

DOI:10.13296/j.1001-1609.hva.2018.09.016

基于多信息融合的变压器故障诊断

袁海满, 吴广宁

(西南交通大学电气工程学院, 成都 610031)

摘要: 目前变压器故障诊断中,以油色谱数据为主的诊断方法信息量不足,同时,基于单一智能算法的故障判断能力有限。鉴于此,文中构建了一种基于多信息融合的变压器故障诊断模型。该方法首先将电气试验等数据与17组油中特征气体含量比值相结合作为故障特征量,以获得更丰富的故障信息,并采用特征敏感性评估与核主元分析方法对所选定的故障信息进行特征降维融合,以实现多层面故障信息的互补。其次,将降维融合后的9维特征量分别作为BP神经网络、SVM及贝叶斯方法的特征输入,进行故障类型的初步判定。最后,若初步诊断结果不存在分歧,则直接得出结论;否则,基于证据理论方法分别计算各证据体的基本信任分配,并运用Dempster组合规则进行决策融合,以做出更合理的故障判断。实例分析表明,该方法有效解决了信息单一和方法单一的问题,且有效提高了故障识别准确率。

关键词: 变压器; 证据理论; 信息融合; 核主元分析; 故障诊断

Fault Diagnosis of Transformer Based on Multi-information Fusion

YUAN Haiman, WU Guangning

(School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: For current fault diagnosis of power transformer, the method based on dissolved gas chromatographic data analysis is insufficient in fault information, and its diagnostic capability based on single algorithm is limited. This paper proposes a transformer fault diagnosis method based on multiple information fusion. The method firstly combines the data of electrical test with 17 groups of the concentrations of characteristic gas components in oil to achieve more fault information. The feature sensitivity evaluation and the kernel principal component analysis (KPCA) are used to reduce the feature dimension of the selected fault data to realize complementary of the multi-level fault information. Then, the nine-dimensional features after dimension reduction are taken as the input characteristic parameters of the BP neural network, the support vector machine (SVM) and the Bayesian method to determine fault type. Subsequently, a conclusion is output if there is no disagreement on the preliminary diagnosis result, otherwise, the basic belief assignment of each evidence is recalculated and the Dempster combination rule is used for decision fusion to make more reasonable fault judgment. Example analysis shows that the proposed method can effectively deal with the problems of insufficient information and single method, and improve diagnostic accuracy.

Key words: transformer; evidence theory; information fusion; kernel principal component analysis; fault diagnosis

0 引言

作为电力网络中最为重要的高压电气设备,变压器在电力的传输和分配中承担着核心任务。因变压器故障造成的非计划停电可能导致能量传输

的中断,从而影响整个系统的运行稳定性,并带来巨大经济损失^[1]。同时,随着电力设备的状态检修模式逐步深入^[2-3]变压器故障状态的准确判断对于制定有效状态检修计划及保证系统稳定运行而言更具切实意义。

收稿日期:2018-04-07; 修回日期:2018-06-09

基金项目:国家自然科学基金项目(U1234202)。

Project Supported by National Natural Science Foundation of China(U1234202).

近年来,变压器故障诊断方法经由最初的特征气体组分含量比值法到智能算法的发展历程,为变压器故障诊断研究提供众多参考,且使得故障诊断准确率得到了较大提升。然而,众多诊断方法中并未具备既高效又稳定的方法。究其原因,现行变压器故障诊断过程中依然存在下述2个关键问题未得到妥善解决:第一,故障特征信息单一。变压器作为一个多元复杂结构体^[4],影响其运行状况的因素非常多,在其出现异常事故时,相应能够反映故障状态的特征信息必定也比较多,但以往的研究多局限于油色谱层面,而油色谱数据所携带及能够呈现的信息较为有限,因此,仅将油色谱数据作为故障特征参量显得过于单一,未能将变压器的诸多有价值信息加以充分挖掘利用^[5];第二,单一诊断方法能力不足。变压器故障通常具有一定多样性、复杂性,此外,故障特征信息数据含有大量的异常变化趋势及不确定因素,致使二者之间的对应关系不够明确,且相互之间存在着较大模糊性^[4,6-8],由此可知,仅运用单一的诊断无法完成诊断任务。

针对上述问题,国内外学者进行了诸多研究,但其研究多基于某一层面的不足进行改进,并未将特征量与单一方法所存在的问题综合处理解决。文[6,9-10]将多种算法融合以改进算法性能提高诊断效率,取得了一定的效果,但其本质上仍是基于单一算法的故障分类;文[11-13]解决了特征单一问题,一定程度上提高了判断准确度,但其在特征融合及单一诊断方法不足层面仍未有效解决;文[14-16]将多个单一算法的诊断结果作为二次判断的输入或证据体进行综合判断,以得出较为客观合理的结论,此类研究解决了单一方法能力不足问题,但其特征量的选取仍局限于DGA层面,因此,其最终判断效果依然不够理想。

基于上述分析,为克服现有诊断方法的不足,文中考虑从特征信息融合与故障诊断决策层面进行改进,在此基础上,提出了一种多信息融合的故障诊断方法。在对变压器众多故障因素充分分析的基础上,对变压器故障与各种故障征兆特征之间的联系进行了协同分析,确定将变压器电气试验等数据与DGA相结合作为故障特征参量,并利用特征敏感性评估及核主元分析方法(kernel principal component analysis, KPCA)对特征信息进行融合,以解决故障特征信息的单一问题;同时,作为一种不确定推理的数学方法,dempster-shafer(D-S)证据理论能够对不确定问题进行建模与推理,为不确定信息的融合提供了一种有效的途径,此外,证据理论

能够将多个初步诊断结果进行有效融合,且能够高效、准确地识别故障^[17]。鉴于此,考虑将BP神经网络、SVM、贝叶斯网络的初步诊断结果作为D-S证据理论的证据体,利用证据合成规则将三种方法的判断结果进行决策融合,以得到较单一方法更准确的结论。

1 理论基础

1.1 证据理论简介

定义1: 设定 Ω 是一辨识框架,若集函数 $m:2^\Omega \rightarrow [0,1]$ (2^Ω 为 Ω 的幂集)满足

$$\begin{cases} m(\phi) = 0 \\ \sum_{A \subseteq \Omega} m(A) = 1 \end{cases} \quad (1)$$

则称 m 为 Ω 上的基本信任分配(basic probability assignment, BPA),也即对命题的信任度。

定义2: 设定 Ω 是一辨识框架, $\forall A \subseteq \Omega$, $m(A)$ 称作 A 的基本信任函数(或mass值)。

定义3: 设定 Ω 是一辨识框架, $\forall A \subseteq \Omega$, $m(A) > 0$,则将 A 称作焦元。

定义4: 设定同一辨识框架 Ω 上的 n 组BPA分别为 $m_1, m_2, \dots, m_n$,相应焦元分别为 $A_i (i=1, 2, \dots, N)$,则Dempster规则为

$$m(A) = \begin{cases} 0 & A = \phi \\ \frac{\sum_{\bigcap_{i=1}^k A_i = A} \prod_{i=1}^k m_i(A_i)}{1 - k} & A \neq \phi \end{cases} \quad (2)$$

式(2)中

$$k = \sum_{\bigcap_{i=1}^k A_i = \phi} \prod_{i=1}^k m_i(A_i) \quad k \neq 1 \quad (3)$$

式(3)中, k 称作 n 组证据的合取冲突。

1.2 多证据体构造及特征融合

由于故障特征信息的获取存在不完备性、数据信息缺失等问题,使得单一诊断方法不能得到更理想的诊断效果。基于此,文中采用基于D-S证据理论的故障决策信息方法,将多种方法的初步诊断结果进行融合决策。已有研究表明^[17-18],BP神经网络、SVM及贝叶斯网络在BPA的构造方面具有一定的优势。文中考虑运用上述3种诊断方法进行初步诊断,并通过诊断结果构造证据理论的证据体,证据体具体构造方法同文[18]。

变压器的全景故障状态特征信息具有来源多、数量庞大、属性繁多及信息异构等特点。因此,原始故障特征信息的简单合并不能故障状态评价模型的需求。主要原因由于是不完备的先验知识,导致在进行特征参量筛选过程中具有一定的盲目性,

难免带来一些问题:其一是过多的特征参量会影响训练速度、训练的收敛性,进而影响最终的诊断精度;其二是对变压器状态变化不敏感特征数据的介入,往往会对特征参量提取以及其分类性能产生较大的不良影响。此外,由文[19–20]可知:KPCA在保持数据分类性能不变的情况下消除冗余信息及数据降维方面具备良好的能力,同时敏感性评估能够降低不敏感数据对KPCA性能的影响,具有良好的辅助效果。综述分析,为有效提高特征融合质量,文中考虑采用特征敏感性评估与KPCA相结合的方法进行特征融合,具体特征融合方法同文[19–20]所述。

2 多信息融合模型及诊断

为有效提高故障诊断效率,文中构建了一种多信息融合模型,见图1。该模型主要包括以下模块:数据预处理、特征信息融合、初步诊断和故障决策融合诊断,其中,特征信息融合与故障决策融合诊断模块是模型的核心环节。




图1 多信息融合故障诊断模型图
Fig. 1 Multi information fusion fault diagnosis model

2.1 特征数据的选取及预处理

1)特征选取。由于能够反映变压器状态信息的

特征量比较繁多,若将变压器中所有的特征状态量考虑在内,那么故障判断体系将变得极其复杂,此外部分特征量较为模糊,不宜进行定量描述,所以这些冗余特征会对全面且准确的变压器故障评估效果产生不利影响。鉴于此,根据前期研究及文[9, 10, 21]的基础上,文中最终筛选出34种能够有效反映出变压器运行状况的特征量作为故障特征,具体故障特征集见表1。

表1 变压器故障特征集
Table 1 Transformer fault feature set

特征编号	故障特征	特征编号	故障特征
S ₁	油击穿电压	S ₁₈	C ₂ H ₂ /H ₂
S ₂	油中微水含量	S ₁₉	C ₂ H ₂ /C ₂ H ₄
S ₃	绝缘油介损	S ₂₀	C ₂ H ₂ /C ₂ H ₆
S ₄	体积电阻率	S ₂₁	C ₂ H ₂ /CH ₄
S ₅	极化指数	S ₂₂	C ₂ H ₄ /C ₂ H ₆
S ₆	吸收比	S ₂₃	C ₂ H ₄ /CH ₄
S ₇	铁心绝缘电阻	S ₂₄	C ₂ H ₄ /H ₂
S ₈	铁心接地电流	S ₂₅	C ₂ H ₂ /CH ₄
S ₉	绕组直流电阻互差	S ₂₆	C ₂ H ₆ /H ₂
S ₁₀	绕组短路阻抗初值差	S ₂₇	CH ₄ /H ₂
S ₁₁	绕组绝缘介损	S ₂₈	C ₂ H ₂ /总烃
S ₁₂	绕组电容初值差	S ₂₉	H ₂ /总烃
S ₁₃	局部放电量	S ₃₀	C ₂ H ₄ /总烃
S ₁₄	中性点油流静电电流	S ₃₁	CH ₄ /总烃
S ₁₅	糠醛含量	S ₃₂	C ₂ H ₆ /总烃
S ₁₆	绝缘纸板聚合度	S ₃₃	(CH ₄ +C ₂ H ₄)/总烃
S ₁₇	油中含气量	S ₃₄	CO/CO ₂

变压器作为一个结构复杂体,其对应的故障类型复杂多样,较难进行细致化分类。鉴于此,文中参照 IEC 60599:2015 及 GB/T 7252—2001 导则,将变压器的故障类型具体分为7大类,相应类型见表2。

表2 变压器故障类型
Table 2 Types of power transformer fault

故障编号	故障类型
F ₁	中低温过热(低于 700 °C)
F ₂	高温过热(高于 700 °C)
F ₃	低能放电
F ₄	高能放电
F ₅	局部放电
F ₆	低能放电兼过热
F ₇	高能放电兼过热

2)数据预处理。由于17组特征气体样本数据比值之间会存在较大差异且以及DGA数据中异常

数据,从而影响样本质量,为此,考虑采用文[11]所提方法对其进行归一化处理。此外,因铁心接地电流、绝缘油介损等电气试验数据具有较大的分散性,为减轻其对数据质量的影响,参照文[22]的处理方法对其进行处理。

2.2 特征信息的融合

单一DGA特征信息的信息含量较为局限,只能从某一方面反映出变压器故障状况,然而变压器的故障往往存在一定的潜伏性,仅依靠DGA数据难以挖掘出变压器具体故障信息。为此,将电气试验数据、在线监测数据与DGA相结合作为特征参量,以实现特征信息之间的信息互补,从而得到较单一信息更为丰富的故障特征信息组合。

特征信息的融合能够有效提高诊断效率及故障决策融合的效果。但特征的简单融合会导致特征样本出现高维性、冗余性等问题的出现,致使最终分类性能降低。由文[20-21]可知,特征敏感性评估能够有效降低故障特征中对故障不敏感的故障参量。同时,KPCA在降维融合及清除冗余特征方面具有良好的性能,并且能够有效保持特征的分类能力。为此,文中首先利用敏感性评估方法对故障特征进行初步融合。可分性指标与特征比例因子之间的关系曲线见图2。经分析,文中确定特征比例因子的阈值 $\beta=0.35$,结合得到阈值与计算得到的各特征量的特征比例因子(见图3)进行对比,最终将 $S_1, S_5, S_{12}, S_{15}, S_{23}, S_{25}, S_{26}$ 冗余特征初步剔除进行降维融合;然后利用KPCA对剩余的27维特征量进行最终降维融合处理。特征值及贡献率见表3,贡献率随主元变化趋势图见图4。根据KPCA累积贡献率不低于90%的要求,并结合表3与图4可知,最终特征量降维融合的维数为9。其中基于敏感性评估与KPCA的特征信息降维融合方法及步骤同文[22]。




图2 可分性指标与特征比例因子的变化关系

Fig. 2 Relationship between the reparability index and the filter scale factor




图3 34种特征量的特征比例因子

Fig. 3 Characteristic scale factor of 34 kinds characteristic

表3 特征值及贡献率

Table 3 Eigenvalues and the contribution rate

主元序号	特征编号	特征值	贡献率/%	累计贡献率/%
1	S_{22}	6.549	23.256	23.256
2	S_{27}	5.353	18.668	41.924
3	S_{19}	3.920	13.942	55.886
4	S_8	2.667	9.974	65.840
5	S_{13}	2.012	8.242	74.082
6	S_{30}	1.625	6.347	80.429
7	S_{11}	1.314	5.240	85.669
8	S_6	1.197	4.109	89.778
9	S_{34}	1.003	3.634	93.412




图4 贡献率随主元变化趋势图

Fig. 4 Variation trend of contribution rate along with the main element

2.3 初步诊断

将进行特征信息融合后样本数据输入到初步诊断模块中,分别利用BP神经网络、SVM及贝叶斯方法进行故障的初步诊断。然后将其诊断输出转化为相应辨识框架下的BPA,以获得便于进行故障决策融合所需的证据体。

2.4 故障决策融合诊断

若3种诊断方法的初步判断结果一致,那么可直接得出决策诊断结果;若其诊断结果不一致,则

需要对其进行证据融合。在进行证据融合之前需要判定 k 值,若 $k=1$,则表示证据之间完全冲突,此时D-S证据合成规则则失效;若 $k<1$,表示证据体之间不完全冲突,则可以使用D-S证据合成规则。

3 实例诊断及对比分析

3.1 基于D-S证据理论的故障决策融合

以某 220 kV 主变(型号为SFSZ10-180000/220)的 363 组故障样本数据进行实例验证,其中 121 组为测试样本数据。

表 4 样本数据
Table 4 Sample data

H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	吸收比	铁心接地电流/A	绕组绝缘介损/%	局部放电量/pC	故障类型
49.2	33.2	1.4	49.9	15.0	1.59	0.090	0.70	74	F ₂
53.9	8.3	7.1	6.0	1.1	1.30	0.115	0.80	190	F ₃
5 945.0	7 964.0	57.4	26 979.0	5 835.0	1.07	0.238	0.92	512	F ₇

对表 4 所给出的数据进行预处理,并用 BP、SVM 及 Bayesian 方法分别对其进行初步诊断,表 5-7 分别对应的是 3 种方法的诊断输出。通过对比分析发现,上述 3 种方法最终得到的结论并不完全一致,因此,需要对其进行进一步决策融合,以得到准确的判断结果。

表 5 BP 诊断输出
Table 5 BP diagnostic output

F ₁	F ₂	F ₃	F ₄	F ₅	F ₆	F ₇
0.632 8	0.330 5	0.051 2	0.016 9	0.023 5	0.067 1	0.074 9
0.073 5	0.010 2	0.699 7	0.070 1	0.129 2	0.049 5	0.100 3
0.003 2	0.520 2	0.021 7	0.105 9	0.130 7	0.001 1	0.260 9

表 6 SVM 诊断输出
Table 6 SVM diagnostic output

F ₁	F ₂	F ₃	F ₄	F ₅	F ₆	F ₇
0.134 6	0.729 4	0.009 7	0.112 2	0.033 4	0.051 4	0.039 5
0.004 7	0.051 1	0.810 9	0.021 9	0.061 5	0.240 3	0.001 5
0.020 9	0.006 1	0.152 6	0.600 5	0.002 2	0.000 7	0.330 6

表 8 基于BP诊断输出的BPA
Table 8 The output of the BPA based on BP diagnostic

$m(F_1)$	$m(F_2)$	$m(F_3)$	$m(F_4)$	$m(F_5)$	$m(F_6)$	$m(F_7)$	$m(\theta)$
0.406 7	0.212 4	0.032 9	0.010 9	0.015 1	0.043 1	0.048 1	0.230 7
0.052 7	0.007 3	0.502 0	0.050 3	0.092 7	0.035 5	0.072 0	0.187 5
0.002 3	0.367 3	0.015 3	0.074 8	0.092 3	0.000 8	0.184 2	0.263 1

故障决策融合主要的目的就是多个初步诊断结果进行有效融合,得到一个比较综合的故障判断结论,以能高效、准确地进行故障分类。D-S证据理论最为基本的策略就是将各证据体划分成为互不相关的个体,其次分别在辨识框架下进行独立的判断,最后运用 Dempster 规则进行决策融合。文中正是基于此种情况下考虑采用证据理论方法对 3 种方法的初步诊断结果进行综合处理,从而得到合理的故障判断结果。文中以 3 组样本数据为例进行故障决策信息的融合,并验证该方法的有效性,样本数据见表 4。

表 7 Bayesian 诊断输出
Table 7 Bayesian diagnostic output

F ₁	F ₂	F ₃	F ₄	F ₅	F ₆	F ₇
0.052 7	0.890 2	0.023 7	0.102 3	0.003 7	0.013 1	0.029 3
0.071 9	0.760 8	0.151 2	0.031 8	0.110 4	0.002 4	0.008 3
0.034 4	0.008 6	0.091 2	0.157 7	0.082 2	0.001 3	0.721 1

其次,按照文[18]中 BPA 的计算方法计算各种智能诊断输出的 BPA,3 种诊断方法的 BPA 情况见表 8-10。然后,利用式(3)计算各组数据的 k 值,通过计算得到 3 组数据的 k 值分别为 0.91、0.90 和 0.97,由第 2 节的第 4 部分可知,各证据体满足 Dempster 组合规则的基本要求。

最后,按照式(2)、(3)将 3 种诊断方法的诊断结果进行决策融合。表 8-10 的融合结果见表 11,将表 8-11 之间进行对比分析可以看出:经过决策信息融合之后不仅其相应诊断决策的置信度均得到了提升,而且其融合决策诊断的不确定度 $m(\theta)$ 的降幅非常明显。此外,通过对比表 4 与表 11 可知,经过决策融合所得出 3 组数据的判断结果与实际故障状况一致。

表9 基于SVM诊断输出的BPA

Table 9 The output of the BPA based on SVM diagnostic

$m(F_1)$	$m(F_2)$	$m(F_3)$	$m(F_4)$	$m(F_5)$	$m(F_6)$	$m(F_7)$	$m(\theta)$
0.102 4	0.554 9	0.007 4	0.085 4	0.025 4	0.039 1	0.030 1	0.155 4
0.003 4	0.036 8	0.583 9	0.015 8	0.044 3	0.173 0	0.001 1	0.141 8
0.015 0	0.004 4	0.109 6	0.431 3	0.001 6	0.000 5	0.237 4	0.200 2

表10 基于Bayesian诊断输出的BPA

Table 10 The output of the BPA based on Bayesian diagnostic

$m(F_1)$	$m(F_2)$	$m(F_3)$	$m(F_4)$	$m(F_5)$	$m(F_6)$	$m(F_7)$	$m(\theta)$
0.041 1	0.694 5	0.018 5	0.079 8	0.002 9	0.010 2	0.022 9	0.130 1
0.139 1	0.147 2	0.292 5	0.061 5	0.213 6	0.004 6	0.016 1	0.125 3
0.025 3	0.006 3	0.067 2	0.116 2	0.060 6	0.001 0	0.531 2	0.192 2

表11 D-S证据理论故障决策融合结果


Table 11 Fault decision fusion results of D-S evidence theory

$m(F_1)$	$m(F_2)$	$m(F_3)$	$m(F_4)$	$m(F_5)$	$m(F_6)$	$m(F_7)$	$m(\theta)$
0.018 776	0.897 661	0.000 049	0.000 811	0.000 012	0.000 189	0.000 363	0.082 155
0.000 262	0.000 418	0.904 187	0.000 515	0.009 246	0.000 301	0.000 013	0.085 058
0.000 030	0.000 336	0.003 715	0.123 361	0.000 291	0.000 000	0.765 082	0.107 185

3.2 故障诊断效果对比分析



为能有效验证文中所构建的多信息融合故障诊断模型的有效性,文中主要从以下3个层面进行验证对比:

1)以DGA等5种特征气体作为故障特征参量,分别利用BP神经网络、SVM、Bayesian及多信息融合模型对其进行故障识别分类,故障分类结果见图5。

图5 基于M₁的故障诊断诊断结果Fig. 5 The fault diagnosis results based on M₁

2)以表1中的34种特征集作为故障特征量,分别利用BP神经网络、SVM、Bayesian及多信息融合模型对其进行故障识别分类,故障分类结果见图6。

3)以表3中特征信息融合后所得到的9种特征量作为特征输入,分别利用上述4种方法对其进行故障类型的判断,故障分类结果见图7。

图6 基于M₂的故障诊断诊断结果Fig. 6 The fault diagnosis results based on M₂图7 基于M₃的故障诊断诊断结果Fig. 7 The fault diagnosis results based on M₃

通过对图5-7进行单独分析可以看出:经过信息融合之后的故障判断效果较BP、SVM及Bayesian诊断方法相比均有明显的提升。对比图5、6可以看

出:未经特征信息融合处理的故障判断效果劣于仅基于DGA作为故障输入的结果。其主要原因是由于冗余信息的存在不仅增加维度及复杂度,而且还会影响训练速度及收敛性,从而影响最终的故障诊断精度;对比图5、7可以看出:从纵向层面分析,经过特征信息融合后的故障识别效率明显优于单一DGA的判断结果;从横向层面分析,经过多信息融合模型所得到的故障诊断准确率优于单一诊断方法,使得判断效率得到了进一步提升。

综上所述,所构建多信息融合故障诊断模型的诊断效果不仅优于基于单一DGA的故障判断结果,而且其故障识别效果较单一诊断方法更具优势,因此,文中所构建的故障方法具有良好的变压器故障识别效果。

4 结论

将电气试验等数据与17组DGA特征气体的比值相结合作为故障特征量,并采用敏感性评估与KPCA对其进行特征信息的降维融合,同时,将BP神经网络、SVM、贝叶斯方法的初步诊断结果作为证据体,利用证据理论的Dempster组合规则进行故障决策融合,得出如下结论:

1)将变压器的离线试验数据等与DGA特征气体的比值相结合,解决了故障特征参量过于单一,从而无法从多层面反映变压器故障状况等问题,实现了多层面特征信息的互补,丰富了变压器故障判断依据。

2)利用敏感性评估与KPCA对所选取的特征量降维融合,实现了多层次特征信息的互补融合,使得更多有价值的初始特征信息得到保留。同时,利用Dempster组合规则对存在冲突的证据体进行融合得到判断结论,有效解决了证据体间的分歧,使得多种算法的故障识别结果得到有效融合。

3)相较于传统诊断方法,文中从多层面综合分析变压器的故障状况,并利用证据理论对多种智能方法的判断结果进行融合,其故障识别方法更具一般性。

参考文献:

- [1] LI Shuaibing, WU Guangning, GAO Bo, et al. Interpretation of DGA for transformer fault diagnosis with complementary SaE-ELM and arctangent transform[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2016, 23(2): 586-595.
- [2] IEEE guide for the evaluation and reconditioning of liquid immersed power transformers: IEEE Std C57.140™—2006[S]. 2007.
- [3] 廖瑞金, 张懿议, 黄飞龙, 等. 基于可拓分析法的电力变压器本体绝缘状态评估[J]. 高电压技术, 2012, 38(3): 521-526.
LIAO Ruijin, ZHANG Yiyi, HUANG Feilong, et al. Power transformer condition assessment strategy using matter element analysis[J]. High Voltage Engineering, 2012, 38(3): 521-526.
- [4] 杨廷方, 周力行, 李景禄, 等. 基于最优权值的组合模型诊断变压器故障[J]. 电网技术, 2013, 37(1): 190-194.
YANG Tingfang, ZHOU Lixing, LI Jinglu, et al. Power transformer fault diagnosis based on optimal weights combined model[J]. Power System Technology, 2013, 37(1): 190-194.
- [5] TANG W H, WU Q H. Condition monitoring and assessment of power transformers using computational intelligence[M]. New York: Springer Verlag Press, 2011: 95-104.
- [6] 张凯, 黄华平, 杨海涛, 等. 利用改进遗传算法与LS-SVM进行变压器故障诊断[J]. 电网技术, 2010, 34(2): 164-168.
ZHANG Kai, HUANG Huaping, YANG Haitao, et al. A transformer fault diagnosis method integrating improved genetic algorithm with least square support vector machine[J]. Power System Technology, 2010, 34(2): 164-168.
- [7] 谷凯凯, 郭江. 紧致融合模糊集和故障树的变压器故障诊断[J]. 高电压技术, 2014, 40(5): 1507-1513.
GU Kaikai, GUO Jiang. Transformer fault diagnosis method based on compact fusion of fuzzy set and fault tree[J]. High Voltage Engineering, 2014, 40(5): 1507-1513.
- [8] 尹玉娟, 王媚, 张金江, 等. 一种自主核优化的二值粒子群优化—多核学习支持向量机变压器故障诊断方法[J]. 电网技术, 2012, 36(7): 250-255.
YIN Yujuan, WANG Mei, ZHANG Jinjiang, et al. An automatic kernel optimization method to diagnosis transformer faults by multi - kernel learning support vector classifier based on binary particle swarm optimization[J]. Power System Technology, 2012, 36(7): 250-255.
- [9] 梁永亮, 李可军, 牛林, 等. 一种优化特征选择—快速相关向量机变压器故障诊断方法[J]. 电网技术, 2013, 37(11): 3262-3267.
LIANG Yongliang, LI Kejun, NIU Lin, et al. A transformer diagnosis method based on optimized feature selection methods and fast relevance vector machine[J]. Power System Technology, 2013, 37(11): 3262-3267.
- [10] LIAO Ruijin, ZHENG Hanbo, GRZYBOWSKI S, et al. Fault diagnosis of power transformers using multi-class least square support machines classifiers with particle swarm optimization[J]. IET Electric Power Application, 2011, 5(9): 691-696.
- [11] 谢龙君, 李黎, 程勇, 等. 融合集对分析和关联规则的变压器故障诊断方法[J]. 中国电机工程学报, 2015, 35

- (2):277-286.
- XIE Longjun, LI Li, CHENG Yong, et al. A fault diagnosis method of power transformers by integrated set pair analysis and association rules[J]. Proceedings of the CSEE, 2015, 35(2):277-286.
- [12] 王永强, 律成方, 李和明. 基于粗糙集理论和贝叶斯网络的电力变压器故障诊断方法[J]. 中国电机工程学报, 2006, 26(8):138-142.
- WANG Yongqiang, LYU Chengfang, Li Heming. Synthetic fault diagnosis method of power transformer based on rough set theory and Bayesian network[J]. Proceedings of the CSEE, 2006, 26(8):138-142.
- [13] 朱永利, 尹金良. 组合核相关向量机在变压器故障诊断中的应用研究[J]. 中国电机工程学报, 2013, 33(22):68-75.
- ZHU Yongli, YIN Jinliang. Study on application of multi-kernel learning relevance vector machines in fault diagnosis of power transformers[J]. Proceedings of the CSEE, 2013, 33(22):68-75.
- [14] 赵文清, 李庆良, 王德文. 基于多模型的变压器故障组合诊断研究[J]. 高电压技术, 2013, 39(2):302-309.
- ZHAO Wenqing, LI Qingliang, WANG Dewen. Combinational diagnosis for transformer faults based on multi-models[J]. High Voltage Engineering, 2013, 39(2):302-309.
- [15] TIAN H X, SUN Y L, LIU S Y. Application of D-S evidence deducing theory to one kind of mechanical fault diagnosis[J]. Applied Mechanics and Materials, 2011, 48(49):249-252.
- [16] LIAO Ruijin, ZHENG Hanbo, GRZYBOWSKI S, et al. An integrated decision-making model for condition assessment of power transformers using-fuzzy approach and evidential reasoning[J]. IEEE Transactions on Power Delivery, 2011, 26(2):1111-1118.
- [17] 沈怀荣, 杨露, 彭颖, 等. 信息融合故障诊断技术[M]. 北京: 科学出版社, 2013:184-247.
- SHEN Huairong, YANG Lu, PENG Ying, et al. Information fusion fault diagnosis technology[M]. Beijing: Science Press, 2013:184-247.
- [18] 陈伟根, 刘娟, 曹敏. 基于信息融合的变压器内部故障诊断方法[J]. 高电压技术, 2015, 41(11):3797-3803.
- CHEN Weigen, LIU Juan, CAO Min. Diagnosis method of internal fault for transformers based on information fusion[J]. High Voltage Engineering, 2015, 41(11):3797-3803.
- [19] 瞿雷, 戴光昊, 王琇峰, 等. 基于特征评估与核主分量分析的齿轮故障分类方法[J]. 机械传动, 2014, 38(11):105-110.
- QU Lei, DAI Guanghao, WANG Xiufeng, et al. Method of gear fault classification based on feature evaluation and kernel principal component analysis[J]. Journal of Mechanical Transmission, 2014, 38(11):105-110.
- [20] 李学军, 李平, 蒋玲莉, 等. 基于异类信息特征融合的异步电机故障诊断[J]. 仪器仪表学报, 2013, 34(1):227-233.
- LI Xuejun, LI Ping, JIANG Lingli, et al. Fault diagnosis method of asynchronous motor based on heterogeneous information feature fusion[J]. Chinese Journal of Scientific Instrument, 2013, 34(1):227-233.
- [21] 李志斌, 陈成优. 基于粗糙集和贝叶斯网络的变压器故障诊断[J]. 上海电力学院学报, 2013, 29(1):30-34.
- LI Zhibin, CHEN Chengyou. Fault diagnosis of power transformer based on rough set theory and Bayesian network[J]. Journal of Shanghai University of Electric Power, 2013, 29(1):30-34.
- [22] 董明, 严璋, 杨莉. 基于证据推理的电力变压器故障诊断策略[J]. 中国电机工程学报, 2006, 26(1):106-114.
- DONG Ming, YAN Zhang, YANG Li. An evidential reasoning approach to transformer fault diagnosis[J]. Proceedings of the CSEE, 2006, 26(1):106-114.

袁海满(1989—), 男, 硕士研究生, 主要从事高压电气设备在线监测与状态评估方面的研究。

吴广宁(1969—), 男, 教授, 博导, 主要从事高电压与绝缘技术相关教学与科研工作。