

# 基于混合分解和 IDBO-TCN 的变压器油中溶解气体含量预测

付文龙<sup>1,2</sup>, 祝鑫锋<sup>1</sup>, 吴川锋<sup>1</sup>, 朱福宝<sup>1</sup>, 邵孟欣<sup>1</sup>, 赵一博<sup>1</sup>

(1. 三峡大学电气与新能源学院, 湖北 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, 湖北 宜昌 443002)

**摘要:** 准确预测变压器油中溶解气体的变化规律和趋势是保证变压器安全可靠运行的关键。为此提出一种基于混合分解和 IDBO-TCN 的油中溶解气体含量预测方法。首先, 利用自适应噪声完全集合经验模态分解对给定气体含量序列进行分解; 然后, 采用经验小波变换对分解出的最高频分量进行二次分解; 进一步对所有分量建立时序卷积网络预测模型; 同时提出改进蜣螂优化算法对 TCN 的初始学习率和卷积核大小进行优化; 最后, 将各分量的预测值累加, 得到最终预测结果。通过油中溶解气体 CH<sub>4</sub>、C<sub>2</sub>H<sub>4</sub>、C<sub>2</sub>H<sub>6</sub>、H<sub>2</sub> 和总烃的预测实例证明了所提方法的优越性。

**关键词:** 变压器油中溶解气体; 自适应噪声完全集合经验模态分解; 经验小波变换; 改进蜣螂优化算法; 时序卷积网络

## Prediction of Dissolved Gas Volume Fraction in Transformer Oil Based on Mixture Decomposition and IDBO-TCN

FU Wenlong<sup>1,2</sup>, ZHU Xinfeng<sup>1</sup>, WU Chuanfeng<sup>1</sup>, ZHU Fubao<sup>1</sup>, SHAO Mengxin<sup>1</sup>, ZHAO Yibo<sup>1</sup>

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Hubei Yichang 443002, China;  
2. Hubei Provincial Key Laboratory for Operation and Control of Cascaded Hydropower Station, China Three Gorges University, Hubei Yichang 443002, China)

**Abstract:** Accurate prediction of the change rule and trend of dissolved gas in transformer oil is crucial in ensuring the safe and reliable operation of transformer. For this purpose, a prediction method based on mixture decomposition and IDBO-TCN is proposed to predict dissolved gases content in transformer oil. Firstly, the given gas content sequence is decomposed by using complete ensemble empirical mode decomposition with adaptive noise. Subsequently, empirical wavelet transform is applied to perform a second decomposition of the highest frequency component. Then, temporal convolutional network is established for all components. Simultaneously, the improved dung beetle optimization is proposed to optimize the initial learning rate and convolution kernel size of TCN. Finally, predicted values of each component are accumulated to obtain the final prediction result. The advantages of the proposed method are demonstrated by predicting the dissolved gases CH<sub>4</sub>, C<sub>2</sub>H<sub>4</sub>, C<sub>2</sub>H<sub>6</sub>, H<sub>2</sub> and total hydrocarbons in oil.

**Key words:** dissolved gas in transformer oil; complete ensemble empirical mode decomposition with adaptive noise; empirical wavelet transform; improved dung beetle optimization; temporal convolutional network

## 0 引言

随着电力工业的快速发展, 变压器作为电力系统的关键设备, 其健康稳定运行对整个电力系统的安全至关重要<sup>[1]</sup>。在变压器长期运行过程中, 由于内部绝

缘油变质, 会导致少量烃类气体溶解在绝缘油中<sup>[2]</sup>。

一般来说, 随着运行时间的延长, 溶解气体含量会逐渐积累, 且烃类气体多为可燃气体, 会对变压器的安全运行构成很大威胁<sup>[3]</sup>。溶解气体分析技术是识别变

**基金项目:** 国家自然科学基金资助项目(51741907); 国网吉林省电力有限公司科技项目(2023JBGS-08)。

Project Supported by National Natural Science Foundation of China(51741907), Science and Technology Project of State Grid Jilin Province Electric Power Company(2023JBGS-08).

压器内部故障的重要手段,其根据油中气体的含量和变化率推断出变压器的固有缺陷和潜在故障<sup>[4]</sup>。因此,准确预测油中溶解气体含量的变化对于保证变压器安全可靠运行具有重要意义<sup>[5]</sup>。

近年来,变压器油中溶解气体含量预测成为研究热点。学者们提出了多种预测方法,主要分为基于统计模型的方法和人工智能模型的方法,其中基于统计模型的方法主要包括灰色系统理论、整合移动平均自回归和卡尔曼滤波,虽然这类模型具有建模简单、拟合速度快、实时修正局部数据的优势,但在拟合溶解气体含量等非线性数据时,此类模型无法发挥有效的预测性能<sup>[6]</sup>。相比之下,人工智能模型因其突出的非线性映射能力和自学习能力而备受关注<sup>[7]</sup>。如文[8]基于变分模态分解将原始序列分解为多个子序列,再利用门控循环单元对各个子序列进行预测,有效降低了数据非平稳性的影响。文[9]提出一种基于麻雀搜索算法和双向门控循环单元的组合预测模型,能够较好预测油中溶解气体含量。文[10]提出了一种融合一维卷积神经网络(CNN)和长短时记忆网络(LSTM)的组合预测模型,解决了单一 LSTM 无法对数据间的深层特征进行有效提取的问题,具有较高精度。然而,过多的历史数据会导致 LSTM 及其变体计算负担变高,并且随着递推次数的增加,误差会不断累积,降低预测精度<sup>[11]</sup>。相比之下,从 CNN 演变而来的时序卷积网络(TCN)更适合处理大规模时间序列数据集<sup>[12]</sup>。

变压器油中溶解气体数据具有非线性和非平稳特点,单一预测模型难以实现高精度预测<sup>[13]</sup>。为此各种分解技术被应用于处理原始数据集,但当原始数据集非线性程度过高时,单次分解得到的最高频分量非线性程度依旧过高,会严重影响模型的预测效果。文[14]提出了一种结合 EMD 和 FNN 的预测方法,将序列中最无序和不系统的部分丢弃,以提高预测精度。文[15]提出了一种结合 EEMD 和 SVM 的混合预测方

法,将通过 EEMD 获得的最高频分量丢弃,以提升模型的预测精度。虽然这会降低序列的非线性对预测模型的影响,但同时序列中的有价值信号也会被丢弃。

此外,预测模型的超参数往往是根据经验设置,不能保证模型处于最优状态,从而降低了模型的预测精度<sup>[16]</sup>。相对地,智能优化算法能够解决如何获得模型最优参数的问题。如文[17]将 LSTM 与粒子群优化算法(PSO)相结合,利用 PSO 对 LSTM 的参数进行迭代优化,提高了预测精度。

针对上述问题,文中提出一种基于混合分解和 IDBO-TCN 的变压器油中溶解气体含量预测方法。首先利用自适应噪声完全集合经验模态分解(CEEMDAN)对给定气体含量序列进行分解;然后采用经验小波变换(EWT)对分解出的最高频分量进行二次分解;进一步对所有分量建立 TCN 预测模型;同时提出改进蜣螂优化算法(IDBO)优化 TCN 的初始学习率和卷积核大小;最后将各分量的预测值累加,得到最终预测结果。

## 1 自适应噪声完全集合经验模态分解

CEEMDAN 是一种将非线性、非平稳数据分解为多个本征模态函数序列的信号处理方法<sup>[18]</sup>。其在经验模态分解(EMD)中引入自适应白噪声,具有更低的计算成本和更好的分解结果。设  $x(t) = \{x(1), x(2), \dots, x(t)\}$  表示原始时间序列,其分解步骤如下:

1)将白色高斯噪声序列添加到原始序列中

$$x_i(t) = x(t) + \varepsilon_0 w^i(t), i = 1, 2, 3, \dots, L \quad (1)$$

式(1)中:  $w^i(t)$ 表示白色噪声序列;  $L$ 表示试验次数;  $\varepsilon_0$ 表示噪声系数。

2)对噪声添加序列  $x_i(t)$ 进行 EMD 分解,并计算其平均值,得到第一个子序列  $IMF_1$

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

3)计算第一个残差分量

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

4)分解添加噪声的残差,  $r_1(t) + \varepsilon_1 E_1(w^j(t))$ , 以获得第二个子序列  $IMF_2$

$$IMF_2(t) = \frac{1}{L} \sum_{i=1}^L E_1(r_1(t) + \varepsilon_1 E_1(w^i(t))) \quad (4)$$

5)对剩余的序列重复步骤3)和4), 直到得到的残差不能再进行EMD分解, 最终的残差为

$$\overline{r_K}(t) = x(t) - \sum_{k=1}^K \overline{c_k}(t) \quad (5)$$

## 2 经验小波变换

EWT 是一种完全自适应的先进信号处理方法, 它结合了EMD的自适应分解技术和小波变换相关理论的优势, 为信号处理提供了一种新的时频分解思路。其通过设计适合信号处理的带通滤波器, 将非线性和非平稳信号分解成多个模态。其具体步骤如下所示<sup>[19]</sup>:

1)对原信号  $f(t)$  的傅里叶谱归一化  $[0, 2\pi]$ , 并根据香农准则讨论  $[0, \pi]$  范围内的信号特性。

2)将傅里叶谱分割成  $N$  个连续段, 则每个部分  $\Lambda_n = [\omega_{n-1}, \omega_n, n=1, 2, \dots, N (\omega_0=0, \omega_N=\pi)]$ , 那么  $U_{n=1}^N \Lambda_n = [0, \pi]$ 。另外, 以每个  $\omega_n$  为中心, 定义过度阶段  $T_n$  的宽度为  $2\tau_n$ 。

3)分段  $N$  确定后, 求出傅里叶谱中的最大值  $M = \{M_i | i=1, 2, \dots, N\}$ , 同时记录其对应的频率  $\omega = \{\omega_i | i=1, 2, \dots, N\}$ 。

4)计算经验尺度函数  $\hat{\phi}_n(\omega)$  和经验小波函数  $\hat{\psi}_n(\omega)$ :

$$\hat{\phi}_n(\omega) = \begin{cases} 1, & |\omega| \leq \omega_n - \tau_n \\ \cos \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\tau_n} (|\omega| - \omega_n + \tau_n) \right) \right], & \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0, & |\omega| \geq \omega_n + \tau_n \end{cases} \quad (6)$$

$$\hat{\psi}_n(\omega) = \begin{cases} 1, & \omega_n + \tau_n \leq |\omega| \leq \omega_{n+1} - \tau_{n+1} \\ \cos \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\tau_{n+1}} (|\omega| - \omega_{n+1} + \tau_{n+1}) \right) \right], & \omega_{n+1} - \tau_{n+1} \leq |\omega| \leq \omega_{n+1} + \tau_{n+1} \\ \sin \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\tau_n} (|\omega| - \omega_n + \tau_n) \right) \right], & \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0, & |\omega| \geq \omega_{n+1} + \tau_{n+1} \end{cases} \quad (7)$$

式(6)、(7)中, 转换函数

$$\beta(x) = x^4(35 - 84x + 70x^2 - 20x^3)。$$

5)计算近似系数  $W_f^\varepsilon(n, t)$  和细节系数  $W_f^\varepsilon(n, t)$ :

$$W_f^\varepsilon(0, t) = \langle f(t), \hat{\phi}_1(t) \rangle = \int f(\tau) \overline{\hat{\phi}_1(\tau - t)} d\tau = F^{-1} \left[ \hat{f}(\omega), \hat{\phi}_1(\omega) \right] \quad (8)$$

$$W_f^\varepsilon(n, t) = \langle f(t), \hat{\psi}_n(t) \rangle = \int f(\tau) \overline{\hat{\psi}_n(\tau - t)} d\tau = F^{-1} \left[ \hat{f}(\omega), \hat{\psi}_n(\omega) \right] \quad (9)$$

式(8)、(9)中,  $F[\cdot]$  和  $F^{-1}[\cdot]$  表示傅里叶变换和傅里叶反变换。

相应地, 原信号被重构为

$$f(t) = W_f^\varepsilon(0, t) * \hat{\phi}_1(t) + \sum_{n=1}^N W_f^\varepsilon(n, t) * \hat{\psi}_n(t) = F^{-1} \left( \hat{W}_f^\varepsilon(0, \omega) * \hat{\phi}_1(\omega) + \sum_{n=1}^N \hat{W}_f^\varepsilon(n, \omega) * \hat{\psi}_n(\omega) \right) \quad (10)$$

此外, 原信号的分解模态可由下式得出:

$$f_0(t) = W_f^\varepsilon(0, t) * \phi_1(t) \quad (11)$$

$$f_k(t) = W_f^\varepsilon(k, t) * \psi_k(t) \quad (12)$$

## 3 改进蜣螂优化算法

### 3.1 蜣螂优化算法

DBO 是薛等人受蜣螂习性启发于 2022 年提出的新算法<sup>[20]</sup>。该算法同时考虑全局搜索和局部搜索, 具有收敛速度快、精度高的特点, 其更新迭代过程分为滚球、跳舞、繁殖、觅食和偷窃 5 个部分。每个行为的位置更新公式如下:

1)滚球

$$x_i(t+1) = x_i(t) + \alpha \times k \times x_i(t-1) + b \times \Delta x$$

$$\Delta x = |x_i(t) - X^w| \quad (13)$$

2)跳舞

$$x_i(t+1) = x_i(t) + \tan \theta |x_i(t) - x_i(t-1)| \quad (14)$$

3)繁殖

$$Lb^* = \max(X^* \times (1-R), Lb)$$

$$Ub^* = \min(X^* \times (1+R), Ub) \quad (15)$$

$$x_i(t+1) = X^* + b_1 \times (x_i(t) - Lb^*) + b_2 \times (x_i(t) - Ub^*) \quad (16)$$

4)觅食

$$Lb^b = \max(X^b \times (1-R), Lb)$$

$$Ub^b = \min(X^b \times (1+R), Ub) \quad (17)$$

$$x_i(t+1) = x_i(t) + C_1 \times (x_i(t) - Lb^b) + C_2 \times (x_i(t) - Ub^b) \quad (18)$$

5) 偷窃

$$x_i(t+1) = X^b + S \times g \times (|x_i(t) - X^*| + |x_i(t) - X^b|) \quad (19)$$

式(13)-(19)中,  $t$  表示当前迭代次数;  $x_i(t)$  表示蜣螂的位置信息;  $\Delta x$  表示光照强度变化;  $\theta \in [0, \pi]$ ;  $X^w$  表示全局最差位置;  $X$  表示局部最优位置;  $X^b$  表示全局最优位置。

### 3.2 改进策略

虽然 DBO 算法具有良好的性能, 但也存在全局搜索能力不足的问题。为此, 将 Levy 飞行策略集成到 DBO 算法中<sup>[21]</sup>。蜣螂的下次迭代为

$$\begin{aligned} x_i(t+1) &= x_i(t) + d \oplus Levy(\theta) \\ d &= d_0 \cdot |x_i(t) - x_i(t-1)| \\ Levy(\theta) &\sim u = t^{-1-\theta} \end{aligned} \quad (20)$$

式(20)中,  $x_i(t)$  表示第  $i$  个蜣螂的位置;  $x_i(t+1)$  表示更新后第  $i$  个蜣螂的位置;  $d$  表示随机数;  $Levy(\theta)$  表示蜣螂的步长;  $d_0$  表示常数;  $\theta$  表示 Levy 指数, 其值为  $[0, 2]$  中的随机数;  $x_i(t-1)$  表示第  $t-1$  次迭代时蜣螂的位置;  $u$  表示正态分布。

此外, DBO 算法容易陷入局部最优。为此, 对迭代后期得到的最优蜣螂群引入自适应变异策略<sup>[22]</sup>, 表达式为

$$\begin{aligned} X^*_v &= X^* [1 + \gamma Cauchy(0,1) + (1-\gamma) Gauss(0,1)] \\ \gamma &= 1 - t^2 / T_{max}^2 \end{aligned} \quad (21)$$

式(21)中,  $X^*$  表示最优蜣螂位置;  $X^*_v$  表示突变后最优蜣螂位置;  $Cauchy(0,1)$  表示标准高斯变异;  $Gauss(0,1)$  表示标准柯西变异;  $\gamma$  表示突变控制系数;  $T_{max}$  表示最大迭代次数;  $t$  表示当前迭代次数。

最后对更新后的最优个体采用贪婪策略

$$X^*_{new} = \begin{cases} X^*_v, & \text{if } f(X^*_v) < f(X^*) \\ X^*, & \text{otherwise} \end{cases} \quad (22)$$

式(22)中,  $X^*_{new}$  表示更新后的蜣螂位置;  $f(X^*_v)$  表示在  $X^*_v$  时的适应度;  $f(X^*)$  表示在  $X^*$  时的适应度。

### 3.3 算法验证

为验证所提 IDBO 的有效性, 将其与 DBO、鲸鱼优化算法(WOA)、蚁狮优化算法(ALO)、正余弦优化算法(SCA)、灰狼优化算法(GWO)和飞蛾火焰优化算法(MFO)进行比较<sup>[23]</sup>。此外采用一些经典的基准函数, 包括单峰函数( $F_1, F_2$ )、多峰函数( $F_3, F_4$ )和定维多峰函数( $F_5, F_6$ )对其进行测试, 见表 1。其中, 单峰函数用于评估全局搜索性能, 多峰函数用于评估局部搜索性能, 定维多峰函数用于全面评估其全局和局部搜索性能<sup>[24]</sup>。所有算法的运行次数、种群数量和最大迭代次数分别设置为 20、30、200。算法的收敛曲线见图 1。

表 1 基准函数

Table 1 Benchmark functions

序号	函数表达式	维度	范围	最优值
$F_1$	$f_1(x) = \sum_{i=1}^n x_i^2$	30	[-100, 100]	0.000 0
$F_2$	$f_2(x) = \sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i $	30	[-10, 10]	0.000 0
$F_3$	$f_{10}(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	30	[-32, 32]	0.000 0
$F_4$	$f_{12}(x) = \frac{\pi}{n} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \right\} + \sum_{i=1}^n u(x_i, 10, 100, 4)$	30	[-50, 50]	0.000 0
$F_5$	$f_{14}(x) = \left( \frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right)^{-1}$	2	[-65, 65]	1.000 0

$$f_{15}(x) = \sum_{i=1}^{11} \left[ a_i - \frac{500x_1(b_i^2 + b_1x_2)}{b_i^2 + b_1x_3 + x_4} \right]^2$$

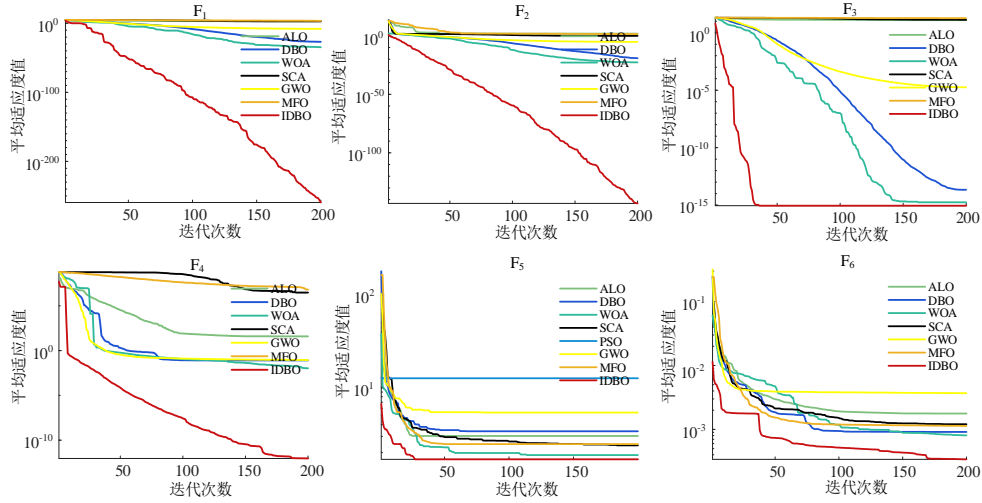


图 1 函数优化收敛曲线

Fig. 1 Function optimization convergence curve

#### 4 时序卷积网络

TCN 作为一种一维全卷积网络，结合了适用于序列的因果卷积结构和适用于历史数据存储的扩张卷积与残差模块，使得 TCN 能够捕获短期和长期依赖性<sup>[25]</sup>。针对变压器油中溶解气体数据时间跨度大的特点，采用带残差模块的扩张卷积可以学习更多的历史数据。扩张卷积的结构见图 2。




图 2 扩张卷积结构

Fig. 2 Dilated convolutional structures

在扩张卷积中，通过在不同层上使用不同大小的卷积核，使得 TCN 能够学习不同尺度的时间特征。对于时间序列  $x$ ，通过 TCN 进行特征提取的输出表达式为

$$F(s) = (x * f_d)(s) = \sum_{i=0}^{k-1} f(i)x_{s-di} \quad (23)$$

式(23)中，\* 表示用于提取特征信息的卷积运算； $k$  表示卷积核大小； $d$  表示展开系数； $f(i)$  表示卷积核的第  $i$  个元素。

在扩张卷积中，通过连接残差模块来解决 TCN 因层数加深而出现的信息丢失问题。残差模块的结构见图 3。

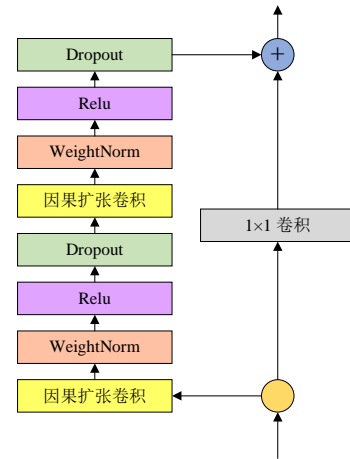


图 3 残差模块结构

Fig. 3 Residual module structure

#### 5 混合分解和 IDBO-TCN 预测方法

##### 5.1 IDBO-TCN 流程

TCN 对超参数的选择具有较高的灵敏性，不同的超参数会对预测精度产生影响。为此，利用所提

IDBO 优化 TCN 的超参数。具体来说, IDBO 用于优化 TCN 的卷积核个数和初始学习率。具体步骤如下:

步骤 1 设置 IDBO 的基本参数, 包括种群数量、最大迭代次数和超参数的搜索范围。同时, 将 TCN 的超参数作为蜣螂的位置, 并将预测值与真实值之间的均方根误差作为目标函数。

步骤 2 根据目标函数计算所有目标群体的适应度值, 并基于 Levy 飞行策略更新所有蜣螂的位置, 将更新后的位置作为 TCN 的新超参数。

步骤 3 将蜣螂的最终位置作为最佳适应度位置  $X^*$ , 并根据式(22)对  $X^*$  进行自适应变异。

步骤 4 重复步骤 2 和步骤 3, 直到达到最大迭代次数。

步骤 5 输出 TCN 的最优参数。

## 5.2 混合分解和 IDBO-TCN 预测流程

为实现油中溶解气体含量高精度预测, 提出一种基于混合分解和 IDBO-TCN 的预测方法, 所提方法基本框架见图 4, 共分为 5 个步骤:

步骤 1 利用 CEEMDAN 将收集到的油中溶解气体含量序列分解为一组 IMF, 并计算残差 Res。

步骤 2 应用 EWT 将 CEEMDAN 分解出的最高频分量进一步分解为  $M$  个模态分量。

步骤 3 对分解出来的所有分量分别建立 TCN 预测模型, 同时应用所提的 IDBO 算法优化 TCN 的超参数。

步骤 4 将各个分量的预测结果相叠加, 得到原始气体含量的最终预测值。

步骤 5 应用评价指标, 对预测结果进行评估。

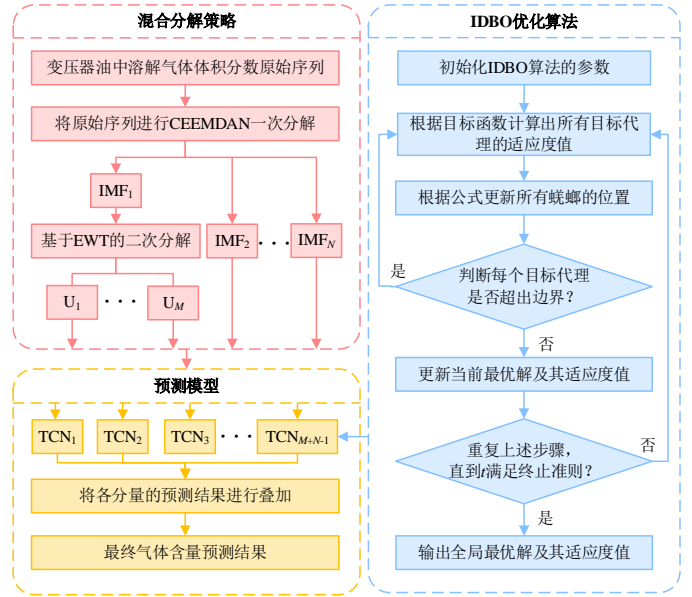


图 4 混合分解和 IDBO-TCN 预测流程图

Fig. 4 Flowchart of hybrid decomposition and IDBO-TCN prediction

## 6 评估指标

为定量评价预测模型精度, 选择平均绝对误差 (MAE)、均方根误差 (RMSE)、平均绝对百分比误差 (MAPE) 对所有实验结果进行量化分析<sup>[26]</sup>。其计算式为:

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i - Y_i^*| \quad (24)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y_i^*)^2} \quad (25)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i - Y_i^*}{Y_i} \right| \quad (26)$$

式(24)-(26)中:  $N$  表示子序列的长度;  $Y_i$  表示实际值;  $Y_i^*$  表示预测值。

## 7 实例分析

文中选用某 500 kV 变压器 2018 年 2 月 16 日至 2020 年 11 月 20 日在线采集的 1008 组 CH<sub>4</sub>、C<sub>2</sub>H<sub>4</sub>、C<sub>2</sub>H<sub>6</sub>、H<sub>2</sub> 和总烃气体含量作为数据集, 采样间隔为一天。前 60% 的数据作为训练集, 后 40% 的数据作为测试集, 并以 CH<sub>4</sub> 气体为例, 对所提模型进行对比分析。本预测任务在 python3.7 环境下完成, 实验硬件

配置为 Intel(R) Core(TM) i5-9300H CPU/12GB RAM/NVIDIA GeForce GTX 1650。

为验证所提模型的有效性，将其与 TCN、CEEMDAN-TCN、CEEMDAN-EWT-TCN 对比，在对比模型中，TCN 的初始学习率、卷积核大小、单次训练样本集、训练次数分别设置为 0.01、2、16、100。并且为防止发生过拟合，在 TCN 中加入 Early Stopping 回调，以便损失函数不在下降时停止训练。CEEMDAN 的白噪声标准差设置为 0.02，噪声添加次数设置为 400。EWT 的滤波器宽度、高斯滤波器的标准差、和多项式次数，分别设置为 10、0.5、和 6。在所提模型中利用所提 IDBO 对 TCN 的初始学习率和卷积核个数寻优，寻优范围分别为[0, 1]和[1, 10]，IDBO 的种群数量和最大迭代次数分别设置为 30 和 50，其余参数与对比模型保持一致。其中，上述实验参数的详细设置见表 2。考虑到 CH<sub>4</sub> 气体含量序列具有较强的波动性，预测难度较大，提出混合分解对其进行处理。首先使用 CEEMDAN 对原始序列进行分解，分解结果见图 5。从图 5 中可以看出，分解出的最高频分量依旧具有较强的非线性，会影响预测模型的准确性和稳定性。为进一步提升预测精度，采用 EWT 对 CEEMDAN 分解出的最高频分量进行二次分解，分解结果见图 6。从图 6 可以看出，经过第二次分解后，降低了最高频分量的波动性和非线性。采用所提模型对各分量进行预测，预测结果见图 7(c)，各对比模型的预测结果见图 7(a)、(b)，评价指标见表 3。

表 2 实验参数设置

Table 2 Experimental parameter setting

模型	组件	参数	区间或固定值
对比模型	CEEMDAN	白噪声的标准差	0.02
		噪声添加次数	400
对比模型	EWT	滤波器宽度	10
		高斯滤波器的标准差	0.5
	TCN	多项式次数	6
		初始学习率	0.01
	卷积核大小	2	

		单次训练样本集	16
		训练次数	100
所提模型	IDBO	种群数量	30
		最大迭代次数	50
对比模型	TCN	初始学习率	[0, 1]
		卷积核个数	[1, 10]




图 5 子序列对比结果

Fig. 5 CEEMDAN decomposes the results






图 6 EWT 二次分解结果


Fig. 6 Results of the EWT quadratic decomposition



(a) 一次分解有效性验证



(b) 二次分解有效性验证



(c) 优化算法有效性验证

图 7 预测结果对比图

Fig. 7 Comparison of the prediction results

表 3 CH<sub>4</sub> 预测结果比较

Table 3 Comparison of CH<sub>4</sub> prediction results

预测模型	误差类型		
	MAE	RMSE	MAPE
TCN	1.101 9	1.341 0	5.542 3
CEEMDAN-TCN	0.537 8	0.690 5	2.783 6
CEEMDAN-EWT-TCN	0.274 4	0.347 3	1.413 2
CEEMDAN-EWT-IDBO-TCN	0.240 3	0.298 9	1.236 4

从图 7 和表 3 中可以看出，单一 TCN 预测效果不佳，而加入 CEEMDAN 后，相应的 MAE、RMSE、

MAPE 分别降低了 51.19%、48.50%、49.77%，表明 CEEMDAN 能够有效降低序列的非平稳性。与 CEEMDAN-TCN 的预测结果相比，CEEMDAN-EWT-TCN 能够更好的拟合预测曲线，其 MAE、RMSE、MAPE 分别降低了 48.97%、49.70%、49.23%，表明所提混合分解可以有效降低数据非线性对预测模型的影响。相比于 CEEMDAN-EWT-TCN，所提模型取得了更好的预测精度，其 MAE、RMSE、MAPE 分别降低了 15.94%、16.35 %、18.26%，表明 IDBO 可以有效优化 TCN 的超参数，使模型的预测性能处于最佳状态。

为进一步证明所提模型的有效性，应用 CEEMDAN-EWT-IDBO-TCN 对 C<sub>2</sub>H<sub>4</sub>、C<sub>2</sub>H<sub>6</sub>、H<sub>2</sub> 和总烃气体进行预测分析，预测结果见表 4。从表 4 可以看出，文中所提模型在所有气体含量中，均有最佳的预测效果。

表 4 剩余气体预测结果比较

Table 4 Comparison of residual gas prediction results

气体类型	误差类型	预测模型			
		TCN	CEEMDAN-TCN	CEEMDAN-EWT-TCN	CEEMDAN-EWT-IDBO-TCN
C <sub>2</sub> H <sub>4</sub>	MAE	0.545 3	0.377 7	0.176 8	0.147 8
	RMSE	0.656 6	0.459 5	0.222 1	0.186 7
	MAPE	5.435 6	3.691 3	1.791 1	1.464 0
C <sub>2</sub> H <sub>6</sub>	MAE	0.200 7	0.137 4	0.061 0	0.052 8
	RMSE	0.237 9	0.166 1	0.076 1	0.065 0
	MAPE	5.052 5	3.421 2	1.528 0	1.322 5
H <sub>2</sub>	MAE	5.698 5	1.845 6	1.033 1	0.879 3
	RMSE	6.867 6	2.265 4	1.287 0	1.133 3
	MAPE	9.078 5	3.043 1	1.717 0	1.461 2
总烃	MAE	1.131 8	0.570 4	0.293 5	0.248 1
	RMSE	1.372 3	0.731 7	0.364 6	0.310 2
	MAPE	4.555 1	2.307 4	1.183 8	1.001 0

## 8 结论

为更加准确的预测变压器油中溶解气体含量，文中提出一种基于混合分解和 IDBO-TCN 的预测方法，并通过 5 组不同气体含量数据集验证所提预测方法的优越性和可靠性。得出以下结论：

1)采用 CEEMDAN 对原始气体数据进行分解，并利用 EWT 对 CEEMDAN 生成的最高频分量二次分解，能够有效降低原始序列的非线性，从而提高预测精度。

2)文中所提的 IDBO 相较于传统优化算法, 具有更好的寻优和收敛能力, 有助于提升预测精度。

3)文中所提的混合分解和 IDBO-TCN 方法能够有效针对变压器油中溶解气体含量数据非平稳、非线性特点, 实现高精度的含量预测, 能够为变压器安全可靠运行提供一定技术支持。

## 参考文献:

- [1] 梁得亮, 柳轶彬, 寇 鹏, 等. 智能配电变压器发展趋势分析[J]. 电力系统自动化, 2020, 44(7): 1-14.  
LIANG Deliang, LIU Yibin, KOU Peng, et al. Analysis of development trend for intelligent distribution transformer[J]. Automation of Electric Power Systems, 2020, 44(7): 1-14.
- [2] 陆怡冰, 李 峰, 周 游, 等. 雷电冲击电压下气制变压器油中流注放电发展机理研究[J]. 高压电器, 2023, 59(12): 130-137.  
LU Yibing, LI Feng, ZHOU You, et al. Study on the streamer-discharge development mechanism in gas-made transformer oil under lightning impulse voltage[J]. High Voltage Apparatus, 2023, 59(12): 130-137.
- [3] 李恩文, 王力农, 宋 斌, 等. 基于改进模糊聚类算法的变压器油色谱分析[J]. 电工技术学报, 2018, 33(19): 4594-4602.  
LI Enwen, WANG Linong, SONG Bin, et al. Analysis of transformer oil chromatography based on improved fuzzy clustering algorithm[J]. Transactions of China Electrotechnical Society, 2018, 33(19): 4594-4602.
- [4] 张丞鸣, 谢菊芳, 胡 东, 等. 基于 QPSO-SVM 与 DGA 五边形解释工具的变压器故障诊断方法[J]. 高压电器, 2021, 57(12): 117-124.  
ZHANG Chengming, XIE Jufang, HU Dong, et al. Fault diagnosis method of transformer based on QPSO-SVM and DGA pentagonal interpretation Tool[J]. High Voltage Apparatus, 2021, 57(12): 117-124.
- [5] 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 Hongzhong, XIAO Yusong, SUN Yongteng, 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.
- [6] DAI Jiejie, SONG Hui, SHENG Gehao, et al. Dissolved gas analysis of insulating oil for power transformer fault diagnosis with deep belief network[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2017, 24(5): 2828-2835.
- [7] 周 秀, 朱洪波, 马云龙, 等. 基于深度学习的变压器局部放电模式识别研究[J]. 高压电器, 2019, 55(12): 98-105.  
ZHOU Xiu, ZHU Hongbo, MA Yunlong, et al. Partial discharge pattern recognition of transformer based on deep learning[J]. High Voltage Apparatus, 2019, 55(12): 98-105.
- [8] 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.
- [9] 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 Zhancheng, WANG Shuang, TANG Bo. Prediction of dissolved gas content in transformer oil based on SSA-BiGRU-Attention model[J]. High Voltage Engineering, 2022, 48(8): 2972-2981.
- [10] 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 Zhiyuan, DU Jiang. 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.
- [11] ROSATO A, PANELLA M, ARANEO R, et al. A neural network based prediction system of distributed generation for

- 
- the management of microgrids[J]. IEEE Transactions on Industry Applications, 2019, 55(6): 7092-7102.
- [12]WANG Y, CHEN J, CHEN X, et al. Short-term load forecasting for industrial customers based on TCN-LightGBM[J]. IEEE Transactions on Power Systems, 2020, 36(3): 1984-1997.
- [13]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): 3998-4007.
- 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.
- [14]GUO Zhenhai, ZHAO Weigang, LU Haiyan, et al. Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model[J]. Renewable Energy, 2012, 37(1): 241-249.
- [15]HU Jianming, WANG Jianzhou, ZENG Guowei. A hybrid forecasting approach applied to wind speed time series[J]. Renewable Energy, 2013(60): 185-194.
- [16]FU Wenlong, FU Yuchen, LI Bailing, et al. A compound framework incorporating improved outlier detection and correction, VMD, weight-based stacked generalization with enhanced DESMA for multi-step short-term wind speed forecasting[J]. Applied Energy, 2023(348): 121587.
- [17]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浓度预测方法[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.
- [18]陈 铁, 陈一夫, 李咸善, 等. 基于 CEEMDAN-SG-BiLSTM 的变压器油中溶解气体体积分数预测[J]. 高压电器, 2023, 59(12): 168-175.
- CHEN Tie, CHEN Yifu, LI Xianshan, et al. Prediction for dissolved gas concentration in power transformer oil based on CEEMDAN-SG-BiLSTM[J]. High Voltage Apparatus, 2023, 59(12): 168-175.
- [19]LI Yanfei, WU Haiping, LIU Hui. Multi-step wind speed forecasting using EWT decomposition, LSTM principal computing, RELM subordinate computing and IEWT Reconstruction[J]. Energy Conversion and Management, 2018(167): 203-219.
- [20]XUE Jiankai, SHEN Bo. Dung Beetle optimizer: A new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [21]LIU Yahui, CAO Buyang. A novel ant colony optimization algorithm with levy flight[J]. IEEE Access, 2020(8): 67205-67213.
- [22]DONG Wenyong, KANG Lanlan, ZHANG Wensheng. Opposition-based particle swarm optimization with adaptive mutation strategy[J]. Soft Computing, 2017, 21(17): 5081-5090.
- [23]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.
- [24]贾东立, 郑国莘. 基于混沌和高斯局部优化的混合差分进化算法[J]. 控制与决策, 2010, 25(6): 899-902.
- JIA Dongli, ZHENG Guoshen. Hybrid differential evolution combined with chaos and Gaussian local optimization[J]. Control and Decision, 2010, 25(6): 899-902.
- [25]陈海鹏, 李 赫, 阚天洋, 等. 考虑风电时序特性的深度小波-时序卷积网络超短期风功率预测[J]. 电网技术, 2023, 47(4): 1653-1662.
- CHEN Haipeng, LI He, KAN Tianyang, et al. DWT-DTCNA ultra-short-term wind power prediction considering wind power timing characteristics[J]. Power System Technology, 2023, 47(4): 1653-1662.

---

[26]付文龙, 章轩瑞, 张海荣, 等. 多尺度特征提取与非线性融合的综合能源系统多元负荷短期预测[J]. 电力系统及其自动化学报, 2023, 35(12): 89-99.

FU Wenlong, ZHANG Xuanrui, ZHANG Hairong, et al. Short-term multivariate load forecasting of integrated energy system based on multiscale feature extraction and nonlinear fusion[J]. Proceedings of the CSU-EPSA, 2023, 35(12): 89-99.

付文龙(1988—), 男, 博士, 副教授, 主要从事电气设备状态监测与诊断研究(E-mail: ctgu\_fuwenlong@126.com)。