

文章编号:1005-0523(2019)05-0136-07

接触网高压隔离开关的机械故障诊断新策略

刘仕兵,马志方,仇智圣,李俊

(华东交通大学电气与自动化工程学院,江西 南昌 330013)

摘要:随着铁路线路的快速发展,高压隔离开关成为使用量最大的高压设备。接触网隔离开关的运行可靠性对保障牵引供电的稳定运行有着重要意义。K-means 作为一种十分有效的聚类分析工具,通过处理电机电流采集系统监测得到的隔离开关电机电流信号,计算获得簇中心及其位置的变化并以此作为判断隔离开关故障情况的依据,分类后的高压隔离开关机械故障为后续的监测和诊断提供了直观的表述。但是由于高压隔离开关机械故障的复杂性,以及 K-means 算法自身的局限性,本文提出一种改进的 K-means 算法,通过结合自适应权重和遗传算法(genetic algorithm,GA),避免了 K-means 算法在依赖初始值和局部收敛等弊端,通过实际数据进行仿真,验证了该方法的有效性。据此可对高压隔离开关的机械故障进行分类并且作为接触网隔离开关故障分类和检测的依据。

关键词:K-means 算法;自适应权重;遗传算法;隔离开关

中图分类号:U225.4+5

文献标志码:A

接触网隔离开关由于常年暴露在野外环境,极易受到腐蚀和振动的影响,使得隔离开关出现关节不同程度卡涩、由于人工操作不规范以及弹簧失能导致的合闸不到位等机械故障,严重影响了线路的安全稳定运行^[1-2]。因此,对高压隔离开关的机械故障诊断拥有极为重要的现实意义。隔离开关的机械故障检测手段有:绝缘子超声波探伤、触头温度在线监测、红外温度检测等^[3-6]。由于电机电流是比较直观的检测数据,通过检测高压隔离开关的刀闸电机电流信号,可以比较清晰的展现隔离开关各个故障情况,即电机电流分析法^[7]。文献[8]通过结合电机电流分析法和 K-means 聚类方法,通过对时间电流信号进行聚类分析,计算得到簇中心及其位置的变化并以此作为检测高压隔离开关的机械故障状态的依据。但是,由于 K-means 分析方法存在过于依赖初试点和局部收敛等限制,使得在隔离开关的故障分析中出现误差和误判。文献[9]介绍了一种结合了 GA 的改进 K-means 算法,在拥有了 GA 的全局收敛能力的同时,也吸收了 K-means 算法局部收敛的特性,提高了算法的运算精确度。本文结合自适应权重、GA 改进 K-means 算法,避免了 K-means 算法过早局部收敛和依赖初始值的缺点,并用该算法对高压隔离开关的机械故障进行仿真计算,期望对隔离开关运行状态的检测提供依据。

1 基于 K-means 算法的接触网隔离开关机械故障检测

1.1 K-means 算法

K-means 算法是基于划分的一种经典聚类分析方法,广泛应用于各个学科领域。针对隔离开关分合闸过程中电机电流的混沌特性,对信号进行相空间重构,并对重构后的信号进行 K-means 聚类分析,获取相应的簇中心,根据其位置的不同来判断隔离开关的运行状况。簇中心位置分布不同代表着隔离开关所处的工况状态不同。

收稿日期:2018-11-15

基金项目:国家自然科学基金科学项目(11162006);江西省教育厅科技项目(GJJ150530;GJJ160488)

作者简介:刘仕兵(1970—),男,教授,研究方向为电气化轨道交通接触网技术研究。

表 1 簇中心矢量和的模
Tab.1 The mode value of the cluster center vector

参数	正常情况	轻微卡涩	严重卡涩	弹簧失效	合闸不到位
模值	9.521	11.78	14.35	12.231	10.443
偏差	0	23.73%	50.72%	28.46%	9.68%

根据表 1 所示簇中心矢量和模的比较,可以清晰的看出与正常情况相比较,各故障矢量和模值发生明显偏差,电机电流的波动幅度较大,且随着卡涩程度的变化,其矢量模值发生偏差的程度越大,使用 K-means 算法可以较为直观的检测隔离开关故障情况。

1.2 传统 K-means 算法的缺点

在运用 K-means 算法进行聚类分析运算时,必须事先设定好聚类数值 K 且其大小直接影响聚类的结果,这就使得 K-means 算法在实际应用中有了局限性。同时,K-means 算法对初始聚类中心也有很大的依赖性,即在根据设定的 K 值随机设定 K 个初始中心点,由于是随机性质,会导致聚类的结果出现较大差异,甚至会出现过早收敛的情况,即“早熟”。在对电机电流进行聚类分析时,容易发生聚类效果不明显,计算周期较长,无法满足对隔离开关的在线监测需求,同时由于过早收敛的特性,使得对给开关卡涩程度的分析不明显。

2 自适应权重

2.1 特征权重的提取

传统的 K-means 算法采用欧氏距离计算数据点之间的相关性,由于欧氏距离会造成数据点之间距离计算失真的局限性,因此本文引入加权欧氏距离,对数据间的属性权重进行自适应变化,可以在提前不指定 K 值的情况下,对数据进行 K-means 聚类分析。

根据聚类分析“类间远离,类内紧凑”的原则,赋予数据第 j 维的属性权重值

$$w_j = \frac{c_j}{\sum_{j=1}^m c_j} \tag{1}$$

式中: $w_j \in [0, 1]$; $\sum_{j=1}^m w_j = 1$; c_j 为属性权重的度量,是类间与类内距离的比值,即

$$c_j = \frac{d_{\text{between}}}{d_{\text{in}}} \tag{2}$$

式中: $d_{\text{in}} = \sum_{k=1}^K \sum_{i=1}^{n_k} (x_{ij} - m_{kj})^2, n_k \in k; d_{\text{between}} = \sum_{k=1}^K (m_{kj} - m_{lj})^2$ 。通过赋权得出加权的欧氏距离

$$d(m, n) = \sqrt{\sum_{j=1}^m w_j (x_{mj} - x_{nj})^2} \tag{3}$$

w_j 的大小代表了对应数据对聚类中心的重要性。其作用就是通过拉伸欧几里得空间,然后进行聚类,更加直观的反映数据的分布情况,从而使计算结果更加精确。

2.2 对初始中心的确定

由于 K-means 算法对初始中心极大的依赖性,所以本文引入基于密度来考量初始中心的方法。通过公式(3)提到的加权欧氏距离来修改准则函数

$$J(k) = \frac{\text{within}(k)}{\text{between}(k)} \tag{4}$$

式中: J 值反映了聚类的效果,改进算法的目的就是为了求解最小的 J 值; k 为聚类中心个数, $\text{within}(k) =$

$\max_{1 \leq i \leq k} \left\{ \min_{1 \leq j \leq c_i} \left\{ \frac{1}{|C_i|} \sum_{p=1}^{|c_i|} \|x_j - x_p\| \right\} \right\}$, $between(k) = \min_{x_p \in C_i, x_q \in C_j, i \neq j} \|x_p - x_q\|$, 分别表示类内距离和类间距离; C_i 和 C_j 分别为

第 i 维和第 j 维的属性权重值度量, 同时, 根据加权的欧氏距离, 可以得到高密度集合, 即

$$Density(x) = \{p \in C | Dist(x, p) \leq r\} \quad (5)$$

式中: C 表示 p 所在维度下的权重值度量; $Dist$ 为加权欧氏距离, 样本点 x 的密度表示整个数据集合的点到 x 的加权的欧氏距离小于或者等于指定的半径 r 的样本点的数目。当获得所有数据点的密度之后, 将满足最小密度数的数据点放进高密度点集合中。

假设高密度集合对象的个数为 S , 其远大于实际的分类个数, 使得迭代次数增多, 计算时间延长。所以取相距最远的 $\lfloor \sqrt{S} \rfloor$ 个点作为初始中心。在这 $\lfloor \sqrt{S} \rfloor$ 个点中, 通过 $\max \{ \min [d(x_i, z_1), d(x_i, z_2)] \}$, $i=1, 2, 3, \dots, n$, 选取密度最大的点作为第 1 个聚类中心。而第 2 个聚类中心就是高密度集合中距离第 1 个聚类中心最远的点。然后根据 $\max \{ \min [d(x_i, z_1), d(x_i, z_2), \dots, d(x_i, z_{q-1})] \}$, $i=1, 2, 3, \dots, n$, 确定第 3 个聚类中心, 重复计算以获得 $\lfloor \sqrt{S} \rfloor$ 个聚类中心点。采用加权的欧氏距离选择初始聚类中心点, 既能随机选择初始聚类中心点, 同时保证了聚类中心得稳定性。

3 基于 GA 改进的 K-means 算法

GA 作为近年来新兴的聚类分析方法, 由于其简单、通用、适用于并行处理的优点而被广泛应用。作为一种模拟生物进化的模型, 通过与计算机的相互渗透与结合, 产生了一种通过简单的编码, 就可以实现由简单的变化到复杂规则进化的方法。通过结合 GA 的全局搜索能力和 K-means 算法的快速收敛能力, 在每一步执行完 GA 操作之后引入 K-means 算法, 对新生的每一个个体进行优化, 优化后的个体进入下一步遗传操作, 反复迭代直至出现最优解。

1) 算法的编码: 本文采用浮点编码方式进行编码对各个个体进行编码。设聚类中心为 m 维, 聚类中心为 k , 则每条染色体的长度为 $l=mk$, 染色体为 $\{x_1, x_2, \dots, x_k\}$, 其中每一条染色体 $x_i = \{x_{i1}, x_{i2}, \dots, x_{ik}\}$, 每条染色体代表一个聚类中心的坐标。

2) 初始化种群: 从样本空间中选出 k 个个体, 每一个个体代表一个初始聚类中心, 通过基于聚类中心的浮点编码方式将这组聚类中心编码成一条染色体。再重复进行 P_{size} 次染色体初始化生成初始种群, P_{size} 为群体总量。

3) 适应度函数: 作为性能好坏的指标, 适应度函数会直接影响算法的收敛速度和最优解的选定。GA 算法的目的就是通过公式(4)所得的 J , 构造使得 J 值最小的适应度函数

$$f = \frac{1}{J(k)} = \frac{between(k)}{within(k)} \quad (9)$$

由公式(9)可以得出, 准则函数 J 越小的聚类中心, 所获得适应度函数值也就越大。

4) 选择操作: GA 通过优胜劣汰来实现对群体的选择操作, 适应度越低的群体遗传到下一代的概率越小, 反之则大。在已有适应度函数的基础上, 通过轮盘赌的方式来保证算法的收敛性。由于个体被选中的概率取决于该个体的适应度的大小。因此每一条染色体适应度在总体中的占有比例决定了其被选中的概率。具体操作如下:

- ① 计算当前种群个体的适应度函数, 并记录适应度最大的个体;
- ② 通过公式(6)获得适应度值 $f(x_i)$, ($i=1, 2, \dots, k$), 计算每一个个体被选择的概率

$$P_x = \frac{f(x_i)}{\sum_{j=1}^k f(x_j)} \quad (7)$$

- ③ 根据所得的概率 P_x , 使用轮盘赌法选择个体进行交叉和变异操作以产生新的个体;
- ④ 重新计算新种群中个体的适应度值, 并将记录的上一代中适应度值高的个体取代下一代中适应度值低的个体, 以此产生下一代种群。

在这个过程中种群的平均适应度得以提升,鲁棒性增强,整体朝着最优解的方向发展。

5) 交叉操作:本文将采用算术交叉的方式来将 2 个个体进行线性交叉产生新的个体。假设交叉个体为 x_1 和 x_2 ,通过如下的均匀算术交叉获得新的个体 x_1' 和 x_2'

$$\begin{aligned} x_1' &= \lambda x_1 + (1-\lambda)x_2 \\ x_2' &= \lambda x_2 + (1-\lambda)x_1 \end{aligned} \tag{8}$$

式中, λ 为相应系数。

6) 变异操作:变异操作即为将同一染色体中的某一部分基因与另一部分基因进行等位替换的操作,从而增加了个体的多样性,改善的遗传算法的局部搜索能力,防止早熟收敛。本文通过均匀变异算子,其具体操作如下:

- ① 取定某一个体编码串中的变异点,确定其取值范围 $[U_{\min}, U_{\max}]$;
- ② 对每一个变异点,以变异概率 P_m 从 $[U_{\min}, U_{\max}]$ 取任意随机数代替原有值,从而获得新的基因

$$x_r = U_{\min} + r(U_{\max} - U_{\min}) \tag{9}$$

式中, r 表示系数。

7) K-means 算法的优化操作:由于结合了自适应权重算法,使得数据的初始中心和聚类数 k 确定,所以在此基础上,对算法进行优化,对数据集的属性权重进行初始化或者结束上一步操作后保持上次运行的权重,计算所有对象的加权距离并进行归类处理,通过计算各个群类的类内、类间距离,计算对应的权重,调整加权的欧氏距离,获得新的 K 个聚类中心,对这 K 个聚类中心编码成染色体,对其进行遗传操作,生成下一代种群。由于电机电流信号的混沌性质,在二维空间的延展性能较强,信号在 K-means 算法聚类的同时,遗传算法的交叉变异操作使得获得簇中心更精确,增强了稳定性,使得隔离开关各工况能够更加直观的表现。

4 算法仿真

4.1 信号的采集

为验证算法的有效性,本文通过如图 1 所示由数据采集卡、霍尔电流传感器和 Labview 软件平台构成的系统来模拟高压隔离开关在正常情况下、轻微卡涩、严重卡涩、弹簧失效、合闸不到位等常见机械故障情况下的电机电流情况,导入到 C++ 平台编译的算法中,计算仿真结果,并同传统 K-means 算法进行比较。

通过图 1 所示结构图所获得的电机电流信号在各个故障情况下的时间电流图像如图 2 所示,图像可知,在不同情况下电机电流信号波形的峰值出现在不同的时间节点,同时各个波峰的时间间隔也不尽相同。

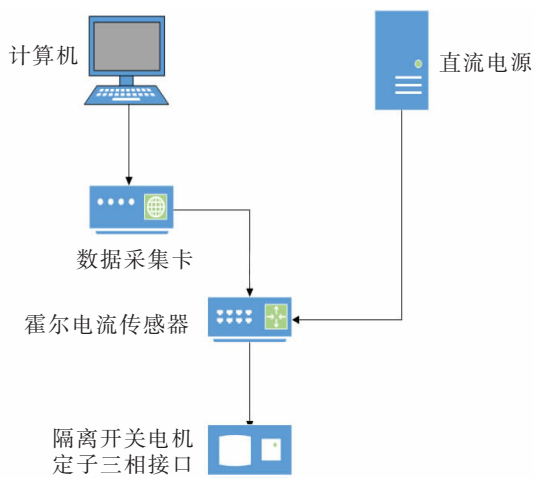


图 1 电机电流采集系统结构图

Fig.1 Structure diagram of electric current acquisition system



图 2 GW5-35DW 隔离开关

Fig.2 GW5-35DW isolation switch

当弹簧失效时,波峰出现时间较正常情况有偏移出现;当机括出现或轻或重的卡涩时,电流信号的幅值也会出现或多或少的增大。可见电机电流信号可以很直观表征高压隔离开关机械故障的状态。

4.2 信号的处理

根据本文所提的改进的 K-means 算法,对信号进行处理,如图 3 所示。

4.3 实验结果与分析

为了验证算法的有效性,本文在 C++ 平台下对算法进行了仿真实验。其中以隔离开关机械故障 5 种工况分别进行计算,每一组数据反复计算 10 次以保证实验的准确性。本文以弹簧失效为例,如表 2 所示。

可见,随着算法的推进,高压隔离开关弹簧失效故障的数据在经过 11 代的迭代下,初始中心获得最终值,且准则函数值趋于稳定在一个固定值,优化值也降为 0。可见算法既确定了初始中心的个数,又确定了最终的优化值,避免了 K-means 算法的弊端,又精确的计算出优化值。

又由表 3 可见,高压隔离开关在工况下使用 GA 改进的 K-means 算法进行特征值提取,其中特征值的提取和准则函数均满足实验需求。

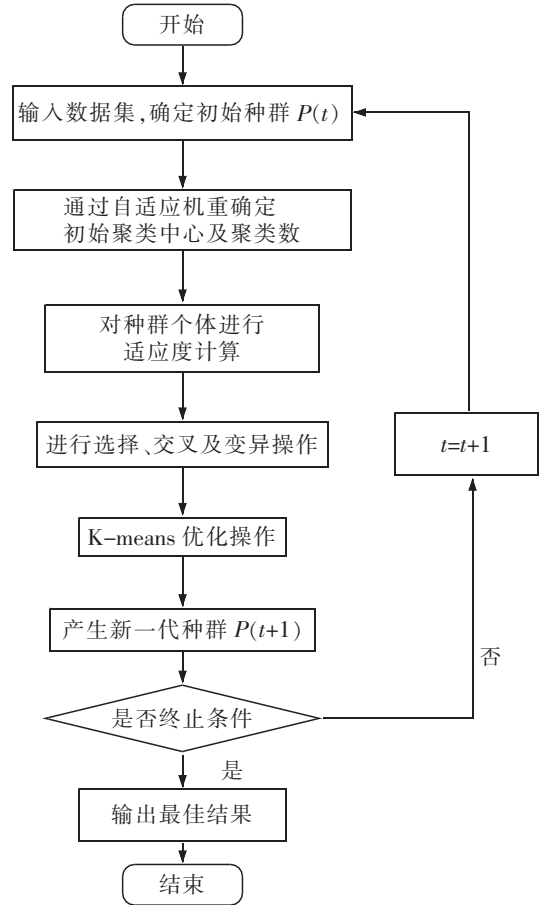


图 3 改进的 K-means 算法流程图
Fig.3 Improved flow chart of K-means algorithm

表 2 高压隔离开关弹簧失效情况下的改进的 K-means 分析结果

Tab.2 Improved K-means analysis results under the condition of high voltage disconnector spring failure

种群繁衍代数	中心值	准则函数值	优化值
第 0 代	(0.850 118,2.067 26,0,0) (1.343 72,1.952 38,0,0) (1.527 14,1.836 91,0,0)	0.048 75	99 980.5
第 1 代	(0.592 578,1.962 97,0,0) (1.273 78,2.015 77,0,0) (1.743 35,1.841 1,0,0)	0.097 94	10.302 9
第 2 代	(0.487 787,1.914 65,0,0) (1.211 74,2.047 8,0,0) (1.772 95,1.837 38,0,0)	0.117 16	1.674 93
第 3 代	(0.428 684,1.888 11,0,0) (1.160 57,2.057 09,0,0) (1.765 36,1.837 95,0,0)	0.126 02	0.599 866
第 4 代	(0.397 656,1.875 38,0,0) (1.126 75,2.062 03,0,0) (1.750 56,1.839 82,0,0)	0.129 62	0.220 535
第 5 代	(0.373 857,1.865 9,0,0) (1.103 7,2.063,0,0) (1.743 35,1.841 1,0,0)	0.131 18	0.091 821 9
第 6 代	(0.365 868,1.862 98,0,0) (1.087 11,2.067 14,0,0) (1.728 8,1.843 99,0,0)	0.132 39	0.069 862 9
第 7 代	(0.357 736,1.859 92,0,0) (1.070 12,2.071 02,0,0) (1.715 09,1.847 13,0,0)	0.133 31	0.051 705 3
第 8 代	(0.349 454,1.856 99,0,0) (1.058 63,2.071 98,0,0) (1.708 36,1.848 84,0,0)	0.133 68	0.020 803 3
第 9 代	(0.349 454,1.856 99,0,0) (1.053 05,2.074 24,0,0) (1.701 71,1.850 72,0,0)	0.133 80	0.007 124 44
第 10 代	(0.341 011,1.854 47,0,0) (1.047 13,2.072 35,0,0) (1.701 71,1.850 72,0,0)	0.133 90	0.005 535 13
第 11 代	(0.341 011,1.854 47,0,0) (1.047 13,2.072 35,0,0) (1.701 71,1.850 72,0,0)	0.133 90	0

表 3 高压隔离开关机械故障在改进的 K-means 算法下的处理结果

Tab.3 Processing result of mechanical fault of high voltage disconnecting switch by improved K-means algorithm

高压隔离开关故障情况	平均迭代次数	平均中心值	平均准则函数值
正常情况	10.9	(0.352 655, 1.699 59, 0, 0)(1.023 2, 1.859 57, 0, 0) (2.086 86, 1.605 72, 0, 0)	0.083 43
弹簧失效	10.2	(0.341 011, 1.854 47, 0, 0)(1.041 69, 2.074 62, 0, 0) (1.694 93, 1.852 52, 0, 0)	0.133 88
合闸不到位	11.5	(0.340 165, 1.837 41, 0, 0)(0.912 795, 2.073 66, 0, 0)(1.370 63, 1.915 07, 0, 0)	0.172 18
严重卡涩	10.2	(0.343 587, 1.803 18, 0, 0)(0.959 334, 2.825 15, 0, 0)(1.450 69, 3.792 63, 0, 0)	0.034 31
轻微卡涩	6.8	(0.410 508, 1.790 7, 0, 0) (0.974 307, 1.998 37, 0, 0)(1.480 21, 1.746 66, 0, 0)	0.113 50

可见由表 4 可得,当隔离开关发生故障时,簇中心的位置同正常情况下相比发生了明显的偏移,其偏移程度随着卡涩的增强而变大,相较于 K-means 算法,改进的 K-means 算法更接近于实际情况,且对轻微与严重的工况进行了较为明显的分离;弹簧失效与合闸不到位情况下的偏移结果较为接近,据此推测导致两者发生的高压隔离开关的机械状态相似,即弹簧机括难以抵达正常位置而导致的开关扭矩差距不大。同时合闸不到位与其他由于隔离开关内部机括损坏而导致的故障不同,其与正常情况数据相差不明显,推测是由于人工的误操作导致。显然,在基于 GA 改进的 K-means 算法下,利用对电机电流的簇中心的分析可以有效诊断出高压隔离开关的机械故障。

通过 SVM 平台训练和测试两种算法,使用同一电机电流数据集比对两种算法的计算时间和正确率如表 5 所示,两种算法的误差平方和相差较大,且传统的 K-means 算法平均计算时间相较于改进算法是时间较长,正确率比较低,可见改进算法的优越性和有效性。

表 4 簇中心矢量和的模值

Tab.4 Modulus of vectors sum for a cluster center

工况	传统 K-means 算法	基于 GA 算法改进的 K-means 算法
正常情况	9.52	9.49
弹簧失效	12.23	11.97
轻微卡涩	11.78	10.57
严重卡涩	14.35	13.82
合闸不到位	10.44	10.21

表 5 聚类中心的误差平方和的比较

Tab.5 The comparison of square error sum of cluster centers

聚类算法	误差平方和	正确率/%	平均计算时/ms
传统 K-means 算法	1.287	85.2	1 620
基于 GA 改进的 K-means 算法	0.482	93.1	925

5 结论

本文通过对接触网高压隔离开关的电机电流进行采集获得不同高压隔离开关机械故障状态,并结合基于 GA 改进的 K-means 算法进行分析,提出一种改进的 K-means 算法对接触网高压隔离开关进行故障监测和诊断的方法,实验结果表明:

1) 通过使用 GA 改进的 K-means 算法对高压隔离开关的电机电流信号进行计算能够有效的提取出各个机械故障状态下的簇中心和特征值,尤其针对高压隔离开关的卡涩情况有明显的分离效果,对于高压隔离开关机械故障的检测和诊断的应用有着广阔前景。

2) 通过比对改进的 K-means 算法和传统 K-means 算法分析,可见通过加入了遗传算法能够大大改进 K-means 算法,避免了 K-means 算法过早收敛,同时由于 GA 算法全局快速收敛的特性,使得计算的精度大大提高。通过加入自适应权重能够解决 K-means 算法过分依赖初试值的弊端,大大提高了运算的速度。

参考文献:

- [1] 苑舜,崔文军. 高压隔离开关设计与改造[M]. 北京:中国电力出版社,2007:1-14.
- [2] 靳玉海. 接触网隔离开关常见故障分析及处置措施[J]. 上海铁道科技,2014(4):77-77.
- [3] 李中祥,宋建成. 高压隔离开关触头温度在线监测系统的研制[J]. 高压电器,2009,45(2):11-13.
- [4] 钟振蛟. 户外隔离开关机械故障的起因及预防[J]. 高压电器,2006(6):464-467.
- [5] 黄聿琛,阮江军,邱志斌,等. 隔离开关操动机构电机输出轴扭矩和电流关系的研究[J]. 高压电器,2015,51(6):139-144.
- [6] 肖荣,徐澄. 220kV GW6型隔离开关导电回路过热故障分析及处理[J]. 高压电器,2013,49(1):107-110.
- [7] 邱志斌,阮江军,黄道春,等. 基于电机电流检测的高压隔离开关机械故障诊断[J]. 中国电机工程学报,2015,35(13):3459-3466.
- [8] 刘仕兵,葛俊祥. 基于 K-means 聚类法的牵引供电隔离开关故障状态监测[J]. 华东交通大学学报,2017,34(3):109-117.
- [9] DONG X C, XIAN D Z, CHANG W Z. A genetic algorithm with gene rearrangement for K-means clustering [J]. Pattern Recognition, 2009, 42(7): 1210-1222.
- [10] 王千,王成,冯振元,等. K-means 聚类算法研究综述[J]. 电子设计工程,2012,20(7):21-24.
- [11] 曹道友. 基于改进遗传算法的应用研究[D]. 合肥:安徽大学,2010.
- [12] 唐哲. 一种基于遗传算法的 k 均值聚类分析[D]. 长沙:长沙理工大学,2014.
- [13] NGUYEN H V, BAI L. Cosine similarity metric learning for face verification[M]. Computer Vision-ACCV, 2010, Springer Berlin Heidelberg, 2011: 709-720.
- [14] GUHA S, RASTOGI R, SHIM K. An efficient clustering algorithm for large Databases. Proceedings of the ACM SIGMOD International Conference on Management of Data[J]. Seattle, 1998:73-84.
- [15] YUNOH M F, ABDULLAH S, SAAD M H, et al. K-means clustering analysis and artificial neural network classification of fatigue strain signals [J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering. 2017, 39(3): 757-764.

New Strategy of Mechanical Fault Diagnosis for High Voltage Isolation Switch of OCS

Liu Shibing, Ma Zhifang, Qiu Zhisheng, Li Jun

(School of Electrical and Automation Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: With the rapid development of railway lines, high voltage disconnectors have become the most frequently used high voltage equipment. The reliability of OCS isolating switch is of great significance for ensuring the stable operation of traction power supply. As a very effective tool for clustering analysis, the K-means algorithm processes the isolated current motor's current signals monitored by the motor current acquisition system, obtaining the cluster centers and the change of their positions, thus determining the fault isolation switch with mechanical fault classification for further processing. Because of the complexity of mechanical failure of high voltage isolation switch, and the limitations of the K-means algorithm itself, this paper proposed an improved K-means algorithm by combining the adaptive weights and GA algorithm (genetic algorithm). K-means algorithm avoided such defects as dependence on initial value and local convergence. The validity of the methods was verified by simulating the actual data. It is found that the mechanical fault of the high-voltage isolating switch can be classified and used as the basis for fault classification and detection of OCS isolating switch.

Key words: K-means algorithm; adaptive weight; genetic algorithm; isolating switch