

DOI:10.19651/j.cnki.emt.2315198

# 基于变分模态分解-布谷鸟搜索-支持向量回归的 变压器油中溶解气体浓度预测方法\*

王娜娜<sup>1,3</sup> 栗文义<sup>1,2</sup> 李建菽<sup>3</sup>

(1. 内蒙古工业大学能源与动力工程学院 呼和浩特 010080; 2. 内蒙古工业大学电力学院 呼和浩特 010080;  
3. 内蒙古电力(集团)有限责任公司培训中心 呼和浩特 010010)

**摘要:** 针对电力变压器油中溶解气体浓度预测过程中存在的时间序列内部复杂和预测困难等问题,研究了时间序列分解预测重构方式,提出变分模态分解,结合布谷鸟搜索-支持向量回归组合预测方法。首先采用VMD将原始溶解气体浓度分解成为一组平稳的模态分量,降低了预测的复杂度。之后利用预测性能较好的SVR对各个模态分量分别进行预测。最后使用CS开展全局搜索对SVR参数进行优化选取,将得到的溶解气体浓度预测结果进行叠加重构。通过对油中溶解气体中H<sub>2</sub>的仿真实验,得到VMD-CS-SVR组合模型预测结果的均方根误差为0.124 μL/L,平均绝对百分比误差为1.19%,有效提升了预测精度。通过对CO和C<sub>2</sub>H<sub>4</sub>建模预测,进一步验证了本文所提模型的有效性。

**关键词:** 电力变压器;油中溶解气体浓度;支持向量回归;布谷鸟搜索;模态分解

**中图分类号:** TM411 **文献标识码:** A **国家标准学科分类代码:** 470.40

## Prediction of dissolved gas content in transformer oil based on variational mode decomposition-cuckoo search-support vector regression model

Wang Nana<sup>1,3</sup> Li Wenyi<sup>1,2</sup> Li Jianqiu<sup>3</sup>

(1. College of Energy and Power Engineering, Inner Mongolia University of Technology, Hohhot 010080, China;  
2. College of Electric Power, Inner Mongolia University of Technology, Hohhot 010080, China;  
3. Inner Mongolia Power(Group)Co., Ltd., Hohhot 010010, China)

**Abstract:** Aiming at the problems of internal complexity and too hard predicting the dissolved gas concentration of transformer oil, a method combining VMD with CS-SVR was proposed for decomposing, predicting, and reconstructing gas concentration. In this paper, firstly, VMD is utilized to decompose the original dissolved gas concentration into a set of stationary modal components. Subsequently, SVR, which has relatively good predictive performance, was used to predict each modal component separately. Finally, CS is utilized for global search to optimize and select SVR parameters, and the predicted dissolved gas concentration results are overlaid and reconstructed. Through simulation experiments on the H<sub>2</sub> content, the root mean square error is 0.124 μL/L and the average absolute percentage error is 1.19%, effectively enhancing prediction accuracy. Further validation of the model's effectiveness is conducted through modeling and predicting CO and C<sub>2</sub>H<sub>4</sub>. The results indicate that the VMD-CS-SVR model has high accuracy and is suitable for predicting dissolved gas concentration in transformer oil.

**Keywords:** power transformer; dissolved gas content; support vector regression; cuckoo search; modal decomposition

## 0 引言

随着碳中和、碳达峰目标的不断深化推进,对于建设新型电力系统提出了更为迫切的要求<sup>[1]</sup>。电力变压器作为电

力系统至关重要的设备,在大规模可再生能源接入的背景下,其安全稳定运行需要更加关注。在极端天气、人为误操作、设备老旧等多重因素的综合作用下,导致电力变压器故障频繁发生。油浸式变压器正常运行时有少量气体溶解在

收稿日期:2023-12-19

\* 基金项目:内蒙古自治区直属高校基本科研费项目(JY20220421)资助

变压器油中,一旦发生故障油中溶解气体会显著变化。变压器油中溶解多种气体,例如氢气( $H_2$ ),一氧化碳( $CO$ ),二氧化碳( $CO_2$ ),甲烷( $CH_4$ ),乙烷( $C_2H_6$ ),乙炔( $C_2H_2$ )和乙烯( $C_2H_4$ )等气体。由于变压器故障类别、故障发生部位及其故障部位能量汇集密度均与油中溶解气体的成分和浓度紧密相连,因此可以通过分析油中溶解气体成分、浓度大小、浓度比值的变化趋势,表征出变压器可能存在的潜伏性故障<sup>[2-3]</sup>。通过监测变压器状态数据,以建模的方式进行相关数据预测,可为变压器运行维护和状态预测提供重要的研判依据。因此,实现油中溶解气体浓度变化趋势的准确预测可为变压器的生产维护提供有力依据,在工业生产和科学研究中有重要意义<sup>[4-5]</sup>。

油中溶解气体在线监测系统是以设定好的采样周期连续不间断采集油中溶解气体数据,监测溶解气体浓度,形成溶解气体浓度时间序列。对该组时间序列进行深度挖掘,探究其随时间变化的演变规律,可将未来某时间段的气体浓度进行预测,则能及时掌握变压器内部状态,预判出绝缘劣化及内部故障情况,尽早排查出潜在事故隐患,便于维护人员进行预案处置。由于变压器在实际运行中会受到周围环境、运行工况及设备器身构造等多方面因素的影响,导致其内部绝缘劣化机理复杂,故障的发生具有不确定性<sup>[6-7]</sup>。油中溶解气体的产生与内部故障密切相关,因此溶解气体时间序列也呈现出复杂性和非线性的特点。

时间序列预测是用一组或几组历史数据来预测该数据未来发展趋势的一种方法,其具有样本有限、预测精度高等优点,因此得到了广泛的应用。进行预测建模时需要分析时间序列自身特点,还要考虑外界因素对时间序列波动的影响以及预测方法的优缺点<sup>[8]</sup>。近年来,许多研究学者对变压器油中溶解气体浓度进行了建模预测,主要分为3类方法:数据统计方法预测模型、人工智能方法预测模型及数据统计与人工智能等方法的组合预测模型。数据统计方法以灰色理论为代表,将其加以改进来预测变压器油中溶解气体浓度<sup>[9]</sup>。该类方法由于拟合函数比较单一,还需要经验分析判断,使得预测模型结构较为简单,难以反映出时间序列自身的数据分布特性。随着人工智能方法的快速崛起,越来越多的智能方法被应用在变压器预测及故障诊断中<sup>[10-11]</sup>。支持向量回归(support vector regression, SVR)是基于统计模型上改进的一种人工智能方法,利用结构风险最小化思想提升模型泛化能力,特别适用于高维度、小样本以及非线性等特征的数据。因此SVR可以对油中溶解气体浓度时间序列进行很好的预测,得到广泛的应用。文献[12]提出使用改进信息熵方法获取各溶解气体的权重并对原始数据进行加权,将处理后的训练数据和相应的故障类型输入到模糊支持向量机(fuzzy support vector machine, FSVM)模型中进行故障分类诊断,进而提高故障诊断准确性。文献[13]利用多尺度标准差模糊熵和哈里斯鹰算法组合后优化支持向量机(support vector machine,

SVM),建立变压器故障诊断模型。组合模型的主要思想是将所用的智能方法利用组合其他方法加以改进,进而提升模型精度。文献[14]采用组合模型对机电系统损伤状态识别,将损伤状态数据进行经验模态分解(empirical mode decomposition, EMD),利用多个不同时间尺度的子序列分量构造能量特征向量,最后使用SVM模型进行状态识别。但是EMD分解容易模态混叠现象,导致序列分解效果一般,需要对EMD进行改进后效果更佳。文献[15]中提到变分模态分解(variational mode decomposition, VMD)是一种具有强大自适应能力的滤波器,可以很好抑制EMD产生的模态混叠现象。文献[16]利用VMD对油色谱时间序列进行平稳化处理分解,并采取非支配排序遗传算法优化的SVR对模态分量进行预测,再将预测的模态分量重构得到最终预测结果,弥补了单一预测模型的不足。

基于上述分析可知,采用SVR进行油中溶解气体预测可以得到较为准确的预测结果。但是由于SVR回归预测的精度严重依赖模型参数的选取,为了提升预测精度,需要在建模之前对其参数进行优化。目前参数选取有交叉验证法和测试给定、超参数网格搜索调优等方法。直接给定参数对无标签测试集的模型精度影响较大,但是交叉验证参数在寻优过程中需要空间足够大同时步距尽可能小,使得建模迭代次数增多进而耗费时间更长,导致模型的实时性差。因此,如何高效的进行参数优化选取是SVR回归预测模型亟待解决的问题。

对于变压器油中溶解气体时间序列数据集的特点及目前已有预测模型的不足,提出了一种基于VMD分解后布谷鸟搜索算法(cuckoo search, CS)优化SVR的变压器油中溶解气体浓度预测模型,并对某实测气体浓度数据集进行验证。实验结果表明,所提出模型可有效克服SVR模型精度依赖其选取参数的缺陷,有效提升了气体浓度的预测精度。

## 1 变压器油中溶解气体浓度预测方法

### 1.1 变分模态分解

VMD通过实际情况确定输入序列的模态分解个数,在分解过程中可以自适应地搜索到各种模态的最优中心频率和有限带宽,完成各个模态分量的分离,实现变分模态的最优解。VMD适用于复杂度高和非线性强的非平稳时间序列,可以分解时间序列为多个不同频率尺度的相对平稳的子序列。其核心步骤是构建和求解变分问题<sup>[17-18]</sup>。

#### 1) 构建变分问题

假设把原始序列 $T(n)$ 被分解为 $K$ 个模态分量 $u_k(n)$ ,分解得到的各个模态分量的有限带宽在中心频率 $\omega_k$ 的位置,并且各个模态分量具有最小估计带宽总和,同时约束条件还需要满足所有模态求和后等同于初始信号,进而得到VMD的约束变分模型如下:

$$\begin{cases} \min_{\{\omega_k, \lambda\}} \left\{ \sum_{k=1}^K \left\| \partial_n \left[ \left( \delta(n) + \frac{j}{\pi n} \right) * u_k(n) \right] e^{-j\omega_k n} \right\|_2^2 \right\} \\ s.t. \sum_{k=1}^K u_k(n) = T(n) \end{cases} \quad (1)$$

其中,  $\delta(n)$  是冲激函数;  $\partial_n$  表示对  $n$  进行偏导数求取,  $*$  代表卷积运算。

2) 求解变分问题

为了解决上述的约束最优化问题, 将约束变分问题转变为非约束变分问题, 利用二次惩罚项  $\alpha$  和拉格朗日算子法  $\lambda(n)$  的优势, 引入增广 Lagrangian 函数, 如下:

$$L_{(\omega_k, \lambda)} = \alpha \sum_{k=1}^K \left\| \partial_n \left[ \left( \delta(n) + \frac{j}{\pi n} \right) * u_k(n) \right] e^{-j\omega_k n} \right\|_2^2 + \left\| T(n) - \sum_{k=1}^K u_k(n) \right\|_2^2 + \langle \lambda(n), T(n) \rangle - \sum_{k=1}^K u_k(n) \quad (2)$$

迭代寻找最优解, 更新泛函步骤如下:

(1) 初始化  $u_k, \omega_k, \lambda^1$  和  $m = 0$ , 设置迭代次数  $m = m + 1, u_k, \omega_k, \lambda$  依次按照式(3)~(5)迭代更新。

(2) 设置非负频率区间, 更新  $u_k$ :

$$\hat{u}_k^{m+1}(\omega) = \frac{\hat{T}(\omega) - \sum_{s=1}^{k-1} \hat{u}_s^m(\omega) + \hat{\lambda}^n(\omega)/2}{1 + 2\alpha(\omega + \omega_m^k)^2} \quad (3)$$

其中,  $\hat{u}_k^{m+1}(\omega), \hat{T}(\omega), \hat{\lambda}^n(\omega)$  一一对应  $u_k^{m+1}, T(n), \lambda^n$  的傅里叶变换。

(3) 将  $\omega_k$  进行更新。

$$\omega_k^{m+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{m+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{m+1}(\omega)|^2 d\omega} \quad (4)$$

(4) 进而在非负频率  $\tau$  区间内, 更新  $\lambda$ 。

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau [\hat{T}(\omega) - \sum_{k=1}^K \hat{u}_k^{m+1}(\omega)] \quad (5)$$

(5) 定义判定精度  $\epsilon$ , 保证  $\epsilon > 0$  得到如下:

$$\frac{\sum_{k=1}^K \|\hat{u}_k^{m+1} - \hat{u}_k^m\|_2^2}{\|\hat{u}_k^m\|_2^2} < \epsilon \quad (6)$$

如式(6)成立则停止迭代, 否则返回步骤(2)继续执行。

1.2 支持向量回归

SVR 是一种基于统计学习理论的机器学习方法, 具有较为出色的泛化能力, 以及较高的预测精度, 能很好地解决小样本、数据非线性等难题, 因而在状态评估、回归预测、模式识别等领域得到广泛的应用。SVR 的主要思想是把具有复杂关系的低维向量非线性映射到高维特征空间, 在高维特征空间中向量可以一一对应进而线性回归, 解决了常规空间无法回归的难题。

找到非线性回归函数, 如式(7)所示, 用该函数去拟合训练样本中的数据  $\{x_i, y_i\}$ , 从而找到一条直线, 可使得样本中的数据点与这条直线的距离最短。

$$y_i = f(x_i) = \omega \cdot \phi(x_i) + b \quad (7)$$

式中:  $x_i$  为输入,  $f(x_i)$  为输出,  $\omega$  为权重,  $\phi(x_i)$  为映射函数,  $b$  为偏差。

因此就是寻找合适的参数  $\omega$  和  $b$ , 具体算式如下:

$$\begin{cases} \min_{\omega} \frac{1}{2} \|\omega\|^2 \\ s.t. \omega \cdot \phi(x_i) + b - y_i \leq \epsilon \\ y_i - \omega \cdot \phi(x_i) - b \leq \epsilon, i = 1, 2, \dots, n \end{cases} \quad (8)$$

在求解过程中, 加入松弛变量  $\delta_i \geq 0, \delta_i^* \geq 0$  以及惩罚因子  $C$ , 使得拟合过程中可有一定的误差裕量, 因此上式中的最优化求解如下:

$$\begin{cases} s.t. \omega \cdot \phi(x_i) + b - y_i \leq \epsilon + \delta_i \\ y_i - \omega \cdot \phi(x_i) - b \leq \epsilon + \delta_i^* \\ \delta_i \geq 0, \delta_i^* \geq 0, i = 1, 2, \dots, n \end{cases} \quad (9)$$

引入拉格朗日乘子  $\lambda, \lambda^*, \eta, \eta^*$ , 得出以下性能函数:

$$L(\omega, b, \lambda, \lambda^*, \delta_i, \delta_i^*, \eta, \eta^*) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\delta_i + \delta_i^*) - \sum_{i=1}^n \lambda (\epsilon + \delta_i + y_i - \omega \cdot \phi(x_i) - b) - \sum_{i=1}^n \lambda^* (\epsilon + \delta_i^* - y_i + \omega \cdot \phi(x_i) + b) - \sum_{i=1}^n (\eta_i \delta_i + \eta_i^* \delta_i^*) \quad (10)$$

因此得到非线性回归函数如下:

$$y_i = f(x) = \sum_{i=1}^n (\lambda_i^* - \lambda_i) K(x_i, x_j) + b \quad (11)$$

式中;  $K$  为径向基核函数 RBF, 如下所示:

$$K(x_i, x_j) = \exp \left\{ - \frac{\|x_i - x_j\|^2}{2\sigma^2} \right\} = \exp \{ \gamma \|x_i - x_j\|^2 \} \quad (12)$$

其中,  $x_i$  与式(7)相同, 代表训练样本的输入变量,  $x_j$  则对应测试样本的输入变量,  $\gamma$  是核函数的参数, 表征 RBF 的核半径。

1.3 布谷鸟搜索算法

CS 核心思想是借鉴布谷鸟产蛋之后寻找最佳鸟巢放蛋的过程, 同时结合了动物的 Lévy 飞行行为, 通过全局游走和局部随机游走的方式来有效地确定最优方案<sup>[19-20]</sup>。寻优过程由三个部分组成, 分别是局部随机搜索、最优解的识别以及全局 Lévy 飞行的随机搜索。基于以下 3 个理想条件进行 CS 参数寻优:

- 1) 每只布谷鸟每次只进行一次产蛋(对应优化一个参数), 随机进行寄生鸟巢的寻优。
- 2) 在寻找过程中, 最优鸟巢位置可保持到下一次寻优。
- 3) 寄生鸟巢个数具有固定特征, 每个鸟巢被发现的概率  $P_a \in [0, 1]$ 。

对下代鸟巢位置通过全局游走进行种群更新:

$$x_k^{t+1} = x_k^t + \alpha L(\lambda) \quad (13)$$

其中,  $x_k^{t+1}$  表示布谷鸟更新之后位置;  $x_k^t$  表示第  $i$  只布谷鸟在第  $t$  代的位置;  $\alpha$  表示步长因子;  $\lambda$  是 Lévy 指数;  $L(\lambda)$  是随机寻优搜索的步长。

对于鸟巢寻优的搜索路径均要服从 Lévy 的飞行原则,

如下:

$$L(\lambda) = \frac{\mu}{|\nu|^{\frac{1}{\lambda}}} \quad (14)$$

其中,  $\mu$  与  $\nu$  都是随机产生的数,当满足式(14)中的寻优路径则进行更新迭代,实现局部随机搜索。当所有鸟巢的位置完成搜索,完成了全局搜索,代表搜索到达最大优化迭代次数,寻优任务结束。

## 2 VMD-CS-SVR 组合预测模型

### 2.1 VMD 参数选取

黏菌优化算法(slime mould algorithm, SMA)在 2020 年由 Li 等人提出,以黏菌多头绒泡菌为研究对象,研究其捕食过程中行为和生理变化,以此构建数学模型。SMA 作为一种新的仿生学优化算法,相关研究已经证实其能够在实际问题中迅速收敛并找到最优解。相对于其他优化算法,例如算术运算算法(arithmetic optimization algorithm, AOA)、海洋捕食者算法(marine predators algorithm, MPA)以及樽海鞘优化算法(salp swarm algorithm, SSA),黏菌算法在在精度和稳定性方面具备更出色的性能<sup>[21]</sup>。文献[17]中讨论了 VMD 参数选取的不同对最终信号分解结果的差异,进一步验证了  $K$  和  $\alpha$  参数寻优的重要性。因此,本文采用 SMA 对 VMD 的参数  $K$  和  $\alpha$  进行优化选取,以最小包络熵为适应度值,参数寻优的步骤如文献[22]。

### 2.2 SVR 参数优化

SVR 模型的精度与惩罚因子  $C$  和核函数参数  $\gamma$  密切相关。在油中溶解气体浓度预测中,可利用参数优化算法与 SVR 组合模行进行预测。本文利用 CS 对 SVR 的参数  $C$  和  $\gamma$  进行优化,提升其模型预测性能,参数优化流程如图 1 所示。

### 2.3 VMD-CS-SVR 组合预测模型框架

VMD-CS-SVR 组合预测模型流程如图 2 所示。预测模型大致可分为 4 个步骤:

- 1)首先使用 VMD 对原始序列进行模态分解,得到多个不同频率尺度的相对平稳的模态分量。
- 2)对各模态分量做归一化处理,然后对其分别进行 SVR 模型预测。
- 3)使用 CS 对 SVR 进行参数寻优,使用最优化 SVR 模型对分解序列预测。
- 4)对得到的做反归一化处理,再将各模态预测分量求和重构,获得最终预测值。

为了定量说明文中提出的 VMD-CS-SVR 的模型具有较好的预测性能,采用均方根误差  $y_{RMSE}$ 、平均绝对百分比误差  $y_{MAPE}$  进行预测效果评价。平均绝对误差、均方根误差越小,预测精度越大,则表示模型拟合的效果越好,预测的越准确。

$$y_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^k (x_{act}(i) - x_{pred}(i))^2} \quad (15)$$

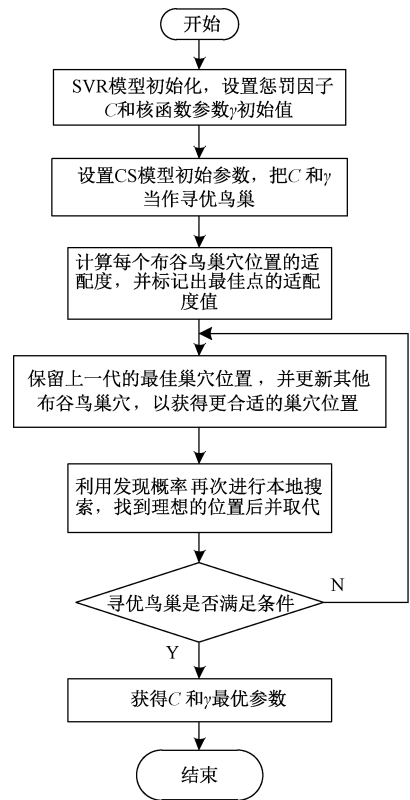


图 1 CS-SVR 参数寻优流程

$$y_{MAPE} = \frac{100\%}{n} \sum_{i=1}^n |x_{act}(i) - x_{pred}(i)| \quad (16)$$

式中:  $x_{act}(i)$  和  $x_{pred}(i)$  是第  $i$  个样本的真实值和预测值,  $n$  是样本的总数。

## 3 实验与分析

样本数据集选用内蒙古某 220 kV 在投变压器油中溶解气体在线监测装置采集到的 500 组等间隔未间断数据, 采样时间为 2019 年 6 月 14 日~2020 年 10 月 26 日, 采集周期为 1 天/次。将前 385 组数据划分为训练集, 其余的 115 组数据作为测试集, 每种气体单一进行建模预测。将前 1~15 天的测试集数据输入到训练好的模型, 预测出第 16 天的气体浓度。然后用 2~15 天的测试集数据加上预测得到的第 16 天的预测值共 15 个数据作为测试集输入到训练好的模型, 预测出第 17 天的气体浓度, 依此类推得到共 100 天浓度预测值。本文以预测性能较好的 SVR 作为基础预测模型, 进而对比其参数优化前后的预测效果, 得到理想的预测模型, 提升溶解气体预测精度。SVR 的初始迭代次数设置为 100。CS 进行优化 SVR 更新模型参数, 发现概率 0.25, 鸟巢数量 20。软件版本为 MATLAB 2019, CPU 为 RAM24 G/2.90 GHz。首先以  $H_2$  浓度为例开展实验。

### 3.1 SVR 模型预测

利用 SVR 和 CS-SVR 模型进行建模预测, 预测结果如

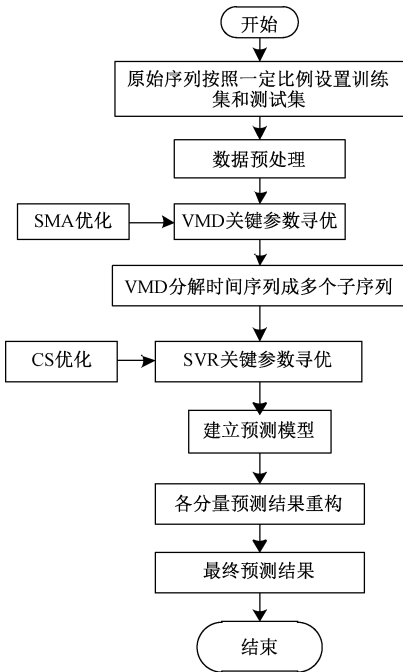


图 2 VMD-CS-SVR 组合预测方法流程

图 3 所示。SVR 可以用来预测油中溶解气体浓度,但由于其模型无法找到最优参数,因此预测效果不佳。与 SVR 相比,经过 CS 优化后的 SVR 预测曲线更接近真实值,预测精度有所提升。经过计算,  $y_{RMSE}$  和  $y_{MAPE}$  的 CS-SVR 模型误差分别为  $0.979 \mu\text{L/L}$  和  $15.7\%$ , 分别比 SVR 模型误差少  $0.423 \mu\text{L/L}$  和  $7.4\%$ 。进一步证实了经过参数优化后的 SVR 模型更准确地预测溶解气体浓度。




图 3 SVR 预测结果对比图

### 3.2 VMD-CS-SVR 模型预测

VMD-CS-SVR 的预测步骤首先通过 SMA 对 VMD 的参数  $K$  和  $\alpha$  进行寻优,如图 4 所示。求取不同种群下的最优目标函数值,种群数量为 30,迭代次数 20,通过求取包络熵,得出最优的  $K$  为 9,  $\alpha$  为 270。

图 5 为不同迭代次数下模态中心频率。显而易见,使




图 4 不同种群数下目标函数下降曲线

用 VMD 分解  $\text{H}_2$  浓度时间序列后得到的各模态分量的中心频率并未出现交叠,为后续时间序列分量预测打下良好的基础。




图 5 SMA 最优分解中心频率

经过 SMA-VMD 分解后得到的模态分量 (intrinsic mode function, IMF),如图 6 所示。采用 VMD 可将  $\text{H}_2$  原始时间序列分解多个具有平稳特性的低频高振幅的子序列和具有相同变化规律的高频低振幅子序列。这一步骤可以将变压器油中溶解气体序列关联因素如周围环境、运行工况及设备器身构造等多方面信息进行分解提取。这种处理方式可以将以上影响因素的信息与气体浓度信息进行剥离,降低了变压器油中溶解气体预测的复杂性,是建模重要的步骤之一。

SMA-VMD 分解得到 IMF 的分量频谱如图 7 所示,分布界限相对清晰,没有明显交叠现象,很好抑制混合频率。因此可知采用此方法进行分解分量,效果显著。对得到的分量进行下一步的预测,得到的分量预测结果如图 8 所示。预测曲线与实际曲线非常接近,因此可以看出文中提出的 VMD-CS-SVR 组合模型无论平稳的低频高振幅子序列和变化规律的高频低振幅子序列都可以实现精准预测。将预




图6 SMA-VMD分解分量

测的 IMF 分量进行进一步的叠加,可得到  $H_2$  浓度最终预测结果,如图 9 所示。对比图 3 和 9 可知,经过模态分解的预测曲线比原始序列预测曲线更贴近实际曲线,对于通过计算得出  $H_2$  含量预测误差  $y_{RMSE}$  和  $y_{MAPE}$  分别为  $0.124 \mu\text{L/L}$  和  $1.19\%$ 。因此可知,经过 VDM 分解之后再 进行预测重构,可以大幅降低模型的复杂度,为后续的精 确预测打下坚实基础。对比 SVR,CS-SVR 预测模型,本文 提出的 VMD-CS-SVR,预测精度得到了很大提升。




图7 SMA-VMD分解频谱




图8 VMD-CS-SVR分量预测结果




图9 VMD-CS-SVR模型  $H_2$  浓度预测结果

### 3.3 VMD-CS-SVR 模型验证

为了进一步验证所提出的预测模型的有效性,以另外两种油中溶解气体  $CO$  和  $C_2H_4$  进行建模预测。模型搭建、参数设置和数据集划分等均与  $H_2$  预测方法保持一致。

$CO$  和  $C_2H_4$  两种气体分解重建后的最终含量预测结果如图 10 和 11 所示,绝大部分  $CO$  的浓度在  $360 \sim 390 \mu\text{L/L}$  之间, $C_2H_4$  浓度在  $23 \sim 33 \mu\text{L/L}$  之间,预测曲线与真实曲线高度重合,说明本文提出的模型同样适用于其它油中溶解气体,验证了模型有效性。此外,从图 10 和 11 中还能明显观察到气体浓度突然发生较大变化时,预测模型还可以有效地捕捉到浓度的变化趋势,实现气体浓度的准确预测。这对于变化复杂、波动频繁的油中溶解气体浓度特别适用。

进一步计算 VMD-CS-SVR 模型预测误差,如表 1 所示。利用组合模型预测后, $CO$  的中  $y_{RMSE}$  仅为  $0.476 \mu\text{L/L}$ ,  $C_2H_4$  仅为  $0.374 \mu\text{L/L}$ 。结合图 10 和 11 的预测值,进一步证实了本文中提出的 VMD-CS-SVR 组合预测模型可准确预测复杂变化的变压器油中溶解气体浓度,可为其它复杂的时间序列预测提供一些思路。




图 10 CO 浓度预测结果


图 11 C<sub>2</sub>H<sub>4</sub> 浓度预测结果

表 1 VMD-CS-SVR 模型预测误差

油中溶解气体	$y_{RMSE} / (\mu\text{L/L})$	$y_{MAPE} / \%$
CO/ $(\mu\text{L/L})$	0.476	0.981
C <sub>2</sub> H <sub>4</sub> / $(\mu\text{L/L})$	0.374	0.209

## 4 结 论

针对变压器油中溶解气体浓度序列小样本和非线性的特性导致预测模型精度欠佳的问题,提出了一种 VMD-CS-SVR 组合模型来进行变压器油中溶解气体浓度预测。

利用 SMA 优化后的 VMD 对原始序列进行模态分解,可得到多个不同频率尺度的模态分量,有效的解决了变压器油中溶解气体预测复杂性和非线性的成因的难题。

通过 CS 对 SVR 参数寻优,完成了变压器油中溶解气体浓度小样本建模,进一步提高模型的预测精。

对比变压器油中多种气体浓度预测实验结果,验证了所提出的组合模型对变压器油中溶解气体浓度预测的有效性,为进一步实现变压器故障诊断提供强有力的数据支撑。

由于样本的局限性,只对变压器正常运行的工况下的进行了预测,并未考虑变压器状态突变或溶解气体含量达

到注意值等情况,下一步可将数据样本完善,进行变压器完整工况的预测。

## 参考文献

- [1] 谭显东,刘俊,徐志成,等.“双碳”目标下“十四五”电力供需形势[J].中国电力,2021,54(5):1-6.
- [2] 国家能源局. 变压器油中溶解气体分析和判断导则: DL/T722—2014[S].北京:中国电力出版社,2015.
- [3] 徐征宇,汪可,孙建涛,等.直流电压下油纸绝缘局部放电发展过程的潜伏期特征[J].电网技术,2016,40(2):614-619.
- [4] 陈铁,陈一夫,李咸,等.基于 SDS-SSA-LSTM 的变压器油中溶解气体浓度预测[J].电子测量技术,2022,45(12):6-11.
- [5] 傅晓锦,杨成.基于 KPCA-ITSO-ELM-Adaboost 的变压器故障诊断方法[J].国外电子测量技术,2022,41(11):160-169.
- [6] 彭刚,周舟,唐松平,等.基于时序分析及变量修正的变压器故障预测[J].电子测量技术,2018,41(12):96-99.
- [7] 冯志亮,肖涵麒,任文凤,等.基于主成分分析的海鸥优化支持向量机变压器故障诊断[J].中国测试,2023,49(2):99-105.
- [8] LIU C, ZHANG H, XIE Z, et al. Combined forecasting method of dissolved gases concentration and its application in condition-based maintenance[J]. IEEE Transactions on Power Delivery, 2019, 34(4):1269-1279.
- [9] 吴汶健,何怡刚,段嘉璐,等.油中溶解气体的灰色模型残差修正融合算法[J].电子测量与仪器学报,2018,32(10):87-94.
- [10] 王雨虹,王志中,付华,等.多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究[J].仪器仪表学报,2022,43(3):87-97.
- [11] 谢国民,蔺晓雨.基于改进 SSA 优化 MDS-SVM 的变压器故障诊断方法[J].控制与决策,2023,28(2):459-467.
- [12] ZHANG H, SUN J, HOU K, et al. Improved information entropy weighted vague support vector machine method for transformer fault diagnosis[J]. High Voltage, 2022,7:510-522.
- [13] 邵凯旋,何怡刚,汪磊.基于多尺度熵分析与改进 SVM 的变压器故障识别[J].电子测量与仪器学报,2022,36(6):161-168.
- [14] 刘聪,钱坤,焦淮,等.用于损伤状态识别的极值延拓 EMD 和 LS-SVM 算法[J].计算机应用,2023,43(S2):256-260.
- [15] 向玲,邓泽奇,赵玥.基于 LPF-VMD 和 KELM 的风速多步预测模型[J].电网技术,2019,43(12):4461-4467.
- [16] 肖怀硕,李清泉,施亚林,等.灰色理论-变分模态分解和 NSGA-II 优化的支持向量机在变压器油中气体预

- 测中的应用[J]. 中国电机工程学报, 2017, 37(12): 3643-3653.
- [17] 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): 117-128.
- [18] 林晓, 张锐, 刘芳, 等. 基于变分模态分解的复杂航天器姿态扰动分析[J]. 振动与冲击. 2023, 42(13): 303-309.
- [19] 乔岩茹, 陈健龙, 侯文. 基于布谷鸟算法优化随机共振参数的轴承故障检测算法[J]. 电子测量技术, 2021, 44(20): 88-93.
- [20] 吴一全, 周建伟. 布谷鸟搜索算法研究及其应用进展[J]. 智能系统学报, 2020, 15(3): 435-444.
- [21] LI S, CHEN H, WANG M, et al. Slimemould algorithm: a new method for stochastic optimization[J]. Future Generation Computer Systems, 2020, 111: 300-323.
- [22] GÜRSSES D, BUREEAT S, SAIT S M, et al. Comparison of the arithmetic optimization algorithm, the slime mold optimization algorithm, the marine predators algorithm, the salp swarm algorithm for real-world engineering applications [J]. Materials Testing, 2021, 63(5): 448-452.

### 作者简介

王娜娜, 博士研究生, 主要研究方向为电力设备故障诊断。

栗文义(通信作者), 博士, 教授, 主要研究方向为电力系统可靠性分析。

E-mail: 875024004@qq.com

李建菽, 硕士, 高级工程师, 主要研究方向为高电压试验技术。