

基于贝叶斯网络和假设检验的变压器故障诊断

何宁辉,朱洪波,李秀广,潘亮亮,周 秀,倪 辉

(国网宁夏电力有限公司电力科学研究院,宁夏 银川 750011)

摘要:电力变压器故障的准确诊断对于电网的可靠运行至关重要。为此,提出一种基于贝叶斯网络和假设检验的溶解气体分析的新型多分类概率诊断模型。该贝叶斯网络模型可嵌入专家知识,从数据中学习数据模式并推断与诊断结果相关的不确定性,并且通过假设检验环节改进数据的选择过程。最后,基于 IEC TC10 数据集,对比 3 种传统诊断方法进行诊断实验,验证所提出模型的有效性。结果表明提出的诊断模型最大诊断准确性为 88.9%,相比传统诊断方法有较大提升。

关键词:溶解气体分析;变压器故障诊断;贝叶斯网络;正态性检验;故障分类

DOI:10.19781/j.issn.1673-9140.2021.06.003 中图分类号:TM86 文章编号:1673-9140(2021)06-0020-08

Transformer fault diagnosis based on bayesian network and hypothesis testing

HE Ninghui, ZHU Hongbo, LI Xiuguang, PAN Liangliang, ZHOU Xiu, NI Hui

(Electric Power Science Research Institute, State Grid Ningxia Electric Power Co., Ltd., Yinchuan 750011, China)

Abstract: Accurate diagnosis of power transformer faults is essential to the reliable operation of the power grid. To achieve this goal, this paper proposes a new multi-class probabilistic diagnostic model based on bayesian network and hypothesis testing of dissolved gas analysis. The bayesian network model can embed expert knowledge, learn data patterns from data and infer uncertainties related to diagnosis results, and improve the data selection process through hypothesis testing. Based on the IEC TC10 data set, this paper compares three traditional diagnostic methods to perform diagnostic experiments to verify the effectiveness of the proposed model. The results show that the maximum diagnostic accuracy of the proposed diagnostic model is 88.9%, which is greatly improved compared to traditional diagnostic methods.

Key words: dissolved gas analysis; transformer fault diagnosis; bayesian network; normality test; fault classification

电力变压器是输配电系统中的重要组件,电力变压器故障严重威胁电网安全运行,可能导致用电企业和电网运行单位的经济损失,因此,变压器故障

诊断已成为状态监测研究和应用的焦点^[1-4]。变压器中的操作和故障事件产生的气体溶解在油中,溶解气体分析(dissolved gas analysis, DGA)进行的变

压器绝缘健康评估^[5]是一种成熟的行业标准方法,专门用于随时间推移测量气体的浓度而及时诊断可能的绝缘问题^[5-6]。

通常 DGA 针对故障气体浓度的变化率来分析变压器的放气行为,目前已有各种不同基于比率的 DGA 分析方法,例如:Doernenburg 法^[7]、Rogers 比值法^[8]或 Duval 三角法^[9]等。这些方法根据特定气体比率的预定义范围对变压器故障进行分类,但是基于比率的 DGA 诊断方法在变压器故障分类中存在问题:

1) 目前已有基于溶解气体分析的一系列变压器故障诊断方法和分析模型,但这些方法给出的结果相互矛盾,并且无法生成与诊断结果相关的不确定性信息^[10];

2) 不同故障诊断方法的适用范围不同,一些方法适用于诊断高级别故障,如热故障一类的故障模式,而其他方法只适用于诊断较低级别的故障,如局部放电^[11];

3) 现有诊断方法给出的诊断结果通常是 100% 置信的,可能导致不同诊断方法针对同一故障得出的结果矛盾,引起诊断困难^[12]。

这 3 个问题直接影响了基于气体比率诊断方法的性能。为了克服这些限制,研究人员提出了基于人工智能技术的诊断方法,但这些方法是黑匣诊断模型,仅表示数值连接,缺乏对物理意义的解释,也就是说它们仅仅表示数据相关性,而不是变压器故障和溶解气体之间的逻辑因果关系。此外,黑匣模型将 100% 置信度分配给单个故障模式,可能使得诊断结果出现矛盾,因此,在工业实践中黑匣模型受到了限制^[13]。

为此该文提出一种基于连续贝叶斯网络和假设检验的概率诊断框架模型,以克服基于比率和黑盒的 DGA 诊断方法的主要局限性,贝叶斯模型一方面捕获了溶解气体和变压器故障之间的定性因果关系;另一方面量化了与故障诊断相对应的条件密度函数,整合了不确定性标准。研究结果可为基于气体溶解性的变压器故障诊断提供参考。

1 贝叶斯网络诊断模型

贝叶斯网络(bayesian networks, BN)是使用随

机图形模型表示随机变量之间概率依存关系的统计模型^[14-15]。BN 模型结构具有多个变量状态,每个状态都可以映射到所研究变量的健康状况。在贝叶斯网络模型中,可用有向无环图(directed acyclic graph, DAG)表示随机变量^[14-15]之间的关系。假设 DAG 由 p 个随机变量组成,表示为 $X = \{X_1 = x_1, X_2 = x_2, \dots, X_p = x_p\}$ 。这些变量通过边链接起来,以反映变量之间的依赖性,如图 1 所示。在 BN 网络中,如果存在一条从 x_1 到 x_2 的边,并且 x_2 是 x_1 的子代,则将节点 x_1 称为另一个节点 x_2 的父代。

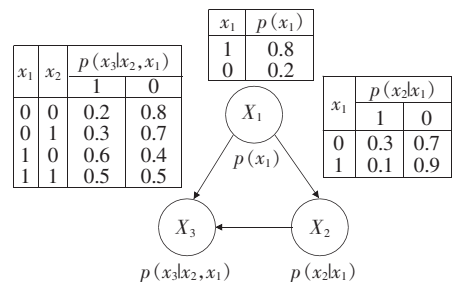


图 1 离散贝叶斯网络示例

Figure 1 Discrete bayesian network example

DAG 中的有向边表示依赖性,统计上随机变量之间的依赖性通过条件概率来量化,例如:节点 x_1 的节点 x_2 的条件概率 $P(x_2|x_1)$ (图 1)指定为

$$P(x_2|x_1) = P(x_2 \cap x_1) / P(x_1) \quad (1)$$

根据等式(1)中的条件概率,可以通过将似然性 $P(x_1|x_2)$ 来估计条件概率 $P(x_2|x_1)$ 以及先验概率 $P(x_2)$,并以证据概率 $P(x_1)$ 进行归一化:

$$P(x_2|x_1) = P(x_2|x_1) / P(x_1) \quad (2)$$

基于贝叶斯定理,应用式(2)进行概率推断,需在贝叶斯网络模型中执行,即网络根据新的计算结果更新每个节点的概率,而贝叶斯网络刚好可以提供 DAG 的定性因果结构,但是在推理任务之前必须通过专家知识或学习算法来指定 DAG 的结构和似然值。贝叶斯网络是一种联合概率分布,在概率论中,基于链式规则可以使用条件概率来计算一组随机变量的联合分布^[14]。因此,随机变量集合 $X = \{X_1 = x_1, X_2 = x_2, \dots, X_p = x_p\}$ 的联合分布定义如下:

$$P(X) = \prod_{i=1}^p P(x_i|x_1, \dots, x_{p-1}) \quad (3)$$

使用 DAG 中编码的信息,可以将等式(3)简化为仅考虑父节点,即如果 X 由离散随机变量组成(图 1),则联合概率密度函数(全局分布)表示为条件概率分布的乘积^[14]:

$$P(X) = \prod_{i=1}^p P(x_i | x_{pa(i)}) \quad (4)$$

式中 $x_{pa(i)}$ 为 x_i 的父集; $P(x_i | x_{pa(i)})$ 为条件概率分布,其中每个变量包含一个分布,如果 X 由连续的随机变量组成,则 BN 模型称为高斯贝叶斯网络(gaussian bayesian network,GBN)模型,联合概率密度函数定义^[14]为

$$P(X) = \prod_{i=1}^p f(x_i | x_{pa(i)}) \quad (5)$$

式中 f 为高斯概率密度分布函数,包含有连续随机变量的密度函数。

通过条件概率表(conditional probability table, CPT)综合从属节点之间的关系强度,可为 BN 模型的每个节点 $x_i \in X$ 定义 CPT,表示所有父节点 $x_{pa(i)}$ 的条件概率分布(conditional probability distribution,CPD)。如果节点是离散的随机变量,则 CPD 可以表示为多项式分布,对于连续随机变量,可以通过正态分布来表示变量的依赖性。在离散情况下,如果节点没有父节点(根节点),则通过边际概率表来反映节点关系(例如图 1 中的节点 x_1);如果某个节点具有父节点,则 CPT 的每个像元将指定该节点处于特定状态的条件概率,条件是给定其父节点(图 1 中的节点 x_2 和 x_3)状态的特定配置。在连续情况下,将使用单变量正态分布来指定根节点的 CPT,如果节点具有父级,则 CPD 将是高斯分布的线性组合。BN 模型完全由 DAG 和节点之间的条件概率定义,即 $f_{BN} = f_{DAG}(\theta)$,其中 θ 表示 CPT 的参数。估计节点之间的条件概率的过程称为参数学习,而估计后验分布的过程(存在特定数据的情况下进行诊断)称为概率推断。

1.1 参数和 BN 结构学习

该文通过参数估计方法来估计连续和离散随机变量的 CPT 值。贝叶斯网络参数学习技术的经典示例包括最大似然估计(maximum likelihood estimation,MLE)和贝叶斯估计^[14]。该文通过最大化给出

给定参数观测值的可能性,这种方法侧重于 MLE 算法。对于给定的训练数据集 $D = \{D_1, D_2, \dots, D_{|train|}\}$,首先,需要估计由贝叶斯网络 $f_{BN} = f_{DAG}(\theta)$ 生成数据集的可能性,然后找到最大似然估计:

$$\hat{\theta} = \arg \max \{L(\theta | D)\} \quad (6)$$

MLE 算法可以看作是所选参数和观测数据之间一致性的最大化过程。根据随机变量的离散或连续性质,将以不同的分布对 CPD 建模,并且可能性将有所不同。除了参数学习,从数据集中还可以学习 DAG 的结构,此时问题集中于在寻找使得分函数的值最大化的 BN 结构。为了处理过拟合问题,将不同的信息标准用作评分函数(如 Akaike 或贝叶斯信息标准^[15]),结构优化问题则以通过不同的元启发法来解决,这个过程称为结构学习^[14]。该文着重于参数学习的步骤,并且 DAG 模型是从 DGA 标准衍生的知识中得出,因此这里不进一步考虑结构学习技术。

1.2 概率推论

在确定贝叶斯网络的结构并完成参数学习之后,可以使用 BN 模型进行概率推断,这项工作的目的是执行诊断或因果分析,即从影响(测得的 DGA 值)反推至原因(变压器故障)的推理。因果分析主要包括通过 BN 网络更新未观察到的节点的概率,并对系统最可能的状态进行估计。也就是说,将实际测量的气体值作为 BN 模型的输入,并通过 DAG 结构评估可能原因的后验概率,即 $P(\text{变压器故障} | \text{气体数据})$ 。根据每个节点的后验概率可以推断出未观测参数的状态以及该节点最可能的状态,对于离散情况和连续情况,推理过程则有所不同。

1.3 贝叶斯故障诊断流程

该文提出的贝叶斯诊断框架如图 2 所示,该框架分为 4 个主要部分:交叉验证、数据预处理、学习和推理。图 2 中的左侧路径用于表示离散随机变量的处理过程,右侧路径用于表示连续随机变量的处理过程。交叉验证阶段的目标有 2 个:①通过获取更准确的估算值来验证每个生成的 BN 模型拟议框架的分类表现;②评估如何将诊断结果推广至一个独立的数据集。交叉验证阶段主要采用蒙特卡洛交

叉验证法,主要步骤^[14-15]如下:

- 1)初始化试验计数器, trials=0;
- 2)随机调整数据集,执行预处理、学习和推理步骤,并存储结果;
- 3)如果 trials<Max_trials,则从上一步进行迭代,再将 trials 计数增加 1;
- 4)如果 trials = Max_trials,则结束循环,然后提取均值。

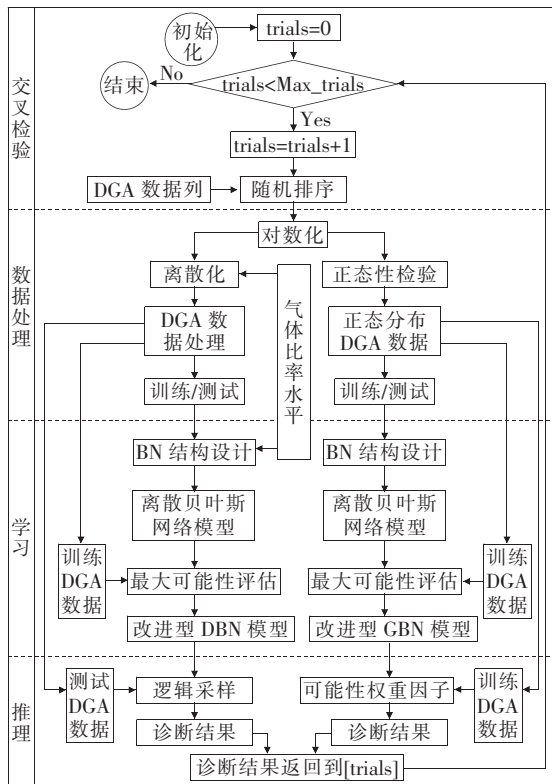


图 2 贝叶斯诊断网络

Figure 2 Schematic diagram of bayesian diagnosis network

对于每个原始数据集,经过随机排序、对数化后都将生成不同的训练和测试数据集,因此,此过程使用 Max_trials 设置的数值,基于训练和测试数据集来重复训练和测试诊断网络,结果表明,该验证过程使诊断结果具有更高的置信度和一致性^[15]。

数据预处理的主要目的是将具有不同数量级的数据标准化,便于分析。数据预处理阶段从对数化步骤开始,应用对数化是因为诊断信息基于结果的数量级^[15]。首先,获取数据集中每个气体样本的对数;然后,将数据集集中的每个变量缩放成均值为零、标准差为 1;最后,通过对变量的每个样本减去平均值并除以标准偏差来实现数据的标准化。

随后根据 DGA 数据的性质进行不同的预处理、学习和推理算法。在离散概率和连续概率情况下,分别使用随机排序后数据集的 80%和 20%将数据集划分为训练、测试数据集(图 2)。不同的 DGA 分析技术使用不同的故障分类标准,将热故障和电气故障分为不同故障级别。为了产生一致且可比较的结果,该文为所有分析技术定义一个通用的分类框架,将所有可能的变压器绝缘故障模式分为过热故障、电弧放电、局部放电(partial discharge, PD)和普通老化故障。此分类与 IEC TC10 案例研究的数据集分类方法一致,该数据集包括有每种故障模式的数据样本,该文采用 R bnlearn 软件包^[15]进行离散和连续贝叶斯网络模型的学习和推理。

1.4 IEC TC10 数据集

IEC TC10 数据集^[14]包含 7 种不同气体的集合:乙烷(C₂H₆)、乙烯(C₂H₄)、氢气(H₂)、甲烷(CH₄)、乙炔(C₂H₂)、一氧化碳(CO)和二氧化碳(CO₂),分别从不同的变压器中采样,并标有其相应的故障模式。故障分为 4 种:正常老化故障、热故障(T<700、T>700 °C)、电弧故障(低能量和高能量放电)和局部放电(PD)故障。IEC TC10 数据库还包含在超过 15 个独立网络上运行的数万台变压器中观察到的典型正常老化数据值。基于 IEC TC10 数据集,该文进行贝叶斯网络的训练、学习、测试和建模工作。

2 结果与讨论

2.1 假设检验及故障模式识别

采用 IEC TC10 数据集,使用线性高斯分布来定义条件概率值 $f(x_i | x_{pa(i)})$,可以估计对数似然的闭合形式解,其计算和学习的结果是一组条件概率表,这些表指定了每个节点的条件概率密度函数。

GBN 网络模型结构如图 3 所示。使用训练集对模型进行训练,即可获得具有 8 列(7 种气体值和故障模式)和 134 行的数据矩阵。学习过程中将估计 BN 模型中每个节点的相应参数,例如电弧故障节点: $P(\text{电弧} | C_2H_6, C_2H_2, CH_4, C_2H_4, CO_2, CO, H_2) \sim N(\beta_0 + \beta_1(C_2H_6) + \beta_2(C_2H_2) + \beta_3(CH_4) + \beta_4(C_2H_4) + \beta_5(CO_2) + \beta_6(CO) + \beta_7(H_2); \sigma^2)$ 。




图 3 GBN 网络模型结构

Figure 3 Structure diagram of GBN network model

由图 3 可知,当拟合分布的图形表示变得复杂且具有 2 个以上的父节点时,将检查每个气体节点的分布拟合优度,以改进数据选择,剔除分布拟合优度不佳的数据组,避免对故障模式的识别造成干扰。

基于拟合正态分布的分位数 Q-Q 如图 4 所示(圆圈表示样品分位数的原始数据点,直线表示拟合直线),可以清晰地看出各种气体的正态性,CO、CO₂ 不遵循正态分布。因此,该文使用服从正态分布气体的数据集训练 GBN 模型。GBN 的概率推断基于似然加权(likelihood weighting, LW)算法^[14],该算法固定了测试 DGA 的气体样本,并使用样本出现的可能性对样本进行加权;LW 算法计算给定节点 $X_i \in X$ 在给定出现次数 $E = \{e_1, e_2, \dots, e_{\text{test}}\}$ 下的加权概率,其中 $X = \{X_1, X_2, \dots, X_n\}$ 。在将该算法应用于 DGA 数据集时,对于每种故障模式 f_i ,推断的结果都是一组加权值 (w_i, x_i) ,其中 $1 < i < K$,其密度值可以通过内核密度估计^[15]进行计算。

使用服从正态分布的气体数据集训练和测试的 GBN 模型故障类型及其故障因素概率分布结果如图 5 所示,其中, y 轴的核密度是每种故障模式的核密度估计值, x 轴是每种故障模式发生的概率数值。在给定的 $P_r(f_i | C_2H_6, C_2H_4, H_2, CH_4, C_2H_2)$ 条件下,故障的原因最大可能为局部放电故障,其故障概率为 0.62(概率分布曲线最大值处对应的概率)。可见根据概率推论结果,就可以在故障判定标准不确定的情况下做出科学的故障判断决策,即不仅可以从最大故障概率的角度制定不同的设备维修方法,还可以通过概率分布函数作为辅助判断标准。

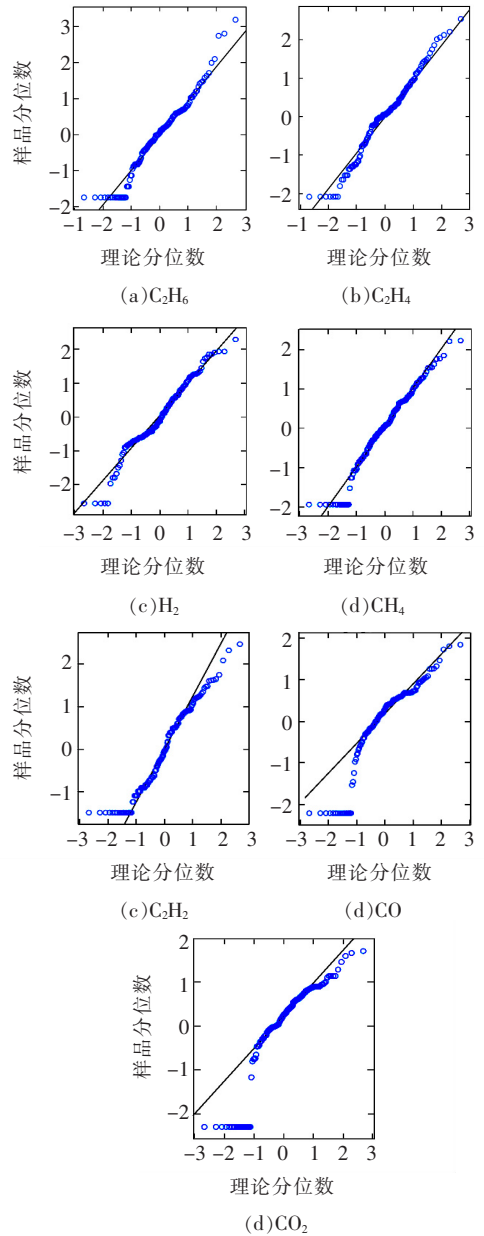


图 4 气体 Q-Q

Figure 4 Gas Q-Q




图 5 连续变量的推断结果分布

Figure 5 Distribution of inference results for continuous variables

例如,概率分布函数的宽度越窄,GBN 模型最终诊断中的置信度就越高,与之相比大多数 AI 方法会丢失此信息,因为普通 AI 的故障分类结果是二进制值或确定性概率值,因此,无法准确得到结果的不确定性以进行后续设备维护策略的制定。

2.2 故障诊断结果

采用传统的固定比率得到的故障模式诊断结果如表 1 所示,比例取值分别来自 Doernenburg、Duval、Rogers 方法。从表 1 可以看出,Doernenburg、

Duval 方法不能诊断出发生正常老化故障的变压器,这会对总体分类精度产生负面影响。但是固定比率法适用于识别局部放电故障(Duval 方法)和电弧故障(Duval、Doernenburg 方法)。

应用贝叶斯框架获得的结果如表 2 所示,其中所有模型均经过 103 次试验,测试数据样本数为 33×103 个。从表 2 可以看出,相对于表 1 中基于比率的诊断技术,离散贝叶斯网络模型明显提高了诊断的准确性。

表 1 基于比率的诊断结果

Table 1 Ratio based diagnostic results

方法	准确性					%
	总体	热	局部放电	电弧	正常	
Rogers	42.39±7.4	58.5±18.72	12.7±33.53	66.2±11.4	3.7±11	
Doernenburg	60.80±6.5	74.3±16.90	73.9±35.20	94.0±6.0	0	
Duval	68.90±7.2	87.7±12.60	96.9±17.00	100.0	0	

表 2 贝叶斯网络结果准确性统计

Table 2 Statistical table of accuracy of bayesian network results

方法	准确性					%
	总体	热	局部放电	电弧	正常	
Rogers	73.76±7.2	70.2±18.0	34.08±13.6	93.72±6.1	61.50±15.8	
Doernenburg*	79.86±6.6	74.3±16.9	73.90±35.2	94.00±6.0	64.00±15.0	
Duval*	72.80±7.0	49.9±20.2	96.30±18.8	96.30±5.0	49.70±16.1	
GBN:所有气体	80.90±6.6	67.7±18.5	81.10±11.3	93.94±6.5	73.07±14.9	
GBN:普通气体	82.30±6.6	68.7±17.4	94.40±6.8	94.19±6.8	72.90±15.4	

注: * 包括 BN 模型中的正常状态

对于 Doernenburg 和 Duval 方法,准确性的提升是预期之内的,因为它们本身就具有捕获正常老化故障的能力。但是 Rogers 方法也显示出整体诊断效果的改进,而 GBN 模型得到的结果精度则有了进一步提升,同时,在 GBN 模型中,仅包含正态分布的气体变量可提供最佳结果,最大整体精度为 88.9%,即 $82.3\%+6.6\%$ 。

部分 DGA 样本如表 3 所示,涵盖了所有气体条件、实际的设备健康状态、表 2 中采用最佳 GBN 设置得到的结果以及采用经典 DGA 方法得到的结果。这些气体的体积分数如表 4 所示,其中,利用该文提出的 GBN 模型和气体的体积分数 # 4 推断出的分类结果见图 5。

由表 3、4 可知,采用该文提出的 GBN 模型推断得到的故障类型与实际故障一致,采用 Duval 方法可以推断所有故障,但是不能准确诊断出由正常老化引起的故障;采用 Rogers、Doernenburg 方法则无法检测出全部故障。

基于 # 1~# 6 数据集,采用该文提出的 GBN 模型,与决策树、支持向量机以及神经网络模型进行对比,得到故障模式识别结果,如表 5 所示,可以看出,在该文 GBN、决策树、支持向量机、神经网络模型中,故障模式识别准确度从大到小依次是该文 GBN>神经网络>决策树=支持向量机,可见该文提出的模型识别准确度最高,其次是神经网络模型,而决策树和支持向量机已经很难准确识别故障类型。

表3 故障诊断分类结果

配置	Rogers	Doernenburg	Duval	GBN	实际故障
#1	N/A	N/A	电弧	电弧	电弧
#2	弧	N/A	热	热	热
#3	N/A	局部放电	热	热	热
#4	N/A	N/A	局部放电	局部放电	局部放电
#5	电弧	N/A	热	正常	正常
#6	正常	N/A	热	正常	正常

表4 气体的体积分数

气体	体积分数					
	#1	#2	#3	#4	#5	#6
H ₂	1 330	66	2 031	9 340	200	134
CH ₄	10	60	149	995	50	134
C ₂ H ₂	182	1	1	7	30	1
C ₂ H ₄	66	7	3	6	200	45
C ₂ H ₆	20	2	20	60	50	157

表5 故障诊断分类模型对比

配置	该文 GBN	决策树	支持向量机	神经网络	实际故障
#1	电弧	热	电弧	电弧	电弧
#2	热	局部放电	热	热	热
#3	热	局部放电	局部放电	电弧	热
#4	局部放电	局部放电	局部放电	局部放电	局部放电
#5	正常	正常	电弧	正常	正常
#6	正常	正常	电弧	电弧	正常
总体准确率/%	100	33.3	33.3	66.7	—

3 结语

经典 DGA 方法得到的诊断结果是确定性概率值,并且缺乏对物理意义的解释,因此,结果意义不明晰,准确度有待提升。为此该文提出了一种基于高斯贝叶斯网络(GBN)的变压器诊断新方法。该方法不仅将清晰的决策范围转换为概率函数,而且每个故障模式的可能性的推断都反映了与决策过程相关的不确定性,得到以下主要结论:

1) 针对正常老化故障、局部放电、热和电弧放电故障的诊断结果,表明该文提出的 GBN 模型的

最大精度为 88.9%,高于传统诊断方法;

2) 测试数据的正态分布性对模型诊断精度至关重要,气体数据正态分布性越好,诊断精度也就越高;

3) 相比传统诊断方法,采用该文提出的 GBN 诊断模型能够有效诊断出故障类型,通过与实际故障类型的对比,表明该文故障诊断分类结果的准确性。

参考文献:

- [1] 黄春梅,马宏忠,付明星,等.基于混沌理论和 KPCM 聚类的变压器绕组松动状态监测[J].高压电器,2019,55(1):95-102.
HUANG Chunmei, MA Hongzhong, FU Mingxing, et al. Looseness state monitoring of transformer winding based on chaos theory and KPCM clustering method[J]. High Voltage Apparatus, 2019, 55(1): 95-102.
- [2] 徐阳,谢天喜,周志成,等.基于多维度信息融合的实用型变压器故障诊断专家系统[J].中国电力,2017,50(1):85-91.
XU Yang, XIE Tianxi, ZHOU Zhicheng, et al. Practical expert system for transformer fault diagnosis based on multi-dimensional information fusion technology[J]. Electric Power, 2017, 50(1): 85-91.
- [3] 康兵,杨勇,李振兴,等.基于实际运行数据的配电变压器故障原因多维度分析[J].智慧电力,2019,47(3):66-70+116.
KANG Bing, YANG Yong, LI Zhenxing, et al. Multidimensional analysis of causes of distribution transformer fault based on actual operation data[J]. Smart Power, 2019, 47(3): 66-70+116.
- [4] 党东升,张树永,葛鹏江,等.基于改进量子粒子群优化支持向量机的变压器故障诊断方法[J].电力科学与技术学报,2019,34(3):108-113.
DANG Dongsheng, ZHANG Shuyong, GE Pengjiang, et al. Transformer fault diagnosis method based on support vector machine optimized by improved quantum-behaved particle swarm optimization[J]. Journal of Electric Power Science and Technology, 2019, 34(3): 108-113.
- [5] 程宏波,刘嘉,康嘉斌,等.一种变压器健康状态的改进免疫识别方法[J].电力科学与技术学报,2018,33(2):141-147.

- CHENG Hongbo, LIU Jia, KANG Jiabin, et al. Improved immune recognition method of transformer health[J]. Journal of Electric Power Science and Technology, 2018, 33(2): 141-147.
- [6] Jin Zhuorui, Sun Jian, Yang Qing, et al. A novel transformer winding fault diagnosis method based on damped oscillation wave[J]. Journal of Physics: Conference Series, 2020, 1619(1): 52-57.
- [7] Zhao Mingyue. Failure of power transformer and diagnosis method[J]. International Core Journal of Engineering, 2020, 6(7): 14-18.
- [8] 朱保军, 咸日常, 范慧芳, 等. WRSR与改进朴素贝叶斯融合的变压器故障诊断技术研究[J]. 电力系统保护与控制, 2021, 49(20): 120-128.
- ZHU Baojun, XIAN Richang, FAN Huifang, et al. Transformer fault diagnosis technology based on the fusion of WRSR and improved naive Bayes[J]. Power System Protection and Control, 2021, 49(20): 120-128.
- [9] 赵莉华, 程胤璋, 武立平, 等. 基于模态分析的变压器铁芯故障诊断[J]. 电测与仪表, 2019, 56(11): 8-13.
- ZHAO Lihua, CHENG Yinzhang, WU Liping, et al. Transformer core fault diagnosis based on modal analysis[J]. Electrical Measurement & Instrumentation, 2019, 56(11): 8-13.
- [10] 段炼, 黄锦增, 唐娴, 等. 基于 Attention-RBF 神经网络的配电变压器电流骤降点辨识方法[J]. 供用电, 2020, 37(12): 31-39.
- DUAN Lian, HUANG Jinzeng, TANG Xian, et al. Identification model of distribution transformer current sag point based on Attention-RBF neural network[J]. Distribution & Utilization, 2020, 37(12): 31-39.
- [11] 陈子辉, 吴智影, 刘贺, 等. 基于纵横交叉算法的变压器三相不平衡损耗研究[J]. 电网与清洁能源, 2020, 36(7): 57-63.
- CHEN Zihui, WU Zhiying, LIU He, et al. Research on three-phase unbalanced loss of transformers based on crisscross optimization algorithm[J]. Power System and Clean Energy, 2020, 36(7): 57-63.
- [12] Ni Hui, Xu Xiaolu, Gong Hao, et al. Design of fast fault diagnosis system for transformer equipment based on CBR and RBR[J]. IOP Conference Series: Earth and Environmental Science, 2020, 546(5): 052004.
- [13] Neapolitan R E. Learning bayesian networks[M]. Englewood, CO: Prentice Hall, 2004: 150-155.
- [14] Huang Xinyi, Huang Xiaoli, Wang Binrong, et al. Fault diagnosis of transformer based on modified grey wolf optimization algorithm and support vector machine[J]. IEEJ Transactions on Electrical and Electronic Engineering, 2020, 15(3): 409-417.
- [15] 位一鸣, 童力, 罗麟, 等. 基于卷积神经网络的主变压器外观缺陷检测方法[J]. 浙江电力, 2019, 38(4): 61-68.
- WEI Yiming, TONG Li, LUO Ling, et al. An exterior defects detecting method of main transformer based on convolutional neural networks[J]. Zhejiang Electric Power, 2019, 38(4): 61-68.