

DOI:10.20033/j.1003-7241.(2026)03-0073-06

基于 LSTM 算法的工业循环冷却水系统运行状态预测方法

葛智泉¹, 谢宙桦², 邢小林¹, 章 颢¹, 贾 迪¹

(1. 安徽淮南平圩发电有限责任公司, 安徽 淮南 232089; 2. 西安热工研究院有限公司, 陕西 西安 710054)

摘要: 为提高工业循环冷却水系统运行状态预测的精度与可靠性, 提出一种基于 LSTM 算法的工业循环冷却水系统运行状态预测方法。针对时间序列的非平稳特性, 采用花授粉算法对变分模态分解的关键参数进行自适应优化, 构建 FPA-VMD 模型, 以更有效地分解原始数据、提取本征模态分量。为解决 LSTM 网络超参数选择困难的问题, 利用蝗虫优化算法对其隐含层节点数、学习率等关键参数进行自动寻优, 建立 GOA-LSTM 预测子模型。将 FPA-VMD 算法与 GOA-LSTM 模型相结合, 搭建一个基于 FPA-VMD+GOA-LSTM 的预测模型, 通过将各子序列的预测结果叠加重构, 得到系统的最终运行状态预测值。实验结果表明, 模型的 MAE、RMSE 和 MAPE 预测误差分别取值为 0.047、0.035 和 0.381%, 明显低于传统的 GOA-RNN 模型、XGBoost-LSTM 模型和 VMD-LSTM 模型, 且模型的预测结果与真实结果的拟合度较高。说明模型的预测精度较高, 可实现工业循环冷却水系统运行状态准确预测。

关键词: LSTM 网络; 冷却水系统; 蝗虫优化算法; 变分模态分解; 运行状态预测

中图分类号: TP18; TP392

文献标志码: A

文章编号: 1003-7241(2026)03-0073-06

Operation method of industrial circulating cooling water system based on LSTM algorithm

GE Zhiqian¹, XIE Zhouhua², XING Xiaolin¹, ZHANG Hao¹, JIA Di¹

(1. Anhui Huainan Pingwei Power Generation Co., Ltd., Huainan 232089, Anhui, China;

2. Xi'an Thermal Engineering Research Institute Co., Ltd., Xi'an 710054, Shaanxi, China)

Abstract: To enhance the accuracy and reliability of predicting the operating state of industrial circulating cooling water systems, a prediction method based on the long short-term memory (LSTM) algorithm is proposed. Considering the non-stationary characteristics of time series data, the flower pollination algorithm (FPA) is employed to adaptively optimize the key parameters of variational mode decomposition (VMD), thereby constructing an FPA-VMD model. This approach enables more effective decomposition of the original data and extraction of intrinsic mode components. To address the challenge of selecting hyperparameters for the LSTM network, the grasshopper optimization algorithm (GOA) is utilized to automatically optimize key parameters such as the number of hidden layer nodes and the learning rate, establishing a GOA-LSTM prediction sub-model. By integrating the FPA-VMD algorithm with the GOA-LSTM model, a prediction model based on FPA-VMD+GOA-LSTM is constructed. The final prediction value of the system's operating state is obtained by superimposing and reconstructing the prediction results of each subsequence. Experimental results demonstrate that the prediction errors of this model, measured by mean absolute error (MAE), root mean square error (RMSE), and mean absolute percentage error (MAPE), are 0.047, 0.035, and 0.381%, respectively, significantly lower than those of traditional models such as GOA-recurrent neural network (GOA-RNN), XGBoost-LSTM, and VMD-LSTM. Moreover, the predicted results of this model exhibit a high degree of fit with the actual results, indicating that this model offers high prediction accuracy and can achieve accurate prediction of the operating state of industrial circulating cooling water systems.

Keywords: LSTM network; cooling water system; locust optimization algorithm; variational mode decomposition; operation state prediction

近年来,随着我国工业水平的不断提升,大型工业生产装置和设备升级逐渐趋于智能化和科技化方向发展。其中,工业循环冷却水系统是工业生产装置和设备中的关键环节,对其运行参数进行提前预测感知和判断,可为设备零部件更换和维修提供有效的数据支撑。针对此问题,刘钢等^[1]提出了以深度卷积神经网络作为基础预测模型,

并将其应用到工业循环冷却水系统中,实现了系统运行状态预测,但预测精度不高;李争等^[2]提出了一种基于相似日聚类和 PCC-VMD-SSA-KELM 模型相结合的预测方法,通过其提升了短期光伏功率的预测准确率,但预测效率不高,缺乏实时性;蔡昌春等^[3]提出基于深度残差网络,引入一种改进的 VMD-MCKD 算法,通过此融合算法提升了风

收稿日期:2024-07-23;录用日期:2024-08-11

基金项目:国家电投集团科技项目(1005FWCG2023100026)

作者简介:葛智泉(1976—),男,工程师,研究方向:电厂化学运行。

引用本文:葛智泉,谢宙桦,邢小林,等. 基于 LSTM 算法的工业循环冷却水系统运行状态预测方法[J]. 自动化技术与应用, 2026,45(3):73-78.

(GE Zhiqian, XIE Zhouhua, XING Xiaolin, et al. Operation method of industrial circulating cooling water system based on LSTM algorithm[J].

Techniques of Automation and Applications, 2026,45(3):73-78.)

机齿轮箱的故障诊断效率。以上研究虽然取得了一定的应用效果,但对于工业循环冷却水系统的运行状态预测研究较少,且预测精度普遍不高。基于此,结合以上研究经验,提出一种基于 LSTM 网络的预测方法,并在此方法基础上引入 GOA 算法和 VMD 算法。以搭建相应的预测模型,通过此模型实现工业循环冷却水系统运行状态准确预测,具有实际应用意义和参考价值。

1 LSTM 算法

长短期记忆神经网络(long short-term memory, LSTM)是深度学习中的经典网络,其通过在循环神经网络(recurrent neural network, RNN)的基础上引入门控机制进化得到。LSTM 网络通过门控机制对数据前后信息进行有效整合,具备较强的复杂数据拟合能力,在时间序列预测领域得到广泛应用。该网络门控机制分为 3 个部分,分别为输入门、遗忘门和输出门。LSTM 网络结构如图 1 所示^[4]。




图 1 LSTM 网络结构

Fig. 1 Structure of LSTM network

图 1 中, x_t 表示 t 时刻的输入序列; h_t 和 h_{t-1} 分别表示神经元在 t 时刻和 $t-1$ 时刻的输出; C_t 、 C_{t-1} 和 C_{t-1} 分别表示为神经元状态、 t 时刻和 $t-1$ 时刻的神经元状态; σ 表示 Sigmoid 型激活函数,通过该函数对输入数据进行处理后,即可输出 0~1 内的值^[5]。

2 基于 FPA-VMD+GOA-LSTM 的预测模型

2.1 GOA 算法优化 LSTM

2.1.1 GOA 算法原理

蝗虫优化算法(grasshopper optimization algorithm, GOA)算法由蝗虫觅食过程模拟得到,属于一种新型的群智能优化算法。GOA 算法通过蝗虫快速移动和缓慢围绕食物移动实现探索和开发。粒子运动方向由群体最优位置 \hat{T}_d 和其他粒子位置得到,以形成群体寻优的正反馈机制。粒子移动行为的数学表达式

$$X_i = S_i + G_i + A_i \quad (1)$$

式中, X_i 和 S_i 分别表示第 i 个粒子的位置和所受的种群影响。其中, $i = 1, 2, \dots, n$, n 表示粒子总数; G_i 和 A_i 分别表示重力作用和风场平流影响。其中, S_i 、 G_i 和 A_i 的具体表达式^[6] 为

$$S_i = \sum_{j=1, j \neq i}^N s(d_{ij}) \hat{d}_{ij} = \sum_{j=1, j \neq i}^N s(|x_i - x_j|) \frac{x_i - x_j}{d_{ij}} \quad (2)$$

$$s(r) = fe^{\frac{-r}{l}} - e^{-r} \quad (3)$$

$$G_i = -ge_g \quad (4)$$

$$A_i = ue_w \quad (5)$$

式中, N 为粒子数量; $d_{ij} = |x_i - x_j|$ 为第 i 个粒子和第 j 个粒子间的距离; $\hat{d}_{ij} = |x_i - x_j|$ 表示单位距离。 $s(r)$ 为蝗虫间的吸引或排斥行为; f 、 l 均为常数,多取值为 0.6 和 1.8。 g 和 u 分别表示为引力常数和风力漂移常数; \hat{e}_g 和 \hat{e}_w 分别表示为单位重力和单位风向。

将上式代入式(1)进行进一步改进后,可得到粒子位置最终更新公式可表示为

$$X_i^d = c \left(\sum_{j=1, j \neq i}^N c \frac{ub_d - lb_d}{2} s(|x_i - x_j|) \frac{x_i - x_j}{d_{ij}} \right) + \hat{T}_d \quad (6)$$

式中, X_i^d 表示第 i 个粒子的当前位置; ub_d 、 lb_d 分别表示第 d 维粒子搜索空间的上界和下界; c 为缩小蝗虫舒适区、排斥区和吸引区的递减系数,具体表达式为

$$c = c_{\max} - \frac{c_{\max} - c_{\min}}{L} \quad (7)$$

式中, L 表示最大迭代次数; c_{\max} 和 c_{\min} 分别为系数 c 的最大值和最小值,通常取值为 1 和 1×10^{-6} ^[7]。GOA 算法通过系数 c 对算法的全局搜索能力和局部开发能力进行平衡处理,以实现全局、局部搜索。GOA 算法流程如图 2 所示。

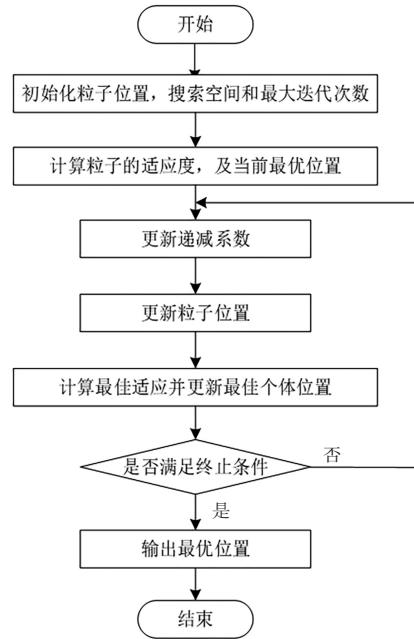


图 2 GOA 算法流程

Fig. 2 Flowchart of GOA algorithm

GOA 算法基本流程为:首先对粒子参数进行初始化处理;然后计算粒子当前适应度在和最优位置;之后对递减系数和粒子位置进行更新^[8],并求出粒子最佳适应度值,以实现最佳个体位置更新;最后判断该值是否为当前群体的最优位置 \hat{T}_d ,若是则可输出最优位置并结束算法;反之则重新进行递减系数、粒子位置更新,直至达到算法终止要求。

2.1.2 GOA-LSTM 预测模型

为实现工业循环冷却水系统运行状态预测,提出以

LSTM神经网络作为基础模型。在该模型中输入工业循环冷却水系统的工作运行数据,输出为系统运行状态预测结果。其中,LSTM在预测过程中可能出现超参数选择困难的问题,使得其最终预测效果不佳。而GOA算法则可有效解决LSTM网络存在的问题,通过其对LSTM节点、学习率等超参数进行优化后,即可基于GOA-LSTM的预测模型,模型结构如图3所示。

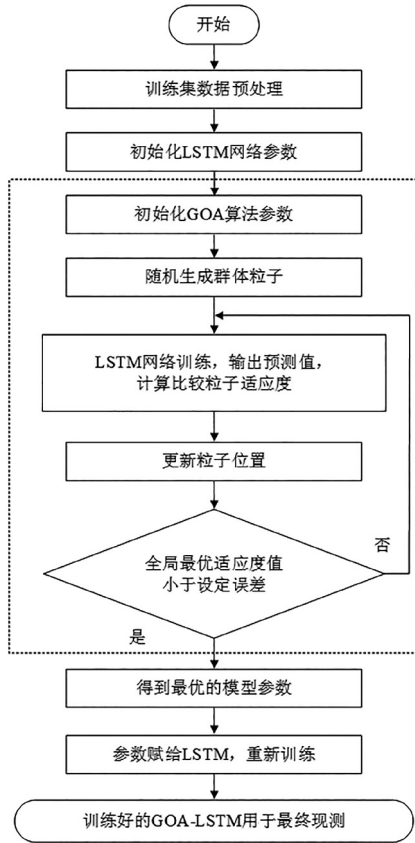


图3 GOA-LSTM的预测模型

Fig. 3 Prediction model based on GOA-LSTM

由图3可知,基于GOA-LSTM的工业循环冷却水系统运行状态预测模型工作流程主要分为5步,具体表现:

- 1) 在模型中输入工业循环冷却水系统运行数据,并对训练集进行预处理^[9]。
- 2) 对LSTM网络参数、GOA算法参数进行初始化处理。
- 3) 随机生成群体粒子并将其输入至LSTM网络中进行训练,得到预测值以求出粒子适应度值。
- 4) 对粒子位置进行更新,以获得全局最优适应度值。
- 5) 对得到的全局最优适应度值进行评估,判断其是否低于设定阈值。若是,则可得到最优模型参数,并将参数输入至LSTM网络中进行重新训练,利用最终训练完成的GOA-LSTM模型实现最终预测。反之则重新回到第3)步进行网络训练和计算。

2.2 FPA算法优化VMD

2.2.1 VMD算法原理

变分模态分解算法(variational mode decomposition, VMD)的目标为分解原始时间序列信号,以获得多个具备不同带宽约束且以中心频率波动为本征模态函数

(intrinsic mode function, IMF)^[10]。此方法可实现IMF分量的迭代更新,实现重构值与真实值的有效拟合。VMD算法通过变分问题构造和求解进行实现。

1) 构造变分问题。即确定目标函数和约束条件,分别将IMF估计带宽之和控制到最低值和IMF之和控制在原始信号范围内。具体表达式为

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}$$

$$\text{s. t. } \sum_{k=1}^K u_k(t) = f(t) \quad (8)$$

式中, u_k 和 ω_k 分别表示本征模态分量和 u_k 的中心频率; K 表示分解个数; $\delta(t)$ 和 $f(t)$ 分别表示狄拉克函数和原始信号^[11]。

2) 变分问题转换。以二次惩罚因子 α 和拉格朗日乘数 $\lambda(t)$ 作为输入,分别代入式(8)中将VMD分解问题进行转换,即将带约束变分问题转换为非约束问题。具体表达式为

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

$$+ \left\| f(t) - \sum_k u_k(t) \right\|_2^2$$

$$+ \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (9)$$

3) 求解变分问题。通过交替方向乘子法进行非约束问题求解,由此得到 u_k 和 ω_k

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (10)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (11)$$

式中, $\hat{f}(\omega)$ 、 $\hat{\lambda}(\omega)$ 和 $\hat{u}_k(\omega)$ 分别表示 $f(t)$ 、 $\lambda(t)$ 和 $u(t)$ 的傅里叶变换^[12]。

2.2.2 FPA算法优化VMD

花授粉算法(flower pollination algorithm, FPA)是智能优化算法中的经典算法,其通过对花朵授粉方式进行模拟得到,该算法可分为自花授粉和异花授粉,具备收敛速度快,寻优精度高的优点。随机生成一个种群规模为 Z , 第 i 个花粉的输入结果表示为

$$X_i = (x_{i1}, x_{i2}, \dots, x_{ij}, \dots, x_{iD})$$

其中, x_{ij} 为第 i 个花粉 x_i 第 j 维的位置, D 为寻优维度。每个花粉可根据转换概率 p 选择对应的授粉方式。

自花授粉和异花授粉的更新公式为

$$X_i^{t+1} = X_i^t + \gamma L(X_j^t - g^*) \quad (12)$$

$$X_i^{t+1} = X_i^t + \varepsilon(X_j^t - X_i^t) \quad (13)$$

式中, X_i^t 和 X_i^{t+1} 分别为 t 时刻和 $t+1$ 时刻更新的花朵个体 i ; X_j^t 为 t 时刻同一种群的另一花朵个体 j ; g^* 表示全局最优个体; γ 和 ε 分别表示控制步长的缩放因子和控制参数。

为实现VMD算法的有效分解,提出结合FPA优点,

采用 FPA 算法对 VMD 算法进行优化,并将 FPA 算法寻优维度设置为 2,由此实现 VMD 参数选择问题转化为约束优化问题。具体表达式为

$$\min_{k,\alpha} \frac{\sum_{i=1}^T |f(t) - f'(t)|}{T}, \text{ s. t } \begin{cases} K \in \{2,3,\dots,34\} \\ \alpha \in [100,10^5] \end{cases} \quad (14)$$

基于式(14)进行问题转换求解后,可有效降低 VMD 分解的信息损失率和随机性,从而实现自适应的分解参数确定,分解效果显著提升。

FPA 算法优化 VMD 分解的具体流程为

- 1) 在 VMD 算法中输入负荷序列,并进行算法参数初始化设置。
- 2) 对 FPA 算法寻优维度进行设置。
- 3) 随机生成初始种群,并计算出每个个体的适应度值。
- 4) 生成授粉强度,并将此参数与转换概率进行对比,以实现异花授粉和自花授粉生成新个体^[13]。
- 5) 基于新生成个体进行归类和替换处理,以生成新种群。
- 6) 求出新种群对应适应度值,并基于此值实现全局最优个体和适应度值更新。
- 7) 对当前迭代次数进行评估,判断其是否满足迭代要求。若满足,则可输出最优求解结果;否则重新进行个体适应度计算,直至取得最优解。

2.3 基于 FPA-VMD+GOA-LSTM 的预测模型

为实现工业循环冷却水系统运行状态的准确预测,提出结合 GOA-LSTM 网络和 FPA-VMD 分解算法,搭建一个基于 FPA-VMD+GOA-LSTM 的预测模型。通过该模型实现时间序列数据建模和处理。模型结构如图 4 所示。

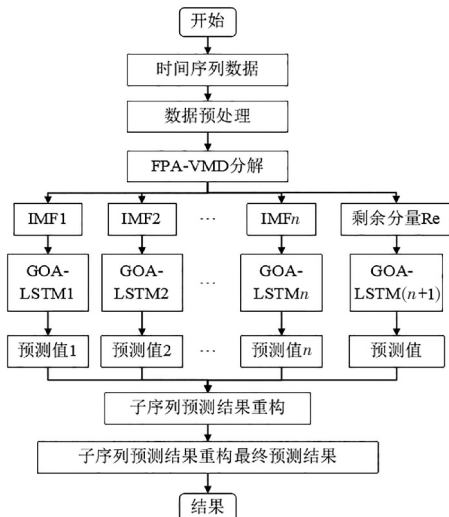


图 4 基于 FPA-VMD+GOA-LSTM 的预测模型

Fig. 4 Prediction model based on FPA-VMD+GOA-LSTM

由图 4 可知,输入原始数据后,即可对数据进行预处理操作;然后通过提出的 FPA-VMD 算法进行数据分解,以获得对应 IMF 分量和剩余分量;之后将分解后的数据集进行划分,得到训练集和测试集,并基于子分量构建对应的 GOA-LSTM 预测模型;然后将训练集输入该模型中

进行训练后,利用滑动窗口法进行滚动预测,以获得各子分量的预测结果^[14];最后将预测结果进行叠加和重构处理,从而得到最终预测结果。对最终预测结果进行评估,以实现工业循环冷却水系统运行状态的准确预测。

3 实验结果与分析

3.1 实验环境

为取得更好的实验效果,采用 Windows 10 软件系统进行实验平台搭建,以 Python3.7 语言和 TensorFlow 深度学习框架搭建 LSTM 神经网络。其中,硬件系统采用 Intel Corei5 -9600KF 3.70 GHz CPU 处理器和 NVIDIA Ge Force GTX 1050Ti 显卡。

3.2 实验数据

实验数据来源于某工业循环冷却水系统的 30 d 内的低温淡水出口温度数据,该数据集采样时间间隔为 0.5 h,共计 3 675 条。为提升网络训练和测试效果,实验基于 8 : 2 占比进行数据集划分,得到训练集和测试集。为提升算法验证效果,实验将对模型参数进行设置,其中,LSTM 网络的输入层节点设置为 8,全连接层输出节点为 2,学习率和批处理大小分别设置为 0.001 和 56,滑动窗口宽度为 9,优化器为 Adam 优化器。

3.3 评价指标

为更加客观地对模型预测精度进行评估,实验以平均绝对百分比误差 (MAPE)、均方根误差 (RMSE) 和平均绝对误差 (MAE) 作为评价标准,3 个指标具体表达式分别为

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y'_i|}{y_i} \times 100\% \quad (15)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (16)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (17)$$

式中, y_i 和 y'_i 分别为第 i 时刻的真实值和预测值, n 为样本总数。通常认为,3 个指标取值越小,模型预测精度越高,预测效果越好^[15]。

3.4 实验结果

3.4.1 VMD 分解参数选择

为提升 VMD 算法的分解效果,提高模型预测精度,提出采用中心频率法和相关系数法对 VMD 算法的关键参数进行选取。相关系数可计算出模态分量与原始数据间的相关性,相关系数取值越小,证明相关程度越低。VMD 算法关键参数为分解个数 K 和惩罚因子 α 。实验将 K 分别取值为 3、5、7、9; α 分别取值为 300、600、1 200、2 400、4 800。利用 VMD 算法进行数据分解后,可得到对应分解相关系数如表 1 所示。

由表 1 对比结果可知,当 $K=5$ 时,剩余分量的相关系数取值为 0.041,明显低于本组模态相关系数最小值 0.136,说明 $K=5$ 时的分解效果更好,与原始数据的相关系数更接近。而 K 取 3、7、9 时的剩余分量相关系数与原

始数据间的差距较大,说明分解效果不佳。因此,选择 $K = 5$ 作为最佳分解个数。

表 1 不同 K 值下各分量与原始数据的相关系数

Tab. 1 Correlation coefficients between each component and the original data under different K values

相关系数 K	IMF1	IMF2	IMF3	剩余分量
3	0.304	0.961	0.145	0.473
5	0.212	0.878	0.252	0.189
7	0.136	0.695	0.419	0.041
9	0.584	0.477	0.378	0.025

实验将 α 分别取值为 300、600、1 200、2 400、4 800, K 取值为 5,其他参数不变,分别输入至 VMD 算法中进行时间序列数据分解实验,可得到不同惩罚因子 α 取值时的运行时间如表 2 所示。

表 2 不同惩罚因子 α 下 VMD 算法运行时间

Tab. 2 Running time of VMD algorithm under different penalty factors α

惩罚因子 α	VMD 算法运行时间/s
300	4.87
600	3.62
1 200	1.44
2 400	2.95
4 800	1.71

由表 2 对比结果可知, α 取值为 1 200 时, VMD 算法的运行时间最短,取值为 1.44 s。说明 $\alpha = 1 200$ 可实现 VMD 算法的快速分解,分解效果和收敛速度更好。因此,将 α 取值为 1 200。

3.4.2 FPA-VMD 数据分解效果验证

为验证优化后的 FPA-VMD 算法对工业循环冷却水系统的数据分解效果,实验将 K 取值为 5, α 取值为 1 200,实验将工业循环冷却水系统原始数据分别输入至本算法与未优化前的 VMD 算法中进行数据分解预测,得到两种算法的分解预测误差对比如表 3 所示。

表 3 改进前后 VMD 算法分解预测误差

Tab. 3 Decomposition and prediction errors of VMD algorithm before and after improvement

算法	MAE	RMSE	MAPE/%
VMD	3.961	8.542	31.79
FPA-VMD	1.504	1.967	8.25

由表 3 对比结果可知, FPA-VMD 分解的 MAE 误差、RMSE 误差和 MAPE 误差分别取值为 1.504、1.967 和 8.25%,明显低于 VMD 分解算法。证明 FPA-VMD 分解后的预测误差明显降低。说明采用 FPA-VMD 分解算法能够有效提取工业循环冷却水序列的非线性特征。

为进一步看出 FPA-VMD 分解算法预测结果与真实结果的对比,实验将选取 80 个样本点(每 20 min 一个采样点)进行预测分析,具体如图 5 所示。

由图 5 可视化结果可知,提出的 FPA-VMD 分解算法的预测结果与真实值更为接近,提出的 FPA-VMD 算法进行数

据分解后的预测误差明显低于 VMD 算法。且本算法分解曲线较为稳定,无明显预测波动误差,说明采用本算法能够实现样本数据平稳化处理,从而增强了预测效果。

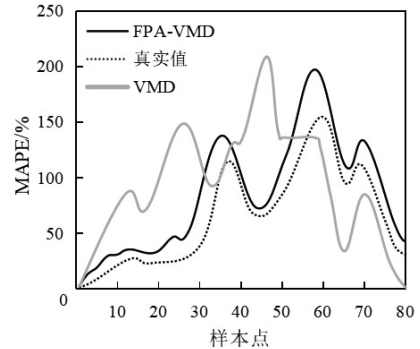


图 5 优化前后 VMD 分解与真实值对比

Fig. 5 Comparison between VMD decomposition before and after optimization and the true value

3.4.3 模型预测实验

为验证本模型的参数预测效果,实验将对 GOA-LSTM 预测模型进行实验测试。GOA 种群规模和搜索维度分别设置为 18 和 5,粒子位置和最大迭代次数分别设置为 $X(A, B, C, D)$ 和 200。可得到该模型的测试结果如表 4 所示。

表 4 各分量预测模型的寻优结果

Tab. 4 Optimization results of prediction models for each component

分量	A	B	C	D
IMF1	7	9	0.031	14
IMF2	9	11	0.042	8
IMF3	4	13	0.075	11
剩余分量	8	14	0.006	9

将以上预测结果进行叠加重构后,得到最终预测结果如图 6 所示。




图 6 本模型最终预测结果

Fig. 6 Final prediction results of the proposed model

由图 6 可知,本模型预测值与真实值拟合曲线十分接近,说明两者预测误差较小,预测精度较高。

基于以上预测结果,分解对各分量和最终预测结果的误差值进行计算,可得到各子序列预测误差如表 5 所示。

由表 5 可知,本模型预测的 MAE、RMSE 和 MAPE 分别取值为 0.047、0.035 和 0.381%,各误差指标均在较低范围内。由此说明,采用本模型进行预测后,预测误差明显降低,预测精度显著提升。

表5 各子序列的预测误差

Tab. 5 Prediction errors of each subsequence

算法	MAE	RMSE	MAPE/%
IMF1	0.034	0.045	5.175
IMF2	0.028	0.369	19.963
IMF3	0.019	0.288	35.417
剩余分量	0.056	0.041	56.269
重构结果	0.047	0.035	0.381

为进一步验证本模型性能是否优越,实验将测试集分别输入至本模型、GOA-RNN模型、XGBoost-LSTM模型和VMD-LSTM4种模型中进行工业循环冷却水系统运行状态预测,得到4种模型的预测结果如图7所示。

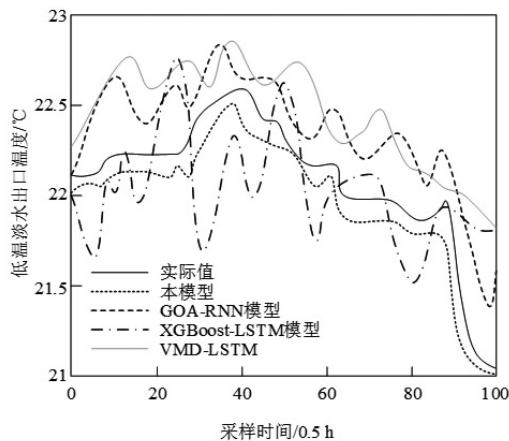


图7 4种模型预测结果

Fig. 7 Prediction results of four models

基于图7预测曲线,可统计出4种模型的预测误差对比如表6所示。

表6 不同模型预测误差对比

Tab. 6 Comparison of prediction errors of different models

算法	MAE	RMSE	MAPE/%
GOA-RNN	0.245	0.337	0.513
XGBoost-LSTM	0.796	0.482	0.649
VMD-LSTM	0.821	0.570	0.458
本模型	0.047	0.035	0.381

由表6可知,本模型的预测误差明显低于前三种模型,预测曲线波动性较小,整体性误差较低。说明本模型的预测精度最高,模型性能更为优越。

4 结论

综上所述,提出的基于FPA-VMD+GOA-LSTM的

预测模型具备可行性和有效性,此模型能够满足工业循环冷却水系统运行状态准确预测,预测精度显著提升。实验发现,采用GOA算法优化LSTM网络并搭建预测模型后,该模型的收敛速度显著提升,可实现LSTM网络超参数有效选取。之后采用FPA算法对VMD分解算法进行改进后,VMD分解效果显著提升。最后在GOA-LSTM预测模型中加入FPA-VMD分解算法后,很大程度上提升了LSTM预测模型的预测精度。将工业循环冷却水系统低温淡水出口温度数据输入至本模型进行测试可知,本模型的预测误差均低于传统预测模型,预测精度显著提升,说明本模型可满足工业循环冷却水系统运行状态预测的实际需求。

参考文献

- [1]刘钢,李晓东,金铁群,等.基于深度卷积神经网络的工业循环冷却水系统运行状态预测[J].热力发电,2022,51(8):149-153.
- [2]李争,张杰,徐若思,等.基于相似日聚类和PCC-VMD-SSA-KELM模型的短期光伏功率预测[J].太阳能学报,2024,45(2):460-468.
- [3]蔡昌春,何捷,承敏钢,等.基于改进VMD-MCKD和深度残差网络的风机齿轮箱故障诊断[J].山东电力技术,2024,51(2):67-78.
- [4]曹还君,李长云.基于SSA-LSTM模型空气质量预测研究[J].现代信息科技,2024,8(4):142-146.
- [5]郑少明,董鹏,刘丹,等.基于多源数据和图神经网络相结合的故障诊断模型在故障录波主站上的应用[J].自动化技术与应用,2025,44(7):182-185.
- [6]翁新龙,焦云强,欧阳福生,等.石化企业循环冷却水系统腐蚀结垢预测模型的研究[J].石油炼制与化工,2023,54(12):119-126.
- [7]孙娜,周绍伟,潘姿宇.基于XGBoost-LSTM模型的多特征股票价格预测研究[J].数学建模及其应用,2023,12(4):32-39.
- [8]王华秋,李春洋,李永德.树种LSTM的冷水机组预测优化模型研究[J].重庆理工大学学报(自然科学),2022,36(10):231-238.
- [9]武晓冬,王麟斌,牛天聪,等.基于数据清洗及LSTM神经网络的CVT故障诊断[J].自动化技术与应用,2025,44(12):173-176.
- [10]陈逸嘉,陶力,李凯,等.基于IMIFS-VMD和ROA-LSTM的日前电价预测方法[J].自动化技术与应用,2025,44(9):23-28.
- [11]高森,王康,姜宏昌,等.基于改进花授粉算法的永磁同步电机参数辨识[J].电机与控制应用,2024,51(1):97-105.
- [12]梁靛,魏亚星,李义鑫,等.基于非线性跨代差分进化的花授粉优化算法及其应用研究[J].电子学报,2023,51(9):2445-2456.
- [13]王雨虹,王淑月,王志中,等.基于改进蝗虫算法优化长短期记忆神经网络的多参数瓦斯浓度预测模型研究[J].传感技术学报,2021,34(9):1196-1203.
- [14]宋长新,马克.基于差分进化改进的蝗虫优化算法[J].自动化技术与应用,2022,41(3):12-16.
- [15]贾彤华,范磊,程光旭,等.长短期记忆神经网络模型改进及其在循环冷却水管道腐蚀预测的应用[J].石油化工设备,2022,51(4):1-6.