

DOI:10.19651/j.cnki.emt.2208994

基于 SDS-SSA-LSTM 的变压器油中溶解气体浓度预测^{*}

陈铁^{1,2} 陈一夫^{1,2} 李咸善^{1,2} 冷昊伟^{1,2} 陈卫东^{1,2}

(1.三峡大学电气与新能源学院 宜昌 443002; 2.三峡大学梯级水电站运行与控制湖北省重点实验室 宜昌 443002)

摘要: 油中溶解气体浓度预测对变压器早期故障检测至关重要。为了提高预测精度,本文提出了奇异谱分析(SSA)结合长短期记忆网络(LSTM)的预测模型。首先针对传统序列分解做法中的数据泄露问题,提出一种基于SSA逐步分解的采样策略,然后基于该策略将特征复杂的原始油中溶解气体浓度序列分解为特征相对单一的趋势分量与波动分量,最后利用LSTM网络对各个分量分别进行单步和多步预测。累加各分量的预测值,得到原气体浓度的预测结果。算例表明,相较于单一LSTM,本文所提模型在实验天数内整体的预测精度更高。

关键词: 变压器;油中溶解气体;数据泄露;逐步分解采样;奇异谱分析;长短期记忆网络

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

Prediction of dissolved gas concentration in transformer oil based on SDS-SSA-LSTM

Chen Tie^{1,2} Chen Yifu^{1,2} Li Xianshan^{1,2} Leng Haowei^{1,2} Chen Weidong^{1,2}

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China;

2. Hubei Provincial Key Laboratory for Operation and Control of Cascaded Hydropower Station, China Three Gorges University, Yichang 443002, China)

Abstract: Prediction of dissolved gas concentration in oil is very important for transformer early fault detection. a prediction model based on singular spectrum analysis (SSA) combined with long and short-term memory network (LSTM) is proposed to improve the prediction accuracy. First, To solve the problem of data leakage in traditional sequence decomposition, a sampling strategy based on SSA stepwise decomposition is proposed. Then based on this strategy, the concentration sequence of dissolved gas in original oil with complex characteristics is decomposed into relatively single trend component and fluctuation component. Finally using LSTM network for each component for single step and multi-step prediction respectively. The predicted values of each component are accumulated to obtain the prediction result of original gas concentration. The example shows that compared with the single LSTM model, the overall prediction accuracy of the proposed method is higher in the experimental days.

Keywords: transformer;dissolved gas in oil;data leakage;stepwise decomposition sampling;singular spectrum analysis;long short-term memory

0 引言

变压器的稳定运行是电网及相关设施正常运行的必要条件。油中溶解气体分析(dissolved gas analysis, DGA)是目前变压器潜伏故障诊断的有效方法^[1]。因此,预测变压器内气体的浓度对其早期故障检测至关重要^[2-6]。

变压器实际运行工况复杂,其油中溶解气体含量呈现

非线性以及波动性的特征^[7]。于是,基于复杂时间序列分解的预测模型,成为了当下研究的重点。

目前,小波分解(wavelet decomposition, WD)^[8]、经验模态分解(empirical mode decomposition, EMD)^[9-10]、集合经验模态分解(ensemble empirical mode decomposition, EEMD)^[11]、互补集合经验模态分解(complete ensemble empirical mode decomposition, CEEMD)^[12-13]和变分模态

收稿日期:2022-02-10

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

分解(variational mode decomposition, VMD)^[14]均已研究用于变压器油中溶解气体浓度预测。然而,上述研究均采用整体分解(overall decomposition sampling, ODS)的采样技术处理数据样本,即先将油中溶解气体浓度序列分解为子序列,再划分训练样本和测试样本。这样,在分解过程中便假设未来的数据是已知的,引发了数据泄露,模型的训练结果不能用于指导在线预测。

基于逐步分解(stepwise decomposition sampling, SDS)的采样技术^[15]可有效规避传统 ODS 采样技术中的数据泄露问题。EMD 因为模态分解数目不可控,不能用于 SDS 采样^[16]。EEMD 和 CEEMD 由于自身算法原理^[17-18],随着待分解时间序列边缘值得更新,各分解分量会产生显著的改变,将它们进行 SDS 采样,所获得训练样本本身时序规律不可控。WD 在小基波与分解层次的确定存在困难,VMD^[19]则是直接分解出的趋势项会产生较大误差,从而给预测带来困难。奇异谱分析(singular spectrum analysis, SSA)是一种非线性时间序列分析方法^[20],能够有效提取原序列中的趋势成分与波动成分,无需选取先验基函数,并且随着待分解时间序列的更新,各分解分量历史的序列特征几乎可以得到完整的保留^[21]。

在对分解分量进行预测方面,较为常用的方法有统计预测中的灰色模型(grey model, GM)^[22]、时间序列模型^[23]等,机器学习中的支持向量机(support vector machine, SVM)^[24]、人工神经网络(artificial neural network, ANN)^[25]等,和深度学习中的长短期记忆网络(long short-term memory, LSTM)。文献[26-27]指出 LSTM 相较于统计预测模型与机器学习模型能够更有效的挖掘油中溶解气体浓度序列在时间上的规律,具有更高的预测精度。

鉴于此,本文提出了基于 SSA 的 SDS 策略,并结合 LSTM 网络实现变压器油中溶解气体浓度预测。流程如下:首先采用 SSA 方法对训练数据进行 SDS 采样,然后对所有分量的样本建立 LSTM 预测模型。接着对测试数据进行 SSA 逐步分解,并以此输入 LSTM 中生成各分量的预测结果,在滚动迭代完成整个测试天数的预测后,累加各分量的预测值,得到最终的预测结果。相较于单一 LSTM,所提模型在实验天数内整体的预测精度更高,并且彻底规避了未来数据的泄露,证实其有效性。

1 时间序列分解

1.1 奇异谱分析

奇异谱分析是一种非线性时间序列分析的方法,通过对时间序列构造轨迹矩阵,并对其进行分解和重构,可以有效提取原序列中的趋势成分与波动成分。该算法具体计算步骤如下:

1)嵌入。将原始时间序列 $\mathbf{X} = (x_1, x_2, \dots, x_n)$, 根据设置的嵌入维度 $L (L \leq n/2)$, 将其转化为轨迹矩阵 \mathbf{Y} 。

$$\mathbf{Y}_{L \times K} = (y_{ij})_{i,j=1}^{L,K} = \begin{pmatrix} x_1 & x_2 & \cdots & x_{n-L+1} \\ x_2 & x_3 & \cdots & x_{n-L+2} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \cdots & x_n \end{pmatrix} \quad (1)$$

式中: $K = n - L + 1$ 。

2)奇异值分解。计算矩阵 $\mathbf{Y}\mathbf{Y}^T$ 的特征值 $\lambda_1, \lambda_2, \dots, \lambda_L (\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L)$ 和对应的特征向量 $\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_L$ 。设 d 为非零特征值的个数,定义 $\mathbf{V}_i = \mathbf{Y}^T \mathbf{U}_i \sqrt{\lambda_i}$, 轨迹矩阵 \mathbf{Y} 的奇异值分解可写为:

$$\mathbf{Y} = \mathbf{Y}_1 + \mathbf{Y}_2 + \cdots + \mathbf{Y}_d \quad (2)$$

式中: $\mathbf{Y}_i = \sqrt{\lambda_i} \mathbf{U}_i \mathbf{V}_i^T, 1 \leq i \leq d$, \mathbf{U}_i 和 \mathbf{V}_i 分别为轨迹矩阵 \mathbf{Y} 的第 i 个奇异值对应左、右奇异向量,并且每个矩阵 \mathbf{Y}_i 对轨迹矩阵 \mathbf{Y} 的贡献程度与特征值 λ_i 相关,其贡献率 η 可以定义为:

$$\eta = \lambda_i / \sum \lambda \quad (3)$$

3)对角平均化。将各子矩阵 \mathbf{Y}_i 还原为长度为 n 的时间序列。假定 \mathbf{Y} 为 $L \times K$ 形状的矩阵,设 $L^* = \min(L, K), K^* = \max(L, K)$, 其中, $K = n - L + 1$, 当 $L < K$ 时, $y_{ij}^* = y_{ij}$, 否则, $y_{ij}^* = y_{ji}$ 。重构序列 $\mathbf{Z}_e = (z_{e1}, z_{e2}, \dots, z_{en})$ 计算如下:

$$z_{el} = \begin{cases} \frac{1}{l+1} \sum_{m=1}^{l+1} y_{m,l-m+2}^*, & 1 \leq l \leq L \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m,l-m+2}^*, & L^* \leq l \leq K^* \\ \frac{1}{n-l} \sum_{m=l-K^*+2}^{l-K^*+1} y_{m,l-m+2}^*, & K^* \leq l \leq n \end{cases} \quad (4)$$

4)分组。最大的特征值对应的奇异向量代表了原序列最大的变化趋势,较小的特征值对应的奇异向量反应了原序列的波动成分。通过设定贡献率阈值 η_e (一般取 $\eta_e \geq 80\%$),然后按特征值由大到小的顺序逐步重构子序列,当出现 $\sum \lambda_i / \sum \lambda \geq \eta_e$ 时,所获得的序列即为原序列的趋势分量,剩余的子序列则重构为波动分量。

1.2 基于逐步分解的采样策略

设时间序列 $\mathbf{TS} = \{x_t | t = 1, \dots, T+K\}$, 其中, $T+K$ 是时间序列 \mathbf{TS} 的长度。使用 x_1 到 x_T 作为训练数据,剩余部分作为测试数据。具体逐步分解步骤如下:

- 1)将时间序列 $\mathbf{x}_{1:L}$ 分解为子序列 $\mathbf{x}_{1:L}^{i1}$ 。 L 是分解长度, $i1$ 表示第一步分解得到的第 i 个子序列。
- 2)将长度为 $L+1$ 的时间序列 $\mathbf{x}_{1:L+1}$ 分解为子序列 $\mathbf{x}_{1:L+1}^{i2}$ 。则第 i 个子序列第一个样本的输入输出分别来自 $\mathbf{x}_{1:L}^{i1}$ 和 $\mathbf{x}_{1:L+1}^{i2}$, 如图 1 所示。需要注意的是,并不是所有的潜在特征都要作为模型输入,应该选择模型时间步长对应的潜在特征作为模型输入。
- 3)继续按照步骤 1)与 2)逐步分解下一个长度为 L 和 $L+1$ 的时间序列,直到得到所有的训练数据集。

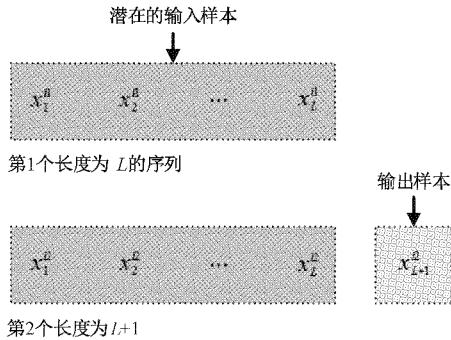


图 1 输入和输出样本

4) 分别为每个子序列建立预测模型。

5) 在预测阶段, 对历史 L 长度的时间序列进行分解, 并根据训练后的模型分别对每个子序列进行预测。

6) 累加各子序列的预测值, 得到原序列的预测结果。

应用上述 SDS 采样策略, 彻底规避了传统 ODS 采样中的数据泄露问题, 基于该策略下训练的模型符合实际的在线预测场景。

2 长短期记忆网络

循环神经网络是一类深度神经网络, 它利用内部的记忆循环来处理序列数据。相较于传统神经网络, RNN 能更有效地捕捉序列数据在时间上的规律。长短期记忆网络是一种改进的 RNN, 通过引入门结构, 进一步获得了传递序列数据长期依赖关系的能力。

LSTM 包含 3 个门结构, 即输入门、遗忘门和输出门, 在时刻 t 分别表示为 i_t 、 f_t 和 o_t , 如图 2 所示。LSTM 输出的计算过程如下:

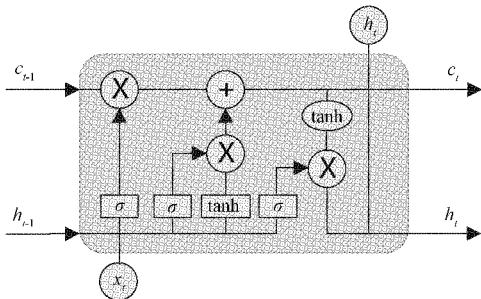


图 2 LSTM 单元结构

$$i_t = \text{sigmoid}(\mathbf{W}_i \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i) \quad (5)$$

$$f_t = \text{sigmoid}(\mathbf{W}_f \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f) \quad (6)$$

$$\tilde{c}_t = \tanh(\mathbf{W}_c \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_c) \quad (7)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (8)$$

$$o_t = \text{sigmoid}(\mathbf{W}_o \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o) \quad (9)$$

$$h_t = o_t * \tanh(c_t) \quad (10)$$

其中, c 表示记忆单元, h 为隐层输出, 其下标表示时刻。 \mathbf{W} 表示相应的连接层权重矩阵, \mathbf{b} 是对应的偏置项。 \tanh 、 sigmoid 则为激活函数。

3 变压器油中溶解气体预测模型

本文提出了一种基于 SDS 采样策略的 SSA-LSTM 模型, 其具体建模流程如图 3 所示。

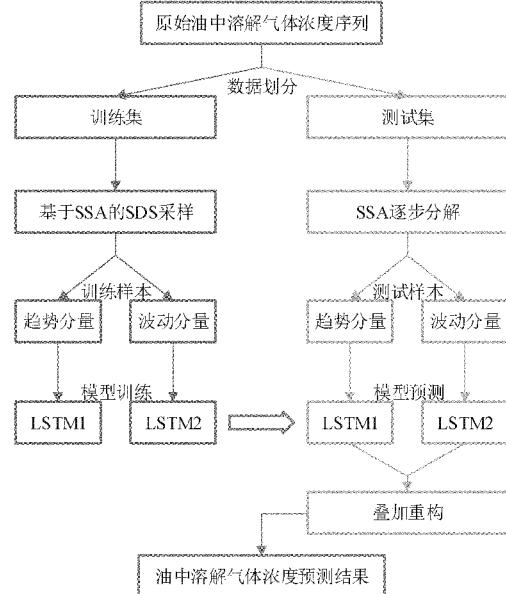


图 3 基于 SDS-SSA-LSTM 气体预测流程

1) 将原始油中溶解气体浓度序列进行训练集和测试集划分。

2) 对训练集基于 SSA 方法进行 SDS 采样, 直到获得趋势分量与波动分量完整的训练样本。

3) 分别为每个子序列的训练样本建立 LSTM 预测模型。

4) 对测试集进行 SSA 逐步分解, 并以此输入 LSTM 中生成各分量的预测结果。

5) 将各分量的预测值进行累加, 得到原始油中溶解气体浓度预测结果。

4 实例研究

4.1 数据选取

本研究选取两台 500 kV 变压器油中溶解气体浓度数据, 其中一台变压器的时间序列起止时间为 2014 年 4 月 26 日~2017 年 1 月 19 日, 包括 H_2 、 CH_4 、 C_2H_4 、 C_2H_6 、 CO 、 CO_2 , 另一台变压器的时间序列起止时间为 2010 年 6 月 29 日~2013 年 3 月 24 日, 包括 C_2H_2 , 采样间隔均为 1 d, 7 种气体分别获得 1 000 组样本点, 选取前 800 d 数据作训练集, 后 200 d 数据作测试集。经过多次试验, 算例设置 SDS-SSA-LSTM 模型参数如表 1 所示。由于篇幅限制, 文中主要以 CO_2 序列为例, 展开分析。

4.2 评价指标

本研究选取平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root mean square error, RMSE) 来对

表 1 SDS-SSA-LSTM 模型参数

模型参数	SDS	SSA	LSTM
神经单元数	X	X	50
学习率	X	X	0.01
时间步长	X	X	10
最大迭代次数	X	X	150
嵌入窗口长度	X	50	X
贡献率阈值/%	X	80	X
分解长度	100	X	X

注: ‘X’表示该列模型不存在此行中的参数。

预测模型进行评估,公式如下:

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (11)$$

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

其中, \hat{y}_i 为预测值, y_i 为真实值, m 为测试样本总数。

4.3 时间序列预处理

1) SSA 分解

应用 SSA 方法对 7 种气体的历史时间序列进行 SDS 采样, 其中 CO_2 序列某训练样本与测试样本的分解结果如图 4 所示。

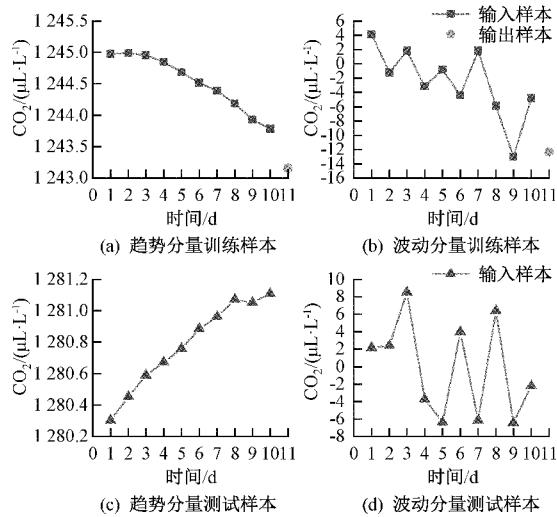


图 4 CO_2 序列的某训练样本与测试样本

2) 数据归一化

为了提高后续预测模型的数据处理效率, 需要对各子序列进行归一化处理, 本文选择 MinMax 标准化, 公式如下:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (13)$$

式中: x' 为归一化后数值, x_{\min} 为训练样本中的最小值, x_{\max} 为训练样本中的最大值。

4.4 结果分析

1) 单步预测结果

为测试本文提出模型在单步预测中的性能, 研究采用 LSTM、ODS-SSA-LSTM 与 SDS-SSA-LSTM 得到的结果进行对比分析。其中, 对 CO_2 的预测效果如图 5 所示。7 种气体对应的测试样本预测误差指标如表 2 所示。

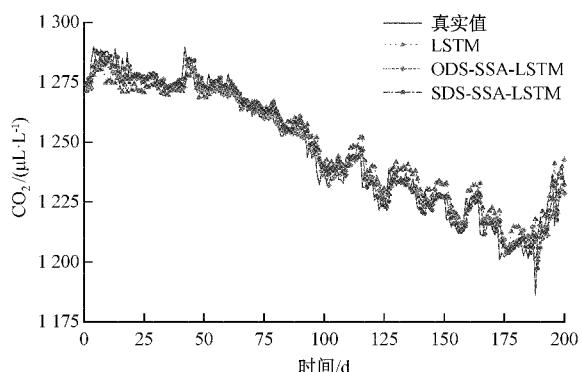


图 5 CO_2 的单步预测效果

表 2 单步预测性能比较

气体类别	评价指标	预测模型		
		LSTM	ODS-SSA-LSTM	SDS-SSA-LSTM
H_2	MAE	0.493 6	0.468 4	0.446 3
	RMSE	0.636 7	0.613 7	0.568 0
CH_4	MAE	0.378 0	0.366 1	0.368 3
	RMSE	0.453 8	0.444 0	0.441 0
C_2H_2	MAE	0.023 6	0.010 8	0.023 4
	RMSE	0.032 4	0.014 2	0.030 5
C_2H_4	MAE	0.294 2	0.218 5	0.212 5
	RMSE	0.352 5	0.279 3	0.275 9
C_2H_6	MAE	0.617 4	0.476 9	0.581 8
	RMSE	0.918 7	0.731 2	0.884 9
CO	MAE	4.336 6	2.353 2	2.471 9
	RMSE	5.671 9	4.213 2	4.401 4
CO_2	MAE	5.704 6	4.150 2	4.227 8
	RMSE	7.475 5	5.635 3	5.731 0

由表 2 可知, 采用 ODS 策略的 SSA-LSTM 模型在单步预测性能上看似优于 LSTM 模型, 但 ODS 采样策略从一开始便假设未来的数据是已知的, 而在实际应用中未来

的数据是需要预测的,因此,基于 ODS 采样策略的模型所得到的预测结果不能反应实际的在线预测效果。而基于 SDS 采样策略的模型彻底规避了未来数据的泄露,其预测结果可以指导在线预测。

表 2 的结果可知,本文提出的 SDS-SSA-LSTM 模型在 7 种气体下的 MAE 与 RMSE 指标较 LSTM 模型低,具有更好的单步预测效果。

2) 多步预测结果

通过将各子序列的单步预测结果与历史监测序列进行拼接,就能构造单步预测模型新的输入序列,从而可以实现各分量的多步滚动预测。通过累加各子序列的预测结果,便能得到原序列的多步预测值。

本文选择 LSTM 与 SDS-SSA-LSTM 对测试集进行未来 2~3 d 的预测,对 CO_2 的预测效果如图 6 所示。7 种气体对应的测试样本预测误差指标如表 3 所示。

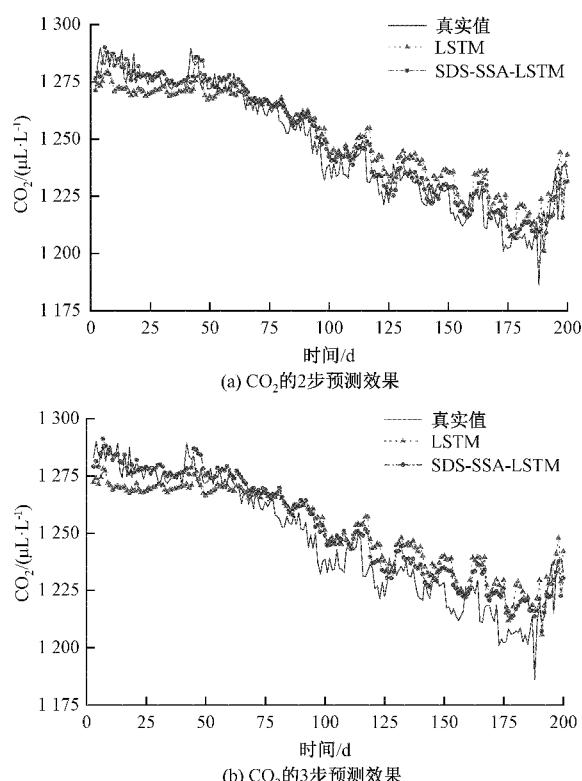


图 6 CO_2 的多步预测效果

表 3 的结果可知,SDS-SSA-LSTM 模型与 LSTM 模型相比在 2 步预测的 MAE 指标平均下降了 18.55%,RMSE 指标平均下降了 15.46%。在 3 步预测中, C_2H_2 气体的 MAE 和 RMSE 指标略微高于 LSTM 模型,这是因为对时间序列进行分解,会增加建模的数量,从而产生一定程度的累计误差。但整体的 MAE 指标仍然平均下降了 14.21%,RMSE 指标平均下降了 12.47%,证实了 SDS-SSA-LSTM 模型的有效性。

表 3 多步预测性能比较

气体 指标	预测 天数	评价 指标	预测模型	
			LSTM	SDS-SSA-LSTM
H_2	2	MAE	0.567 5	0.527 0
	3	RMSE	0.727 5	0.659 3
		MAE	0.618 8	0.606 6
		RMSE	0.794 8	0.769 5
CH_4	2	MAE	0.383 5	0.380 9
	3	RMSE	0.459 5	0.453 7
		MAE	0.393 1	0.390 4
		RMSE	0.469 9	0.465 4
C_2H_2	2	MAE	0.025 0	0.024 5
		RMSE	0.033 1	0.031 8
	3	MAE	0.030 1	0.030 6
		RMSE	0.038 8	0.038 9
C_2H_4	2	MAE	0.383 1	0.240 9
		RMSE	0.456 1	0.315 4
	3	MAE	0.468 6	0.297 2
		RMSE	0.553 4	0.376 2
C_2H_6	2	MAE	0.673 1	0.643 7
		RMSE	0.974 7	0.960 0
	3	MAE	0.771 7	0.761 3
		RMSE	1.112 7	1.097 1
CO	2	MAE	8.312 9	4.731 3
		RMSE	9.592 4	6.549 7
	3	MAE	11.814 5	7.274 5
		RMSE	13.367 8	9.144 7
CO_2	2	MAE	7.863 7	5.076 0
		RMSE	9.691 9	6.826 0
	3	MAE	10.058 3	7.836 7
		RMSE	12.065 9	9.843 0

5 结 论

为了更准确地预测变压器油中溶解气体浓度,本文提出一种基于 SDS-SSA-LSTM 的预测模型。通过对实际算例进行分析,得出如下结论:1) SDS 策略能够有效规避预测模型在测试阶段涉入未来的数据,解决了传统 ODS 策略的数据泄露问题。2)运用 SSA 方法,将特征混杂的油中溶解气体浓度序列,分解为特征相对单一的趋势序列与波动序列,易于模型学习。3) SDS-SSA-LSTM 相较于单一 LSTM,在多步 1~3 d 的预测中,其整体的模型评价指标更低,具有更好的短期预测效果。4)在未来,开发基于分解的预测模型需要与 SDS 策略相结合。并且,由于建模数量增加而带来的累计误差是实现中长期预测的一个挑战。

参考文献

- [1] MIROWSKI P, LECUN Y. Statistical machine

- learning and dissolved gas analysis: A review [J]. IEEE Transactions on Power Delivery, 2012, 27(4): 1791-1799.
- [2] 李黄曼, 张勇, 张遥. 基于 ISSA 优化 SVM 的变压器故障诊断研究[J]. 电子测量与仪器学报, 2020, 35(3): 123-129.
- [3] 王雨虹, 王志中. 基于 RFRFE 与 ISSA-XGBoost 的变压器故障辨识方法[J]. 电子测量与仪器学报, 2021, 35(12): 142-150.
- [4] 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.
- [5] 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.
- [6] 肖云波, 范菁, 张宜, 等. 基于改进粒子群算法与油中溶解气体的变压器故障诊断的研究[J]. 电子测量技术, 2021, 44(18): 122-128.
- [7] 齐波, 张鹏, 荣智海, 等. 基于相空间重构的变压器油色谱数据最优长度选择方法[J]. 中国电机工程学报, 2018, 38(8): 2504-2512.
- [8] 王兴, 荣海娜, 王健, 等. 基于小波分解和长短期记忆网络的变压器油中溶解气体浓度预测[J]. 电工技术, 2020(9): 24-29, 33.
- [9] ZENG B, GUO J, ZHANG F, et al. Prediction model for dissolved gas concentration in transformer oil based on modified grey wolf optimizer and LSSVM with grey relational analysis and empirical mode decomposition[J]. Energies, 2020, 13(2): 422.
- [10] 刘云鹏, 许自强, 董王英, 等. 基于经验模态分解和长短期记忆神经网络的变压器油中溶解气体浓度预测方法[J]. 中国电机工程学报, 2019, 39(13): 3998-4008.
- [11] 周峰, 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.
- [12] 杨海晶, 孙运全, 朱伟, 等. 基于 CEEMD-TCN 模型的变压器油中溶解气体浓度预测方法[J]. 电子器件, 2021, 44(4): 887-892.
- [13] 张玲, 卞建鹏, 郝培旭, 等. 基于 CEEMD 和 ABC-LSTM 的电力变压器油中溶解气体预测[J]. 兰州交通大学学报, 2021, 40(5): 58-64, 92.
- [14] 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.
- [15] QIAN Z, PEI Y, ZAREIPOUR H, et al. A review and discussion of decomposition-based hybrid models for wind energy forecasting applications[J]. Applied Energy, 2019, 235: 939-953.
- [16] FANG W, HUANG S, REN K, et al. Examining the applicability of different sampling techniques in the development of decomposition-based streamflow forecasting models[J]. Journal of Hydrology, 2019, 568: 534-550.
- [17] WANG T, ZHANG M, YU Q, et al. Comparing the applications of EMD and EEMD on time-frequency analysis of seismic signal[J]. Journal of Applied Geophysics, 2012, 83: 29-34.
- [18] TORRES M E, COLOMINAS M A, SCHLÖTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C]. 2011 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP), IEEE, 2011: 4144-4147.
- [19] 张鹏, 齐波, 张若思, 等. 基于经验小波变换和梯度提升径向基的变压器油中溶解气体预测方法[J]. 电网技术, 2021, 45(9): 3745-3754.
- [20] FENGHUA W E N, JIHONG X, ZHIFANG H E, et al. Stock price prediction based on SSA and SVM[J]. Procedia Computer Science, 2014, 31: 625-631.
- [21] 吴坚, 项颂, 阎诚, 等. 基于奇异谱分析的超短期风电功率多步预测[J]. 可再生能源, 2021, 39(11): 1548-1555.
- [22] 王本广, 何山, 陈小丹, 等. 基于灰色滚动预测方法的变压器智能监测研究[J]. 计算机仿真, 2020, 37(12): 72-77, 152.
- [23] 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.
- [24] 唐勇波, 丰娟. KTA-SVM 的变压器油中溶解气体浓度预测[J]. 控制工程, 2017, 24(11): 2263-2267.
- [25] LIN J, SHENG G, YAN Y, et al. Prediction of dissolved gas concentrations in transformer oil based on the KPCA-FFOA-GRNN model[J]. Energies, 2018, 11(1): 225.
- [26] 王科, 苟家莫, 彭晶, 等. 基于 LSTM 网络的变压器油中溶解气体浓度预测[J]. 电子测量技术, 2020, 43(4): 81-87.
- [27] 代杰杰, 宋辉, 盛戈皞, 等. 采用 LSTM 网络的电力变压器运行状态预测方法研究[J]. 高电压技术, 2018, 44(4): 1099-1106.

作者简介

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

E-mail: chent@ctgu.edu.cn

陈一夫, 硕士研究生, 主要研究方向为电力变压器状态预测与故障诊断。

E-mail: 913735090@qq.com