

DOI:10.13296/j.1001-1609.hva.2017.09.041

基于 Relief 特征量优化及 SOM 网络的 断路器操作机构状态评估

张 浩¹, 赵莉华¹, 景 伟², 阳 薇², 姜海洋²,
朱林林², 荣 强¹, 付荣荣¹

(1. 四川大学电气信息学院, 成都 610065; 2. 国网黑龙江电力有限公司检修公司, 哈尔滨 150090)

摘要: 为提高断路器操作机构状态评估的效率及准确性, 文中提出了采用 Relief 优化方法对分合闸线圈电流特征向量进行优化及 SOM 网络对线圈电流样本进行分类的高压断路器操作机构状态评估方法。仿真研究表明: 基于 Relief 的分合闸线圈电流特征向量优化方法和 SOM 网络分类方法的操作机构状态评估能够实现操作机构状态的准确评估, 同时采用优化后的电流特征向量数据进行状态评估减小了运算量和缩短了运算时间, 提高了断路器机构状态评估的效率。

关键词: Relief; 状态评估; 特征向量; 操作机构; SOM

Condition Assessment of the Circuit Breaker Operating Mechanism Based on Relief Feature Vector Optimization and Som Network

ZHANG Hao¹, ZHAO Lihua¹, JING Wei², YANG Wei², JIANG Haiyang², ZHU Linlin²,
RONG Qiang¹, FU Rongrong¹

(1. School of Electrical Engineering and Information, Sichuan University, Chengdu 610065, China;

2. Maintenance Company of Heilongjiang Electric Power Company Limited, Heilongjiang 150090, China)

Abstract: To improve the condition assessment efficiency of a circuit breaker operating mechanism, Relief is employed to optimize the feature vector of a high voltage circuit breaker and SOM neural network is adopted to classify the samples of switching coil current. Thus, an operating mechanism condition assessment method for high voltage circuit breakers is proposed. Simulation results show that this Relief and SOM based operating mechanism condition assessment method can recognize the operating mechanism condition accurately, and application of the optimized current feature vector can reduce the computing amount and time and improve the assessment efficiency.

Key words: Relief; condition assessment; feature vector; operating mechanism; SOM

0 引言

在电网中, 高压断路器是重要的一次设备, 它的运行可靠性对电网的可靠运行具有重要作用。CIGRE 对高压断路器运行情况调查表明, 操作机构故障率在断路器各种故障中位居前列, 所以操作机构是影响断路器正常运行的关键部件之一。操作机构分合闸线圈电流可以反映操作机构在动作过程中的许多状态信息^[1-2], 基于分合闸线圈电流的分析可

以评估操作机构的状态, 对断路器的可靠运行具有重要的作用^[3]。

国内外专家学者对断路器操作机构状态评估进行了一些研究, 文[4]对机构运行参数变化影响线圈电流波形进行试验研究, 对比各种状态的线圈电流变化趋势, 但没有提出具体的状态评估方法, 文[5-9]提出了基于专家系统、灰色关联度、支持向量机等多种状态评估方法, 具有一定的实用性, 但这些方法未对特征量进行优化, 存在特征量冗余问题, 计算量大, 计算过程较复杂。

文中通过 Relief 方法对高压断路器弹簧操作机

收稿日期: 2017-03-07; 修回日期: 2017-05-14

基金项目: 国家电网科技项目(SGHLJG00YJJS1400303)。

Project Supported by Science and Technology Project of the State Grid(SGHLJG00YJJS1400303).

构分合闸线圈电流(线圈电流)的特征向量进行优化, 基于线圈电流特征向量数据进行 SOM 网络模型的训练及分类, 实现基于 SOM 网络分类方法的机构状态评估。仿真结果表明基于 Relief 的分合闸线圈电流特征向量优化和 SOM 网络分类的操作机构状态评估方法能够准确分析操作机构的状态, 同时采用优化后的电流特征向量数据进行状态评估减小了运算量和运算时间, 提高了断路器机构状态评估的效率。

1 线圈电流与断路器操作机构状态评估

断路器操作机构典型线圈电流波形见图 1。图 1 中的电流波形可分为 5 个阶段, 分别为: 阶段 1(t_0-t_1) 时, 电流按指数规律上升; 阶段 2(t_1-t_2) 时, 电磁铁动作, 电流逐渐下降; 阶段 3(t_2-t_3) 时, 电磁铁动作到位, 电流呈指数规律增加; 阶段 4(t_3-t_4) 时, 此阶段电流近似为最大值, 波形平稳; 阶段 5(t_4-t_5) 时, 电流切断阶段, 随着辅助开关的动作电流逐渐减小为零。




图 1 典型线圈电流特性波形图

Fig. 1 Coil current characteristic waveform

从图 1 中可以看出, 有 6 个反映电流波形特征的关键点, 称为特征点, 分别是: $(t_0, 0)$, (t_1, i_1) , (t_2, i_2) , (t_3, i_3) , (t_4, i_4) , $(t_5, 0)$, 6 个特征点共有 12 个特征量。线圈电流起始点的时间和电流值为零, 且电流终值也为零, 所以反映线圈电流波形的特征量只有 9 个。这里定义 T_1 为反映线圈电流特征的向量, 即有 $T_1 = [t_1, i_1, t_2, i_2, t_3, i_3, t_4, i_4, t_5]$ 。

操作机构状态或动作参数改变, 线圈电流波形也会随之变化。线圈电压、电磁铁铁心阻力、电磁回路电阻变化时线圈电流波形变化的趋势见图 2。从图 2 中可以看出, 线圈电流特征点值随波形的变化而变化。影响线圈电流波形的主要因素有: 线圈电压、线圈回路电阻、铁心阻力、铁心气隙、机构卡滞等。所以, 可以根据线圈电流或特征点的变化来判断高压断路器操作机构的状态。

2 基于 Relief 的线圈电流特征向量优化

从上节分析可知, 反映线圈电流特征的量有 9 个,




图 2 机构参数对线圈电流的影响

Fig. 2 Operating mechanism parameters effect to coil current

在进行样本分类处理时运算量大且运行时间长。而这 9 个特征量中可能存在一些与分类无关或冗余的特征量, 如果能找出有效特征量进行特征向量降维, 那么可在状态评估时减少故障分类机器学习训练的时间。在特征量优化方面, 常用的有 Relief、CBFS、马尔科夫毯等多种方法^[10-12]。这些方法中, CBFS 法运算量较大, 马尔科夫毯法在确定有效特征变量时比较模糊, 运算过程也复杂, 而 Relief 算法通过考察特征在两类样本之间的差异来确定特征的权重, 其求解过程较简单且运算效率高, 文中采用 Relief 方法对线圈电流的特征向量进行优化。

2.1 Relief 特征权重的算法原理

Relief 是一种特征权重算法, 运用该算法可以计算出各个特征量在分类方面的权重值, 根据权重值大小移除权重小于设定阈值的特征量, 达到降维简化运算的目的, 从而实现特征向量的优化。Relief 算法在特征向量降维, 克服冗余数据等方面有十分广泛的作用^[10-12]。

Relief 算法的原理:

1) 假定所有训练样本的特征向量维数为 I , 首先将训练样本按照一定的原则分为两类, 然后在任意一类中随机选出一个样本 C ;

2) 从与样本 C 同类的样本中寻找一个欧式距离最近的样本 E , 再从与样本 C 不同类的另外一类样本中寻找一个欧式距离最近的样本 F ;

3) 设样本 C 与样本 E 中的某个特征量差值为 D_1 , 设样本 C 与样本 F 中某个特征量的差值为 D_2 。如果 $D_1 < D_2$, 表明这个特征量有助于将样本分类, 将这个特征向量的权重值 $W(j)$ 增加, $W(j)$ 表示特征向量的第 j 个特征量的权重; 相反, 如果 $D_2 < D_1$, 则减少 $W(j)$ 的值; 更新权重 $W(j)$ 的公式为

$$W(j) = W(j)' - [\text{diff}(A, C, E) - \text{diff}(A, C, F)] / m. \quad (1)$$

式(1)中: $W(j)'$ 为 $W(j)$ 前一次的值; $W(j)$ 初始值为

零; m 为步骤 1)~3)的重复次数; $\text{diff}(A, C, E)$ 为样本 C 与样本 E 中的第 j 个特征量的差值即 D_1 ; $\text{diff}(A, C, F)$ 为样本 C 与样本 F 中的第 j 个特征量的差值即 D_2 。

4)重复步骤 1)~3) m 次,将 m 次的权重结果进行平均,得到特征量的权重值,其权重越大,表明该特征量分类能力越强。将权重值大于阈值的特征量构成一个新的特征向量,这个新的特征向量能够反映原来特征向量的关键信息,同时特征量个数减少,从而实现了特征向量的降维。

Relief 算法流程图见图 3。图 3 中 i 为循环次数。




图 3 Relief 算法流程图

Fig. 3 Flowchart algorithm of relief

2.2 基于 Relief 的线圈电流特征向量优化

文中对高压断路器的弹簧操作机构进行了测试试验,弹簧操作机构的额定参数为:额定电压 DC 220 V,控制回路电阻 100 Ω ,铁心间隙 2.5 mm。试验内容包括:正常机构测试,改变操作机构线圈电压、控制回路电阻、铁心间隙、模拟机构卡滞等测试。测试得到线圈电流波形形状与 2.1 节中分析一致,按照 1 节中的特征点,弹簧操作机构线圈电流测试的特征量数据见表 1。

将表 1 中样本 1~11 作为训练样本,样本 12~24 为测试样本。将训练样本的正常情况数据分为一类,非正常情况(机构参数变化及存在卡滞)数据分为另一类。根据图 3 所示的流程计算训练样本的 Relief 权重,其中 $m=10$,程序运行 3 次后各特征量的权重值见图 4。从图 4 可以看出,3 次运行结果基本一致,

权重值大于 0.4 的特征量为 i_1, i_2, i_3, i_4 。根据图 1 典型线圈电流波形可知,阶段 4 电流基本维持恒定(如图 1 所示), i_3 和 i_4 所反映的信息相同,所以二者取一,这里不考虑 i_4 ,则特征量 i_1, i_2, i_3 能够反映样本的特征。定义 T_2 为优化后的特征向量,即 $T_2=[i_1, i_2, i_3]$ 。通过 Relief 算法,将线圈电流波形的 9 个特征量优化为 3 个特征量,大大减少了特征量个数。由于试验条件有限文中涉及样本类型并不完全,如果试验样本类型比较完全的情况下,通过 Relief 算法的得出结果可能有所不同。

3 SOM 自组织特征映射神经网络

SOM(self-organizing map)自组织特征映射神经网络是神经网络中的一种,它不需要先验知识和学习过程的监督^[13-15],能自动找出样本之间的近似程度,从而实现对样本数据的分类。文中采用 SOM 网络对机构测试样本数据进行处理和分类,达到对机构进行状态评估的目的。

3.1 SOM 网络基本结构

SOM 网络的基本结构见图 5。它由输出层(即竞争层)和输入层组成。输入层由 n 个神经元构成,可输入具有 n 维向量的样本;输出层是由 $a \times b$ 个神经元组成的二维平面阵。输入层与竞争层之间实现全连接,竞争层神经元之间形成图 5 中的网格型连接。

将训练样本输入到 SOM 网络进行训练,训练过程中 SOM 网络自动调整第 j 个输出神经元与 n 个输入神经元之间的权值向量 W_j ,向量 W_j 为

$$W_j = [W_{j1}, W_{j2}, W_{j3}, \dots, W_{jn}]。 \quad (2)$$

式(2)中, $W_{j1} \sim W_{jn}$ 表示输出层第 j 个神经元分别与 n 个输入神经元之间的连接权值, $j \in 1, 2, \dots, a \times b$ 。

对于每个样本 SOM 网络只输出竞争获胜的神经元,竞争获胜的神经元即代表样本被 SOM 网络分类后的类别。用训练完成后的 SOM 网络对测试样本进行测试,如测试样本与训练中的某个样本相同,则它们输出结果一致;如测试样本类型与训练中的所有样本均不同,则输出可能与所有训练样本的输出均不同。

3.2 SOM 网络学习算法

SOM 网络能够自动找出输入数据之间的类似度,其学习算法如下:

1)初始化网络。给 n 个连接输入与输出神经元之间的权值 W_j 随机赋予较小的值。输入训练样本 $X = \{x_1, x_2, x_3, \dots, x_n\}$ 。

2)按照式(3)计算输出第 j 个输出神经元与输入样本的距离

表 1 弹簧操作机构线圈电流特征量数据

Table 1 Coil current characteristic data under various states

样本编号	t_1/ms	i_1/A	t_2/ms	i_2/A	t_3/ms	i_3/A	t_4/ms	i_4/A	t_5/ms	机构状态
1	14.00	1.15	15.50	1.13	66.40	2.18	125.20	2.18	227.50	正常
2	14.30	1.15	15.50	1.14	66.70	2.18	124.30	2.18	226.90	正常
3	20.00	1.21	23.30	1.14	78.60	1.79	121.90	1.79	224.20	线圈电压降低 15%
4	16.60	1.57	18.10	1.00	82.40	1.79	123.40	1.79	226.10	线圈电压降低 15%
5	14.90	1.06	17.40	1.03	75.30	1.86	123.80	1.86	204.10	控制回路电阻增加 13%
6	15.00	1.01	17.70	0.97	68.60	1.66	123.30	1.66	208.00	控制回路电阻增加 26%
7	13.00	1.15	15.00	1.11	72.70	2.11	121.00	2.11	225.00	铁心间隙增加 28%
8	13.90	1.14	15.90	1.10	73.50	2.11	123.50	2.11	227.80	铁心间隙增加 12%
9	12.00	1.24	14.40	1.27	62.80	2.52	124.70	2.52	230.30	线圈电压增加 20%
10	11.20	1.21	14.50	1.26	56.20	2.51	124.20	2.51	229.60	线圈电压增加 20%
11	13.40	1.11	15.20	1.10	63.90	2.10	122.80	2.10	228.10	触发器轻微卡滞
12	14.20	1.13	15.40	1.12	66.40	2.18	122.90	2.18	227.50	正常
13	14.50	1.12	16.00	1.10	66.30	2.17	124.10	2.17	226.60	正常
14	19.50	1.15	21.90	1.10	79.60	1.79	123.70	1.79	225.50	线圈电压降低 15%
15	16.20	1.02	18.60	1.79	79.40	1.79	123.00	1.79	225.50	线圈电压降低 15%
16	15.10	1.06	16.30	1.03	75.00	1.86	123.20	1.86	212.60	控制回路电阻增加 13%
17	17.40	1.10	19.70	1.00	68.10	1.66	123.40	1.66	207.70	控制回路电阻增加 26%
18	13.00	1.14	15.40	1.10	83.20	2.11	123.10	2.11	227.70	铁心间隙增加 12%
19	14.50	1.15	16.00	1.11	64.70	2.10	123.00	2.10	228.10	铁心间隙增加 28%
20	11.00	1.22	14.00	1.26	59.10	2.51	122.60	2.51	229.10	线圈电压增加 20%
21	11.40	1.23	14.40	1.27	62.80	2.51	122.20	2.51	227.70	线圈电压增加 20%
22	11.50	1.22	14.80	1.28	70.00	2.51	123.10	2.51	228.90	线圈电压增加 20%
23	13.80	1.14	15.00	1.12	64.00	2.10	121.00	2.10	232.00	触发器轻微卡滞
24	16.00	1.17	17.50	1.15	66.20	2.10	123.70	2.10	235.10	触发器轻微卡滞




图 4 各特征量权重值

Fig. 4 Each feature quantity weights




图 5 SOM 网络结构

Fig. 5 SOM net structure

$$d_j = \|X - W_j\| = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2} \quad (3)$$

计算输入样本与所有输出神经元的距离后,可以确定获胜的输出神经元 l , 获胜输出神经元 l 一定满足关系 $d_l = \min(d_j)$ 。

3) 进行权值的学习。为保证获胜神经元对某一类样本做出最大的响应, 需对获胜神经优胜领域内的神经元进行权值调整。获胜神经元的优胜领域是指获胜神经元周围一定半径的神经元组成的区域, 见图 6, 图 6 中: 黑色圆圈为获胜神经元; 较小矩形框表示半径为 1 的优胜领域; 较大的矩形框表示半径为 2 的优胜领域。




图 6 获胜神经元优胜领域示意图

Fig. 6 Field of winning neurons schematic

优胜领域 $L(m)$ 可按式(4)进行确定

$$L(m)=\text{INT}\left[L(0)\left(1-\frac{m}{M}\right)\right]。 \quad (4)$$

(4)中: $L(0)$ 表示初始优胜领域; m 表示该次为第 m 次网络训练; M 为网络训练的总次数; INT 为取整函数。

按式(5)修正优胜领域内神经元权值向量。

$$w_{ij}=w_{ij}'+\eta(t)(x_i-w_{ij}')。 \quad (5)$$

式(5)中: w_{ij}' 为 w_{ij} 更新前的值, t 为时间; $\eta(t)$ 为学习速率,一般取 $\eta(t)=0.2(1-\frac{t}{10\ 000})$ 。

输入下一个训练样本,重复步骤 1)~3)直至所有训练样本训练完成。

4)按照式(3)计算训练样本 x 与每个神经元的距离,将距离最小的竞争层神经元作为该样本的输出,输出形式为神经元编号,按照这个方法得到每个训练样本输出。

得到每个训练样本的输出后,判断 SOM 网络输出结果是否与样本实际状态一致,如果不一致,重复上述步骤 1)~4),继续对网络进行训练,直到每个训练样本输出结果与样本实际状态一致为止。

4 基于特征量优化的高压断路器操作机构状态评估

利用在 4 节中建立的 SOM 分类网络模型分别对优化前 T_1 向量样本和优化后 T_2 向量样本进行分类训练,训练样本和测试样本数据如表 1 所示,其中样本 1-11 为训练样本,样本 12-24 为测试样本,训练样本共分为 6 类。将 SOM 输出神经元数目设置为 3×3 ,理论上可将所有样本分为 9 类,即这 11 个样本的训练输出值为 1-9 之间的整数,输出为 1 表示该样本为第 1 类。SOM 网络参数初始化设置:初始优胜领域 $L(0)=1$ 。

4.1 特征向量优化前

对未优化的线圈电流样本进行训练,训练后的网络称为 T_1 网络。当训练次数为 200 次、训练时间为 4s 时,网络达到了预设目标。训练结果见表 2。表 2 中:训练输出结果 1 表示线圈电压增加;2 表示触发器轻微卡滞;4 表示机构状态正常;6 表示控制回路电阻增加;7 表示线圈电压降低;8 表示电磁铁铁芯气隙增加;3、5、9 表示其他状态。从表 2 可以看出训练后的 SOM 网络能够实现对机构状态的准确分类,表格左边 3 列为分类结果。

将未进行特征量优化的样本 12-24 输入 T_1 网络,对 T_1 网络进行测试,测试结果见表 2 的右边两列。从表 1、2 可以看出,训练后的 T_1 网络能够对训

表 2 特征量未优化前训练及测试评估结果

训练样本编号	机构状态	训练输出结果	测试样本编号	评估结果
1	正常	4	12	4
2	正常	4	13	4
3	线圈电压降低	7	14	7
4	线圈电压降低	7	15	7
5	控制回路电阻增加	6	16	6
6	控制回路电阻增加	6	17	6
7	铁心间隙增加	8	18	8
8	铁心间隙增加	8	19	8
9	线圈电压增加	1	20	1
10	线圈电压增加	1	21	1
11	触发器轻微卡滞	2	22	1
—	—	—	23	2
—	—	—	24	2

练样本机构的状态进行准确评估。

4.2 特征量优化后

同样对优化后的线圈电流样本进行训练,训练后的网络称为 T_2 网络。当训练次数为 100 次、训练时间为 1.5 s 时,网络达到了预设目标。训练结果见表 3 左边 3 列。表 3 中:训练输出结果 1 表示线圈电压降低;3 表示线圈电压增加;5 表示正常;6 表示触发器轻微卡滞;7 表示控制回路电阻增加;9 表示电磁铁铁芯气隙增加;2、4、8 表示其他状态。从表 3 可以看出训练后的 SOM 网络能够实现对机构状态的准确分类。将未进行特征量优化的样本 12-24 输入 T_2 网络,对 T_2 网络进行测试,测试结果见表 3 的右边两列。由表 1 和表 3 可知,经过优化后的特征向量训练的 T_2 网络也能够准确对断路器操作机构进行状态评估,且 T_2 网络训练时间和训练次数比 T_1 网络都大大减小。

表 3 特征量优化后训练测试评估结果

训练样本编号	机构状态	训练输出结果	测试样本编号	评估结果
1	正常	5	12	5
2	正常	5	13	5
3	线圈电压降低	1	14	1
4	线圈电压降低	1	15	1
5	控制回路电阻增加	7	16	7
6	控制回路电阻增加	7	17	7
7	电磁铁铁心间隙增加	9	18	9
8	电磁铁铁心间隙增加	9	19	9
9	线圈电压增加	3	20	3
10	线圈电压增加	3	21	3
11	触发器轻微卡滞	6	22	3
—	—	—	23	6
—	—	—	24	6

4.3 特征量优化对 SOM 网络的影响

特征向量维数的变化,除了影响网络训练的速度外,还可能对网络分辨能力有所影响。特征向量优化前后获胜神经元的分布情况见图 7。图 7 中,六边形为输出层的各个神经元,获胜的神经元用带数字的椭圆表示,其中数字表示被分类到该神经元的样本数,相邻神经元之间的距离(即相似程度)用颜色深浅的菱形表示,颜色越深表明两个神经元之间的距离越远,颜色越浅,表明两个神经元之间可区分程度越小,即出现误判的几率增大。从图 7 可以直观了解神经元分类训练结果,图 7(a)中颜色浅的菱形相对图 7(b)少,表明 T_1 网络各个输出神经元之间的距离相对 T_2 大,具有更好的分辨性。图 7 虽然体现了相邻神经元之间的近似程度(即距离),但不够具体,为此给出 SOM 网络神经元权值分布图见图 8。图 8 中黑色圆点表示输出神经元,从图 8 中更加直观地看出 T_2 网络的输出神经元相对 T_1 密集,表明 T_2 网络的分辨率确实比 T_1 低。根据对特征量优化前后 SOM 网络输出神经元分类及权重分布情况看,特征量优化在一定程度上减弱了网络的分辨率,但是从样本测试情况看,不影响对样本的正确分类,能满足高压断路器操作机构状态评估的要求。




图 7 网络训练分类情况

Fig. 7 Winning neuron distribution of training




图 8 SOM 网络输出神经元权重分布对比

Fig. 8 SOM output neural weight distribution comparison

5 结语

针对高压断路器操作机构分合闸线圈电流特征量个数较多,线圈电流样本分类处理时运算量大且运行时间相对较长,存在冗余特征量的问题,文中提出了采用 Relief 特征权重方法对线圈电流特征向量进行优化。为进行断路器操作机构状态评估,建立 SOM 网络分别对基于优化前后线圈电流特征量的样本进行训练和测试,训练和测试结果表明:①所建立 SOM 网络能够对断路器操作机构状态准确评估;②采用优化后的特征向量将 SOM 网络训练的运算量和运算时间大大减小(训练时间从 4 s 减至 1.5 s,训练次数减少了一半),且特征量的优化不影响对机构状态的准确评估;③提出的基于 Relief 的线圈电流特征向量优化方法对于文中的线圈电流样本和故障类型是准确和有效的。

参考文献:

- [1] ANDRUȘCĂ M, ADAM M, PANTELIMON R, et al. About diagnosis of circuit breakers[C]//International Symposium on Advanced Topics in Electrical Engineering. Buchares: IEEE, 2013: 1-4.
- [2] JOHA H, MOUSAVI M J. Coil current analysis method for predictive maintenance of circuit breakers[C]//Transmission and Distribution Conference and Exposition. Chicago: IEEE, 2008: 1-7.
- [3] FOROOTANI A, AFZALIAN A, MELLI A. Circuit breaker coil modeling and operation monitoring using feature extraction[C]//Innovative Smart Grid Technologies-Asia (ISGT Asia). [S.l.]: IEEE, 2012: 1-6.
- [4] RAZI-KAZEMI A A, VAKILIAN M, NIAYESH K, et al. circuit-breaker automated failure tracking based on coil current signature[J]. IEEE Transactions on Power Delivery, 2014, 29(1): 283-290.
- [5] 黄凌洁, 王玮, 吴振升, 等. 基于模糊理论的高压 SF₆ 断路器故障诊断模型的研究[J]. 高压电器, 2008, 44(3): 246-249.
HUANG Lingjie, WANG Wei, WU Zhensheng, et al. Diagnosis model of HV SF₆ circuit breaker based on fuzzy theory artificial immune network[J]. High Voltage Apparatus, 2008, 44(3): 246-249.
- [6] 杨志泽, 梁良, 李小勇, 等. 灰色关联模型在高压断路器故障诊断中的应用[J]. 电网技术, 2015, 39(6): 1731-1735.
YANG Zhize, LIANG Liang, LI Xiaoyong, et al. Application of the gray correlation model in fault diagnosis of high-voltage circuit breakers[J]. Power System Technology, 2015, 39(6): 1731-1735.

- [7] 程 序,关永刚,张文鹏,等.基于因子分析和支持向量机算法的高压断路器机械故障诊断方法[J]. 电工技术学报,2014,29(7):209-215.
CHENG Xu, GUAN Yonggang, ZHANG Wenpeng, et al. Diagnosis method on the mechanical failure of high voltage circuit breakers based on factor analysis and SVM [J]. Transactions of China Electrotechnical Society, 2014, 29 (7): 209-215
- [8] 梅 飞,梅 军,郑建勇,等.粒子群优化的 KFCM 及 SVM 诊断模型在断路器故障诊断中的应用[J]. 中国电机工程学报,2013,33(36): 134-141.
MEI Fei, MEI Jun, ZHENG Jianyong, et al. Application of particle swarm fused KFCM and classification model of SVM for fault diagnosis of circuit breaker[J]. Proceedings of the CSEE, 2013, 33(36): 134-141.
- [9] 徐建源,张 彬,林 莘,等.能谱熵向量法及粒子群优化的 RBF 神经网络在高压断路器机械故障诊断中的应用[J]. 高电压技术,2012,38(6):1299-1306.
XU Jianyuan, ZHANG Bin, LIN Xin, et al. Application of Energy spectrum entropy vector method and RBF neural network optimized by the particle swarm in high voltage circuit breaker mechanical fault diagnosis[J]. High Voltage Engineering, 2012, 38(6): 1299-1306.
- [10] 吴艳文,胡学钢,陈效军.基于 Relief 算法的特征学习聚类[J]. 合肥学院学报(自然科学版),2008,18(2): 45-48.
WU Yanwen, HU Xuegang, CHEN Xiaojun. Feature learning clustering based on Relief algorithm[J]. Journal of Hefei University(Natural Sciences), 2008, 18(2): 45-48.
- [11] 李晓岚.基于 Relief 特征选择算法的研究与应用[D]. 大连:大连理工大学,2013.
LI Xiaolan. The study and application of feature selection algorithms based on Relief[D]. Dalian: Dalian University of Technology, 2013.
- [12] 李先锋.基于特征优化和多特征融合的杂草识别方法研究[D]. 镇江:江苏大学,2010.
LI Xianfeng. Research of weed recognition method based on feature optimization and multi-feature fusion[D]. Zhenjiang: Jiangsu University, 2010.
- [13] HAYKIN S.神经网络原理[M]. 叶世伟,史忠植,译. 北京:机械工业出版社,2004.
HAYKIN S. Neural networks[M]. YE Shiwei, SHI Zhongzhi, Translation. Beijing: China Machine Press, 2004.
- [14] 刘 绚,文 俊,刘天琪.基于自组织神经网络的模糊聚类同调机群识别[J]. 电网技术,2010,34(7):98-101.
LIU Xuan, WEN Jun, LIU Tianqi. A fuzzy clustering method to recognize coherent generator groups based on self-organizing neural network[J]. Power System Technology, 2010, 34(7): 91-101.
- [15] 薛 峰,张佑生,江巨浪,等.基于改进 SOM 的纹理合成算法[J]. 系统仿真学报,2006,18(3):581-585.
XUE Feng, ZHANG Yousheng, JIANG Julang, et al. Synthesizing texture using variant SOM[J]. Journal of System Simulation, 2006, 18(3): 581-585.
- 张 浩(1991—),男,硕士研究生,研究方向为电力设备状态评估。
赵莉华(1968—),女,副教授,博硕士生导师,研究方向为电器设备监测技术、新能源发电及并网技术、电能质量。

(上接第 239 页)

- CHENG Ning. Quality improvement of concentricity of rod axle and ring[J]. New Technology & New Process, 2012 (12):85-87.
- [17] 黎 斌. SF₆ 高压电器设计[M]. 北京:机械工业出版社, 2003.
LI Bin. Design of SF₆ high voltage electrical apparatus[M]. Beijing: China Machine Press, 2003.
- [18] 吴 钟. 断路器的操动系统(二)[J]. 高压电器, 1974, 14 (6):23-33.
WU Zhong. Operating system of circuit breaker(2)[J]. High Voltage Apparatus, 1974, 14(6): 23-33.
- 赵现平(1974—),男,高级工程师,研究方向为开关类设备绝缘状态检测技术研究。
马宏明(1987—),男,工程师,硕士,研究方向为高压开关设备状态评价。
程志万(1987—),男,工程师,本科,研究方向为高压开关设备状态评价。