

基于油中溶解气体分析的变压器故障预测

王清泉 贾喜龙 白旭

北京惠通盛电力工程有限责任公司房山分公司 北京市 102488

摘要: 在电气系统中, 变压器是最重要的大型电气装置之一。变压器的可靠运行也是保证电网整体稳定的重要环节。近年来, 随着我国经济的快速发展和能源需求的逐年增加, 紧张程度越高, 体积越大, 就成为变压器发展的必然趋势。因此, 如何提高变压器的安全性, 保证其可靠运行具有重要意义。目前, 以故障诊断技术为核心的变压器状态维修, 是保证变压器稳定运行的重要手段。油中溶解气体分析(DGA)法能够在线实时监测变压器油中的气体数据, 在国内外得到了广泛的应用。

关键词: 油中溶解气体; 分析; 变压器; 故障预测

Transformer fault prediction based on dissolved gas analysis in oil

Wang Qingquan, Jia Xilong, Bai Xu

Fangshan Branch of Beijing huitongsheng Power Engineering Co., Ltd. 102488, Beijing

Abstract: In the electrical system, transformer is one of the most important large-scale electrical devices. The reliable operation of transformer is also an important link to ensure the overall stability of power grid. In recent years, with the rapid development of China's economy and the increase of energy demand year by year, the higher the tension and the larger the volume, it has become the inevitable trend of transformer development. Therefore, how to improve the safety of transformer and ensure its reliable operation is of great significance. At present, transformer condition based maintenance with fault diagnosis technology as the core is an important means to ensure the stable operation of transformer. Dissolved gas analysis (DGA) method can monitor the gas data in transformer oil online and in real time, and has been widely used at home and abroad.

Key words: Dissolved gas in oil; analysis; transformer; Fault prediction

预测变压器的潜在故障对评估变压器的健康状况非常重要。提出了一种新的变压器故障预测方法。首先, 建立了基于LSTM网络的时间注意力机制预测框架, 并利用ialo算法对其参数进行了优化; 其次, 利用优化模型预测变压器油中的溶解气体; 然后利用MPA算法优化的SVM模型对瓦斯预测结果进行故障诊断; 最后对诊断结果进行统计, 并与实际运行状态进行比较, 验证模型的正确性。实验结果表明, 在第42~58天内, 异常运行条件的最大数量为29个, 未来两个月内异常运行的概率为86.89%, 其中中温过热故障所占比例最高, 为88.67%, 与实际情况的误差仅为2.46%和1.29%。预测结果与实际运行情况吻合较好, 证明了该方法在准确预测变压器运行状态异常时间点和故障类型方面的可行性。

1 变压器油中气体产生机理及常见故障

目前, 电力系统中的变压器一般都属于油浸式结构。在日常运行过程中, 由于损耗, 变压器中的绝缘材料会老化和分解, 并在这一过程中产生气体, 主要包括甲烷(CH_4)、乙烷(C_2H_6)、乙烯(C_2H_4)、乙炔(C_2H_2)、氢气(H_2)和其他碳氢化合物二氧化碳(CO_2)和一氧化碳(CO), 其

中大部分可溶于变压器油。此外, 如果变压器中存在潜在故障, 上述气体的生成速度将加快, 且含量将随着故障的发展逐渐增加, 最终因超过溶解极限而释放。

变压器油中溶解气体分析(DGA)在实际应用中是一种成熟的故障诊断方法。它主要从变压器内部提取油样, 然后通过脱气法获得样品中的气体, 最后通过油色谱实验分析得到的混合气体的成分和含量, 从而实现变压器故障类型的识别。DGA具有在线监测、精度高等优点, 在工程中得到了广泛的应用。

2 理论基础

2.1 IALO算法优化的时间注意力机制LSTM网络

注意力机制是模仿生物观察行为, 从数据中提取重要特征。它在自然语言处理、图像识别、数据预测等领域有着广泛的应用。本文的注意力机制框架以LSTM网络为载体, 建立编码器和解码器。

2.1.1 长短时记忆网络

LSTM在循环神经网络(RNN)的基础上, 增加了选通单元来代替隐藏单元, 缓解了梯度爆炸问题, 实现了信息的

选择性传输和长期存储。其单元结构如图1所示。

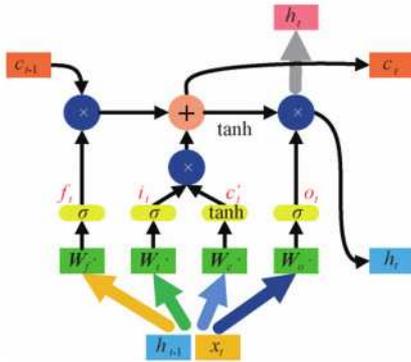


图1 LSTM 单元结构

LSTM网络的每个单元包含三种状态：遗忘门、输入门和输出门。建模过程如等式(1)~(6)所示。

$$\begin{aligned}
 f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) & (1) \\
 i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) & (2) \\
 c'_t &= \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) & (3) \\
 c_t &= f_t * c_{t-1} + i_t * c'_t & (4) \\
 o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) & (5) \\
 h_t &= o_t * \tanh(c_t) & (6)
 \end{aligned}$$

式(1)~(6)中: f_t 、 i_t 和 o_t 分别是遗忘门、输入门和输出门的计算结果, c'_t 是输入单元状态, W_f 、 W_i 、 W_c 和 W_o 是权重矩阵, b_f 、 b_i 、 b_c 和 b_o 是相应的偏置。 σ 是sigmoid激活函数, $\tanh()$ 是双曲正切激活函数, 符号*表示元素相乘。

LSTM的训练过程是通过输出误差函数不断更新网络的超参数, 通常依靠经验法设置各参数初始值, 多次训练不断调整, 这具有很强的不确定性, 而且模型无法达到理想的精度要求。

2.1.2 IALO算法优化的LSTM网络

ALO算法通过模拟蚁狮狩猎机制来优化神经网络超参数, IALO算法是在ALO算法的基础上引入莱维飞行算法扩大目标搜索范围, 提高模型优化性能。IALO算法对LSTM网络的优化过程如步骤(1)~(9)所示。

(1)设置LSTM网络隐层神经元个数 N 、学习率 lr 、训练次数 E 和步长 γ , 将其作为蚂蚁和蚁狮的初始位置;

(2)确定最大迭代次数和种群规模, 设置陷阱, 每只蚂蚁只被一个蚁狮陷阱吸引, 在优化过程中蚂蚁根据适应度值转盘选择蚁狮;

(3)利用莱维飞行算法扩大搜索范围, 更新蚂蚁位置;

$$X_j^{t+1} = X_j^t + \alpha \oplus Levy(s) \quad (7)$$

式中: α 是常数, \oplus 是点积, $s = \mu / |\nu|^{1/\beta}$ 是步长, $\nu \sim N(0, \sigma \nu 2)$, $\mu \sim N(0, \sigma \mu 2)$, $\beta \in (0, 2]$ 。

(4)根据初始化参数建立并训练LSTM网络模型, 将训练结果平均绝对误差作为优化目标函数, 计算相应蚁狮的适应度;

$$X(N, lr, E, \gamma) = f\left(\frac{1}{k} \sum_{i=1}^k (y_i - \hat{y}_i)\right) \quad (8)$$

式中: f 为适应度函数, k 是训练样本个数, y_i 、 \hat{y}_i 是实际值和预测值, $X(N, lr, E, \gamma)$ 为蚁狮适应度。

(5)进入陷阱, 蚁狮陷阱会影响蚂蚁随机游走;

$$\begin{cases} c'_j = Antlion_j^t + c^t \\ d'_j = Antlion_j^t + d^t \end{cases} \quad (9)$$

式中: $Antlion_j^t$ 为第 t 次迭代时第 j 个蚁狮的位置, c'_j 、 d'_j 代表第 t 次迭代变量中的最小值和最大值。

(6)捕捉蚂蚁, 蚂蚁落入陷阱后被蚁狮追踪, 随迭代次数增加游走范围上限 d^t 和下线 c^t 减小;

$$\begin{cases} c^t = \frac{c^t}{I} \\ d^t = \frac{d^t}{I} \end{cases} \quad (10)$$

式中: I 是比率, t 是当前迭代次数。

(7)精英化, 当蚂蚁适应度大于蚁狮适应度时蚂蚁被捕, 更新蚁狮适应度获得当前最优参数;

(8)根据转盘的平均值和精英蚁狮的移动来更新蚂蚁位置;

$$Ant_i^t = \frac{R_A^t + R_E^t}{2} \quad (11)$$

式中: R_A^t 和 R_E^t 分别表示在第 t 次迭代时蚂蚁围绕蚁狮和精英蚁狮游走的位置。

(9)当蚁狮适应度不再更新或达到最大迭代次数时停止优化, 获得最优网络参数 N 、 lr 、 E 和 γ 。

2.1.3 时间注意力机制LSTM网络

本文设计的时间注意力机制LSTM网络的超参数均由IALO算法优化所得, 其结构如图2所示。

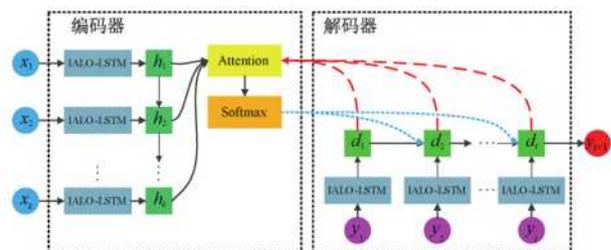


图2 时间注意力机制 LSTM 网络

首先编码阶段采用LSTM单元完成输入序列 x_k 到隐层状态 h_k 的映射。然后结合解码器 $t-1$ 时刻隐层状态 d_{t-1} , 通过注意力层对编码器的隐层状态 h_k 分配权重, 并加权求和得到中间向量 c_t 。解码阶段采用LSTM单元把 t 时刻目标序列的测量值 y_t 与中间向量 c_t 融合得出 t 时刻的隐层状态 d_t , 循环迭代计算最终时刻 d_T 。最后经单层前馈网络将 c_T 和 d_T 融合得出目标序列的预测值。

时间注意力机制LSTM网络建模过程如式(12)~(18)所示。

$$h_k = f_{LSTM}(h_{k-1}, x_k) \quad (12)$$

$$e_i^t = V_e^T \tanh(W_e[d_{i-1}, s_{i-1}] + U_e h_k) \quad (13)$$

$$\beta_i^t = \text{softmax}(e_i^t) = \frac{\exp(e_i^t)}{\sum_{j=1}^T \exp(e_j^t)} \quad (14)$$

$$c_i = \sum_{k=1}^T \beta_i^t h_k \quad (15)$$

$$y_i' = \omega' [y_i, c_i] + b' \quad (16)$$

$$d_i = f_{LSTM}(d_{i-1}, y_i') \quad (17)$$

$$V_y^T(W_T[d_T, c_T] + b_T) + b_y \quad (18)$$

式(12)~(18)中: V_e 、 W_e 和 U_e 为多层感知机权重, ω' 和 W_T 是单层前馈网络的权重, b' 和 b_T 是相应的偏置, V_y 和 b_y 进行前馈网络维度变换的权重和偏置。

2.2 MPA算法优化的SVM模型

SVM是一种具有优异泛化能力的机器学习方法, 对于任何二元分类问题可表示为 $\{(x_i, y_i), i=1, 2, \dots, n\}$, 其中 x_i 为模型训练集的输入, y_i 为训练集的输出。

为保证分类精度, 需确定一个最优分类超平面, 其表达式如式(19)所示

$$\omega^T x + b = 0 \quad (19)$$

式中: ω 是权值矢量, x 是输入变量, b 是阈值。

当样本数据为非线性时, 分类问题的表示如式(20)所示。

$$\begin{aligned} \min_{\omega, b} \quad & \frac{\|\omega\|^2}{2} + C \sum_{i=1}^n \xi_i \\ \text{s. t.} \quad & y_i(\omega^T x_i + b) \geq 1 - \xi_i, \\ & \xi_i \geq 0, i = 1, 2, \dots, n \end{aligned} \quad (20)$$

式中: C 是惩罚因子, ξ_i 是松弛变量。

当输入数据为非线性时, 需引入核函数($K(x_i, x_j) = \phi(x_i) \phi(x_j)$)将样本 x 映射到更高维空间并进行线性样本的分割, 求解得到最优决策函数:

$$f(x) = \text{sgn}\left[\sum_{i=1}^n y_i \alpha_i K(x_i, x_j) + b\right] \quad (21)$$

式中: α_i 和 b 分别代表拉格朗日系数、分类阈值, $\text{sgn}()$ 为整型变量函数。

SVM的性能主要取决于惩罚参数 C 和核参数 σ 。MPA算法是一种基于莱维运动和布朗运动相结合的新型参数优化算法, 改善了传统优化算法收敛速度慢和易陷入局部最优的问题。如步骤1)~5)所示MPA算法对SVM模型参数优化过程

- 1)输入训练集和测试集, 对样本进行归一化;
- 2)初始化SVM模型和MPA算法的参数, 设置种群大小、迭代次数和参数维度;
- 3)获取捕食者的初始位置, 并设置分类准确率为目标优化函数;
- 4)进行迭代优化更新猎物位置, 计算新位置的适应度, 并将新值与原值进行比较确定当前最优位置;

5)若已取得全局最大适应度或完成最大迭代次数, 输出全局最优参数组合(C, σ), 否则继续迭代寻优。

3 变压器故障预测建模

本文所提变压器故障预测方法流程如图3所示, 主要分为溶解气体浓度预测、变压器故障诊断、故障发生几率统计与分析3个模块。

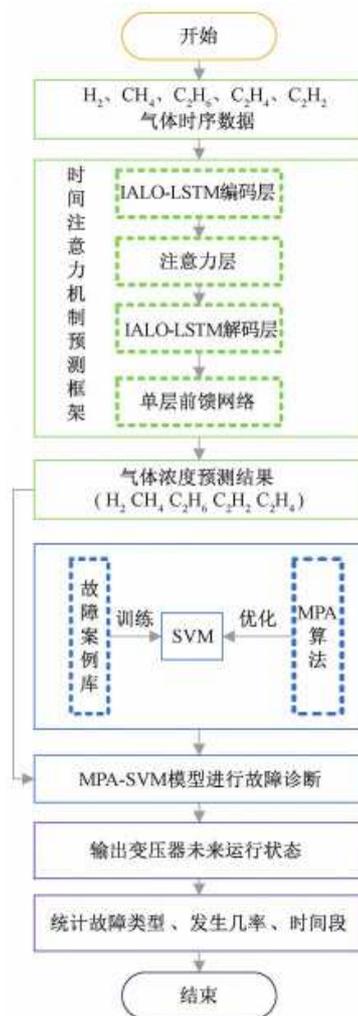


图3 变压器故障预测流程

首先, 针对溶解气体时序数据的非线性和非平稳性, 建立基于LSTM载体的注意力机制预测框架, 同时采用IALO算法确定网络最佳参数, 使用优化的模型对变压器油中溶解气体进行预测。

由于变压器故障诊断属于多分类问题, 本文基于二叉树原理建立多层二分类SVM故障诊断模型。结合IEC60599标准和现有数据集, 将变压器运行状态分为7类, 包括:健康状态、局部放电、低能放电(火花放电)、高能放电(电弧放电)、低温过热、中温过热和高温过热, 采用MPA算法优化的SVM模型在现有的528组变压器故障案例数据集上训练和测试模型, 最后使用测试后的SVM模型对溶解气体预测结果进行故障诊断。

最后, 统计并分析变压器故障发生的几率大小, 时间段

以及具体的故障类型, 与实际运行情况对比验证。

4 算例分析

实验采用某220kV电力变压器在2020年1~10月的油中溶解气体采样数据, 通过油色谱在线检测装置每12个小时对H₂、CH₄、C₂H₆、C₂H₄和C₂H₂的浓度记录一次。监测数据显示该变压器在运行期间内H₂和CH₄的含量逐渐升高, 但H₂含量未超过氢烃的27%, 溶解气体中含有少量的C₂H₂, 且C₂H₂含量超过C₂H₄含量的10%, 根据油中溶解气体分析和判断导则, 初步评估该变压器存在过热性故障的可能性最大。采用2020年1~8月的溶解气体数据集训练模型, 并预测未来2个月的溶解气体发展趋势。平均绝对百分比误差(MAPE)和拟合优度检验(R²)被用于评估所提模型预测效果, 定义如式(22)~(23)所示。

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (22)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (23)$$

式(22)~(23)中: y_i 和 \hat{y}_i 分别是测试集的实际值和预测值, \bar{y} 是 y_i 的平均值, n 是测试集样本长度。

4.1 油中溶解气体浓度的预测

自适应动量Adam优化器用于自动更新LSTM网络的权值, 包括初始隐层神经元 n 、学习率LR、训练次数E和LSTM网络步长 γ , 范围为[10, 100]、[0.001, 0.1]、[10, 150]、[1, 100]; ialo算法中蚂蚁和蚂蚁狮子的种群规模为50, 最大迭代次数为100, 常数 β 为1.5。

参数优化结果如下: 隐层神经元数为20个, 学习率为0.073, 训练次数为112次, 步长为15。变压器油中溶解气体浓度的预测效果如图4所示。在相同条件下, 建立了LSTM、alo LSTM和ialo LSTM预测模型, 比较了本文提出的模型的预测效果。预测误差评估结果如表1所示。以氢气浓度预测为例, 比较了不同模型对未来15d、30d、45d和61D的预测精度。比较结果如表2所示。

从图4可以看出, H₂和CH₄气体的预测趋势是先下降后上升, 而C₂H₆、C₂H₄和C₂H₂气体在未来两个月内呈下降趋势, 这与溶解气体的实际发展相一致, 结果表明, 本文提出的方法能够准确预测不同特征气体的发展趋势。误差分析表明, 采用ialo算法优化的LSTM网络的预测误差明显小于LSTM和alo-LSTM网络, 表明ialo算法比传统的alo算法具有更有效的模型参数优化能力。对不同时间尺度下预测结果的误差分析表明, 当预测时间从15d增加到30d时, 所有模型的预测误差都会增加。LSTM网络的预测误差增幅最大, 从2.9097%增加到3.9689%, 但该方法的预测误差增幅最小, 仅为0.0611%; 当预测持续时间增加到61D时, 时间注意机制LSTM网络的拟合优度检验指数最大, 对特征气体整体发展趋势的预测效果最好, 而无注意机制的ialo LSTM网络的拟合

优度检验指数下降了4.71%, 高于该方法的1.93%, 表明对于具有强非线性和非平稳性的时间序列, 时间注意机制可以提高LSTM网络对不同时间尺度特征的学习能力, 增强时间序列中关键点信息的表达, 使预测模型在短期、中期和长期预测中保持较高的预测精度和趋势预测效果。

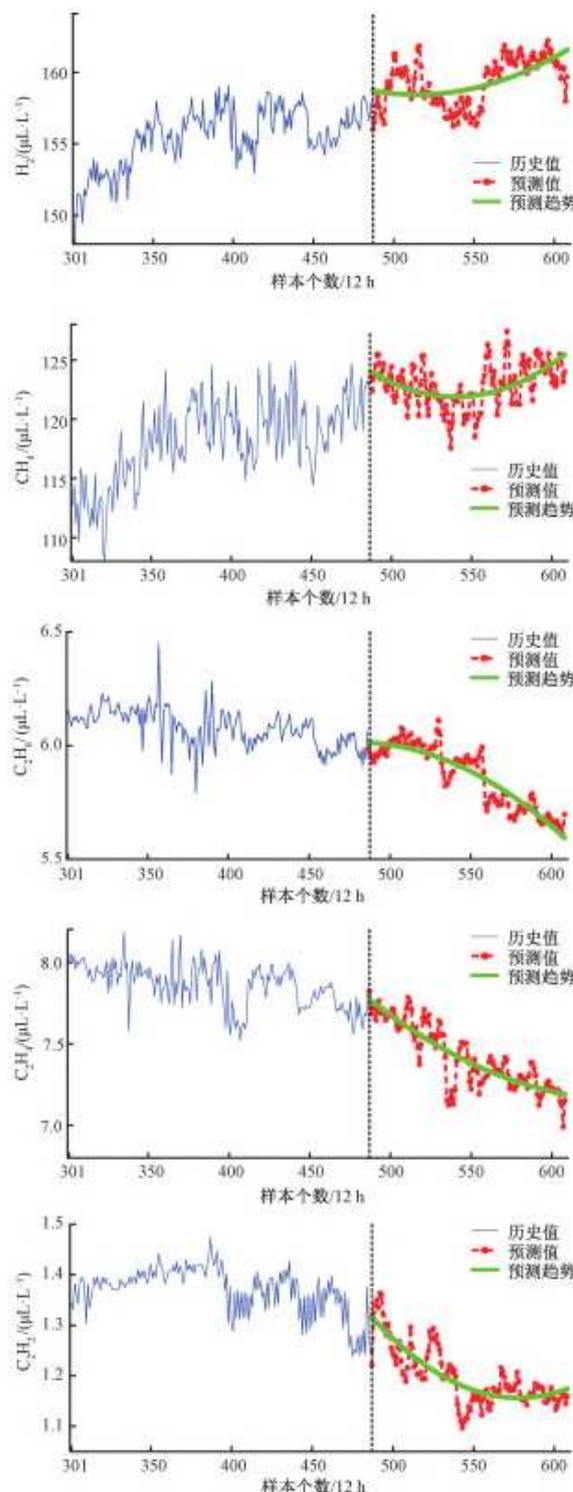


图4 变压器油中溶解气体浓度预测效果

4.2 变压器故障预测

在变压器故障预测之前, 使用528组带有变压器运行状

态标签的油中溶解气体数据集对SVM分类模型进行训练和测试, 包括154组健康状态、50组局部放电、45组低能放电、68组高能放电、, 低温过热57组, 中温过热81组, 高温过热73组。使用MPa算法优化SVM模型, 选择高斯核函数、惩罚因子C和核参数作为核函数 σ , 搜索的上限和下限设置为[10-2, 102], MPa算法的最大迭代次数为100次, 种群规模为30, 影响系数为0.2, 常数P为0.5。

为了验证所提出的分类模型的有效性^[1], 在同一数据集下建立了wpa-svm模型、PSO-svm模型和svm模型, 其中wpa算法的最大迭代次数为100次, 种群规模为50, 更新比例系数为 50β 为6; PSO算法的最大迭代次数为100次, 种群规模为50, 惯性权重分别为0.9和0.6。优化算法在不同迭代下的适应度曲线如图5所示。

从图5可以看出, WPA算法和PSO算法在参数优化过程中最终停止收敛的迭代次数大于MPA算法, 由于搜索空间的多样性损失, 算法陷入局部优化, MPA算法的最终适应度最大^[2], 表明MPA算法可以缓解传统优化算法在参数优化中容易陷入局部最优的问题。

表3给出了各型号试验装置中158组变压器分类精度的比较结果。结果表明, MPA算法优化后的SVM模型分类精

度最高, 为95.57%, 分别比WPA算法和PSO算法高2.53%和7.60%, 与未优化的SVM相比, 最显著的改进为12.66%, 结果表明, MPa算法在参数优化方面的性能最好^[3]。因此, 本文将mpa-svm分类模型用于变压器故障预测。

将时间注意机制LSTM网络预测的122组变压器油中溶解气体数据输入训练好的mpa-svm模型进行故障诊断。诊断结果如表4所示。结果表明, 在上述预测的122组数据中, 故障数从第17组逐渐增加, 而第84组和第115组之间的最大故障数为29。^[4]在预测的两个月时间内, 106组故障总数占86.89%, 其中中温过热故障比例最高为88.67%, 其次, 预测低温过热故障和高温过热故障的发生率分别为6.62%和3.77%, 放电故障的次数至少为一次。因此, 确定变压器在2020年9月至10月期间极有可能出现中温过热故障。根据工作人员的记录, 实时监控平台在2020年9月中旬开始多次报警, 十月中旬和十月的报警次数最多。经现场调查, 发现变压器过热运行。监测记录数据显示, 异常运行占84.43%, 中温过热故障占87.38%, 预测结果与实际情况的误差仅为2.46%和1.29%, 与变压器的实际运行状态吻合较好, 结果表明, 该方法能准确预测变压器异常运行状态的时间周期和故障概率^[5]。

表 1 各模型预测结果评估指标

气体类型	MAPE/%				R ²			
	LSTM	ALO-LSTM	IALO-LSTM	本文方法	LSTM	ALO-LSTM	IALO-LSTM	本文方法
H ₂	3.968 9	3.019 1	2.155 4	0.505 6	0.799 7	0.895 9	0.902 6	0.942 6
CH ₄	4.014 1	2.711 7	1.383 6	0.471 9	0.744 9	0.847 5	0.916 1	0.930 9
C ₂ H ₄	3.758 0	3.144 5	2.017 3	0.420 3	0.720 1	0.802 5	0.898 6	0.949 1
C ₂ H ₂	4.679 3	2.738 3	1.964 7	0.947 3	0.698 8	0.785 5	0.824 7	0.888 0
C ₂ H ₆	3.330 2	2.505 6	1.905 9	0.609 1	0.707 5	0.816 7	0.881 9	0.937 1

表 2 各模型对不同时间尺度预测结果评估

预测时长/ d	MAPE/%				R ²			
	LSTM	ALO-LSTM	IALO-LSTM	本文方法	LSTM	ALO-LSTM	IALO-LSTM	本文方法
15	2.909 7	1.884 4	1.491 9	0.058 2	0.875 4	0.933 4	0.949 7	0.970 4
30	3.379 2	2.030 6	1.521 9	0.119 3	0.833 2	0.922 6	0.920 6	0.957 4
45	3.635 4	2.485 3	1.705 4	0.160 4	0.816 1	0.904 5	0.911 7	0.948 5
61	3.968 9	3.019 1	2.155 4	0.505 6	0.799 7	0.895 9	0.902 6	0.942 6

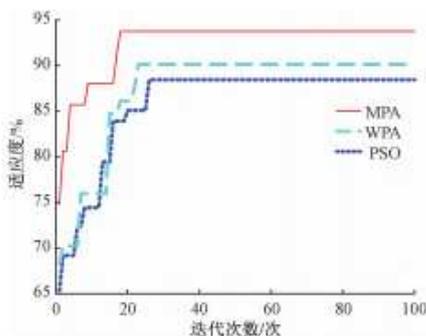


图 5 优化算法参数寻优迭代曲线

表 4 变压器故障诊断结果

运行状态	实际	实际故障	诊断	诊断故障类
	结果/次	类型占比/%	结果/次	型占比/%
正常状态	19	—	16	—
局部放电	0	0	0	0
低能放电	0	0	1	0.94
高能放电	0	0	0	0
低温过热	8	7.76	7	6.62
中温过热	90	87.38	94	88.67
高温过热	5	4.86	4	3.77
故障比例/%	84.43	—	86.89	—

表3 不同模型分类结果对比

模型	正确 分类/组	准确率/ %	参数设置/ (C,σ)	训练 用时/s
MPA-SVM	151	95.57	[15.732 5,0.014 4]	53.93
WPA-SVM	147	93.04	[12.367 7,0.119 3]	76.62
PSO-SVM	139	87.97	[17.606 0,0.047 7]	84.59
SVM	131	82.91	[23.550 0,0.060 0]	102.07

结论

本文提出了一种基于油中溶解气体分析的变压器故障预测方法,可以在较小的误差范围内预测变压器未来运行状态下的异常时段和某些故障发生的概率,为变压器运行维护提供重要参考。该方法首先使用ialo算法对LSTM网络进行优化,然后以其为载体建立时间注意机制框架来预测变压器油中的溶解气体。它的收敛速度比传统的alo-lstm方法快。注意机制的引入增强了时间序列中关键信息的学习和表达,大大提高了变压器油中溶解气体浓度的预测效率和准确性;最后,利用MPA算法优化的SVM模型对溶解气体预测结果进行故障诊断。MPA算法良好的局部搜索和全局优化能力,缓解了传统方法收敛速度慢、易陷入局部最优的问题,提高了

SVM模型在变压器故障分类中的准确性。在后续研究中,本文将深入探讨其他特征气体、油温和环境温度对溶解气体预测的影响,从而进一步提高变压器故障预测的准确性。

参考文献:

- [1]李毅.基于油中溶解气体分析的电力变压器故障诊断方法[J].通讯世界,2020,27(05):151-152.
- [2]郑华.变压器油中溶解气体分析和故障诊断研究[J].中国设备工程,2019(23):80-82.
- [3]洗锋.绝缘油中溶解气体分析及其气体浓度预测在肇庆供电局应用研究[D].华南理工大学,2019.DOI:10.27151/d.cnki.ghnlu.2019.004352.
- [4]郭晶,赵杜.变压器油中溶解气体含量突增故障诊断与分析[J].河北电力技术,2019,38(03):38-40.
- [5]滕文辉.电力变压器油中溶解气体浓度预测与故障诊断的研究[D].山东科技大学,2019.DOI:10.27275/d.cnki.gsdku.2019.000450.

作者简介:王清泉(1984.3.4——),男,汉族,河北省保定市,本科,油务员技师。

