

# 基于多级特征提取和 IHHO-KELM 的变压器油中溶解气体体积分数预测

傅雨晨<sup>1</sup>, 陈星<sup>1</sup>, 付文龙<sup>1,2</sup>, 方念<sup>3</sup>, 张凯<sup>1</sup>, 曹正江<sup>1</sup>

(1. 三峡大学电气与新能源学院, 湖北宜昌 443000; 2. 三峡大学梯级水电站运行与控制湖北省重点实验室, 湖北宜昌 443000; 3. 国网浙江省电力有限公司宁波供电公司, 浙江宁波 315000)

**摘要:** 油中溶解气体分析是变压器早期故障诊断的主要方法, 准确预测未来特征气体体积分数有助于提前获取变压器的运行状态。为此提出了一种基于多级特征提取和 IHHO-KELM 的变压器油中溶解气体体积分数预测方法。首先, 通过自适应白噪声完全集合经验模态分解将气体体积分数序列分解为多个子序列, 利用奇异谱分析对子序列做进一步降噪处理, 降低其非平稳性; 其次, 建立核极限学习机预测模型分别对各子序列进行预测, 再将各子序列的预测结果叠加得到油中溶解气体体积分数的最终预测结果, 并通过改进哈里斯鹰算法优化其超参数; 最后, 通过算例验证表明, 所提模型具有更优的预测性能, 可以更好的追踪油中溶解气体体积分数的变化趋势。

**关键词:** 油中溶解气体体积分数预测; 自适应白噪声完全集合经验模态分解; 奇异谱分析; 改进哈里斯鹰算法

## Prediction of Dissolved Gas Concentration in Transformer Oil Based on Multistage Feature Extraction and IHHO-KELM

FU Yuchen<sup>1</sup>, CHEN Xing<sup>1</sup>, FU Wenlong<sup>1,2</sup>, FANG Nian<sup>3</sup>, ZHANG Kai<sup>1</sup>, CAO Zhengjiang<sup>1</sup>

(1. School of Electrical Engineering and New Energy, China Three Gorges University, Hubei Yichang 443000, China; 2. Hubei Provincial Key Laboratory for Operation and Control of Cascaded Hydropower Station, China Three Gorges University, Hubei Yichang 443000, China; 3. State Grid Zhejiang Electric Power Co., Ltd., Ningbo Power Supply Company, Zhejiang Ningbo 315000, China)

**Abstract:** Dissolved gas concentration analysis in transformer oil have gradually become a mainstream pattern in early fault discrimination. Accurate prediction of dissolved gas in oil contributes to gain transformer operation status in advance. Therefore, prediction model of dissolved gas concentration in transformer oil based on multistage feature extraction and IHHO-KELM is proposed. Firstly, dissolved gas concentration data is decomposed into multiple subsequences by complete ensemble empirical mode decomposition with adaptive noise, after which the subsequences are further denoised by singular spectrum analysis to reduce its non-stationarity. Then, kernel based extreme learning machine is adopted to forecast each subsequence. Meanwhile, improved harris hawk optimization is applied to optimize the hyper-parameter of kernel based extreme learning machine. Subsequently, the final dissolved gas concentration results are attained by summing the prediction values of all subsequences. Finally, the experimental results are clarified that the proposed model achieves better prediction performance, which can better track the variation trend of dissolved gas concentration in transformer oil.

**Key words:** prediction of dissolved gas in oil; complete ensemble empirical mode decomposition with adaptive noise; singular spectrum analysis; improved harris hawk optimization

## 0 引言

变压器作为电力系统中的主要设备之一, 其正常运行对于电力系统的可靠性和稳定性至关重要<sup>[1]</sup>。油中溶解气体分析(dissolved gas analysis, DGA)<sup>[2]</sup>是发现变压器早期故障的有效手段, 能够提前判断变压器的运行状态<sup>[3-4]</sup>, 对指导变压器检修工作和预防电网重大事故具有重要意义。

近年来, 许多学者在变压器油中气体预测领域进行了大量研究, 主要可以分为物理统计模型和人工智

能预测模型。其中, 物理统计预测模型主要包括自动回归移动平均模型<sup>[5]</sup>、灰色关联模型<sup>[6]</sup>等, 此类模型常用于线性时间序列预测, 并不适合直接用于具有非线性和非平稳性特点的序列。目前, 人工智能技术在预测领域发展迅速, 并取得了一些成果。常用方法有 BP 神经网络<sup>[7]</sup>、支持向量机(SVM)<sup>[8-9]</sup>、广义神经网络(GRNN)<sup>[10]</sup>等。文[11]利用 BP 神经网络实现了对变压器绕组热点温度预测, 验证了此模型的有效性。文[12]采用黏菌算法优化改进 SVM 模型对变压器油中

**基金项目:** 国家自然科学基金资助项目(51741907)。

Project Supported by National Natural Science Foundation of China (51741907).

溶解气体体积分数进行预测,取得了较好的效果。虽然人工智能模型在非线性和非平稳性的时序预测中,表现出了良好的适应度,但也存在许多问题。例如:BP神经网络作为误差逆向反馈型的神经网络,需要设置众多参数,其网络结构难以确定,收敛速度慢。SVM模型计算成本会随着数据规模的增长而显著增加,难以训练大规模数据。相比之下,结合正则化系数和核函数的核极限学习机(kernel based extreme learning machine, KELM)具有较少的参数设置和显著的计算速度<sup>[13-14]</sup>,可以很好的解决上述问题。KELM虽有不错的预测性能,但也存在参数选择困难的问题。因此,文中选用改进哈里斯鹰算法(improved harris hawk optimization, IHHO)优化其模型参数。

同时,考虑到变压器油中溶解气体体积分数序列受负载、油温及测量误差等因素的影响,呈现出非平稳性和非线性的特点<sup>[15]</sup>。为提高预测精度,很多研究利用信号分解方法对原始序列数据进行平稳化处理<sup>[16]</sup>。文[17]采用经验模态分解(empirical mode decomposition, EMD),将油中溶解气体体积分数的原始序列分解为多个子序列,降低其非平稳性用于预测。但EMD在分解过程中易出现模态混叠的问题,而自适应白噪声完全集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)是一种新的信号分解方法<sup>[18]</sup>,适用于油中溶解气体体积分数序列的分解,且效果较好<sup>[19]</sup>。如文[1]采用CEEMDAN对历史气体体积分数时间序列进行分解,实验结果表明利用CEEMDAN分解气体序列,能够避免原始序列非平稳性对预测效果的影响,有助于提高预测性能。

基于上述分析,文中提出了一种基于多级特征提

取和IHHO-KELM的变压器油中溶解气体体积分数预测方法。首先,利用CEEMDAN和奇异谱分析(singular spectrum analysis, SSA)方法对原始油中溶解气体体积分数序列进行多级特征提取,其中使用CEEMDAN将原始序列分解为多个固有模态函数(IMFs),利用SSA进一步提取IMFs的主导成分,以降低原始数据序列的非平稳性。其次,构建KELM预测模型对所有子序列进行预测,并将所有子序的预测结果叠加得到最终的预测结果。考虑到KELM模型参数设置对其预测性能的影响,提出了一种IHHO算法优化其模型参数,以提升模型的预测性能。最后,通过算例分析验证了所提方法的有效性。

## 1 自适应白噪声完全集合经验模态分解

CEEMDAN是由Torres等人提出的一种信号处理方法<sup>[20]</sup>,能够将原始的时间序列输出信号分解为多个IMFs,以降低信号的随机性和非平稳性。该方法通过在分解过程中加入适量的自适应白噪声,解决了EMD引起的模态混叠和集合经验模态分解造成的信号丢失以及计算效率低下等问题。

设 $x(t)$ 为原始信号,加入符合高斯分布的白噪声信号 $\varepsilon_0\omega(t)^{(i)}$ 后,第 $i$ 个序列的表达式可以表示为

$$x_i(t) = x(t) + \varepsilon\omega_i(t), (i = 1, 2, 3, \dots, I) \quad (1)$$

式(1)中: $\omega_i(t)$ 表示第 $i$ 次高斯白噪声; $\varepsilon$ 表示高斯白噪声系数。CEEMDAN的具体分解步骤如下:

1)采用EMD对 $x_i(t)$ 进行分解,并对第一个EMD分解后的信号分量取均值,得到第一个子序列 $IMF_1$ 和残差分量 $r_1$ 。

$$IMF_1(t) = \frac{1}{I} \sum_{i=1}^I IMF_1^i(t) \quad (2)$$

$$r_1(t) = x(t) - IMF_1(t) \quad (3)$$

式(2)、(3)中,  $IMF_1^i(t)$ 表示第一个 EMD 分解后的信号分量。

2)按照类似的方法,将白噪声信号加入到第  $k$  个残差分量,通过 EMD 对余量信号进行分解,根据式(4)和式(5),计算第  $k$  个子序列  $IMF_k$  和残差信号  $r_k$ 。

$$IMF_k(t) = \frac{1}{I} \sum_{i=1}^I H_1(r_{k-1} + \varepsilon_{k-1} H_{k-1}(\omega_i(t))) \quad (4)$$

$$r_k(t) = r_{k-1}(t) - IMF_k(t) \quad (5)$$

式(4)中,  $H_{k-1}$ 表示 EMD 分解后的分量。

3)重复 2),当极点数小于 2 或达到人为设定子序列个数时停止循环。此时原始信号的分解结果可以表示为

$$x(t) = \sum_{k=1}^K IMF_k(t) + r_k(t) \quad (6)$$

## 2 奇异谱分析

SSA 是一种分析时间序列数据的有效方法<sup>[21]</sup>,可广泛应用于解决周期性或者非周期性分量的检测与捕获、信号去噪、边缘性检测等问题。由于其对非线性信号的处理能力较强,因此,文中将其用于变压器油中溶解气体序列的降噪。标准的奇异谱分析包括嵌入、奇异值分解、分组和对角平均化 4 个步骤,具体过程如下:

1)嵌入。假设样本数为  $N$  的油中溶解气体时间序列数据为  $Y = [y_1, y_2, \dots, y_N]^T$ , SSA 的嵌入维数用  $L$  表示,其中  $2 \leq L \leq N$ 。那么滞后向量可以定义为

$$X_i = [y_i, y_{i+1}, \dots, y_{i+L-1}]^T, \quad \text{其中}$$

$i = 1, 2, \dots, K, K = N - L + 1$ 。因此,新的序列数据可

以被重构成为轨迹矩阵,该矩阵的定义为

$$X = \begin{pmatrix} y_1 & y_2 & \dots & y_K \\ y_2 & y_3 & \dots & y_{K+1} \\ \vdots & \vdots & \dots & \vdots \\ y_L & y_{L+1} & \dots & y_N \end{pmatrix} \quad (7)$$

2)奇异值分解。通过奇异值分解将轨迹矩阵  $X$  分解为  $d$  个分量,其中  $d = \text{rank}(X)$ 。此外,矩阵  $X$  奇异值分解的第  $i$  个特征向量为  $(\lambda_i, U_i, V_i)$ ,其中  $\lambda_i$  表示协方差矩阵  $XX^T$  的特征值,  $U_i$  和  $V_i$  表示矩阵  $XX^T$  中的左右特征向量。因此,轨迹矩阵  $X$  可以进一步表示为:

$$X = \sum_{i=1}^d X_i \quad (8)$$

$$X_i = \sqrt{\lambda_i} U_i V_i \quad (9)$$

3)分组。重构  $d$  个分量中的主导成分,得到重构序列,定义为

$$X_l = X_{l1} + X_{l2} + \dots + X_{lm} \quad (10)$$

4)对角平均化。假设  $X$  是一个元素为  $x_{ij}$  的  $P \times J$  矩阵,  $P^* = \min(P, J)$ ,  $J^* = \max(P, J)$ 。如果  $P < J$ , 则设  $x_{ij}^* = x_{ij}$ , 否则设  $x_{ij}^* = x_{ji}$ 。重构的时间序列

$Z = \{z_1, z_2, \dots, z_N\}$  的计算过程为

$$z_k = \begin{cases} \frac{1}{k} \sum_{q=1}^k x_{q, k-q+1}^*, & 1 \leq k \leq P^* \\ \frac{1}{P^*} \sum_{q=1}^{P^*} x_{q, k-q+1}^*, & P^* \leq k \leq J \\ \frac{1}{N-k+1} \sum_{q=k-J^*+1}^{N-J^*+1} x_{q, k-q+1}^*, & J^* \leq k \leq N \end{cases} \quad (11)$$

### 3 改进哈里斯鹰算法

#### 3.1 哈里斯鹰算法

哈里斯鹰优化算法(harris hawk optimization, HHO)<sup>[22]</sup>是 Heidari 等人通过模拟哈里斯鹰的捕食行为为开发出的一种智能优化算法,该算法主要由3个部

分组成:搜索阶段、搜索与开发转化阶段和开发阶段,具体实现过程如下。

在搜索阶段,哈里斯鹰随机栖息在一个位置,按照式(12)所示策略搜索猎物

$$X_{t+1} = \begin{cases} X_{rand}(t) - r_1 |X_{rand}(t) - 2r_2 X(t)| & q \geq 0.5 \\ (X_{rabbit}(t) - X_m(t)) - r_3(LB + r_4(UB - LB)) & q < 0.5 \end{cases} \quad (12)$$

式(12)中:  $X(t)$ 、 $X_{t+1}$ 表示当前和下次迭代时个体的位置;  $X_{rand}(t)$ 表示种群的随机位置;  $X_{rabbit}(t)$ 表示猎物位置,也代表个体最优适应度位置;  $r_1$ 、 $r_2$ 、 $r_3$ 、 $r_4$ 分别表示[0, 1]之间的随机数;  $q$ 表示随机选择的更新策略;  $UB$ 、 $LB$ 表示搜索空间的上、下边界;  $X_m(t)$ 为个体的平均位置,其表达式为

$$X_m(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \quad (13)$$

式(13)中:  $N$ 表示种群数量;  $X_i(t)$ 表示第 $t$ 次迭代时种群位置。

HHO 算法会根据猎物的逃逸能量,在搜索和局部开发两种行为之间实现转化,逃逸能量可以定义为

$$E = 2E_0(1 - \frac{t}{T}) \quad (14)$$

式(14)中:  $E_0$ 表示每次迭代在(-1, 1)区间的初始

能量;  $T$ 表示最大迭代次数,当 $|E| \geq 1$ 时进入搜索阶段,  $|E| < 1$ 时进入局部开发阶段。

在局部开发阶段,HHO 算法根据哈里斯鹰的追捕策略和猎物的逃逸行为,提出了四种不同的攻击策略。用 $h$ 表示[0, 1]之间的随机数。

1)软包围。当 $h \geq 0.5$ 且 $|E| \geq 0.5$ 时,哈里斯鹰

位置更新公式为

$$X(t+1) = (X_{rabbit}(t) - X(t)) - E \times |J \times X_{rabbit}(t) - X(t)| \quad (15)$$

式(15)中,  $J$ 为[0, 2]之间的随机数。

位置更新公式为

2)硬包围。当 $h \geq 0.5$ 且 $|E| < 0.5$ 时,哈里斯鹰

$$X(t+1) = (X_{rabbit}(t) - X(t)) - E \times |X_{rabbit}(t) - X(t)| \quad (16)$$

3)快速俯冲式的软包围。当 $h < 0.5$ 且 $|E| \geq 0.5$

$$X(t+1) = X_{rabbit}(t) - E \times |JX_{rabbit}(t) - X(t)| \quad (17)$$

时,更新方式如下,并采用 Levy 策略扩大搜索范围。

$$Z = Y + S \times LF(D) \quad (18)$$

$$X(t+1) = \begin{cases} Y & \text{if } F(Y) < F(X(t)) \\ Z & \text{if } F(Z) < F(X(t)) \end{cases} \quad (19)$$

4)快速俯冲式的硬包围。当  $h < 0.5$  且  $|E| < 0.5$

时, 哈里斯鹰的位置更新公式为:

$$X(t+1) = X_{rabbit}(t) - E \times |JX_{rabbit}(t) - X_m(t)| \quad (20)$$

$$Z = Y + S \times LF(D) \quad (21)$$

$$X(t+1) = \begin{cases} Y & \text{if } F(Y) < F(X(t)) \\ Z & \text{if } F(Z) < F(X(t)) \end{cases} \quad (22)$$

### 3.2 改进策略

1)非线性逃逸能量更新策略。HHO 算法在迭代初期侧重于探索阶段, 迭代后期则侧重于开发阶段,

$$X_i(t)' = X_i(t) + \varepsilon_1(X_{r_1}(t) - X_i(t)) + \varepsilon_2(X_{r_2}(t) - X_i(t)) \quad (24)$$

式(24)中:  $X_{r_1}(t)$ 、 $X_{r_2}(t)$  为种群中随机产生的

个体;  $\varepsilon_1$ 、 $\varepsilon_2$  是在[0, 1]区间内产生的随机数。更新

$$X_{new}(t) = \begin{cases} X_i(t)', & \text{fitness}(X_i(t)') < \text{fitness}(X_i(t)) \\ X_i(t), & \text{else} \end{cases} \quad (25)$$

IHHO 算法的具体实现步骤如下:

1)初始化种群, 设置算法参数, 包括种群数  $N$ , 最大迭代次数  $T$  等。

2)计算种群个体的适应度值, 选出最优的个体设为当前猎物位置。

3)根据式(23)计算  $E$  值, 并根据  $E$  和随机数  $r$  选择策略更新位置。

4)将哈里斯鹰的最终位置作为最佳适应度位置,

为有效平衡两者, 在其基础上提出新的逃逸能量  $E$  的公式为

$$E = E_0 \left[ 1 + \cos\left(\pi \cdot \frac{t}{T}\right) \right] \quad (23)$$

2)交叉变异策略。HHO 算法在收敛后期种群多样性降低, 易陷入局部最优解。因此为摆脱局部最优, 对后期迭代得到的最优种群进行交叉变异, 以保持后期迭代种群多样, 策略表达式为

后的最优个体采用贪婪策略进行保存见式(25)

利用式(24)进行交叉变异操作, 如果变异后个体的适应度值更好则保留。

5)判断结束条件是否成立, 成立则输出最优结果, 否则重复执行 2)到 4)。

### 3.3 算法验证

为验证所提出 IHHO 的优越性, 选择不同的测试函数进行测试, 包括单峰、多峰和定维多峰函数。测试函数见表 1。

表 1 基准测试函数

Table 1 Benchmark functions

序号	函数表达式	维度	范围	最优值
F <sub>1</sub>	$f_3(x) = \sum_{i=1}^{n-1} \left[ 100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2 \right]$	30	[-30,30]	0

F <sub>2</sub>	$f_6(x) = \sum_{i=1}^{n-1} ( x_i + 0.5 )^2$	30	[-30,30]	0
F <sub>3</sub>	$f_{12}(x) = \frac{\pi}{n} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \right\}$ $+ \sum_{i=1}^n u(x_i, 10, 100, 4)$ $y_i = 1 + \frac{x_i + 1}{4} u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 - a & < x_i < a \\ k(-x_i - a)^m & x_i < -a \end{cases}$	30	[-50,50]	0
F <sub>4</sub>	$f_{13}(x) = 0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] \right.$ $\left. + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] \right\} + \sum_{i=1}^n u(x_i, 5, 100, 4)$	30	[-50,50]	0
F <sub>5</sub>	$f_{14}(x) = \left( \frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right)^{-1}$	2	[-65,65]	1
F <sub>6</sub>	$f_{15}(x) = \sum_{i=1}^{11} \left[ a_i - \frac{x_i (b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4} \right]^2$	4	[-5,5]	0.003

实验过程中设置 HHO、PSO、WOA、SCA、DE、GWO 六种常用算法作为对照组。所有算法的种群数量和迭代次数分别设置为 30 和 200 次，并且每个算法在测试函数上独立执行 10 次，取平均值 AVG 和标准差 STD 作为测试指标。实验结果见表 2，算法收敛图见图 1。从实验结果可以看出，与对照组的 6 种算

法相比，所提出的 IHHO 算法在收敛速度和计算解的质量方面都有最优的性能，证明了 IHHO 算法中的非线性逃逸能量更新策略可以较好的平衡全局搜索和局部开发两个阶段，提高算法的收敛能力。交叉变异策略也明显提升了算法跳出局部最优解的能力。

表 2 不同算法的测试结果

Table 2 Test results of different algorithms

序号	指标	IHHO	HHO	PSO	WOA	SCA	DE	GWO
F <sub>1</sub>	AVG	0.00	7.90×10 <sup>-2</sup>	3.14×10 <sup>2</sup>	2.86×10 <sup>1</sup>	1.73×10 <sup>6</sup>	6.93×10 <sup>3</sup>	2.75×10 <sup>1</sup>
	STD	0.00	8.94×10 <sup>-2</sup>	4.41×10 <sup>1</sup>	2.01×10 <sup>-1</sup>	1.96×10 <sup>6</sup>	3.42×10 <sup>3</sup>	6.66×10 <sup>-1</sup>
F <sub>2</sub>	AVG	0.00	1.25×10 <sup>-3</sup>	6.29×10 <sup>0</sup>	1.27×10 <sup>0</sup>	3.14×10 <sup>2</sup>	3.64×10 <sup>1</sup>	1.24×10 <sup>0</sup>
	STD	0.00	2.54×10 <sup>-3</sup>	1.46×10 <sup>0</sup>	3.32×10 <sup>-1</sup>	2.95×10 <sup>2</sup>	1.02×10 <sup>1</sup>	3.03×10 <sup>-1</sup>
F <sub>3</sub>	AVG	1.57×10 <sup>-32</sup>	6.96×10 <sup>-5</sup>	1.70×10 <sup>-1</sup>	1.23×10 <sup>-1</sup>	2.22×10 <sup>6</sup>	3.88×10 <sup>0</sup>	9.17×10 <sup>-2</sup>
	STD	2.74×10 <sup>-48</sup>	1.36×10 <sup>-4</sup>	5.60×10 <sup>-2</sup>	1.55×10 <sup>-1</sup>	3.56×10 <sup>6</sup>	8.79×10 <sup>-1</sup>	4.49×10 <sup>-2</sup>
F <sub>4</sub>	AVG	1.35×10 <sup>-32</sup>	5.16×10 <sup>-4</sup>	4.27×10 <sup>-1</sup>	9.90×10 <sup>-1</sup>	4.46×10 <sup>6</sup>	1.45×10 <sup>1</sup>	1.06×10 <sup>0</sup>
	STD	2.74×10 <sup>-48</sup>	1.36×10 <sup>-4</sup>	5.60×10 <sup>-2</sup>	1.55×10 <sup>-1</sup>	3.56×10 <sup>6</sup>	8.79×10 <sup>-1</sup>	4.49×10 <sup>-2</sup>
F <sub>5</sub>	AVG	-2.00×10 <sup>-3</sup>	5.90×10 <sup>-1</sup>	1.17×10 <sup>1</sup>	2.26×10 <sup>0</sup>	1.98×10 <sup>0</sup>	4.91×10 <sup>-1</sup>	4.21×10 <sup>0</sup>
	STD	1.73×10 <sup>-16</sup>	1.56×10 <sup>0</sup>	1.50×10 <sup>-13</sup>	3.06×10 <sup>0</sup>	2.90×10 <sup>0</sup>	1.56×10 <sup>0</sup>	4.10×10 <sup>0</sup>
F <sub>6</sub>	AVG	2.75×10 <sup>-5</sup>	9.64×10 <sup>-5</sup>	2.73×10 <sup>-4</sup>	5.32×10 <sup>-4</sup>	8.58×10 <sup>-4</sup>	6.04×10 <sup>-4</sup>	4.27×10 <sup>-3</sup>
	STD	1.76×10 <sup>-5</sup>	9.16×10 <sup>-5</sup>	1.64×10 <sup>-4</sup>	5.23×10 <sup>-4</sup>	4.27×10 <sup>-4</sup>	2.30×10 <sup>-4</sup>	7.90×10 <sup>-3</sup>

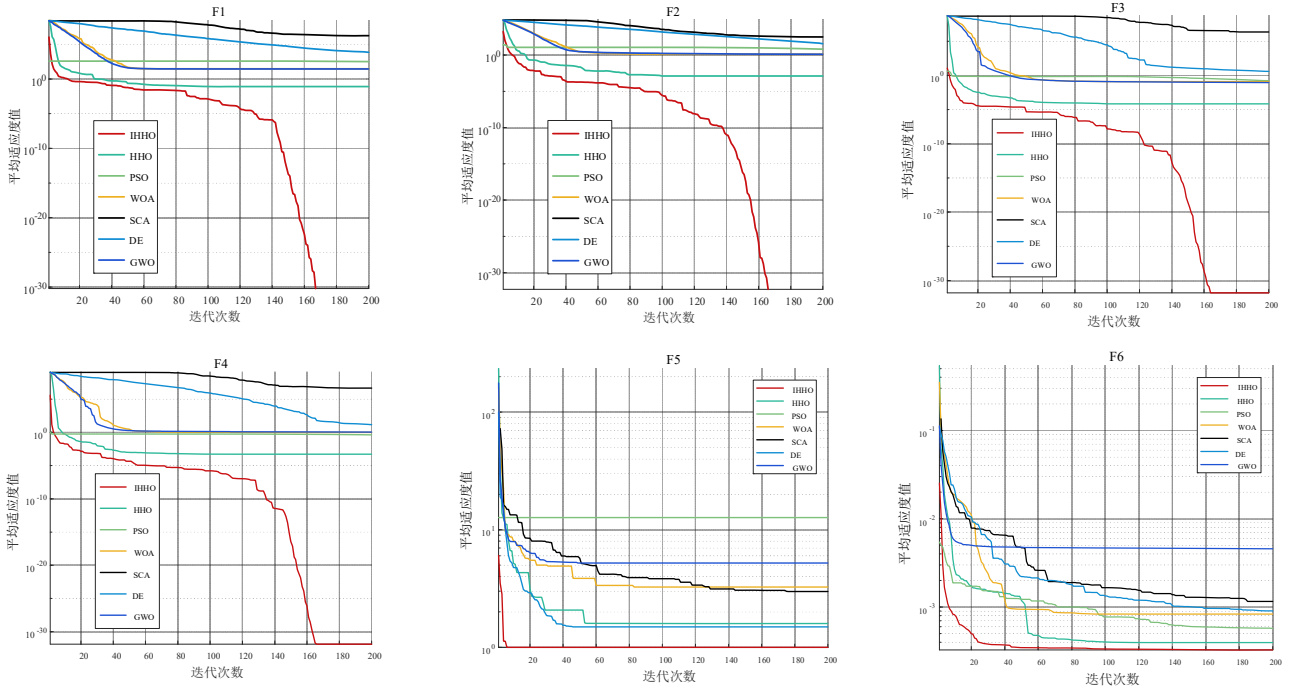


图 1 基准函数上所有算法的收敛曲线

Fig. 1 Convergence curves of all algorithms on the reference function

#### 4 变压器油中溶解气体预测模型的实现

变压器油中溶解气体体积分数字列易受到油温、负载、采集误差等多种因素的影响，往往会呈现出随机性和非平稳性的特点。信号分解技术可以使序列更

加平稳化，能够提取时序变化中的主导成分，对预测模型的预测精度提升明显。因此，文中提出了基于多级特征提取和 IHHO-KELM 的变压器油中溶解气体体积分数预测方法，实现流程见图 2。

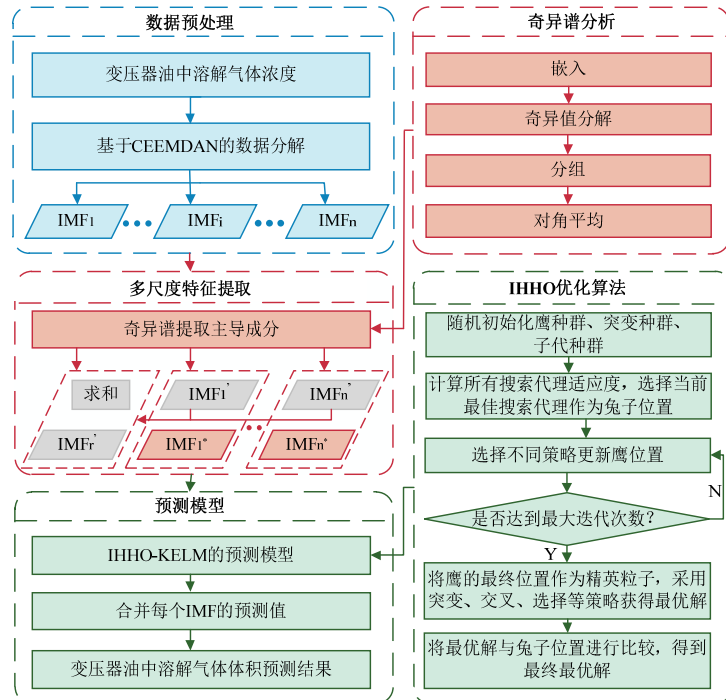


图 2 CEEMDAN-SSA-IHHO-KELM 预测流程图

Fig. 2 CEEMDAN-SSA-IHHO-KELM prediction flow chart

具体实现步骤如下：

1)利用 CEEMADN 将油中溶解气体的时间序列

数据分解为多组 IMFs。

2)使用 SSA 算法对分解后的序列做进一步主成分提取,降低其非平稳性,达到去噪效果。

3)划分测试集、训练集和验证集,对数据做归一化处理。

4)构建 KELM 模型对其所有子序列进行训练,在此过程中利用提出的 IHHO 算法优化 KELM 模型参数。

5) 使用训练完成的 CEEMADN-SSA-IHHO-KELM 模型预测所有子序列。

6)经过反归一化后,将各子分量的预测结果相加,得到最终的预测结果。

7)根据评价指标对最终预测结果进行评估,以验证模型的性能。

## 5 算例分析

### 5.1 数据选取

文中采用从某 500 kV 变压器油色谱在线监测系统收集到的一组变压器油中溶解气体体积分数数据为案例进行试验分析。数据采样间隔为一天,采样时间从 2018 年 2 月 16 日至 2020 年 11 月 20 日,共获得 1 008 组数据样本点。在实验之前,原始数据被分为 3 个部分,即训练集、验证集和测试集,依次用于模型的建立、超参数的选择和模型的验证。其中训练集、验证集和测试集的比例为 4 : 1 : 2,即前 576 组数据为训练集,中间的 144 组数据为验证集,后 288 组数据为测试集,数据展示见图 3。出于文章篇幅考虑,以下实验均以 CH<sub>4</sub> 气体数据为例展开分析。




图 3 CH<sub>4</sub>原始时间序列

Fig. 3 Original CH<sub>4</sub> time series

### 5.2 数据预处理

观察原始数据图 3 可以发现 CH<sub>4</sub> 气体体积分数序列具有非平稳性和非线性的特点,具有很大的预测难度。信号分解方法是削弱气体体积分数序列非线性和非平稳性的有效方法。因此,CEEMDAN 分解方法被用来对原始 CH<sub>4</sub> 采样时间序列数据进行模态分解,得到 9 组 IMF 分量 and 一组残差分量。处理结果见图 4。为了进一步降低分解子序列的非平稳性,采用 SSA

提取子序列中的主导成分和残留成分。然后,对各个子序列进行归一化,具体公式为

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (26)$$

式(26)中:  $x$  表示原始子序列样本数据;  $x_{\min}$  表示最小的样本值;  $x_{\max}$  表示最大的样本值;  $x_n$  表示子序列做归一化处理后的样本值。




图4 CEEMDAN-SSA 分解结果

Fig. 4 Decomposition results of CEEMDAN-SSA

### 5.3 评估指标

采用均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)和平均绝对百分比误差(mean absolute percentage error, MAPE)3种不同的指标对实验结果进行对比分析,其计算公式为:

$$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (e_i - \hat{e})^2} \quad (27)$$

$$e_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |e_i - \hat{e}| \quad (28)$$

$$e_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{e_i - \hat{e}}{e_i} \right| \quad (29)$$

式(27)-(29)中:  $N$  表示预测子序列的长度;  $e_i$  和  $\hat{e}$  分别表示实际值和模型预测值反归一化后的结果。

### 5.4 基于多级特征提取的有效性验证

将预处理好的  $\text{CH}_4$  气体体积分数的时间序列数据输入到 KELM 模型中进行训练后进行预测,其中 KELM 模型中的正则化系数和核参数由所提的 IHHO 优化算法确定。本次实验中正则化系数和核参数的搜索范围均设为  $[0.01, 1000]$ , IHHO 算法的种群数和最大迭代次数分别设置为 30 和 50。  $\text{CH}_4$  子序列的模型预测值经反归一化后的结果见图 5, 评估指标值见表 3。




图5  $\text{CH}_4$  子序列预测结果

Fig. 5 Prediction results of  $\text{CH}_4$  subsequence

表 3 子序列预测结果的评估指标值

Table 3 Evaluation index values of prediction result of subsequence


子序列	误差类型		
	$e_{RMSE}$	$e_{MAE}$	$e_{MAPE}$
IMF <sub>1</sub>	0.233 3	0.193 3	76.991 7
IMF <sub>2</sub>	0.010 1	0.008 1	43.863 9
IMF <sub>3</sub>	0.015 3	0.012 1	33.708 1
IMF <sub>4</sub>	0.009 7	0.007 9	8.605 4
IMF <sub>5</sub>	0.027 1	0.008 1	12.776 5
IMF <sub>6</sub>	0.006 5	0.003 8	3.458 9
IMF <sub>7</sub>	0.001 7	0.001 1	1.286 8
IMF <sub>8</sub>	0.008 6	0.007 0	9.428 2
IMF <sub>9</sub>	0.004 2	0.001 9	0.195 0
Res	0.020 8	0.011 5	0.059 0

从表 3 和图 5 可以看出, 预测模型对 CH<sub>4</sub> 经过多级特征提取得到的子序列具有很好的拟合效果。这是因为原始序列在经过多级特征提取之后, 在很大程度上削弱了原始序列的非平稳性和波动性的特点, 使其具有较高的预测精度。


### 5.5 结果分析

为了验证所提出预测模型有效性, 应用 CEEMDAN-SSA-IHHO-KELM 模型、


CEEMDAN-SSA-KELM 模型、CEEMDAN-KELM 模型、KELM 模型对变压器油中 CH<sub>4</sub> 气体体积分数进行建模预测, 其中对比模型的超参数均由网格搜索法确定, 各模型预测值经反归一化后的结果见图 6, 评估指标值见表 4。




(a) KELM



(b) CEEMDAN-KELM



(c) CEEMDAN-SSA-KELM



(d) CEEMDAN-SSA-IHHO-KELM

图 6 对比模型与提出模型预测图

Fig. 6 Compare models and propose model prediction charts

表 4 不同模型的评估指标值

Table 4 Evaluation index values of different models

预测模型	误差类型		
	$e_{RMSE}$	$e_{MAE}$	$e_{MAPE}$
CEEMDAN-SSA-IHHO-KELM	0.504 3	0.409 7	2.071 0
CEEMDAN-SSA-KELM	0.606 3	0.494 3	2.481 2
CEEMDAN-KELM	0.695 8	0.554 4	2.776 2
KELM	1.217 2	0.990 0	4.970 9

通过图 6 可以看出,单一的 KELM 模型在对非线性的原始序列进行预测时的表现并不理想,而在加入 CEEMDAN 分解方法后预测数据的拟合效果有了很大的提升。在表 4 中得到相同的结论,单一 KELM 模型的  $e_{RMSE}$ 、 $e_{MAE}$ 、 $e_{MAPE}$  分别为 1.217 2、0.990 0、4.970 9;而在加入 CEEMDAN 分解方法后,这一组评估指标下降为 0.695 8、0.554 4、2.776 2。相比于 KELM 模型,CEEMDAN-KELM 模型的  $e_{RMSE}$ 、 $e_{MAE}$ 、 $e_{MAPE}$  指标分别降低了 42.84%、44%、44.15%。因此可以得出数据预处理在处理非平稳数据的优越性。在采用信号分解方法对原始序列进行处理后可以通过对 SSA 子序列的主导特征进行提取进一步降低预测难度和提升预测精度。通过对比

表 4 中 CEEMDAN-KELM 模型和 CEEMDAN-SSA-KELM 模型的评估指标可以看到在加入 SSA 后的预测模型误差指标有了明显降低, $e_{RMSE}$ 、 $e_{MAE}$ 、 $e_{MAPE}$  误差指标下降率为 12.86%、10.84%、10.63%,因此可以验证多级特征提取在变压器油中溶解气体体积分数预测方面的有效性。预测模型对于超参数的选择具有较高的灵敏性,选择不同的超参数进行建模会对预测精度产生影响,相比于对比模型中采用网格搜索法对超参数进行寻优,文中提出 IHHO 优化算法对超参数进行选择。通过分析表 4 可以得出,相比于 CEEMDAN-SSA-KELM 模型,CEEMDAN-SSA-IHHO-KELM 模型的  $e_{RMSE}$ 、 $e_{MAE}$

和  $e_{MAPE}$  误差指标分别降低了 0.102、0.084 6、0.410 2，下降率分别为为 16.82%、17.12%、16.53%。因此可以发现所提优化算法能够选择出更加合适的模型超参数用于对变压器油中溶解  $CH_4$  气体体积分数进行预测，展现所提预测方法的优越性。

## 5.6 其他气体分析结果

为了进一步验证所提

CEEMDAN-SSA-IHHO-KELM 模型的预测稳定性和可靠性，继续选用此变压器 2018 年 2 月 16 日至 2020 年 11 月 20 日油中溶解的其他气体体积分数数据进行预测，实际值和模型预测值反归一化后的结果见表 5。对于其他油中溶解气体体积分数的预测结果，文中所提模型均有最好的表现。

表 5 其他气体的不同模型的预测结果

Table 5 Prediction results of different models for other gases

气体类型	误差类型	预测模型			
		CEEMDAN-SSA-IHHO-KELM	CEEMDAN-SSA-KELM	CEEMDAN-KELM	KELM
$C_2H_4$	$e_{RMSE}$	0.252 5	0.291 3	0.339 5	0.725 8
	$e_{MAE}$	0.200 0	0.233 3	0.286 5	0.587 6
	$e_{MAPE}$	2.184 8	2.557 3	3.057 8	6.192 7
$C_2H_6$	$e_{RMSE}$	0.114 8	0.137 6	0.145 8	0.222 1
	$e_{MAE}$	0.094 8	0.116 4	0.117 2	0.188 1
	$e_{MAPE}$	2.369 1	2.906 7	2.938 0	4.740 5
$H_2$	$e_{RMSE}$	1.438 2	2.349 5	2.350 7	6.208 6
	$e_{MAE}$	1.112 2	1.872 4	1.906 1	4.868 6
	$e_{MAPE}$	1.745 9	2.888 0	2.958 0	7.472 4
总烃	$e_{RMSE}$	0.508 0	0.593 6	0.606 3	1.295 0
	$e_{MAE}$	0.407 1	0.488 8	0.481 2	1.046 6
	$e_{MAPE}$	1.630 3	1.936 1	1.906 4	4.151 1

## 6 结论

为了更加精准预测变压器油中溶解气体的体积分数，文中提出了一种基于多级特征提取和 IHHO-KELM 的变压器油中溶解气体体积分数预测方法。得到的具体结论如下：

1)使用 CEEMDAN 方法将变压器原始气体体积分数序列分解为多个子序列，利用 SSA 进一步提取各子序列的主导成分，以降低原始数据序列的非平稳性，进而可以提升模型的预测精度。

2)文中提出的 IHHO 算法与其他常用算法相比有更好的计算精度和收敛速度，可以很好的解决 KELM 参数选择敏感的问题。

3)算例结果表明，文中构建的

CEEMDAN-SSA-IHHO-KELM 模型具有较好的预测精度，能够为变压器油中气体体积分数预测提供一定的参考价值。

### 参考文献：

- [1] 栗磊, 王廷涛, 殷浩然, 等. 基于 GWO-LSTM 与 NKDE 的变压器油中溶解气体体积分数点——区间联合预测方法[J]. 高压电器, 2022, 58(11): 88-97.  
LI Lei, WANG Tingtao, YIN Haoran, et al. Point-interval joint prediction method of dissolved gas volume fraction in transformer oil based on GWO-LSTM and NKDE[J]. High Voltage Apparatus, 2022, 58(11): 88-97.
- [2] 刘宇鹏, 侯文君, 周渠, 等. 基于密度泛函理论的油中特征气体在钨掺杂 SnP3 单层上吸附及传感性能研究[J]. 中国电机工程学报, 2023, 43(5): 2040-2049.  
LIU Yupeng, HOU Wenjun, ZHOU Qu, et al. Investigation

- on adsorption and sensing performance of characteristic gas in oil on palladium-doped SnP3 monolayer based on density functional theory[J]. Proceedings of the CSEE, 2023, 43(5): 2040-2049.
- [3] 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 Tongliang, HU Dong, TANG Chao, 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.
- [4] 谢乐, 仇炜, 李振伟, 等. 基于变分模态分解和门控循环单元神经网络的变压器油中溶解气体预测模型[J]. 高电压技术, 2022, 48(2): 653-660.  
XIE Le, QIU Wei, LI Zhenwei, et al. Prediction model of dissolved gas in transformer oil based on variational modal decomposition and recurrent neural network with gated recurrent unit[J]. High Voltage Engineering, 2022, 48(2): 653-660.
- [5] 贾茹宾, 高金峰. 基于 ARIMA 模型的变压器油中溶解气体含量时间序列预测方法[J]. 郑州大学学报(工学版), 2020, 41(2): 67-72.  
JIA Rubin, GAO Jinpeng. Time series prediction method of dissolved gas content in transformer oil based on ARIMA model[J]. Journal of Zhengzhou University(Engineering Science Edition), 2020, 41(2): 67-72.
- [6] 刘航, 王有元, 梁玄鸿, 等. 基于多因素的变压器油中溶解气体体积分数预测方法[J]. 高电压技术, 2018, 44(4): 1114-1121.  
LIU Hang, WANG Youyuan, LIANG Xuanhong, et al. Prediction method of the dissolved gas volume fraction in transformer oil based on multi factors[J]. High Voltage Engineering, 2018, 44(4): 1114-1121.
- [7] 杨廷方, 刘沛, 李浙, 等. 应用新型多方法组合预测模型估计变压器油中溶解气体体积分数[J]. 中国电机工程学报, 2008, 28(31): 108-113.  
YANG Tingfang, LIU Pei, LI Zhe, et al. A new combination forecasting model for concentration prediction of dissolved gases in transformer oil[J]. Proceedings of the CSEE, 2008, 28(31): 108-113.
- [8] 连文莉, 耿波, 周舟, 等. 基于自适应粒子群优化 LSSVM 的变压器油中溶解气体体积分数预测[J]. 电工电能新技术, 2021, 40(5): 42-49.  
LIAN Wenli, GENG Bo, ZHOU Zhou, et al. Predicting method for dissolved gas in transformer oil based on improved self-adaptive PSO algorithm and LSSVM[J]. Advanced Technology of Electrical Engineering and Energy, 2021, 40(5): 42-49.
- [9] 陈铁, 陈卫东, 李咸善, 等. 基于油中溶解气体分析的变压器故障预测[J]. 电子测量技术, 2021, 44(22): 25-31.  
CHEN Tie, CHEN Weidong, LI Xianshan, et al. Transformer fault prediction based on analysis of dissolved gas in oil[J]. Electronic Measurement Technology, 2021, 44(22): 25-31.
- [10] 苏磊, 陈璐, 徐鹏, 等. 基于 GRNN 和 KPCA 组合模型的变压器油中气体体积分数短期预测[J]. 高压电器, 2021, 57(1): 82-88.  
SU Lei, CHEN Lu, XU Peng, et al. Short-term prediction of gases dissolved in transformer oil based on GRNN and KPCA model[J]. High Voltage Apparatus, 2021, 57(1): 82-88.
- [11] 江兵, 杨春, 杨雨亭, 等. 基于 ACO 优化 BP 神经网络的变压器热点温度预测[J]. 电子测量与仪器学报, 2022, 36(10): 235-242.  
JIANG Bing, YANG Chun, YANG Yuting, et al. Temperature prediction of transformer hot spot based on BP neural network optimized by ACO[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 235-242.
- [12] DING Can, DING Qingchang, FENG Lu, et al. Prediction model of dissolved gas in transformer oil based on VMD-SMA-LSSVM[J]. IEEE Transactions on Electrical and Electronic Engineering, 2022, 17(10): 1432-1440.
- [13] 唐勇波, 熊印国. 基于二次维数约简的油中溶解气体体积分数预测[J]. 电工技术学报, 2017, 32(21): 194-202.  
TANG Yongbo, XIONG Yinguo. Prediction model for dissolved gases content in transformer oil based on twice dimensionality reduction[J]. Transactions of China Electrotechnical Society, 2017, 32(21): 194-202.
- [14] 李可军, 亓孝武, 魏本刚, 等. 基于核极限学习机误差预测修正的变压器顶层油温预测[J]. 高电压技术, 2017, 43(12): 4045-4053.  
LI Kejun, QI Xiaowu, WEI Bengang, et al. Prediction of transformer top oil temperature based on kernel extreme learning machine error prediction and correction[J]. High Voltage Engineering, 2017, 43(12): 4045-4053.
- [15] 周锋, 孙廷玺, 权少静, 等. 基于集合经验模态分解和极限学习机的变压器油中溶解气体体积分数预测方法[J]. 高电压技术, 2020, 46(10): 3658-3665.  
ZHOU Feng, SUN Tingxi, QUAN Shaojing, et al. Prediction of dissolved gases concentration in transformer oil based on ensemble empirical mode decomposition and extreme learning machine[J]. High Voltage Engineering,

---

2020, 46(10): 3658-3665.

- [16]刘可真, 苟家萁, 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体积分数预测方法[J]. 电网技术, 2020, 44(7): 2778-2784.

LIU Kezhen, GOU Jiaqi, LUO Zhao, et al. Prediction of dissolved gas concentration in transformer oil based on PSO-LSTM model[J]. Power System Technology, 2020, 44(7): 2778-2784.

- [17]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体积分数预测方法[J]. 中国电机工程学报, 2019, 39(13): 3998-4007.

LIU Yunpeng, XU Ziqiang, DONG Wangying, et al. Concentration prediction of dissolved gases in transformer oil based on empirical mode decomposition and long short-term memory neural networks[J]. Proceedings of the CSEE, 2019, 39(13): 3998-4007.

- [18]舒 畅, 金 潇, 李自品, 等. 基于 CEEMDAN 的配电变压器放电故障噪声诊断方法[J]. 高电压技术, 2018, 44(8): 2603-2611.

SHU Chang, JIN Xiao, LI Zipin, et al. Noise diagnosis method of distribution transformer discharge fault based on CEEMDAN[J]. High Voltage Engineering, 2018, 44(8): 2603-2611.

- [19]李 佳, 邓 科, 侯玉莲, 等. 基于 GRA-CEEMDAN-BiLSTM 的变压器油中溶解气体体积分数预测[J]. 变压器, 2022, 59(6): 42-47.

LI Jia, DENG Ke, HOU Yulian, et al. Prediction of dissolved gas concentration in transformer oil based on GRA-CEEMDAN-BiLSTM[J]. Transformer, 2022, 59(6): 42-47.

- [20]TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C]//2011 IEEE International Conference on Acoustics , Speech and Signal Processing (ICASSP). [S.l.]: IEEE, 2011: 4144-4147.

- [21]陈 铁, 陈一夫, 李咸善, 等. 基于 SDS-SSA-LSTM 的变压器油中溶解气体体积分数预测[J]. 电子测量技术, 2022, 45(12): 6-11.

CHEN Tie, CHEN Yifu, LI Xianshan, et al. Prediction of dissolved gas concentration in transformer oil based on SDS-SSA-LSTM[J]. Electronic Measurement Technology, 2022, 45(12): 6-11.

- [22]HEIDARI AA, MIRJALILI S, FARIS H, et al. Harris hawks optimization : Algorithm and applications[J]. Future Generation Computer Systems, 2019(97): 849-872.

傅雨晨(1999—), 女, 硕士研究生, 主要研究方向为人工智能应用(E-mail: 202108580021063@ctgu.edu.cn)。

陈 星(1988—), 女, 硕士, 讲师, 主要研究方向为电力设备状态监测与故障诊断(通信作者)(E-mail: chenxing20230511@163.com)。

付文龙(1988—), 男, 博士, 副教授, 博导, 主要研究方向为人工智能应用、电力设备状态监测与故障诊断(E-mail: ctgu\_fuwenlong@126.com)。