

基于堆栈稀疏自编码器与 XGBoost 的电力变压器故障诊断

梁浩语

安徽理工大学 电气与信息工程学院, 安徽 淮南 232001

摘要:目的 针对变压器油中的 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 气体的浓度存在耦合性问题及电力变压器故障诊断精度较低的问题,提出了利用堆栈稀疏自编码器(Stacked Sparse Autoencoder, SSAE)和 XGBoost 模型结合的方法来提高电力变压器故障诊断的准确率。方法 首先利用堆栈稀疏自编码器(Stacked Sparse Autoencoder, SSAE)处理 DGA 数据;其次确定自编码器堆栈个数,确定隐含层数目;然后利用 SSAE 对原始数据进行数据转换,提取深层次特征信息;接着为了消除数据之间数量级差异较大的问题,对提取后的特征数据归一化处理;最后将处理之后得到的数据再输入 XGBoost 模型之中进行分类验证。结果 本文建立的基于堆栈稀疏自编码器与 XGBoost 的电力变压器故障诊断方法诊断准确率为 91.11%,高于常用的其他机器学习模型。结论 实验结果验证了方法的有效性,表明基于堆栈稀疏自编码器与 XGBoost 的电力变压器故障诊断方法能够有效提高故障诊断的准确率。

关键词:故障诊断;堆栈稀疏自编码器;特征提取;XGBoost 模型;变压器

中图分类号:TM421 文献标识码:A doi:10.16055/j.issn.1672-058X.2024.0006.008

Fault Diagnosis of Power Transformer Based on Stacked Sparse Autoencoder and XGBoost

LIANG Haoyu

School of Electrical and Information Engineering, Anhui University of Science and Technology, Anhui Huainan 232001, China

Abstract: Objective To address the challenge of coupling the concentrations of H_2 , CH_4 , C_2H_6 , C_2H_4 , and C_2H_2 gases in transformer oil and to improve the accuracy of power transformer fault diagnosis, this paper proposed a method using the combination of Stacked Sparse Autoencoder (SSAE) and XGBoost model to improve the accuracy of power transformer fault diagnosis. **Methods** Firstly, a stacked sparse autoencoder (SSAE) was used to process DGA data. Secondly, the number of stacks in the autoencoder was determined to establish the number of implicit layers. Thirdly, SSAE was applied to transform the original data and extract deep-level feature information. Fourthly, to address the issue of significant magnitude differences between data, the extracted feature data were normalized. Finally, the processed data was input into the XGBoost model for classification and verification. **Results** The fault diagnosis accuracy of the proposed method based on stacked sparse autoencoder and XGBoost for power transformer was 91.11%, which was higher than that of other commonly used machine learning models. **Conclusion** Experimental results verify the effectiveness of the proposed method, demonstrating that this power transformer fault diagnosis method based on stacked sparse autoencoder and XGBoost can effectively improve the accuracy of fault diagnosis for power transformers.

Keywords: fault diagnosis; stacked sparse autoencoder; feature extraction; XGBoost model; transformer

收稿日期:2023-07-12 修回日期:2023-09-09 文章编号:1672-058X(2024)06-0065-07

作者简介:梁浩语(1999—),男,江苏盐城人,硕士研究生,从事变压器故障诊断研究。

引用格式:梁浩语. 基于堆栈稀疏自编码器与 XGBoost 的电力变压器故障诊断[J]. 重庆工商大学学报(自然科学版), 2024, 41(6): 65-71.

LIANG Haoyu. Fault diagnosis of power transformer based on stacked sparse autoencoder and XGBoost[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2024, 41(6): 65-71.

投稿地址 <http://journal.ctbu.edu.cn/zr/ch/index.aspx>

1 引言

变压器在整个电力系统之中起着重要的作用,是电力系统中至关重要的设备,在电力系统中承担着电压变换^[1]、电力储能分配以及电力传输的作用,变压器能否安全有保障运行,关系到电力网络系统的安全及供电的质量。因此,准确地诊断变压器的故障对维护电网安全运行、保证供电质量有着重要的意义^[2-3]。

气相色谱(GC)分析技术作为被分析化学家们普遍运用的技术,近些年来备受青睐^[4-6]。通过同位素稀释和内标技术可以提高气体的定量精度和定性能力,所以其具有定性能力高和定性能力强等优点,并且气相色谱技术的性价比也很高。近些年来,气相色谱技术一直处于稳定进步的状态,特别是在与行业相关的应用上十分活跃。

电力变压器在发生故障时,产生故障的原因往往比较复杂,并不能直接诊断出来。电力变压器在过热还有放电状态下,其绝缘油会产生气体,并溶解在油中。通常是通过分析溶解气体的情况,得到变压器的运行状况。常用的液体中气体浓度检测方法为油中溶解气体分析(DGA)法。通过 DGA 法检测变压器油中的 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 气体的浓度进而对变压器运行状态进行评价。常用的评价方法有:三比值法、Rogers 比值法、无编码比值法等。传统比值方法都是利用溶解气体的相对含量来判断故障类型,计算简单,但对阈值附近的数据分类效果不好,常出现“缺码”或“超码”现象。

王涛等^[7]利用优化的 BP 神经网络与 DGA 法相结合。这种方法可以在一定程度上找出数据的相互关联性,提高变压器故障诊断的准确率,但数据之间的数学关系不够严谨,学习效率也相当固定,会导致其收敛速度慢,需要比较长的训练时间,对学习和记忆的稳定性造成影响。

李亮等^[8]利用支持向量机与 DGA 法相结合的方法来进行变压器故障诊断。该方法运用支持向量机来进行变压器故障诊断在高维空间十分有效,也具有较弱的泛化能力,但在多个故障类别时,可能会出现过拟合等问题,导致故障诊断的准确率不高。

何宁辉等^[9]利用优化的极限学习机模型进行变压器的故障诊断。其模型在隐藏层无需迭代,具有学习速度比较快,泛化良好等优点,但这种方法没有考虑到结构化风险,可能会导致数据过度拟合,对数据集的可控性也相对较差,从而会导致其分类精度随之下降。

用堆栈自编码器进行数据处理,在一定程度上可以对数据进行特征提取处理,但是缺点也很明显。堆栈自编码器的泛化能力较差,对于网络波动的数据量来说并不能很好地筛选训练处理。稀疏自编码器可以

在很大程度上减少计算量,通过隐藏层 z 单元再加上稀疏性限制可以在很大程度上降低数据的过度拟合问题。通过表征学习发现,多层堆叠会产生影响程度更高的特征。

因此,将堆栈自编码器的多层堆栈方式和稀疏自编码器的稀疏性进行结合,构建出一个堆栈稀疏自编码器。采用堆栈稀疏自编码器与 XGBoost 模型结合的方法来提高变压器故障诊断的准确率。验证结果表明该方法具有更高的故障诊断准确率。

2 算法介绍

2.1 堆栈稀疏自编码器(SSAE)

堆栈稀疏自编码是将多个稀疏自编码器进行堆叠,稀疏堆栈自编码器原理如图 1 所示。

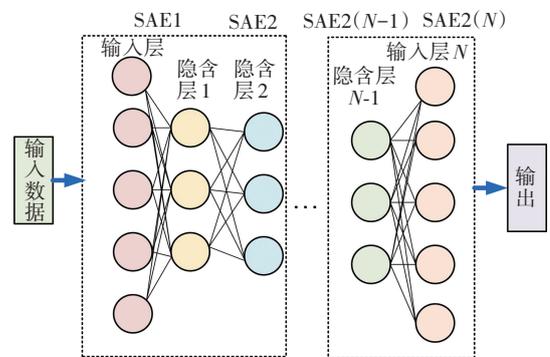


图 1 堆栈稀疏自编码器原理

Fig. 1 Principle of stack sparse auto-encoder

堆栈稀疏自编码器有预处理和微调两个阶段^[10-11]:

(1) 预处理阶段是对 SSAE 网络进行不断地训练,让原数据不会受到影响,保留原本的特征。输出低维信号的同时去除那些可能干扰数据准确性的高维信号部分,最后将训练得到的影响程度高的特征进行整合用于分类识别。

(2) 微调阶段是在训练的形式上,是将原始的数据集作为输入项放入自编码器中,采用无监督的方式进行训练;然后丢弃解码器层,再将其放入第二层进行训练,即把第一个自编码器隐含层的输出作为第二个自编码器的输入,一直到初始化完成所有自编码器;最后把最后一个自编码器的隐含层的输出作为分类模型的输入,进行有监督地训练。这种方法在一定意义上对数据进行了拟合,加快了迭代收敛,大大减少了需要训练参数的数目。其中交叉熵损失函数如式(1)所示:

$$l = - \sum_i^N (y_i \ln \hat{y}_i) \quad (1)$$

2.2 极端梯度提升树(XGBoost)

XGBoost 是在 Gradient Boosting 框架下实现的机器学习算法,又叫极端梯度提升树^[12-13],是分类回归树和随机森林的一种延伸。基本思路是当一个模型表现不好

时,继续按照表现不好的那一部分训练第二个模型,后面则按照前面的思路对数据一直进行训练。和 GBDT^[14]的思路其实是相同的,通过多个学习器进行学习,不断降低与实际值的误差,最后当迭代的次数达到上限或残差失效时,停止训练,最终在学习器的基础上形成强分类器。XGBoost 的目标函数如式(2)所示:

$$t_{\text{obj}} = \sum_{i=1}^n l(y_i, \hat{y}_i^{t-1} + f_i(x_i)) + \Omega(f_i) + C \quad (2)$$

其中, x_i 为输入的第 i 个样本,是前 $t-1$ 棵数的预测结果; $\Omega(f_i)$ 是正则化项,通过正则化 $\Omega(f_i) = \gamma T + \frac{1}{2} + \lambda \sum_{j=1}^T \omega_j^2$ 项来控制模型的复杂程度,以防出现过度拟合,从而提高模型的泛化能力; γ 和 λ 是超参数,用于控制惩罚力度; T 是当前回归树叶子节点的总个数,表示每个叶子节点值的平方和; $\sum_{j=1}^T \omega_j^2$ 是叶子节点的输出向量。

XGBoost 是在函数空间中利用牛顿法,在 $f_i(x_i)$ 处进行二阶泰勒展开:

$$t_{\text{obj}} \cong \sum_{i=1}^n \left[l(y_i - \hat{y}_i^{t-1}) + g_i f_i(x_i) + \frac{h_i f_i^2(x_i)}{2} \right] + \Omega(f_i + C) \quad (3)$$

其中, $g_i = \partial_{y_i} l(y_i, \hat{y}_i^{t-1})$, $h_i = \partial_{y_i}^2 l(y_i, \hat{y}_i^{t-1})$ 。

当求到 t 棵数模型时,前面 $t-1$ 棵树的结果或结构肯定已经确定,所以将其视为常数,式(3)去掉各项常数后,可得:

$$t_{\text{obj}} \cong \sum_{i=1}^n \left[g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i) \right] + \Omega(f_i) \quad (4)$$

定义 1 $I_j = \{i | q(x_i) = j\}$,表示某个样本映射到的节点集合,因为映射到同一叶子节点的样本权重都相同,可以处理表示为式(5):

$$t_{\text{obj}} = \sum_{j=1}^T \left[\left(\sum_{i \in I_j} g_i \right) \omega_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) \omega_j^2 \right] + \gamma T = \sum_{j=1}^T \left[G_j \omega_j + \frac{1}{2} (H_j + \lambda) \omega_j^2 \right] + \lambda T \quad (5)$$

其中, $G_j = \sum_{i \in I_j} g_i$, $H_j = \sum_{i \in I_j} h_i$ 。

因为 G_j 和 H_j 都是 $t-1$ 棵树已经确定的,因此对于一棵确定的树, T 已知的情况下,此时目标函数只与 ω_j 相关。如式(6)对 ω_j 求偏导,将偏导数为 0 时的 ω 值代入式(7),最后代入目标函数,将取得最小值如式(8)所示:

$$\frac{\partial J(f_i)}{\partial \omega_j} = G_j + (H_j + \lambda) \omega_j = 0 \quad (6)$$

$$\omega_j = -\frac{G_j}{H_j + \lambda} \quad (7)$$

$$t_{\text{obj}} = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T \quad (8)$$

3 仿真实验与结果分析

3.1 数据描述

数据由国家电网某公司提供,选取 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 为变压器故障诊断的属性,含正常状态和故障状态数据共 245 组。诊断模型的输出结果为变压器的故障种类,根据 GB-T7252-2016 变压器油中溶解气体分析和判断导则,本文以 7 种变压器的故障类型作为输出特征,分别是局部放电、低能放电、高能放电、低温过热、中温过热、高温过热以及正常状态。故障状态编码及其相应的样本数目如表 1 所示。随机划分训练集与测试集,得到训练集样本数目为 200 组,测试集样本数目为 45 组。部分数据样本如表 2 所示。

表 1 故障状态编码详细信息

Table 1 Details of fault status codes

故障类型	状态编码	样本数目	训练集数目	测试集数目
正常状态	1	36	29	7
低温过热	2	36	29	7
中温过热	3	33	30	3
高温过热	4	34	27	7
局部放电	5	36	29	7
低能放电	6	33	24	9
高能放电	7	37	32	5

表 2 部分原始数据详细信息

Table 2 Detailed information on selected raw data

单位: $\mu\text{L} \cdot \text{L}^{-1}$					
H_2	CH_4	C_2H_6	C_2H_4	C_2H_2	真实故障类别
28	9	27	5	0.5	正常运行
120	120	33	83	0.58	低温过热
131	253	97	357	2.4	高温过热
28	93	43	63	0.2	中温过热
106	24	4	28	37	高能放电

3.2 隐含层层数的确定

在 SSAE 网络模型中,隐含层层数对于诊断的准确率会产生一定的影响。为了找到最优隐含层层数,使用了 4 个实验组来进行分析对比。隐含层层数分别为 2、3、4、5 层,隐藏节点个数均设置为 5,分别输入 Softmax 层^[15]进行 10 次故障诊断,分析输出的诊断准确率。实验组中,隐含层层数仿真优化结果如表 3,实验组的结果如图 2 所示。

表 3 各实验组隐含层层数

Table 3 Number of implied layers in each experimental group

实验组别	第 1 隐含层	第 2 隐含层	第 3 隐含层	第 4 隐含层	第 5 隐含层
1	5	5			
2	5	5	5		
3	5	5	5	5	
4	5	5	5	5	5

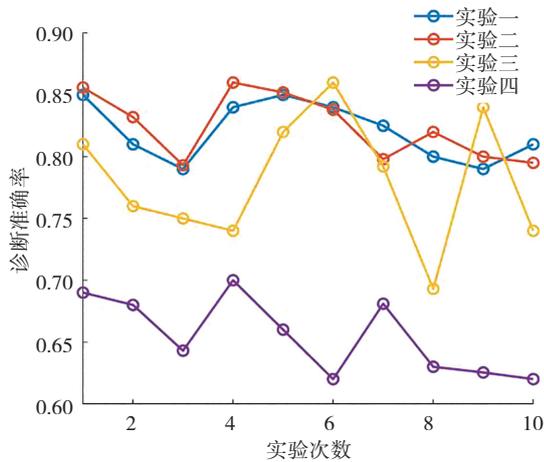


图 2 隐藏层层数确定

Fig. 2 Determination of the number of hidden layers

图 2 的实验结果表明:当隐藏层层数分别为 2、3、4 时,深度学习网络的平均测试诊断准确率约为 0.8;当隐藏层层数为 3 时,平均故障诊断率达到最优值,为 0.824 4;隐藏层层数为 5 时,深度学习网络的平均测试诊断准确率低于 0.7。仿真实验结果表明:较高的隐含层层数会造成样本数据的丢失,导致过拟合,对故障诊断的准确率有较大影响。因此,在本文中隐含层层数设为 3。

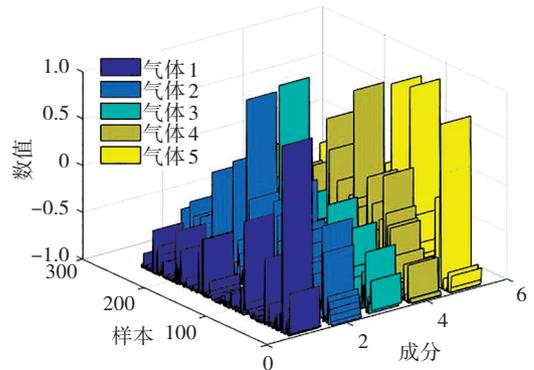
3.3 基于 SSAE 的特征提取

SSAE 由多层稀疏自编码器 (Stacked Sparse Autoencoder, SSAE) 组成^[16],稀疏自编码器是一种无监督学习方法,用于学习输入数据的高阶特征表示。堆栈稀疏自编码器的主要思想是通过逐层训练和叠加多个稀疏自编码器,从而逐步学习输入数据,得到更抽象、更高层次的特征表示。模型的每一层都包含一个自编码器,该自编码器由编码器和解码器组成,编码器将输入数据映射到隐藏层表示,而解码器将隐藏层表示映射回原始输入空间,每一层的隐藏层表示被用作下一层的输入数据。此外,堆栈稀疏自编码器能够自适应地学习输入数据的特征表示,无需手动设计特征提取器,这使得模型能够更好地适应不同的数据分布和任务需求。

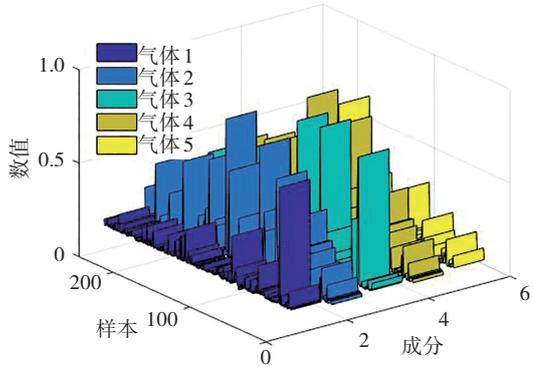
因为 DGA 数据存在一定的冗余性,一些无关的数据变量会对实验的准确性产生影响,所以本文使用 SSAE 对原始数据进行处理,深层次提取特征信息,并提高模型的泛化能力。

如图 3 所示,使用 SSAE 对原始 DGA 数据进行特征提取,采用区间值化法对数据进行处理。加上原 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 这 5 维特征变量,共 10 维特征变量。由于原始数据数量级差异较大,为了降低由此

带来的计算精度误差,论文对其进行标准化归一化处理,使数据处于 $[-1, 1]$ 范围内。



(a) 原始数据



(b) 经 SSAE 处理后的数据

图 3 原始数据和经 SSAE 处理后的数据

Fig. 3 Raw data and SSAE-processed data

得到提取后的数据集,帮助模型更好地适应不同的输入变化,提高模型在实际应用中的性能。数据归一化是一种线性变化,将原始结果映射在 $[-1, 1]$ 之间,使特征具有相同的度量尺度。本文采用区间值化法对数据进行归一化处理,数据按比例缩放特定区间,表达式如式(9)所示:

$$X_i = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \times [1 - (-1)] + (-1) \quad (9)$$

其中, X 是归一化处理之前的数据; X_i 是归一化处理之后的数据, $i = 1, 2, \dots, n$; X_{\max} 是数据样本的最大值; X_{\min} 为数据样本的最小值。

3.4 基于 XGBoost 的故障诊断结果

用全部训练集对模型进行训练,然后将训练好的模型对独立测试集进行故障诊断。利用 XGBoost 模型对前文经归一化处理后的特征进行故障诊断。模型的检测结果如图 4 所示。

从图 4 中可以看出基于 SSAE 的特征提取方法与 XGBoost 模型的变压器诊断效果良好,诊断准确率可达到 91.11%。

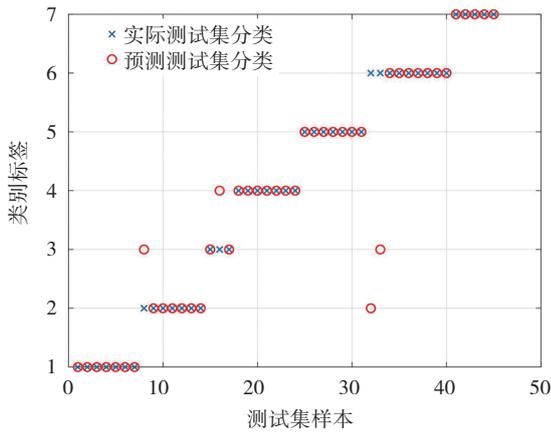


图 4 基于 XGBoost 模型的诊断结果图

Fig. 4 Diagnostic result graph based on XGBoost model

在分类算法实现过程中,模型的精确度、召回率、 $F1_{score}$ 是判断模型分类效果的 3 个主要指标。精确度 (Precision)、召回率 (Recall) 和 $F1_{score}$ 的计算公式如下:

$$P = \frac{T_p}{T_p + F_p} \quad (10)$$

$$R = \frac{T_p}{T_p + F_n} \quad (11)$$

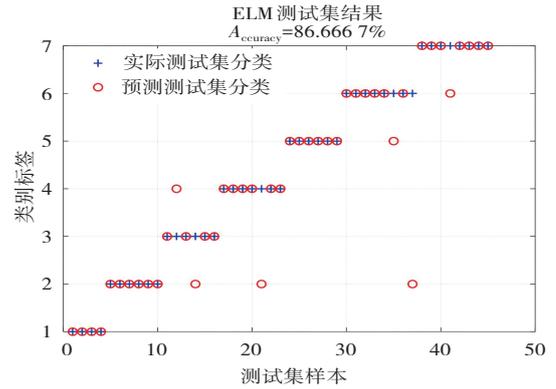
$$F1_{Score} = \frac{2 * P * R}{P + R} \quad (12)$$

其中,式 (12) 中的 P 和 R 分别表示精确度和召回率; T_p : 预测是正确的正样本; F_p : 预测是错误的正样本; F_n : 预测是错误的负样本。

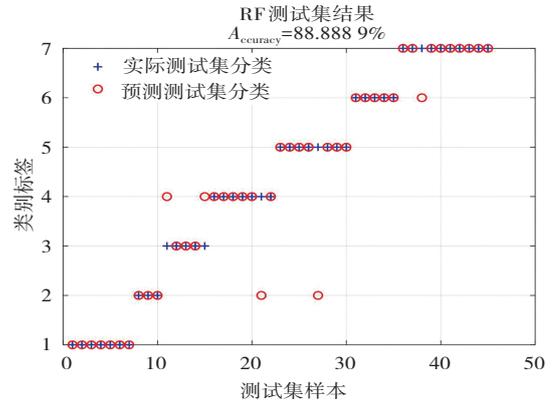
表 4 各指标详细信息表
Table 4 Details of indicators

故障标签	正确个数	P	R	$F1_{Score}$
正常状态	7/7	1	1	1
低温过热	6/7	0.857 1	0.857 1	0.857 1
中温过热	2/3	0.5	0.666 7	0.571 4
高温过热	7/7	0.875 0	1	0.933 3
局部放电	7/7	1	1	1
低能放电	7/9	1	0.777 8	0.875 0
高能放电	5/5	1	1	1
平均值		0.890 3	0.900 2	0.891 0

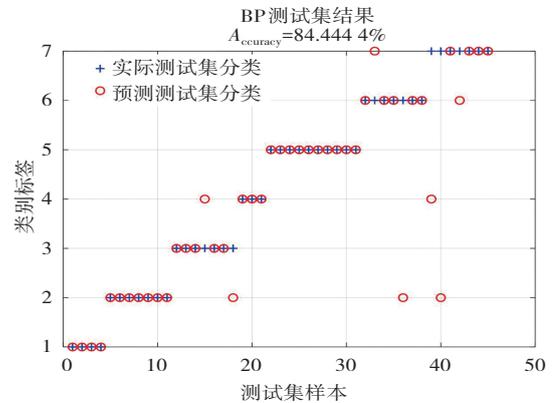
宏平均 $F1$ 值即为各故障标签样本所得 $F1_{score}$ 值的平均值,由此可得本文所建立模型的宏平均 $F1$ 值为 0.891 0,取得了较好的结果。为验证 XGBoost 模型故障诊断的优越性,分别采用电力变压器故障诊断常用的分类模型:极限学习机 (Extreme Learning Machines, ELM)^[17]、BP 神经网络 (BP Neural Network)^[18]、随机森林 (Random Forest, RF)^[19]、支持向量机 (SVM)^[20] 和本文选用的 XGBoost 模型进行诊断,将经前文处理后的特征数据输入模型中,对比实验结果,验证 XGBoost 模型在电力变压器故障诊断上的优越性。不同模型的诊断结果如图 5 所示。



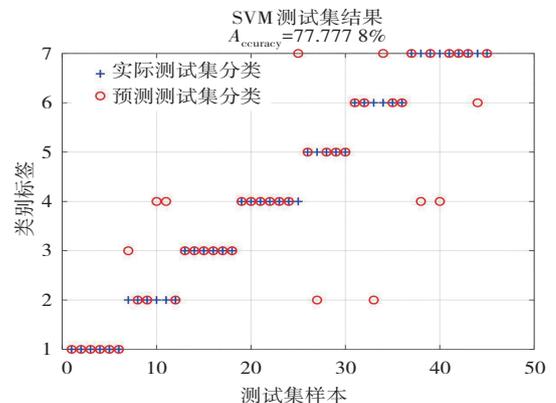
(a) ELM 测试集诊断结果图



(b) RF 测试集诊断结果图



(c) BP 测试集诊断结果图



(d) SVM 测试集诊断结果图

图 5 不同模型分类效果对比

Fig. 5 Comparison of classification effects of different models

由图 5 可以看出:4 种分类模型的效果均在 80% 左右,均低于本文选用的 XGBoost 模型。其中,SVM 模型的诊断准确率最低,为 77.78%。此外,对 4 个模型的诊断结果分别计算宏平均 F_1 值,如图 6 所示。

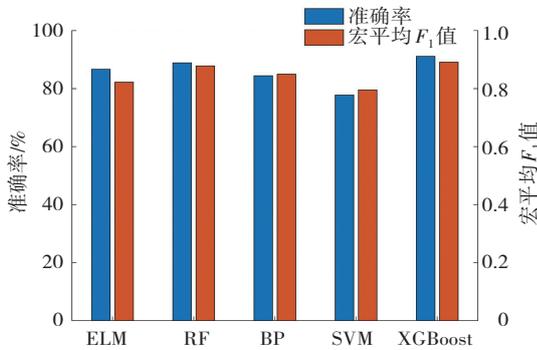


图 6 不同模型的宏平均 F_1 值

Fig. 6 Macro-averaged F_1 values for different models

由图 6 可以看出:除模型准确率之外,发现各模型的宏平均 F_1 值均低于本文选用的 XGBoost 模型。故本文所选用的模型较其他模型具有更好的分类效果。进一步表明使用的 XGBoost 模型具有更好的诊断性能。

4 结 论

变压器在整个电力系统之中起着重要的作用,是电力系统中至关重要的设备,因为气体的浓度存在耦合性问题,并且运用传统电力变压器故障诊断方法会存在诊断精度较低的问题,因此提出一种用堆栈稀疏自编码器处理 DGA 数据,并引入 XGBoost 模型对数据进行分类的变压器故障诊断方法。经实例验证,得到结论如下:

(1) 基于堆栈稀疏自编码器的特征提取方法可以有效捕获输入数据的不同抽象特征,从而得到更具表征性的特征表示,提高模型在实际应用中的性能。

(2) 在不同模型的诊断效果对比上,本文使用的 XGBoost 模型效果最好,其诊断准确率达到 91.11%,宏平均 F_1 值为 0.9810,均高于其他模型。

(3) 针对低能放电准确率不高的问题,后期会着重在低能放电部分展开更深入的研究。

参考文献(References):

[1] 朱庆东,朱文兵,王浩哲,等.基于油中溶解气监测的变压器在线半监督故障诊断方法研究[J].电网技术,2023,47(3):1031-1037.
ZHU Qing-dong, ZHU Wen-bing, WANG Hao-zhe, et al. Research on online semi-supervised fault diagnosis method of

transformer based on dissolved gas monitoring in oil[J]. Power System Technology, 2023, 47(3): 1031-1037.

- [2] 郭方洪,刘师硕,吴祥,等.基于联邦学习的含不平衡样本数据电力变压器故障诊断[J].电力系统自动化,2023,47(10):145-152.
GUO Fang-hong, LIU Shi-shuo, WU Xiang, et al. Fault diagnosis of power transformers containing unbalanced sample data based on federated learning[J]. Automation of Electric Power Systems, 2023, 47(10): 145-152.
- [3] 齐波,王一鸣,张鹏,等.基于自决策主动纠偏的电力变压器油色谱诊断模型[J].高电压技术,2020,46(1):23-32.
QI Bo, WANG Yi-ming, ZHANG Peng, et al. Diagnostic model of power transformer oil chromatography based on self-decision-making active correction[J]. High Voltage Engineering, 2020, 46(1): 23-32.
- [4] 张育杰,冯健,李典阳,等.基于油色谱数据的变压器故障征兆新优选策略[J].电网技术,2021,45(8):3324-3332.
ZHANG Yu-jie, FENG Jian, LI Dian-yang, et al. A new preferred strategy for transformer fault signs based on oil chromatography data[J]. Power System Technology, 2021, 45(8): 3324-3332.
- [5] 赵婉芳,王慧芳,邱剑,等.基于油色谱监测数据的变压器动态可靠性分析[J].电力系统自动化,2014,38(22):38-42,49.
ZHAO Wan-fang, WANG Hui-fang, QIU Jian, et al. Dynamic reliability analysis of transformer based on oil chromatography monitoring data[J]. Automation of Electric Power Systems, 2014, 38(22): 38-42, 49.
- [6] 戴晨伟,王化杰,吴明华.气相色谱法测定合成气厌氧发酵液中挥发性脂肪酸[J].重庆工商大学学报(自然科学版),2019,36(3):111-115.
DAI Chen-wei, WANG Hua-jie, WU Ming-hua. Determination of volatile fatty acids in syngas anaerobic fermentation broth by gas chromatography[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2019, 36(3): 111-115.
- [7] 王涛,王晓霞.基于改进 PSO-BP 算法的变压器故障诊断[J].中国电力,2009,42(5):13-16.
WANG Tao, WANG Xiao-xia. Transformer fault diagnosis based on improved PSO-BP algorithm[J]. Electric Power, 2009, 42(5): 13-16.
- [8] 李亮,范瑾,闫林,等.基于混合采样和支持向量机的变压器故障诊断[J].中国电力,2021,54(12):150-155.
LI Liang, FAN Jin, YAN Lin, et al. Transformer fault diagnosis based on hybrid sampling and support vector machine[J].

- Electric Power, 2021, 54(12): 150-155.
- [9] 何宁辉, 丁培, 马飞越, 等. 基于优化极限学习机的变压器故障诊断方法研究[J]. 电子器件, 2021, 44(4): 897-902.
HE Ning-hui, DING Pei, MA Fei-yue, et al. Research on transformer fault diagnosis method based on optimized limit learning machine [J]. Chinese Journal of Electron Devices, 2021, 44(4): 897-902.
- [10] 秦华锋, 刘霞. 基于稀疏自编码的手指静脉图像分割[J]. 重庆工商大学学报(自然科学版), 2019, 36(4): 1-8.
QIN Hua-feng, LIU Xia. Finger vein image segmentation based on sparse self-coding[J]. Journal of Chongqing Technology and Business University(Natural Science Edition), 2019, 36(4): 1-8.
- [11] 高佳程, 朱永利, 郑艳艳, 等. 基于 VMD-WVD 分布与堆栈稀疏自编码网络的局放类型识别[J]. 中国电机工程学报, 2019, 39(14): 4118-4129.
GAO Jia-cheng, ZHU Yong-li, ZHENG Yan-yan, et al. Localization type identification based on VMD-WVD distribution with stacked sparse self-coding network [J]. Proceedings of the CSEE, 2019, 39(14): 4118-4129.
- [12] 陈明华, 刘群英, 张家枢, 等. 基于 XGBoost 的电力系统暂态稳定预测方法[J]. 电网技术, 2020, 44(3): 1026-1034.
CHEN Ming-hua, LIU Qun-ying, ZHANG Jia-shu, et al. A transient stability prediction method for power systems based on XGBoost [J]. Power System Technology, 2020, 44(3): 1026-1034.
- [13] 赵洪山, 闫西慧, 王桂兰, 等. 应用深度自编码网络和 XGBoost 的风电机组发电机故障诊断[J]. 电力系统自动化, 2019, 43(1): 81-86.
ZHAO Hong-shan, YAN Xi-hui, WANG Gui-lan, et al. Fault diagnosis of wind turbine generator applying deep self-coding network and XGBoost[J]. Automation of Electric Power Systems, 2019, 43(1): 81-86.
- [14] 廖伟涵, 郭创新, 金宇, 等. 基于四阶段预处理与 GBDT 的油浸式变压器故障诊断方法[J]. 电网技术, 2019, 43(6): 2195-2203.
LIAO Wei-han, GUO Chuang-xin, JIN Yu, et al. Fault diagnosis method of oil-immersed transformer based on four-stage preprocessing and GBDT[J]. Power System Technology, 2019, 43(6): 2195-2203.
- [15] 王昱皓, 武建文, 马速良, 等. 基于核主成分分析-SoftMax 的高压断路器机械故障诊断技术研究[J]. 电工技术学报, 2020, 35(S1): 267-276.
WANG Yu-hao, WU Jian-wen, MA Su-liang, et al. Research on mechanical fault diagnosis technology of high-voltage circuit breaker based on kernel principal component analysis-SoftMax[J]. Transactions of China Electrotechnical Society, 2020, 35(S1): 267-276.
- [16] 胡天宇, 郭庆来, 孙宏斌. 基于堆叠去相关自编码器和支向量机的窃电检测[J]. 电力系统自动化, 2019, 43(1): 119-125.
HU Tian-yu, GUO Qing-lai, SUN Hong-bin. Electricity theft detection based on stacked de-correlation autoencoder and support vector machine[J]. Automation of Electric Power Systems, 2019, 43(1): 119-125.
- [17] 郝玲玲, 朱永利, 王永正. 基于 DCAE-KSSELM 的变压器故障诊断方法[J]. 中国电力, 2022, 55(2): 125-130.
HAO Ling-ling, ZHU Yong-li, WANG Yong-zheng. Transformer fault diagnosis method based on DCAE-KSSELM [J]. Electric Power, 2022, 55(2): 125-130.
- [18] 谢敏, 吴亚雄, 闫圆圆, 等. 基于改进动态自适应模糊 Petri 网与 BP 算法的电网故障诊断[J]. 中国电机工程学报, 2015, 35(12): 3008-3017.
XIE Min, WU Ya-xiong, YAN Yuan-yuan, et al. Grid fault diagnosis based on improved dynamic adaptive fuzzy Petri net with BP algorithm [J]. Proceedings of the CSEE, 2015, 35(12): 3008-3017.
- [19] 胡青, 孙才新, 杜林, 等. 核主成分分析与随机森林相结合的变压器故障诊断方法[J]. 高电压技术, 2010, 36(7): 1725-1729.
HU Qing, SUN Cai-xin, DU Lin, et al. Transformer fault diagnosis method combining kernel principal component analysis and random forest [J]. High Voltage Engineering, 2010, 36(7): 1725-1729.
- [20] 刘国柱. 基于自注意力机制与 1D-CNN 的变压器故障诊断方法[J]. 重庆工商大学学报(自然科学版), 2023(4): 1-8.
LIU Guo-zhu. Transformer fault diagnosis method based on self-attention mechanism and 1D-CNN[J]. Journal of Chongqing Technology and Business University(Natural Science Edition), 2023(4): 1-8.

责任编辑:李翠薇