

DOI: 10.13382/j.jemi.B2407769

计及时空特性的变压器油中溶解气体预测模型

李紫豪 何怡刚 周亚中 雷蕾潇

(武汉大学电气与自动化学院 武汉 430000)

摘要:针对电力变压器复杂运行环境下油中溶解气体随时间呈现非平稳和非线性特性,仅考虑时间维度关联特征的神经网络预测模型难以满足高准确性、高可靠性需求,且在数据采集过程中不可避免的存在异常值,导致数据质量下降,进而影响预测模型精度。因此首先采用基于密度的噪声应用空间聚类(DBSCAN)对油中溶解气体数据清洗,然后提出自适应非线性权重和莱维飞行策略改进鲸鱼优化算法,提高其局部及全局寻优能力,利用改进的鲸鱼优化算法优化DBSCAN中超参数提高数据清洗效果,最后分析气体成分间复杂关联关系,构建时空耦合卷积神经网络模型挖掘气体的时空特征,实现油中溶解气体时间序列预测。通过某电站变压器油中溶解气体实测数据验证,结果表明数据清洗后预测拟合优度(R^2)提高0.727,在6种特征气体预测中 R^2 都在0.9以上。相较于其他模型,所提模型在特征气体预测中均取得了最佳的预测结果,充分证明所提模型的有效性。

关键词:改进的鲸鱼优化算法;数据清洗;时空耦合卷积神经网络;油中溶解气体预测

中图分类号: TM407; TN06

文献标识码: A

国家标准学科分类代码: 470.40

Prediction model for dissolved gases in oil considering spatiotemporal characteristics

Li Zihao He Yigang Zhou Yazhong Lei Leixiao

(School of Electrical Engineering and Automation, Wuhan University, Wuhan 430000, China)

Abstract: In complex operating environments of power transformers, the dissolved gases in transformers have non-stationary and nonlinear characteristics. The prediction models of the neural network are difficult to meet high accuracy and reliability requirements which only consider the temporal features. During the data collection process, it is inevitable to exist outliers, which leads to a decrease in data quality and subsequently affects the accuracy of the prediction model. Firstly, density-based spatial clustering of applications with noise (DBSCAN) is proposed to clean the time-series data of dissolved gases in oil in this paper. Then, the adaptive nonlinear weight and Levy flight strategy are proposed to improve the whale optimization algorithm, enhancing its local and global optimization capabilities. The improved whale optimization algorithm is used to optimize hyperparameters in DBSCAN which improves the efficiency of data cleaning. Finally, the complex correlation between gases is analyzed, and a spatiotemporal coupled convolutional neural network model is constructed to mine the spatiotemporal characteristics of gases and achieve gas prediction. Verified by the dissolved gases in the oil of the power station, the results show that the R-squared increased by 0.727 after data cleaning. The R-squared is above 0.9 in all six characteristic gas predictions. Compared with other models, this prediction model proposed in this paper has achieved the best prediction results in feature gas prediction, which demonstrates the effectiveness of the prediction models.

Keywords: improved whale optimization algorithm; data clean; spatiotemporal coupled convolutional neural network; prediction of the dissolved gases in transformer

0 引言

建设数字中国是数字时代推进中国现代化的重要引擎,是构筑国家竞争新优势的有力支撑。变压器作为电网可靠运行的载体,其健康状态的准确评估是电力装备数字化的重要组成部分,也是落实数字中国重大战略的重要举措^[1]。随着设备运行年限的增长,变压器老化、故障等隐患增大,实时监测变压器的运行状态,实现变压器早期故障预警,对提升电力系统可靠性及稳定性具有重要意义^[2]。油中溶解气体作为表征变压器运行状况的重要状态参量,其预测的准确性是早期故障预警的关键一环^[3]。

多状态参量的传感器及高性能计算集群的普及导致海量数据资源的累积^[4]。受限于传感装置稳定性差、电磁环境复杂、数据传输中断、人为记录错误等原因,反映设备运行情况的状态参量数据中存在着大量的异常数据,这对变压器油中溶解气体的预测带来极大的挑战^[5]。因此对油中溶解气体时间序列数据清洗,为预测模型提供完整可靠的数据支撑具有重要意义^[6]。

现有的数据清洗方法主要包括基于阈值判据^[7-8]和基于机器学习的数据清洗模型。由于变压器油老化、变压器本身存在异常等因素造成变压器油中溶解气体时间序列是非线性的、非周期性的、非平稳的^[9],导致基于阈值判据的数据清洗模型难以实现趋势性的、断层性的油中溶解气体时间序列异常数据可靠检测。文献[10]利用 k 均值聚类算法(K-means clustering algorithm, K-means)对变压器顶层油温数据清洗,去除噪声和突变值,但 K-means 在处理随机性时间序列效果较差,不能同时检测零值和异常值。文献[11]采用最邻近集成隔离法综合考虑局部度量与全局度量的特性实现气体异常数据的准确识别。文献[12]采用自组织特征映射网络对变压器顶层油温异常值辨识,证明了神经网络在数据清洗方面的可行性。文献[13]利用长短时记忆神经网络对时间序列预测,设置上下限阈值对异常数据进行检测。但其对异常数据的检测可靠性取决于网络预测的准确性,且网络训练需要大量的历史样本^[12-13]。

随着计算机技术的快速发展,以机器学习及神经网络为代表的智能模型已被广泛的应用在变压器溶解气体时间序列预测领域^[14]。极限学习机(extreme learning machine, ELM)在处理时序预测问题上具有更好的适应性和准确性,其在油中溶解气体预测上具有良好的表现^[15-16]。文献[17]通过采用海洋捕食者算法优化自回归积分滑动平均模型(autoregressive integrated moving average model, ARIMA)对油中溶解气体预测,文献[18]通过蜣螂优化算法优化 ARIMA 对电力变压器振动信号

预测,获得较高的预测精度。但 ELM 和 ARIMA 的预测精度与其超参数有着很大的联系,具有不确定性^[15-18]。

长短期记忆神经网络(long short-term memory networks, LSTM)引入门控单元保留重要信息,以其独特的记忆功能挖掘时间维度的关联特性被广泛的应用于油中溶解气体时间序列预测领域^[19]。文献[20]采用门控循环单元(GRU)有效提高了变压器气体含量预测精度。文献[21-22]通过先引入卷积神经网络(convolutional neural networks, CNN)挖掘油中溶解气体时间序列关键特征,再输入至长短期记忆神经网络实现高精度预测。文献[23-24]通过引入注意力机制,通过注意力矩阵,对所有时间步进行点积的建模,从而加强了模型的预测能力。文献[25]融合时间卷积网络和图卷积网络,通过扩张卷积核代替舍弃层,提高预测精度。但这些网络模型仅限于时间维度的特征挖掘,缺少对气体成分之间的复杂关联关系特征分析。

针对变压器油中溶解气体时间序列非线性、非平稳性,存在异常值,现有网络模型缺乏考虑空间维度的关联特征,本文计及时空特性,采用基于密度的噪声应用空间聚类算法(density-based spatial clustering of applications with noise, DBSCAN)对油中溶解气体时间序列进行数据清洗,提出自适应非线性权重和莱维飞行策略改进鲸鱼优化算法对 DBSCAN 中超参数优化,为油中溶解气体预测提供完整可靠的数据支撑;分析气体成分间复杂关联关系,提出时空耦合卷积神经网络预测模型挖掘气体的时空特征,实现气体含量高精度、高可靠预测。

1 油中溶解气体数据清洗模型

1.1 基于密度的噪声应用空间聚类

由于传感器故障、数据传输中断、人为记录错误等原因导致变压器油中溶解气体存在异常值,造成数据质量下降,严重影响基于神经网络的时间序列预测模型预测精度。考虑到变压器油中溶解气体在时间空间上是密度相连的,因此本文分析压器油中溶解气体时空特性,提出基于密度的噪声应用空间聚类算法。

DBSCAN 是一种无监督的聚类算法,不需要对簇类数进行设置,对任意形状稠密数据集进行聚类,将相似的数据分配到相同的簇中,其原理如图 1 所示。DBSCAN 算法中包含两个超参数,一个为邻域半径 Eps ,另一个为邻域中数据点数目阈值 $MinPts$ 。当一个数据点的邻域半径内数据点数目大于阈值时为核心点,不属于核心点但在某个核心点的邻域内的点称为边界点,其余为噪声点。如图 1 所示, x_2 在核心点 x_1 的邻域内,则 x_1 与 x_2 之间密度直达; z_1, z_2, z_3, z_4 都为核心点且密度直达,其之间密度可达; y_1, y_2, y_3 之间密度可达,则它们之间密度相连,密

度相连的点为同一类簇。因此 $\{x_1, x_2, x_3, \dots, x_n\}$ 、 $\{y_1, y_2, y_3, \dots, y_n\}$ 、 $\{z_1, z_2, z_3, \dots, z_n\}$ 为同一类簇, $\{o_1, o_2\}$ 为异常噪声点。

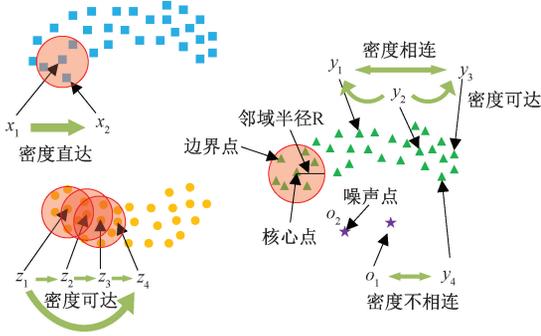


图1 基于密度的噪声应用空间聚类原理

Fig. 1 Density based noise application spatial clustering

由于不同的超参数 Eps 、 $MinPts$ 设置对油中溶解气体数据清洗效果影响较大,且通过试验的方式不易得到最佳的超参数值。因此引入改进的鲸鱼优化算法对 DBSCAN 中超参数优化,提高数据清洗效率。

1.2 改进的鲸鱼优化算法 (whale optimization algorithm, WOA)

采用自适应非线性权重策略和莱维飞行策略对传统的鲸鱼优化算法进行改进,增强鲸鱼优化算法的全局和局部寻优能力。

1) 鲸鱼优化算法

鲸鱼优化算法是模仿自然界鲸鱼捕食行为的群智能优化算法,通过鲸鱼群体搜索、包围、追捕和攻击猎物等过程实现优化时搜索的目的,主要包括包围猎物、发泡网攻击、搜索捕食 3 个过程^[26]。

(1) 包围猎物

鲸鱼群总是向最靠近猎物的鲸鱼个体位置移动,其表示式如式(1)~(4)所示。

$$A = 2a \times r_1 - a \quad (1)$$

$$C = 2r_2 \quad (2)$$

$$D_j = |C \times X_j^* - X_j^i| \quad (3)$$

$$X_j^{i,new} = X_j^* - A \times D_j \quad (4)$$

式中: a 随着迭代次数增加由 2~0 的线性衰减; r_1 、 r_2 为 0~1 的随机数; A 、 C 为随机系数; X_j^* 为最优鲸鱼个体的第 j 个参数值; X_j^i 为第 i 个鲸鱼个体在本次迭代中的第 j 个参数值; D_j 为包含随机系数 C 的第 i 个鲸鱼与最优鲸鱼个体距离; $X_j^{i,new}$ 为第 i 个鲸鱼个体在下一个迭代中的第 j 个参数值。

(2) 发泡网攻击

鲸鱼在围捕猎物时,不仅会收缩包围圈,而且会以螺旋形式向猎物游去,其表达式如式(5)和(6)所示。

$$D'_j = |X_j^* - X_j^i| \quad (5)$$

$$X_j^{i,new} = X_j^* + D'_j \times e^{bl} \times \cos(2\pi l) \quad (6)$$

式中: D'_j 为第 i 个鲸鱼与最优鲸鱼个体距离; b 为对数螺旋形状常数; l 为 -1~1 的随机数

(3) 搜索捕食

当式(1)中 A 的绝对值小于 1 时,鲸鱼个体可能不会向当前最靠近猎物的鲸鱼个体移动,而是向随机鲸鱼个体移动,其表达式如式(7)和(8)所示。

$$D''_j = |C \times X_j^{rand} - X_j^i| \quad (7)$$

$$X_j^{i,new} = X_j^{rand} - A \times D''_j \quad (8)$$

式中: X_j^{rand} 为随机鲸鱼个体的第 j 个参数值; D''_j 为包含随机系数 C 的随机个体与第 i 个鲸鱼的距离。

2) 自适应非线性权重

由于式(1)中 A 是随迭代次数衰减的,说明鲸鱼优化算法在寻优过程中,在迭代前期时 A 的值较大,能够在最优鲸鱼个体附近全局搜索;在迭代后期时 A 的值较小,能够在最优鲸鱼个体局部搜索最优解。然而鲸鱼优化算法只考虑迭代次数对搜索范围的影响,并未考虑适应度函数对搜索范围的影响,因此提出基于适应度函数值的自适应非线性权重。由式(2)可知, C 是一个随机数,并未赋予其任何意义。因此在式(2)中引入基于适应度函数的自适应非线性权重,表达式如式(9)所示。

$$C = 2r_2 + 2e^{-\frac{f(x^i)}{\max f(x)}} \quad (9)$$

式中: $f(x^i)$ 是第 i 个鲸鱼个体的适应度函数; $\max f(x)$ 是最优鲸鱼个体的适应度函数。

由式(9)可知,当第 i 个鲸鱼个体较最优个体越远时, C 的值越大,则在最优鲸鱼个体全局搜索;当第 i 个鲸鱼个体越接近最优个体时, C 的值越小,即在最优鲸鱼个体局部搜索。

3) 莱维飞行

莱维飞行是一种随机步长描绘莱维分布的方法,其少数长距离跳跃的特性可以很好的解决算法陷入局部最优的问题,且很大程度上提高算法的全局搜索能力,莱维飞行的表达式如式(10)所示。

$$s = \frac{\mu}{|v|^{\frac{1}{\beta}}} \quad (10)$$

式中: s 为随机步长; μ 、 v 为服从正态分布的随机数, $\mu \sim N(0, \sigma_\mu^2)$, $v \sim N(0, \sigma_v^2)$; σ_μ^2 和 σ_v^2 为通过数学运算得到的标量,表达式如式(11)所示。

$$\left\{ \begin{aligned} \sigma_\mu &= \left(\frac{\Gamma(1 + \beta) \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1 + \beta}{2}\right) \beta \times 2^{\frac{\beta-1}{2}}} \right)^{\frac{1}{\beta}} \\ \sigma_v &= 1 \end{aligned} \right. \quad (11)$$

式中: Γ 为伽马函数; β 是 0~2 的随机数,通常取 1.5。

由于莱维飞行机制,使个体位置的变化更加灵动,为贴合鲸鱼优化算法,在鲸鱼搜索捕食环节中引入莱维飞行,即将式(10)引入式(8)。表达式更新如式(12)所示。

$$X_j^{i,new} = X_j^{rand} - s \times A \times D_j'' \quad (12)$$

因此结合式(4)、(6)和(12),总结 WOA 算法的数学模型如式(13)所示。

$$X_j^{i,new} = \begin{cases} X_j^* - A \times D_j, & p < 0.5; |A| < 1 \\ X_j^{rand} - s \times A \times D_j'', & p < 0.5; |A| > 1 \\ X_j^* + D_j' \times e^{bl} \times \cos 2\pi l, & p > 0.5 \end{cases} \quad (13)$$

式中: p 为概率系数,是0~1的随机数。

2 时空耦合卷积神经网络预测模型

变压器油中溶解气体时间序列不仅在时序上存在关联,且各气体成分之间具有一定的相关性,因此,文章挖掘气体成分之间的时空特性,提出时空耦合卷积神经网络预测模型。空间特征模块以卷积神经网络为基础,挖掘各气体成分之间的相关特征,时间特征模块以长短记忆神经网络为基础引入自注意力机制,挖掘气体在时间维度的关联特征。

2.1 卷积神经网络

传统的卷积神经网络一般包括5个标准步骤:卷积计算、批标准化、激活函数、池化、舍弃。

卷积计算可以认为是一种有效提取数据特征的方法,其简化计算公式为:

$$y = \omega_{ij} x_{ij} + b \quad (14)$$

式中: x_{ij} 为第*i*行第*j*列的输入值; ω_{ij} 为第*i*行第*j*列的权重; b 为偏置; y 为输出。

标准化可以使数据符合以0为均值,1为标准差的标准正态分布,防止特征数据随着网络层数的增加而发生偏移。池化可以减少卷积神经网络中的特征数据量。舍弃层通过舍弃部分神经元,能够有效防止卷积神经网络的过拟合。

2.2 长短记忆神经网络

长短记忆神经网络的核心是细胞状态,其通过一种被称为门的结构对细胞状态进行删除或者添加信息,有效的保留重要特征。门结构分别为遗忘门、输入门和输出门,如图2所示。

遗忘门负责决定保留多少上一时刻的单元状态到当前时刻的单元状态;输入门负责决定保留多少当前时刻的输入到当前时刻的单元状态;输出门负责决定当前时刻的单元状态有多少输出,其计算过程如式(15)所示。

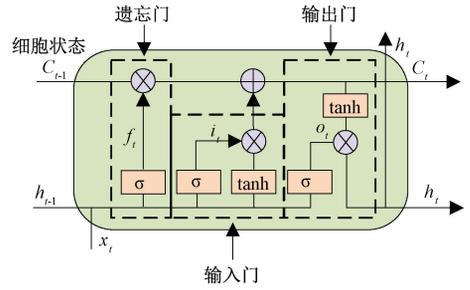


图2 长短记忆神经网络模型结构

Fig. 2 Long short memory neural network model

$$\begin{cases} f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \\ C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \\ o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \\ h_t = o_t \times \tanh(C_t) \end{cases} \quad (15)$$

式中: x_t 为第*t*时刻的输入值; f_t, i_t, o_t 为遗忘门、输入门和输出门在第*t*时刻的输出值; \tilde{C}_t 为输入门 tanh 层的输出值; C_{t-1}, C_t 分别为上一时刻的细胞状态及第*t*时刻的细胞状态; h_{t-1}, h_t 分别为上一时刻的输出值和第*t*时刻的输出值; W_f, W_i, W_c, W_o 为遗忘门、输入门、细胞状态、输出门的权重; b_f, b_i, b_c, b_o 为遗忘门、输入门、细胞状态、输出门的偏置; σ 为 sigmoid 函数。tanh 函数及 sigmoid 函数表达式如式(16)和(17)所示。

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (16)$$

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (17)$$

2.3 自注意力机制

自注意力机制通过引入查询向量(query, Q)、键向量(key, K)、值向量(value, V)与输入相乘,有效捕捉序列中的长距离依赖关系,权重共享相同的参数,有助于减少模型的参数数量和计算量。自注意力机制首先计算Q和K之间的点积,然后利用 softmax 函数将结果归一化为概率分布,再乘以矩阵V得到权重求和的表示。计算过程如式(18)所示。

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (18)$$

式中: d_k 为Key向量的维度。

2.4 时空耦合卷积神经网络 (spatiotemporal coupled convolutional neural network, SCCNN)

时空耦合卷积神经网络模型如图3所示,时间特征模块采用预测气体 x_0 第*m*时刻的前*n*个时刻值作为输

入端,空间特征模块采用与预测气体 x_0 具有相关性的其他气体的第 $m+1$ 时刻的前 $n-1$ 个时刻作为输入端。时间特征模块通过连接层 1 获取油中溶解气体时间序列时间特征 y_0 ,与空间特征模块的输入端进行深度方向的耦合;空间特征模块随时间推移的各气体成分数据逐层将后一时刻的输入端与前一时刻的输出端进行深度方向耦合,通过叠加时间特征模块与空间特征模块的输出值获取最终的预测结果。时空耦合卷积神经网络通过深度耦合时间空间特征参量,实现时间、空间特征的自融合与互融合,挖掘油中溶解气体时间序列时空特性,从而提高预测的精度。

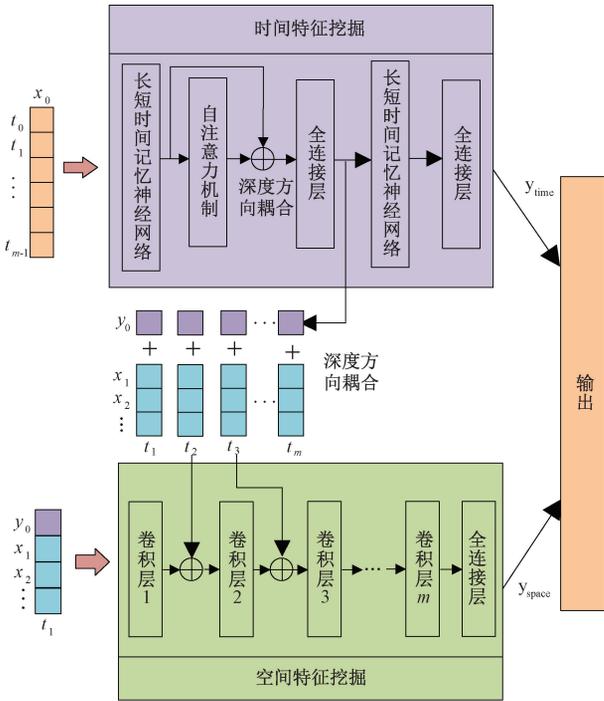


图3 时空耦合卷积神经网络

Fig. 3 Spatiotemporal coupled convolutional neural network

3 油中溶解气体预测框架

油中溶解气体时间序列预测方法如图4所示,其实现过程如下:

- 1) 将油中溶解气体时间序列进行归一化,将时间、空间作为二维特征输入到 DBSCAN 模型,通过改进的鲸鱼优化算法对 DBSCAN 的 Eps 、 $MinPts$ 参数进行优化提高数据清洗效果,采用平均插值法修改数据清洗的异常值。
- 2) 采用灰色关联分析及皮尔逊相关系数挖掘油中溶解气体各成分之间的关联性,将相关性较大的气体成分作为时空耦合卷积神经网络中空间特征模块的输入端。
- 3) 采用变分模态分解方法将油中溶解气体时间序列进行分解,将分解的各序列输入到时空耦合卷积神经网络中预测,相加得到最终的预测结果。

络中预测,相加得到最终的预测结果。

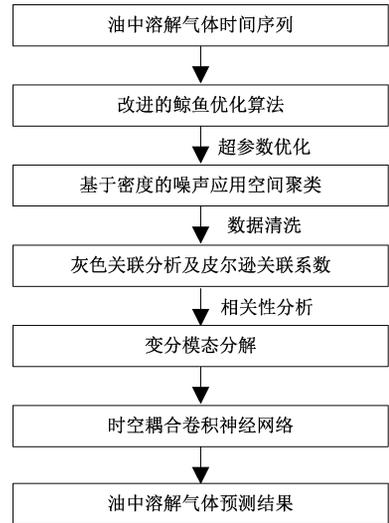


图4 油中溶解气体时间序列方法框架

Fig. 4 Time series method framework for dissolved gases in transformer

4 实验验证

变压器油中溶解气体数据来源于2010年至2012年期间英国电站某台变压器的公开数据^[27],包括氢气、甲烷、乙烷、乙烯、乙炔、一氧化碳、二氧化碳。每4h对油中溶解气体各成分进行记录,共有2916条数据,部分数据如图5所示。由于乙炔气体含量基本维持在0,因此对氢气、甲烷、乙烷、乙烯、一氧化碳、二氧化碳6种特征气体进行实验。实验在pycharm平台上使用tensorflow2.0编码实现,GPU为NVIDIA GeForce RTX 3080。

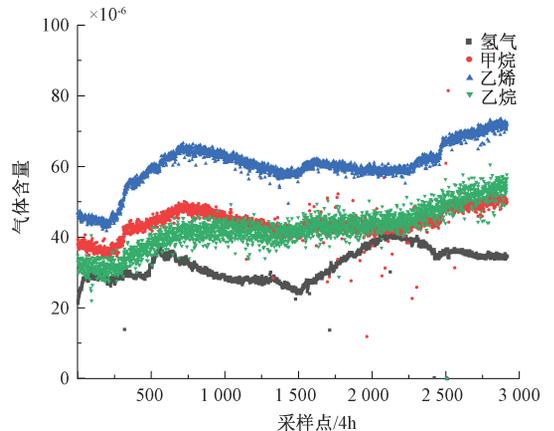


图5 油中溶解气体时间序列

Fig. 5 Time series of dissolved gases in oil

4.1 优化算法寻优结果对比

从标准测试函数库中选择4个典型测试函数进行寻

优性能测试,包括两个单峰函数和两个多峰函数,其中单峰函数能检验寻优算法的局部寻优能力,即局部最优解;多峰函数能检验寻优算法的全局寻优能力,即不陷入局部最优寻找全局最优。测试函数表达式及相关参数设置

如表 1 所示,其中, $f_1(x)$ 、 $f_2(x)$ 为单峰函数, $f_3(x)$ 、 $f_4(x)$ 为多峰函数,这 4 个典型测试函数既考察群智能优化算法寻优精度又考察其全局搜索能力。

表 1 测试函数

Table 1 Test functions

| 测试函数 | 维度 | 范围 | 理论最小值 |
|--|----|--------------|-------|
| $f_1(x) = \sum_{i=1}^n x_i^2$ | 30 | [-100,100] | 0 |
| $f_2(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2$ | 30 | [-100,100] | 0 |
| $f_3(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$ | 30 | [-5.12,5.12] | 0 |
| $f_4(x) = -20e^{-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}} - e^{\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)} + 20 + e$ | 30 | [-32,32] | 0 |

为验证改进鲸鱼优化算法的有效性和优越性,采用人工蜂群算法、遗传算法、粒子群算法、鲸鱼优化算法、改进鲸鱼优化算法对 4 个测试函数进行寻优测试,为保证

测试的公平性,所有群智能优化算法的设置群个体为 50,最大迭代次数为 200。寻优结果如表 2 所示,寻优迭代过程如图 6 所示。

表 2 群智能优化算法寻优结果

Table 2 Optimization results of group intelligent optimization algorithm

| 测试函数 | 人工蜂群算法 | 遗传算法 | 粒子群算法 | 鲸鱼优化算法 | 改进鲸鱼优化算法 |
|----------|-----------|-----------|----------|-----------------------|------------------------|
| $f_1(x)$ | 1 071.53 | 106.83 | 397.93 | 8.41×10^{-9} | 9.01×10^{-12} |
| $f_2(x)$ | 83 873.89 | 22 034.30 | 8 990.00 | 28.39 | 0.03 |
| $f_3(x)$ | 273.49 | 90.15 | 51.79 | 3.55×10^{-8} | 3.34×10^{-12} |
| $f_4(x)$ | 12.21 | 4.16 | 4.15 | 1.03×10^{-4} | 2.99×10^{-7} |

由图 6 可知,在单峰函数中与传统的鲸鱼优化算法寻优速度相似,而在双峰函数中寻优速度相对较快。改进的鲸鱼优化算法在 120 次迭代后优于其他传统的寻优算法。由图 6(a) 可知改进的鲸鱼优化算法在较少的迭代次数下找到相对最优解,在后续中迭代过程中不断接近理论值。由图 6(b) 可知,改进的鲸鱼优化算法在单峰函数中具有更高的寻优精度。由图 6(c)、(d) 可知,改进的鲸鱼优化算法不易陷入局部最优实现全局搜索。由表 2 可知改进的鲸鱼优化算法在 4 个测试函数的最优解都更接近理论值,验证其有效性及优越性。本文所提优化算法在较少的迭代次数得到精确的最优解,相较于传统的寻优算法有较高的计算效率。

4.2 数据清洗实验效果

由图 5 可知,油中溶解气体存在一定数量的异常值。因此将原始数据输入到 DBSCAN 中进行数据清洗,采用改进的鲸鱼优化算法对 DBSCAN 中超参数优化,提高数据清洗效果。考虑油中溶解气体时空特性,将时间序列转换为由 0~1 的参量,表达式如式 (19) 所示。

$$T_t = \frac{t}{t_{all}} \tag{19}$$

式中: T_t 为第 t 个观测时间点的时间参量值; t_{all} 为观测时间点的总数。

将气体参量进行归一化,表达式如式 (20) 所示。

$$x_t^i = \frac{x_t^i - x_{\min}^i}{x_{\max}^i - x_{\min}^i} \tag{20}$$

式中: x_t^i 为第 i 类油中溶解气体在第 t 时刻归一化值; x_{\min}^i 为第 i 类油中溶解气体的最小值; x_{\max}^i 为第 i 类油中溶解气体的最大值。

将时间与气体含量二维矩阵输入到 DBSCAN 中,数据清洗部分结果如图 7 所示。DBSCAN 通过密度相连的方式将正常值与异常值区分为不同的簇,识别出与正常数据偏离度较高的异常数据。由图 7 可知,DBSCAN 数据适用于非线性、非周期性的油中溶解气体时间序列,在异常值识别中变现出良好的效果。

4.3 数据清洗前后预测模型对比

由于每 4 h 记录 1 次数据,以 2 d 为单位,设置预测时刻的前 11 个时刻作为时间特征模块的输入端,通过皮

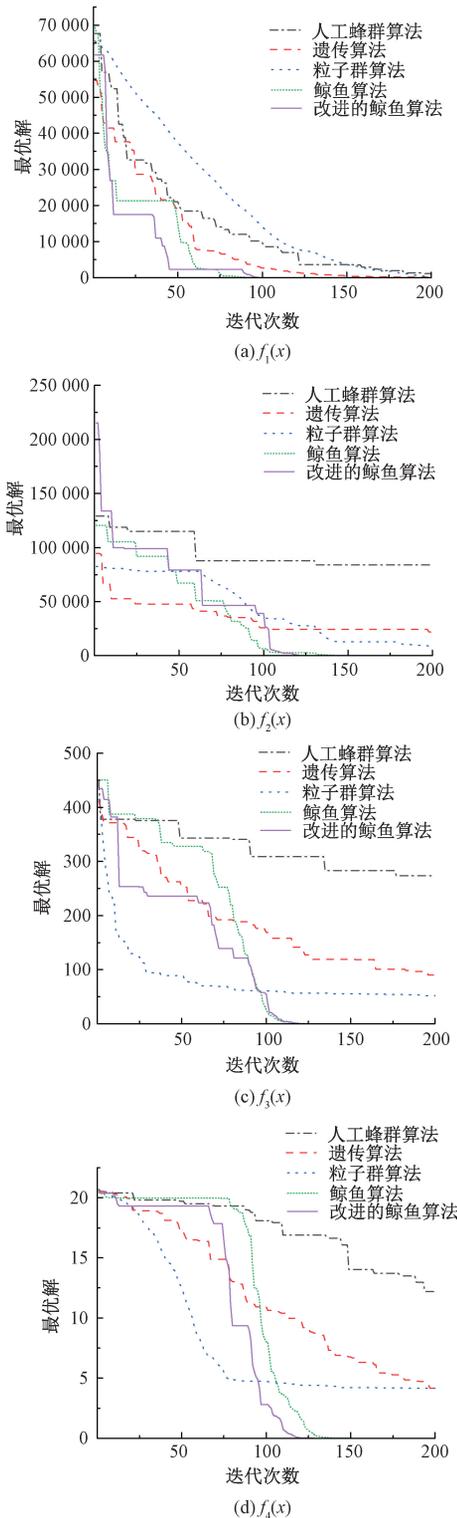


图 6 测试函数迭代过程

Fig. 6 Test function iteration process diagram

集共有 600 条数据。

针对油中溶解气体时间序列清洗前后状态下对时空耦合卷积神经网络预测精度的影响,限于篇幅原因,以乙烷为例对照试验并展开分析,取乙烷预测时刻的前 11 个时刻为时间特征模块的输入端,与乙烷皮尔逊相关系数 > 0.7 的气体为甲烷、乙烯和二氧化碳,选甲烷、乙烯和二氧化碳预测时刻的含量作为空间特征模块的输入端,预测结果如图 8 所示。

采用均方误差 (mean squared error, MSE)、均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE) 和拟合优度 (R^2) 对模型预测效果进行评价,结果如表 3 所示。评价指标表达式如式 (21) ~ (24) 所示。

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (21)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (22)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (23)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y} - y_i)^2} \quad (24)$$

式中: \hat{y}_i 和 y_i 为第 i 时刻油中溶解气体时间序列的预测值和真实值; \bar{y} 为真实值的平均值; n 为样本数。

由图 8 可知,油中溶解气体时间序列的异常值将严重影响模型的预测能力,从图中异常值出现的后半段看出,模型预测值与真实值虽然在趋势上大致相同,但是整体出现偏差,这是由于模型在学习过程中遇到异常值,偏离了油中溶解气体时间序列的整体趋势,从而无法正确反映变压器实际运行的真实状态。由表 3 可知由于异常值的出现,模型预测均方误差、均方根误差及平均绝对误差变大, R^2 从原来的 0.915 下降至 0.188,从实验可知,异常值的存在严重影响模型的预测精度。因此,对原始数据清洗将有效提高模型预测的有效性和可靠性。

表 3 乙烷数据清洗前后 SCCNN 模型评价指标
Table 3 Valuation indicators of C_2H_6 in SCCNN before and after cleaning

| 模型 | MSE | RMSE | MAE | R^2 |
|-----|--------|-------|-------|-------|
| 清洗前 | 12.781 | 3.575 | 1.563 | 0.188 |
| 清洗后 | 0.612 | 0.782 | 0.633 | 0.915 |

4.4 消融实验预测结果

为验证文章提出时空耦合卷积神经网络的有效性,设计消融对比实验,采用 LSTM、引入注意力机制的长短

尔逊系数及灰色关联分析法挖掘特征气体之间的复杂关联关系,选取皮尔逊相关系数 > 0.7 的特征气体作为空间特征模块的输入端,将数据分为训练集和测试集,测试

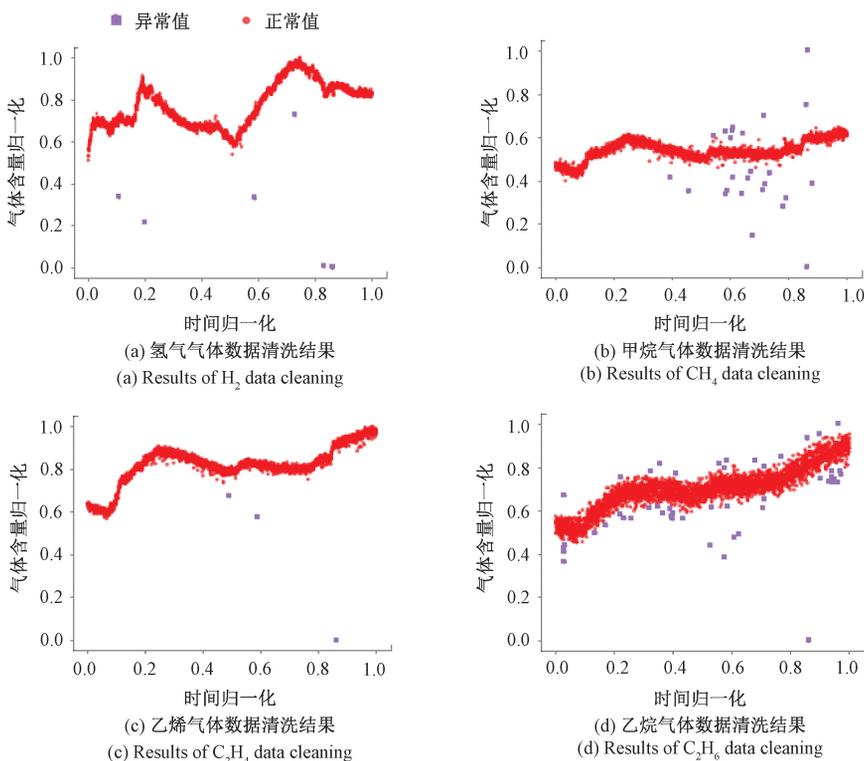


图 7 数据清洗效果

Fig. 7 Data cleaning effect diagram

记忆神经网络 (LSTM-Attention) 及 LSTM-CNN 3 种模型与本文提出模型对乙烷气体进行预测。由于油中溶解气体时间序列为一维数据, 本文设置时空耦合卷积神经网络中卷积层的卷积核为 2, 由于输入端采用前 11 个时刻的数据, 在空间特征挖掘模块设置卷积层数为 11 层, 采用 Adam 优化器, 学习率为 0.001。消融实验预测结果及评价指标如表 4、图 9 所示。

由图 9 可知, 本文提出的方法相较于 LSTM、LSTM-Attention、LSTM-CNN 的预测能力更强, 预测的曲线更贴合真实曲线。由表 4 可知, LSTM-Attention 模型引入注意力机制提高了预测精度, LSTM-CNN 通过考虑气体之间的关联关系同样提高了预测精度。本文所提 SCCNN 模型预测值与真实值均方误差、均方根误差、平均绝对误差更小, R^2 相较于原始 LSTM 模型提高了 0.124。

表 4 消融实验评价指标

Table 4 Evaluation indicators for ablation experiments

| 模型 | MSE | RMSE | MAE | R^2 |
|----------------|-------|-------|-------|-------|
| LSTM | 1.188 | 1.090 | 0.893 | 0.791 |
| LSTM-Attention | 0.750 | 0.866 | 0.699 | 0.905 |
| LSTM-CNN | 0.800 | 0.894 | 0.734 | 0.864 |
| SCCNN | 0.612 | 0.782 | 0.633 | 0.915 |

于不同的学习率, 时空耦合卷积神经网络对乙烷气体预测均方根误差、平均绝对误差如图 10 所示。

由图 10 可知, 学习率的大小影响模型预测性能。在学习率为 0.1 时, 模型学习不到油中溶解气体时空耦合变化特性, 导致无法做出预测误差较大。学习率从 0.01~0.00001 变化的过程中, 模型预测误差呈现先下降后上升现象, 在学习率为 0.001 时, 模型性能最佳。实验结果显示较大的学习率难以挖掘油中溶剂气体变化特性, 较小的学习率容易使网络模型陷入局部最优, 从而达到不到最优性能。

4.5 不同模型预测结果

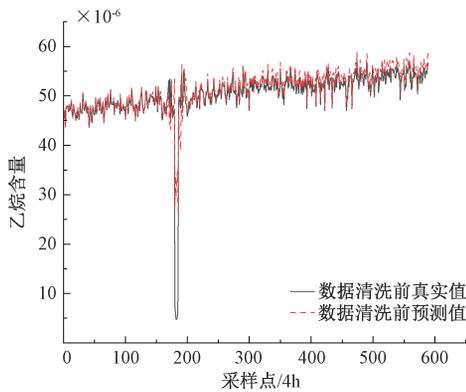
为了更好的说明本文所提模型的优势, 进一步验证所提模型的科学性与有效性, 采用应用广泛的 GRU 及先采用卷积神经网络挖掘关键特征, 再输入至长短记忆神经网络的油中溶解气体预测模型 CNN-LSTM 作为对比模型, 测试集预测结果与评价指标分别如表 5 和图 11 所示。

表 5 不同模型评价结果

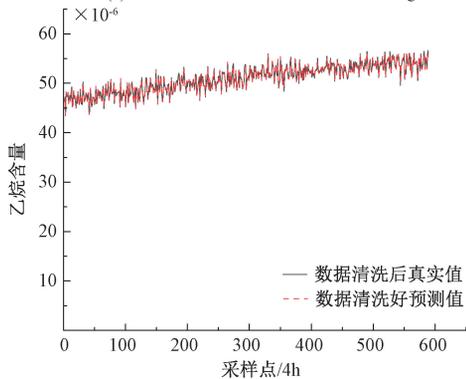
Table 5 Evaluation results of different models

| 模型 | MSE | RMSE | MAE | R^2 |
|----------|-------|-------|-------|-------|
| GRU | 1.045 | 1.022 | 0.833 | 0.895 |
| CNN-LSTM | 1.259 | 1.122 | 0.925 | 0.782 |
| SCCNN | 0.612 | 0.782 | 0.633 | 0.915 |

本文通过改变学习率大小分析模型的性能变化。基



(a) 数据清洗前预测结果
(a) Prediction results before data cleaning



(b) 数据清洗后预测结果
(b) Prediction results after data cleaning

图8 乙烷数据清洗前后预测结果

Fig. 8 Prediction results of C_2H_6 before and after cleaning

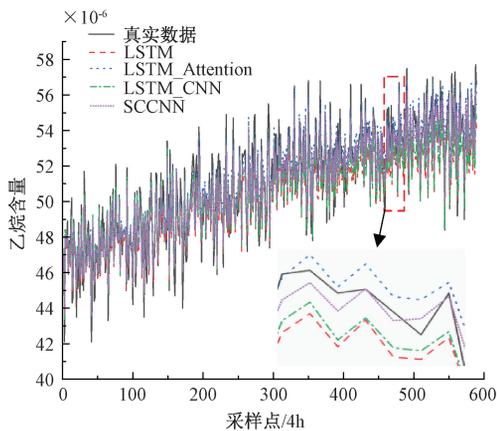


图9 消融实验预测结果

Fig. 9 Prediction results of ablation experiment

由图 11、表 5 可知,本文提出的时空耦合卷积神经网络预测曲线与真实曲线更加接近,预测精度更高, R^2 较 GRU 提高了 0.02, 相对 CNN-LSTM 提高了 0.133, 证明本文所提模型的科学性与有效性。

为验证方法的泛化性、稳定性及可靠性,采用 H_2 、

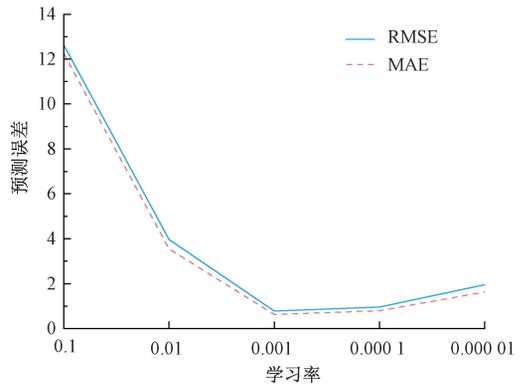


图10 不同学习率下模型预测误差

Fig. 10 Model prediction error at different learning rates

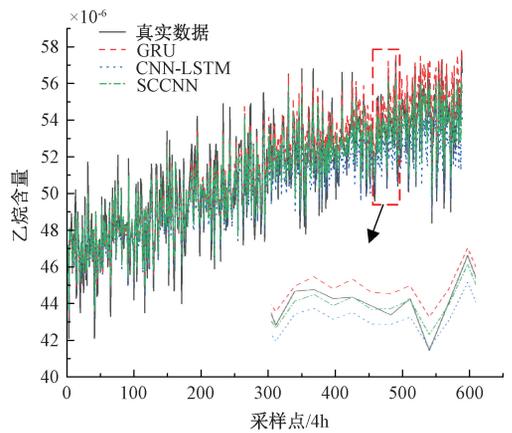


图11 不同模型实验预测结果

Fig. 11 Experimental prediction results of different models

CH_4 、 C_2H_2 、 CO 、 CO_2 气体, 预测结果如表 6 所示。

表6 其他油中溶解气体预测评价结果

Table 6 Evaluation results of other gases in transformer

| 预测气体 | 模型 | MSE | RMSE | MAE | R^2 |
|----------|----------|---------|--------|--------|-------|
| H_2 | GRU | 0.168 | 0.409 | 0.336 | 0.848 |
| | CNN-LSTM | 0.285 | 0.534 | 0.514 | 0.762 |
| | 本文 | 0.026 | 0.160 | 0.126 | 0.979 |
| CH_4 | GRU | 0.229 | 0.478 | 0.383 | 0.944 |
| | CNN-LSTM | 0.554 | 0.744 | 0.549 | 0.841 |
| | 本文 | 0.145 | 0.381 | 0.288 | 0.971 |
| C_2H_4 | GRU | 1.270 | 1.127 | 0.872 | 0.921 |
| | CNN-LSTM | 0.998 | 0.999 | 0.820 | 0.882 |
| | 本文 | 0.259 | 0.509 | 0.406 | 0.975 |
| CO | GRU | 1.997 | 1.413 | 1.074 | 0.983 |
| | CNN-LSTM | 6.540 | 2.557 | 2.321 | 0.933 |
| | 本文 | 0.474 | 0.689 | 0.578 | 0.996 |
| CO_2 | GRU | 150.986 | 12.288 | 11.196 | 0.866 |
| | CNN-LSTM | 206.278 | 14.362 | 11.720 | 0.773 |
| | 本文 | 32.684 | 5.717 | 4.700 | 0.971 |

由表 6 可知,本文所提方法在其他 5 种油中溶解气

体时间序列预测中保持良好的性能,均取得了最佳的预测结果,特征气体的预测结果评价指标中 R^2 都大于 0.95,说明本文多提模型适用于不同的数据样本,具有更强的泛化能力。

5 总 结

为提升变压器油中溶解气体预测准确性,文章提出融合基于 DBSCAN 数据清洗模型及 SCCNN 预测模型。采用自适应非线性权重策略及莱维飞行策略改进鲸鱼优化算法,提高鲸鱼优化算法的局部与全局寻优能力,寻找 DBSCAN 最优超参数,克服 DBSCAN 超参数选择难题,实现变压器油中溶解气体数据清洗。采用 SCCNN 挖掘不同气体成分间的复杂关联关系及时间维度变化规律,考虑油中溶解气体时空特性,提取提高模型的预测精度。

实验结果表明经过 DBSCAN 清洗的数据预测结果相较于清洗前平均绝对误差下降了 0.93,拟合优度提高了 0.727,说明 DBSCAN 有效检测了异常值,增强数据质量能够提高预测精度。SCCNN 相较于其他模型预测结果误差最小,拟合优度最大,预测结果更贴合真实数据说明模型的有效性,且在所有 6 种特征气体中的预测结果均为最佳,拟合优度都保持在 0.9 以上,验证所提模型的强泛化性。

海上风能资源丰富稳定,全球风电开发呈现由陆上向海上发展的趋势。变压器作为海上风电远程监测的关键设备,其状态参量在采集、传输过程中存在丢失和异常现象,导致变压器状态评估、故障预警准确率下降。本文所提方法为变压器故障诊断提供完整、精确、可靠的数据支撑,为风险预警奠定良好基础。后续将重点研究海上风电变压器故障状态演变及风险预警相关内容。

参考文献

[1] 刘亚东, 严英杰, 严波, 等. 电力装备内部状态反演重构研究框架与应用展望[J]. 高电压技术, 2022, 48(8): 2883-2896.
LIU Y D, YAN Y J, YAN B, et al. Framework and application prospect of internal state inversion and reconstruction of power equipment [J]. High Voltage Engineering, 2022, 48(8): 2883-2896.

[2] ZHANG Y, CHEN H, DU Y, et al. Early warning of incipient faults for power transformer based on DGA using a two-stage feature extraction technique [J]. IEEE Transactions on Power Delivery, 2022, 37 (3): 2040-2049.

[3] ABBASI A R. Fault detection and diagnosis in power transformers; A comprehensive review and classification of publications and methods[J]. Electric Power Systems

Research, 2022, 209(1): 107990.

[4] 齐波, 冀茂, 郑玉平, 等. 电力物联网技术在输变电设备状态评估中的应用现状与发展展望[J]. 高电压技术, 2022, 48(8): 3012-3031.
QI B, JI M, ZHENG Y P, et al. Application status and development prospect of power internet of things technology in condition assessment of power transmission and transformation equipment [J]. High Voltage Engineering, 2022, 48(8): 3012-3031.

[5] 齐波, 张鹏, 张书琦, 等. 数字孪生技术在输变电设备状态评估中的应用现状与发展展望[J]. 高电压技术, 2021, 47(5): 1522-1538.
QI B, ZHANG P, ZHANG SH Q, et al. Application status and development prospects of digital twin technology in condition assessment of power transmission and transformation equipment [J]. High Voltage Engineering, 2021, 47(5): 1522-1538.

[6] 廖才波, 杨鑫鑫, 邱志斌, 等. 基于缺失数据填补的油浸式变压器故障诊断[J]. 高电压技术, 2024, 50(9): 4091-4100.
LIAO C B, YANG J X, QIU ZH B, et al. Fault diagnosis method for oil-immersed transformer based on missing data imputation[J]. High Voltage Engineering, 2024, 50(9): 4091-4100.

[7] 齐波, 张鹏, 荣智海, 等. 基于数据驱动和多判据融合的油色谱监测传感器有效性评估方法[J]. 电网技术, 2017, 41(11): 3662-3669.
QI B, ZHANG P, RONG ZH H, et al. Validity assessment method of DGA sensors based on data driven and multiple criterion integration [J]. Power System Technology, 2017, 41(11): 3662-3669.

[8] 朱有产, 梁玮轩, 王英姿. 基于时间序列的配电网数据清理和融合方法研究[J]. 电网技术, 2021, 45(7): 2839-2846.
ZHU Y CH, LIANG W X, WANG Y Z. Research on data cleaning and fusion in distribution power grid based on time series technology[J]. Power System Technology, 2021, 45(7): 2839-2846.

[9] 刘云鹏, 许自强, 李刚, 等. 人工智能驱动的数据分析技术在电力变压器状态检修中的应用综述[J]. 高电压技术, 2019, 45(2): 337-348.
LIU Y P, XU Z Q, LI G, et al. Review on applications of artificial intelligence driven data analysis technology in condition based maintenance of power transformers [J]. High Voltage Engineering, 2019, 45(2): 337-348.

[10] 严英杰, 盛戈峰, 刘亚东, 等. 基于滑动窗口和聚类算法的变压器状态异常检测[J]. 高电压技术, 2016, 42(12): 4020-4025.

- YAN Y J, SHENG G H, LIU Y D, et al. Anomalous state detection of power transformer based on algorithm sliding windows and clustering [J]. *High Voltage Engineering*, 2016, 42(12): 4020-4025.
- [11] 杜江, 范志远, 范仲华, 等. 电力变压器油中溶解气体异常数据识别与含量预测研究[J]. *电网技术*, 2025, 49(2): 844-853.
- DU J, FAN ZH Y, FAN ZH H, et al. Research on abnormal data identification and content prediction of dissolved gas in power transformer oil[J]. *Power System Technology*, 2025, 49(2): 844-853.
- [12] 孟令雯, 张锐锋, 李鑫卓, 等. 基于机器学习的变电站设备异常状态数据清洗[J]. *电力系统及其自动化学报*, 2021, 33(12): 79-86.
- MENG L W, ZHANG R F, LI X ZH, et al. Cleaning abnormal status data of substation equipment based on machine learning [J]. *Proceedings of the CSU-EPSA*, 2021, 33(12): 79-86.
- [13] SUN D, XUE S, WU H, et al. A data stream cleaning system using edge intelligence for smart city industrial environments [J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(2): 1165-1174.
- [14] 马宏忠, 肖雨松, 孙永腾, 等. 基于 ICEEMDAN 和时变权重集成预测模型的变压器油中溶解气体含量预测[J]. *高电压技术*, 2024, 50(1): 210-220.
- MA H ZH, XIAO Y S, SUN Y T, et al. Prediction of dissolved gas concentration in transformer oil based on ICEEMDAN and time-varying weight integrated prediction Model[J]. *High Voltage Engineering*, 2024, 50(1): 210-220.
- [15] 谢明浩, 张林鎔, 董小刚, 等. 基于 OVMD-HWOA-KELM 模型的变压器油中溶解气体体积分数预测方法[J]. *高电压技术*, 2024, 50(8): 3793-3807.
- XIE M H, ZHANG L X, DONG X G, et al. Prediction method of dissolved gas volume fraction in transformer oil based on OVMD-HWOA-KELM model[J]. *High Voltage Engineering*, 2024, 50(8): 3793-3807.
- [16] ZENG W, CAO Y, FENG L, et al. Hybrid CEEMDAN-DBN-ELM for online DGA serials and transformer status forecasting[J]. *Electric Power Systems Research*, 2023, 217(1): 109176.
- [17] XING Z, HE Y, WANG X, et al. VMD-IARIMA-based time-series forecasting model and its application in dissolved gas analysis [J]. *IEEE Transactions on Dielectrics and Electrical Insulation*, 2023, 30(2): 802-811.
- [18] 周亚中, 何怡刚, 邢致恺, 等. 基于 IDBO-ARIMA 的电力变压器振动信号预测[J]. *电子测量与仪器学报*, 2023, 37(8): 11-20.
- ZHOU Y ZH, HE Y G, XING ZH K, et al. Power transformer vibration signal prediction based on IDBO-ARIMA [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(8): 11-20.
- [19] ZHONG M, CAO Y, HE G, et al. Dissolved gas in transformer oil forecasting for transformer fault evaluation based on HATT-RLSTM [J]. *Electric Power Systems Research*, 2023, 221(1): 109431.
- [20] 杨童亮, 胡东, 唐超, 等. 基于 SMA-VMD-GRU 模型的变压器油中溶解气体含量预测[J]. *电工技术学报*, 2023, 38(1): 117-130.
- YANG T L, HU D, TANG CH, et al. Prediction of dissolved gas content in transformer oil based on SMA-VMD-GRU model [J]. *Transactions of China Electrotechnical Society*, 2023, 38(1): 117-130.
- [21] 范志远, 杜江. 基于相关变分模态分解和 CNN-LSTM 的变压器油中溶解气体体积分数预测[J]. *高电压技术*, 2024, 50(1): 263-273.
- FAN ZH Y, DU J. Prediction of dissolved gas volume fraction in transformer oil based on correlation variational mode decomposition and CNN-LSTM[J]. *High Voltage Engineering*, 2024, 50(1): 263-273.
- [22] 杨威, 蒲彩霞, 杨坤, 等. 基于 CNN-GRU 组合神经网络的变压器短期故障预测方法[J]. *电力系统保护与控制*, 2022, 50(6): 107-116.
- YANG W, PU C X, YANG K, et al. Short-term fault prediction method for a transformer based on a CNN-GRU combined neural network [J]. *Power System Protection and Control*, 2022, 50(6): 107-116.
- [23] 李启明, 李彬, 刘浩, 等. 基于自监督预训练与时序注意力机制的变压器顶层油温预测[J]. *中国电机工程学报*, 2024, 44(S1): 318-331.
- LI Q M, LI B, LIU H, et al. Transformer top oil temperature prediction based on self-supervised pre-training and time-series attention mechanism [J]. *Proceedings of the CSEE*, 2024, 44(S1): 318-331.
- [24] 刘展程, 王爽, 唐波. 基于 SSA-BiGRU-Attention 模型的变压器油中溶解气体含量预测[J]. *高电压技术*, 2022, 48(8): 2972-2981.
- LIU ZH CH, WANG SH, TANG B. Prediction of dissolved gas content in transformer oil based on SSA-BiGRU-Attention model [J]. *High Voltage Engineering*, 2022, 48(8): 2972-2981.
- [25] LUO D, FANG J, HE H, et al. Prediction for dissolved gas in power transformer oil based on TCN and GCN [J]. *IEEE Transactions on Industry Applications*, 2022, 58(6): 7818-7826.

- [26] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95(1): 51-67.
- [27] LEWIS Z M, WILD J A, ALLCOCK M, et al. Assessing the impact of weak and moderate geomagnetic storms on UK power station transformers [J]. Space Weather-the International Journal of Research and Applications, 2022, 20(4), DOI: 10.1029/2021SW003021.

作者简介



李紫豪, 2020 年于合肥工业大学获得学士学位, 现为武汉大学电气与自动化学院博士研究生, 主要研究方向为电力变压器故障诊断及状态评估。

E-mail: zihaoli1209@whu.edu.cn

Li Zihao received his B. Sc. degree from Hefei University of Technology in 2020. Now he is a Ph. D. candidate at Wuhan University. His main research interests

include fault diagnosis and status assessment of the power transformers.



何怡刚(通信作者), 1992 年于湖南大学获得硕士学位, 1996 年于西安交通大学获得博士学位, 现为武汉大学二级教授, 国家杰出青年基金获得者, 主要研究方向为能源装备状态监测、电力电子电路理论及其应用等。

E-mail: yghe1221@whu.edu.cn

He Yigang (Corresponding author) received his M. Sc. degree from Hunan University in 1992, and Ph. D. degree from Xian Jiaotong University in 1996. Now he is a second level professor at Wuhan University and a winner of the national science fund for distinguished young scholars. His main research interests include condition monitoring of energy equipment, power electronic circuit theory and its applications, etc.