

DOI:10.13296/j.1001-1609.hva.2020.09.006

应用于油中溶解气体分析的深度信念网络与典型神经网络对比研究

任双赞¹, 徐尧宇², 李元², 王怡静², 张冠军²

(1. 国网陕西省电力公司电力科学研究院, 西安 710100; 2. 西安交通大学电力设备电气绝缘国家重点实验室, 西安 710049)

摘要: 油中溶解气体分析是诊断油浸式变压器绝缘系统故障最有效的方法之一, 对实现变压器故障精确诊断具有重要意义。文中基于深度信念网络(deep belief network, DBN)、BP神经网络(back propagation neural network, BPNN)和RBF神经网络(radial basis function neural network, RBFNN)构建了不同结构的变压器油中溶解气体分析模型, 实现了基于油中溶解气体分析的变压器故障诊断。文中对比分析了不同建模方法、不同训练样本数和不同模型参数对变压器故障诊断精确度的影响。结果表明, 文中构建的基于DBN的油中溶解气体分析模型在1 000组训练样本、5层DBN模型结构和第2层20个节点时, 达到最高的识别精度84.87%。

关键词: 油中溶解气体分析; 故障诊断; 智能方法; 神经网络

Comparison Studies of Deep Belief Network and Typical Neural Network Applied to Analysis of Dissolved Gas in Oil

REN Shuangzan¹, XU Yaoyu², LI Yuan², WANG Yijing², ZHANG Guanjun²

(1. State Grid Shannxi Electric Power Co., Ltd., Electric Power Research Institute, Xi'an 710100, China; 2. State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Dissolved gas analysis in transformer oil is one of the most effective methods to diagnose the fault of oil-immersed power transformer insulation system, which is of great significance to realize the accurate diagnosis of transformer fault. Based on the deep belief network (DBN) and the typical neural network model, BP neural network (BPNN) and RBF neural network (RBFNN), this paper builds different structures of the DGA models to realize the transformer fault diagnosis. In addition, influences of different training data, modeling methods and parameters on the diagnosis accuracy of transformers is further analyzed. The proposed dissolved gas in oil model based on DBN achieves the highest recognition accuracy of 84.87% under 1 000-set training data, 5-layer in DBN model structure and 20 nodes in 2nd-layer.

Key words: dissolved gas in oil analysis; fault diagnosis; intelligent method; neural network

0 引言

油浸式电力变压器的油中溶解气体分析(dissolved gas analysis, DGA)是诊断设备绝缘系统故障最有效的方法之一, 具有在线监测、应用灵活、响应速度快等优点^[1-2]。DGA主要检测变压器油中溶解的特征气体含量, 包括变压器油裂解产生的氢气H₂、甲烷CH₄、乙炔C₂H₂、乙烯C₂H₄和乙烷C₂H₆以及

绝缘纸(板)纤维素裂解产生的一氧化碳CO和二氧化碳CO₂^[3]。近年来, CIGRE^[4]、IEC 60599:2015^[5]、DL/T 722—2014^[6]等也都提出了油中溶解气体分析的诊断标准, 然而, 这些分析和判断依据大多是建立在现场经验基础上, 实际应用时往往会出现较大的诊断误差。此外, 由于变压器绝缘结构复杂, 油中溶解气体的产生和发展较为复杂并且有很大的不确定性^[7], 因此如何更有效的采用油中溶解气体分析精确诊断或预测变压器故障一直是当前研究的热

收稿日期:2020-05-21; 修回日期:2020-06-30

基金项目:国网陕西省电力公司电力科学研究院科技项目(SGTYHT/18-JS-209);国家自然科学基金(51607139)。

Project Supported by Supported by Science and Technology Project of State Grid Shannxi Electric Power Research Institute (SGTYHT/18-JS-209), National Natural Science Foundation of China(5160713).

点和难题^[8]。

近些年来,随着人工智能技术(artificial intelligence, AI)的改进和发展,研究人员引入智能学习方法实现变压器油中溶解气体分析,一定程度上提高了变压器故障诊断效率和精度^[9-11]。苗长新^[12]等人通过构成混沌粒子群算法优化神经网络参数,克服了BP神经网络训练收敛速度慢的缺点,提高了变压器DGA的诊断效率。袁海满^[13]等人构建了一种基于粒子群优化极限学习机的变压器故障诊断方法,以特征气体作为输入参量,提高变压器故障诊断的精度。

此外,随着大数据分析技术的飞速发展,在线监测设备的普及和增多,油中溶解气体分析的样本数据也不断增加,传统智能方法无法从大量的样本数据中高效的提取数据特征并实现变压器的故障诊断。因此,研究人员开始结合深度学习方法实现变压器油中溶解气体分析建模,提高模型的训练效率和诊断精度^[14-15]。代杰杰^[16-17]等人提出采用深度信念网络实现变压器油中溶解气体分析于气体含量预测,并通过改变特征气体输入结构,如特征气体含量作为输入参量、气体比值作为输入参量,对比分析了DBN模型的故障诊断精度。曹渝昆^[18]等人提出了一种基于深度神经网络的变压器故障分类方法,利用无编码的DGA数据,对比分析了不同激活函数和网络训练算法的性能,提高了模型的收敛速度和鲁棒性,促进了变压器故障诊断效率的提升。

当前研究工作已证明智能学习算法能够用于变压器油中溶解气体分析建模。但是,大部分研究成果仅采用单个智能学习方法实现油中溶解气体分析,较少对比分析不同模型结构、不同建模方法及不同训练样本下模型的识别精度。因此,文中基于深度信念网络(deep belief network, DBN)和传统神经网络模型(BP神经网络, back propagation neural network, BPNN 和 RBF神经网络, radial basis function neural network, RBFNN)构建了变压器油中溶解气体分析模型,实现变压器故障诊断。此外,文中还对比分析了不同建模方法、不同训练样本数和不同模型建模参数对变压器故障诊断精确度的影响,提出了变压器油中溶解气体分析的最优建模策略,为实现变压器故障的精确诊断提供了理论基础。

1 基于DBN的油中溶解气体分析建模

1.1 DBN的原理及结构

深度信念网络(DBN)由多层受限玻尔兹曼机(restricted boltzmann machine, RBM)组成^[19]。RBM包

含一层观察变量(可见层)和潜变量(隐藏层)的概率图模型,见图1。图1中: nv 和 nh 分别表示可见层和隐藏层中神经元数目; v_i 和 a_i 分别表示可见层中第 i 个神经元状态向量和偏置向量; h_j 和 b_j 分别表示隐藏层中第 j 个神经元状态向量和偏置向量; $W=(w_{ij}) \in R^{nh \times nv}$ 表示隐藏层和可见层的权值矩阵, w_{ij} 表示隐藏层中第 j 个神经元与可见层中第 i 个神经元之间连接权重。




图1 RBM结构图

Fig. 1 Structure of RBM

RBM是一种基于能量函数的模型。对于一组状态 (v, h) , RBM的能量函数 E_θ 描述了状态 (v, h) 的系统能量值,见式(1)。 E_θ 越小系统状态越稳定, E_θ 可视为一种代价函数。

$$E_\theta(v, h) = \sum_{i=1}^{nv} a_i v_i + \sum_{j=1}^{nh} b_j h_j + \sum_{i=1}^{nv} \sum_{j=1}^{nh} h_j w_{ji} v_i \quad (1)$$

此外,状态 (v, h) 的联合概率分布为

$$P_\theta(v, h) = \frac{1}{Z_\theta} e^{-E_\theta(v, h)} \quad (2)$$

式(2)中, Z_θ 为归一化因子,也称为分配函数,见式(3)。

$$Z_\theta = \sum_{v, h} e^{-E_\theta(v, h)} \quad (3)$$

参数 θ 的似然函数见式(4)-(5):

$$P_\theta(v) = \sum_h P_\theta(v, h) = \frac{1}{Z_\theta} \sum_h e^{-E_\theta(v, h)} \quad (4)$$

$$P_\theta(h) = \sum_v P_\theta(v, h) = \frac{1}{Z_\theta} \sum_v e^{-E_\theta(v, h)} \quad (5)$$

由此,给定可见层(图1-v层)上所有神经元的状态时,隐藏层(图1-h层)上某个神经单元被激活(取值为1)的概率,即 $P(h_k=1|v)$,可由式(6)计算,(推导过程略,为了表示方便省略参数 θ)。

$$P(h_k=1|v) = \text{sigmoid}(b_k + \sum_{i=1}^{nv} w_{ki} v_i) \quad (6)$$

式(6)中, $\text{sigmoid}()$ 表示sigmoid激励函数。

给定训练样本后,训练RBM要求调整参数 θ 拟合训练样本(例如油色谱数据和对应的故障状态),使得该参数下由相应RBM表示的概率分布与训练样本数据相拟合。设训练样本集合为 $S=\{v^1, v^2, v^3, \dots, v^s\}$,其中每个训练样本 $v \in S$ 中包含 nv 个输入变量和对应的 nh 个输出变量。训练RBM的目标函数为

$$\max_{\theta} L_{\theta,s} = \prod_{i=1}^{ns} P(v^i) \quad (7)$$

一个完整的DBN模型由若干个RBM构成,见图2。图2中第1个RBM由初始输入层 V_1 和隐藏层 H_1 组成,第2RBM由层 V_2 和 H_2 组成,即第1个RBM的输出层 H_1 是第2个RBM的输入层 V_2 ,依此类推,逐层提取和训练原始数据。




图2 4隐层的DBN结构图

Fig. 2 DBN of 4-layer

1.2 基于DBN的油中溶解气体分析模型

基于DGA的变压器故障诊断属于多分类问题,文中采用油中 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 、CO和 CO_2 的含量作为输入数据,故障类型为输出数据,构建基于DBN的油中溶解气体分析模型见图3。图3中,顶部分类层采用SoftMax分类器。




图3 基于DBN分类器的油中溶解气体分析模型

Fig. 3 DGA model based on DBN classifier

文中采用梯度下降法将模型输出与原始数据间的误差反向传播至每一层RBM,实现模型参数最优化。基于DBN分类器的油中溶解气体分析模型的性能由式(8)计算。

$$R = \frac{\sum N_+}{\sum N} \times 100\% \quad (8)$$

式(8)中: R 也称为DBN分类器的识别率; N_+ 是测

试样本中正确分类的样本数; N 是测试数据样本总数。

2 基于BP和RBF神经网络的油中溶解气体分析模型

2.1 基于BP神经网络的油中溶解气体分析模型

BP神经网络常采用3层结构^[20],分别是输入层(I),隐含层(H),输出层(O),见图4。图4中: x 为输入数据; y 为输出数据; g 为节点间权值。每个节点值由上层节点值和上一层节点权值决定,具体计算方法见式(9)。




图4 BP神经网络

Fig. 4 BP neural network

$$y_j = f(x) \quad (9)$$

式(9)中: f 为激活函数; x 为上层节点值。设节点和节点之间的权值为 g_{ij} ,为了更好的与前述基于DBN的油中溶解气体分析模型对比分析,文中选取sigmoid激活函数

$$y_j = f(x) = \sum_{i=1}^{nx} g_{ij} \frac{1}{1 + e^{-x_i}} \quad (10)$$

式(10)中: nx 为上层节点个数; x_i 为第 i 个上层节点。BP神经网络正向传递的过程按照式(9)-(10)计算。设样本的真实值为 d_j ,BP神经网络的反向传播过程的优化目标由式(11)给出。

$$\min_{\theta} E_{\theta} = \frac{1}{2} \sum_{j=0}^{n-1} (d_j - y_j)^2 \quad (11)$$

利用BP神经网络构建油中溶解气体分析模型,七种气体含量为输入数据,变压器故障模式为输出数据,见图5。输入和输出层节点数是确定的,通过修改不同数量的隐藏节点寻找最优模型结构。




图5 基于BP神经网络的油中溶解气体分析模型

Fig. 5 DGA model based on BP neural network

2.2 基于RBF神经网络的油中溶解气体分析模型

RBF神经网络与BP神经网络相比,仅有前向传播过程,但RBF神经网络能够以任意精度逼近任意连续函数,适合解决分类问题^[21]。基于RBF神经网络的油中溶解气体分析模型见图6。RBF神经网络与BP神经网络的主要区别之一为隐单元的激励函数是RBF径向基函数,RBF神经网络的输出可由式(12)表示。




图6 基于RBF神经网络的油中溶解气体分析模型

Fig. 6 DGA model based on RBF neural network

$$Y_j = \sum_{k=1}^K r_{kj} \exp\left(-\frac{1}{2\sigma^2} \|x_p - c_k\|^2\right) \quad (12)$$

式(12)中: Y_j 为第 j 个输出向量; x_p 为第 p 个输入向量; r_{kj} 为隐含层与输出层的权值; σ 为径向基函数的标准差; c_k 为第 k 个隐层节点对应的径向基函数对称轴,径向基函数定义为

$$f(x) = \exp\left(-\frac{1}{2\sigma^2} \|x - c\|^2\right) \quad (13)$$

RBF神经网络输入到输出是非线性映射,而输出与隐含层是线性映射,因此,网络的权值可由线性方程组求得,有助于加快训练速度。

3 实例验证及对比分析

文中收集整理IEC 60599:2015、IEC TC 10数据^[22]和国内某电力公司中1 000余组DGA数据,通过随机采样法分别利用其中200、500、1 000例案例作为训练集建模,其中50例样本作为测试集,采用交叉验证法测试不同神经网络和不同网络结构对诊断精度的影响。此外,考虑到不平衡样本对模型诊断精度的影响^[23-25],文中所用的训练集和测试集中变压器各故障类型对应的样本占比保持相等。

文中采用线性函数归一化方法,对上述7种气体含量做归一化处理,其表达式为

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (14)$$

式(14)中: X' 为归一化后数据; X 为原始数据中对应气体含量; $X_{\max}$ 、 $X_{\min}$ 分别为样本中对应气体含量的最大值和最小值。变压器故障类型编码采用二进制编码,见表1。

表1 变压器故障类型编码

Table 1 Codes of fault types of power transformer

故障类型	编码
无故障	000001
局部放电	000010
低能放电	000100
高能放电	001000
低温过热(< 700 ℃)	010000
高温过热(≥ 700 ℃)	100000

3.1 网络结构对油中溶解气体分析精度的影响

对于DBN模型来说,影响其识别精度的主要因素在于训练样本数、网络层数和隐层节点数。此外,经过反复测试发现,DBN模型第2隐层的个数对识别精度影响较大,测试结果见图7-9。




图7 采用200训练样本的DBN模型识别精度

Fig. 7 Recognition rate of DBN under 200-set




图8 采用500训练样本的DBN模型识别精度

Fig. 8 Recognition rate of DBN under 500-set training data




图9 采用1 000训练样本的DBN模型识别精度

Fig. 9 Recognition rate of DBN under 1 000-set

training data

从图7-9可以明显看出,在不同的网络结构或不同训练样本下,DBN模型具有不同的泛化能力。图7中200组训练样本时,4层DBN模型的识别率约为63.67%;图8中500组训练样本时,4层DBN模型的识别率约为73.84%;图9中1000组训练样本时,5层DBN模型的识别率约为84.87%。

结果表明,DBN模型的识别率随着训练数据和模型层数的增加而有所提高。但是,由于DBN层数的增加会导致模型结构误差累积,更多隐层的DBN模型并不一定会有更高的识别率(图7-9中7层DBN结构的识别率低于其他结构识别率)。此外,DBN模型在训练数据较少时泛化能力并不理想(200训练数据的最高识别率仅有63.67%),因此,为了获得较高的泛化能力,需要尽可能提高训练样本数并寻找最优DBN分类器结构。

对于基于BP神经网络和RBF神经网络的油中溶解气体分析模型来说,影响其诊断性能的主要因素为训练样本数和隐层节点数。分别采用200、500和1000组训练数据进行验证,BP神经网络和RBF神经网络的测试结果分别见图10、11。由图10、11中可以看出,BP神经网络模型的最高识别精度为500组训练样本、隐层节点数4个时的80.24%,RBF神经网络模型的最高识别精度为500组训练样本、隐层节点数5个时的77.86%。BP神经网络模型和RBF神经网络模型的识别精度在1000组训练样本时有所下降,分别为70.15%和60.14%,其主要原因可能为,随着训练样本的增多,数据样本特征分布的离散型越大,两模型会产生不同程度的误差。更具体的说,RBF神经网络模型的隐含层节点的输入离径向基函数中心越远,则输出层节点的激活程度就越低,因此RBF模型在高维训练样本下易产生“局部映射”的问题,导致识别精度下降。此外,尽管BP神经网络模型能够实现非线性映射的全局逼近,但是BP神经网络在学习新样本时有“遗忘”旧样本特征的趋势,因此当训练样本从500组增加至1000组时,BP神经网络模型的识别精度下降。




图10 BP神经网络模型识别精度

Fig. 10 Recognition rate of BP neural network




图11 RBF神经网络模型识别精度

Fig. 11 Recognition rate of RBF neural network

3.2 DBN模型与BP&RBF模型性能的对比分析

提取上述分析中不同训练样本下各网络模型的最高识别精度,对比结果见图12。图12中可以明显看出,DBN模型的识别精度随着训练样本的增多而上升(1000组训练样本时识别精度为84.87%),而BP神经网络模型和RBF神经网络模型的识别精度在500组训练样本时最大,分别为80.24%和77.86%。表明DBN模型在训练样本较多时(1000组训练样本)其识别性能高于传统的BP神经网络模型和RBF神经网络模型。但是,在小样本数据中,如200组训和500组训练样本时,DBN模型的识别精度低于传统BP神经网络模型和RBF神经网络模型。此外,由于BP神经网络模型具有全局泛化能力,因此其识别性能高于RBF神经网络模型。总的来说,为了提高油中溶解气体分析的识别精度和效率,高样本数据时宜采用DBN模型,小样本数据时宜采用BP神经网络模型。




图12 200、500和1000组训练样本下3种模型的识别精度

Fig. 12 Recognition rate of the three models under
200-set, 500-set and 1000-set training data

4 结论

文中采用深度信念网络DBN、BP神经网络和RBF神经网络模型实现了基于油中溶解气体分析的变压器故障诊断建模,并通过采用变压器案例样本数据进行测试和验证,对比分析了不同模型的诊断识别性能。文中所得结论如下:

1)基于DBN的油中溶解气体分析模型的识别

性能主要取决于训练样本数、模型层数和第2层节点数,文中构建的DBN分类器模型在1 000组训练样本、5层DBN模型结构和第2层20个节点时,达到最高的识别精度84.87%。因此,采用DBN模型建模分析变压器油中溶解气体时应根据样本数采用合适的模型结构,以达到最好的分类效果;

2)3层的BP神经网络模型和RBF神经网络模型在500组训练样本下具有较高的性能,识别精度分别为80.24%和77.86%,且200组训练样本下BP神经网络模型的性能高于RBF神经网络模型(识别精度分别为71.75%和69.28%)。具有全局优化能力的BP神经网络比RBF神经网络的识别精度更高;

3)对比3种模型的识别性能发现,当训练样本较多时,1 000组训练样本时采用DBN模型能够达到较高的识别精度。训练样本较少时,小于500组训练样本,油中溶解气体分析建模宜采用BP神经网络。

文中研究结果可为变压器油中溶解气体分析建模的优选提供理论参考,为实现变压器故障的精确诊断提供了新的思路。

参考文献:

- [1] KAN H, MIYAMOTO T. Proposals for an improvement in transformer diagnosis using dissolved gas analysis (DGA) [J]. Electrical Insulation Magazine IEEE, 1995, 11(6):15-21.
- [2] 郑一鸣,何文林,孙翔,等.基于油色谱超立方映射的电力变压器缺陷援例诊断模型[J]. 电力工程技术, 2017, 36(4): 48-53.
ZHENG Yiming, HE Wenlin, SUN Xiang, et al. Case based power transformer defects diagnose model using hypercube mapping of oil chromatography[J]. Electric Power Engineering Technology, 2017, 36(4): 48-53.
- [3] 汪可,李金忠,张书琦,等.变压器故障诊断用油中溶解气体新特征参量[J]. 中国电机工程学报, 2016, 36(23): 269-277.
WANG Ke, LI Jinzhong, ZHANG Shuqi, et al. New features derived from dissolved gas analysis for fault diagnosis of power transformers[J]. proceedings of the CSEE, 2016, 36(23): 269-277.
- [4] MOLLMANN A, PAHLAVANPOUR B. New guideline for interpretation of dissolved gas analysis in oil filled transformers[J]. Electra, 1999(186): 31-51.
- [5] Mineral oil-filled electrical equipment in service-guidance on the interpretation of dissolved and free gases analysis: IEC 60599:2015[S]. 2015.
- [6] 变压器油中溶解气体分析和判断导则:DL/T 722—2014[S].2014.
Guide to the analysis and the diagnosis of gases dissolved in transformer oil:DL/T 722—2014[S].2014.
- [7] 朱德恒,严璋,谈克雄. 电气设备状态监测与故障诊断技术[M]. 北京: 中国电力出版社, 2009.
- ZHU Deheng, YAN Zhang, TAN Kexiong. Condition monitoring and fault diagnosis of electrical equipment[M]. Beijing: China Electric Power Press, 2009.
- [8] 刘文泽,张俊,邓焱,等.基于深度置信网络和多维信息融合的变压器故障诊断方法[J]. 电力工程技术, 2019, 38(6): 16-23.
LIU Wenze, ZHANG Jun, DENG Yan, et al. Transformer fault diagnosis method based on deep learning and multidimensional information fusion[J]. Electric Power Engineering Technology, 2019, 38(6): 16-23.
- [9] 尹金良,朱永利,俞国勤,等.基于高斯过程分类器的变压器故障诊断[J]. 电工技术学报, 2013, 28(1): 158-164.
YIN Jinliang, ZHU Yongli, YU Guoqin, et al. Fault diagnosis of transformers based on Gaussian process classifier[J]. Transactions of China Electrotechnical Society, 2013, 28(1): 158-164.
- [10] 黄新波,王享,田毅,等.基于PSO-ELM融合动态加权AdaBoost的变压器故障诊断方法[J]. 高压电器, 2020, 56(5): 39-46.
HUANG Xinbo, WANG Xiang, TIAN Yi, et al. Transformer fault diagnosis algorithm based on PSO-ELM fusion dynamically weighted AdaBoost[J]. High Voltage Apparatus, 2020, 56(5): 39-46.
- [11] 何尧,梁宏池,连鸿松,等.基于滑动窗口和多元高斯分布的变压器油色谱异常值检测[J]. 高压电器, 2020, 56(1): 203-209.
HE Yao, LIANG Hongchi, LIAN Hongsong, et al. Outlier detection of power transformer oil chromatographic data based on algorithm sliding windows and multivariate gaussian distribution[J]. High Voltage Apparatus, 2020, 56(1): 203-209.
- [12] 苗长新,申坤,钟世华.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. Power transformer fault diagnosis based on improved neutral network and DGA[J]. High Voltage Apparatus, 2016, 52(11):163-168.
- [13] 袁海满,吴广宁,高波.基于DGA的粒子群极限学习机电力变压器故障诊断[J]. 高压电器, 2016, 52(11): 176-180.
YUAN Haiman, WU Guangning, GAO Bo. Fault diagnosis of power transformer using particle swarm optimization and extreme learning machine based on DGA[J]. High Voltage Apparatus, 2016, 52(11):176-180.
- [14] 江秀臣,盛戈皞. 电力设备状态大数据分析的研究和应用[J]. 高电压技术, 2018, 44(4): 1041-1050.
JIANG Xiuchen, SHENG Gehao. Research and application of big data analysis of power equipment condition[J]. High Voltage Engineering, 2018, 44(4): 1041-1050.
- [15] 李刚,于长海,刘云鹏,等. 电力变压器故障预测与健康管理的挑战与展望[J]. 电力系统自动化, 2017, 41(23): 162-173.
LI Gang, YU Changhai, LIU Yunpeng, et al. Challenges and prospects of fault prognostic and health management for power transformer[J]. Automation of Electric Power Systems, 2017, 41(23):162-173.

- [16] 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):359-364.
DAI Jiejie, SONG Hui, YANG Yi, et al. Concentration prediction of dissolved gases in transformer oil based on deep belief networks[J]. Power System Technology, 2017, 41(8):359-364.
- [17] DAI J, SONG H, SHENG G, et al. Dissolved gas analysis of insulating oil for power transformer fault diagnosis with deep belief network[J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2017, 24(5):2828-2835.
- [18] 曹渝昆, 何健伟. 基于RA-DNN的电力变压器故障分类方法[J]. 自动化装置与设备, 2019(2):98-107.
CAO Yukun, HE Jianwei. Power transformer fault classification method based on RA-DNN[J]. Automation Devices & Equipments, 2019(2):98-107.
- [19] HINTON G E. A practical guide to training restricted boltzmann machines[J]. Momentum, 2012, 9(1):599-619.
- [20] HECHT-NIELSEN R. Theory of the backpropagation neural network[C]//International 1989 Joint Conference on Neural Networks. Washington, DC, USA: IEEE, 1989: 65-93.
- [21] VT S E, SHIN Y C. Radial basis function neural network for approximation and estimation of nonlinear stochastic dynamic systems[J]. IEEE Transactions on Neural Networks, 1994, 5(4): 594-603.
- [22] DUVAL M, DEPABLA A. Interpretation of gas-in-oil analysis using new IEC publication 60599 and IEC TC 10 databases[J]. Electrical Insulation Magazine IEEE, 2002, 17(2):31-41.
- [23] 崔宇, 侯慧娟, 苏磊, 等. 考虑不平衡案例样本的电力变压器故障诊断方法[J]. 高电压技术, 2020, 46(1): 33-41.
CUI Yu, HOU Huijuan, SU Lei, et al. Fault diagnosis method for power transformer considering imbalanced class distribution[J]. High Voltage Engineering, 2020, 46(1): 33-41.
- [24] 王有元, 周立玮, 梁玄鸿, 等. 基于关联规则分析的电力变压器故障马尔科夫预测模型[J]. 高电压技术, 2018, 44(4): 1051-1058.
WANG Youyuan, ZHOU Liwei, LIANG Xuanhong, et al. Markov forecasting model of power transformer fault based on association rules analysis[J]. High Voltage Engineering, 2018, 44(4): 1051-1058.
- [25] 邓冉, 朱永利, 刘雪纯, 等. 基于L2-VAE的局部放电未知信号识别方法[J]. 广东电力, 2019, 32(9):69-77.
DENG Ran, ZHU Yongli, LIU Xuechun, et al. Pattern recognition of unknown signals for partial discharge based on L2-VAE[J]. Guangdong Electric Power, 2019, 32(9):69-77.

任双赞(1981—), 男, 高级工程师, 主要研究变压器在线监测及状态诊断技术(E-mail: 154889311@qq.com)。

徐尧宇(1993—), 男, 博士研究生, 主要研究变压器绝缘状态评估。

李元(1984—), 男, 副教授, 主要研究变压器故障预警与健康管理。

王怡静(1995—), 女, 硕士研究生, 主要研究智能学习算法与电力设备故障诊断技术。

张冠军(1970—), 男, 教授, 主要研究电力设备的故障诊断和状态评估技术。

(上接第38页)

- system[J]. Automation & Instrumentation, 2020(1):44-46.
- [20] 王永祥, 何海涛, 邓木玲, 等. 基于光纤光栅压力传感器的轨道占用检测方法研究[J]. 广州航海学院学报, 2019, 27(4):55-58.
WANG Yongxiang, HE Haitao, DENG Muling, et al. Research on track occupancy detection method based on fiber bragg grating pressure sensor[J]. Journal of Guangzhou Maritime University, 2019, 27(4):55-58.
- [21] 刘世奎. 结构力学[M]. 北京: 清华大学出版社, 2008.
LIU Shikui. Structural mechanics[M]. Beijing: Tsinghua University Press, 2008.
- [22] 江磊, 沈烈, 郑强. 聚合物的热膨胀[J]. 功能材料, 2004(2):142-144.
JIANG Lei, SHEN Lie, ZHENG Qiang. The thermal expansion of polymer[J]. Journal of Functional Materials, 2004(2): 142-144.
- [23] 苏波. 流固耦合方程的建立及耦合数据传递[C]//庆祝刘锡良教授八十华诞暨第八届全国现代结构工程学术研讨会论文集. 天津大学: 全国现代结构工程学术研讨会学术委员会, 2008:704-709.
SU bo. Establishment of fluid-structure coupling equation and coupling data transfer[C]//Proceedings of the 8th National Symposium on Modern Structural Engineering. Tianjin University: Academic Committee of National Symposium on Modern Structural Engineering, 2008:704-709.
- [24] 朱文, 赵晓凤. 油液金属颗粒对500 kV变压器出线装置电场的影响[J]. 广东电力, 2018, 31(7):112-118.
ZHU Wen, ZHAO Xiaofeng. Influence of oil metallic particles on electric field of 500 kV transformer outlet device[J]. Guangdong Electric Power, 2018, 31(7): 112-118.
- [25] 董锦涛, 李德波, 周杰联, 等. 220 kV变压器短路状态绕组受力数值模拟[J]. 广东电力, 2018, 31(7):124-129.
DONG Chuntao, LI Debo, ZHOU Jieliang, et al. Numerical simulation on winding force of 220 kV transformer in short-circuit condition[J]. Guangdong Electric Power, 2018, 31(7):124-129.
- [26] 孙安, 乔学光, 贾振安, 等. 聚合物封装光纤布拉格光栅传感器温度压力特性研究[J]. 中国激光, 2005(2): 224-227.
SUN An, QIAO Xueguang, JIA Zhen'an, et al. Temperature and pressure responsive characteristics of polymer packaged fiber bragg grating with large dynamic range[J]. Chinese Journal of Lasers. 2005(2):224-227.
- 冀茂(1995—), 男, 博士研究生, 主要从事电气设备绝缘在线监测与故障诊断(E-mail: m.ji@ncepu.edu.cn)。