

基于 D—S 证据理论的变压器诊断系统研究

曹 海

(四川电力物流集团公司, 四川 成都 610061)

摘 要:以 Dempster—Shafer 证据理论为基础, 给出了基于神经网络的基本概率分配构造方法和诊断决策规则, 提出了一种神经网络初步诊断和证据理论融合决策诊断相结合的集成神经网络故障诊断方法, 建立了相应的功能模型。并以变压器故障诊断为例, 详细说明了该方法的具体步骤。结果表明, 使用 D—S 证据理论合成法则进行信度合成, 诊断结论的可信度明显提高, 不确定性明显减小, 充分显示了该方法的有效性。

关键词:证据理论; 变压器; 信息融合; 故障诊断

Abstract: On the basis of Dempster—Shafer (D—S) theory of evidence the basic probability distribution construction method and diagnostic decision-making rules based on neural network are given. The integrated neural-network fault diagnosis method combining the preliminary diagnosis of neural network with a mix of evidence theory and decision-making diagnosis is proposed and the relevant functional model is set up. Taking the fault diagnosis of transformer for example the detailed steps of the method are described. The results show that using D—S theory of evidence to do the belief combination the reliability of diagnosis conclusion is enhanced and the uncertainties is significantly reduced which fully demonstrates that the method is effective.

Key words: evidence theory; transformer; information fusion; fault diagnosis

中图分类号: TM835 **文献标志码:** A **文章编号:** 1003—6954(2009)05—0046—04

1 D—S 证据理论

D—S 证据理论是由 Dempster 于 1967 年提出的, 后由 Shafer 加以扩充和发展, 所以证据理论又称为 D—S 证据理论。证据理论是 Bayes 方法的推广, 但比 Bayes 方法具有更多优点。Bayes 方法需要先验概率, 而在 Dempster—Shafer 形式中可以巧妙地解决这一问题, 它是一种在不确定条件下进行推理的强有力的方法。它用先验概率分配函数去获得后验的证据区间, 证据区间量化了命题的可信程度和似然概率。D—S 证据理论比传统的概率论能更好地把握问题的未知性和不确定, 从而在多传感器信息融合中得到了广泛的应用。

1.1 证据理论的基本概念

在故障诊断问题中, 每一种可能的故障都为假设, 各种可能故障的集合为识别框, 故障的每一症状为证据。

在某个条件 E (或证据) 下所有假设的有限集合 $U = \{x_1, x_2, x_3, \dots, x_n\}$ 为识别框, U 表示 X 所有可能

取值的一个论域集合, 且所有在 U 内元素间是互不相容的, 则称 U 为 X 的识别框架。 U 的所有子集构成的集合就是 U 的幂集, 记为 2^U 。

D—S 理论的基本策略是把证据集合划分为若干不相关的部分 (独立的证据), 并分别利用它们对识别框独立进行判断。每一证据下对识别框中每个假设都存在一组判断信息 (概率分布), 称之为该证据的信任函数, 其相应的概率分布为该信任函数所对应的基本概率分配函数。根据不同证据下对某一假设的判断, 按照某一规则进行组合 (或称为信息融合), 即对该假设进行各信任函数的综合, 可形成综合证据 (信任函数) 下对该假设的总的信任程度, 进而分别求出所有假设在综合证据下的信任程度。

1.2 D—S 证据理论的组合规则

证据理论中的组合规则是把证据集合划分为若干个不相关的部分, 并分别利用它们对识别框独立进行判断, 然后利用组合规则把它们组合起来。设 $BEL_1, BEL_2, \dots, BEL_n$ 为论域 U 上的 n 个独立证据的信任函数, 其相应的基本概率赋值分别为 m_1, m_2, \dots, m_n 。

那么组合后的基本概率赋值如下。

设焦点元素分别为

$A_1, A_2, \dots, A_k, B_1, B_2, \dots, B_p, \dots, C_1, C_2, \dots, C_q$

$$K_1 = \sum_{A_i \cap B_j \cap \dots \cap C_p = \Phi} m(A_i)m(B_j)\dots m(C_p)$$

如果 $K_1 < 1$, 则 A B... C 融合后的可信度分配为

$$m(x) = \frac{\sum_{A_i \cap B_j \cap \dots \cap C_p = \Phi} m(A_i)m(B_j)\dots m(C_p)}{1 - K_1} \quad (1)$$

如果 $K_1 = 1$, 则表示 A B... C 互相矛盾, 无法对其基本概率赋值进行融合。由式 (1) 所给出的证据组合规则称为 Dempster 组合规则。

2 BP神经网络法分析

BP网络是一种采用了误差反向传播 (error back propagation, BP) 算法的单向传播的多层前馈网络, 该算法由 Rumelhart 等人于 1986 年完整地提出, 系统地解决了权值调整的问题。BP 网络有明显的输入、隐含和输出层, 隐含层可以有多层, 相邻层采用全互连方式连接, 同层节点之间没有连接, 输出层与输入层之间也没有直接的联系。BP 网络可以看作是一个从输入空间到输出空间的高度非线性映射。

BP 网一般是对采用 BP 算法的前向无反馈神经网络的简称, 它可以实现输入到输出的非线性映射。由 BP 网络理论可知, 如果 BP 网络的隐含层可以根据需要自由设定, 那么一个三层网络能以任意精度逼近任何连续函数。利用 DGA 法的检测数据进行故障判断, 实际上是完成气体组份到故障类型的一个复杂的非线性映射, 而 BP 网络恰好能完成这类复杂的映射问题。BP 网络能存贮任意连续的模式对 $(X_k, T_k, k = 1, \dots, m)$, 完成输入 $\{X_k\}$ 到期望输出 $\{Z_k\}$ 的映射。所以, 在油中溶解气体分析法中采用 BP 网进行故障诊断是比较恰当的。

将 BP 网络理论学习算法转化为实际的学习过程是一个典型的前馈层次网络, 在结构上有如下特点^[1~3]: ①网络分为输入层、隐含层和输出层。根据 BP 网络理论, 隐含层可以为一层或多层, 但是有一个隐含层的 BP 网络能够以任意精度完成任何连续函数的映射, 为了避免训练速度过慢, 只采用一个隐含层。BP 网络分为三层, 输入层 I、隐含层 H 和输出层

O。② I 层有 n 个节点, 对应网络的 n 个征兆输入 (x_1, x_2, \dots, x_n) ; O 层含有 q 节点, 与 BP 网络的 q 种故障输出 (z_1, z_2, \dots, z_q) 响应。H 层节点 (y_1, y_2, \dots, y_p) 数目根据具体模拟的每一诊断标准和方法来的需要来设置。③同层节点无关联, 异层节点前向连接。

令 I 层节点到 H 层节点间的连接权为 v_{ij} , $V = V_{n \times p}$; 令 H 层节点到 O 层节点间的连接权为 ω_{ij} , $W = W_{p \times q}$ 。k (k = 1, 2, ..., m) 为给定的样本数。 θ_i 为 H 层节点的域值, γ_i 为 O 层节点的域值。

BP 网络根据样本的期望输出与实际输出之间的总体误差, 通过学习过程, 从输出层开始, 逐层修正权系数, 使两者之差小于规定的数值。经过学习训练的 BP 网络, 输入故障征兆向量后, 其输出 T_k 与期望输出 Z_k 在允许误差下是近似相等的。因此, BP 网络的输出就是实际故障模式的近似, 从而获得故障问题的近似诊断解。

3 变压器故障诊断实例

证据理论的基本可信度分配, 是专家在所获证据的基础上, 根据个人的经验对识别框架中不同命题的支持程度的数字化表示, 主观性很强。因此不同的专家由同一个证据对同一个命题会给出不同的信度分配, 有时差别很大。为了更客观地得到一证据对不同的命题的信度分配, 可以将各个独立的低维的神经网络作为证据理论的一个证据, 并把低维神经网络的输出值处理后作为辨识框架上命题的基本可信度。经过证据理论的再次融合, 类似于神经网络对信号层面数据的特征提取后的特征值再加以融合, 充分利用证据源的信息, 将大大提高识别的准确率, 消除单一数据源包含信息的不全面和信息的模糊性, 因为证据理论可以对多个证据都支持的判断进行加强。神经网络和证据理论融合的故障诊断方法的基本原理描述如下: 每个测点的传感器 (或传感器组), 对应一个局部神经网络进行局部诊断。这样可以简化各个网络, 避免了单一诊断神经网络复杂的结构形式, 以及某一传感器故障或数据源错误对整个诊断系统带来的不良影响, 诊断系统的容错性能增强。

为了验证神经网络和证据理论集成的故障诊断方法的有效性, 下面以某变电站 220 kV 主变压器的局部放电检测结果作为试验对象, 采用变压器高能量放电故障作为被诊故障。选择变压器常发故障——

高能量放电、绕组围屏破损、硅钢片间短路、电屏蔽装置松动放电作为诊断的故障域。采集变压器正常运行和发生高能量放电故障时正交小波神经和油中溶解气体信号作为诊断数据。

选择正交小波神经和油中溶解气体两个局部诊断网络 A 和 B 并对网络结构进行了构造和对网络进行了训练。对正交小波神经诊断网络 A, 取 50 组数据作为诊断数据, 其余 150 组数据作为诊断网络训练数据。同样, 对油中溶解气体诊断网络 B, 取 50 组数据作为诊断数据, 其余 150 组数据作为诊断网络训练数据。选取变压器高能量放电时的 3 组数据作为诊断数据, 诊断结果见表 1~表 3。

在变压器高能量放电故障下的正交小波神经和油中溶解气体各 3 组数据分别通过两个诊断网络进行独立诊断, 结果表明, 正交小波神经网络 A 对第 2 组数据的诊断结果, 变压器处于高能量放电状态的置信区间为 (0.415 343 7, 0.575 343 7), 变压器处于正常状态的置信区间为 (0.387 536 2, 0.507 536 2), 无法确定变压器的状态, 难以正确判断变压器的实际状

态, 见表 1。由于高能量放电故障对变压器总烃量变化影响比较明显, 因此变压器油中溶解气体网络 B 很好地确诊了故障。但未知信度仍然比较高, 达到了 0.04, 见表 2。分析表 2 独立诊断结果可以发现, 如果其他故障发生或多个故障同时发生时, 同样会像网络 A 那样出现难以判断变压器的实际状态。传感器由于安放位置的不同和自身监测性能的限制, 不同传感器采集的不同故障的数据蕴涵的故障信息有很大的差异, 所以任何诊断网络都存在诊断结果的模糊性。

为了提高诊断准确率, 运用数据融合技术, 充分利用网络 A 和网络 B 诊断信息, 将两者分别作为证据理论融合的两个证据, 使用 D-S 证据理论合成法则进行信度合成, 合成信度见表 3。可以发现, 由于充分利用了不同证据的冗余和互补故障信息, 实现了变压器状态的精确识别。网络的未知信度明显减小, 最大的未知信度仅有 0.009 197, A、B 网络支持度均高的状态的信度相对上升, 支持度均低的状态的信度相对降低, 诊断的能力明显增强。

表 1 正交小波神经网络对高能量放电诊断的结果

	数据 1	数据 2	数据 3
绕组围屏破损	(0.005 950 5, 0.165 904 8)	(0.005 851 2, 0.165 851 2)	(0.006 018 5, 0.166 018 5)
硅钢片间短路	(0.005 954 2, 0.165 954 2)	(0.005 854 6, 0.165 854 6)	(0.006 023 1, 0.166 023 1)
电屏蔽松动放电	(0.005 950 7, 0.165 950 7)	(0.005 863 3, 0.165 863 3)	(0.006 020 2, 0.166 020 2)
高能量放电	(0.766 557 7, 0.966 557 7)	(0.415 343 7, 0.575 343 7)	(0.779 199 4, 0.979 199 4)
正常状态	(0.155 868 8, 0.355 868 8)	(0.387 536 2, 0.507 536 2)	(0.002 438 7, 0.202 438 7)
未知信度	0.16	0.16	0.16
诊断结果	高能量放电	不确定	高能量放电

表 2 油中溶解气体诊断网络对高能量放电诊断的结果

	数据 1	数据 2	数据 3
绕组围屏破损	(0.005 856 4, 0.045 856 4)	(0.005 753 3, 0.045 753 3)	(0.005 816 7, 0.045 816 7)
硅钢片间短路	(0.005 831 2, 0.045 831 2)	(0.005 632 5, 0.045 632 5)	(0.005 863 4, 0.045 863 4)
电屏蔽松动放电	(0.005 864 5, 0.045 864 5)	(0.005 718 6, 0.045 718 6)	(0.005 857 3, 0.045 857 3)
高能量放电	(0.824 135 2, 0.864 135 2)	(0.823 559 5, 0.863 559 5)	(0.823 812 1, 0.863 812 1)
正常状态	(0.001 808 6, 0.041 808 6)	(0.001 879 0, 0.041 879 0)	(0.001 835 7, 0.041 835 7)
未知信度	0.04	0.04	0.04
诊断结果	高能量放电	高能量放电	高能量放电

表 3 两个独立诊断网络信度融合后诊断的结果

	数据 1	数据 2	数据 3
绕组围屏破损	(0.000 059 3, 0.000 979 0)	(0.000 072 8, 0.001 431 4)	(0.000 057 2, 0.000 980 3)
硅钢片间短路	(0.000 058 7, 0.000 978 4)	(0.000 075 6, 0.001 434 2)	(0.000 056 8, 0.000 979 9)
电屏蔽松动放电	(0.000 057 9, 0.000 977 6)	(0.000 078 1, 0.001 436 7)	(0.000 054 6, 0.000 977 7)
高能量放电	(0.742 434 1, 0.743 353 8)	(0.659 873 2, 0.661 231 8)	(0.742 568 9, 0.743 492 0)
正常状态	(0.000 386 3, 0.001 305 9)	(0.000 869 2, 0.002 227 8)	(0.000 379 8, 0.001 302 9)
未知信度	0.009 197	0.013 586	0.009 231
诊断结果	高能量放电	高能量放电	高能量放电

4 结 论

利用该方法进行故障诊断,不但可以克服 BP 网络的缺点,又能利用 BP 网络获得 D-S 证据理论的基本概率赋值,解决了 D-S 证据理论难以获得基本概率赋值的弊端。使用 D-S 证据理论合成法则进行信度合成,可以提高局部诊断网络的诊断能力,提高了诊断准确度,降低了诊断的不确定性。通过变压器故障诊断实验证明,神经网络与 D-S 证据理论相结合的融合诊断算法能够提高诊断精度,并能满足复杂系统实时诊断的要求。

参考文献

[1] 靳蕃等. 神经网络与神经计算机 [M]. 成都:西南交通大

学出版社, 1991.

[2] 史忠植. 神经计算 [M]. 电子工业出版社, 1993.

[3] 焦李成. 神经网络理论 [M]. 西安:西安电子科技大学出版社, 1990.

[4] 夏虹. 基于数据融合技术的设备故障诊断方法研究 [D]. 哈尔滨工程大学博士论文, 2000.

[5] 臧宏志. 基于信息融合的大型电力变压器故障诊断 [D]. 山东大学硕士论文, 2002.

[6] 张兆礼. 神经网络数据融合算法研究 [D]. 哈尔滨工业大学博士论文, 2001.

[7] 吴艳. 多传感器数据融合算法研究 [D]. 西安电子科技大学博士论文, 2003.

[8] 刘宜平, 沈毅. 一种基于多级信息融合技术的系统故障诊断方法 [J]. 系统工程与电子技术, 2000, 22(12): 97-100.

(收稿日期: 2009-07-22)

(上接第 34 页)

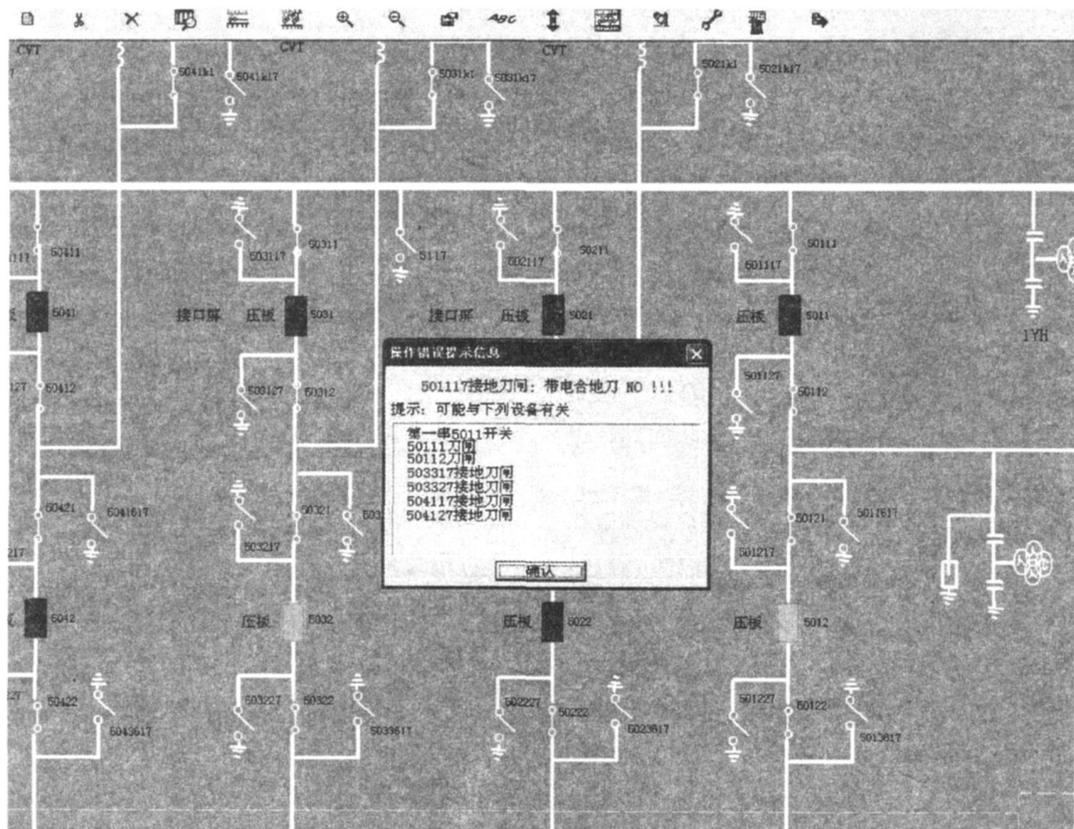


图 2 仿真变电站防误演示

机五防进行了全面的模拟,其在电力数学模型、五防等方面的创造性贡献已为变电运行人员的培训迈上新台阶提供了可靠的技术支持和保障。

参考文献

[1] 防止电力生产重大事故的二十五项重点要求 [M]. 北

京:中国电力出版社, 2000.

[2] DL/T 687-1999. 微机型防止电气误操作装置通用技术条件 [S].

[3] 游景玉主编. 仿真控制论文集 [M]. 珠海出版社, 1999.

(收稿日期: 2009-07-10)