度算法的基础上提出的, 是在多个尺度上计算时间序列的排列熵。具体步骤如下^[12-14]:

1) 对时间序列 $\{x_1, x_2, \dots, x_N\}$ 进行粗粒化处理, 根据式(5)构造出多尺度时间序列

$$\{y_j^{(s)}\} = \frac{1}{s} \sum_{i=(j-1)s+1}^{js} x_i \quad 1 \leq j \leq \frac{N}{s} \quad (5)$$

式(5)中: s 为尺度因子; N 为原始时间序列的长度。

2) 在对原始时间序列粗粒化处理后, 计算各粗粒度时间序列的排列熵。

利用多尺度排列熵进行特征提取时, 嵌入维数 m 、延迟时间 τ 和尺度因子 s 会直接影响计算结果^[15]: 如果 m 过小, 重构的向量中包含的状态量少, 算法失去意义, 如果 m 取值过大, 相空间的重构将会均匀化时间序列, 此时不仅计算时间长, 而且也无法反映序列的细微变换, Bandt 建议, 嵌入维数 m 取 3~7; 延迟时间 τ 对序列的计算影响较小, 文中选择 $\tau = 1$; 而尺度因子 $s > 10$ 时, 系统不同尺度下的动力学变化规律才会表现出来^[16], 文中 s 取 12。

对 OLTC 正常信号进行不同嵌入维数的 MPE 计算, 结果表明, 当 m 为 3、4、5、6 时, 多尺度排列熵的取值范围较小, 分别为 0.338 9、0.412 6、0.436 4、0.470 3, 而当 $m = 7$ 时, 取值范围为 0.608 5, 这主要是因为 m 取值过小时, 重构的向量中包含的状态信息较少, 不能完全反映出信号的特征。因此, 文中 MPE 的嵌入维数取值 7。

2 基于 PSO 优化 K-means 的算法

K-means 算法用数据到各聚类中心的距离来表示数据间的相似, 距离越小, 相似度越高, 是一种常见的聚类算法, 具体算法步骤见文[17-18]。但 K-means 算法也存在对初始聚类中心比较依赖、容易收敛到局部最优解等不足之处^[19]。文中针对 K-means 算法的缺点, 采用粒子群算法对 K-means 聚

类算法进行优化。

PSO算法中粒子根据自身经验(个体最优位置)和群体共享的社会经验(群体最优位置)改变速度和位置朝全局最优解的方向飞行^[20-21]。针对K-means算法受初始聚类中心影响易陷入局部极小值的缺点,结合PSO算法全局自适应搜索的优点^[22-23],可以提高K-means聚类的准确率。

定义①粒子群中第*i*个粒子在*n*维空间的位置表示为 $x_i=(x_{i1},x_{i2},\cdots,x_{in})$,速度 $v_i=(v_{i1},v_{i2},\cdots,v_{in})$;②粒子群中第*i*个粒子在*n*维空间经历过的最好位置 $p_i=(p_{i1},p_{i2},\cdots,p_{in})$;③整个粒子群经历过的最好位置 $g=(g_1,g_2,\cdots,g_n)$;④粒子更新自身速度和位置的公式为:

$$v_i(t+1)=\omega v_i(t)+c_1 \times r_1 \times (p_i-x_i)+c_2 \times r_2 \times (g-x_i) \quad (6)$$

$$x_i(t+1)=x_i+v_i(t+1) \quad (7)$$

式(6)、(7)中:*t*是表示迭代次数的变量; ω 为惯性权重系数;常数 c_1 、 c_2 为学习因子; r_1 、 r_2 为均匀分布在[0,1]范围中的随机数。

⑤适应度函数计算公式为 $f(x)=1/d_{\max}(x_i,x_j)$,其中 $d_{\max}(x_i,x_j)$ 是点 x_i 与聚类点 x_j 之间的距离的最大值。

基于PSO的K-means聚类算法描述如下:输入待聚类数据集、聚类数目*k*以及最大迭代次数*M*;输出聚类数据集的聚类中心不再变化的*k*个聚类划分。算法的步骤如下^[24]:

- 1)将数据集均分为*k*个聚类,每个类为一个粒子群,随机设定每个粒子的初始位置 x_i 和初始速度 v_i ;
- 2)根据式(6)、(7)更新粒子的速度和位置;
- 3)计算每个粒子的适应度值;
- 4)比较每个粒子的适应度值与它经历过的最好位置 p_i 的适应度值,如果适应度值更大,则用当前粒子的位置和适应度值更新 p_i 和 p_i 的适应度值;
- 5)比较每个粒子的适应度值与整个粒子群经历过的最好位置 g 的适应度值,如果适应度值更大,则用当前粒子的位置和适应度值更新 g 和 g 的适应度值,记录数据集中该位置的下标;
- 6)根据公式更新每个粒子的速度和位置;
- 7)直到达到最大迭代次数*M*,终止粒子群的迭代并将对应的聚类中心作为K-means算法的初值,否则转2)继续迭代执行;
- 8)从*k*个初始聚类中心出发,运用K-means算法进行聚类。

3 OLTC机械故障诊断方法

分接开关不同故障状态,切换过程中的振动信号将发生变化,可利用振动信号随机性的变化来反映其工作状态,再根据各工作状态随机性的相似性进行OLTC机械故障诊断。MPE是一种能很好反映时间序列随机性的算法,文中在提取分接开关MPE的基础上,采用PSO优化的K-means算法对OLTC机械运行状态进行聚类。其机械故障诊断原理见图1。




图1 OLTC机械故障诊断流程


Fig. 1 OLTC mechanical fault diagnosis process

4 实验数据采集


文中采用CMIII-500-63B-10193W型分接开关,见图2(a)。此分接开关为三相Y连接,最大的分接位置数为19。振动传感器采用分辨率高且抗干扰能力强的LC0151型压电式加速度传感器。实验时考虑到振动信号的传播介质以及传播过程的阻尼,文中把振动传感器安装在分接开关的顶端,如图2(b)中A点所示,此位置所拾取的振动信号高频衰减比较少,信号较完整。

触头松动及弹簧性能下降作为有载分接开关主要故障之一,对其振动信号进行分析,具有一定的实践意义,因此文中实验室模拟OLTC这两种机械故障,通过Nicolet数据采集仪将采集到的振动信号转化为数字信号,存储到计算机中。分接开关的操作振动信号的主要频率集中在20 kHz以内,根据采样定理,并考虑到一定的裕度,采样频率设为50 kHz。

OLTC振动信号的原始信号见图3,从上到下依次为正常信号、触头松动以及弹簧性能下降,由图3可知,振动信号从时域上难以形成确定的判据,因此需要研究能取作OLTC机械故障指纹的特征矢量。



(a) 有载分接开关



(b) 振动传感器安装位置

图2 有载分接开关实验

Fig. 2 The experiment of OLTC

5 实验数据分析

文中对 OLTC 的 3 种机械状态(正常,触头松动,弹簧性能下降)进行 MPE 特征提取, OLTC 处于 3 种机械运行状态下的 MPE 见图 4。由图 4 可知,正常与故障状态下的单尺度排列熵差异不大,因此文中采用多尺度分析,其中多尺度排列熵参数选取为 $m=7, \tau=1, s=12$ 。此外,正常状态下的 MPE 明显高于故障状态,充分表现了信号的动力学规律。因此, PE 值的变化很好地反映了 OLTC 机械故障程度。




图3 3种状态下的振动信号

Fig. 3 Vibration signals under three conditions




图4 3种状态下的MPE

Fig. 4 MPE under three conditions

文中每种机械运行状态采集 5 组数据,共 15 组数据。限于篇幅,OLTC 处于 3 种机械运行状态下的部分 MPE 见表 1。表 1 中:1 表示正常状态;2 表示触头松动;3 表示弹簧性能下降。分别采用传统 K-means 和 PSO 优化的 K-means 对这 15 组特征量进行聚类,并比较其聚类效果。其中,最大迭代次数设置为 200,类别数为 3。

表1 3种状态下的MPE值

Table 1 MPE under three conditions

序列	1	2	3	4	5	6	7	8	9	10
MPE	0.328 8	0.336 5	0.257 8	0.264 5	0.252 8	0.299 5	0.304 7	0.300 2	0.296 1	0.293 2
	0.516 4	0.530 3	0.395 3	0.399 7	0.389 6	0.453 4	0.459 1	0.459 1	0.460 6	0.445 3
	0.627 6	0.638 6	0.477 8	0.484 6	0.478 0	0.540 4	0.544 5	0.544 5	0.541 7	0.532 4
	0.691 2	0.711 6	0.541 5	0.536 8	0.549 8	0.598 7	0.591 9	0.591 9	0.593 6	0.586 3
	0.738 5	0.759 1	0.602 2	0.598 0	0.601 5	0.630 1	0.632 7	0.632 7	0.635 1	0.629 3
	0.781 0	0.809 3	0.647 9	0.636 9	0.655 5	0.676 1	0.666 4	0.666 4	0.679 2	0.669 4
	0.809 6	0.835 4	0.691 9	0.684 7	0.694 5	0.713 0	0.695 3	0.695 3	0.703 9	0.692 1
	0.833 8	0.849 0	0.722 4	0.717 6	0.725 8	0.732 7	0.713 6	0.713 6	0.729 0	0.724 1
	0.860 6	0.871 8	0.755 2	0.758 0	0.761 5	0.766 1	0.744 2	0.744 2	0.763 8	0.744 5
	0.887 1	0.912 0	0.801 1	0.807 0	0.795 9	0.786 7	0.795 3	0.795 3	0.802 7	0.800 1
类别	0.920 8	0.918 8	0.842 3	0.836 5	0.822 9	0.837 7	0.835 8	0.835 8	0.834 2	0.823 7
	0.937 3	0.944 5	0.867 4	0.872 5	0.848 3	0.865 4	0.855 9	0.855 9	0.869 1	0.865 7
类别	1	1	2	2	2	3	3	3	3	3

受初始化聚类中心的影响,对同样的样本进行多次K-means聚类,会出现多种聚类结果,为了观察K-means算法聚类的稳定性,文中对15组特征量进行重复多次聚类。以 $s=1$ 时的排列熵为长度, $s=2$ 时的排列熵为宽度构成的聚类散点图见图5、6,15组数据点在散点图中的位置不变,经聚类后,会给每个数据点分配不同的颜色,通过颜色种类即可判断分接开关的机械运行状态。




图5 K-means聚类结果

Fig. 5 K-means clustering result

传统K-means算法对分接开关15组特征量进




图6 改进K-means算法聚类结果

Fig. 6 Improved K-means clustering result

行聚类的部分聚类效果散点图见图5,其中,4张小图为其对同样的15组特征量不同次聚类的结果。由图5可知,采用传统K-means算法对15组特征量进行多次聚类,每次聚类后分接开关3种机械状态分配的颜色不同,也即出现了多种聚类结果,聚类不稳定。且由图5的第4个聚类结果图可知,弹簧性能下降和触头松动的10组数据点聚类出同样的颜色,而正常状态的5组数据点聚类出2种颜色,聚类出错。因此,传统K-means对其聚类效果不好,且其稳定性差,无法根据聚类结果诊断分接开关机械运行状态。

粒子群算法具有全局自适应搜索的优点,可以快速地搜索到K-means算法所需的初始聚类中心,使其聚类结果具有一定的稳定性。经PSO优化后的K-means算法聚类效果散点图见图6。结果表明,经过多次聚类,其聚类结果散点图都见图6,也即只出现一种聚类结果,每种颜色代表固定的OLTC机械状态,可通过分类颜色直观地判别OLTC的机械状态。因此,PSO优化的K-means具有一定的稳定性,且聚类效果好。

为了检验PSO优化的K-means聚类算法在小样本数据故障诊断中的优势,将其与常用的BP网络进行诊断效果比较。采用同样的15组数据对BP网络进行训练,并对这15组数据进行预测。预测结果表明,BP网络迭代步数比改进K-means聚类算法多,且前者预测结果出错,输出的数据之间差异小,预测结果可能存在误判的情况。

6 结论

文中针对OLTC振动信号的非线性,提出MPE非线性分析方法用于OLTC机械故障特征提取,在此基础上采用PSO优化的K-means算法进行聚类。研究结果表明:

1)单尺度排列熵表征OLTC振动信号特征的能

力有限,文中采用多尺度排列熵进行 OLTC 机械故障特征提取,参数设置为 $m=7, \tau=1, s=12$, 可以形成明显的判据;

2)运用 PSO 优化的 K-means 算法对有载分接开关 MPE 特征量进行聚类,其聚类效果优于传统 K-means 聚类算法,具有较高的准确性和较好的稳定性;

3)在小样本数据故障诊断中,PSO 优化的 K-means 算法优于 BP 网络,具有较好的诊断能力。

参考文献:

- [1] 周 翔,王丰华,傅 坚,等. 基于混沌理论和 K-means 聚类的有载分接开关机械状态监测[J]. 中国电机工程学报,2015,35(6): 1541-1548.
ZHOU Xiang, WANG Fenghua, FU Jian, et al. Mechanical condition monitoring of on-load tap changers based on chaos theory and K-means clustering method[J]. Proceedings of the CSEE, 2015, 35(6): 1541-1548.
- [2] 张伟政,施琳琛,汲胜昌,等. 小波奇异性检测诊断有载分接开关故障[J]. 高电压技术,2006,32(7):49-53.
ZHANG Weizheng, SHI Linchen, JI Shengchang, et al. Wavelet singularity detection used for fault diagnosis of on-load tap changers[J]. High Voltage Engineering, 2006, 32(7):49-53.
- [3] KANG P, BIRTWHISTLE D. Condition monitoring of power transformer on-load tap changers. Part 1: Detection of aging from vibration signatures[J]. IEE Proceedings on Generation, Transmission and Distribution, 2001, 148(4):301-306.
- [4] KANG P, BIRTWHISTLE D. Condition monitoring of power transformer on-load tap changers. Part 2: Detection of aging from vibration signatures[J]. IEE Proceedings on Generation, Transmission and Distribution, 2001, 148(4):307-311.
- [5] 高 鹏,马宏忠,张惠峰,等. 分接开关振动信号 EMD 熵和小波熵的比较[J]. 电力系统及其自动化学报,2012,24(4):48-53.
GAO Peng, MA Hongzhong, ZHANG Huifeng, et al. Comparison of EMD entropy and wavelet entropy in vibration signals of OLTC[J]. Proceedings of the CSU-EPSC, 2012, 24(4):48-53.
- [6] 张惠峰,马宏忠,陈 凯,等. 基于振动信号 EMD-HT 时频分析的变压器有载分接开关故障诊断[J]. 高压电器,2012,48(1):76-81.
ZHANG Huifeng, MA Hongzhong, CHEN Kai, et al. Fault diagnosis of power transformer on-load tap changer based on EMD-HT analysis of vibration signal[J]. High Voltage Apparatus, 2012, 48(1):76-81.
- [7] 陆 琳,崔艳华. 基于振动信号的变压器分接开关触头故障诊断[J]. 电力自动化设备,2012,32(1):93-97.
LU Lin, CUI Yanhua. Diagnosis of transformer tap changer contact fault based on vibration signal[J]. Electric Power Automation Equipment, 2012, 32(1):93-97.
- [8] BANDT C, POMPE B. Permutation entropy: A natural complexity measure for time series[J]. Physical Review Letters, 2002, 88(17):1-4.
- [9] 马转霞. 基于多尺度排列熵的涡旋压缩机故障诊断[D]. 兰州:兰州理工大学,2016.
MA Zhuanxia. Scroll compressor fault diagnosis based on multiscale permutation entropy[D]. Lanzhou: Lanzhou University of Technology, 2016.
- [10] 郑近德,程军圣,杨 宇. 改进的 EEMD 算法及其应用研究[J]. 振动与冲击,2013,32(21):21-26.
ZHENG Jinde, CHENG Junsheng, YANG Yu. Modified EEMD algorithm and its applications[J]. Journal of Vibration and Shock, 2013, 32(21):21-26.
- [11] 王晓龙. 基于振动信号处理的滚动轴承故障诊断方法研究[D]. 北京:华北电力大学,2017.
WANG Xiaolong. Research on fault diagnosis method of rolling bearing based on vibration signal processing[D]. Beijing: North China Electric Power University, 2017.
- [12] 刘尚坤. 基于振动信号处理的旋转机械故障诊断方法研究[D]. 北京:华北电力大学,2017.
LIU Shangkun. Research on fault diagnosis of rotating machinery based on vibration signal processing[D]. Beijing: North China Electric Power University, 2017.
- [13] 孙曙光,张 强,杜太行,等. 基于振动信号的低压万能式断路器分合闸故障程度评估方法的研究[J]. 中国电机工程学报,2017,37(18):5473-5482.
SUN Shuguang, ZHANG Qiang, DU Taihang, et al. Study of evaluation method for low voltage conventional circuit breaker switching fault degree based on vibration signal[J]. Proceedings of the CSEE, 2017, 37(18):5473-5482.
- [14] 王 晶. 非平稳时间序列的多尺度分析[D]. 北京:北京交通大学,2015.
WANG Jing. Multiscale analysis of nonstationary time series[D]. Beijing: Beijing Jiaotong University, 2015.
- [15] YAN Ruqiang, GAO R X. Approximate entropy as a diagnostic tool for machine health monitoring[J]. Mechanical Systems and Signal Processing, 2007, 21(2):824-839.
- [16] COSTA M, GOLDBERGER A L, PENG C K. Multiscale entropy analysis of complex physiological time series[J]. Physical Review Letters, 2002, 89(6):1-18.
- [17] JAIN A K. Data clustering: 50 years beyond K-means[J]. Pattern Recognition Letters, 2010, 31(8):651-666.
- [18] 傅 涛,孙亚民. 基于 PSO 的 K-means 算法及其在网络入侵检测中的应用[J]. 计算机科学, 2011, 38(5):54-55.
FU Tao, SUN Yamin. PSO-based K-means algorithm and its application in network intrusion detection system[J]. Computer Science, 2011, 38(5):54-55.
- [19] 谢秀华,李陶深. 一种基于改进 PSO 的 K-means 优化聚类算法[J]. 计算机技术与发展,2014,24(2):34-38.

- XIE Xiuhua, LI Taoshen. An optimized K-means clustering algorithm based on improved particle swarm optimization[J]. Computer Technology and Development, 2014, 24(2): 34-38.
- [20] 刘 晶, 翁公羽, 付 华. 基于 PSO-ENN 算法的高压直流输电线路故障测距[J]. 高压电器, 2016, 52(9): 153-157.
LIU Jing, WENG Gongyu, FU Hua. Fault location on HVDC transmission line based on PSO-ENN algorithm[J]. High Voltage Apparatus, 2016, 52(9): 153-157.
- [21] 袁海满, 吴广宁, 高 波. 基于 DGA 的粒子群极限学习机电力变压器故障诊断[J]. 高压电器, 2016, 52(11): 176-180.
YUAN Haiman, WU Guangning, GAO Bo. Fault diagnosis of power transformer using particle swarm optimization and extreme learning machine based on DGA[J]. High Voltage Apparatus, 2016, 52(11): 176-180.
- [22] 李善寿, 张 兴, 张鸿恺, 等. 基于功率闭环控制与 PSO 算法的全局 MPPT 方法[J]. 中国电机工程学报, 2014, 34(28): 4809-4816.
LI Shanshou, ZHANG Xing, ZHANG Hongkai, et al. Global MPPT method based on power closed-loop control and pso algorithm[J]. Proceedings of the CSEE, 2014, 34(28): 4809-4816.
- [23] 左迎芝, 曹洪亮, 韩 通, 等. 基于粒子群算法的金属氧化物避雷器老化监测研究[J]. 高压电器, 2016, 52(11): 113-118.
ZUO Yingzhi, CAO Hongliang, HAN Tong, et al. On-line aging monitoring of metal oxide arrester using particle swarm optimization[J]. High Voltage Apparatus, 2016, 52(11): 113-118.
- [24] 马汉达, 郝晓宇, 马仁庆. 基于 Hadoop 的并行 PSO-kmeans 算法实现 Web 日志挖掘[J]. 计算机科学, 2015, 42(s1): 470-473.
MA Handa, HAO Xiaoyu, MA Renqing. Parallel PSO-kmeans algorithm implementing web log mining based on Hadoop[J]. Computer Science, 2015, 42(s1): 470-473.
- 马宏忠(1962—), 男, 博士, 教授, 博士生导师, 主要研究方向为电气设备状态监测与故障诊断、电机运行与控制、电能质量。
- 徐 艳(1992—), 女, 硕士, 主要研究方向为电气设备状态监测与故障诊断(E-mail: 13585207210@163.com)。

(上接第 197 页)

- [21] 高 媛, 陈向坚, 王平心, 等. 面向一致性样本的属性约简[J]. 智能系统学报, 2019, 14(6): 1170-1178.
GAO Yuan, CHEN Xiangjian, WANG Pingxin, et al. Attribute reduction over consistent samples[J]. CAAI Transactions on Intelligent Systems, 2019, 14(6): 1170-1178.
- [22] 郑 诚, 王 波, 洪彤彤. 关系矩阵的知识粒度增量式属性约简[J]. 小型微型计算机系统, 2018, 39(5): 1000-1004.
ZHENG Cheng, WANG Bo, HONG Tongtong. Incremental attribute reduction based on relational matrix[J]. Journal of Chinese Computer Systems, 2018, 39(5): 1000-1004.
- 莫文火(1964—), 男, 学士, 高级工程师, 国家注册监理工程师, 研究方向为电力系统最优运行与规划、电力大数据分析及应用(E-mail: 2645725094@qq.com)。
- 陈碧云(1978—), 女, 博士, 副教授, 研究方向为电力系统规划与可靠性、电力大数据分析及应用。