

DOI:10.13296/j.1001-1609.hva.2026.03.007

基于优化VMD-TCN-LSTM的变压器油中溶解气体预测

代浩^{1,2}, 胡东¹, 杨童亮¹, 付强¹, 杨勇¹, 唐超^{1,2}, 谭为民^{1,2}
(1. 西南大学工程技术学院, 重庆 400715; 2. 西南大学智能电网及装备新技术国际研发中心, 重庆 400715)

摘要: 针对非平稳变压器油中溶解气体序列既有长期趋势又有短期细微波动的复杂特性, 文中将黄金正弦算法(GSA)优化的麻雀搜索算法(SSA)与变分模态分解(VMD)组合构成GSSA-VMD模型; 对原始变压器油中溶解气体序列使用GSSA-VMD分解, 最终得到一组平稳的模态分量; 其次, 为了精准预测变压器气体序列长期趋势和短期波动, 文中将时序卷积网络(TCN)与长短期记忆网络(LSTM)组合起来, 并与GSSA-VMD组合构成变压器油中溶解气体含量组合预测模型; 最后, 文中选用变压器油中溶解气体CO₂进行实验验证, 与VMD-TCN-LSTM、EMD-TCN-LSTM和GSSA-VMD-LSTM模型进行对比实验, 实验结果得出文中提出的变压器油中溶解气体混合预测模型效果最佳, 平均绝对百分比误差MAPE值为0.71%, 均方根误差RMSE值为9.04 μL/L。

关键词: 油中溶解气体; 组合预测模型; 变压器; 变分模态分解

Prediction of Dissolved Gas in Transformer Oil Based on Optimized VMD-TCN-LSTM

DAI Hao^{1,2}, HU Dong¹, YANG Tongliang¹, FU Qiang¹, YANG Yong¹,
TANG Chao^{1,2}, TAN Weimin^{1,2}

(1. School of Engineering and Technology, Southwest University, Chongqing 400715, China; 2. International R&D Center for Smart Grid and New Equipment Technology, Southwest University, Chongqing 400715, China)

Abstract: As for the such complex characteristics as both long-term trends and short-term subtle fluctuations of non-stationary dissolved gas sequences in transformer oil, the GSSA-VMD model is formed by integrating the golden sine algorithm(GSA)-optimized sparrow search algorithm(SSA) with variational mode decomposition(VMD). The original dissolved gas sequences in transformer oil are decomposed by GSSA-VMD and a set of stationary modal components is finally obtained. Then, for accurately predicting the long-term trends and short-term fluctuations of gas sequences of transformer, in this paper the temporal convolutional network(TCN) and long short-term memory(LSTM) are combined, which is further combined with GSSA-VMD to form a hybrid prediction model for dissolved gas content in transformer oil. Finally, in this paper the dissolved gas CO₂ in transformer oil is selected for experimental verification. It is concluded by the comparative experiments with VMD-TCN-LSTM, EMD-TCN-LSTM, and GSSA-VMD-LSTM models that the hybrid prediction model proposed in the paper achieves the best performance, with a mean absolute percentage error(MAPE) of 0.71% and a root mean square error(RMSE) of 9.04 μL/L.

Key words: dissolved gas in oil; combination prediction model; transformer; variational mode decomposition

0 引言

变压器作为电网互联和功率交换的核心设备, 其正常运行直接影响电力系统的可靠性与稳定

性。变压器内部运用油纸绝缘系统, 其绝缘材料在长期的运作过程中会受到热应力等多种因素的长期作用, 逐渐释放出氢气(H₂)、甲烷(CH₄)、一氧化碳(CO)等微量的溶解性气体^[1-2]。目前变压器早期故障

收稿日期: 2025-08-06; 修回日期: 2025-10-12

基金项目: 国家自然科学基金(51977179)。

Project Supported by National Natural Science Foundation of China(51977179).

检测常用油中溶解气体分析技术(dissolved gas analysis, DGA),通过分析油中气体含量的历史数据,并据此预测这些气体的变化趋势,能够为变压器内部状态监测与故障诊断提供参考,进而实现早期故障预警^[3]。

针对变压器油中溶解气体含量预测,国内外研究者们提出了许多方法。例如,基于数理统计学方法、机器学习方法、深度学习算法等。其中基于数理统计学方法以回归模型、灰色模型最为经典;朱庆龙等人^[4]提出使用回归模型来预测溶解气体,但是这种方法需要大量的时间序列样本。灰色模型虽然可以实现小样本数据的预测,但使用单调增长或下降的函数来说明溶解气体含量的预测模式,在预测上存在局限性^[5]。随着机器学习的不断发展,有研究者使用支持向量机进行小样本数据的预测,但这些机器学习的模型不能从依赖关系中提取时间信息,即不能有效地提取气体含量数据的时间特征^[6]。深度学习算法中,递归神经网络(recurrent neural network, RNN)依靠其内部的循环连接结构来捕捉数据中的时间依赖性,擅长分析和预测时间序列数据中的模式和趋势,然而传统的RNN在处理长序列数据时容易出现梯度消失以及梯度爆炸^[7]。长短期记忆网络(long short-term memory, LSTM)是一种优化RNN网络,它引入“门”机制来调控信息的流动,缓解了梯度消失和梯度爆炸问题^[8]。但LSTM在中长期的预测中,随着递推次数的增加,误差会不断累积,降低预测精度,且单一LSTM无法满足数据变化时细节特征的挖掘^[9]。而最近的研究表明,时间卷积网络(temporal convolutional network, TCN)能够有效地捕获序列数据的短期局部特征信息^[10]。

另外,变压器油中溶解气体的产生受多种因素影响,例如多种气体间相互影响以及顶层油温、外部环境湿度、湿度等,导致油中溶解气体时序序列呈现出一种非平稳的特点。基于这一特点,单功能预测模型在气体含量的预测精度上会受到限制,因此需要将气体含量数据进行平稳化处理,得到一组规律性较强的平稳序列^[11]。信号分解方法是提取原始数据特征的有效方法,一些研究人员已经使用信号分解和神经网络的混合模型来预测,例如小波分解^[12],但小波分解较难确定小波基和分解层数,而经验模态分解^[13](empirical mode decomposition, EMD)容易出现模态混叠。变分模态分解(variational mode decomposition, VMD)通过自适应性和准正交特性,能够将混合信号分解为多个清晰定义带宽受限的模态函数^[14]。赵洪山^[15]使用VMD有效提取出原始温

度序列中的周期子序列和趋势特征子序列。文[16]使用VMD改善月降水序列的波动性和非平稳性。然而,传统VMD有着2个缺陷:①参数选取不当时,例如模态分解数量 K 值定义不当,不仅增加计算量而且会影响信号分解的精度,惩罚因子 α 选取不当的情况下无法将噪声的影响降到最低;②VMD在处理具有趋势项的序列时,会将趋势项误分解为周期项,影响预测精度。所以如何选择最佳参数和消除趋势项对VMD分解至关重要^[14,17]。

基于上述分析,文中首先使用差分法^[18]对油中溶解气体进行去趋势预处理,然后使用黄金正弦算法(golden sine algorithm, GSA)改进麻雀搜索算法(sparrow search algorithm, SSA),并与VMD结合提出GSSA-VMD分解模型,将去趋势后的气体序列分解为较平稳的模态分量;鉴于变压器油中溶解气体的数据特性,其既展现出气体体积分数变化的短期细微波动,又蕴含长期趋势,而TCN模型擅长捕获序列数据中的短期局部特征信息,LSTM模型擅长捕获序列数据的长期相关性^[9],因此文中使用TCN-LSTM组合预测模型来提取变压器油中溶解气体序列中的短期局部特征信息与长期相关性,从而提高预测的准确性和可靠性。鉴于此,文中提出优化VMD-TCN-LSTM的油中溶解气体组合预测模型,然后与VMD-TCN-LSTM、VMD-LSTM、EMD-TCN-LSTM进行对比实验验证。使用油中溶解气体 CO_2 序列为实验对象,实验结果证明文中提出的变压器油中溶解气体组合预测模型的MAPE值为0.71%、RMSE值为 $9.04 \mu\text{L/L}$,验证了模型的有效性。

1 模型原理

1.1 VMD方法

变分模态分解是一种非递归信号处理算法,可以将信号分解为一组具有特定带宽的分量信号,其核心是变分问题的构造和求解,本质上是一个约束优化问题^[20]。

1.1.1 变分问题建立

变分问题是最小化IMF的估计带宽之和,约束条件是IMF之和为原始信号,其计算为

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\| \right\} \\ \text{s.t. } \sum_k u_k = f(t) \end{cases} \quad (1)$$

式(1)中: k 为模态的总数; j 为虚数单位; ∂_t 为对 t 求偏导数; $\delta(t)$ 为冲激函数; $*$ 为卷积运算;s.t.为“subject to”的缩写; $f(t)$ 是原始信号;

$\{u\} = \{u_1, u_2, \dots, u_k\}$ 和 $\{\omega\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 分别为所有分量及其相对应的中心频率。

1.1.2 变分问题求解

为了简化式(1), VMD引入二次惩罚因子 α 和拉格朗日算子 $\lambda(t)$, 将约束问题转化为无约束问题; α 保证了信号的重构精度, $\lambda(t)$ 保证了约束的严格性, 构成扩展拉格朗日表达式

$$L(\{u_k\}, \{\omega_k\}, \{\lambda\}) = \alpha \sum_k \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\|_2^2 e^{-j\omega_k t} + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (2)$$

式(2)中, $\langle x, y \rangle$ 为两变量的内积。

最后, 通过交替更新的方法求解扩展拉格朗日表达式的鞍点。更新 u_k^{n+1} 、 ω_k^{n+1} 、 λ^{n+1} :

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

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




图1 K固定中心频率变化

Fig. 1 K fixed center frequency change

2) 当 $K=8$ 时, 不同 α 值(200、2 000、20 000)对 VMD分解中各模态分量中心频率的影响见图2。分析结果表明, 惩罚因子 α 值对分解结果也有一定影响, 当 α 值为200时, 模态分量中心频率在迭代初期出现了明显的重叠现象; 随着 α 值的增大, 重叠现象减弱, 见图2(b); 然而, 当 α 值过高 ($\alpha=20\,000$) 时, 各分量之间的特征差异显著减小, 见图2(c), 这可能影响分解后的信号表征能力。此外过大的 α 值会导致分量重构精度下降, 影响分解结果的可靠性。

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left[\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right] \quad (5)$$

式(3)-(5)中: $\hat{f}(\omega)$ 、 $\hat{u}_k(\omega)$ 、 $\hat{\lambda}(\omega)$ 、 $\hat{u}_k^{n+1}(\omega)$ 分别为 $f(\omega)$ 、 $u_k(\omega)$ 、 $\lambda(\omega)$ 、 $u_k^{n+1}(\omega)$ 的傅里叶变换; n 和 τ 为迭代次数和对偶更新的更新系数。当收敛条件满足式(6)时, 停止迭代。

$$\frac{\sum_k \|u_k^{n+1} - u_k^n\|_2^2}{\|u_k^n\|_2^2} < \varepsilon \quad (6)$$

1.1.3 VMD参数设置影响分析

研究通过分析变压器油中溶解气体 CO_2 体积分数序列经 VMD分解后各模态分量的中心频率分布特性, 探究模态数 K 与惩罚因子 α 对分解效果的影响规律。

1) 当 $\alpha=200$ 时, 不同 K 值(4、8、12)对模态分量中心频率的影响见图1。分析结果表明 K 值为4时, 分解分量频率迭代次数较少, 见图1(a), 表明此时的 VMD分解处于欠分解状态; 而当 K 值为12时, 模态分量在迭代初期出现中心频率重叠现象, 见图1(c), 表明现在的 K 值导致了过分解现象的出现; 相比之下, 当 K 值为8时, 频率重叠现象减少, 见图1(b), 说明此时的分解效果相对更优。

1.2 改进麻雀搜索算法

在应用 VMD 进行时间序列分解时, 需预先确定模态数 K 和惩罚因子 α 这两个关键参数。不同取值的 K 值将导致分解结果出现显著差异, 而惩罚因子 α 的取值同样对分解结果产生重要影响: 较小的 α 值将导致各分量具有较大的带宽, 而较大的 α 值则会使分量的带宽减小^[21]。 K 和 α 这两个影响 VMD 分解的取值常常难以确定, 并且在时间序列处理方面, 目前没有相关的文献能够提供参数选取经验。




图2 α 固定中心频率变化

Fig. 2 α fixed center frequency change

因此,文中提出将GSSA群体智能优化算法应用于VMD关键参数组 $[K, \alpha]$ 的自动寻优,以获取全局最优参数组。该方法能够有效克服传统参数选择方法的局限性,为时间序列信号的VMD分解提供了一种科学的参数优化方案。

2020年,Jiangkai Xue等提出麻雀搜索算法^[22]。SSA算法的位置更新机制倾向于迭代初期即趋近全局最优,此特性虽加速了搜索进程,却也增大了算法陷入局部最优、发生早熟收敛的风险^[23]。为了克服这一不足,将黄金正弦算法引入到SSA算法中发现者位置更新策略中,以改进其性能。

GSA借鉴正弦函数在单位圆内扫描的方式,模拟待优化问题在解空间中搜索的过程,利用黄金分割率缩小搜索空间以逼近算法最优解^[24]。GSA在位置更新的策略中,引入黄金分割系数 x_1 、 x_2 ,以优化“搜索”和“开发”间的平衡。这些系数缩小了搜索空间,引导个体逐步趋近最优值, x_1 、 x_2 为

$$x_1 = a \times (1 - \tau) + b \times \tau \quad (7)$$

$$x_2 = a \times \tau + b \times (1 - \tau) \quad (8)$$

式(7)、(8)中: a 、 b 为黄金分割比率搜索初始值,一般 $a = -\pi$, $b = \pi$; τ 为黄金比率, $\tau = (\sqrt{5} - 1)/2$ 。

GSA的核心机制在于通过迭代方式优化解集,先在搜索空间内随机初始化 s 个候选解,每个解均代表着搜索域内潜在最优解的可能位置。随后,利用迭代方法,持续调整这些候选解的位置,以逐步逼近全局最优解,第 i 个个体的位置更新为

$$X_i^d(t+1) = X_i^d(t) \left| \sin(r_1) \right| + r_2 \sin(r_1) \left| x_1 P^d(t) - x_2 X_i^d(t) \right| \quad (9)$$

式(9)中: $X_i^d(t)$ 为 d 维空间中第 t 次迭代第 i 个个体的空间位置; $P^d(t)$ ($t = 1, 2, \dots, t_{\max}$)为第 t 次迭代全局最优位置; r_1 和 r_2 为随机数, r_1 为下一阶段迭

代过程中个体的移动距离, $r_1 \in [0, 2\pi]$, r_2 为下一阶段迭代过程中第 i 个个体的位置更新方向, $r_2 \in [0, \pi]$ 。改进后的麻雀发现者位置更新为

$$X_{ij}^{t+1} = \begin{cases} X_{ij}^t \times |\sin(r_1)| + r_2 \times \sin(r_1) \times |x_1 \times X_{\text{best}}^t - x_2 \times X_{ij}^t| & r_2 < ST \\ X_{ij}^t + Q \cdot L & r_2 \geq ST \end{cases} \quad (10)$$

式(10)中: j 为维度, $j = 1, 2, \dots, D$; X_{ij}^t 为第 i 只麻雀在第 t 次迭代第 j 维时的位置; X_{best}^t 为当前全局最优位置; $ST \in [0.5, 1]$ 为安全值; Q 为符合正态分布的随机数; L 为 $1 \times D$ 的矩阵。

1.3 TCN原理

TCN的核心是一个多层的一维卷积神经网络。每个卷积运算可以被看作是一个滤波器,通过使用多个滤波器来提取输入数据的特征^[25]。但卷积操作运算会降低数据的维数,为了在卷积之后保持输入数据的大小与输出数据的大小相同,在每一层中的数据左侧填充零元素^[26]。

1.3.1 膨胀因果卷积

在TCN中,输入和输出的映射如下: $Y = F_T(X)$,其中 $F_T(\cdot)$ 是TCN模型, t 时刻的输入序列为 $X = \{x_1, x_2, x_3, \dots, x_{t-1}, x_t\}$,相应的输出序列为 $Y = \{y_1, y_2, y_3, \dots, y_{t-1}, y_t\}$ 。一个4层膨胀因果卷积网络见图3,其核大小 $K=2$,输入时间窗口 $T=8$,扩张因子 $d=1, 2, 4$ 。

1.3.2 残差链接

在TCN中,膨胀因果卷积的引入会加深网络层数,但也会引起训练时间成本提高、反向传播过程中难收敛、常数映射难拟合、模型难优化等困难,使得其性能反而会逐渐下降。膨胀因果卷积见图3。为了解决上述问题,TCN引入了残差模块使网络收

敛更快,更有效。残差模块结构见图4,其数学定义为

$$\hat{Z}^{(i)} = \varphi \left[\hat{Z}^{(i-1)} + F \left(\hat{Z}^{(i-1)}, s^{(i-1)} \right) \right] \quad (11)$$

式(11)中: $\hat{Z}^{(i-1)}$ 为第*i*-1级的输入序列; $\hat{Z}^{(i)}$ 是残差模块的输出; $F \left(\hat{Z}^{(i-1)}, s^{(i-1)} \right)$ 为权重为 $s^{(i-1)}$ 层所学习的残差映射; $\varphi(\cdot)$ 为激活函数。




图3 膨胀因果卷积

Fig. 3 Dilational convolution

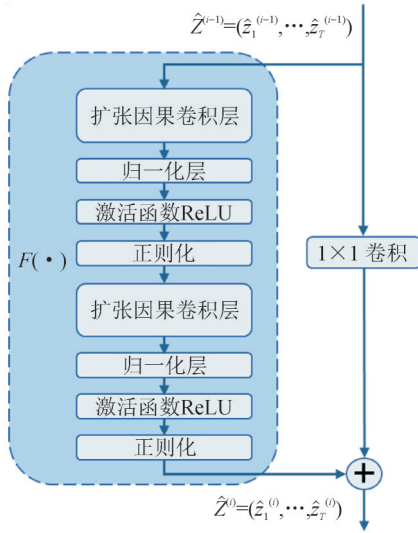


图4 残差模块

Fig. 4 Residual module

1.4 LSTM

长短期记忆网络(long short-term memory, LSTM)是一种特殊的循环神经网络^[27],旨在解决传统RNN无法有效处理长序列时的梯度消失和梯度爆炸问题。LSTM模型结构见图5。




图5 长短期记忆网络

Fig. 5 Long short-term memory

2 文中所提预测模型

2.1 基于GSSA优化的VMD方法

为了确保VMD分解后的各个分量尽可能的平稳且有序,文中选择排列熵与能量追踪法作为优化过程中的适应度函数^[14],排列熵具有计算简单、快速,抗噪能力强等优点,广泛应用于检测时间序列随机性和动力学突变行为;而能量追踪法能反映各个子序列与原时间序列的关系。文中使用GSSA对VMD中的模态数量*K*和惩罚因子 α 的寻优步骤见图6。

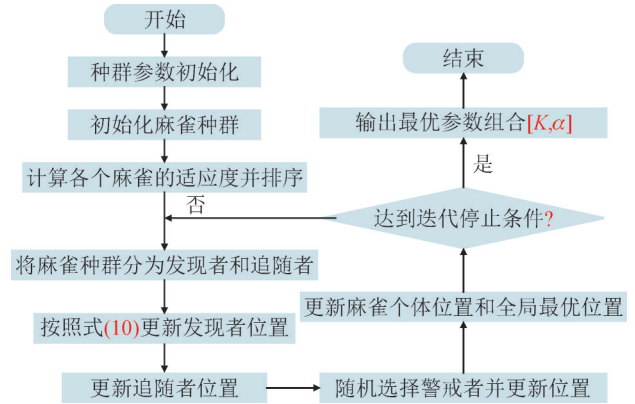


图6 GSSA-VMD算法流程图

Fig. 6 Flowchart of the GSSA-VMD algorithm

2.2 文中所提组合预测模型

文中所提基于GSSA优化VMD-TCN-LSTM的变压器油中溶解气体组合预测模型,分为数据预处理、VMD分解、VMD分量预测、数据重构4个步骤,其流程见图7。

文中油中溶解气体预测模型步骤为:①使用差分法去除序列中的趋势成分;②运用VMD对去趋势化后的序列进行分解,此过程中,通过GSSA对VMD进行关键参数*K*和 α 寻优,构建GSSA-VMD分解方法,实现对去趋势序列的自适应分解,从而得到不同频率段的子序列 $[IMF_1, IMF_2, \dots, IMF_L]$;③对分解得到的各模态分量进行归一化处理,针对每个分量,单独构建TCN-LSTM预测模型并输出分量预测结果;④反归一化各个模态分量预测结果并进行重构,再加上原始趋势项,得到最终的预测结果。

2.3 评价指标

均方根误差RMSE(root mean squared error)和平均绝对百分比误差MAPE(mean absolute percentage error)都是回归模型的典型指标^[28],用来定量分析预测值与真实值之间的差异。所以文中选用RMSE和MAPE为该研究评价指标,计算公式为:

$$e_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

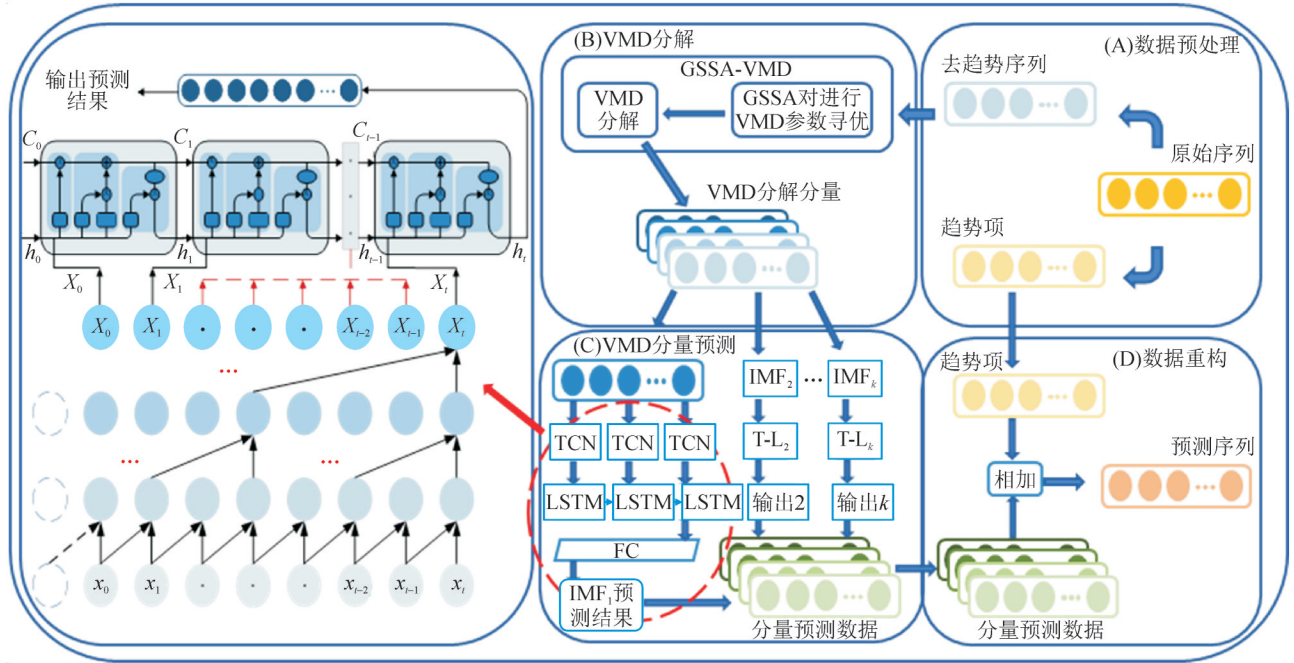


图7 文中所提组合预测模型流程

Fig. 7 The process of the combination prediction model mentioned in this article

$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \div y_i \times 100\% \quad (13)$$

式(12)、(13)中： n 为采样点数； y_i 为真实值； \hat{y}_i 为预测值。

3 实例分析

文中选用深圳某变电站在运 500 kV 变压器 2020年4月12日至2022年11月17日采集的950组油中溶解气体时序数据,采样周期为1天。为了更好地对比模型,将950个数据点中训练集、验证集和测试集个数设置为750、100、100。本研究采用Keras框架构建TCN-LSTM模型,其中TCN层设有10个滤波器,卷积核尺寸为2,膨胀系数为[1,2,4],将LSTM设置为10-1的单隐藏层结构,即隐藏层神经元设定为10,并包含一个输出;为了得到一个动态的学习率,使预测效果更好,训练过程使用Adam优化^[29],迭代周期设定为50,学习率为0.01。为了验证所提模型的精度,文中首先选取CO₂气体体积分数数据为例,对所提模型进行对比分析。

文中使用收敛曲线来比较GSSA算法和原始SSA算法的性能,收敛曲线直观反映算法收敛精度、速度及逃离局部最优的能力。将GSSA优化算法初始种群数量设置为30,迭代次数为10,得到迭代次数和适应度值绘制的函数收敛曲线见图8。

根据收敛曲线可知,文中所提算法在跳出局部最优的能力上优于原始SSA算法和哈里斯鹰优化算法(harris hawks optimization, HHO)算法,GSSA只需




图8 收敛曲线

Fig. 8 Convergence curve

要3次迭代就达到了最优适应度。优化算法寻得的最优参数见表1。

表1 优化算法寻优参数

Table 1 Optimization algorithm to optimize parameters

优化算法	模态数 K	惩罚因子 α	最优适应度 P_{ew}
GSSA	11	9 287	0.480 5
SSA	11	9 389	0.480 5
HHO	11	9 335	0.480 5

3.1 组合预测模型对比分析

当信号靠近基线中心时,信号时程波动特征的准确性和频谱分析的分辨率会上升^[30],同时,剔除信号中外部趋势的影响后,能够还原时间序列本身所

具有的统计特性^[31-37],并且VMD在处理具有趋势项的序列时,会将趋势项误分解为周期项,影响预测精度。所以,为了更好地分析变压器油中溶解气体时序序列中的周期性、季节性,减少趋势项的影响,本研究首先使用差分法剔除原始数据中的趋势,再

使用VMD对去趋势后的序列进行分解,以消除长期趋势对后续分析的影响。原始CO₂体积分数及其去趋势后的CO₂体积分数曲线见图9。

GSSA-VMD和EMD的CO₂分解效果见图10、11。

图10(a)、11(a)是分量图,图10(b)、11(b)是频谱图。




图9 CO₂体积分数序列曲线

Fig. 9 Sequence curve of CO₂ content

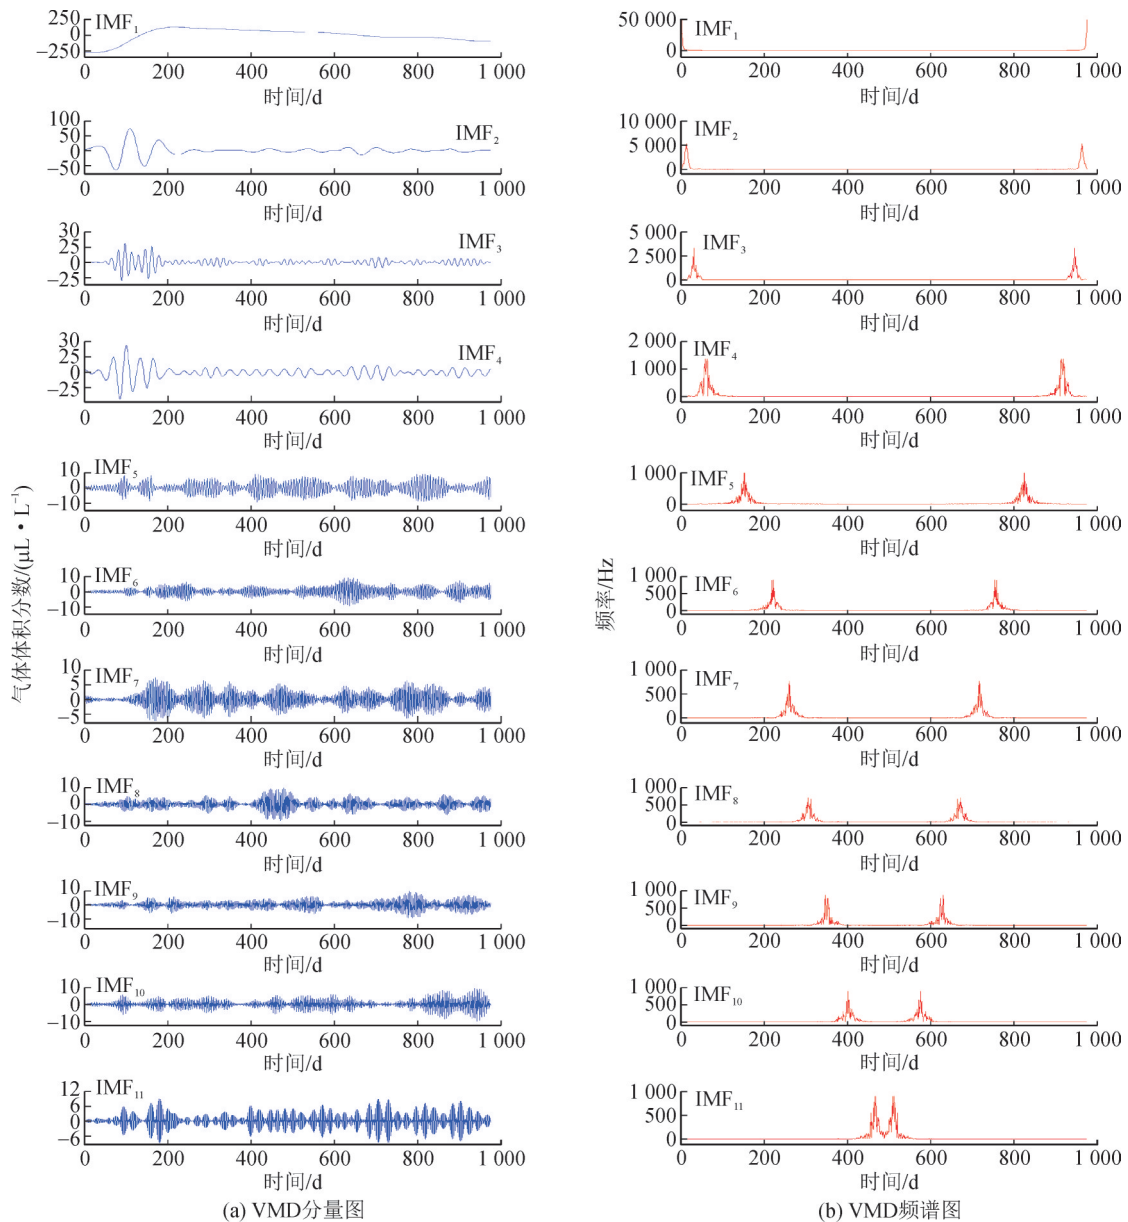


图10 VMD分量与频谱

Fig. 10 VMD components and spectrum

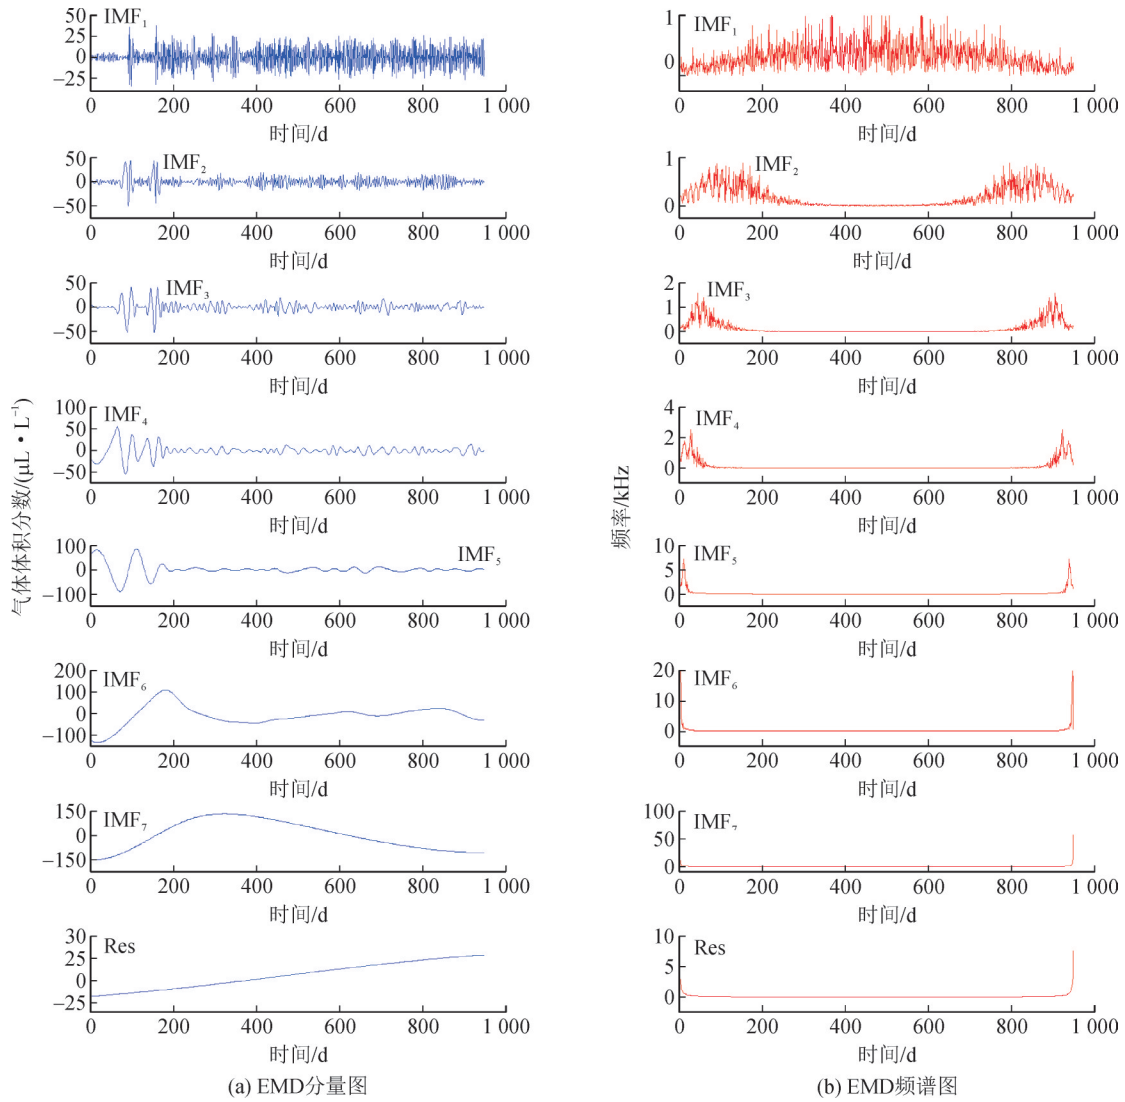


图 11 EMD分量与频谱

Fig. 11 EMD components and spectrum

从图 10 可以看出, IMF_1 变化较为平稳、幅值较大, 为去趋势后 CO_2 序列的高频部分; IMF_2 - IMF_4 表现出一定的周期性变化, 是变压器油中溶解气体 CO_2 序列中周期变化的分量; IMF_5 - IMF_{11} 波动显著赋值较小, 说明变压器油中溶解气体 CO_2 体积分数在复杂环境下受到环境温度、湿度等多随机变量的影响较大, 图 10(b) 频谱结果显示 GSSA-VMD 方法取得了良好的分解效果, 基本没有出现模态混叠的现象。结果表明, 使用 GSSA-VMD 方法能够有效地提取出原始序列中的子序列, 为建立更高准确度的温度预测模型奠定了良好基础。

从图 11(b) 中可以观察到, 采用 EMD 方法时, 分解结果出现了明显的模态混叠现象, 即不同频率分量的模态函数(IMF)之间发生了重叠与干扰。而图 10(b) 中 GSSA-VMD 方法分解出的各个 IMF 分量则几乎未受模态混叠现象的影响, 保持了较好的频

率成分分离效果。以此可以得出结论, GSSA-VMD 分解相较于 EMD 分解性能更优。

1) 使用 GSSA 优化算法与未使用优化算法的模型预测效果对比见图 12。使用固定参数的 VMD-TCN-LSTM 组合预测模型的 K 值和 α 值分别设置为 8 和 5 000。




图 12 优化 VMD 与固定值 VMD 预测对比

Fig. 12 Optimized comparison of VMD prediction with fixed value VMD prediction

从图 12 中可以看出, 与固定参数的 VMD-TCN-

LSTM组合预测模型相比,采用GSSA算法优化后的模型预测精度更具性能优势。这种效果的取得,主要得益于GSSA算法在VMD关键参数寻优过程中的表现,通过智能优化算法实现VMD参数的全局最优配置,能够有效提升模型的预测精度和稳定性。

2)使用TCN提取时间序列局部特征的组合预测模型TCN-LSTM和未使用TCN的单一LSTM预测模型对比见图13。




图13 TCN-LSTM与LSTM预测对比

Fig. 13 Comparison of TCN-LSTM with LSTM prediction

从图13中可以看出,仅依赖单一的LSTM模型对变压器油中CO₂气体体积分数的时序序列进行预测时,尽管预测结果在一定程度上捕捉到了CO₂体积分数的变化总趋势,但不能有效地预测出气体的短期波动和局部特征。相比之下,文中提出的组合模型不仅能够准确地预测CO₂体积分数的长期变化趋势,还能在短期波动和局部特征上实现更为精细的预测,提升了预测效果。

3)使用VMD分解方法和使用EMD分解方法对比见图14。




图14 VMD与EMD预测对比

Fig. 14 Comparison of VMD with EMD prediction

图14表明,相较于EMD-TCN-LSTM组合预测模型,文中所提出的组合预测模型在预测准确性方面展现出了更高的性能,可以清晰地看到文中组合预测模型输出的预测结果更为贴近真实情况,不仅在长期趋势上与实际数据保持一致,并且在短期波动和局部细节的捕捉上也展现出更高的精确度。变压器油中CO₂体积分数的预测误差对比见表2。

表2 组合预测模型误差对比

Table 2 Error comparison of combined prediction models

预测模型	$e_{MAPE}/\%$	$e_{RMSE}/(\mu L \cdot L^{-1})$
GSSA-VMD-TCN-LSTM	0.71	9.04
VMD-TCN-LSTM	1.04	9.81
EMD-TCN-LSTM	1.50	11.59
GSSA-VMD-LSTM	1.32	10.14

本研究提出的组合预测模型相比于其他组合模型拥有更低的误差MAPE值为0.71%,RMSE值为9.04 $\mu L/L$,与使用固定参数进行VMD分解的组合模型VMD-TCN-LSTM进行比较,文中所提组合模型的MAPE值减小了0.33%,RMSE值减少了0.77 $\mu L/L$ 。与基于EMD分解的组合模型EMD-TCN-LSTM相比,文中所提组合模型和VMD-TCN-LSTM模型,在MAPE值上分别减少0.79%、0.46%,RMSE值减少了2.55、1.78 $\mu L/L$ 。与未使用TCN的GSSA-VMD-LSTM组合模型相比,文中所提组合预测模型在MAPE值上减小了0.61%,在RMSE值上减小了1.10 $\mu L/L$ 。

结合图12-14的预测效果对比图,文中所提变压器油中溶解气体模型在预测效果和误差精度上优于使用EMD分解和未使用TCN增强短期特征提取能力的组合预测模型。

3.2 GSSA-VMD-TCN-LSTM组合预测模型有效性验证

为了验证文中所提组合预测模型的有效性,使用同一变压器中另外两种油中溶解气体H₂和CO作为验证对象。在实验中,参数设定均与3.1中CO₂的实验参数相同。H₂和CO体积分数原始序列曲线和去趋势曲线见图15,分解结果及预测结果见图16-19。

首先,对H₂、CO原始序列使用差分法进行去趋势化处理,然后使用GSSA优化算法对3种序列进行VMD最优参数寻优,得到的最小适应度 P_{EW} 、最优 K 、 α 值见表3。

由图16、17的分解结果可得,H₂与CO的频谱分解图在采用GSSA-VMD方法后,H₂和CO信号均呈现出清晰的分离状态,各模态分量间相互独立,未观测到模态混叠现象,验证了GSSA-VMD在油中溶解气体分解中的有效性。

文中所提预测模型对变压器油中溶解气体H₂、CO的预测结果图见图18、19。

从预测结果图来看,文中提出的变压器油中溶

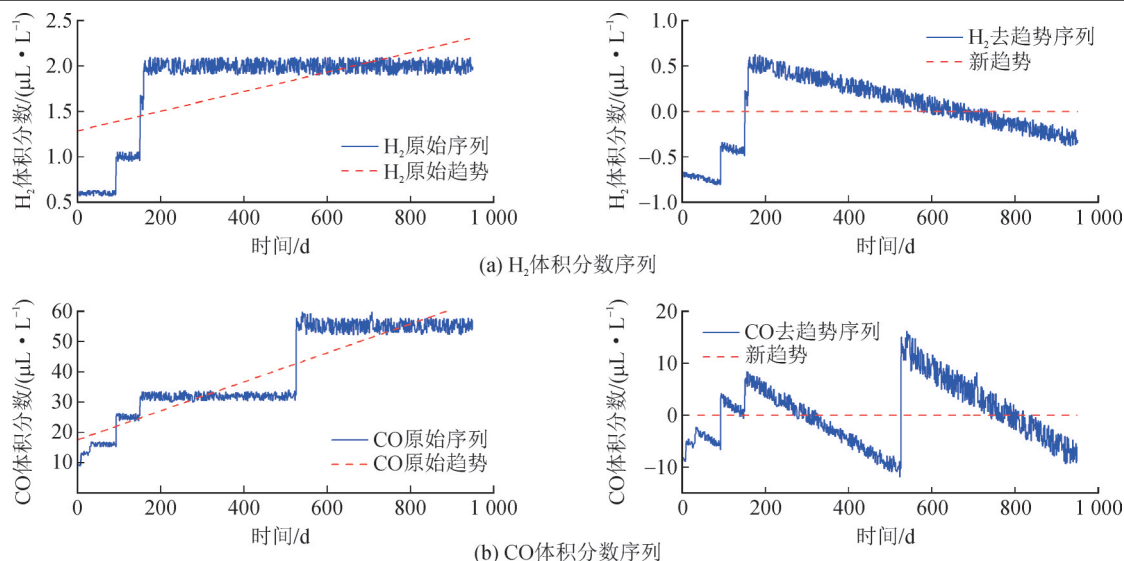


图 15 H₂和CO体积分数原始序列
Fig. 15 Original sequence of H₂ and CO content

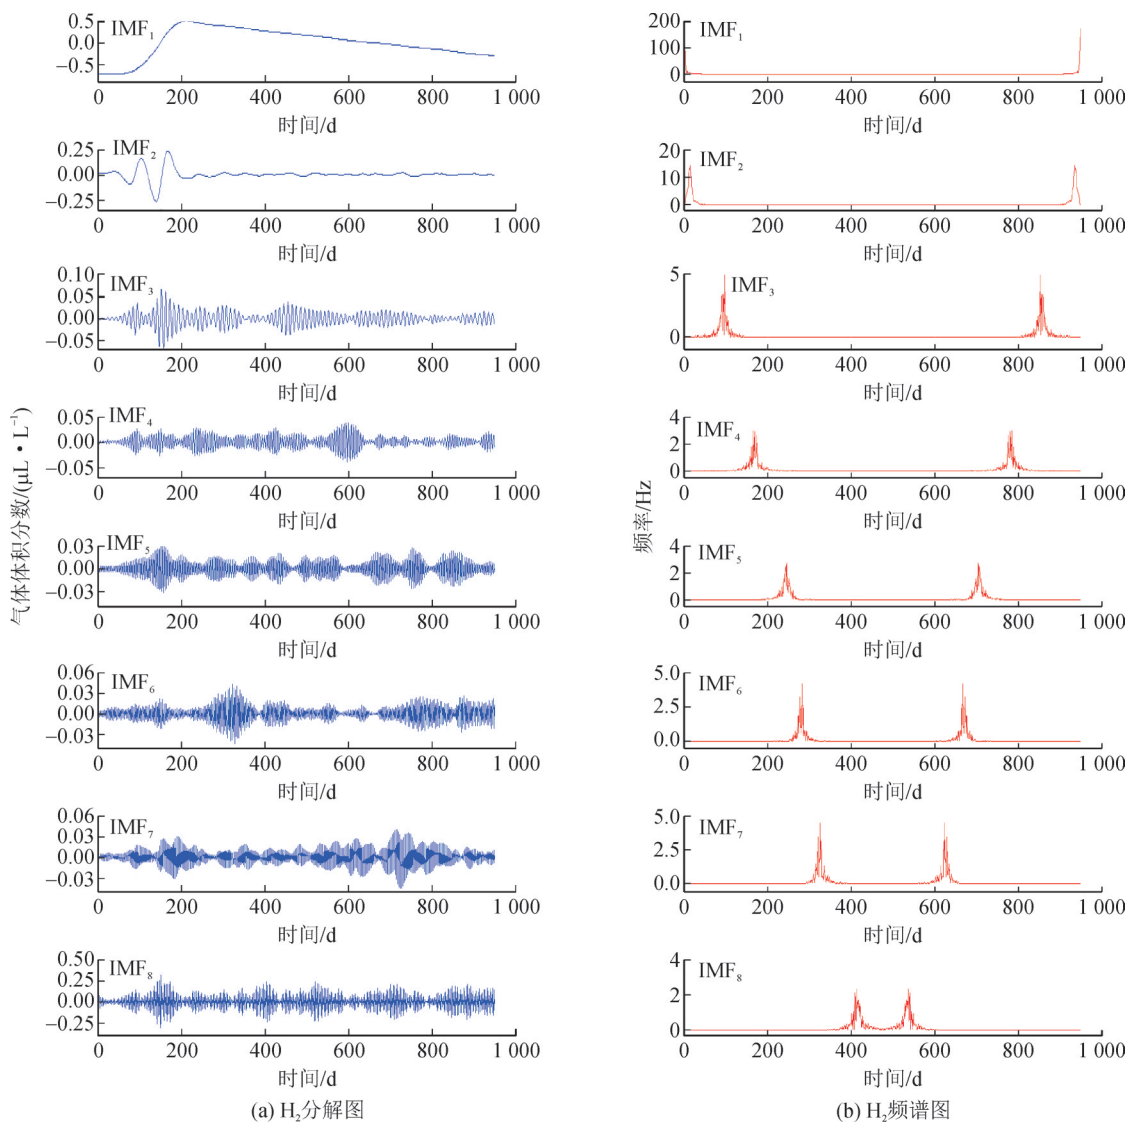


图 16 H₂序列的VMD分解分量与频谱
Fig. 16 VMD decomposition components and spectrum of H₂ sequence

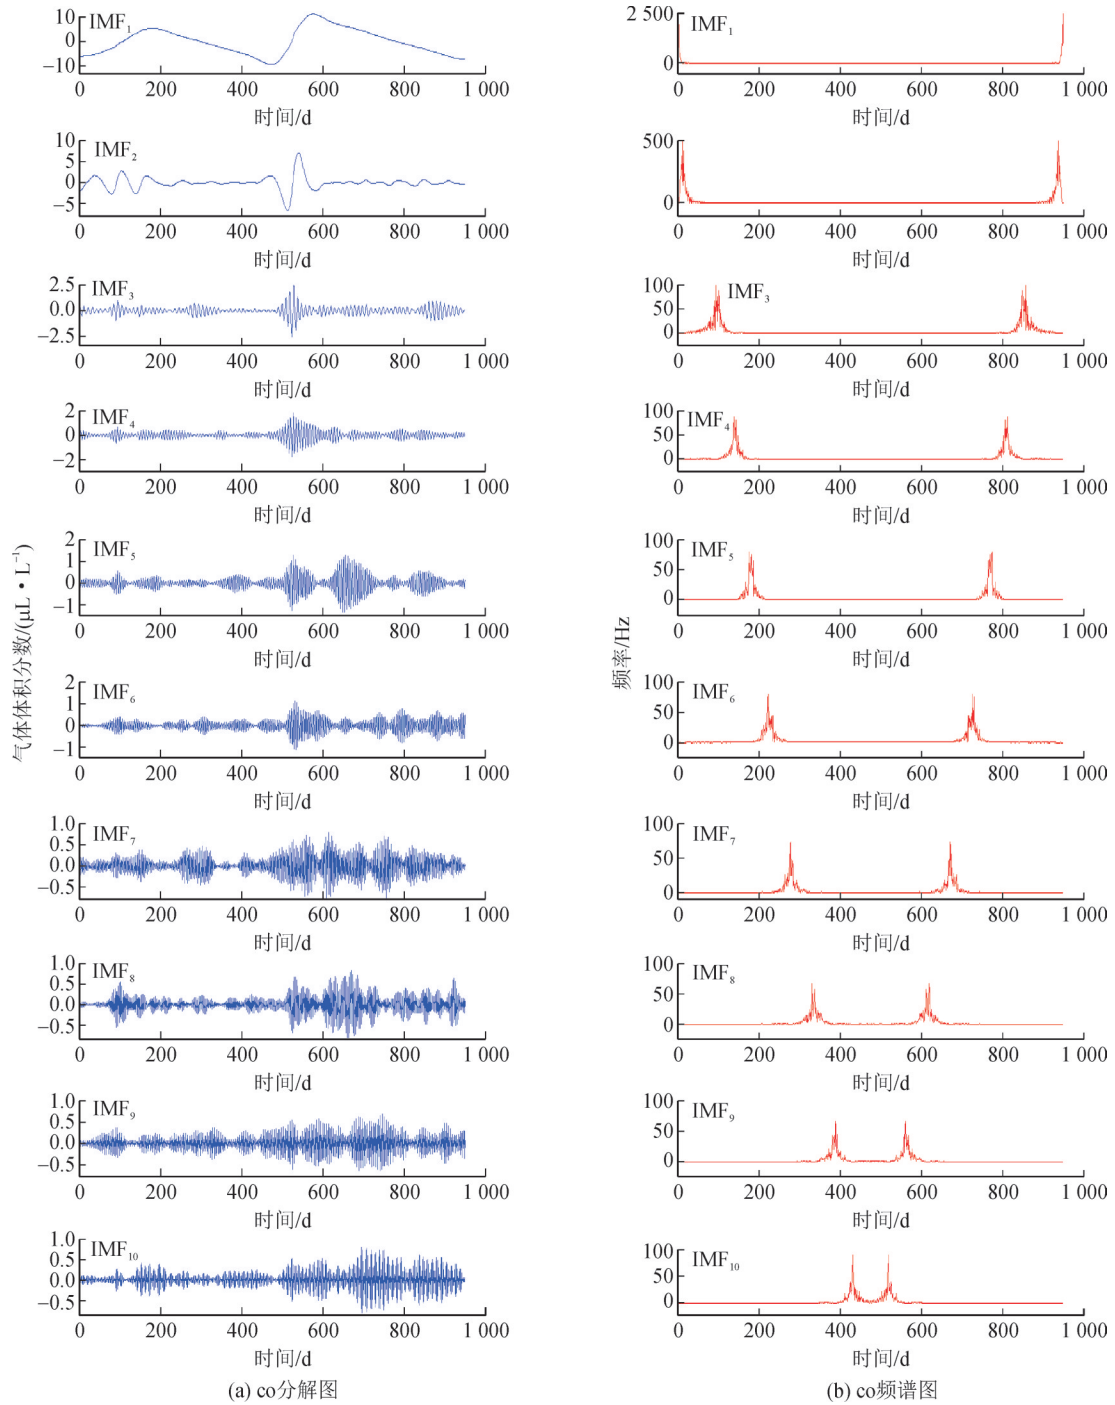


图 17 CO 序列的 VMD 分解分量与频谱

Fig. 17 VMD decomposition components and spectrum of CO sequence




图 18 H₂ 体积分数预测结果

Fig. 18 Prediction results of H₂ content




图 19 CO 体积分数预测结果

Fig. 19 Prediction results of CO content

解气体组合模型不仅准确预测了气体体积分数的长期趋势,并且捕捉到其短期内的细微变化。

表3 GSSA-VMD 寻优参数

Table 3 Optimization parameters of GSSA-VMD

参数	H ₂	CO
寻优 P_{EW} 值	0.472 77	0.277 10
最优 K 值	8	10
最优 α 值	999 8	741 4

组合预测模型对 H₂、CO 的预测误差见表 4, 两种气体预测的 MAPE 值分别为 0.57%、0.43%, RMSE 值分别为 0.03、0.63 $\mu\text{L/L}$, 预测误差很小;结合图 18、19, 可以证明本研究所提组合预测模型对多种变压器油中溶解气体体积分数预测的有效性。

表4 GSSA-VMD-TCN-LSTM 组合预测模型预测误差

Table 4 Prediction error of GSSA-VMD-TCN-LSTM combined prediction model

油中溶解气体	$e_{MAPE}/\%$	$e_{RMSE}/(\mu\text{L}\cdot\text{L}^{-1})$
H ₂	0.57	0.03
CO	0.43	0.63

4 结论

针对非平稳变压器油中溶解气体序列既有长期趋势又有短期细微波动的复杂特性,文中提出了一种基于优化 VMD-TCN-LSTM 的变压器油中溶解气体组合预测模型。通过实验分析,得出以下结论:

1)针对变压器油中溶解气体序列非平稳特性影响预测精度问题,文中提出了 GSSA-VMD 模型对其原始序列进行分解;该方法基于 VMD 分解时序数据,相较于 EMD 方法减少了分解过程中的模态混叠现象;通过引入 GSSA 优化算法对 VMD 关键参数进行自适应寻优,该方法能够将原始气体序列平稳化,为提高预测精度奠定了良好的数据基础。

2)所构建的 VMD-TCN-LSTM 组合预测模型较其他预测模型,在变压器油中溶解气体 CO₂ 预测中取得了最好的预测效果,尤其是在短期波动部分,预测精度较其他方法具有明显改善;实验结果表明,模型预测结果 MAPE 值为 0.71%, RMSE 值为 9.04 $\mu\text{L/L}$, 为变压器早期故障预警提供了可靠的技术支撑。

3)在预先设定好 GSSA 种群数量、迭代次数以及 TCN-LSTM 网络结构参数后,文中所提方法在整个预测过程无须手动调节其他参数;通过变压器油中溶解 H₂、CO 气体序列预测的有效性验证实验,可

以得出,所提预测模型对 H₂、CO 序列预测结果 MAPE 值为 0.57%、0.43%, RMSE 值为 0.03、0.63 $\mu\text{L/L}$, 验证了文中所提模型的鲁棒性,为工程应用推广提供了重要参考。

未来研究将重点考虑多因素(如温度、负载、设备老化等)对溶解气体体积分数的影响,进一步完善预测模型的综合性能。

参考文献:

- 尹豪杰. 基于油中溶解气体的变压器故障预测研究[D]. 成都:西南交通大学,2018.
YIN Haojie. Fault prediction of transformer based on dissolved gas analysis[D]. Chengdu:Southwest Jiaotong University, 2018.
- 变压器油中溶解气体分析和判断导则:DL/T 722—2014[S]. 2014.
Guide to the analysis and the diagnosis of gases dissolved in transformer oil:DL/T 722—2014[S].2014.
- YANG Tongliang, FANG Yun, ZHANG Chengming, et al. Prediction of dissolved gas content in transformer oil based on multi-information fusion[J]. High Voltage, 2024, 9(3):685-699.
- 朱庆龙,郑智勇,杨廷方. 基于 LSTSVR 模型的并联电抗器油中溶解气体浓度预测[J]. 机电信息, 2020(30):108-109.
ZHU Qinglong, ZHENG Zhiyong, YANG Tingfang. Prediction of dissolved gas concentration in shunt reactor oil based on LSTSVR model[J]. Mechanical and Electrical Information, 2020(30): 108-109.
- 曹正江,付文龙,文斌,等. 基于 TVFEMD 和多模型融合的变压器油中溶解气体体积分数预测方法[J]. 高压电器, 2024, 60(8):156-166.
CAO Zhengjiang, FU Wenlong, WEN Bin, et al. Prediction method of dissolved gas volume fraction in transformer oil based on TVFEMD and multi-model fusion[J]. High Voltage Apparatus, 2024, 60(8):156-166.
- 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.
- 彭继慎,夏玲云,王焱增. 基于 CEEMD 联合 TGSCSO-LSTM 算法的变压器油中气体浓度预测方法[J]. 电气工程学报, 2024, 19(4):407-415.
PENG Jishen, XIA Lingyun, WANG Yizeng. Prediction method of gas concentration in transformer oil based on CEEMD and TGSCSO-LSTM[J]. Journal of Electrical Engineering, 2024, 19(4): 407-415.
- HAFIZ F, AWAL M A, QUEIROZ A R D, et al. Real-time stochastic optimization of energy storage management using deep learning-based forecasts for residential PV applications[J]. IEEE Transactions on Industry Applications, 2020, 56(3):2216-2226.

- [9] 王志勃, 姜仲秋, 张天舒. 基于CNN-LSTM的白马湖水质预测模型研究[J]. 电脑知识与技术, 2022, 18(26): 11-13.
WANG Zhibo, JIANG Zhongqiu, ZHANG Tianshu. Research on water quality prediction model of baima lake based on CNN-LSTM [J]. Computer Knowledge and Technology, 2022, 18(26): 11-13.
- [10] WANG Yu, LIU Guohua. MLA - TCN: Multioutput prediction of dam displacement based on temporal convolutional network with attention mechanism[J]. Structural Control and Health Monitoring, 2023(1): 1-19.
- [11] 杨文栋. 基于神经网络模型的时间序列预测框架的构建与应用[D]. 大连: 东北财经大学, 2020.
YANG Wendong. Establishment and application of time series forecasting framework based on neural network model[D]. Dalian: Dongbei University of Finance and Economics, 2020.
- [12] 马星河, 张登奎. 基于改进经验小波变换的高压电缆局部放电噪声抑制研究[J]. 电工技术学报, 2021, 36(s1): 353-361.
MA Xinghe, ZHANG Dengkui. Research on suppression of partial discharge noise of high voltage cable based on improved empirical wavelet transform[J]. Transactions of China Electrotechnical Society, 2021, 36(s1): 353-361.
- [13] 林琳, 陈志英. 基于粗糙集神经网络和振动信号的高压断路器机械故障诊断[J]. 电工技术学报, 2020, 35(s1): 277-283.
LIN Lin, CHEN Zhiying. Mechanical fault diagnosis of high voltage circuit breakers based on rough set neural networks and vibration signals[J]. Transactions of China Electrotechnical Society, 2020, 35(s1): 277-283.
- [14] 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.
- [15] 赵洪山, 王奎, 王震, 等. 基于VMD-MGRU的箱式变压器高压套管温度预测[J]. 电机与控制学报, 2021, 25(8): 18-28.
ZHAO Hongshan, WANG Kui, WANG Zhen, et al. Temperature prediction of box-type transformer high-voltage bushing based on VMD - MGRU[J]. Electric Machines and Control, 2021, 25(8): 18-28.
- [16] 徐冬梅, 王亚琴, 王文川. 基于VMD-TCN的月降水量预测模型[J]. 水文, 2022, 42(2): 13-18.
XU Dongmei, WANG Yaqin, WANG Wenchuan. Monthly precipitation prediction model based on VMD-TCN[J]. Journal of China Hydrology, 2022, 42(2): 13-18.
- [17] 李青, 张新燕, 马天娇, 等. 基于ECBO-VMD-WKELM的风电功率超短期多步预测[J]. 电网技术, 2021, 45(8): 3070-3078.
LI Qing, ZHANG Xinyan, MA Tianjiao, et al. Multi-step ahead ultra-short term forecasting of wind power based on ECBO - VMD - WKELM[J]. Power System Technology, 2021, 45(8): 3070-3078.
- [18] 曹奇, 岳东杰, 高永攀, 等. 基于非平稳时间序列的不同趋势项提取方法对比研究[J]. 大地测量与地球动力学, 2013, 33(6): 150-154.
CAO Qi, YUE Dongjie, GAO Yongpan, et al. Contrast study on various methods extracting trend extraction based on non-stationary time series[J]. Journal of Geodesy and Geodynamics, 2013, 33(6): 150-154.
- [19] JI Qiyang, HAN Lei, JIANG Lifang, et al. Short-term prediction of the significant wave height and average wave period based on the variational mode decomposition - temporal convolutional network - long short-term memory(VMD - TCN - LSTM)algorithm[J]. Ocean Science, 2023, 19(6): 1561-1578.
- [20] ALI M, KHAN A, REHMAN N U. Hybrid multiscale wind speed forecasting based on variational mode decomposition[J]. European Transactions on Electrical Power, 2018, 28(1): 2466.
- [21] 叶鑫, 王海瑞, 李远博, 等. 基于优化VMD和集成模型的锂电池寿命预测[J]. 化工自动化及仪表, 2023, 50(4): 500-506.
YE Xin, WANG Hairui, LI Yuanbo, et al. Remaining life prediction method for lithium batteries based on optimized vmd and integrated model[J]. Control and Instruments in Chemical Industry, 2023, 50(4): 500-506.
- [22] XUE Jiankai, SHEN Bo. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [23] 聂方鑫, 王宇嘉. 基于自适应t分布与随机游走的麻雀搜索算法[J]. 电子科技, 2023, 36(7): 75-80.
NIE Fangxin, WANG Yujia. Sparrow search algorithm based on adaptive t-distribution and random walk[J]. Electronic Science and Technology, 2023, 36(7): 75-80.
- [24] TANYILDIZI E, DEMIR G. Golden sine algorithm: a novel math-inspired algorithm[J]. Advances in Electrical and Computer Engineering, 2017, 17(2): 71-78.
- [25] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generative convolutional and recurrent networks for sequence modeling [EB/OL]. [2025-08-06]. <https://arxiv.org/abs/1803.01271>.
- [26] LUO Diansheng, FANG Jie, HE Hongying, et al. Prediction for dissolved gas in power transformer oil based on TCN and GCN[J]. IEEE Transactions on Industry Applications, 2022, 58(6): 7818-7826.
- [27] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [28] CHICCO D, WARRENS M J, JURMAN G. The coefficient of determination R - squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation[J]. PeerJ Computer Science, 2021(7): 1-24.
- [29] 刘海东, 李星诚, 张文豪. 改进Adam优化器在瓦斯涌出量预测中的应用研究[J]. 工矿自动化, 2023, 49(12): 25-32.
LIU Haidong, LI Xingcheng, ZHANG Wenhao. Research on the application of improved Adam training optimizer in gas emission prediction[J]. Industry and Mine Automation, 2023, 49(12): 25-32.
- [30] 李晨, 梁书锋, 刘传鹏, 等. 基于改进的集合经验模态分解的爆破振动信号趋势项消除方法[J]. 北京理工大学学报, 2021, 41(6): 636-641.
LI Chen, LIANG Shufeng, LIU Chuanpeng, et al. Trend removing method of blasting vibration signals based on MEEMD[J]. Transactions of Beijing Institute of Technology, 2021, 41(6): 636-641.
- [31] 任刚, 贾继德, 梅检民, 等. 基于变分模态分解和去趋势波动

- 分析的柴油机振动信号去噪方法[J]. 内燃机工程, 2019, 40(2): 76-81.
- REN Gang, JIA Jide, MEI Jianmin, et al. Vibration signal denoising method of diesel engines based on VMD and DFA[J]. Chinese Internal Combustion Engine Engineering, 2019, 40(2): 76-81.
- [32] 宗琳, 周晓华, 罗文广, 等. 蜣螂算法优化概率神经网络的变压器故障诊断[J]. 智慧电力, 2024, 52(5): 98-104.
- ZONG Lin, ZHOU Xiaohua, LUO Wenguang, et al. Transformer fault diagnosis based on probabilistic neural network optimized by dung beetle optimizer[J]. Smart Power, 2024, 52(5): 98-104.
- [33] 李永康, 张丙旭, 杜振斌, 等. 一起低端换流变压器油中缓慢产生乙炔故障分析[J]. 变压器, 2024, 61(2): 74-76.
- LI Yongkang, ZHANG Bingxu, DU Zhenbin, et al. Analysis of acetylene fault in oil of a low - end converter transformer[J]. Transformer, 2024, 61(2): 74-76.
- [34] 刘道生, 华叙云, 王仕会, 等. 变压器油流带电影响因素及其抑制方法[J]. 变压器, 2024, 61(7): 1-12.
- LIU Daosheng, HUA Xuyun, WANG Shihui, et al. Factors influencing electrification of oil flow in transformer and its suppression method[J]. Transformer, 2024, 61(7): 1-12.
- [35] 连鸿松, 刘慧鑫, 黄锦, 等. 变压器油多参量一体化分析平台[J]. 变压器, 2025, 62(4): 53-61.
- LIAN Hongsong, LIU Huixin, HUANG Jin, et al. Transformer oil multi-parameter integrated analysis platform[J]. Transformer, 2025, 62(4): 53-61.
- [36] 刘建锋, 李志远, 周亚茹. 基于漏磁场和ICOA-ResNet的变压器绕组早期故障诊断[J]. 电力系统保护与控制, 2024, 52(9): 99-110.
- LIU Jianfeng, LI Zhiyuan, ZHOU Yaru. Transformer windings based on leakage field and ICOA-ResNet early fault diagnosis[J]. Power System Protection and Control, 2024, 52(9): 99-110.
- [37] 杨金鑫, 廖才波, 胡雄, 等. 基于DGA与TPE-LightGBM的变压器故障诊断[J]. 电力科学与技术学报, 2024, 39(4): 70-77.
- YANG Jinxin, LIAO Caibo, HU Xiong, et al. Transformer fault diagnosis based on DGA and TPE-LightGBM[J]. Journal of Electric Power Science and Technology, 2024, 39(4): 70-77.

代浩(1999—), 男, 硕士研究生, 研究方向为电力设备状态监测与故障诊断(E-mail: 344159070@qq.com)。

谭为民(1974—), 女, 副教授, 硕士生导师, 研究方向为计算机辅助测试与信号处理、电力设备状态监测与故障诊断(通信作者)(E-mail: 391904395@qq.com)。

(上接第46页)

- Insulating Materials, 2006, 39(2): 36-38.
- [20] 张俊民, 徐国政, 王其平. PTFE蒸气对电弧特性影响的数值分析[J]. 高压电器, 2002, 38(4): 12-15.
- ZHANG Junmin, XU Guozheng, WANG Qiping. Numerical analysis of the influence of PTFE vapour on the characteristics of nozzle arc[J]. High Voltage Apparatus, 2002, 38(4): 12-15.
- [21] 杨涌, 王其平. SF₆断路器喷口电弧熄灭过程的数字模拟[J]. 中国电机工程学报, 2000, 20(5): 9-13.
- YANG Yong, WANG Qiping. Computer aided numerical analysis of arcing processes in SF₆ circuit breaker nozzle[J]. Proceedings of the CSEE, 2000, 20(5): 9-13.
- [22] 李仰平, 张建宏, 彭宗仁, 等. 高压断路器喷口材料的试验研究[J]. 高压电器, 2002, 38(4): 19-21.
- LI Yangping, ZHANG Jianhong, PENG Zongren, et al. Experimental study on nozzle materials of high - voltage circuit breaker[J]. High Voltage Apparatus, 2002, 38(4): 19-21.
- [23] 李仰平, 耿波, 刘泽响, 等. SF₆断路器喷口用复合PTFE电气性能的研究[J]. 高压电器, 2006, 42(2): 122-124.
- LI Yangping, GENG Bo, LIU Zexiang, et al. Research on the electric properties of PTFE composite used in nozzle of SF₆ circuit breaker[J]. High Voltage Apparatus, 2006, 42(2): 122-124.
- [24] 刘先兰. 聚四氟乙烯(PTFE)制品的成型工艺及质量分析[J]. 现代机械, 2003(3): 77-78.
- LIU Xianlan. Moulding techniques and quality analysis of the products of poly tetra fluoro ethylene[J]. Modern Machinery, 2003 (3): 77-78.
- [25] 张俊民, 徐国政. SF₆自能膨胀式断路器喷口烧蚀的数学模型[J]. 清华大学学报(自然科学版), 2002, 42(9): 1172-1175.
- ZHANG Junmin, XU Guozheng. Mathematical model of nozzle ablation in an SF₆ auto - expansion circuit breaker[J]. Journal of Tsinghua University(Science and Technology), 2002, 42(9): 1172-1175.

卫亚博(1984—), 女, 讲师, 博士, 研究方向为高压电器与测量技术(E-mail: woshiyabo1020@163.com)。

孙珂珂(1982—), 男, 正高级工程师, 博士, 研究方向为高压电器与系统仿真(通信作者)(E-mail: sunkeke2010@163.com)。