

基于邻域粗糙集与深度信念网络的 油浸式变压器故障诊断

李水天¹, 黄雪薇¹, 田 伟², 蒋 晶¹, 李钧涛³

(1. 广东电网有限责任公司广州供电局, 广东 广州 510000; 2. 新乡航空工业(集团)有限公司, 河南 新乡 453003;
3. 河南师范大学 数学与信息科学学院, 河南 新乡 453007)

摘要: 针对油浸式变压器的故障类型分类问题, 提出一种基于邻域粗糙集与 DBN 的故障诊断模型。通过对变压器中故障气体进行无编码比值处理, 得到了 35 种故障特征气体比值。利用相关性分析与邻域粗糙集算法对所得气体比值进行特征选择, 删去冗余以及对故障类型没有贡献的特征气体比值。将所得的 9 种特征气体比值作为输入变量, 构建 DBN 诊断模型, 实现了油浸式变压器的故障诊断。DGA 数据上的实验结果验证了所提方法的有效性和准确性。

关键词: 油浸式变压器; 邻域粗糙集; 深度信念网络; 故障诊断

中图分类号: TP13

文献标志码: A

文章编号: 2096-7772-(2024)01-0007-07

0 引言

油浸式变压器是电力系统中不可或缺的设备之一, 在电能的传输和分配中扮演着重要的角色^[1]。然而, 变压器的长期运行和高负荷工作会导致设备性能下降或严重损坏, 对电力系统的稳定性和可靠性带来威胁^[2]。传统的变压器检修维护主要依赖于定期巡视和试验, 但这种检修方式可能无法及时发现变压器内部潜在的故障^[3], 从而导致故障被忽视或延误维修, 增加故障风险和维修成本。为了及时采取有效的维修和保养措施, 减少故障带来的影响, 精准的故障类型预测变得尤为重要。

油中溶解气体分析法 (Dissolved Gas Analysis, DGA) 是目前最常用的油浸式变压器故障诊断方法之一^[4-5]。在变压器运行过程中, 油-纸复合绝缘材料会发生化学反应, 释放出低分子的氢气、烃类和含碳的气体化合物, 并且溶解于绝缘油中^[6]。不同类型的故障会导致不同的气体产生, 其中最为主要的是氢气 (H₂)、甲烷 (CH₄)、乙烷 (C₂H₆)、乙烯 (C₂H₄) 和乙炔 (C₂H₂)^[7]。因此, 可以根据故障气体的种类和含量来判断变压器

是否存在特定的故障类型。传统的诊断方法, 如 IEC 三比值法^[8]、Doernenberg 比值法和 Rogers 比值法^[9]等, 通过对故障气体的比值进行故障编码, 并将其与故障类型对应起来, 进而实现变压器故障类型的诊断。然而, 在实际中可能会出现故障编码不在编码范围内的编码组合, 导致传统的诊断方法无法准确识别变压器的故障类型。从数据中学习是现代人工智能的核心研究领域^[10]。基于机器学习的故障诊断技术已经成功地应用于油浸式变压器的故障类型预测^[11-14]。文献 [11] 提出了基于贝叶斯正则化算法的深度信念网络 (Deep Belief Network, DBN), 实现了对变压器的故障诊断。文献 [12] 提出了基于麻雀优化算法的支持向量机来进一步提高变压器的诊断精度和运算速度。值得注意的是文献 [11] 和 [12] 均采用传统的 5 种基本故障气体 (即 H₂、CH₄、C₂H₆、C₂H₄ 和 C₂H₂) 作为诊断模型的输入变量。因为这 5 种特征变量所包含的故障信息不完整, 所以导致故障诊断的准确率较低。为了充分利用故障气体中所包含的故障信息, 文献 [13] 采用无编码比值法获得了 8 种故障特征气体比值, 并将这 8 种特征作为改进版本支持向量机的输入变量, 有效

收稿日期: 2023-08-09

基金项目: 河南省科技攻关计划 (212102210140, 172102210047)

第一作者简介: 李水天 (1996—), 男, 广东吴川人, 工程师, 硕士, 主要从事配网规划及运维研究。

通信作者简介: 李钧涛 (1978—), 男, 河南南阳人, 教授, 博士, 主要从事数据驱动建模与控制、机器学习等研究。

地提高了故障诊断的准确率。此外,文献[14]利用主成分分析对 17 种故障气体比值进行降维处理和特征提取,并据此构建了基于 LightGBM 的变压器故障诊断模型,提高了分类预测精度。

尽管上述文献在变压器故障诊断方面取得了一定的进展,但其所利用的故障气体种类相对有限,无法全面反映故障信息。为此,本文通过相关性分析与邻域粗糙集 (Neighborhood Rough Sets, NRS) 算法对所构建的 35 种特征气体进行特征选择,得到 9 种对故障类型有贡献的特征气体比值。并将所得特征气体比值作为输入变量,基于 DBN 构建了油浸式变压器故障类型的诊断模型。

1 变压器油中气体及故障特性分析

目前,我国常见的供配电系统采用的是油浸式电力变压器,其典型的故障类型主要分为机械类故障、热性故障和电性故障^[15]。由于机械类故障会以热性故障和电性故障的形式表示出来,因此本文不考虑机械类故障。热性故障类型主要包括中低温过热和高温过热,电性故障类型主要包括局部放电、低能放电和高能放电等。

变压器的热性故障或电性故障主要体现在溶解于油中不同气体含量的变化上,其中最为主要的是 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 和 C_2H_2 的含量。不同故障类型的故障气体含量特点如表 1 所示。

表 1 不同故障类型特征气体的含量特点

故障类型	气体含量
热性故障	烃类气体含量高, H_2 含量高
局部放电	H_2 、 CH_4 、 C_2H_6 含量较高
电性故障	低能放电 C_2H_4 、 C_2H_2 、 H_2 含量较高
高能放电	C_2H_2 含量高、 H_2 含量较高

从表 1 中可以看出,不同类型的故障通常会导致特定气体的释放。通过对油中溶解气体定性和定量分析,能够得知变压器内部的运行状况和潜在的故障类型。因此,可以利用油中溶解气体分析法来诊断供配电系统中变压器的故障类型。一般含有 5 种故障气体含量和故障类型的数据称为 DGA 数据。

2 基于 NRS 与 DBN 的油浸式变压器故障诊断

根据上一节的分析,油浸式变压器的故障类型可总结为六种:低能放电、高能放电、局部放电、高温过热、中低温过热和正常。因此,油浸式变压器的故障诊断问题可视为一个六分类问题。为了实现分类

任务,我们基于 NRS 算法,构建了 DBN 诊断模型。整体框架如图 1 所示。




图 1 基于邻域粗糙集与 DBN 的油浸式变压器故障诊断流程

本文所用的 DGA 数据可从 <https://github.com/Cliango/DGA.git> 获取。该数据包含 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 和 C_2H_2 共 5 种故障气体和正常、中低温过热、高温过热、低能放电、高能放电和局部放电 6 种故障类型,共有 202 个样本。数据样本的分布见表 2。

表 2 DGA 数据样本分布

故障类型	低能放电	高能放电	局部放电	高温过热	中低温过热	正常
编号	1	2	3	5	4	6
样本数	35	45	27	31	30	34

2.1 基于相关性分析与邻域粗糙集的特征选择

传统诊断方法 (如 IEC 三比值法^[8]、Doernenberg 比值法和 Rogers 比值法^[9]等)表明,故障气体之间的比值在油浸式变压器的故障诊断中具有一定的应用价值。此外,故障气体的占比变化与故障类型之间联系密切。因此,可以利用 5 种故障气体之间的比值作为特征来分析判断变压器的内部运行状态。本文通过无编码比值法构建了 35 种特征气体比值,具体结果见表 3,其中 C_1 代表一阶碳氢化合物 (即 CH_4), C_2 代表二阶碳氢化合物之和 (即 $C_2H_6+C_2H_4+C_2H_2$)。

表 3 特征气体含量比值

编号	比值	编号	比值	编号	比值	编号	比值
1	CH ₄ /H ₂	10	C ₂ H ₂ /C ₂ H ₄	19	C ₂ H ₄ /(C ₁ +C ₂)	28	C ₂ H ₆ /(H ₂ +C ₁)
2	C ₂ H ₆ /H ₂	11	H ₂ /C ₂	20	C ₂ H ₂ /(C ₁ +C ₂)	29	C ₂ H ₄ /(H ₂ +C ₁)
3	C ₂ H ₄ /H ₂	12	CH ₄ /C ₂	21	H ₂ /(H ₂ +C ₁ +C ₂)	30	C ₂ H ₂ /(H ₂ +C ₁)
4	C ₂ H ₂ /H ₂	13	C ₂ H ₆ /C ₂	22	CH ₄ /(H ₂ +C ₁ +C ₂)	31	H ₂ /(H ₂ +C ₂)
5	C ₂ H ₆ /CH	14	C ₂ H ₄ /C ₂	23	C ₂ H ₄ /(H ₂ +C ₁ +C ₂)	32	CH ₄ /(H ₂ +C ₂)
6	C ₂ H ₄ /CH ₄	15	C ₂ H ₂ /C ₂	24	C ₂ H ₄ /(H ₂ +C ₁ +C ₂)	33	C ₂ H ₆ /(H ₂ +C ₂)
7	C ₂ H ₂ /CH ₄	16	H ₂ /(C ₁ +C ₂)	25	C ₂ H ₂ /(H ₂ +C ₁ +C ₂)	34	C ₂ H ₄ /(H ₂ +C ₂)
8	C ₂ H ₄ /C ₂ H ₆	17	CH ₄ /(C ₁ +C ₂)	26	H ₂ /(H ₂ +C ₁)	35	C ₂ H ₂ /(H ₂ +C ₂)
9	C ₂ H ₂ /C ₂ H ₆	18	C ₂ H ₆ /(C ₁ +C ₂)	27	CH ₄ /(H ₂ +C ₁)		

令 $D = \{x_i, y_i\}_{i=1}^{202}$ 为对 DGA 数据无编码比值处理后得到的数据集, 其中 $x_i = (x_{i1}, x_{i2}, \dots, x_{i35})$ 代表第 i 个样本, 代表第 x_{ij} 样本中第 j 个特征, 标签 $y_i \in \{\text{正常, 中低温过热, 高温过热, 低能放电, 高能放电, 局部放电}\}$ 。若使用所有 35 个特征气体比值作为输入特征可能会导致维度过高, 增加诊断模型的复杂性。此外, 过多的特征输入可能会导致诊断过程受到相关性较低的特征的干扰, 从而影响诊断的准确率。因此, 在建立诊断模型之前, 需要进行特征选择和降维处理, 以保证模型的高效性和准确性, 并避免不必要的干扰。为此, 先对数据 D 中的特征进行 Pearson 相关性分析, 去除掉存在线性关系的特征, 从而避免引入冗余信息或多重共线性。令数据矩阵 $X = (x_1^T, x_2^T, \dots, x_{202}^T) \in R^{35 \times 202}$, 其中矩阵 X 的第 i 行 (用 X_i 表示) 代表样本的第 i 个特征。那么对任意的两个特征 X_i 和 X_j , 它们之间的 Pearson 相关

系数为

$$r(X_i, X_j) = \frac{\sum_{k=1}^n (X_{ik} - \mu_{X_i})(X_{jk} - \mu_{X_j})}{nS_{X_i}S_{X_j}}, \quad (1)$$

式中: μ_{X_i} 和 S_{X_i} 分别表示 X_i 的均值和标准差, X_{ik} 代表第 k 个样本中第 i 个特征。相关系数 r 的取值范围介于 -1 到 1 之间。当 r 接近 1(-1) 时, 特征 X_i 和 X_j 越正 (负) 相关, 接近 0 时, 表示两特征之间无线性相关性。在本文中, 删去数据中 $|r| \geq 0.8$ 的特征气体比值。图 2 是特征气体比值之间的 Pearson 相关系数热力图。热力图中的色块颜色与数字相对应, 数字的绝对值越大代表相关性越强。

结果显示 $|r| \geq 0.8$, 相关系数的特征气体比值共有 20 个, 分别为表 3 中编号为 2、3、6、9、16、19、20、23~35 的特征气体比值。这些特征之间存在较强的线性相关性, 为了避免引入冗余信息, 将这些特征从数据集 D 中删去, 得到包含 15 个特征气体比值的数据集 $\bar{D}$ 。




图 2 特征气体比值之间的 Pearson 相关系数热力图

相关性分析能够排除特征之间的冗余信息，但要全面评估特征的重要性，还需要考察特征与标签之间的关系，即特征与目标变量之间的相关性。一般来说，与目标变量具有较高相关性的特征更可能对模型的预测能力有所贡献。邻域粗糙集算法是一种基于粗糙集理论的数据挖掘算法，用于特征选择和数据约简^[16]。通过计算属性重要度可对每个属性进行评估，进而将数据集中的冗余信息和不重要的属性去除，保留最有价值的属性。因此，本文采用邻域粗糙集算法对数据中的特征气体比值进一步约简。

对于一个决策系统 $DS = (U, C \cup E, V, f)$ ，其中 U 为论域， C 为条件属性，为决策属性， $E \neq \emptyset$ 为决策属性，且 $C \cap E \neq \emptyset$ ， $V = \{V_a | a \in C \cup E\}$ 是各属性值 V_a 的集合，信息函数 $f: U \times (C \cup E) \rightarrow V$ 表示样本、属性和属性值之间的映射关系。在本文中，特征气体比值构成的集合为条件属性 C ，5 种故障类型构成的集合为决策属性。令 B 为条件属性的子集，即所有特征气体比值的子集。对任意的 $B \subseteq C$ ，决策属性 E 对条件属性 B 的依赖度定义为

$$\gamma_B(E) = \frac{|Pos_B(E)|}{|U|}, \quad (2)$$

式中： $Pos_B(E)$ 代表属性子集的下近似。于是某条件属性对决策属性的重要度计算公式为

$$sig(a, B, E) = \gamma_B(E) - \gamma_{B-\{a\}}(E) \quad (3)$$

根据式 (3)，可以计算出每个特征气体比值对故障类型的贡献程度。该算法的主要步骤如下：

Step1: 数据归一化处理。

Step2: 确定等价类。通过等价关系将数据集中的对象进行分组，使得在同一组内的对象具有相同的属性，将数据集划分为不同的等价类。

Step3: 计算属性重要度。按照 (3) 式计算属性重要度，对每个属性进行评估，计算其对数据集中等价类的划分和描述能力。

Step4: 邻域构建。分别计算属性 a_i 的标准差 $Std(a_i)$ ，构建属性 a_i 的邻域半径 $\delta = Std(a_i)/\tau$ ，其中 τ 是一个提前设定的参数，用于调整邻域大小，一般取 2~4。根据属性重要度的大小，选择一组最重要的属性作为邻域，形成邻域粗糙集。

Step5: 数据约简。通过邻域粗糙集进行数据约简，将数据集中的冗余信息和不重要的属性去除，保留最有价值的属性。

为了使约简后的特征最少，本文设定参数 $\tau = 2$ 。然后对数据集 $\bar{D}$ 执行上述算法步骤，将重要度低的特征气体比值进行删减，得到与故障标签相关性高的 9

种特征气体比值，具体结果见表 4。

表 4 约简后的特征气体比值

编号	比值	编号	比值
7	C_2H_2/CH	17	$CH_4/(C_1+C_2)$
11	H_2/C_2	18	$C_2H_6/(C_1+C_2)$
13	C_2H_6/C_2	21	$H_2/(H_2+C_1+C_2)$
14	C_2H_4/C_2	2	$CH_4/(H_2+C_1+C_2)$
15	C_2H_2/C_2		

2.2 DBN 诊断模型

DBN 是一种深度学习模型，由多个受限玻尔兹曼机 (Restricted Boltzmann Machine, RBM) 堆叠而成^[17]，网络结构见图 1。每个 RBM 由两层神经元组成。可见层接收输入数据，隐藏层用于捕捉数据的抽象特征。DBN 的训练过程分为两个阶段：无监督预训练和微调^[18]。

无监督预训练：从底层开始，逐层地训练每个 RBM。每个 RBM 的隐藏层输出被用作下一个 RBM 的可见层输入，通过对参数更新可以重构输入数据的分布。在这个过程中，选择重构误差最小的神经元间的网络连接权值，从而生成 RBM1 的新隐含层。接着，将该新的隐含层作为 RBM2 的可见层进行训练。以此类推，不断通过堆叠多层 RBM 来提取数据特征，使得最终得到的特征表示尽可能地接近于原始输入数据的分布。在整个预训练过程中并未使用数据的标签，因此该过程属于无监督学习。

微调：虽然 DBN 模型在逐层预训练后可以初步建立深层特征，但由于每个 RBM 是独立地对重构误差最小化进行训练，并不能保证得到全局最优的深层特征表示。为了进一步优化整个 DBN 模型，确保得到更优的深层特征表示，通常需要在 DBN 尾部添加一个与分类器相连接的反向 BP 网络，以进行微调。微调过程使用有监督学习的方法，利用带标签的数据来调整整个 DBN 的参数，包括权重和偏置，以最小化分类器的损失函数。这样，整个 DBN 模型可以更好地适应特定的分类任务，并得到更优的特征表示。

本文利用 DBN 完成油浸式变压器故障类型的分类任务。将低能放电、高能放电、局部放电、高温过热、中低温过热和正常五种故障类型分别编码为 (1,0,0,0,0,0)、(0,1,0,0,0,0)、(0,0,1,0,0,0)、(0,0,0,1,0,0)、(0,0,0,0,1,0) 和 (0,0,0,0,0,1) 和。将 2.1 节中经过相关性分析和邻域粗糙集算法约简后的 9 种特征气体比值作为 DBN 的输入层，5 种故障类型编码作为输出层。完整的油浸式变压器故障诊断步骤如下：

Step1: 收集油浸式变压器运行过程中油中溶解气

体的分析数据, 包含各种故障气体的含量。

Step2: 对数据中故障气体进行无编码比值处理, 得到 35 种特征气体比值。

Step3: 通过相关性分析删去冗余特征, 并对数据进行归一化。采用邻域粗糙集算法进行特征选择, 删去对故障类型贡献不大的特征, 以优化特征集。

Step4: 将处理后的数据按照一定比例划分为训练集和测试集, 确保模型训练和评估的独立性。

Step5: 将特征选择后的特征气体比值和二值编码后的故障类型分别作为 DBN 的输入层和输出层。确定 DBN 网络参数, 主要有网络层数、学习率、隐含层神经元个数等。

Step6: 对 DBN 网络进行预训练和微调, 直到达到设定的训练次数或者期望误差时, 完成 DBN 故障诊断模型。输入要测试的数据, 经过 DBN 得到输出结果。

在训练 DBN 时, 需要设置和选择网络参数, 如 Step5 中的网络层数、学习率和隐含层神经元个数等, 合理地设置这些网络参数能够优化 DBN 模型, 提高

模型的性能和效果。由于没有固定的规则或准则来确定最佳参数, 需要在实践中不断地进行试错和优化, 以找到最适合的参数配置。根据图 1 中的流程图, 在处理后的数据中每一类样本按照 7 : 3 的比例划分为测试集和训练集, 其中 70% 的数据用于训练, 30% 的数据用于测试模型的性能。在模型中, RBM 的学习率被设置为 0.01。这是在预训练过程中使用的学习率, 它控制着 RBM 网络权重的更新速度, 使其逐渐收敛到更好的特征表示。而在 BP 微调算法中, 一般采用动态学习率, 初始值设置为 0.01。动态学习率是一种自适应学习率策略, 它允许在训练过程中根据模型的性能动态地调整学习率。这样做的目的是在训练的初期使用较高的学习率来加快收敛速度, 而在训练后期逐渐降低学习率以稳定模型的收敛过程。

为了确定最佳的隐藏层层数和隐藏层节点个数, 分别设置了 6 个不同配置的 DBN 网络模型: 9-5-6、9-15-6、9-5-5-6、9-15-15-6、9-5-5-5-6、9-15-15-15-6。每个模型进行 10 次实验并计算平均诊断精度, 具体结果如表 5 所示。

表 5 不同隐藏层的平均精度

隐藏层层数	1		2		3	
DBN 网络结构	9-5-6	9-15-6	9-5-5-6	9-15-15-6	9-5-5-5-6	9-15-15-15-6
平均精度	0.843	0.875	0.803	0.842	0.642	0.71

从表 5 中可以看出, 随着隐藏层神经元个数的增加, DBN 模型的诊断精度也逐渐提高, 这是因为更多的神经元能够更好地捕捉数据的特征, 增强了模型的拟合能力。但当隐藏层数增加到 2 层时, DBN 模型的诊断精度开始下降, 原因可能在于对特定的 DGA 数据集, 当隐藏层数增加到 2 层以上时, DBN 网络可能变得过于复杂, 无法很好地泛化到未见过的数据, 因此导致诊断精度下降。通过以上分析, 本文采用隐藏层为 1 层的 DBN 网络结构。

3 油浸式变压器故障诊断结果

按照 2.2 节中数据集的划分方式和参数设置, 选择网络结构为 9-10-6 的 DBN 模型, 在训练集上训练 DBN 诊断模型。完成训练后, 对测试集样本进行 6 种故障类型的分类预测。表 6 给出了各故障类型的诊断精度。图 3 和图 4 分别是一次实验中 DBN 诊断模型的训练误差曲线和测试集上的预测精度。如图 3 所示, 随着迭代次数的增加, DBN 诊断模型的训练误差逐渐减小, 在 700 次迭代之后误差小于 0.1。图 4 显示出最终训练好的 DBN 诊断模型在测试集上的诊断精度为 91.67。

表 6 一次实验中各故障类型的诊断精度

故障类型	样本总数	测试样本数	诊断正确数	精度
低能放电	35	10	8	0.8
高能放电	45	14	14	1
局部放电	27	8	6	0.75
高温过热	30	9	9	1
中低温过热	31	9	8	0.89
正常	34	10	10	1
总计	202	60	55	0.9167

为了避免实验的偶然性, 对 DGA 数据集进行 5 次随机划分, 用所构建的 DBN 诊断模型进行 5 次实验。表 7 展示了 5 次实验中各故障类型的平均诊断正确的样本数以及平均精度, 其中故障类型为中低温过热的诊断准确率为 100, 高能放电和局部放电的平均诊断准确率也超过了 90。图 5 展示了 5 次随机数据划分实验中 DBN 诊断模型平均预测结果的混淆矩阵。从混淆矩阵的颜色分布可以看出, 非主对角块上的颜色很浅, 而主对角块上的颜色很深, 这表明所构建的 DBN 诊断模型的预测性能很好。综合以上分析, 本文所构建的 DBN 诊断模型在油浸式变压器的故障预测上具有准确性和有效性。




图 3 DBN 诊断模型的训练误差曲线




图 4 DBN 诊断模型在测试集上的预测精度

表 7 5 次实验各故障类型以及总体的平均精度

故障类型	平均诊断正确数	平均精度
低能放电	7	0.70
高能放电	13	0.929
局部放电	7.2	0.90
高温过热	8.8	0.88
中低温过热	9	1.00
正常	8.8	0.88
总计	—	0.897




图 5 5 次随机数据划分实验中 DBN 诊断模型平均预测结果的混淆矩阵

4 结论

本文提出了一种基于 NRS 和 DBN 的油浸式变压

器故障类型的诊断模型。通过相关性分析与领域粗糙集算法提取了 9 种对故障类型有贡献的特征。与传统的的方法相比, 通过 NRS 算法所提取的特征对变压器故障类型贡献更为显著和具有代表性。将所得的 9 种特征气体比值作为输入变量, 构建 DBN 诊断模型, 在 DGA 测试集上取得了 89.7% 的平均精度。

参考文献:

- [1] 李黄曼, 张勇, 张瑶. 基于 ISSA 优化 SVM 的变压器故障诊断研究[J]. 电子测量与仪器学报, 2021, 35(3): 123-129.
- [2] ZHANG Y, TANG Y F, LIU Y Q, et al. Fault diagnosis of transformer using artificial intelligence: A review[J]. Frontiers in Energy Research, 2022, 10: 1006474.
- [3] WANG T L, LI Q, YANG J G, et al. Transformer fault Diagnosis method based on incomplete data and TPE-XGBoost[J]. Applied Science, 2023, 13(13): 7539.
- [4] 周晓华, 冯雨辰, 陈磊, 等. 改进秃鹰搜索算法优化 SVM 的变压器故障诊断研究[J]. 电力系统保护与控制, 2023, 51(8): 118-126.
- [5] 陈铁, 冷昊伟, 李咸善, 等. 基于油中气体分析与类重叠特征的变压器分层故障诊断模型[J]. 中国电力, 2022, 55(7): 22-32, 41.
- [6] 王艳, 李伟, 赵洪山, 等. 基于油中溶解气体分析的 DBN-SSAELM 变压器故障诊断方法[J]. 电力系统保护与控制, 2023, 51(4): 32-42.
- [7] THANGO B A. Dissolved gas analysis and application of artificial intelligence technique for fault diagnosis in power transformers: A south African case study[J]. Energies, 2022, 15(23): 9030.
- [8] HONG L C, CHEN C H, WANG Y F, et al. A novel SVM-based decision framework considering feature distribution for power transformer fault diagnosis[J]. Energy Reports, 2022, 8: 9392-9401.
- [9] TAN X M, GUO C, WANG K, et al. A novel two-stage dissolved gas analysis fault diagnosis system based semi-supervised learning[J]. High Voltage, 2022, 7(4): 676-691.
- [10] 李钧涛, 杨瑞峰, 左红亮. 统计机器学习研究[J]. 河南师范大学学报(自然科学版), 2010, 38(6): 35-40.
- [11] 王德文, 雷倩. 基于贝叶斯正则化深度信念网络的电力变压器故障诊断方法[J]. 电力自动化设备, 2018, 38(5): 129-135.
- [12] 冯百卿. 大型变压器的智能诊断与故障预测[D]. 沈阳: 沈阳工业大学, 2022.
- [13] 单亚峰, 段金凤, 付华, 等. 基于 SSA-AdaBoost-SVM 的变压器故障诊断[J]. 控制工程, 2022, 29(2): 280-286.
- [14] 肖宏磊, 留毅, 夏红军, 等. 基于 PCA 与 SSA-LightGBM 的油浸式变压器故障诊断方法[J]. 综合智能电源, 2023, 45(3): 9-16.
- [15] 许倩文. 基于油中溶解气体的变压器故障诊断[D]. 青岛: 山东科技大学, 2019.
- [16] 张清华, 胡荣德, 姚龙洋, 等. 基于属性重要度的风险决策粗糙集属性约简[J]. 控制与决策, 2016, 31(7): 1199-1205.
- [17] 代杰杰, 宋辉, 杨祎, 等. 基于深度信念网络的变压器油中溶解气体浓度预测方法[J]. 电网技术, 2017, 41(8): 2737-2742.
- [18] 李黄曼. 基于深度学习的电力变压器故障诊断研究[D]. 西安: 陕西科技大学, 2021.

Oil-Immersed Transformer Fault Diagnosis Via Combining Neighborhood Rough Sets and Deep Belief Networks

LI Shuitian¹, HUANG Xuexiao¹, TIAN Wei², JIANG jing¹, Li Juntao³

(1. Guangzhou Power Supply Bureau of Guangdong Power Grid Co., Ltd., Guangzhou 510000, China; 2. Xinxiang Aviation Industry (Group) Co., Ltd., Xinxiang 453003, China; 3. College of Mathematics and Information Science, Henan Normal University, Xinxiang 453007, China)

Abstract: In order to comprehensively explore fault information in transformer fault data and address the problem of fault type classification in oil-immersed transformers, a fault diagnosis model based on Neighborhood Rough Sets and Deep Belief Network (DBN) is proposed. Through non-coding ratio processing applied to fault gases within transformers, a total of 35 fault feature gas ratios are derived. These ratios undergo feature selection utilizing correlation analysis and the neighborhood rough set algorithm, aim at removing redundancies and irrelevant gas ratios that lack significance in identifying fault types. The resultant 9 selected gas ratios are utilized as input variables for the construction of a DBN diagnostic model intended for fault diagnosis in oil-immersed transformers. The effectiveness and accuracy of the proposed method were confirmed through experimental validation using dissolved gas analysis (DGA) data.

Key words: oil-immersed transformer; neighborhood rough sets; deep belief network; fault diagnosis
(责任编辑 吕春红)

(上接第6页)

[72] 陈鑫力. 废旧电线热解处理技术与中试试验研究[D]. 天津: 天津大学, 2012.

[73] 张伟, 陈红, 李陈莹, 等. 高压电力电缆隧道火灾早期预警判据的实验研究[J]. 火灾科学, 2021,30(4):232-241.

[74] 韩佳. 基于二氧化锡半导体气体传感器的PVC电缆火灾早期探测[D]. 合肥: 中国科学技术大学, 2020.

[75] 湛文佳, 易建新. PVC电缆火灾早期特征气体的组成分析和传感器探测[J]. 火灾科学, 2019,28(2):94-100.

Research Progress of Cable Fire Cause and Detection Technology in Utility Tunnel

WANG Weidong^{1,2}, WAN Liujie^{1,2}, ZHANG Jing^{1,2}, HUANG Zhijie¹

(1. School of Cable Engineering, Henan Institute of Technology, Xinxiang 453003, China; 2. Henan Key Laboratory of Wire and Cable Structures and Materials, Xinxiang 453003, China)

Abstract: The ignition mechanism of cable fire in utility tunnel, the common cable fire detection technology and the research progress of cable pyrolytic gas are reviewed. In the aspect of fire mechanism, electric arc and overheating of cable core are the essential causes of cable fire in utility tunnel. At present, most of the research focuses on the combustion of cable materials caused by external heat source, while the research on the combustion caused by electric arc or cable internal overheating is scarce. In the aspect of cable fire detection technology in utility tunnel, the existing fire detection methods are summarized. According to the fire development process, the fire warning method based on gas detection technology can be used for early warning of cable fire. This paper has a certain reference significance for the operation and maintenance of the utility tunnel.

Key words: utility tunnel; cable fire; gas detection

(责任编辑 吕春红)