基于 AdaBoost-RBF 算法与 DSmT 的变压器故障诊断技术

刘云鹏^{1,2},付浩川¹,许自强¹,李 刚³,高树国⁴,董王英¹

(1. 华北电力大学 河北省输变电设备安全防御重点实验室,河北 保定 071003;2. 华北电力大学 新能源电力系统国家重点实验室,北京 102206;3. 华北电力大学 控制与计算机工程学院,

河北 保定 071003;4. 国网河北省电力有限公司电力科学研究院,河北 石家庄 050011)

摘要:针对目前浅层机器学习理论在变压器故障诊断上精度不高以及大多数诊断方法参考的信息特征量单一的现状,提出一种基于 AdaBoost-RBF 算法与 Dezert-Smarandache 理论(DSmT)的变压器故障诊断方法。选择反映变压器故障信息的油中溶解气体、试验及产气率数据构成诊断参量空间,利用 AdaBoost 算法改进 RBF 神经网络算法,应用 AdaBoost-RBF 算法搭建并行的训练单元构造变压器故障诊断识别框架的基本信度赋值(BBA)。基于多源信息融合的思想,应用 DSmT 对基本信度赋值进行融合得到最终诊断结论,该理论克服了 D-S 证据理论无法融合高冲突性证据的局限性。对 110 kV 变压器进行仿真实例分析,结果表明所提方法具 有良好的实用性。

0 引言

电力变压器是输变电和供配电系统中的重要设备,其运行状态对电网的安全稳定运行有着重要影响^[1]。目前大型电力变压器故障诊断大多基于油中溶解气体分析(DGA)技术,其诊断方法从最早沿用传统的 IEC 的三比值法及改良三比值法^[2-3],发展到近年来国内外学者提出的人工智能算法,如人工神经网络、支持向量机(SVM)、正态云模型、粗糙集理论、贝叶斯理论等^[4-7],在取得了一定诊断效果的同时也解决了传统算法分类边界过于绝对化的局限性。

然而目前大部分变压器故障诊断方法所参考的 故障信息参量单一,往往只考虑油中溶解气体信息, 而离线的试验数据及缺陷记录等反映变压器工况状 态的信息并未得到全面利用^[8]。单一的故障信息参 量并不能携带足够充分的故障信息,易出现误诊断 的情况。同时,目前多以故障性质为依据将变压器 故障分为电、热、机械等故障,无法对变压器的具体 故障部位进行定位。另外,随着变压器在线监测数 据量与试验数据量的增长,浅层机器学习方法在数 据挖掘方面的能力略显薄弱,且由于本身算法存在 的局限性导致变压器故障诊断的正确率降低^[9],而 深度学习模型由于数据量维度及数据集样本偏斜的 问题易出现欠拟合的情况。

收稿日期:2018-03-31;修回日期:2019-03-28

基金项目:国家自然科学基金资助项目(51407076);中央高校基本科研业务费专项资金资助项目(2015ZD28,2018QN-076);国家电网公司科技项目(5204DY170010)

Project supported by the National Natural Science Foundation of China (51407076), the Fundamental Research Funds for the Central Universities (2015ZD28, 2018QN076) and the Science and Technology Project of SGCC(5204DY170010)

针对变压器故障信息的复杂性与不确定性,信 息融合理论在变压器故障诊断的应用中取得了良好 的效果[10],研究基于多源信息融合的变压器故障诊 断方法可以从整体上反映变压器的故障状态,更为 准确地对变压器故障部位进行定位。D-S 证据理论 目前被广泛地应用于信息融合中,但当利用其处理 高冲突性信息时,会出现融合后产生悖论的情况。 Dezert-Smarandache 理论 DSmT (Dezert-Smarandache Theory)作为一种有效的证据冲突组合理论,其采用 冲突比例重分配规则处理高冲突性证据,可以克服 D-S证据理论的局限性,目前较多地应用于图像多 特征融合识别以及航天机械故障诊断领域中[11-13]。 针对浅层机器学习方法在变压器诊断方面精度不高 的问题, AdaBoost 算法作为一种迭代算法可以聚合多 个基分类器构成强分类器,将 AdaBoost 算法与浅层机 器学习方法(径向基函数(RBF)、BP 算法、云理论等) 相结合[14-16],可以有效提升变压器故障诊断的精度。

本文采用多源信息融合的思想设计变压器故障 诊断模型,将变压器中的油中溶解气体含量、电气试 验与绝缘油试验参量、产气率参量等多源信息相结 合,基于 AdaBoost-RBF 算法分模块训练构造识别框 架的基本信度赋值,最后应用 DSmT 及决策规则对 变压器故障做出最终诊断。本文所提方法有效地解 决了变压器高冲突性故障信息证据体的融合问题, 提高了故障诊断的正确率,对变压器的维修决策有 一定的指导意义。

1 AdaBoost-RBF 算法与 DSmT

1.1 AdaBoost-RBF 算法

1.1.1 RBF 神经网络

RBF 神经网络基于多变量差值的函数方法,其

属于三层前向网络,适用于解决分类问题^[17]。由输 入层、隐含层和输出层构成的一般 RBF 神经网络结 构如图 1 所示。



图 1 RBF 神经网络结构图

Fig.1 Structure of RBF neural network

RBF 网络隐含层第 g 个节点的输出可表示为:

$$r_{g} = \exp\left(-\frac{1}{2\sigma_{g}^{2}} \|\boldsymbol{R}_{i} - \boldsymbol{T}_{g}\|^{2}\right)$$
(1)

其中, r_g 为第g 个隐含层节点的输出; R_i 为n 维输入向量; T_g 为第g 个隐含层节点函数的中心向量; σ_g 为第g 个隐含层节点的标准化常数。

最终输出层输出的线性组合为:

$$y_j = \sum_{g=1}^n w_{gj} r_g - \theta_j \tag{2}$$

其中, y_j 为输出层第j个节点的输出值; w_{gj} 为隐含层 到输出层的权值; θ_j 为第j个输出节点的阈值。 1.1.2 基于 AdaBoost.M2 的 RBF 组合算法

AdaBoost 算法由 Yoav Freund 和 Robert E. Schapire 提出,是一种用于解决二分类问题的集成方法, 之后提出的 AdaBoost.M1 算法将二分类扩展到多分 类问题,而 AdaBoost.M2 算法不仅可以处理多分类 问题,还引入了置信度的概念,进一步扩展了 AdaBoost 算法^[18]。

由于变压器的故障诊断识别属于多分类问题且 需要最终的置信度来进行融合决策,所以本文采用 AdaBoost.M2 算法与 RBF 相结合的 AdaBoost-RBF 算 法构建变压器诊断模型。AdaBoost-RBF 算法的优势 在于可以搭建框架来集成多个 RBF 弱分类器,以此 提升分类的准确率^[19]。但由于 AdaBoost 算法本身 存在迭代,相较于 RBF 算法其时间效率会有所下 降。在构建 AdaBoost-RBF 算法时,需考虑具体情况 调试合适的迭代次数来均衡算法准确率与算法效率 之间的关系。本文模型以 RBF 神经网络为基础弱 分类器,根据训练结果误差来修正样本的权重系数, 通过 AdaBoost.M2 算法迭代得到训练完成的一系列 RBF 分类器,最后依据各个基分类器的错误率以加 权集成的方法组合成 AdaBoost-RBF 强分类器,其结 构图如图 2 所示。

1.2 DSmT 模型

DSmT 是由 Dezert 和 Smarandache 提出的一种



Fig.2 Structure of AdaBoost-RBF algorithm

新的模糊矛盾推理理论,可看作是经典 Dempster-Shafer 理论(DST)的自然延伸,但是两者之间存在着 重要的差异。DSmT 可以处理不确定、高度冲突和 不精确的信息源的融合问题^[20],适合应用于变压器 故障诊断。

1.2.1 基本概念

(1) 广义识别框架: 令 $\Theta = \{\theta_0, \theta_1, \dots, \theta_n\}$ 作为 融合问题的鉴别框, 其是由 n 个元素构成的非空集 合。在变压器故障诊断中, 识别框架元素对应着不 同的故障类型。

(2)超幂集 *D^θ*:*Θ* 中命题通过 ∪ 和 ∩ 算子的运 算组成的所有复合命题的集合。

(3) 广义信度分配函数。在 Θ 中存在 1 组映射

$$m(\cdot): D^{\Theta} \longrightarrow [0,1]$$
(3)

如果满足条件

$$m(\emptyset) = 0, \sum_{A \in D^{\Theta}} m(A) = 1$$
 (4)

则称m(A)为A在广义识别框架 Θ 中的信度分配函数。

1.2.2 PCR 融合规则^[21]

在变压器故障诊断中,采用完全排他性约束的 DSmT模型,只针对单一元素 θ_n 进行信度赋值。为 简化融合决策运算,采用冲突信息按照各个单焦元 置信度再分配的方法,即 PCR(Proportional Conflict Redistribution)理论。由于变压器故障诊断中最终 需要融合的证据源超过了3种,所以采用最精确且 满足融合要求的 PCR6 规则,DSmT 融合公式如下:

$$\begin{aligned}
f_{m_{\text{PCR6}}}(\emptyset) &= 0 \\
\forall A \in D^{\Theta} \setminus \emptyset, \\
m_{\text{PCR6}}(A) &= m_{12\cdots k}(A) + \sum_{i=1}^{k} (m_i(A))^2 \times \\
\sum_{\substack{k=1 \ j=1 \ m_{\sigma_i(j)}(Y_{\sigma_i(j)}) \\ (Y_{\sigma_i(1), \cdots, Y_{\sigma_i(k-1)}) \in (D^{\Theta})^{k-1}}} \frac{\prod_{j=1}^{k-1} m_{\sigma_i(j)}(Y_{\sigma_i(j)})}{m_i(A) + \sum_{j=1}^{k-1} m_{\sigma_i(j)}(Y_{\sigma_i(j)})}
\end{aligned}$$
(5)

$$m_i(A) + \sum_{j=1}^{k-1} m_{\sigma_i(j)}(Y_{\sigma_i(j)}) \neq 0$$

其中, $m(\cdot)$ 为信度分配函数; $m_{12\cdots k}(A)$ 为基本信 念赋值 $m_1(\cdot) - m_k(\cdot)$ 的合取规则, $m_{12\cdots k}(A) =$

 $\sum_{A_1,\dots,A_k \in D^{\Theta}} \prod_{i=1}^k m_i(A_i) ; Y_{\sigma_i(j)} 为框架 @ 中的类别子集;$

k为证据源的个数; $\sigma_i(j) = 1, 2, \dots, i, \dots, k, \perp \sigma_i(j)$ 满足 $\sigma_i(j) = \begin{cases} j & j < i \\ j+1 & j \ge i^{\circ} \end{cases}$

2 基于 AdaBoost-RBF 算法与 DSmT 的变压 器故障诊断模型

2.1 故障诊断特征参量选取

在电力变压器的故障诊断中,有多种状态参量 以及试验特征参量可以反映变压器的故障类型及故 障部位。选择可靠且有效的特征参量对于提升变压 器故障诊断的正确率有着重要意义。

对于故障诊断特征参量的选取,既要满足信息 的实用性,即便于检测和收集,又要满足独立性,即 特征参量之间应相互独立且整体反映变压器的故障 特征。根据上述特征参量选择原则,将变压器故障 特征参量按照油中溶解气体含量(单位为μL/L)、 电气试验与绝缘油试验信息、产气率3个部分进行 分类,分类结果与子参量如表1所示。

表1 变压器故障特征参量

Table 1 Fault	characteristic parameters of transformer
参量模块	子参量
油中溶解气体 含量	C ₂ H ₂ 、H ₂ 、C ₂ H ₄ 、C ₂ H ₆ 、CH ₄ 、 CO、CO ₂ 的气体含量
电气试验与 绝缘油试验	铁芯接地电流、局部放电量、绕组直流电阻 不平衡系数、绝缘电阻、微水、油击穿电压
产气率 (绝对产气速率)	C_2H_2 、 H_2 、总烃、 CO 、 CO_2 的绝对产气速率

2.2 故障识别框架确定

根据变压器故障部位的不同,结合故障树理论 对变压器典型故障进行分类,故障识别框架为 Θ = $\{S_1, S_2, S_3, S_4\}, 其中 S_1 为绕组故障, S_2 为铁芯故$ $障, S_3 为油纸绝缘故障, S_4 为正常。S_1—S_3 这 3 种$ 部位故障类型基本涵盖了变压器典型故障^[22],对变压器故障诊断后的维修决策有一定的指导意义。

2.3 故障诊断模型搭建

基于 AdaBoost-RBF 算法与 DSmT 搭建变压器 故障诊断模型如图 3 所示。

在图 3 所示的模型中,油中溶解气体中各气体的体积分数参量构成诊断信息模块 I_1 ,铁芯接地电流、油击穿电压等电气试验与绝缘油试验数据构成诊断信息模块 I_2 , C_2H_2 、 H_2 、总烃等的绝对产气速率信息构成诊断信息模块 I_3 。结合已分类的诊断信息模块,将 I_1 、 I_2 、 I_3 作为 AdaBoost-RBF 模块的输入,并



图 3 变压器故障诊断模型

Fig.3 Transformer fault diagnosis model

联各个 AdaBoost-RBF 模块作为诊断模型的第1级系统。

输出节点 m_1 、 m_2 、 m_3 分别为诊断信息模块 Ada-Boost-RBF1、AdaBoost-RBF2、AdaBoost-RBF3 对应于 识别框架 $\Theta = \{S_1, S_2, S_3, S_4\}$ 的基本信度赋值。在 DSmT 融合模块中,将各个信度赋值 m_1 、 m_2 、 m_3 进行 融合处理,得到融合后的信度分配。基于最大信度 分配的决策规则得出最终的变压器故障诊断结果。

2.4 算法流程

2.4.1 数据预处理环节

由于各个诊断信息模型中的信息参量种类复杂,在训练前需要对诊断信息数据进行预处理。

油中溶解气体数据需要进行归一化处理,由于 量纲相同,所以只需得到它们的体积分数即可。电 气试验与绝缘油试验信息及产气率信息则需要根据 式(6)、(7)比较其规程和注意值来进行数据量 化^[23],试验信息在高、中低压侧选择超规程最大的 数据进行训练,以此提高 AdaBoost-RBF 模型训练的 效率。

如果数据指标的规程规定小于阈值,则其量化 公式为:

$$\mu = \begin{cases} 1 & X \leq 0.7X_0 \\ \frac{1.3X_0 - X}{0.6X_0} & 1.3X_0 \geq X > 0.7X_0 \\ 0 & X > 1.3X_0 \end{cases}$$
(6)

其中, X_0 为规程规定的阈值;X为原始数据。

如果数据指标的规程规定大于阈值,则其量化 公式为:

$$\mu = \begin{cases} 1 & X > 1.3X_0 \\ \frac{X - 0.7X_0}{0.6X_0} & 1.3X_0 \ge X > 0.7X_0 \\ 0 & X \le 0.7X_0 \end{cases}$$
(7)

2.4.2 训练环节

对已有的故障案例数据进行分类,经过预处理 之后将数据以及故障类别编码作为 AdaBoost-RBF 模型的输入对其进行训练。生成的 N 个训练样本 集为:

R $= \{ (x_1, y_1), (x_2, y_2), \dots, (x_i, y_i), \dots, (x_N, y_N) \}$ 其中, $y_i \in Y = \{ 1, 2, \dots, k \}$, *i* 为样本训练标号, *k* 为故 障类别。

AdaBoost-RBF 训练流程如下。

(1)初始化权值:

$$w_{i,x}^{1} = D_{1}(i)/(k-1)$$

其中, $i=1,2,...,N; y \in Y-y_i$,表示对每次迭代后基 分类器中训练失败($y \neq y_i$)的样本 i 进行权值 $w_{i,y}^t$ 初 始化; $D_1(i) = 1/N_{\circ}$

(2)设置迭代次数为 *T*,在第 *t* 次(*t*=1,2,…,*T*) 迭代时进行下列步骤。

a. 令
$$W_i^t = \sum_{y \neq y_i} w_{i,y}^t$$
,则标签加权函数为:
 $q(i,y) = w_{i,y}^t / W_i^t$ (8)

其中,w^t_{i,y}为第 t 次迭代后训练失败样本的权重;W^t_i 为其依故障框架叠加的权重。

则样本的分布权重值为:

$$D_i(i) = W_i^t / \sum_{i=1}^N W_i^t$$
(9)

b. 根据分布权重值 *D*_{*i*}(*i*) 更新样本训练集训练 RBF 神经网络,得到基分类器 *h*_{*i*}。

c. 计算 h_i 的伪误差 ε_i :

$$\varepsilon_{t} = \frac{1}{2} \sum_{i=1}^{N} D_{t}(i) \left(1 - h_{t}(x_{i}, y_{i}) + \sum_{i, y \neq y_{i}} q_{t}(i, y) h_{t}(x_{i}, y) \right)$$
(10)

如果 $\varepsilon_{\iota} \leq 0.5$,则迭代结束。

d. 更新权重:

$$w_{i,x}^{t+1} = w_{i,x}^{t} \beta_{t}^{\frac{1}{2}(1+h_{t}(x_{i},y_{i})-h_{t}(x_{i},y))}$$
(11)

其中, $\beta_t = \varepsilon_t / (1 - \varepsilon_t)$,为第 t 个基分类器的修正 系数。

e. T 次迭代结束后,得到强分类器 H(x):

$$H(x) = \operatorname*{argmax}_{y \in Y} \sum_{i=1}^{I} \left(\ln \frac{1}{\beta_i} \right) h_i(x, y) \quad (12)$$

2.4.3 识别环节

首先将待测样本数据归一化处理后代入训练模块,得到3组基本信度赋值。其次在 DSmT 融合模块中进行3组证信度赋值的融合并得到融合诊断结果,最后基于决策规则对故障类别进行判定,整体的变压器故障诊断算法流程如图4所示。

图 4 中,决策规则^[24]为设定 2 个阈值 $\varepsilon_1 \ \varepsilon_2 \ \varepsilon_2$ 。 对 $\forall S_i \ S_j \in D^{\Theta}$,若存在 $m(S_i) > m(S_j)$,且大于识别 框架中任意其他元素,如果满足 $m(S_i) > \varepsilon_1$,并且满 足 $m(S_i) - m(S_j) > \varepsilon_2$,则 S_i 为最终识别结果。

2.5 训练结果

本文利用从南瑞各单位搜集的 110 kV 变压器 运行试验数据进行算法训练,收集到的案例样本中 正样本为 88 组,负样本为 396 组。将负样本按照故 障发生的部位,分为绕组故障、铁芯故障及油纸绝缘



图 4 变压器故障诊断算法流程

Fig.4 Flowchart of transformer fault diagnosis algorithm 故障。最后将案例样本中的数据信息及案例样本的 故障类型标签构成 3 个信息模块的数据集。数据集 中包含 DGA 数据 484 组、试验数据 113 组和产气率 数据 187 组。其中, DGA 数据中训练集为 364 组, 测 试集为 120 组; 试验数据中训练集为 83 组, 测试集 30 组; 产气率数据中训练集为 140 组, 测试集为 47 组。

设置迭代次数 T = 20、RBF 神经网络拓展系数 spread 为 0.05、决策阈值 $\varepsilon_1 = 0.5$ 和 $\varepsilon_2 = 0.1$ 。DGA 信息模块所对应的 AdaBoost-RBF1 的训练结果如图 5 所示,其中训练样本正确率为 DGA 训练集 364 组 数据在模型中的诊断正确率,测试样本正确率为 DGA 测试集 120 组数据在模型中的诊断正确率。



由图 5 可以看出,随着迭代次数的增加, AdaBoost-RBF 算法的训练样本和测试样本的正确率 均有所上升;对比训练及测试样本正确率后可以发 现,AdaBoost-RBF 算法迭代后得到的强分类器 *H_i*(*x*) 相比基分类器*h_i*(RBF神经网络算法)在识别精度方 面有着显著的提升。

分别对电气试验与绝缘油试验信息模块 Ada-Boost-RBF2 与产气率信息模块 AdaBoost-RBF3 进行 训练,设置迭代参数 *T* = 20, spread 分别设置为 1 和 0.1。3 个 AdaBoost-RBF 模块的测试样本正确率与 RBF 测试样本正确率及 SVM 测试样本正确率之间 的对比见表 2,可以看出 AdaBoost-RBF 算法性能明 显优于 RBF 及 SVM。

表 2 测试样本识别正确率

Table 2 Recognition accuracy of test samples

		测试样本识别正确率/%	
并伍	DGA 模块	电气试验与油试验模块	产气率模块
AdaBoost-RBF	78.33	93.33	76.59
RBF	66.67	76.67	51.06
SVM	63.33	83.33	53.19

考虑算法模型的运算效率及识别精度,3个 Ada-Boost-RBF 模型的参数最终设置为:AdaBoost-RBF1 模型的迭代次数为 8, spread 为 0.05; AdaBoost-RBF2 模型的迭代次数为 3, spread 为 1; AdaBoost-RBF3 模 型的迭代次数为 7, spread 为 0.1。

基于已建立的 AdaBoost-RBF 模型,利用搜集的 21 个完整案例对 DSmT 融合模块进行测试,测试结 果如表 3 所示。由表 3 可以看出,3 个 AdaBoost-RBF 模块经过融合之后,其诊断正确率有了显著提 升。测试结果证明 DSmT 融合模块克服了单一证据 体的片面性,在单个诊断模块出现误差或失效的情 况下,模型仍能正常可靠地工作,其提高了变压器诊 断模型的正确率,实现了不同诊断信息的互补。

表 3 DSmT 融合后诊断正确率

Table 3 Diagnostic accuracy after DSmT fusion

模块	诊断正确案例数	诊断正确率/%
DGA	14	66.67
电气试验与油试验	18	85.71
产气率	15	71.42
DSmT 融合	20	95.23

3 实例分析

3.1 案例1

取某供电公司 110 kV 变电站 1 号主变压器 2006 年的故障案例进行分析,变压器型号为 SSZB-40000/110,其在 2006 年 1 月 19 日运行中主变主动 差动保护动作,本体重瓦斯动作,主变 110 kV 侧开 关跳闸。取故障后的数据进行诊断,其故障前后的 油中溶解气体含量数据、电气试验与绝缘油数据、特 征气体绝对产气速率如附录 A 中的表 A1—A3 所示。

按照 2.4.1 节的数据预处理方法对表 A1—A3 中的数据分别进行归一化与量化处理构成待识别的

数据参量 *I*₁、*I*₂、*I*₃。将 *I*₁、*I*₂、*I*₃作为训练完成的 Ada-Boost-RBF 模型的输入来得到识别框架的 3 组基本 信度赋值,运用 DST 及 DSmT 融合后的基本信度赋 值结果如附录 A 中的表 A4 所示。依据 DST 与 DSmT 的融合结果,基于 2.4.3 节中的决策规则判 定,变压器的故障类型均被判定为 S₁,即绕组部位发 生故障。实际现场中通过故障分析发现该变压器 A 相中压绕组变形严重,证明本文方法诊断结果与实 际故障部位相一致。

3.2 案例 2

取某电厂110 kV 变压器 2013 年的故障案例进行分析,变压器型号为 SF10-75000/110,其在 2013 年 5 月 8 日正常运行中,主变重瓦斯保护突然动作,故障前后的油中溶解气体含量数据、电气试验与绝缘油试验数据、绝对产气速率数据如附录 B 中的表 B1—B3 所示。

将预处理后的数据代入 AdaBoost-RBF 模型得 到识别框架的 3 组基本信度赋值,运用 DST 及 DSmT 融合后的基本信度赋值结果如附录 B 中的表 B4 所示。

从表 B4 中可以看出证据 $m_1 = m_2$ 是支持 S₁ 的,而证据 m_3 是支持 S₂ 的。基于决策规则对变压 器故障类型进行判定,DST 的融合结果被判定为 S₃, 显然与常理相悖。这是由于融合阶段中证据 m_2 与 证据 m_3 的冲突因子 $K_{23} = 0.936$ 5,接近于 1,导致 DST 组合规则失效。

对于 m_2 与 m_3 这样的高冲突性的证据而言, DST 并不适用,而 DSmT 能够通过冲突比例规则重 新分配冲突证据,解决冲突性证据之间的融合问题。 依据 DSmT 的融合结果,根据决策规则判定变压器 的故障类型为 S_1 ,即绕组部位发生故障。实际变压 器返厂拆检发现该变压器 C 相绕组绝缘被破坏,发 生匝间短路,本文方法诊断结果与实际故障部位 一致。

4 结论

(1)本文构建了结合 AdaBoost-RBF 算法与 DSmT 的变压器故障诊断模型,通过训练结果及实 例分析表明,AdaBoost-RBF 可以提升诊断的正确率, 该模型具有较高的准确度与实用性。

(2) 仅靠单一的变压器故障参量信息进行故障 诊断易出现误判的情况。本文基于信息融合的思 想,将多源信息参量分模块并行诊断并利用 DSmT 进行信度融合,克服了单一证据体的片面性,提高了 诊断正确率,同时也克服了传统 DST 无法融合冲突 性证据的局限性。

(3)随着变压器在线监测数据及状态信息数据 的不断增加与积累,基于信息融合理论对于变压器 进行多源异构大数据(例如红外、紫外图像以及环境 信息)的深度挖掘处理是后续的研究方向。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

 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 En-

gineering, 2014, 40(5):1507-1513.[2] 国家质量监督检验检疫总局.变压器油中溶解气体分析和判断

- [2] 国家质量监督检验检疫芯周. 支压硫油中沿庸(译万仍和判例 导则:GB/T 7252—2001[S]. 北京:国家标准局,2001.
- [3] 国家能源局.变压器油中溶解气体分析和判断导则:DL/T 722—2014[S].北京:中国电力出版社,2014.
- [4] 程加堂,艾莉,段志梅. 改进证据理论与神经网络集成的变压器 故障诊断[J]. 电力系统保护与控制,2013,41(14):92-96.
 CHENG Jiatang, AI Li, DUAN Zhimei. Transformer fault diagnosis based on improved evidence theory and neural network integrated method[J]. Power System Protection and Control, 2013,41(14): 92-96.
- [5]司马莉萍,舒乃秋,李自品,等. 基于 SVM 和 D-S 证据理论的电力变压器内部故障部位识别[J]. 电力自动化设备,2012,32 (11):72-77.

SIMA Liping, SHU Naiqiu, LI Zipin, et al. Identification of interior fault position based on SVM and D-S evidence theory for electric transformer [J]. Electric Power Automation Equipment, 2012, 32 (11):72-77.

- [6]张重远,林志锋,刘栋,等. 基于正态云模型与改进贝叶斯分类器的变压器故障诊断[J]. 电测与仪表,2017,54(4):50-56.
 ZHANG Zhongyuan,LIN Zhifeng,LIU Dong, et al. Transformer fault diagnosis based on normal cloud model and improved Bayesian classifier[J]. Electrical Measurement & Instrumentation,2017,54(4): 50-56.
- [7] 王永强,律方成,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): 137-141.

WANG Yongqiang, LÜ Fangcheng, 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):137-141.

- [8] 钱国超, 邹德旭, 颜冰,等. 集成证据推理与多神经网络的电力 变压器故障综合诊断[J]. 高压电器, 2015, 51(9):71-76.
 QIAN Guochao, ZOU Dexu, YAN Bing, et al. Synthetic fault diagnosis for power transformers based on integration of evidence reasoning and neural network [J]. High Voltage Apparatus, 2015, 51(9): 71-76.
- [9]姜有泉,黄良,王波,等. 基于 DGA 和深度置信网络的变压器内 部故障诊断[J]. 武汉大学学报(工学版),2017,50(5):749-753.

JIANG Youquan, HUANG Liang, WANG Bo, et al. Transformer internal fault diagnosis based on DGA and deep belief network [J]. Journal of Wuhan University(Engineering Science), 2017, 50(5): 749-753.

[10] 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.

- [11] 李新德,潘锦东,DEZERT Jean. 一种基于 DSmT 和 HMM 的序列 飞机目标识别算法[J]. 自动化学报,2014,40(12):2862-2876.
 LI Xinde, PAN Jindong, DEZERT Jean. A target recognition algorithm for sequential aircraft based on DSmT and HMM[J]. Acta Automatica Sinica,2014,40(12):2862-2876.
- [12] 李新德,杨伟东,DEZERT Jean. 一种飞机图像目标多特征信息 融合识别方法[J]. 自动化学报,2012,38(8):1298-1307.
 LI Xinde,YANG Weidong,DEZERT Jean. An airplane image target's multi-feature fusion recognition method[J]. Acta Automatica Sinica, 2012,38(8):1298-1307.
- [13] 翟旭升,胡金海,谢寿生,等. 基于 DSmT 的航空发动机早期振动故障融合诊断方法[J]. 航空动力学报,2012,27(2);301-306. ZHAI Xusheng,HU Jinhai,XIE Shousheng,et al. Diagnosis of aeroengine with early vibration fault symptom using DSmT[J]. Journal of Aerospace Power,2012,27(2):301-306.
- [14] 周湶,王时征,廖瑞金,等. 基于 AdaBoost 优化云理论的变压器 故障诊断方法[J]. 高电压技术,2015,41(11):3804-3811.
 ZHOU Yu,WANG Shizheng,LIAO Ruijin, et al. Power transformer fault diagnosis method based on cloud model of AdaBoost algorithm
 [J]. High Voltage Engineering,2015,41(11):3804-3811.
- [15] 吴俊利,张步涵,王魁. 基于 AdaBoost 的 BP 神经网络改进算法 在短期风速预测中的应用[J]. 电网技术,2012,36(9):221-225.
 WU Junli, ZHANG Buhan, WANG Kui. Application of AdaBoostbased BP neural network for short-term wind speed forecast[J].
 Power System Technology,2012,36(9):221-225.
- [16] 王文豪,严云洋. 基于 AdaBoost RBF 神经网络的火灾烟雾检测
 [J]. 河南理工大学学报(自然科学版),2014,33(2):132-138.
 WANG Wenhao,YAN Yunyang. Fire smoke detection based on Ada-Boost and RBF neural network [J]. Journal of Henan Polytechnic University(Natural Science),2014,33(2):132-138.
- [17] 刘景艳,王福忠,杨占山. 基于 RBF 神经网络和自适应遗传算 法的变压器故障诊断[J]. 武汉大学学报(工学版),2016,49 (1):88-93.

LIU Jingyan, WANG Fuzhong, YANG Zhanshan. Transformer fault diagnosis based on RBF neural network and adaptive genetic algorithm [J]. Journal of Wuhan University (Engineering Science), 2016,49(1):88-93.

- [18] FREUND Y, SCHAPIRE R E. Game theory, on-line prediction and boosting[C] // Proceedings of the Ninth Annual Conference on Computational Learning Theory. Desenzano del Garda, Italy:[s.n.], 1996:325-332.
- [19] 娄生超. 基于 RBF 核函数的集成分类 AdaBoost 算法研究[J].
 科学技术与工程,2012,12(34):9207-9210.
 LOU Shengchao. Research on AdaBoost integrated classification algorithm based on RBF kernel function[J]. Science Technology and Engineering,2012,12(34):9207-9210.
- [20] 文成林,徐晓斌. 多源不确定信息融合理论及应用[M]. 北京: 科学出版社,2012:128-130.
- [21] SMARANDACHE F, DEZERT J. Advances and applications of DSmT for information fusion [M]. Rehoboth, USA: American Research Press, 2004:2-4.
- [22] 李刚,于长海,范辉,等. 基于多级决策融合模型的电力变压器 故障深度诊断方法[J]. 电力自动化设备,2017,37(11):138-144.

LI Gang, YU Changhai, FAN Hui, et al. Deep fault diagnosis of power transformer based on multilevel decision fusion model[J]. Electric

Power Automation Equipment, 2017, 37(11):138-144.

- [23] 谢红玲,律方成. 基于信息融合的变压器状态评估方法研究
 [J]. 华北电力大学学报,2006(2):8-11.
 XIE Hongling,LÜ Fangcheng. Transformer condition evaluation based on information fusion [J]. Journal of North China Electric Power University,2006(2):8-11.
- [24] 陈法法,汤宝平,姚金宝. 基于 DSmT 与小波网络的齿轮箱早期 故障融合诊断[J]. 振动与冲击,2013,32(9):40-45.
 CHEN Fafa, TANG Baoping, YAO Jinbao. Gearbox incipient fault fusion diagnosis based on DSmT and wavelet neural network[J].
 Journal of Vibration and Shock,2013,32(9):40-45.

作者简介:



刘云鹏(1976—),男,安徽六安人,教授,博士,主要研究方向为特高压输电技术 以及电气设备在线检测和外绝缘(E-mail: liuyunpeng@ncepu.edu.cn);

付浩川(1993—),男,河北沧州人,硕 士研究生,主要研究方向为电气设备故障 预警及健康管理(E-mail:fhc_ncepu@163.

Transformer fault diagnosis technology based on AdaBoost-RBF algorithm and DSmT

com)

LIU Yunpeng^{1,2}, FU Haochuan¹, XU Ziqiang¹, LI Gang³, GAO Shuguo⁴, DONG Wangying¹

(1. Hebei Provincial Key Laboratory of Power Transmission Equipment Security Defense, North China Electric Power University, Baoding 071003, China; 2. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China; 3. School of Control and Computer Engineering,

North China Electric Power University, Baoding 071003, China; 4. State Grid Hebei Electric Power Research Institute,

Shijiazhuang 050011, China)

Abstract: Aiming at the low accuracy of shallow machine learning theory in transformer fault diagnosis and the fact that most diagnostic methods only refer to a single information feature, a transformer fault diagnosis method based on AdaBoost-RBF algorithm and DSmT(Dezert-Smarandache Theory) is proposed. The dissolved gas in oil, test and gas production rate data, which can reflect the transformer fault information, are used to form the diagnostic parameter space. AdaBoost algorithm is applied to improve the RBF neural network algorithm. A parallel training unit is constructed with AdaBoost-RBF algorithm to construct the BBA(Basic Belief Assignment) for the transformer fault recognition framework. Based on the idea of multi-source information fusion, the final diagnosis conclusion can be achieved by applying DSmT to fuse the BBA, which overcomes the limitations of D-S evidence theory that it is unable to solve the fusion problem of high conflict evidences. The case study of 110 kV transformer is carried out, the result shows that the proposed method has good practicability.

Key words: power transformers; fault diagnosis; AdaBoost-RBF; DSmT; basic belief assignment; multi-source information fusion; high conflict evidence

(上接第 165 页 continued from page 165)

Probabilistic load flow calculation based on cumulant method combining singular value decomposition and uniform design sampling

MAO Xiaoming, YE Jiajun

(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: In the process of sample formation, the PLF-CM (Probabilistic Load Flow based on Cumulant Method) calculation may encounter the condition that the correlation coefficient matrix of input variables is non-positive definite, where the commonly used Cholesky decomposition is no longer applicable. A PLF-CM calculation method with the combination of SVD(Singular Value Decomposition) and UDS(Uniform Design Sampling) is proposed. The random variable samples with the consideration of correlation are obtained by the combination of SVD, UDS and Nataf transformation, which are used to calculate the cumulants of some input variables that are hardly be solved by the conventional numerical methods. The SVD is adopted to deal with the covariance matrix of input variables to accurately calculate the cumulants of output variables, and the probability distribution of output variables is obtained through Cornish-Fisher series expansion. The modified IEEE 14-bus test system is taken as an example to verify the rapidity, effectiveness, and adaptability of the proposed method to high permeability new energy power generation.

Key words: electric power systems; probabilistic load flow; cumulant method; singular value decomposition; uniform design sampling

AI Dissolved gas content in on before and after failure, in C			
	气体含量/	气体含量/(μL·L ⁻¹)	
气体	2005-01-19(故障前)	2006-1-22(故障后)	
H ₂	29.00	159.00	
CH_4	6.63	46.70	
C_2H_6	1.94	5.90	
C_2H_4	23.23	82.57	
C_2H_2	5.88	106.43	
CO	622.00	680.00	
CO_2	2809.00	2941.00	

表 A1 故障前后油中溶解气体含量(案例 1) Table A1 Dissolved gas content in oil before and after failure, in Case1

表 A2 电气试验与绝缘油试验数据(案例1) TableA2 Data of electrical test and insulation oil test in Case1

试验指标	数值	试验指标	数值
局部放电量/pC	≤ 300	绝缘电阻/ ΜΩ	1399
铁芯接地电流/mA	≤ 100	微水/ (mg · L ⁻¹)	6.7
绕组直流电阻相	4.05	油土容由压4-34	25 7
间不平衡系数/%	4.95	油西牙电压/K V	55.7

表 A3 绝对产气率数据(案例1) TableA3 Data of relative gas production in Case1

气体	绝对产气速 <i>率/</i> (mL•d ⁻¹)	气体	绝对产气速率/ (mL・d ⁻¹)	
H ₂	895.88	СО	399.7	
C_2H_2	408.93	CO_2	909.66	
总烃	1401.57			

表 A4 故障融合诊断结果(案例1) Table A4 Results of fault fusion diagnosis in Case1

诊断参量空间	基本信度分配	DST 融合结果	DSmT 融合结果
I	$m_1(S_1) = 0.7341, m_1(S_2) = 0.1421$		
11	$m_1(S_3) = 0.1161, m_1(S_4) = 0.0077$	$m(S_1) = 0.9929$	$m(S_1) = 0.8867$
Ţ	$m_2(S_1) = 0.8262, m_2(S_2) = 0.0136$	$m(S_2) = 0.0013$	$m(S_2) = 0.0659$
I_2	$m_2(S_3) = 0.1518, m_2(S_4) = 0.0084$	$m(S_3) = 0.0057$	$m(S_3) = 0.0463$
	$m_3(S_1) = 0.5923, m_3(S_2) = 0.2584$	$m(S_4) = 0.0001$	$m(S_4) = 0.0011$
I_3	$m_3(S_3) = 0.1173, m_3(S_4) = 0.0320$		

8		•		
左任	气体含量/	气体含量/(μL·L ⁻¹)		
~14	2013-01-15(故障前)	2013-05-09(故障后)		
H_2	3.00	650.50		
CH_4	22.32	306.00		
C_2H_6	3.01	92.55		
C_2H_4	2.17	660.26		
C_2H_2	0	1432.54		
CO	977.68	1268.09		
CO_2	95.15	607.50		

表 B1 故障前后油中溶解气体含量(案例 2) TableB1 Dissolved gas content in oil before and after failure, in Case2

表 B2 电气试验与绝缘油试验数据(案例2) TableB2 Data of electrical test and insulation oil test in Case2

试验指标	数值	试验指标	数值
局部放电量/pC	≤ 300	绝缘电阻/ M Ω	≥ 10000
铁芯接地电流/mA	≤ 100	微水/ (mg · L ⁻¹)	8
绕组直流电阻相			
间不平衡系数/%	75.69	油击穿电压/k V	48.6

表 B3 绝对产气率数据(案例2) TableB3 Data of relative gas production in Case2

气体	绝对产气速率/ (mL•d ⁻¹)	气体	绝对产气速率/ (mL•d ⁻¹)
H ₂	251.94	СО	112.37
C_2H_2	557.39	CO ₂	198.24
总烃	953.32		

表B4 故障融合诊断结果(案例2) TableB4 Results of fault fusion diagnosis in Case 2

诊断参量空间	基本信度分配	DST 融合结果	DSmT 融合结果
I	$m_1(S_1) = 0.6142, m_1(S_2) = 0.0026$		
1	$m_1(S_3) = 0.3819, m_1(S_4) = 0.0013$	$m(S_1) = 0.3805$	$m(S_1) = 0.5660$
,	$m_2(S_1) = 0.8073, m_2(S_2) = 0.0005$	$m(S_2) = 0.0000$	$m(S_2) = 0.2659$
I_2	$m_2(S_3) = 0.1921, m_2(S_4) = 0.0001$	$m(S_3) = 0.6195$	$m(S_3) = 0.1670$
_	$m_3(S_1) = 0.0216, m_3(S_2) = 0.7052$	$m(S_4) = 0.0000$	$m(S_4) = 0.0011$
<i>I</i> ₃	$m_3(S_3) = 0.2377, m_3(S_4) = 0.0355$		

-