

DOI:10.13296/j.1001-1609.hva.2025.02.010

基于反馈约束变分模态分解和LSTM网络的并联电抗器油温预测研究

丁文涛¹, 淡淑恒¹, 陈浩宇¹, 蔡立川²

(1. 上海电力大学电气工程学院, 上海 200082; 2. 四川省电力公司, 成都 610000)

摘要: 并联电抗器作为电网重要的电力设备,准确估计其油温变化趋势,可为早期故障监测和预警提供重要依据。提出一种基于反馈约束变分模态分解(VMD)和长短期记忆神经网络(LSTM)的并联电抗器油温预测模型;利用信号反馈约束和加权样本熵优化VMD分解个数 k 和惩罚因子 α ,形成VMDFS分解方法将并联电抗器原始油温序列分解成多组平稳的子序列,消除不平稳信息的影响;再对各子序列构建LSTM神经网络预测模型,用粒子群优化神经元个数;最后将各子序列预测油温叠加得到并联电抗器最终预测油温。通过对某变电站一台220 kV并联电抗器实测数据分析,证明所提模型在单步和多步预测性能上具有精度高、鲁棒性强和误差累积缓慢等优势,能有效反映并联电抗器油温变化趋势,为其监测预警提供参考。

关键词: 并联电抗器; 油温预测; VMDFS; LSTM神经网络

Study on Oil Temperature Prediction of Shunt Reactor Based on Feedback Constrained Variational Mode Decomposition and Long Short-term Memory Neural Network

DING Wentao¹, DAN Shuheng¹, CHEN Haoyu¹, CAI Lichuan²

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200082, China; 2. State Grid Sichuan Electric Power Company, Chengdu 610000, China)

Abstract: Shunt reactor is an important power equipment in the power grid. Accurate estimation of its oil temperature variation trend can provide an important basis for early fault monitoring and warning. An kind of oil temperature prediction model of shunt reactor based on feedback-constrained variational mode decomposition (VMD) and long short-term memory neural network (LSTM) is proposed. Firstly, the signal feedback constrains and weighted sample entropy are used to optimize VMD decomposition number k and penalty factors α to form a VMDFS decomposition method, decompose the original oil temperature sequence of the shunt reactor into multiple sets of smooth sub-sequence so to eliminate the influence of the unsteady information. Then, the LSTM neural network prediction models for each sub-sequence is set up and particle swarm is used to optimize the number of neurons. Finally, the predicted oil temperature of each sub-sequence is superimposed to obtain the final estimated oil temperature of the shunt reactor. It is proved through the analysis of the measurement data of a 220 kV shunt reactor at a substation that the proposed model has such advantages as high accuracy, strong robustness and slow accumulation of errors in single-step and multi-step estimation performance, and can effectively reflect to the oil temperature variation trend of shunt reactor, as well as provide reference for its monitoring and early warning.

Key words: shunt reactor; oil temperature prediction; VMDFS; long short-term memory neural network (LSTM)

收稿日期:2024-09-19; 修回日期:2024-11-13

基金项目:国家自然科学基金项目(50577040)。

Project Supported by National Natural Science Foundation of China(50577040).

0 引言

并联电抗器作为电力系统中重要一次设备之一,电压高,容量大,运行时内部发热,而且有振动、噪声等因素作用,这些都影响并联电抗器的绝缘性能,一旦发生故障将会给电力系统带来重大损失^[1-4]。若能提前预测绕组温度和油温,及时有效评估电抗器内部热状态,发现潜伏性故障,就可以对电抗器的运行情况提早预警。

目前,国内外学者针对并联电抗器进行大量研究,主要集中在电磁场分布^[5]、温度场及绕组温度异常分析^[6-7]、抗震实验^[8]和噪声分析^[9]等方面。现有对电抗器温度研究集中在有限元法和有限体积法的数值仿真模型上,聚焦于并联电抗器内部温度的实时计算,关于并联电抗器绕组温度和油温的预测研究则有限。鉴于电抗器与变压器的相似性,文中借鉴变压器顶层油温预测方法^[10-14],其中数据驱动模型预测精度高于采用集总参数的半物理模型^[10]。电抗器油温预测是一个非线性的时间序列问题^[15],人工神经网络、极限学习机等传统的人工智能算法难以捕捉到时间序列数据的关联性。LSTM^[14]作为循环神经网络的优化变体,对时间序列有更强的处理能力,又引入记忆模块避免梯度消失和爆炸等问题。

油温序列受电抗器自身结构和外部环境等多方面因素影响表现出一定非平稳性和随机性的特征,合适的预处理对提升精度十分必要。预处理方法主要有小波变换(wavelet transform, WT)^[16]、经验模态分解(empirical mode decomposition, EMD)^[17]和变分模态分解(variational mode decomposition, VMD)^[18]。小波变换易受基函数影响,不具备自适应性,可能增加预测模型复杂程度。EMD实现自适应选择,但存在模态混叠和端点效应等缺陷。文[19]中加入白噪声来抑制模态混叠现象,缺乏数学基础且模态分量会多于真实值。VMD^[20]是一种新的自适应非递归信号变分分解方法,能有效避免上述方法的缺点,效率高鲁棒性好。但VMD受参数 k 和 α 影响,文[21]中采用中心频率和相关系数组合确定;为了更好地自适应选择,诸多学者采用优化算法^[22-23]对参数寻优,在故障诊断中广泛应用,但寻优过程时间长,不利于预测模型的建立。

针对上述研究现状,利用并联电抗器油温时序特性预测油温变化趋势,提出一种VMDFS-LSTM的并联电抗器油温预测模型。首先利用信号反馈约束和加权样本熵优化VMD参数,形成VMDFS分解

方法将原序列分解成多组平稳的子序列;然后分别对各子序列构建LSTM神经网络预测模型,并用粒子群优化神经元个数;最后叠加得到预测结果。实例分析,与VMDFS-SVM、VMD-LSTM、EEMD-LSTM、LSTM和SVM相比,文中预测模型精度更高,平稳性更强,误差累积更缓慢,能准确估计并联电抗器油温变化趋势。

1 VMD原理和参数选择

1.1 VMD基本原理

VMD算法是2014年提出的一种非递归准正交的信号变分分解方法,其核心是利用迭代搜索来确定每个分量的中心频率及带宽,有效减少了模态混叠现象。VMD主要包括构造变分问题和求解变分问题,其过程如下。

1.1.1 构造变分问题

1)利用Hilber对于每个模态函数 $u_k(t)$ 变换计算对应的解析信号

$$\left[\delta(t) + \frac{j}{\pi t} \right] \cdot u_k(t) \quad (1)$$

2)预估各模态解析信号中心频率 $e^{-j\omega_k t}$ 进行混叠,将每个模态的频谱调制到基频频带

$$\left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \quad (2)$$

3)计算上述解调信号梯度的平方 L^2 范数,建立约束条件为

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_k u_k = f \end{cases} \quad (3)$$

式(3)中: u_k 为模态分量; ω_k 为模态中心频率; $\delta(t)$ 为冲激函数。

1.1.2 求解变分问题

1)引入拉格朗日乘法算子 $\lambda(t)$ 和二次惩罚因子 α ,将上述约束变分问题转化为非约束变分问题,推广拉格朗日表达式为

$$L[\{\mu_k\}, \{\omega_k\}, \lambda(t)] = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (4)$$

2)采用乘法算子交替方向法解决上述变分问题,不断更新 u_k 、 ω_k 和 λ^n 优化表达式(4)的最佳解

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i^n(\omega) + [\hat{\lambda}^n(\omega)/2]}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (5)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (6)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left[\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right] \quad (7)$$

3)重复步骤2),直至满足精度 ε 时停止迭代,得到 k 个分量

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (8)$$

式(5)–(8)中, $\hat{f}(\omega)$ 、 $\hat{u}(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别代表 $f(t)$ 、 $u(t)$ 、 $\lambda(t)$ 的傅里叶变换。

1.2 VMDFS过程

VMD算法需要预先设定参数 k 和 α ,不同 k 值导致分解程度存在差异,影响预测结果; α 主要干扰分量带宽,也会对分解结果产生一定影响。文中基于反馈VMD算法^[24]加以相关约束条件和加权样本熵综合确定参数。先使用经验惩罚因子^[25]二模态分解;然后根据相关系数将得到的最纯净分量反馈到VMD输入端,输入端将反馈的最纯净分量减去得到剩余信号继续重复该过程至分解完全;最后确定 k 值。

令分解信号 $x(t)$ 与第 n 次分解得到的模态分量为 $u_{n,1}(t)$ 和 $u_{n,2}(t)$ 的相关系数分别为 $\delta_{n,1}$ 和 $\delta_{n,2}$,表达式为

$$\delta_{n,i} = \frac{\left| \sum_{i=1}^N u_{n,i}(t)x(t) \right|}{\sqrt{\sum_{i=1}^N u_{n,i}^2(t) \sum_{i=1}^N x^2(t)}} \quad (9)$$

反馈分解的同时防止分解出无相关性分量,约束第 n 次分解的两个分量与原始数据的最大相似度小于 $n-1$ 次分解分量最小相似度或者其两个分量相似度都低于0.1,即都是无关分量时停止;防止高频复杂度高造成影响,约束 n 次分解模态样本熵(SE)高于0.5时停止。综上判断是否分解完全的约束条件为:

$$\max(\delta_{n,1}, \delta_{n,2}) < \min(\delta_{n-1,1}, \delta_{n-1,2}) \quad (10)$$

$$\max(\delta_{n,1}, \delta_{n,2}) < 0.1 \quad (11)$$

$$\max(SE_{n,1}, SE_{n,2}) > 0.5 \quad (12)$$

引用样本熵衡量序列的复杂度,其过程见文[26];计算 k 个模态分量的样本熵值为 $\{SE(1), SE(2), \dots, SE(k)\}$;分解预测核心在于得到低频高幅的平稳分量,但在分解过程中高频低幅分量的影响不可避免,借鉴加权算法思路^[27-28],令各分解分量占原始分量的均方根幅值占比为权重对 SE 进行加权求和。

$$\omega_k = \frac{A_k}{A} \quad (13)$$

$$WSE = \omega_1 \cdot SE(1) + \omega_2 \cdot SE(2) + \dots + \omega_k \cdot SE(k) \quad (14)$$

式(13)、(14)中: A 为原始序列均方根幅值; A_k 为各子序列均方根幅值; WSE 为加权样本熵。

以 WSE 值最小为目标搜索 k 对应的 α ,最终确定 VMD 参数 $[k, \alpha]$ 。

2 LSTM神经网络

LSTM神经网络是RNN网络的一种特殊类型^[29],与简单的神经网络或RNN相比, LSTM通过引入门控机制,在隐藏层的原始神经元中加入记忆细胞和3个门(输入门、遗忘门和输出门)结构来控制当前的输入、输出和记忆信息;避免梯度爆炸或梯度消失的弊端。其结构见图1。




图1 LSTM神经网络结构

Fig. 1 LSTM neural network structure

工作原理如下:

1)通过遗忘门对 $t-1$ 时刻记忆单元信息筛选

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (15)$$

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (16)$$

2)通过输入门对 t 时刻的新信息更新

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (17)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (18)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (19)$$

3)遗忘门和输入门共同更新记忆,得到 t 时刻记忆,在 t 时刻中新的记忆状态包含 $t-1$ 时刻留下来的

记忆

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (20)$$

4)最后经过输出门作用当前记忆,筛选出下一时刻的隐状态和输出

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (21)$$

$$h_t = o_t \tanh(C_t) \quad (22)$$

式(15)–(22)中: x_t 是 t 时刻输入, 隐层 $t-1$ 时刻; f_t 为遗忘门的值; i_t 为输入门的值; $\tilde{C}_t$ 为候选状态信息; O_t 输出门的值; h_t 为 LSTM 单元记忆输出; C_t 为 t 时刻记忆单元状态值; b_c 为记忆节点偏置; b_f 、 b_i 、 b_o 为 3 个门的偏置项; σ 为 sigmoid 函数; $\odot$ 为逐元素相乘操作。

3 VMDFS-LSTM 预测模型

3.1 预测模型建立

鉴于 VMD 对非平稳序列良好的平稳化处理效果以及 LSTM 神经网络处理时序数据优异的表现, 文中提出一种 VMDFS-LSTM 组合预测模型, 见图 2, 主要分为以下 4 个步骤:

1) 利用 VMDFS 方法将原始油温序列分解成不同频段的模态分量, 若多个高频分量, 则将其重组, 防止多高频波动误差叠加(文中对比模型也采用相似频段组合减少误差)。

2) 归一化后对分解的子序列分别建立 LSTM 神经网络预测模型, 利用粒子群优化神经元个数, 并分别对各子序列进行单步和多步预测。

3) 将预测值反归一化后叠加得到最终预测值。




图2 VMDFS-LSTM组合预测模型流程图

Fig. 2 Flowchart of VMDFS-LSTM combined prediction

4)与实际值对比,通过误差指标来评估各模型预测性能。

3.2 评价指标

采用均方根误差(RMSE)、平均绝对误差(MAE)和平均绝对百分比误差(MAPE)对预测结果综合评估。

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_r - y_p)^2}{N}} \quad (23)$$

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

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|y_r - y_p|}{y_r} \times 100\% \quad (25)$$

式(23)–(25)中: y_r 为真实值; y_p 为预测值; N

为数据集长度。

4 实例分析

4.1 并联电抗器油温特性

文中实验数据采用国网某市 220 kV 并联电抗器 2021 年 3 月 11 日至 4 月 22 日现场油温监测数据作为研究对象, 采样间隔为 5 min。其中, 将前 42 天监测数据作为训练数据, 第 43 天监测数据作为测试数据。监控记录设备一般采集 2 组油温数据, 记为油温 1 和油温 2, 由于篇幅有限且 2 种油温趋势相同数值相近, 故以油温 1 为例详细分析。

日平均油温和油温随时刻的相关性变化见图 3。如图 3 所示, 油温随着时刻的变化而变化, 呈现“单

峰单谷”现象;一天中早晚时刻温度负相关,所以 0 时刻与前 288 时刻的相关性绝对值先降低后少量增加,根据有相关系数的定义^[30],与前时刻始终保持强相关性。




图3 日平均油温和油温随时刻的相关性变化

Fig. 3 Correlation changes of daily average oil temperature and oil temperature with time

4.2 预测模型建立

将油温时间序列 $n=2$ 使用经验 α 二模态分解, 见表 1, $n=2$ 时, 由式 (10) 可知 $\max(\delta_{2,1}, \delta_{2,2}) < \min(\delta_{1,1}, \delta_{1,2})$, 迭代终止。进一步证明当 $n=3$ 时, 所得分量的相似度都低于 0.1, 说明分解的两个分量都是无关分量, 且 $\max(SE_{3,1}, SE_{3,2}) > 0.5$, 出现复杂度较高的分量, 综上分解个数 $k=n+1=3$ 。

表1 二模态分解子序列与原始序列关系

Table 1 Bimodal decomposition of subsequence and original sequence relationship

分解次数	$\delta_{n,1}$	$\delta_{n,2}$	$SE_{n,1}$	$SE_{n,2}$
$n=1$	0.914 3	0.440 5	0.008 5	0.075 3
$n=2$	0.437 9	0.084 2	0.071 8	0.411 9
$n=3$	0.083 6	0.035 7	0.580 5	0.385 7

确定 $k=3$ 对 α 进行搜索, 避免偶然取 [100, 20 000] 大区间, 步长为 200, 以 WSE 最小为目标函数搜索, 见图 4, 影响区间仅在过大或过小时, 当 $\alpha=14\ 300$ 时, $WSE_{\min}=33.503$ 。




图4 惩罚因子对应的 WSE 分布

Fig. 4 WSE distribution corresponding to penalty factor

对原始油温序列进行 VMDFS 分解, 参数设置 [3, 14 300], 逐级分解出 3 组 IMF 分量和一组残差, 见图 5。对分解后的子序列用 LSTM 神经网络预测, 并用粒子群优化神经元个数, 见图 6。预测模型最大迭代次数 250, 训练初始学习率 0.002, 学习率下降期为 100, 学习率下降因子为 0.2, Dropout 层避免训练过拟合。粒子群种群数为 10, 惯性系数最大为 0.8, 最小为 0.4, 最大迭代次数为 30 次, 学习因子 $c_1=c_2=1.5$ 。验证文中 VMDFS-LSTM 组合预测模型的性能, 与其他 5 种模型分别进行 1、4、8、12、24、36 步预测性能对比, 对照思路见表 2。




图5 VMDFS 分解结果

Fig. 5 VMDFS results of oil temperature

4.3 单步预测结果分析

单步预测性能对比见表 3。由表 3 可知, 与 SVM 相比, LSTM 误差指标分别降低了 17.65%、19.93%、23.39%, 表明 LSTM 神经网络对历史监测数据的时序相关性具有更好的信息捕捉能力, 对不同变化规律的子序列具有更好的适用性。在分解处理上, 分解组合模型比单一模型有更好的拟合效果和预测精度, 精确度 $VMDFS > VMD > EEMD$, 证明序列平稳化处理可以更充分地挖掘油温序列特征, 增加序列可预测性。文中 VMDFS-LSTM 模型比其他 5 种模型拥有更高精度。




图6 LSTM神经元个数寻优迭代过程

Fig. 6 Iterative process of optimizing the number of LSTM neurons

表2 预测模型对比方法

Table 2 Predictive model comparison methods

模型	对照模型	目的
LSTM	SVM	验证模型对时序序列的处理能力
文中模型 (VMDFS-LSTM)	LSTM	证明未分解和不同分解方法对预测能力
	EEMD-LSTM	
	VMD-LSTM	对比经验参数VMD和文中优化VMD后对序列预测能力
	VMDFS-SVM	对比相同分解不同模型的预测性能

表3 单步预测性能对比

Table 3 Performance comparison of single-step prediction

模型类型	RMSE	MAE	MAPE/%
VMDFS-LSTM	0.215	0.157	0.279
VMDFS-SVM	0.238	0.182	0.329
VMD-LSTM	0.247	0.188	0.331
EEMD-LSTM	0.260	0.190	0.340
LSTM	0.308	0.241	0.429
SVM	0.374	0.301	0.560

4.4 多步预测结果分析

多步预测性能对评价模型优异更具有实际意义。文中采用预测值迭代方法实现多步预测,如将油温第1步预测结果作为输入带入预测模型得到第2步预测值,再将第2步预测值作为输入得到第3步预测值,以此类推,得到各步预测结果见图7。

多步预测性能对比见表4。由表4可知。

1)通过分解前后误差对比,平稳化处理可以有效减少序列波动带来的预测误差,降低多步预测的误差累积,4种分解组合预测模型的精度均优于单一预测模型。文中VMDFS方法优势更加明显,以36步为例,采用文中分解处理后的LSMT和SVM模型与单一预测模型相比,其RMSE分别降低了63.81%、45.21%;MAE分别降低了59.09%、44.70%;MAPE指标分别降低了57.97%、47.01%。

2)VMD分解比EEMD表现的更加优异,这是因为VMD分解得到的子序列平稳性更高,有利于预测分析。文中优化方法VMDFS比VMD的组合模型精度更高,因为反馈约束限和加权样本熵的优化过程有效抑制了分解时无相关性和高复杂度分量的产生,减少了干扰序列误差对预测精度的影响,见图8。如图8所示,当预测步数相同时,文中分解组合预测模型精度和稳定性都明显高于其他模型,并且随着步数增加,误差累积也相对缓慢,证明文中方法提高了油温序列的可预测性,有效降低了误差累积。

进一步分析文中分解组合预测模型抗误差累积的能力,对比各模型持续迭代预测一天的误差分布。采用箱须对6种模型预测误差绝对值分布情况进行直观展示见图9,从图9可以看出单一预测模型误差急剧累积,误差大且波动性高;EEMD-LSTM模型的预处理有效降低了误差,但箱体依然过长,误差波动大;VMD-LSTM模型具有很好的效果,得到的




图7 并联电抗器油温1单步和多步预测结果

Fig. 7 Single-step and multi-step prediction results of shunt reactor oil temperature 1 temperature

平稳序列抑制了误差波动,但中位线过高,误差集中在较高水平;两种分解组合模型都难以有效抑制误差累积。文中模型对VMD进行优化,又融合两种模型各自优势,不仅很好地降低误差,而且将误差分布集中控制在较小箱体中,具有更好的抗误差累积能力,精度和稳定性。

5 结论

针对并联电抗器油温预测问题,利用并联电抗器油温时序特性预测油温变化趋势。

1)利用信号反馈和加权样本熵优化VMD,形成VMDFS方法对油温序列平稳化处理,降低序列波动

和减少分解过程中干扰序列的产生,并将得到的高频量叠加,防止多个高频率序列波动带来误差累积。

2)对分解的子序列分别建立LSTM神经网络预测模型,进行单步和多步预测,设置3种方式6种模型对比,证明文中分解组合预测具有更好适用性。

3)以国网某市220 kV并联电抗器现场监测数据为例,对所提模型进行仿真实验,通过对各模型误差分析,结果表明VMDFS-LSTM预测模型可靠性和精度更高,误差累积缓慢,能有效反应并联电抗器油温变化趋势,可以为并联电抗器油温预警提供一定参考价值。

4)文中预测模型基于数据驱动技术,数据质量

表4 多步预测性能对比

Table 4 Performance comparison of multi-step prediction

预测步数	评价指标	预测模型					
		VMDFS-LSTM	VMDFS-SVM	VMD-LSTM	EEMD-LSTM	LSTM	SVM
第4步/20 min	RMSE	0.359	0.422	0.361	0.482	0.575	0.797
	MAE	0.268	0.327	0.285	0.394	0.439	0.600
	MAPE/%	0.473	0.595	0.503	0.696	0.784	1.127
第8步/40 min	RMSE	0.456	0.556	0.524	0.775	0.906	1.184
	MAE	0.367	0.436	0.409	0.573	0.671	0.849
	MAPE/%	0.642	0.798	0.721	1.066	1.199	1.606
第12步/1 h	RMSE	0.588	0.771	0.665	0.915	1.219	1.516
	MAE	0.463	0.561	0.534	0.677	0.892	1.084
	MAPE/%	0.818	1.083	0.941	1.258	1.588	2.050
第24步/2 h	RMSE	0.721	1.075	0.929	1.179	1.988	2.160
	MAE	0.605	0.824	0.790	0.840	1.462	1.527
	MAPE/%	1.084	1.497	1.402	1.700	2.577	2.901
第36步/3 h	RMSE	0.908	1.418	1.183	1.459	2.509	2.588
	MAE	0.727	1.044	0.949	1.147	1.777	1.888
	MAPE/%	1.307	1.894	1.691	2.026	3.110	3.574




图8 多步预测误差对比

Fig. 8 Error comparison of multi-step prediction




图9 连续迭代预测1 d误差绝对值分布箱须图

Fig. 9 Contrast of box-whisker plots for continuous iterative prediction of 1 d absolute error distribution

和驱动参数是影响其性能的关键因素,所以高效的数据清洗技术和关键参数的优化方法及适应度函数和约束条件的设计是后续值得优化的重点工作。

参考文献:

- [1] 郑涛,赵彦杰.超/特高压可控并联电抗器关键技术综述[J].电力系统自动化,2014,38(7):127-135.
ZHENG Tao,ZHAO Yanjie. Overview of key techniques of EHV/UHV controllable shunt reactor[J]. Automation of Electric Power Systems,2014,38(7):127-135.
- [2] 戴锋,高爽,宋博,等.基于有限元的干式空心电抗器振动特性研究[J].电力电容器与无功补偿,2020,41(5):104-109.
DAI Feng, GAO Shuang, SONG Bo, et al. Study on vibration characteristic of dry-type air-core reactor based on finite element method[J]. Power Capacitor & Reactive Power Compensation,2020,41(5):104-109.
- [3] 周秀,田天,罗艳,等.一起干式电抗器接地及基础发热问题分析[J].电力电容器与无功补偿,2019,40(6):73-78.
ZHOU Xiu, TIAN Tian, LUO Yan, et al. Analysis on heating problem of dry-type reactor earthing system and foundation[J]. Power Capacitor & Reactive Power Compensation,2019,40(6):73-78.
- [4] 李浩,晏年平,贾志东.干式空心电抗器包封受潮对绝缘的影响研究[J].高压电器,2020,56(5):55-61.
LI Hao, YAN Nianping, JIA Zhidong. Influence of moisture in dry-type air-core reactor package on its insulation[J]. High Voltage Apparatus,2020,56(5):55-61.
- [5] 褚凡武,付颖,王琦,等.不同工况下干式空心滤波电抗器稳态磁场及电磁力分布规律[J].高压电器,2019,55(11):41-47.
CHU Fanwu, FU Ying, WANG Qi, et al. Distributions of steady-state magnetic field and electromagnetic force of a dry-type air-core filter reactor under different operating conditions[J]. High Voltage Apparatus,2019,55(11):41-47.
- [6] 陈隽,戴奇奇,袁召,等.特高压油浸式空心电抗器温度场计算及其影响因素分析[J].高压电器,2020,56(1):87-95.
CHEN Jun, DAI Qiqi, YUAN Zhao, et al. Calculation in temperature field of UHV oil-immersed air-core reactor and analysis of influencing factors[J]. High Voltage Apparatus,2020,56(1):87-95.
- [7] 李卫良,杨洪涛,韩士杰,等.一种抽能型电抗器的抽能绕组匝间保护及动模测试方案[J].电力系统自动化,2019,43(24):165-170.
LI Weiliang, YANG Hongtao, HAN Shijie, et al. An inter-turn protection and dynamic simulation test on pumped windings of energy-extraction reactor[J]. Automation of Electric Power Systems,2019,43(24):165-170.
- [8] 张猛,王红雨,刘成柱,等.110 kV干式空心并联电抗器地震模拟震动台试验[J].高压电器,2022,58(3):186-193.
ZHANG Meng, WANG Hongyu, LIU Chengzhu, et al. Test of seismic simulation bench for 110 kV dry-type air-core shunt reactor[J]. High Voltage Apparatus,2022,58(3):186-193.
- [9] 吴书煜,马宏忠,姜宁,等.基于多物理场耦合的特高压并联电抗器振动噪声仿真分析与实验研究[J].电力自动化设备,2020,40(3):122-127.
WU Shuyu, MA Hongzhong, JIANG Ning, et al. Simulation analysis and experimental research on vibration and noise of UHV shunt reactor based on multi physical field coupling[J]. Electric Power Automation Equipment,2020,40(3):122-127.
- [10] 亓孝武,李可军,于小晏,等.基于核极限学习机和Bootstrap方法的变压器顶层油温区间预测[J].中国电机工程学报,2017,37(19):5821-5828.
QI Xiaowu, LI Kejun, YU Xiaoyan, et al. Transformer top oil temperature interval prediction based on kernel extreme learning machine and Bootstrap method[J]. Proceedings of the CSEE,2017,37(19):5821-5828.
- [11] 李诗勇,薛静,吴冕之,等.基于粒子群优化的改进加权支持向量回归的变压器顶层油温预测[J].高压电器,2021,57(12):103-109.
LI Shiyong, XUE Jing, WU Mianzhi, et al. Prediction of transformer top-oil temperature with the improved weighted support vector regression based on particle swarm optimization[J]. High Voltage Apparatus,2021,57(12):103-109.
- [12] 谭风雷,陈昊,何嘉弘.基于K-means聚类方法和相似时段的特高压并联电抗器油温预测[J].电力自动化设备,2021,41(6):213-219.

- TAN Fenglei, CHEN Hao, HE Jiahong. Oil temperature forecasting of UHV shunt reactor based on K - means clustering method and similar period[J]. Electric Power Automation Equipment, 2021, 41(6): 213-219.
- [13] 谭风雷, 陈昊, 何嘉弘. 基于最佳分段和改进半物理模型的特高压并联电抗器顶层油温预测[J]. 电网技术, 2021, 45(8): 3314-3323.
- TAN Fenglei, CHEN Hao, HE Jiahong. Prediction of UHV shunt reactor top oil temperature based on optimal segmentation and improved semi-physical model[J]. Power System Technology, 2021, 45(8): 3314-3323.
- [14] SHU Xiangbo, ZHANG Liyan, SUN Yunlian, et al. Host-parasite: Graph LSTM - in - LSTM for group activity recognition[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(2): 663-674.
- [15] WANG Kai, ZHANG Hongru, WANG Xiaoyi. Prediction method of transformer top oil temperature based on VMD and GRU neural network[C]//2020 IEEE International Conference on High Voltage Engineering and Application (ICHVE). [S.l.]: IEEE, 2020: 1-4.
- [16] 张鹏, 齐波, 张若愚, 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.
- ZHANG Peng, QI Bo, ZHANG Ruoyu, et al. Dissolved gas prediction in transformer oil based on empirical wavelet transform and gradient boosting radial basis[J]. Power System Technology, 2021, 45(9): 3745-3754.
- [17] LIANG Yi, NIU Dongxiao, HONG W C. Short term load forecasting based on feature extraction and improved general regression neural network model[J]. Energy, 2019 (166): 653-663.
- [18] 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.
- [19] DING Can, ZHOU Yiyuan, DING Qingchang, et al. Integrated carbon-capture-based low-carbon economic dispatch of power systems based on EEMD-LSTM-SVR wind power forecasting[J]. Energies, 2022, 5(15): 644-650.
- [20] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [21] 王粟, 江鑫, 曾亮, 等. 基于VMD-DESN-MSGP模型的超短期光伏功率预测[J]. 电网技术, 2020, 44(3): 917-925.
- WANG Su, JIANG Xin, ZENG Liang, et al. Ultra-short-term photovoltaic power prediction based on VMD-DESN-MSGP model[J]. Power System Technology, 2020, 44(3): 917-925.
- [22] 何勇, 王红, 谷穗. 一种基于遗传算法的VMD参数优化轴承故障诊断新方法[J]. 振动与冲击, 2021, 40(6): 184-189.
- HE Yong, WANG Hong, GU Sui. New fault diagnosis approach for bearings based on parameter optimized VMD and genetic algorithm[J]. Journal of Vibration and Shock, 2021, 40(6): 184-189.
- [23] WANG Lishu, LIU Yanhui, LI Tianshu, et al. Short-term PV power prediction based on optimized VMD and LSTM[J]. IEEE Access, 2020(8): 165849-165862.
- [24] 赵知劲, 黄艳波, 强芳芳, 等. 基于反馈变分模式分解的单通道盲源分离算法[J]. 振动与冲击, 2019, 38(13): 268-273.
- ZHAO Zhijin, HUANG Yanbo, QIANG Fangfang, et al. Single channel blind source separation algorithm based on feedback variational mode decomposition[J]. Journal of Vibration and Shock, 2019, 38(13): 268-273.
- [25] 向玲, 李京蓄, 王朋鹤, 等. 基于VMD-FIG和参数优化GRU的风速多步区间预测[J]. 太阳能学报, 2021, 42(10): 237-242.
- XIANG Ling, LI Jingxu, WANG Penghe, et al. Wind speed multistep interval forecasting based on VMD-FIG and parameter-optimized GRU[J]. Acta Energeticae Solaris Sinica, 2021, 42(10): 237-242.
- [26] 蒋锋, 乔雅倩. 基于样本熵和优化极限学习机的PM_(2.5)浓度预测[J]. 统计与决策, 2021, 37(3): 166-171.
- JIANG Feng, QIAO Yaqian. PM_(2.5) concentration prediction based on sample entropy and optimized extreme learning machine[J]. Statistics and Decision, 2021, 37(3): 166-171.
- [27] FADLALLAH B, CHEN B, KEIL A, et al. Weighted-permutation entropy: A complexity measure for time series incorporating amplitude information[J]. Physical Review E, 2013, 87(2): 022911.
- [28] 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.
- [29] 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

- University, 2021.
- [29] 黄 石, 冯蒙霜. 计及非线性的电力系统状态估计算法研究[J]. 陕西电力, 2017, 45(1): 51-56.
HUANG Shi, FENG Mengshuang. Research on power system state estimation algorithm considering nonlinearity [J]. Shaanxi Electric Power, 2017, 45(1): 51-56.
- [30] 李世龙, 王天辉, 马立元, 等. 大型复杂结构损伤识别两步法研究[J]. 中国机械工程, 2012, 23(9): 1051-1056.
LI Shilong, WANG Tianhui, MA Liyuan, et al. Study on two-step damage detection methods of large and complex structures[J]. China Mechanical Engineering, 2012, 23(9): 1051-1056.
- [31] 李海奎, 王雪峰. 基于符号运算和信赖域方法的非线性最小二乘法[J]. 计算机应用, 2004, 24(7): 22-24.
LI Haikui, WANG Xuefeng. Nonlinear least square algorithm based on symbol calculation and trust region method[J]. Journal of Computer Applications, 2004, 24(7): 22-24.
- [32] 肖 阳, 康忠健, 马晓炜. 基于最小二乘法引导的信赖域算法在电力系统动态负荷参数辨识中的应用[J]. 电网与清洁能源, 2014, 30(4): 13-17.
XIAO Yang, KANG Zhongjian, MA Xiaowei. Application of the trust region algorithm based on the method of least squares power guided in the identification of system dynamic load parameter[J]. Advances of Power System & Hydroelectric Engineering, 2014, 30(4): 13-17.
- [33] 张晓飞. 解张量分解问题的信赖域交替最小二乘法[D]. 南京: 南京师范大学, 2014.
ZHANG Xiaofei. Trust - region alternating least squares algorithm for tensor decomposition problems[D]. Nanjing: Nanjing Normal University, 2014.
- 刘开禹(1994—), 男, 助理研发工程师, 硕士, 主要研究方向为中压元器件智能化(E-mail: kail-kaiyu. liu@cn. abb. com)。
- 杨 光(1983—), 男, 高级研发工程师, 硕士, 主要研究方向为中压元器件智能化(通信作者)(E-mail: guang. yang@cn. abb. com)。
-
- (上接第 92 页)
- term memory neural networks[J]. Proceedings of the CSEE, 2019, 39(13): 3998-4007.
- [30] 胡 琛, 张 竹, 焦 洋, 等. 基于随机矩阵理论的电子式互感器误差状态相关性分析方法[J]. 电力自动化设备, 2018, 38(9): 45-53.
HU Chen, ZHANG Zhu, JIAO Yang, et al. Error state correlation analysis based on random matrix theory for electronic transformer[J]. Electric Power Automation Equipment, 2018, 38(9): 45-53.
- 丁文涛(1997—), 男, 硕士研究生, 主要研究方向为电气设备在线监测及故障诊断(通信作者)(E-mail: 1085606464@qq. com)。
- 淡淑恒(1969—), 女, 教授, 博士, 主要研究方向为电气设备绝缘在线监测与故障诊断、新型电气设备的机理研究及研制(E-mail: danshuheng@shiep. edu. cn)。