

DOI:10.12158/j.2096-3203.2019.06.003

# 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

刘文泽, 张俊, 邓焱

(华南理工大学电力学院, 广东 广州 510640)

**摘要:**为了综合多维度信息,快速准确判断变压器缺陷,同时解决多维度信息融合权重难以确定的问题,文中基于深度学习理论,采用稀疏受限玻尔兹曼机搭建了用于故障诊断的深度学习故障分类模型,结合大型变压器的多维度监测数据,提出了一种基于深度置信网络和多维度信息融合的变压器故障诊断方法。该方法能够利用变压器海量的无标签多维监测数据作为学习样本,只需对少量带标签数据进行辅助优化,根据变压器实时在线多维监测数据,被训练后的模型能够对变压器本体状态做出准确的故障诊断。对某市 220 kV 主变进行诊断测试,结果表明,文中提出方法的故障诊断准确率较现有方法高约 4%,验证了该方法的可行性和有效性。

**关键词:**电力变压器;多维度信息融合;故障诊断;深度置信网络;稀疏受限玻尔兹曼机

**中图分类号:**TM741

**文献标志码:**A

**文章编号:**2096-3203(2019)06-0016-08

## 0 引言

输变电系统中,电网的稳定可靠运行离不开变压器的安全稳定。变压器如果出现异常或者故障,往往导致严重后果。变压器发生故障的原因众多<sup>[1-2]</sup>,其运行中产生的海量监测数据对识别故障不可或缺,如何合理高效地利用这些数据是变压器故障诊断中的关键内容之一。

电力变压器的故障诊断是通过收集变压器各种故障特征信息,在故障潜伏期,对其可能出现的故障进行预测,并根据故障类型、位置、原因提前制定状态检修方案。目前,一般采用 2 种不同类型的故障诊断方法进行故障识别<sup>[3]</sup>。其一为传统方法,包括预防性电力试验<sup>[4]</sup>、油中溶解气体分析<sup>[5-6]</sup>、冲击电压波形试验<sup>[7]</sup>等方法;其二为智能方法,包括人工神经网络<sup>[8-9]</sup>、支持向量机(support vector machine, SVM)<sup>[10-11]</sup>、专家诊断系统<sup>[12-14]</sup>等方法,能够模拟智能思维,更准确高效地处理复杂问题。这些诊断方法均存在一定缺陷,如预防性电气试验法能够较全面检测变压器的潜伏故障,但需要停电操作,费时费力,不符合目前电力行业设备资源的精益化管理要求;冲击电压波形试验法直观方便,但诊断准确率较低;人工神经网络法虽然具有很强的学习能力,但必须采用大量的、有标签的数据进行学习,同时存在着学习效率低、收敛速度慢、容易发生局部收敛的问题;深度学习法是 2006 年被提出的一种深层次机器学习方法<sup>[15-16]</sup>,是机器学习领域新热点<sup>[17]</sup>。目前深度学习已经在图像识别、语音识别

和文字识别等领域取得了重大突破,但在变压器故障诊断方面的应用仍处于起步阶段。文献[18—19]将深度学习引入变压器诊断中,取得了良好效果,但其应用仅限于油色谱分析,并不能全面地识别、诊断变压器各类故障。

文中基于深度学习神经网络,首先采用稀疏受限玻尔兹曼机(restricted boltzmann machine, RBM)堆叠形成底层网络,再在顶层加入分类器模型,形成基于稀疏深度置信网络(deep believe network, DBN)的深度学习模型,结合多维信息融合理论,选取变压器的多维度在线监测数据作为模型的输入量,构建基于深度置信网络和多维度信息融合的变压器故障诊断模型。通过机理分析和典型数据集对比测试表明,文中所提方法相比现有算法具有更强的特征提取能力和更高的诊断正确率。最后通过工程实例验证了文中设计的故障诊断方法的优势和有效性。

## 1 深度学习神经网络简介

深度学习是以对人类大脑神经网络的认识理解为基础建立的模拟人类大脑神经连接结构的深度学习神经网络,含有多个隐含层的神经网络结构使其具有较强地从少量样本中提取数据本质特征的能力。深度学习是一种半监督的学习方式,可以从大量的无标签样本数据中完成预训练过程,优化模型参数,提高模型分类的准确率。

深度学习神经网络可以被理解为一个含有多个隐含层的神经网络,相比于传统的 3 层人工神经网络,能够从数据中提取更具有判别性能的高维特征及其内在规律,从而更加容易分类,分类准确度

收稿日期:2019-05-11;修回日期:2019-06-21

基金项目:国家自然科学基金资助项目(51577073)

更高。不同应用场景下建立的深度学习模型不同,目前深度学习的主要方法分为基于卷积神经网络、基于自动编码器和基于 RBM 3 大类。

相比于其他模型,基于 RBM 构建的 DBN 模型具有多重优势,在相对简单的模型下,能够更好地提取故障特征,因而在进行高维度数据处理分析时有较快的速度和较高的正确率。依据变压器故障诊断的多维特点及故障分类要求,文中选取基于 RBM 堆叠构建的 DBN 模型来进行变压器故障诊断。

### 1.1 RBM

RBM 是一种由能量函数定义的、具有对称结构的神经网络<sup>[20]</sup>。由可见层和隐含层 2 层组成,该网络中的神经元只有 2 种状态:未激活状态和激活状态,分别用 0,1 表示。玻尔兹曼机作为无监督训练模型,具有强大的学习能力,可以从原始数据中学习到高维特征,其模型层间连接如图 1 所示。

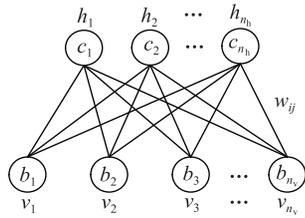


图 1 RBM 模型层间结构

Fig.1 Layer-structure of RBM model

图 1 中,  $n_h$  和  $n_v$  分别为隐含层和可见层中所包含的神经元个数;  $w_{ij}$  为连接可见层第  $i$  个神经元与隐含层第  $j$  个神经元之间的权重;  $c = (c_1, c_2, \dots, c_{n_h})$ , 为隐含层神经元的偏置。确定 RBM 后,可将能量函数<sup>[19]</sup>定义如下:

$$E(v, h | \theta) = - \sum_{i=1}^{n_v} \sum_{j=1}^{n_h} w_{ij} v_i h_j - \sum_{i=1}^{n_v} b_i v_i - \sum_{j=1}^{n_h} c_j h_j \quad (1)$$

式中:  $\theta = \{w_{ij}, b_i, c_j\}$ , 为模型的其他参量;  $h_j$  为隐含层第  $j$  个神经元的状态值;  $b = (b_1, b_2, \dots, b_{n_v})$ , 为可见层神经元的偏置;  $v_i$  为可见层第  $i$  个神经元的状态值。

由式(1),推出状态  $(v, h)$  的联合概率分布为:

$$P(v, h | \theta) = \frac{1}{Z(\theta)} e^{-E(v, h | \theta)} \quad (2)$$

式中:  $Z(\theta) = \sum_{v, h} e^{-E(v, h | \theta)}$ , 为归一化因子,即配分函数。进而  $v, h$  的边缘概率分布为:

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

$$P(h | \theta) = \frac{1}{Z(\theta)} \sum_v e^{-E(v, h | \theta)} \quad (4)$$

所以训练 RBM 就是为了得出能较好拟合训练样本的 RBM 相关参量  $\theta = \{w_{ij}, b_i, c_j\}$ 。

RBM 特殊的模型结构决定了,当可见层的激活状态已知时,隐含层神经元  $j$  被激活的概率为:

$$P(h_j = 1 | v, \theta) = S \left( \sum_i^{n_v} w_{ij} v_i + c_j \right) \quad (5)$$

式中:  $S(x) = 1/(1+e^{-x})$ 。

可见层第  $i$  个神经元被激活的概率为:

$$P(v_i = 1 | h, \theta) = S \left( \sum_j^{n_h} w_{ij} h_j + b_i \right) \quad (6)$$

对于式(5)和式(6),采用对比散度算法对重构数据进行近似采样。算法步骤如下:

(1) 设定初值  $v_0 = x_0$ , 初始化模型参数  $\theta_0$ , 设定该 RBM 最大训练迭代次数  $l$ 。

(2) 对隐含层神经元,计算:

$$P(h_{0j} = 1 | v_0) = S \left( c_j + \sum_{i=1}^{n_v} \omega_{ij} v_{0i} \right) \quad (7)$$

并根据  $P(h_{0j} = 1 | v_0)$  对隐含层的神经元  $h_0 = \{h_{01}, h_{02}, \dots, h_{0n_h}\}$  进行随机采样。

(3) 对可见层神经元,计算:

$$P(v_{1i} = 1 | h_0) = S \left( b_i + \sum_{j=1}^{n_h} h_{0j} \omega_{ij} \right) \quad (8)$$

并根据  $P(v_{1i} = 1 | h_0)$  对可见层的神经元  $h_1 = \{h_{11}, h_{12}, \dots, v_{1n_v}\}$  进行随机采样。

(4) 对隐含层神经元,计算:

$$P(h_{1j} = 1 | v_1) = S \left( c_j + \sum_{i=1}^{n_v} \omega_{ij} v_{1i} \right) \quad (9)$$

(5) 按式(10)更新参数。

$$\begin{cases} \omega_{ij} = \omega_{ij} + \rho [P(h_{0j} = 1 | v_0) v_{10} - P(v) P(h_{1j} = 1 | v_1) v_{11}] \\ b_i = b_i + \rho [v_{10} - v_{11}] \\ c_j = c_j + [P(h_{1j} = 1 | v_0) - P(h_{1j} = 1 | v_1)] \end{cases} \quad (10)$$

式中:  $\rho$  为学习率。

(6) 重复步骤(2)~(5),直到最大迭代次数  $l$ , 结束该层 RBM 的参数训练。

### 1.2 稀疏系数的引入

通常, RBM 学习到的特征,表示为非稀疏的,即 RBM 的隐含层神经元,大多数是处于被激活状态,为了避免特征信息冗余,减少复杂度,稀疏的概念被引入到 RBM 中,形成了稀疏 RBM,具有更高的识

别准确率。

稀疏 RBM 是通过将原有 RBM 的对数似然函数增加稀疏惩罚项,以此控制隐含层神经元被激活的概率。稀疏 RBM 算法步骤如下:

(1) 采用 CD 算法,按照下式更新 RBM 参数:

$$\begin{cases} \omega_{ij}^{(t+1)} = \omega_{ij}^{(t)} + \rho [v_i h_{jP(v,h|\theta)} - v_i h_{jP(h|v,\theta)}] \\ b_i^{(t+1)} = b_i^{(t)} + \rho [v_i P(v,h|\theta) - v_i P(h|v,\theta)] \\ c_j^{(t+1)} = c_j^{(t)} + \rho [h_{jP(v,h|\theta)} - h_{jP(h|v,\theta)}] \end{cases} \quad (11)$$

式中:  $t=1,2,\dots,m$ ,  $m$  为训练样本个数。

(2) 采用稀疏惩罚项  $L_{s*}$  的梯度格式,按照下式再次更新参数:

$$\begin{cases} \omega_{ij}^{(t+1)} = \omega_{ij}^{(t+1)} + \partial L_s / \partial \omega_{ij}^{(t)} \\ c_j^{(t+1)} = c_j^{(t+1)} + \partial L_s / \partial c_j^{(t)} \end{cases} \quad (12)$$

(3) 重复步骤(1)和(2)直到最大迭代次数  $L$ ,结束该层 RBM 的参数训练。

文中采用 LogSum 范数作为稀疏惩罚项,形成 LogSum-RBM,其稀疏惩罚项表示如下:

$$L_s = \sum_{i=1}^m \sum_{j=1}^{m_h} \log \left[ 1 + \frac{E(h_j^{(i)} | v^{(i)})}{\varepsilon} \right] \quad (13)$$

式中:  $\varepsilon$  表示稀疏常数。所以稀疏惩罚项对参数的梯度表示为:

$$\frac{\partial L_s}{\partial \omega_{ij}} = \frac{1}{\varepsilon} \sum_{i=1}^m [\sigma(1-\sigma)v_i^{(i)}] / \left(1 + \frac{\sigma}{\varepsilon}\right) \quad (14)$$

$$\frac{\partial L_s}{\partial c_j} = \frac{1}{\varepsilon} \sum_{i=1}^m [\sigma(1-\sigma)] / \left(1 + \frac{\sigma}{\varepsilon}\right) \quad (15)$$

其中:

$$\sigma = S \left( \sum_i \omega_{ij} v_i^{(i)} + c_j \right) \quad (16)$$

### 1.3 RBM 堆叠构建的 DBN 模型

DBN 是深度学习中最关键的一个多层网络架构,如图 2 所示,由多层 RBM 堆叠而成,前一层 RBM 的输出为后一层 RBM 的输入,最顶层采用 Softmax 分类器作为标签层,输出分类识别的结果。

DBN 的训练分为预训练和调优 2 个阶段。预训练阶段:采用无监督的逐层贪心训练方法来训练每层 RBM 的参数,先训练网络的第 1 个隐含层,训练好后接着训练第 2 个隐含层,以此类推直到最后一个隐含层。微调阶段:对预训练好的网络,采用 BP 算法有监督地对整个网络参数进行进一步优化和调整,使其达到全局最优。

文中将 DBN 中底层的 RBM 全部替换为上文所提的 LogSum-RBM,从而构成稀疏 LogSum-DBN,用于变压器诊断模型的构建。

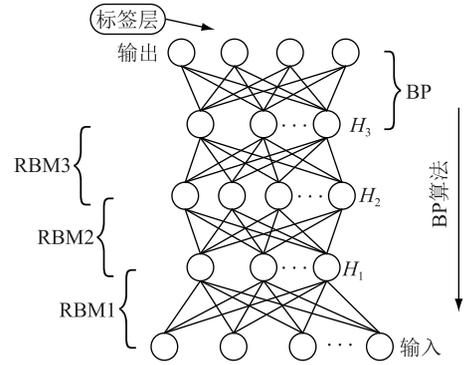


图 2 深度置信网络结构

Fig.2 Structure diagram of deep believe network

电力变压器在线监测数据绝大多数都为无标签数据,因为带标签的样本数据较难获得。相比其他应用较多的故障诊断智能算法,如 SVM 和自组织映射(self-organizing maps, SOM)等诊断方法,文中所设计的 LogSum-DBN 算法在变压器故障诊断方面具有较明显的优势。从算法机理角度分析,该算法基于深度学习,是一种半监督学习算法,对于训练样本有较高的利用率,能够针对变压器在线监测得到的海量多维异构数据学习其特征。训练开始前,利用大量无标签样本进行无监督预训练,对参数进行初始化,能用更少的迭代次数获得更稳定准确的结果。而传统的机器学习方法多为有监督学习,无法有效利用无标签数据,对样本的利用率较低。且传统智能算法均属于浅层机器学习算法,学习能力相对有限,对变压器故障诊断的准确率较低。

## 2 基于 LogSum-DBN 的变压器故障诊断方法

### 2.1 变压器故障诊断问题

电力变压器故障诊断模型的输入量为提取出的样本特征,表示如下:

$$\mathbf{X} = [\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^L, \mathbf{x}^{L+1}, \dots, \mathbf{x}^{L+U}] = \begin{bmatrix} x_1^1 & x_1^2 & \dots & x_1^L & x_1^{L+1} & \dots & x_1^{L+U} \\ x_2^1 & x_2^2 & \dots & x_2^L & x_2^{L+1} & \dots & x_2^{L+U} \\ \vdots & \vdots & & \vdots & \vdots & & \vdots \\ x_D^1 & x_D^2 & \dots & x_D^L & x_D^{L+1} & \dots & x_D^{L+U} \end{bmatrix} \quad (17)$$

式中:  $L$  为带标签样本的总数;  $U$  为无标签样本的总数;  $D$  为每个样本数据的输入特征数。注意的是,当  $U=0$  即表明所有的输入数据均为带标签样本数据。每一组样本数据都可以看做是数据集中的一个向量,即  $\mathbf{X}$  中的一列,  $x_j^i$  表示第  $i$  组样本中的第  $j$  个特征。

矩阵  $\mathbf{Y}$  为带标签样本数据集,其表达式如式

(18)所示。其中,  $C$  为标签的类别数,在变压器故障诊断问题中,标签类别为变压器的常见故障类型。变压器故障诊断即为寻找  $X \rightarrow Y$  的映射问题。

$$Y = [y^1, y^2, \dots, y^L] = \begin{bmatrix} y_1^1 & y_1^2 & \dots & y_1^L \\ y_2^1 & y_2^2 & \dots & y_2^L \\ \vdots & \vdots & \dots & \vdots \\ y_c^1 & y_c^2 & \dots & y_c^L \end{bmatrix} \quad (18)$$

### 2.2 变压器多维监测数据的选取

为了保证评估诊断的正确有效,文中综合现有的研究文献,并且结合最新的在线监测技术<sup>[21-23]</sup>,在该系统中选取代表变压器健康状态的多维度在线监测量作为故障诊断模型的输入特征,特征集如表1所示。

表1 变压器故障诊断输入特征集

Table 1 Power transformer fault diagnosis input characteristic set

输入特征	特征描述	单位
$x_1$	H <sub>2</sub> 含量	μL/L
$x_2$	CH <sub>4</sub> 含量	μL/L
$x_3$	C <sub>2</sub> H <sub>2</sub> 含量	μL/L
$x_4$	C <sub>2</sub> H <sub>4</sub> 含量	μL/L
$x_5$	C <sub>2</sub> H <sub>6</sub> 含量	μL/L
$x_6$	总烃含量	μL/L
$x_7$	总烃相对产气速率	%
$x_8$	总烃绝对产气速率	mL/d
$x_9$	H <sub>2</sub> 绝对产气速率	mL/d
$x_{10}$	C <sub>2</sub> H <sub>2</sub> 绝对产气速率	mL/d
$x_{11}$	CO绝对产气速率	mL/d
$x_{12}$	CO <sub>2</sub> 绝对产气速率	mL/d
$x_{13}$	油中微水含量	μL/L
$x_{14}$	振动信号	K
$x_{15}$	铁芯接地电流	mA
$x_{16}$	套管介损(tanδ)	%
$x_{17}$	套管电容差值	%
$x_{18}$	顶层油温	℃

### 2.3 输入数据的归一化处理

变压器多维度的监测数据存在不同的量纲、标度,因此必须进行归一化处理。对于监测数据越低越优的评估指标,采用下降半梯形模型<sup>[24]</sup>进行归一化:

$$y(x_i) = \begin{cases} 1 & 0 \leq x_i < a \\ 1 - \frac{x_i - a}{b - a} & a \leq x_i < b \\ 0 & b \leq x_i \end{cases} \quad (19)$$

对于监测数据越高越优的评估指标,采用上升半梯形模型:

$$y(x_i) = \begin{cases} 0 & 0 \leq x_i < a \\ \frac{x_i - a}{b - a} & a \leq x_i < b \\ 1 & b \leq x_i \end{cases} \quad (20)$$

式中: $x_i$ 为所测实际数据; $a, b$ 为该项评估指标的定量阈值<sup>[25]</sup>。

### 2.4 变压器故障编码

根据变压器历史故障数据统计<sup>[26-27]</sup>,为了使诊断系统的输出类别尽可能的覆盖变压器常见故障类别,选取的诊断类别为:正常、绕组故障、铁芯故障、绝缘故障、油故障、热故障、套管故障和分接开关故障共8类,将其故障类别编码如表2所示。

表2 变压器故障编码

Table 2 Transformer fault code

故障类型	对应编码
正常	(1,0,0,0,0,0,0,0)
绕组故障	(0,1,0,0,0,0,0,0)
铁芯故障	(0,0,1,0,0,0,0,0)
绝缘故障	(0,0,0,1,0,0,0,0)
油故障	(0,0,0,0,1,0,0,0)
热故障	(0,0,0,0,0,1,0,0)
套管故障	(0,0,0,0,0,0,1,0)
分接开关故障	(0,0,0,0,0,0,0,1)

### 2.5 变压器故障诊断 LogSum-DBN 模型

图3所示为基于LogSum-DBN的变压器故障诊断模型(图中为部分数据),特征提取分多层依次进行,最终输出结果为该样本概率值最大的一项。

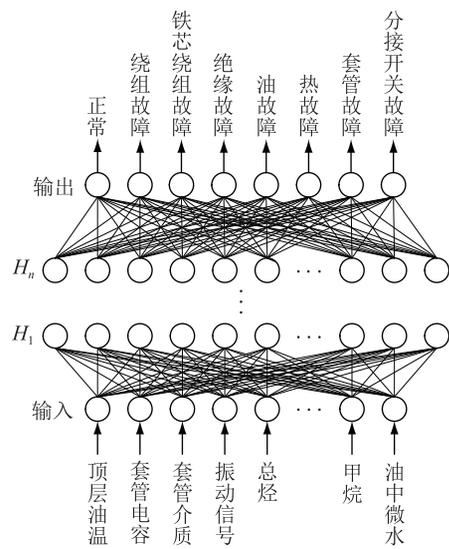


图3 变压器故障诊断模型

Fig.3 Transformer fault diagnosis model

基于LogSum-DBN的变压器故障诊断模型的实现过程如图4所示。

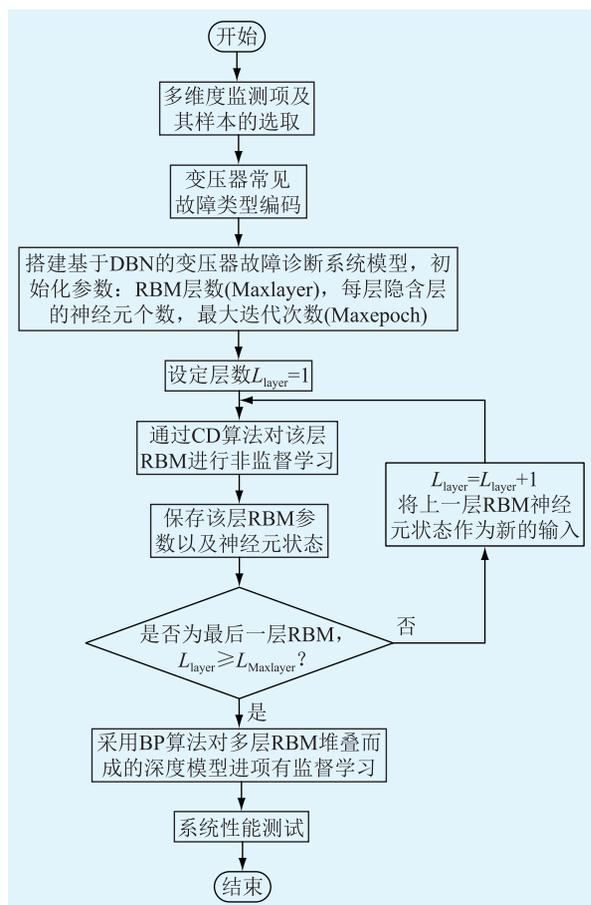


图4 诊断模型训练过程

Fig.4 Training process of diagnosis model

### 3 实例分析

以某市 220 kV 主变作为实验对象,该主变型号为 SFPS 10-180 000/220。选择监测得到的 1 000 组无标签多维监测数据,用作预训练集。测试集和调优集以不同比例选自待测变压器正常及故障时监测到的 500 组数据。其中变压器正常时的监测数据 100 组;故障时的监测数据 400 组,分为 8 类常见故障,每类 50 组。以此验证所设计的基于 LogSum-DBN 算法的变压器故障诊断模型的有效性。

根据文献[28],模型中迭代次数为 50 次,选取每一层的隐含层神经元有且仅有 100 个。在此基础上,设置隐含层层数从 1 变化到 10,测试此时不含稀疏系数的诊断模型正确率,结果如图 5 所示。

分析图 5,在未引入稀疏系数时,变压器诊断模型的诊断正确率呈先上升后缓慢下降的趋势,在隐含层数为 5 时,诊断正确率达到最大值,为 93% 左右。多种原因可导致此现象,如隐含层逐渐增加时,运算复杂度随之增加,诊断效率降低。因而考虑选择隐含层数目为 5 比较合适。

根据上述测试,确定文中诊断模型基本网络参

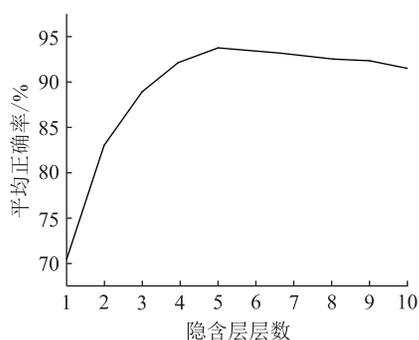


图5 隐含层数变化时变压器诊断平均正确率

Fig.5 Transformer fault diagnosis average accuracy when hidden layer number changes

数如下:变压器故障诊断的深度学习模型的深度(隐含层层数)为 5 层;变压器监测项维度为 18;输出层的神经元个数为 8;隐含层从下至上每层分别含有的神经元个数均为 100。在每种情况中,打乱样本顺序,分批迭代训练。在此基础上,引入稀疏算法,在相同条件下测得引入稀疏后的变压器故障诊断正确率,结果如图 6 所示。

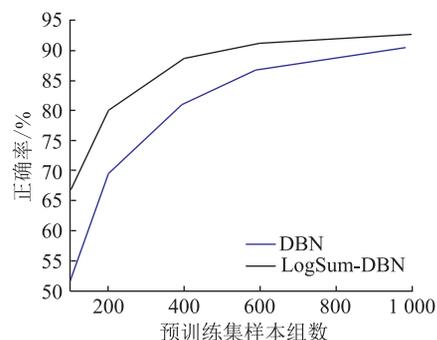


图6 引入稀疏后的变压器故障诊断情况

Fig.6 Transformer fault diagnosis after introducing the sparse algorithm

由图 6 可知,横向分析,无论是否引入稀疏系数,诊断模型的平均正确率都会随着预训练样本数的增加而增加,上升曲线呈总体上升、先快后慢的趋势。分析原因,是由于模型参数在大量的无监督训练下已经进行了优化,进而能更好的微调模型相关参数。纵向对比,相同预训练样本数时,引入稀疏系数后的诊断正确率有明显提高,且在样本数减少时正确率下降幅度较小,证明样本不足时,引入稀疏系数后的 DBN 模型仍有优异的性能。

为了验证算法 LogSum-DBN 相比其他算法的优势,在相同条件下,将 DBN、BP 神经网络(back propagation neural network, BPNN)、SVM 和 SOM 诊断方法分别进行测试,以便与文中方法进行对比分析。

按照调优集和测试集的不同数据比例组合,将 100 组带标签样本分为 3 种情况进行测试,如表 3

所示,用以验证在不同情况下该模型的有效性。测试结果如表 4 所示。

表 3 3 种不同情况下的训练样本分类  
Table 3 Classification of training samples in three different situations

Case	调优集比例/%	测试集比例/%
C1	70	30
C2	50	50
C3	30	70

表 4 不同诊断方法的诊断性能比较  
Table 4 Comparison of diagnostic performance of different diagnostic methods

方法	调优集平均准确率/%			测试集平均准确率/%		
	C1	C2	C3	C1	C2	C3
LogSum-DBN	92.21	88.07	85.98	88.96	85.71	82.72
DBN	88.72	86.24	83.23	86.59	84.27	81.03
SVM	87.24	84.21	80.95	85.73	82.12	78.57
BPNN	78.76	75.58	70.32	74.71	72.63	67.63
SOM	68.37	63.86	59.54	66.37	62.08	58.86

根据表 4 可知,文中提出的引入稀疏系数 LogSum-DBN 变压器诊断算法,在各类情况下均表现出最优异的性能,相较于 DBN 算法,有 4% 左右的性能提升,且两者相比 SVM 等其他算法优势显著;当训练集(调优集)比例下降时,上述各类算法诊断准确率均随之下降,而纵向对比 5 种算法的下降幅度可知,DBN 算法诊断准确率下降幅度最小,LogSum-DBN 下降幅度次之,表明基于深度学习的两种算法在训练样本不足时仍有较高的诊断准确率。

从算法机理角度分析,LogSum-DBN 算法通过引入稀疏系数强化了 DBN 对样本的特征提取能力,使得该模型算法相比 DBN 等算法平均诊断准确率有进一步提高。另一方面,相比其他算法,深度学习算法的特点之一是,在训练前多出了一个无监督预训练的过程,即通过大量无标签样本数据进行预训练,提取样本的高维特征,使得整个网络参数趋于全局最优,基于深度学习的 LogSum-DBN 算法通过这一预训练过程对带标签样本数据的依赖大大减小。而其他算法需要随机初始化参数,所以很大程度上其诊断准确率取决于带标签样本数据是否全面。由表 4 可知,SOM 算法相比其他算法,其故障诊断准确率明显较低,分析算法机理,是由于该算法为非监督学习算法,其学习过程中不包含任何变压器诊断结果的先验知识,从而在学习多维测量与变压器故障状态之间的非线性关系上的能力较弱。

目前变压器故障诊断中仅有油中溶解气体这

一监测量有大量的监测数据,其余多维度的样本数据较少,且变压器运行相对稳定,故障较少,故不像其余应用领域存在大量带标签样本数据,所以深度学习算法相比于其他算法应用于变压器故障诊断中有相对较高的准确率。

## 4 结论

文中提出了一种基于 LogSum-DBN 和多维度信息融合的变压器故障诊断方法,通过机理分析、数据集测试和实例验证得出以下结论:

(1) 基于深度置信网络的学习方法为半监督学习,可充分利用大量无标签样本,解决 SVM、神经网络等智能算法过于依赖带标签样本的问题。

(2) 将稀疏系数引入到 RBM 中,构成基于稀疏 LogSum-DBN 的变压器故障诊断模型,可优化模型分类性能,对高维数据具有更高的识别准确率。

(3) 所提方法能够对变压器进行多维度故障诊断,可为变压器的运维检修工作提供更为准确的参考。

受限于数据来源,文中仅对 220 kV 电压等级进行了实例验证,后续将针对其他电压等级的应用场景进行研究和分析。

### 参考文献:

- [1] 杨廷方. 变压器在线监测与故障诊断新技术的研究[D]. 武汉:华中科技大学, 2008.  
YANG Tingfang. Study on new techniques of online monitoring and fault diagnosis for power transformer[D]. Wuhan: Huazhong University of Science and Technology, 2008.
- [2] 吴鹏,陶风波,蔚超,等. 统一潮流控制器用 500 kV 油浸式串联变压器技术解析[J]. 电力工程技术, 2018, 37(01): 14-18.  
WU Peng, TAO Fengbo, WEI Chao, et al. Technical analysis of 500 kV oil-immersed series transformer for unified power flow controller[J]. Electric Power Engineering Technology, 2018, 37(01): 14-18.
- [3] 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.
- [4] 电力设备预防性试验规程: Q/CSG 1140002-2011[S]. 广州: 中国南方电网公司, 2011.  
Preventive test code for electric power equipment: Q/CSG 114002-2011[S]. Guangzhou: China Southern Power Grid Company, 2011.
- [5] 张卫华,苑津莎,张铁峰,等. 应用 B 样条理论改进的变压器三比值故障诊断方法[J]. 中国电机工程学报, 2014, 34(24): 4129-4136.  
ZHANG Weihua, YUAN Jinsha, ZHANG Tiefeng, et al. An im-

- proved three-ratio method for transformer fault diagnosis using B-spline theory[J]. Proceedings of the CSEE, 2014, 34(24): 4129-4136.
- [6] 变压器油中溶解气体分析和判断导则:DL/T 722—2014[S]. 北京:中国电力出版社,2014.  
Guide to the analysis and the diagnosis of gases dissolved in transformer oil: DL/T 722—2014[S]. Beijing: China Electric Power Press, 2014.
- [7] 刘学民. 变压器冲击试验波形影响因素的研究[D]. 北京:华北电力大学,2013.  
LIU Xuemin. Research on wave-effecting factor of transformer impulse tests[D]. Beijing: North China Electric Power University, 2013.
- [8] 宋志杰,王健. 模糊聚类和 LM 算法改进 BP 神经网络的变压器故障诊断[J]. 高压电器, 2013(5): 54-59.  
SONG Zhijie, WANG Jian. Transformer fault diagnosis based on BP neural network optimized by fuzzy clustering and LM algorithm[J]. High Voltage Apparatus, 2013(5): 54-59.
- [9] 廖瑞金,廖玉祥,杨丽君,等. 多神经网络与证据理论融合的变压器故障综合诊断方法研究[J]. 中国电机工程学报, 2006, 26(3): 119-124.  
LIAO Ruijin, LIAO Yuxiang, YANG Lijun, et al. Study on synthetic diagnosis method of transformer fault using multi-neural network and evidence theory [J]. Proceedings of the CSEE, 2006, 26(3): 119-124.
- [10] 郑含博,王伟,李晓纲,等. 基于多分类最小二乘支持向量机和改进粒子群优化算法的电力变压器故障诊断方法[J]. 高电压技术, 2014, 40(11): 3424-3429.  
ZHEN Hanbo, WANG Wei, LI Xiaogang, et al. Fault diagnosis method of power transformers using multi-class LS-SVM and improved PSO[J]. High Voltage Engineering, 2014, 40(11): 3424-3429.
- [11] 费胜巍,苗玉彬,刘成良,等. 基于粒子群优化支持向量机的变压器故障诊断[J]. 高电压技术, 2009, 35(3): 509-513.  
FEI Shengwei, MIAO Yubing, LIU Chengliang, et al. Fault diagnosis of transformer based on particle swarm optimization-based support vector machine[J]. High Voltage Engineering, 2009, 35(3): 509-513.
- [12] 杨兵,丁辉,罗为民,等. 基于知识库的变压器故障诊断专家系统[J]. 中国电机工程学报, 2002, 22(10): 121-124.  
YANG Bing, DING Hui, LUO Weimin, et al. Expert system of transformer fault diagnosis based on knowledge base[J]. Proceedings of the CSEE, 2002, 22(10): 121-124.
- [13] 史家燕,赵肖敏,史源素,等. 变压器故障诊断专家系统的开发及应用[J]. 中国电力, 2015, 48(5): 31-35.  
SHI Jiayan, ZHAO Xiaomin, SHI Yuansu, et al. Development and application of transformer fault diagnosis expert system [J]. Electric Power, 2015, 48(5): 34-35.
- [14] 郑焯,黄海,赵海峰,等. 变压器故障诊断专家系统的改良设计[J]. 电工电气, 2014, 50(1): 47-50.  
ZHENG Ye, HUANG Hai, ZHAO Haifeng, et al. Improved design of expert system for transformer fault diagnosis [J]. Electrotechnics Electric, 2014, 50(1): 47-50.
- [15] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504.
- [16] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[M]. MIT Press, 2006.
- [17] BENGIO Y. Learning deep architectures for AI[M]. Now Publishers, 2009.
- [18] 石鑫,朱永利. 深度学习神经网络在电力变压器故障诊断中的应用[J]. 电力建设, 2015, 36(12): 116-122.  
SHI Xin, ZHU Yongli. Application of deep learning neural network in fault diagnosis of power transformer [J]. Electric Power Construction, 2015, 36(12): 116-122.
- [19] 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.
- [20] HINTON G E. A practical guide to training restricted boltzmann machines [M]. Neural Networks: Tricks of the Trade. Springer Berlin Heidelberg, 2012: 599-619.
- [21] JI N, ZHANG J, ZHANG C, et al. Enhancing performance of restricted Boltzmann machines via log-sum regularization [J]. Knowledge-Based Systems, 2014, 63(3): 82-96.
- [22] 岳红权,王建渊,杨文字,等. 基于互联网+的充电站配电设备在线监测研究 [J]. 电网与清洁能源, 2018, 34(4): 29-35.  
YUE Hongquan, WANG Jianyuan, YANG Wenyu, et al. Research on online monitoring of power distribution equipment based on internet + [J]. Power System and Clean Energy, 2018, 34(4): 29-35.
- [23] 陆云才,胡汉巧,蔚超,等. 基于超声波法的变压器重症监护系统研制及应用[J]. 电力工程技术, 2017, 36(2): 94-98.  
LU Yuncai, HU Hanqiao, WEI Chao, et al. Development and application of transformer intensive care system based on ultrasonic method [J]. Electric Power Engineering Technology, 2017, 36(2): 94-98.
- [24] 朱瑞凯. 电力变压器在线监测应用技术研究[D]. 北京:华北电力大学,2015.  
ZHU Ruikai. Research of transformer on-line monitoring technology [D]. Beijing: North China Electric Power University, 2015.
- [25] 赵文清,朱永利,姜波,等. 基于贝叶斯网络的电力变压器状态评估[J]. 高电压技术, 2008, 34(5): 1032-1039.  
ZHAO Wenqing, ZHU Yongli, JIANG Bo, et al. Condition assessment for power transformers by Bayes networks [J]. High Voltage Engineering, 2008, 34(5): 1032-1039.
- [26] 廖瑞金,王谦,骆思佳,等. 基于模糊综合评判的电力变压器运行状态评估模型[J]. 电力系统自动化, 2008, 32(3): 70-75.  
LIAO Ruijin, WANG Qian, LUO Sijia, et al. Condition assess-

ment model for power transformer in service based on fuzzy synthetic evaluation [ J ]. Automation of Electric Power Systems, 2008, 32(3) : 70-75.

- [27] 谢成,曹张洁,温典,等. 基于实时运行数据挖掘的配电变压器状态评估[J]. 浙江电力, 2017, 36(8) : 1-6.  
XIE Cheng, CAO Zhangjie, WEN Dian, et al. State evaluation of distribution transformers based on real-time operation data mining[J]. Zhejiang Electric Power, 2017, 36(8) : 1-6.
- [28] 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, 2009:121-123.  
ZHU Deheng, YAN Zhang, TAN Kexiong. Electrical equipm-

ent condition monitoring and fault diagnosis technology [ M ]. Beijing: China Electric Power Press, 2009: 121-123.

作者简介:



刘文泽

刘文泽(1973),男,博士,副教授,研究方向为电力系统监控、配网规划等(E-mail: liuwzh@scut.edu.cn);

张俊(1994),男,硕士在读,研究方向为电气设备故障诊断,光伏逆变器并网控制;

邓焱(1992),男,硕士在读,研究方向为电气设备故障诊断,电力系统监控。

## Transformer fault diagnosis method based on deep learning and multi-dimensional information fusion

LIU WENZE, ZHANG JUN, DENG YAN

(School of Electric Power, South China University of Technology, Guangzhou 510640, China)

**Abstract:** The paper constructs a deep learning fault classification model for fault diagnosis using a Sparse Restricted Boltzmann Machine (Sparse-RBM) based on the deep learning (DP) theory, in order to synthesize multi-dimensional information, determine transformer defects quickly and accurately, and solve the problem that multi-dimensional information fusion weights are difficult to determine. Combined with the multi-dimensional monitoring of large transformers, a transformer fault diagnosis method based on multi-dimensional information fusion and deep belief network is proposed. The method can utilize the massive unlabeled multi-dimensional monitoring data of the transformer as the learning sample, and only needs a small amount of tagged data for auxiliary optimization. The trained model can make an accurate fault diagnosis of the transformer body state according to the real-time online multi-dimensional monitoring data of transformers. The diagnosis test of a 220 kV main transformer in a city is carried out. The test results show that the accuracy of the method proposed in the paper is improved by 4% compared with the existing one.

**Keywords:** power transformer; multi-dimensional information fusion; fault diagnosis; deep learning; Sparse-RBM

(编辑 江林)