

基于多级决策融合模型的电力变压器故障深度诊断方法

李 刚^{1,2}, 于长海¹, 范 辉³, 刘云鹏², 宋 雨¹

(1. 华北电力大学 控制与计算机工程学院, 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. 国网河北省电力公司电力科学研究院, 河北 石家庄 050011)

摘要: 针对电力变压器故障的深度诊断问题, 提出一种深度置信网络与 D-S 证据理论相结合的方法。采用深度置信网络对电力变压器故障的多维数据进行特征提取及分类, 并结合 D-S 证据理论解决故障诊断中的不确定性问题, 构造了电力变压器故障诊断的多级决策融合模型。以变压器油中溶解气体、局放量以及历史故障数据和家族质量史等数据为样本进行仿真实验, 结果表明所提方法对于具备大量多源信息的电力变压器故障诊断问题是有效的。

关键词: 电力变压器; 故障诊断; 多源信息融合; 深度置信网络; D-S 证据理论; 不确定性分析

中图分类号: TM 41

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2017.11.022

0 引言

电力变压器是电力系统中的重要设备, 保证其稳定可靠运行至关重要^[1]。随着生产工艺的提升和改进, 电力变压器的结构更加复杂化、故障类型更加多样化。及时准确地定位故障发生部位, 了解故障发生原因, 进而执行维修活动是确保电力变压器安全稳定运行的关键, 故障诊断方法的研究与应用则为其提供了重要的基础和保障。目前, 在工程实践中较为常见的故障诊断方法是采用改良三比值法对油中溶解气体进行分析, 这也是电力变压器故障诊断最方便有效的方法之一。然而, 该方法在分类和边界确定方面过于绝对化, 致使边界重叠情况发生。针对上述问题, 国内外研究学者尝试将机器学习方法以及统计学方法(如支持向量机^[2]、人工神经网络^[3]、模糊理论^[4]等)用于故障诊断, 并取得了一定的诊断效果。

然而, 目前的故障诊断方法考虑因素较为单一, 并未充分利用电力变压器的检修历史、缺陷信息、家族质量史以及全面运行工况等状态信息^[5]。同时, 数据监测技术的局限性以及知识的不精确性等原因致使信息具有模糊性、随机性等特征, 进而导致电力变压器故障诊断的准确性和时效性远未达到实际应用的要求。此外, 电力变压器整体及内部构造的复杂

性以及部件/系统老化和失效模式演化的非线性、不稳定性等原因, 使其故障诊断存在诸多的不确定性^[6]。且随着量测设备制造工艺的提高及种类的增多, 大量且各式量测设备(如传感器)被部署在变压器上用于实时状态信息的监测, 监测数据呈指数级增长, 其数据量已经达到 TB (TeraByte) 甚至 PB (PetaByte) 级别。上述故障诊断方法中高维数据的处理、有效特征的提取以及存在的各种不确定性等问题, 是电力变压器故障诊断领域亟需解决的难题之一。

深度置信网络 DBN (Deep Belief Nets) 是深度学习模型中的一种, 是在非监督数据上建立多层神经网络的一个有效方法^[7], 其在处理高维、非线性数据的特征提取方面具有显著优势, 可以用来更好地分类, 进而提高分类的正确率。同时, Dempster-Shafer (D-S) 证据理论适用于多源信息的融合分析, 进而可以解决单一信息导致故障诊断中存在的信息不确定性等问题^[8-9]。

综上所述, 本文充分计及两者的优点和弥补现有故障诊断方法的不足, 拟将 DBN 与 D-S 证据理论相结合, 构建多级决策融合模型, 逐步找出故障原因。最后, 通过仿真实验验证了所提方法对于电力变压器故障诊断的有效性。

1 DBN 的基本原理

DBN 方法由多伦多大学的 Geoffrey Hinton 教授^[10]在 2006 年提出, 该方法已经成功应用于分类问题, 而且表现出一定的优势, 是当前国际上机器学习研究的热点领域^[11]。

本质上, DBN 是在无标签数据和标签之间建立一个联合概率分布, 是一个概率生成模型。从其结构

收稿日期: 2017-04-09; 修回日期: 2017-09-27

基金项目: 国家自然科学基金资助项目(51407076); 国家电网公司科技项目(5204DY170010); 河北省自然科学基金资助项目(F2014502050); 中央高校基本科研业务费专项资金资助项目(2015ZD28)

Project supported by the National Natural Science Foundation of China(51407076), the State Grid Science & Technology Project(5204DY170010), the Natural Science Foundation of Hebei Province(F2014502050) and the Fundamental Research Funds for the Central Universities(2015ZD28)

来看, DBN 主要是由多个受限玻尔兹曼机 RBM (Restricted Boltzmann Machine) 堆栈构成。其模型训练采用逐层无监督学习的方式进行, 从而解决了传统神经网络方法对于多层网络训练不适用的问题。此外, DBN 方法集数据特征提取和分类于一体, 具有一定的普适性, 同时可以有效地避免发生维数灾难以及诊断能力不足等问题^[9]。文献[9, 11]已经对 DBN 方法在大数据量特征提取方面的优势给出了充分验证, 本文不再与其他方法进行比较说明。DBN 模型的建立主要包括预训练和调优 2 个过程^[11-12], 下文主要对这 2 个过程做简要介绍。

1.1 预训练

RBM 是 DBN 的基础, 其结构如图 1 所示。从图 1 中可以看出, RBM 由一个显层 v 和一个隐层 h 组成, 且每层中的各神经元无连接, 层与层之间的神经元全连接。预训练的作用是计算得到模型参数的初始值, 其基本思想是: 自底层向上无监督地学习每层 RBM, 单次只训练一层 RBM, 然后将该层 RBM 输出的结果作为其高一层的输入。预训练所需要获得的模型参数是层间连接权值矩阵以及每层各神经元的偏置值。




图 1 RBM 结构图

Fig.1 Structure of RBM

假设 RBM 的 v 层有 N 个显神经元 (显元), h 层有 M 个隐神经元 (隐元), 且显元和隐元均服从伯努利分布。对于一组给定状态下的 (v, h) 值, 计算 RBM 的能量公式为:

$$E(v, h|\theta) = -\sum_{i=1}^N a_i v_i - \sum_{j=1}^M b_j h_j - \sum_{i=1}^N \sum_{j=1}^M v_i W_{ij} h_j \quad (1)$$

其中, v_i 为第 i 个显元的状态; h_j 为第 j 个隐元的状态; 参数 $\theta \in \{W_{ij}, a_i, b_j\}$, W_{ij} 、 a_i 、 b_j 分别为显元 i 与隐元 j 之间的连接权值、显元 i 的偏置阈值、隐元 j 的偏置阈值。

对式 (1) 所示能量函数指数化和正则化后可以得到 (v, h) 的联合概率分布为:

$$P(v, h|\theta) = \frac{e^{-E(v, h|\theta)}}{Z(\theta)} \quad (2)$$

其中, $Z(\theta) = \sum_{v, h} e^{-E(v, h|\theta)}$ 为归一化因子或配分函数, 其计算的结果是显元和隐元集合所有能量指数的和。同时, 对隐元的所有能量指数求和, 可以得到显元集合的边缘分布如下:

$$P(v|\theta) = \frac{1}{Z(\theta)} \sum_h e^{-E(v, h|\theta)} \quad (3)$$

为了使显层概率分布与训练数据符合, 参数 θ

的求解是关键之一。可以通过最大化边缘分布在训练集上的对数似然函数求解参数 θ , 详细的推导过程本文不再展开, 具体可以参考文献[10]。

1.2 调优

在无监督贪婪预训练之后, 可以得到每层 RBM 的初始参数, 从而形成了 DBN 的初始框架。然后需要进一步优化各层网络的参数, 使得网络的判别性能更好。调优的基本思想是自顶层而下的监督学习过程, 利用已添加标签的数据进行训练, 利用径向基函数 (BP) 神经网络算法对 DBN 模型的连接权值和偏置阈值进行反向微调, 最终使网络达到全局最优。

2 D-S 证据理论基本原理

哈佛大学的 A. P. Dempster 教授于 1967 年提出证据理论, 后经其学生 Glenn Shafer 加以扩充和发展, D-S 证据理论由此而来^[13-14]。此后, 随着工程领域中传感器的大量使用, 有效处理多源信息使得 D-S 证据理论被广泛应用。

为了描述和处理来自多源监测数据的不确定性, D-S 证据理论中使用了基本概率分配函数、信任函数及似然函数等概念。

a. 基本概率分配函数。

Θ 为 D-S 证据理论的基本框架, 由互不相容的集合组 θ 的幂集 (2^θ) 构成了命题集合。基本概率分配函数 m 是 $2^\theta \rightarrow [0, 1]$ 的映射, 且对于不可能事件有 $m(\theta) \neq 0$ 以及对 Θ 中全部元素的基本概率之和为 1, 即 $\sum_{A \in \Theta} m(A) = 1$ 。

b. 信任函数。

对于 $\forall A \subset \Theta$, 信任函数定义为 A 中所有子集对应的基本概率之和, 即 $B_{cl}(A) = \sum_{B \subset A} m_i(B)$ 。

c. 似然函数。

似然函数表示不否定 A 的信任程度, 用 p_1 表示如下:

$$p_1(A) = 1 - B_{cl}(\bar{A}) = \sum_{B \subset \Theta} m(B) - \sum_{B \subset \bar{A}} m(B) = \sum_{B \cap A \neq \emptyset} m(B) \quad (4)$$

d. 焦元与内核。

对于 $\forall A \subset \Theta$, 若 $m(A) > 0$, 则称 A 为信任函数 B_{cl} 的焦元; 内核则是识别框架 Θ 中所有焦元的并集。

e. 组合规则。

对于同一个证据, 当其具有 2 个或多个不同的概率分配函数时, 需要对它们进行组合; 对于 $\forall A \subset \Theta$, 识别框架 Θ 中的有限个 mass 函数 $m_1, m_2, \dots, m_n$ 的合成规则为:

$$(m_1 \oplus m_2 \oplus \dots \oplus m_n)(A) = K^{-1} \sum_{A_1 \cap A_2 \cap \dots \cap A_n = A} \prod_{1 \leq i \leq n} m_i(A_i) \quad (5)$$

其中, K 为冲突因子, 其计算公式如式 (6) 所示。

$$K=1-\frac{\sum_{A_1 \cap A_2 \cap \dots \cap A_i = \emptyset, 1 \leq i \leq n} \prod_{1 \leq i \leq n} m_i(A_i)}{\sum_{A_1 \cap A_2 \cap \dots \cap A_i = \emptyset, 1 \leq i \leq n} \prod_{1 \leq i \leq n} m_i(A_i)} \quad (6)$$

f. 判决规则。

$$\begin{cases} m(A_1)-m(A_2)>\varepsilon_1 & \varepsilon_1>0 \\ m(\Theta)<\varepsilon_2 & \varepsilon_2>0 \\ m(A_1)>m(\Theta) \end{cases} \quad (7)$$

其中, A_1 为判断结果; ε_1 、 ε_2 为事先设定的阈值。

3 电力变压器故障深度诊断模型

3.1 变压器故障机理分析

电力变压器在实际运行过程中可能会受到一种或多种应力作用,进而导致其出现各种异常现象,将发生异常的电力变压器作为数据源之一,从中获取相关故障数据,利用数据驱动的方法对其进行故障诊断,是目前较为广泛使用的方法。

电力变压器故障诊断的数据来源具有多样性、复杂性以及不确定性等特征。根据多源信息融合分层决策模型的要求,对电力变压器故障诊断实施多源信息融合,其分类过程是一个从宏观到微观、由故障部位到故障原因的逐级分类过程。从目前电力系统运行的历史统计记录来看,外部短路、绝缘受潮、分接开关触头接触不良等故障出现次数最多,故障频发部位的次序大致为绕组、铁芯、分接开关、套管、绝缘油、冷却系统、保护装置、测示系统、油箱^[15]。以绕组为例,其故障又分为绕组过热、绕组变形、绕组断线、绕组匝间短路等。电力变压器部分故障部位及原因如图 2 所示。




图 2 电力变压器故障部位及原因
Fig.2 Fault location and cause of power transformer

3.2 变压器 DBN 特征提取和分类过程

利用 DBN 方法对电力变压器进行特征提取和故障分类,其过程主要包含以下 6 个步骤:获得需要进行特征提取和分类的变压器源数据;根据需要,定义类别并添加标签;对数据进行[0,1]标准化处理,并将处理后的数据按一定的量化规则分为训练集和测试集;建立一个多隐藏层的 DBN 模型,根据样本维数确定 DBN 模型的输入层神经元个数,使用训练集对 DBN 模型进行无监督逐层训练;根据所要划分

的类别数,确定 DBN 模型的输出层神经元个数,利用 BP 神经网络算法对 DBN 模型的连接权值和偏置阈值进行反向微调;用测试集对模型进行测试。DBN 特征提取和分类模型示意图如图 3 所示。




图 3 DBN 特征提取和分类模型示意图
Fig.3 Schematic diagram of feature extraction and classification model of DBN

3.3 变压器 D-S 证据理论中概率分配函数的定义

在 D-S 证据理论中,概率分配函数并没有明确定义,因此,根据不同场合和需求合理确定基本概率值是实际应用的关键。本文将 DBN 输出结果作为证据之一,其基本概率值计算如下:

$$m(R_i)=y(R_i)/\left(\sum_{i=1}^N y(R_i)+E_n\right) \quad (8)$$

其中, $y(R_i)$ 为 DBN 模型的输出结果; E_n 为网络训练的误差,且 $E_n=\frac{1}{2} \sum (t_j-y_j)^2$, t_j 、 y_j 分别为 DBN 模型的期望输出值和实际输出值; $R_i(i=1,2,\dots,N_1)$ 为故障类别; N_1 为故障类别的总数。

其他实验结论作为证据时,一般采用专家经验与故障数据统计分析结果确定其基本概率赋值。

3.4 变压器多级决策故障诊断模型

文献[16]虽然也提出利用改进的 BP 神经网络与 D-S 证据理论结合构建多层决策模型,但其考虑的实验参数仅限于油中溶解气体分析(DGA)数据,且 BP 神经网络存在诸多局限性。考虑到模型的泛化能力和可靠性,同时结合前文分析,本文在文献[16]的基础上提出一种基于 DBN 和 D-S 证据理论的大型变压器故障诊断方法。变压器多级决策故障诊断模型如图 4 所示,进而逐步分析变压器的故障部位及故障的具体原因。

a. 第 1 级决策融合。

在第 1 级决策融合过程中,首先利用获取的大量数据构造训练样本来训练 DBN 模型(具体的训练过程参考第 3.2 节内容)。然后,利用训练好的 DBN 模型对待诊断数据进行诊断,并获得诊断结果。此外,为了解决模型及数据存在的不确定性问题,还需要尽可能获得在不影响变压器正常运行时的其他相关证据,利用 D-S 证据理论融合所有证据,获得第 1 级决策融合的最终结论。综上,可以将第 1 级决策融




图 4 变压器多级决策故障诊断模型

Fig.4 Multilevel decision model for transformer fault diagnosis

合中故障部位的目标识别框架定义为: $F = \{F_1, F_2, F_3\}$, 其中 F_1, F_2, F_3 分别表示变压器故障部位发生在绕组、油纸绝缘、铁芯。

b. 第 2 级决策融合。

通过第 1 级决策融合基本可以锁定故障发生的部位,但具体的故障原因并不能确定。因此,需要继续寻找关于故障原因更确切的证据来支持第 2 级决策融合,从而得到具体故障原因的诊断结论。第 2 级决策过程的目的是对第 1 级融合中 F_1, F_2, F_3 的故障原因进行细化。因此,将第 2 级决策融合中故障原因的目标识别框架设为 $C = \{C_1, C_2, \dots, C_i\}$, C_i 表示故障具体原因为绕组过热、绕组变形等。针对不同故障部位分别训练 DBN,对细分故障原因进行初步判定,然后结合相关的电气及实验结论以及变压器维修记录等信息,对第 2 级各证据进行 D-S 证据理论融合推理,得到最终诊断结果。

3.5 算法流程

通过以上分析,本文进行多级决策融合的算法流程图如图 5 所示。

具体步骤如下:

- 重构原始数据并为类别添加标签;
- 将待训练的数据统一标准化处理(一般采用 $[0, 1]$ 归一化处理),按一定比例定义训练集和测试集;
- 初始化 DBN 相关参数;




图 5 算法流程图

Fig.5 Flowchart of algorithm

d. 使用训练集中的带标签数据训练各层 RBM, 得到并保存训练好的 DBN 模型;

e. 将待诊断数据输入训练好的 DBN 模型, 得到网络输出结果;

f. 根据公式 (8) 计算网络输出的基本概率值, 同时根据专家经验等规则获取其他证据的基本概率值;

g. 根据公式 (4) — (6) 计算各焦元的信任函数和似然函数以及冲突因子 K ;

h. 求得置信区间 (B_d, p_i) , 得到诊断结论;

i. 根据故障部位, 重新构造 DBN 模型, 按照步骤 a — h 继续寻找更深入的故障原因;

j. 得到最终诊断结论。

4 故障诊断实例

4.1 数据集描述

本文根据所收集的近年来电力变压器故障数据, 得到绕组故障数据、油纸绝缘故障数据、铁芯故障数据等几十项故障部位数据集。具体参数包括变压器型号、数据日期、运行信息 (油温、负载等)、实验数据 (DGA、绕组直流电阻等) 等参数。其中每个数据集后有具体的故障原因 (或健康状态)。此外, 与该变压器相关的历史数据、家族缺陷等数据作为相关证据也一同获得。以收集的廉州站主变压器 (型号为 ODFPSZ-250000/500, 容量为 250 MV·A, 油重为 52.5 t) 的绕组故障数据为例, 其部分参量如表 1 所示。

为了简化并设计 DBN 所需要的训练和测试样本数据, 具体操作如下: 选取同型电力变压器绕组、油纸绝缘、铁芯 3 类故障数据样本, 收集日期不做要求。在第 1 级决策融合中, 从 3 类数据样本中各提取包括 DGA 参量、局放量在内的 1500 组数据, 并为其添加标签, 并按 14:1 的比例提取并组成训练集 D_1 和

表 1 绕组故障样本数据
Table 1 Sample data of winding faults

故障原因	气体体积分数							局放量/pC
	H ₂	CH ₄	C ₂ H ₆	C ₂ H ₄	C ₂ H ₂	CO	CO ₂	
绕组过热	2.7×10 ⁻⁵	9.0×10 ⁻⁵	4.2×10 ⁻⁵	6.3×10 ⁻⁵	2.0×10 ⁻⁷	3.2654×10 ⁻⁴	3.19587×10 ⁻³	240
绕组变形	2.175×10 ⁻⁴	4.0×10 ⁻⁵	4.9×10 ⁻⁶	5.18×10 ⁻⁵	6.75×10 ⁻⁵	3.4845×10 ⁻⁴	3.23154×10 ⁻³	270
绕组断线	3.45×10 ⁻⁴	1.1225×10 ⁻⁴	1.95×10 ⁻⁵	5.15×10 ⁻⁵	5.975×10 ⁻⁵	3.7732×10 ⁻⁴	3.66126×10 ⁻³	234
绕组匝间短路	1.729×10 ⁻⁴	3.341×10 ⁻⁴	1.729×10 ⁻⁴	8.125×10 ⁻⁴	3.77×10 ⁻⁵	3.1125×10 ⁻⁴	3.32528×10 ⁻³	297

测试集 T_1 。因此, D_1 为一个 4200×11 阶的矩阵样本空间。在第 2 级决策融合中, 需要针对不同故障部位分别训练 DBN 模型。本节仍以绕组部位故障数据为例, 对数据中的各故障原因添加标签, 选取前 1400 组样本作为训练集 D_{21} , 其余作为测试集 T_{21} , 可知 D_{21} 为一个 1400×12 阶的矩阵样本空间。其他构造与绕组类似, 这里不再赘述。类别标签编码如表 2 所示。

表 2 类别标签编码
Table 2 Class label coding

多级融合故障诊断模型	故障类别	标签编码
第 1 级决策融合	绕组故障	(1,0,0)
	油纸绝缘故障	(0,1,0)
	铁芯故障	(0,0,1)
第 2 级决策融合	绕组过热	(1,0,0,0)
	绕组变形	(0,1,0,0)
	绕组断线	(0,0,1,0)
	绕组匝间短路	(0,0,0,1)

第 1 级决策融合和第 2 级决策融合中的 DBN 模型采用经典的 5 层模型, 第 1 级决策融合中 DBN 模型的最底层输入神经元数为 8, 最顶层输出神经元数为 3; 第 2 级决策融合中 DBN 模型的最底层输入神经元数为 8, 最顶层输出神经元数为 4。RBM 的最大迭代次数为 100, 学习率为 0.1, 动量参数为 0.9。

4.2 仿真实验

针对该型号变压器在投入运行后不久发生异常的情况, 收集其 DGA 和局放量数据见表 3。

表 3 变压器投入与异常时 DGA 和局放量
Table 3 DGA and partial discharge value when transformer is input and abnormal

状态	气体体积分数							局放量/pC
	H ₂	CH ₄	C ₂ H ₆	C ₂ H ₄	C ₂ H ₂	CO	CO ₂	
投入	1.3×10 ⁻⁵	4.5×10 ⁻⁶	1.2×10 ⁻⁶	5.4×10 ⁻⁶	0	3×10 ⁻⁴	3.603×10 ⁻³	—
异常	2.5×10 ⁻⁵	8.7×10 ⁻⁵	4×10 ⁻⁵	6×10 ⁻⁵	5×10 ⁻⁷	3.7521×10 ⁻⁴	3.551×10 ⁻³	2.3×10 ⁻⁴

该异常经现场检测后确定故障部位发生在绕组, 由绕组过热引起。由本文提出的电力变压器多级决策故障诊断模型对故障数据进行分级决策融合, 其过程如下。

a. 第 1 级决策融合的证据空间为 $E = \{e_1, e_2\}$, 其中证据 e_1 是第 1 级 DBN 模型的诊断结果, e_2 为故障部位历史统计结果。

b. 将发现异常后的数据经归一化后输入训练好的第 1 级决策融合的 DBN 模型中, 得到网络实际输出为 (0.9325, 0.0227, 0.0448), 其期望输出为 (1, 0, 0); 然后根据式 (8), 获得关于证据 e_1 对故障部位 F_1 、 F_2 、 F_3 (分别对应绕组、油纸绝缘、铁芯故障) 的基本概率分配为 (0.9292, 0.0226, 0.0446)。

c. 对于证据 e_2 , 本文考虑 92 台该型号变压器近几年故障发生部位的统计结果, 可以得到证据 e_2 对故障部位 F_1 、 F_2 、 F_3 的基本概率分配为 (0.8030, 0.0325, 0.0338)。

通过以上分析, 得到第 1 级决策融合中证据 e_1 和 e_2 对故障部位的基本概率分配, 具体如表 4 所示。

表 4 第 1 级决策融合基本概率分配函数
Table 4 Basic probability assignment function of first level decision fusion

证据	基本概率			不确定度
	F_1	F_2	F_3	
e_1	0.9292	0.0226	0.0446	0.0036
e_2	0.8030	0.0325	0.0338	0.1307

根据所获得的证据 e_1 和 e_2 以及其对故障部位的基本概率值, 利用 D-S 证据理论进行融合处理, 通过式 (4) — (6) 计算得到冲突因子 $K=0.8822$, 各故障部位的信任度和似然度如表 5 所示。

通过以上分析可以得到, 第 1 级决策融合的结论为: 故障部位为绕组, 其不确定度为 0.0004, 信任区间为 (0.9834, 0.9838)。观察表 5 可知, F_1 经过第 1 级决策融合后, 可靠度明显提高。

d. 经过第 1 级决策融合之后, 需要根据相应的证据进一步识别和确定故障的具体原因。第 2 级决策融合关于绕组部位故障的识别框架为 $C = \{C_1, C_2, C_3, C_4\}$, $C_i (i=1, 2, 3, 4)$ 代表绕组故障的具体原因, 即绕组过热、绕组变形、绕组断线、绕组匝间短路。将相应的气体数据归一化后输入训练好的第 2 级决策融合的 DBN 模型中, 得到网络输出为 (0.7563, 0.1536, 0.0251, 0.0650), 期望输出为 (1, 0, 0, 0)。根据式 (8), 同样可以获得证据 e_3 对绕组故障原因 C_1 、 C_2 、 C_3 、 C_4 的基本概率分配为 (0.7244, 0.1471, 0.0240, 0.0622)。

表 5 各故障部位的信任度和似然度
Table 5 Confidence and likelihood of each fault location

故障	B_{el}	p_l
F_1	0.9834	0.9838
F_2	0.0041	0.0045
F_3	0.0083	0.0087

e. 对于证据 e_4 ,采用 IEC60599 三比值诊断法作为证据来源,统计 104 台该型号电力变压器故障原因,得到证据 e_4 对 C_1 、 C_2 、 C_3 、 C_4 的基本概率分配为 (0.6527,0.1348,0.0275,0.1259)。

通过以上分析,得到第 2 级决策融合中证据 e_3 和 e_4 对各故障原因的基本概率分配,具体如表 6 所示。

表 6 第 2 级决策融合基本概率分配函数
Table 6 Basic probability assignment function of second level decision fusion

证据	基本概率				不确定度
	C_1	C_2	C_3	C_4	
e_3	0.7244	0.1471	0.0240	0.0622	0.0423
e_4	0.6527	0.1348	0.0275	0.1259	0.0591

将证据 e_3 和 e_4 用 D-S 证据理论进行融合,根据式(4)–(6)得到冲突因子 $K=0.6$,则故障原因的信任度和似然度如表 7 所示。

表 7 故障原因的信任度和似然度
Table 7 Confidence and likelihood of each fault cause

故障原因	B_d	p_1	故障原因	B_d	p_1
C_1	0.8593	0.8617	C_3	0.0034	0.0058
C_2	0.0475	0.0499	C_4	0.0191	0.0215

因此,第 2 级决策融合的结论为:故障原因是绕组过热,其不确定度仅为 0.0024,信任区间为 (0.8593, 0.8617)。综合 2 级决策融合的结果可以得出,变压器故障的具体部位为绕组,故障原因是绕组过热,该诊断结果与现场检测结果一致,且可信度较高。融合前后结果对比如图 6 所示。




图 6 各级融合前后结果对比

Fig.6 Results comparison before and after fusion at each level

5 结论

在智能电网环境下利用先进的量测装置可以收集电力变压器越来越多的监测数据。针对影响电力变压器故障发展的不确定性因素增多的实际情况,本文提出了一种利用 DBN 和 D-S 证据理论相结合的电力变压器综合多级决策诊断模型,DBN 对于大量多源异构数据的特征提取具有很好的效果,D-S 证据理论在融合多证据方面也有很好的表现,仿真实验证实了所提模型对提高电力变压器故障诊断正确率的有效性,进而增加了故障诊断的可靠性。本文工作对进一步开展面向电力变压器的状态维护与健

康管理工作提供了可借鉴的方法,今后将在故障原因的深度诊断以及多源异构数据驱动的全参数诊断方面做进一步的研究。

参考文献:

[1] 吴坤,康建设,池阔. 基于改进多分类算法和相关向量机的电力变压器故障诊断方法[J]. 高电压技术,2016,42(9):3011-3017.
WU Kun,KANG Jianshe,CHI Kuo. Fault diagnosis method of power transformers using improved multi-class classification algorithm and relevance vector machine[J]. High Voltage Engineering,2016,42(9):3011-3017.

[2] BACHA K,SOUAHLIA S,GOSSA M. Power transformer fault diagnosis based on dissolved gas analysis by support vector machine[J]. Electric Power Systems Research,2012,83(1):73-79.

[3] 苗长新,申坤,钟世华,等. 基于优化神经网络和 DGA 的变压器故障诊断[J]. 高压电器,2016,52(11):163-168.
MIAO Changxin,SHEN Kun,ZHONG Shihua,et al. Power transformer fault diagnosis based on improved neutral network and DGA[J]. High Voltage Apparatus,2016,52(11):163-168.

[4] HUANG Y C,SUN H C. Dissolved gas analysis of mineral oil for power transformer fault diagnosis using fuzzy logic[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2013,20(3):974-981.

[5] 赵文清,朱永利. 电力变压器状态评估综述[J]. 变压器,2007,44(11):9-12.
ZHAO Wenqing,ZHU Yongli. Summary of condition assessment for power transformer[J]. Transformer,2007,44(11):9-12.

[6] 彭宇,刘大同. 数据驱动故障预测和健康管理综述[J]. 仪器仪表学报,2014,35(3):481-495.
PENG Yu,LIU Datong. Data-driven prognostics and health management:a review of recent advances[J]. Chinese Journal of Scientific Instrument,2014,35(3):481-495.

[7] 赵光权,葛强强,刘小勇,等. 基于 DBN 的故障特征提取及诊断方法研究[J]. 仪器仪表学报,2016,37(9):1946-1953.
ZHAO Guangquan,GE Qiangqiang,LIU Xiaoyong,et al. Fault feature extraction and diagnosis method based on deep belief network[J]. Chinese Journal of Scientific Instrument,2016,37(9):1946-1953.

[8] 阮玲,谢齐家,高胜友,等. 人工神经网络和信息融合技术在变压器状态评估中的应用[J]. 高电压技术,2014,40(3):822-828.
RUAN Ling,XIE Qijia,GAO Shengyou,et al. Application of artificial neural network and information fusion technology in power transformer condition assessment[J]. High Voltage Engineering,2014,40(3):822-828.

[9] 叶汉民,肖尊定. 多传感器信息融合技术在变压器故障诊断中的应用[J]. 变压器,2014,51(9):60-64.
YE Hanmin,XIAO Zunding. Application of multi-sensor information fusion technology to transformer fault diagnosis[J]. Transformer,2014,51(9):60-64.

[10] HINTON G E,OSINDERO S,TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation,2006,18(7):1527-1554.

[11] 石鑫,朱永利,萨初日拉,等. 基于深度信念网络的电力变压器故障分类建模[J]. 电力系统保护与控制,2016,44(1):71-76.
SHI Xin,ZHU Yongli,SA Churila,et al. Power transformer

- fault classifying model based on deep belief network[J]. Power System Protection and Control, 2016, 44(1): 71-76.
- [12] 石鑫, 朱永利, 宁晓光, 等. 基于深度自编码网络的电力变压器故障诊断[J]. 电力自动化设备, 2016, 36(5): 122-126.
- SHI Xin, ZHU Yongli, NING Xiaoguang, et al. Transformer fault diagnosis based on deep autoencoder network[J]. Electric Power Automation Equipment, 2016, 36(5): 122-126.
- [13] DEMPSTER A P. Upper and lower probabilities induced by a multivalued mapping [J]. Annals of Mathematical Statistics, 1967, 38(2): 325-339.
- [14] SHAFFER G. A mathematical theory of evidence[M]. Princeton, USA: Princeton University Press, 1976: 115-136.
- [15] FALLIS A G. Failure analysis of power transformer based on fault tree analysis[J]. Womens Studies International Quarterly, 2013, 3(1): 115-119.
- [16] 魏星, 舒乃秋, 崔鹏程, 等. 基于改进 PSO-BP 神经网络和 D-S 证据理论的大型变压器故障综合诊断[J]. 电力系统自动化, 2006, 30(7): 46-50.
- WEI Xing, SHU Naiqiu, CUI Pengcheng, et al. Power transformer fault integrated diagnosis based on improved PSO-BP neural networks and D-S evidential reasoning[J]. Automation

of Electric Power Systems, 2006, 30(7): 46-50.

作者简介:



李 刚

李 刚(1980—), 男, 河北枣强人, 副教授, 博士, 通信作者, 主要从事智能电网与大数据、信息物理能源系统、故障预测与健康管理方面的研究工作 (E-mail: ququ_er2003@126.com);

于长海(1992—), 男, 黑龙江牡丹江人, 硕士研究生, 主要研究方向为数据驱动方法及应用、电力系统故障预测与健康管理 (E-mail: mdjych@foxmail.com);

范 辉(1969—), 男, 河北石家庄人, 高级工程师, 硕士, 主要研究方向为电力系统分析与控制、电网保护与仿真;

刘云鹏(1976—), 男, 安徽金寨人, 教授, 博士研究生导师, 博士, 主要研究方向为特高压输电技术、电气设备在线检测与外绝缘 (E-mail: liuyunpeng@ncepu.edu.cn);

宋 雨(1958—), 男, 河北张家口人, 教授, 硕士, 主要研究方向为软件工程 (E-mail: syu1999@163.com)。

Deep fault diagnosis of power transformer based on multilevel decision fusion model

LI Gang^{1,2}, YU Changhai¹, FAN Hui³, LIU Yunpeng², SONG Yu¹

(1. School of Computer and Control Engineering, 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. State Grid Hebei Electric Power Research Institute, Shijiazhuang 050011, China)

Abstract: A method combining deep confidence nets with D-S evidence theory is proposed to solve the deep fault diagnosis problem of power transformer. A multi-level decision fusion model is established for fault diagnosis of power transformer, by using deep confidence nets to extract and classify the characteristics of multi-source information in faults of power transformer and using D-S evidence theory to solve the uncertainties of fault diagnosis. Simulation is carried out with dissolved gases in transformer oil, partial discharge value, historical fault data and family history of quality as samples, whose results show that the proposed method is effective for fault diagnosis of power transformer, which has a large amount of multi-source information.

Key words: power transformers; fault diagnosis; multi-source information fusion; deep belief nets; D-S evidence theory; uncertainty analysis