

DOI:10.19651/j.cnki.emt.2107478

# 基于油中溶解气体分析的变压器故障预测\*

陈 铁<sup>1,2</sup> 陈卫东<sup>1,2</sup> 李咸善<sup>1,2</sup> 陈 忠<sup>3</sup>

(1. 三峡大学 电气与新能源学院 宜昌 443002; 2. 三峡大学 梯级水电站运行与控制湖北省重点实验室 宜昌 443002;  
3. 宜昌电力勘测设计院有限公司 宜昌 443003)

**摘要:** 预测变压器潜伏性故障对评估其健康状态至关重要。提出一种新型变压器故障预测方法,首先以 LSTM 网络为载体搭建时间注意力机制预测框架,并采用 IALO 算法优化其参数;其次利用优化的模型预测变压器油中溶解气体;然后采用 MPA 算法优化的 SVM 模型对气体预测结果进行故障诊断;最后统计诊断结果并与实际运行状态对比验证模型。实验结果显示在第 42~58 天内运行状态异常次数最多为 29 次,未来两个月内运行异常几率为 86.89%,其中中温过热故障占比最高为 88.67%,与实际情况误差仅为 2.46% 和 1.29%,预测结果与实际运行情况符合较高,证明了所提方法在准确预测变压器运行状态异常时间点和故障类型中的可行性。

**关键词:** 变压器;故障预测;溶解气体分析;改进的蚁狮算法;长短时记忆网络;时间注意力机制;支持向量机

**中图分类号:** TM411;TP183 **文献标识码:** A **国家标准学科分类代码:** 470.4017

## Transformer fault prediction based on analysis of dissolved gas in oil

Chen Tie<sup>1,2</sup> Chen Weidong<sup>1,2</sup> Li Xianshan<sup>1,2</sup> Chen Zhong<sup>3</sup>

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China;  
2. Hubei Provincial Key Laboratory for Operation and Control of Cascaded Hydropower Station, China Three Gorges University,  
Yichang 443002, China; 3. Yichang Electric Power Survey and Design Institute Company Limited, Yichang 443003, China)

**Abstract:** Predicting latent faults of transformers is essential to evaluate their health status. This paper proposes a new transformer fault prediction method. First of all, a prediction framework of temporal attention mechanism is built based on LSTM network, and the IALO algorithm is used to optimize the hyperparameters of LSTM. Afterwards, use the optimized model to predict the dissolved gas in transformer oil. Then, the SVM model optimized by the MPA algorithm is used to diagnose the gas prediction results. Finally, the fault diagnosis results are counted, and the model is verified by comparing with the actual operation state. The experimental results show that the abnormal operation status is up to 29 times from the 42th to 58th day, and the abnormal operation probability is 86.89% in the next two months, among which the proportion of medium temperature overheating fault is highest, 88.67%, and the errors from the actual situations are only 2.46% and 1.29%. The predicted results are in good agreement with the actual operating situations of transformers, which proves the feasibility of the proposed method in accurately predicting the time point and fault type of abnormal operation states of transformers.

**Keywords:** transformer; fault prediction; dissolved gas analysis; improved antlion optimization; long short-term memory network; temporal attention mechanism; support vector machine

## 0 引 言

准确预测变压器故障对评估其未来运行状态和指导运维工作具有重要意义<sup>[1-4]</sup>。变压器内部绝缘老化、电故障和热故障等原因导致绝缘油中碳氢化合物裂解产生不同成分的气体。当前变压器故障预测的主流方法是利用历史时序

数据建模预测油中溶解气体,然后建立故障诊断模型对预测结果进行诊断,可以近似预测出变压器潜伏性故障和掌握其健康状况<sup>[5-6]</sup>。

在气体预测方面,长短时记忆网络(long short-term memory network, LSTM)因具有长期记忆功能而广受关注<sup>[7-8]</sup>。但因 LSTM 网络的超参数组合种类繁多,导致预

收稿日期:2021-08-04

\* 基金项目:国家自然科学基金(51741907)、梯级水电站运行与控制湖北省重点实验室开放基金(2019KJX08)项目资助

测结果不确定性较大,如学习率设置过大会出现振荡使网络无法收敛,过小则会导致模型收敛速度很慢,隐层神经元个数越多模型的学习和表达能力越强,但也会带来过拟合的问题,传统预测建模过程中依赖经验法确定这些超参数使模型无法达到理想效果。研究人员提出优化策略对其进行改进,如采用优化算法将 LSTM 隐层神经元个数、学习率、训练次数和步长等参数交叉组合,以预测误差为目标函数,获得最优参数组合,或在 LSTM 网络隐层输出状态引入注意力机制增强模型对时序特征的学习深度,提高模型的预测精度<sup>[9-11]</sup>。

上述方法存在收敛速度慢和易陷入局部最优的问题。莱维飞行(Levy flight)算法是一种非高斯分布的随机游走策略,伴随着频繁的短距离行走和偶尔的长距离行走,可以平衡优化算法的局部开发和全局探索能力<sup>[12]</sup>。因此,可考虑采用莱维飞行算法扩大蚁狮算法(ant lion optimization, ALO)的参数寻优范围,提高优化效率。

在故障诊断方面,支持向量机模型(support vector machines, SVM)应用最为广泛<sup>[13-14]</sup>,但其惩罚因子和核参数设置不合理会导致模型过拟合、分类准确性低。而改进的模型中采用的优化算法如粒子群优化算法(particle swarm optimization, PSO)、狼群算法(wolf pack algorithm, WPA)等都存在收敛速度慢、易陷入局部最优的问题<sup>[15-16]</sup>。海洋捕食者算法(marine predator algorithm, MPA)是一种基于海洋捕食者觅食策略的随机全局优化算法,其特点是将莱维运动和布朗运动组合用于提高优化性能<sup>[17]</sup>,其优化能力已经通过各种优化任务得到证明<sup>[18-20]</sup>,可用于 SVM 模型的超参数优化。

另外,目前的研究都是利用溶解气体预测结果对潜伏性故障分类,分析变压器未来状态发展趋势,并没有预测出变压器发生故障的时间段、几率及故障类型,这给精确掌握变压器未来健康状态带来影响。

鉴于此,本文提出一种基于油中溶解气体分析的变压器故障预测模型。首先使用 IALO 算法来优化 LSTM 网络超参数,然后以此为载体建立时间注意力机制预测框架,预测某 220 kV 变压器未来两个月的气体浓度,再使用 MPA 优化的 SVM 模型对气体预测结果进行故障诊断,最后基于诊断结果分析变压器在未来某个时间段的运行状态及可能发生某种故障的概率。实验结果发现该变压器在未来两个月内运行状态发生异常的比例为 86.89%,分别诊断出高温过热、中温过热、低温过热等不同类型的过热性故障,而发生中温过热故障的比例最高,占总故障次数的 88.67%,与该变压器的实际检修结果基本吻合,误差仅为 1.29%,证明了本文方法在准确预测变压器故障应用中的可行性和可靠性。

## 1 理论基础

### 1.1 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来提取数据中的重要

特征,已被广泛应用于自然语言处理、图像识别和数据预测等多个领域<sup>[21-23]</sup>。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。

#### 1) 长短时记忆网络

LSTM 在循环神经网络(recurrent neural network, RNN)的基础上增加门控单元取代隐藏单元,缓解梯度爆炸问题,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 网络每个单元包含遗忘门、输入门和输出门 3 种状态,其建模过程如式(1)~(6)所示。

$$f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$c'_t = \tanh(\mathbf{W}_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$c_t = f_t * c_{t-1} + i_t * c'_t \quad (4)$$

$$o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(c_t) \quad (6)$$

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, $\mathbf{W}_f, \mathbf{W}_i, \mathbf{W}_c$ 和 $\mathbf{W}_o$ 是权重矩阵, $b_f, b_i, b_c$ 和 $b_o$ 是相应的偏置。 $\sigma$ 是 sigmoid 激活函数,  $\tanh()$ 是双曲正切激活函数,符号 $*$ 表示按元素相乘。

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) 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  $\gamma$ ,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轮盘选择蚁狮;

(3)利用莱维飞行算法扩大搜索范围,更新蚂蚁位置;

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

式中:  $\alpha$  是常数,  $\oplus$  是点积,  $s = \mu / |\nu|^{\frac{1}{\beta}}$  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;

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

式中:  $Antlion'_j$  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  $d^t$  和下限  $c^t$  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) 根据轮盘的平均值和精英蚁狮的移动来更新蚂蚁位置;

$$Ant'_i = \frac{R'_A + R'_E}{2} \quad (11)$$

式中:  $R'_A$  和  $R'_E$  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  $\gamma$ 。

### 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  $d_{i-1}$ , 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  $c_i$ 。解码阶段采用 LSTM 单元把  $t$

时刻目标序列的测量值  $y_i$  与中间向量  $c_i$  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。

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

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

$$\beta_t^k = \text{softmax}(e_t^k) = \frac{\exp(e_t^k)}{\sum_{j=1}^T \exp(e_j^k)} \quad (14)$$

$$c_t = \sum_{k=1}^T \beta_t^k h_k \quad (15)$$

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

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

$$y_{T+1} = f_{LSTM}(y_1, \dots, y_T, x_1, \dots, x_T) = V_y^T (W_T [d_T, c_T] + b_T) + b_y \quad (18)$$

式(12)~(18)中:  $V_e, W_e$  和  $U_e$  为多层感知机权重,  $\omega'$  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。

### 1.2 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:  $\omega$  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。

$$\min_{a, b} \frac{\|\omega\|^2}{2} + C \sum_{i=1}^l \xi_i \quad (20)$$

$$\text{s. t. } y_i (\omega^T x_i + b) \geq 1 - \xi_i,$$

$$\xi_i \geq 0, i = 1, 2, \dots, n$$

式中:  $C$  是惩罚因子,  $\xi_i$  是松弛变量。

当输入数据为非线性时, 需引入核函数 ( $K(x_i, x_j) = \varphi(x_i)\varphi(x_j)$ ) 将样本  $x$  映射到更高维空间并进行线性样本的分割<sup>[24]</sup>, 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:  $\alpha_i$  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  $\sigma$ 。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。MPA 算法对 SVM 模型参数优化过程如步骤 1)~5) 所示:

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  $(C, \sigma)$ , 否则继续迭代寻优。

## 2 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。

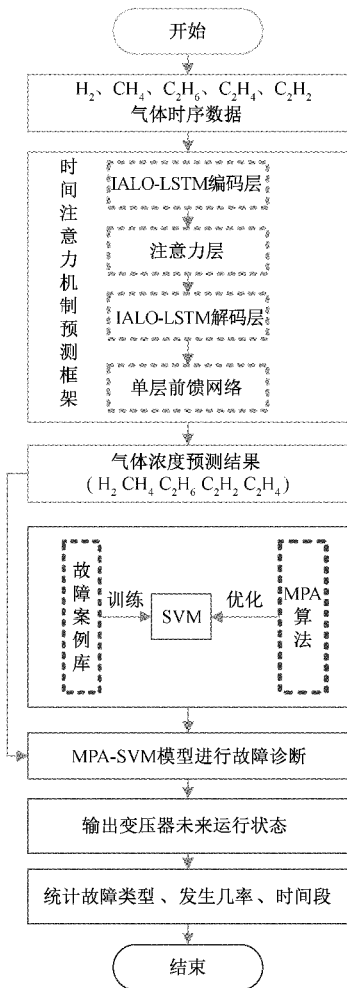


图 3 变压器故障预测流程

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。

## 3 算例分析

实验采用某 220 kV 电力变压器在 2015 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  $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$  和  $C_2H_2$  的浓度记录一次。监测数据显示该变压器在运行期间内  $H_2$  和  $CH_4$  的含量逐渐升高, 但  $H_2$  含量未超过氢气的 27%, 溶解气体中含有少量的  $C_2H_2$ , 且  $C_2H_2$  含量超过  $C_2H_4$  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 2015 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 ( $R^2$ ) 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。

### 3.1 油中溶解气体浓度预测

采用自适应动量 Adam 优化器自动更新 LSTM 网络权重, LSTM 网络初始隐层神经元个数  $N$ 、学习率  $lr$ 、训练次数  $E$  和步长  $\gamma$  的范围分别为  $[10, 100]$ 、 $[0.001, 0.1]$ 、 $[10, 150]$ 、 $[1, 100]$ ; IALO 算法中蚂蚁和蚁狮的种群规模为 50, 最大迭代次数为 100, 常量  $\beta$  为 1.5。

参数优化结果为: 隐藏层神经元个数为 20、学习率为 0.073、训练次数为 112、步长为 15, 变压器油中溶解气体浓度预测效果如图 4 所示。在相同条件下建立 LSTM、ALO-LSTM、IALO-LSTM 预测模型用以对比本文所提模型预测效果, 预测误差评估结果如表 1 所示。并以  $H_2$  浓度的预测为例比较不同模型对未来 15 d、30 d、45 d、61 d 的预测准确性, 对比结果如表 2 所示。

由图 4 可知,  $H_2$  和  $CH_4$  气体预测趋势先降低后升高, 而  $C_2H_6$ 、 $C_2H_4$  和  $C_2H_2$  气体在未来两个月内整体呈下降趋势, 与溶解气体实际发展情况相符合, 这表明本文所提方法可以准确预测出不同特征气体的发展趋势。误差分析显示, 经 IALO 算法优化的 LSTM 网络预测误差明显小于




图 4 变压器油中溶解气体浓度预测效果

LSTM 和 ALO-LSTM 网络,说明 IALO 算法比传统 ALO 算法具有更高效的模型参数寻优能力。针对不同时间尺度

的预测结果误差分析显示,当预测时长从 15 d 增加到 30 d 时,所有模型的预测误差均有所增大,LSTM 网络的预测误差增加幅度最大,从 2.909 7% 增到 3.968 9%,但本文方法预测误差增加幅度最小,仅增加 0.061 1%;当预测时长增加到 61 d 时,时间注意力机制 LSTM 网络的拟合优度检验指标最大,对特征气体总体发展趋势的预测效果保持最好,而没有注意力机制的 IALO-LSTM 网络的拟合优度检验指标减小 4.71%,高于本文方法 1.93%,表明针对非线性和非平稳性较强的时间序列,时间注意力机制可以提高 LSTM 网络对不同时间尺度内特征的学习能力,增强时间序列中关键点信息的表达使预测模型在短、中、长期预测时维持较高的预测精度和趋势预测效果。

### 3.2 变压器故障预测

在进行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,其中健康状态 154 组、局部放电 50 组、低能放电 45 组、高能放电 68 组、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,核函数选择高斯核函数,惩罚因子  $C$  和核参数  $\sigma$  的搜索上下限设置为  $[10^{-2}, 10^2]$ ,MPA 算法最大迭代次数为 100,种群规模为 30,效应系数为 0.2,常量  $p$  为 0.5。

为验证所提分类模型的有效性,在相同数据集下建立 WPA-SVM 模型、PSO-SVM 模型和 SVM 模型,其中 WPA 算法最大迭代次数为 100,种群规模 50,狼群更新比例系数  $\beta$  为 6;PSO 算法最大迭代次数为 100,种群规模 50,惯性权重分别取值 0.9 和 0.6,优化算法在不同迭代次数下的适应度曲线如图 5 所示。

由图 5 可知,WPA 算法和 PSO 算法在参数寻优过程中最终停止收敛迭代次数大于 MPA 算法,种群在搜索空间中因多样性丢失导致算法陷入局部最优,MPA 算法的最终适应度最大,表明 MPA 算法可以缓解传统优化算法在参数寻优时易陷入局部最优问题。

各模型对测试集中 158 组变压器运行状态的分类准确率比较结果如表 3 所示。结果显示经 MPA 算法优化的 SVM 模型具有最高的分类准确率为 95.57%,相比 WPA 算法和 PSO 算法分别提高 2.53%、7.60%,相比没有优化的 SVM 提高最显著为 12.66%,表明 MPA 算法对参数优化性能最好,因此 MPA-SVM 分类模型可以用于本文中变压器的故障预测。

将时间注意力机制 LSTM 网络预测出的 122 组变压器油中溶解气体数据输入到训练完成的 MPA-SVM 模型进行故障诊断,诊断结果如表 4 所示。结果显示,在前文预测出来的 122 组数据中,从第 17 组开始出现故障的次数逐渐增加,而在第 84 组与 115 组之间出现故障次数最多为 29 次,在两个月的预测时长内总故障次数 106 组占比为 86.89%,其中发生中温过热故障的比例最高为 88.67%,其次预测出低温过热故障和高温过热故障发生比例分别为

表 1 各模型预测结果评估指标

气体类型	MAPE/%				R <sup>2</sup>			
	LSTM	ALO-LSTM	IALO-LSTM	本文方法	LSTM	ALO-LSTM	IALO-LSTM	本文方法
H <sub>2</sub>	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 <sub>4</sub>	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 <sub>2</sub> H <sub>6</sub>	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 <sub>2</sub> H <sub>4</sub>	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 <sub>2</sub> H <sub>2</sub>	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 <sup>2</sup>			
	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 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

6.62%和 3.77%，放电性故障出现次数最少仅 1 次，因此判定该变压器在 2015 年 9~10 月时间段内发生中温过热故障的可能性极大。据工作人员记录实时监测平台在 2015 年 9 月中旬开始出现多次报警，而在 10 月中下旬报警次数最多，经现场勘查后发现该变压器处于过热运行状态，监测记录数据显示出现运行状态异常的情况占 84.43%，而中温过热故障占 87.38%，本文所提方法的预测结果与实际情况误差仅为 2.46%和 1.29%，与变压器实际运行状态符合较高，这表明所提方可以准确预测出变压器运行状态异常的时间段和发生故障的几率。

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	—

## 4 结 论

本文提出一种基于油中溶解气体分析的变压器故障预测方法，可在较小误差范围内预测出变压器未来运行状态出现异常的时间段及发生某种故障的概率，为变压器运维工作提供重要的参考。该方法首先使用 IALO 算法优化 LSTM 网络，然后将其作为载体建立时间注意力机制框架来预测变压器油中溶解气体，其收敛速度相比传统 ALO-LSTM 方法更快，注意力机制的引用增强了 LSTM 网络对时序中关键信息的学习和表达，大幅提高了变压器油中溶解气体浓度预测效率和准确性；最后使用 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 算法优异的局部探索和全局优化能力缓解了传统方法存在的收敛慢和易陷入局部最优问题，提高 SVM 模型对变压器故障分类精度。在后续的研究中，本文将深度探讨溶解气体在预测时受到其他特征气体、油温及环境温度等因素的影响，进一步提升变压器故障预测的准确性。

## 参考文献

- [1] 张朝龙,何怡刚,杜博伦,等. 基于深度学习的电力变压器智能故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(1):81-89.
- [2] 李黄曼,张勇,张瑶. 基于 ISSA 优化 SVM 的变压器故障诊断研究[J]. 电子测量与仪器学报, 2020, 35(3): 123-129.
- [3] 谢松,邹阳,蔡金锭. 基于模糊粗糙集的变压器油纸绝缘状态评估[J]. 仪器仪表学报, 2017, 38(1):190-197.
- [4] 康新兴. 基于蒙特卡罗仿真的电力变压器故障树分析[J]. 国外电子测量技术, 2018, 37(10):5-9.
- [5] JIANG J, CHEN R, ZHANG C, et al. Dynamic fault prediction of power transformers based on lasso regression and change point detection by dissolved gas analysis[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2020, 27(6): 2130-2137.
- [6] 黄新波,蒋卫涛,朱永灿,等. 基于时间序列和支持向量机的变压器故障预测[J]. 高电压技术, 2020, 46(7): 2530-2538.
- [7] 刘云鹏,许自强,董王英,等. 基于经验模态分解和长短期记忆神经网络的变压器油中溶解气体浓度预测方法[J]. 中国电机工程学报, 2019, 39(13):3998-4008.
- [8] 王科,苟家冀,彭晶,等. 基于 LSTM 网络的变压器油中溶解气体浓度预测[J]. 电子测量技术, 2020, 43(4): 81-87.
- [9] 刘可真,苟家冀,骆钊,等. 基于粒子群优化-长短期记忆网络模型的变压器油中溶解气体浓度预测方法[J]. 电网技术, 2020, 44(7):2778-2785.
- [10] YUAN X, CHEN C, LEI X, et al. Monthly runoff forecasting based on LSTM-ALO model [J]. Stochastic environmental research and risk assessment, 2018, 32(8): 2199-2212.
- [11] 崔宇,侯慧娟,胥明凯,等. 基于双重注意力机制的变压器油中溶解气体预测模型[J]. 中国电机工程学报, 2020, 40(1):338-347,400.
- [12] LIU Y, CAO B, LI H. Improving ant colony optimization algorithm with epsilon greedy and Levy flight [J]. Complex & Intelligent Systems, 2021, 7(4): 1711-1722.
- [13] 官文峰,陈辉,张美玲,等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. 仪器仪表学报, 2020, 41(1): 195-205.
- [14] FU W, SHAO K, TAN J, et al. Fault diagnosis for rolling bearings based on composite multiscale fine-sorted dispersion entropy and SVM with hybrid mutation SCA-HHO algorithm optimization[J]. IEEE Access, 2020, 8: 13086-13104.
- [15] ZHANG X, HAN P, XU L, et al. Research on bearing fault diagnosis of wind turbine gearbox based on 1DCNN-PSO-SVM[J]. IEEE Access, 2020, 8: 192248-192258.
- [16] 陈铁,吕长钦,张欣,等. 基于 KPCA-WPA-SVM 的变压器故障诊断模型[J]. 电测与仪表, 2021, 58(4): 158-164.
- [17] WANG N, WANG J S, ZHU L F, et al. A novel dynamic clustering method by integrating marine predators algorithm and particle swarm optimization algorithm[J]. IEEE Access, 2020, 9: 3557-3569.
- [18] YAN X, JIA M. A novel optimized SVM classification algorithm with multi-domain feature and its application to fault diagnosis of rolling bearing[J]. Neurocomputing, 2018, 313: 47-64.
- [19] YU G, MENG Z, MA H, et al. An adaptive marine predators algorithm for optimizing a hybrid PV/DG/battery system for a remote area in China[J]. Energy Reports, 2021, 7: 398-412.
- [20] ZHONG K, LUO Q, ZHOU Y, et al. TLMPA: Teaching-learning-based marine predators algorithm[J]. AIMS Mathematics, 2021, 6(2): 1395-1442.
- [21] MAKIN J G, MOSES D A, CHANG E F. Machine translation of cortical activity to text with an encoder-decoder framework[J]. Nature Neuroscience, 2020, 23(4): 575-582.
- [22] WANG E K, ZHANG X, WANG F, et al. Multilayer dense attention model for image caption[J]. IEEE Access, 2019, 7: 66358-66368.
- [23] CHEN C, WU T, GUO Z, et al. Combination of deep neural network with attention mechanism enhances the explainability of protein contact prediction[J]. Proteins: Structure, Function, and Bioinformatics, 2021, 89(6): 697-707.
- [24] BACHA K, SOUAHLIA S, GOSSA M. Power transformer fault diagnosis based on dissolved gas analysis by support vector machine[J]. Electric Power Systems Research, 2012, 83(1): 73-79.

## 作者简介

陈铁,副教授,主要研究方向为电力变压器状态预测与故障诊断、人工智能和数据挖掘技术等。

E-mail:chent@ctgu.edu.cn

陈卫东,硕士,主要研究方向为电力变压器状态预测与故障诊断、信号处理等。

E-mail:503793381@qq.com