

高林,李瑶,李捍东,等.基于VMD-IDBO-TABiLSTM的煤气化炉剩余寿命预测[J].湖南科技大学学报(自然科学版),2025,40(2):80-91.doi:10.13582/j.cnki.1672-9102.2025.02.010

GAO L, LI Y, LI H D, et al. Remaining Life Prediction of Coal Gasifier Based on VMD-IDBO-TABiLSTM [J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2025, 40(2): 80-91. doi: 10.13582/j.cnki.1672-9102.2025.02.010

基于VMD-IDBO-TABiLSTM的 煤气化炉剩余寿命预测

高林¹, 李瑶², 李捍东^{1*}, 熊国江¹

(1. 贵州大学 电气工程学院, 贵州 贵阳 550025; 2. 国网四川省电力公司天府新区供电公司, 四川 成都 610000)

摘要: 针对传统人工经验的煤气化炉剩余寿命预测方法存在精度不足、实时性差的问题, 提出一种变分模态分解-改进蜣螂算法-三重注意力双向长短期记忆网络 (Variational Mode Decomposition-Improved Dung Beetle Optimizer-Triplet Attention Bidirectional Long Short-Term Memory, VMD-IDBO-TABiLSTM) 的煤气化炉剩余寿命预测模型。利用 VMD 充分挖掘数据中的隐藏时序特征, 通过结合人工蜂群算法与动态权重系数对 IDBO 算法进行全局策略的超参数优化, 采用三重注意力机制的 TABiLSTM 学习复杂的时间依赖关系。以机械结构寿命损失分数为准则, 对模型的可靠性进行分析, 结果表明: 在变工况的条件下, VMD-IDBO-TABiLSTM 模型对 3 台煤气化炉的剩余寿命预测值与实际值的拟合度分别为 93.88%, 91.75%, 96.72%, 显示出模型在泛化能力和鲁棒性方面的显著优势。

关键词: 煤气化炉; 剩余寿命预测; 变分模态分解; 深度学习

中图分类号: TQ545

文献标志码: A

文章编号: 1672-9102(2025)02-0080-12

Remaining Life Prediction of Coal Gasifier Based on VMD-IDBO-TABiLSTM

GAO Lin¹, LI Yao², LI Handong¹, XIONG Guojian¹

(1. School of Electrical Engineering, Guizhou University, Guiyang 550025, China;

2. State Grid Tianfu New Area Power Supply Company, Chengdu 610000, China)

Abstract: In response to the issues of insufficient accuracy and poor real-time performance in traditional artificial experience-based prediction methods for the remaining service life of gasifiers, this study proposes a novel prediction model for the remaining service life of gasifiers, which integrates Variational Mode Decomposition (VMD), Improved Dung Beetle Optimizer (IDBO), and Triplet Attention Bidirectional Long Short-Term Memory (TABiLSTM). The model first employs VMD to thoroughly extract hidden temporal features from the data, followed by a global strategic hyperparameter optimization of the IDBO algorithm through the integration of artificial bee colony algorithms and dynamic weight coefficients. Furthermore, the model utilizes TABiLSTM with triple attention mechanisms to learn complex temporal dependencies. Using the mechanical structure service life loss score as the criterion, comparative analysis of model reliability indicates that the VMD-IDBO-TABiLSTM model achieves a high degree of fit with the actual values in varying conditions for the remaining service life

prediction of three gasifiers, with fit rates of 93.88%, 91.75%, and 96.72%, respectively, demonstrating the model's significant advantages in terms of generalization and robustness.

Keywords: coal gasifier; remaining life prediction; variational modal decomposition; deep learning

随着国内外智能制造的稳步推进,新型数字化仿真技术通过赋能传统工业,在节能增效、降低成本和可视化生产等方面带来显著效果.煤气化炉是为工业化生产提供煤气燃料(主要有 CO, H₂ 等)的核心装置,其高温炉管在长期运行中容易发生破裂,炉管失效不仅会影响煤气的正常生产,还可能会引发煤气泄漏甚至爆炸^[1],造成严重的安全事故.故障预测与健康管理(Prognostics and Health Management, PHM)技术作为工业设备管理的核心方法,对控制高温炉管性能衰退引发的安全风险及运维成本起到非常关键的作用.其中,剩余使用寿命(Remaining Useful Life, RUL)评估作为 PHM 的核心组成部分^[2],其准确性直接影响设备的检修计划优化、生产连续性保障以及煤气化装置的管理效率.构建预测模型可以减少突发停机风险,同时为维护决策提供支持,推动传统维护模式向智能化预测性维护转变.

在现有的 RUL 预测研究中,数据驱动方法已成为主流的技术路径.依据模型的特性差异,可进一步将数据驱动方法分为传统机器学习与深度学习两大分支^[3].以支持向量机(Support Vector Machine, SVM)和随机森林(Random Forest, RF)为代表的机器学习算法,因其强大的性能和广泛的适用性,在实际场景中得到广泛应用,但其基于浅层网络结构的特征学习能力有限,且依赖人工特征工程构建,在预测精度与自适应能力方面较深度学习方法存在显著的局限性.针对此问题, HU 等^[4]创新性地构建双向长短期记忆网络(Bidirectional Long Short-Term Memory, BiLSTM)-注意力机制变分自编码器(Variational Auto-Encoders, VAE)回归模型,通过融合双向时序特征提取与注意力加权机制,能够从多源传感器数据中提取深层退化特征,并通过数据聚类分析增强退化表征能力,为航空发动机 RUL 预测提供了新的解决方案.

然而,变工况煤气化炉的时间序列数据呈现显著的非稳态特性,直接对其进行预测会随时间推移发生异变,上述深度学习方法对结构的复杂度具有高度敏感性,浅层特征提取易受噪声干扰,导致预测误差累积放大.未经预处理的非平稳信号会破坏模型输入数据的一致性分布,使得常规神经网络难以建立有效的特征映射关系^[5].

针对上述问题,本文采用的煤气化炉剩余寿命预测方法首先利用变分模态分解(Variational Mode Decomposition, VMD)将高维深层信息分解,提升模型精度;然后选择改进的侦察蜂改变滚球蜣螂位置和动态权重系数,改进雌性蜣螂位置,提高传统蜣螂优化(Dung Beetle Optimizer, DBO)算法的参数寻优效果;最后通过三重并行自注意力机制,改进 BiLSTM 网络架构的学习效率.所提出的基于 VMD-IDBO-TABiLSTM 多模态融合预测框架采用 VMD 对多源传感器时序信号进行频域解耦,通过自适应分解获得具有物理意义的模态分量,然后将预处理数据导入 TABiLSTM,利用其双向时序建模能力捕捉设备退化特征的空间关联性,同时通过注意力权重分配强化关键退化节点的特征表征.引入改进蜣螂算法(Improved Dung Beetle Optimizer, IDBO)实施超参数空间搜索,有效规避传统参数整定过程中的局部最优陷阱,从而获得理想的变工况煤气化炉 RUL 预测值并将其作为输出.选用机械结构寿命损失分数作为准则,分析 4 种预测模型的可靠性,对比分析可知:在变工况煤气化炉剩余寿命预测模型中, VMD-IDBO-TABiLSTM 模型对 3 台煤气化炉的寿命预测结果与真实寿命值的拟合度均有大幅提升.

1 煤气化炉剩余寿命预测算法

1.1 IDBO 算法

DBO 算法是一种新型的群智能寻优算法,灵感来自蜣螂的滚球、跳舞、觅食、偷窃和繁殖等行为,与传统的反向传播(Back Propagation, BP)神经网络^[6]相比,可以避免陷入局部最小值的问题,具有较好的泛化能力,优化效果更好.然而,初始的 DBO 算法存在自适应参数需要手动设置、串行搜索效率低的问题.

因此,本文构建 IDBO 算法框架,其创新性体现在 2 个核心模块:首先,采用人工蜂群算法(Artificial Bee Colony, ABC)重构滚球导航机制;其次,设计动态权重调节器重塑繁殖个体的迁移策略.这种双重优化架构不仅加速了算法的收敛进程,更重要的是所建立的全局探索与区域开发的动态均衡机制可以使算法在复杂优化场景中展现出更优的泛化能力和计算效能.

1.1.1 人工蜂群算法

改进滚球蜣螂位置^[7]:蜣螂利用太阳在滚动的粪球中进行导航,借鉴蜂群的分工协作机制,通过 ABC 算法优化滚球蜣螂的位置,模拟蜂群的动态搜索特性,寻找全局最优解。

1) 初始化:初始化蜣螂的位置 x_i 和适应度值 $f(x_i)$ 。

2) 位置更新:对于每只蜣螂 i , 选择 2 个不同的滚球蜣螂 x_k 和 x_l 动态搜索位置更新,定义如下:

$$\begin{cases} x_i(t+1) = x_i(t) + \alpha k x_i(t-1) + b + \Delta x; \\ \Delta x = |x_i(t) - X^w|; \\ x_i(t+1)^{\text{new}} = x_i(t+1) + \varphi_i(x_k - x_l). \end{cases} \quad (1)$$

式中: t 为当前迭代次数; $x_i(t)$ 为第 i 只蜣螂在第 t 次迭代时的空间坐标信息; k 为自适应调节因子, $k \in (0, 0.2]$; b 为 $(0, 1)$ 的常数调节因子; α 为赋值为 -1 或 1 的自然系数; X^w 为对应种群的全局最差位置; Δx 为模拟光强的变化,其数值增大对应光源强度减弱; φ_i 为均匀分布的随机变量, $\varphi_i \in [-1, 1]$ 。

3) 选择操作:计算新的适应度值 $f(x_i^{\text{new}})$, 如果 $f(x_i^{\text{new}})$ 优于 $f(x_i)$, 则接受位置更新, 否则保持原始位置。

1.1.2 引入动态权重系数

引入动态权重系数^[8]来改进雌性蜣螂的位置更新,使其能够自适应地调整搜索行为。动态权重系数 $w(t)$ 可以根据迭代次数或其他因素进行调整。

$$w(t) = w_{\max} - \frac{t}{T}(w_{\max} - w_{\min}). \quad (2)$$

式中: $w_{\max}$, $w_{\min}$ 为权重系数的最大值和最小值; T 为最大迭代次数。

1) 初始化:初始化雌性蜣螂的位置 x_i 和适应度值 $f(x_i)$ 。

2) 位置更新:通过时变权重系数与边界约束策略的协同整合模拟雌性蜣螂产卵,建立权重参数与解空间特征间的动态映射关系^[9],动态调控产卵区域的空间探索策略,定义如下:

$$\begin{cases} L_b^* = \max[X^*(1-R), L_b]; \\ U_b^* = \min[X^*(1+R), U_b]; \\ x_i(t+1) = x_i(t) + w(t)V_i. \end{cases} \quad (3)$$

式中: X^* 为当前迭代周期内的局部最优位置; L_b^* , U_b^* 为产卵区域的下界和上界; R 为动态调整的比例半径, $R = 1 - t/T_{\max}$, $T_{\max}$ 为最大进化迭代次数; L_b 为优化变量理论的下界; U_b 为优化变量理论的上界; V_i 为雌性蜣螂产卵阶段的移动速度。

1.2 IDBO 算法性能分析

为了验证 IDBO 算法的寻优能力,选取 4 种测试函数^[10]开展 DBO 与 IDBO 的对比试验,测试函数如表 1 所示。试验设置统一的参数^[11]:种群规模为 30,最大迭代代数为 500 次,每个测试函数独立执行 30 次重复试验以消除随机性误差。在维度配置方面,单峰与多峰函数测试的维度设定为 30 维,其中,固定维度的多峰函数特别设置为 2 维空间,以验证算法在低维复杂环境中的表现^[12]。对比算法分别为粒子群优化算法(Particle Swarm Optimization, PSO),鲸鱼优化算法(Whale Optimization Algorithm, WOA),灰狼优化算法(Grey Wolf Optimizer, GWO), DBO 和 IDBO,参数配置如表 2 所示。

表 1 测试函数

函数名	测试函数	种群规模 n	测试范围
Sphere	$F_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$
Ackley	$F_{10}(x) = -20 \exp(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	30	$[-32, 32]$
Colville	$F_{13}(x) = 0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^n \frac{(x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)]}{1 + (x_i - 1)^2 [1 + \sin^2(2\pi x_i)]} \right\} + \sum_{i=1}^n u(x_i, 5, 100, 4)$	30	$[-50, 50]$
Bohachevsky	$F_{17}(x) = (x_2 - \frac{5.1}{4\pi^2} x_1^2 + \frac{5}{\pi} x_1 - 6)^2 + 10(1 - \frac{1}{8\pi}) \cos x_1 + 10$	2	$[-5, 5]$

表 2 算法参数设置

算法模型	参数设置
PSO	$C_1 = C_2 = 2, W = (0.1, 0.9)$
WOA	$a = (0, 2)$
GWO	$FADs = 0.2, P = 0.5$
DBO	$k = \lambda = 0.1, b = 0.3, s = 0.5$
IDBO	$\varphi_i = 0.5, T = 200, w_{\max} = 0.8, w_{\min} = 0.2$

测试函数的三维模型及收敛曲线如图 1 所示.由图 1(a)可知:在单峰优化问题中,IDBO 算法在迭代初期即展现出明显的收敛速率优势,且在搜索过程中能有效地逼近全局最优解.相较而言,算法的收敛轨迹呈现出较平缓的下降趋势.由图 1(b)和图 1(c)可知:针对多峰基准函数的试验结果,IDBO 算法不仅能维持最优收敛速率,还表现出卓越的局部极值规避能力,而其他算法均出现不同程度的早熟收敛现象.由图 1(d)可知:在固定维度多模态测试函数评估中,IDBO 算法的性能优势呈现数量级差异,验证其在复杂解空间中的鲁棒性.综合来看,IDBO 算法的优化结果具有竞争力.测试函数评价指标如表 3 所示.表 3 中,Mean 为函数均值,SD 为标准差(Standard Deviation).由表 3 可知:相比其他算法,IDBO 算法在大多数情况下的适应度均值和标准差更小、更稳定,也不易陷入局部最优,表现出显著的优越性.




图 1 测试函数收敛曲线对比

表 3 测试函数评价指标

算法	$F_1(x)$		$F_{10}(x)$		$F_{13}(x)$		$F_{17}(x)$	
	Mean	SD	Mean	SD	Mean	SD	Mean	SD
PSO	-2.58×10^{-3}	1.68×10^{-4}	8.341×10^{-4}	8.314×10^{-3}	1.000	5.29×10^{-5}	3.141	0.397
WOA	1.89×10^{-12}	5.07×10^{-23}	-1.43×10^{-16}	4.44×10^{-16}	1.328	1.17×10^{-2}	9.424	0.397
GWO	2.38×10^{-43}	-6.29×10^{-15}	-6.09×10^{-18}	4.44×10^{-16}	0.999	0.866	3.141	0.398
DBO	-2.14×10^{-21}	1.52×10^{-40}	1.11×10^{-13}	1.46×10^{-14}	-1.53×10^{-2}	0.936	3.141	0.398
IDBO	7.86×10^{-76}	1.47×10^{-146}	1.93×10^{-79}	3.27×10^{-23}	1.23×10^{-12}	7.53×10^{-23}	3.474×10^{-14}	3.95×10^{-23}

1.3 TABiLSTM 网络框架

尽管 BiLSTM 在 LSTM 的基础上进行了双向结构优化,但其对长序列的起始段仍存在显著的信息衰减,且固有的全局信息压缩机制缺乏特征筛选能力,难以有效捕获序列的全局表征和时序动态关联特性^[9].改进 TABiLSTM 是整合三重并行注意力机制的双向长短期记忆网络模型,通过动态调整分配输入信息的注意力权重,使系统能够聚焦于核心数据节点.该架构在保持序列的全局特征提取能力的同时,重点解析不同时间片段之间的动态关联特性,通过这种设计实现对时序数据多层次特征的协同挖掘,进而提升模型在关键信息捕获和整体预测精度方面的表现.

TABiLSTM 神经网络结构如图 2 所示. TABiLSTM 模型将自注意力机制引入正向 LSTM 前和逆向 LSTM 后,对输入输出序列的特征信息进行学习;同时,将加性注意力机制引入 2 个 LSTM 层之间,以挖掘煤气化炉 1[#]~8[#]的巡检温度和加压机出入口压强 (Temperature and Pressure, T&P) 时间序列的时间相关性;在输出层隐含层输出加入乘性注意力机制,确定注意力得分.通过三重注意力机制的作用,模型能够处理长距离依赖关系,更好地学习特征,避免丢失一些关联信息并捕捉煤气化炉时间序列的长期依赖性^[10].

1.3.1 计算注意力分数

加性注意力使用一个小型前馈神经网络用于非线性变换,乘性注意力使用点积计算查询相似度,自注意力通过点积计算并引用缩放因子防止梯度消失得到注意力得分.

$$\begin{cases} e_{ij}^1 = \mathbf{v}^T \tanh(\mathbf{W}_q \mathbf{q}_i + \mathbf{W}_k \mathbf{k}_j); \\ e_{ij}^2 = \frac{\mathbf{q}_i^T \mathbf{k}_j}{\sqrt{d_k}}; \\ e_{ij}^3 = \mathbf{q}_i^T \mathbf{k}_j. \end{cases} \quad (4)$$

式中: e_{ij}^x 为原始注意力权重, x 取 1, 2, 3 分别为加性注意力、自注意力和乘性注意力; $\mathbf{v}$ 为可学习的参数向量; $\mathbf{q}$ 为查询向量; $\mathbf{k}$ 为键向量; $\mathbf{W}_q$ 为查询矩阵; $\mathbf{W}_k$ 为键矩阵; $\sqrt{d_k}$ 为键向量的缩放因子; $\mathbf{k}_j$ 为 $\mathbf{W}_k$ 的第 j 个元素.

1.3.2 计算注意力权重

通过 Softmax 函数将注意力分数转换为权重:

$$a_{ij}^x = \frac{\exp(e_{ij}^x)}{\sum_u \exp(e_{ij}^x)}. \quad (5)$$

式中: a_{ij}^x 为注意力转换权重; u 为遍历求和索引变量.

1.3.3 计算上下文向量

使用注意力权重对值向量进行加权求和,得到上下文向量:

$$\mathbf{c}_i^x = \sum_j a_{ij}^x \mathbf{v}_j. \quad (6)$$

式中: $\mathbf{v}_j$ 为转换速率.




图 2 TABiLSTM 神经网络结构

为了评估算法的稳定性,引入函数均值(Mean)和标准差(SD)^[11],计算公式如式(7)和式(8)所示.

$$\text{Mean} = \frac{1}{P} \sum_{i=1}^P f_i; \quad (7)$$

$$\text{SD} = \sqrt{\frac{1}{P-1} \sum_{i=1}^P (f_i - \text{Mean})^2}. \quad (8)$$

式中: P 为试验优化次数; f_i 为每次独立运行时的最优值.

2 VMD-IDBO-TABiLSTM 模型

VMD-IDBO-TABiLSTM 预测模型如图3所示.

1) 使用中心频率法^[13],通过对不同 K 值(K 为聚类分析中的簇目数)的中心频率进行计算,用来确定各模态分量.

2) 采用 VMD 对原始信号进行噪声抑制与有效信息分离,分解为本征模态函数(Intrinsic Mode Function, IMF),以此提高模型对非平稳序列数据的预测精度.

3) 采用 IDBO 算法对 TABiLSTM 神经网络的拓扑结构、迭代次数和学习率进行寻优,确定 T&P 数据集的最优参数^[14].

4) 对 T&P 数据进行相关性分析并归一化处理,输入 IDBO-TABiLSTM 模型进行时序特征挖掘,重构各子序列的预测值并相加,获得时序预测结果.

5) 将预测的 T&P 结果输入到利用可靠性理论和寿命损耗分数准则建立的煤气化炉剩余寿命预测模型中,最终得到剩余寿命预测值.




图3 VMD-IDBO-TABiLSTM 模型

3 试验与结果分析

3.1 试验数据集

以贵州省遵义市某陶瓷厂的 3 台两段式煤气化炉作为研究对象,收集这 3 台煤气化炉近 2 a 的运行传感器数据,选择各自信号的 672 个采样点,组成 672×19 的原始信号矩阵.数据集按照 80% 和 20% 的比例分为训练验证集和测试集,其中将训练验证集中的 75% 作为训练集,剩下的 25% 作为验证集.数据集如表 4 所示.煤气化炉剩余寿命预测数据描述如表 5 所示.

表 4 数据集

数据集	工况数量	使用时长/h
QHL01	120	22 051
QHL02	254	43 232
QHL03	298	47 861

表 5 煤气化炉剩余寿命预测数据描述

特征序号	特征描述	符号
1	炉管上段温度	T_UP
2	炉管下段温度	T_DOWN
3	炉管上段压强	P_UP
4	炉管下段压强	P_DOWN
5	炉底压强	P_D
6	加压机入口压强	P_RK
7	加压机出口压强	P_CK
8	1#巡检温度	T_X1
...	...	...
15	8#巡检温度	T_X8
16	煤耗	C_C
17	氧气耗	C_O
18	蒸汽耗	C_H ₂ O
19	电耗	C_E

3.2 试验环境

采用 Intel Core i7-12700H CPU, NVIDIA GeForce RTX3080Ti GPU, 16 GB 内存, Win10 64 位的系统以及 MATLAB 2020b 编程软件.

3.3 预测评价指标

利用均方根误差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)以及拟合度(Goodness of Fit, R^2)对 VMD-IDBO-TABiLSTM 网络模型的预测性能进行评价.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}; \quad (9)$$

$$\text{MAE} = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n}; \quad (10)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}. \quad (11)$$

式中: n 为样本数; y_i 为真实值; $\hat{y}_i$ 为预测值; $\bar{y}_i$ 为预测平均值.

RMSE 和 MAE 的值越小,代表模型的预测效果越好, R^2 的值越接近 1,代表预测模型的拟合效果越好^[15].

3.4 数据预处理

为了评估所使用传感器数据的可靠性,提高数据对预测模型算法训练的准确性,采用皮尔逊相关性^[16]进行分析,数据的皮尔逊相关性分析结果如图 4 所示.由图 4 可知:在煤气化炉寿命预测模型中,相关性较高的数据为煤气化炉 1[#]~8[#]巡检温度和加压机出入口压强.




图 4 皮尔逊相关性分析结果

为了加速模型的收敛,提升模型计算的稳定性,防止多源传感器采集的信号数据由于量纲不统一造成梯度爆炸,对信号数据进行归一化操作将数据映射到 $(0,1]$,计算公式为^[17]

$$x_{\text{normalization}} = \frac{x - x_{\min}(A_s)}{x_{\max}(A_s) - x_{\min}(A_s)}. \quad (12)$$

式中: A_s 为第 s 个通道的原始时域信号; x 为样本数据的采样点; $x_{\max}$ 为采样点的最大值; $x_{\min}$ 为采样点的最小值; $x_{\text{normalization}}$ 为归一化后的数值.数据归一化处理如图 5 所示.




图 5 T&P 数据归一化处理

利用 VMD 分解后的 T&P 数据序列频率分布如图 6 所示,T&P 对应的中心频率如表 6 和表 7 所示.




图 6 利用 VMD 分解后的 T&P 数据序列频率分布

表 6 不同 K 值下 T 的 IMF 分量对应的中心频率

K	IMF ₁	IMF ₂	IMF ₃	IMF ₄	IMF ₅	IMF ₆	IMF ₇
1	0.000 1	0.101 9	0.167 4	0.298 8			
2	0.000 1	0.123 5	0.200 7	0.306 4	0.471 3		
3	0.000 1	0.149 8	0.241 9	0.335 1	0.345 5	0.490 6	
4	0.000 1	0.155 5	0.284 3	0.336 9	0.342 4	0.358 7	0.483 2

表 7 不同 K 值下 P 的 IMF 分量对应的中心频率

K	IMF ₁	IMF ₂	IMF ₃	IMF ₄	IMF ₅	IMF ₆	IMF ₇
1	0.000 1	0.098 2	0.269 4	0.463 4			
2	0.000 1	0.089 4	0.249 5	0.391 1	0.624 3		
3	0.000 1	0.642 1	0.210 3	0.340 1	0.495 3	0.649 9	
4	0.000 1	0.049 6	0.190 3	0.283 3	0.490 4	0.535 6	0.635 5

K 为聚类分析中的簇目数, K 值过大会导致过分解, 而过小则会导致欠分解. 经过多次调整, 最终确定 $K = 3$ 时的分解效果最佳.

3.5 消融实验

为了验证引入 VMD 序列分解和 IDBO 算法的优越性, 以及与 BiLSTM 相比, TABiLSTM 模型能更好地捕捉序列中的长期依赖关系的优点, 将 LSTM, VMD-BiLSTM, IDBO-TABiLSTM 和 VMD-IDBO-TABiLSTM 这 4 个预测模型进行对比, 各模型预测对比结果如图 7 所示. 得到 4 类模型在测试集上的 RUL 预测曲线可视化对比, 进一步量化分析对比模型的预测值与真实值之间的误差评价, 结果如表 8 和表 9 所示.




图 7 各模型预测对比结果

表 8 T 的消融实验预测结果

试验预测模型	VMD	IDBO	TABiLSTM	RMSE	MAE	$R^2/\%$	Time/s
LSTM	—	—	—	0.107	0.085	43.43	4.251
VMD-BiLSTM	✓	—	—	0.107	0.065	59.47	4.719
IDBO-TABiLSTM	—	✓	✓	0.065	0.035	85.09	3.164
VMD-IDBO-TABiLSTM	✓	✓	✓	0.034	0.015	92.36	2.583

注: ✓ 为预测模型融合该模块; — 为预测模型未融合该模块.

表 9 P 的消融实验预测结果

试验预测模型	VMD	IDBO	TABiLSTM	RMSE	MAE	$R^2/\%$	Time/s
LSTM	—	—	—	0.032	0.025	51.87	3.649
VMD-BiLSTM	✓	—	—	0.083	0.057	64.80	2.943
IDBO-TABiLSTM	—	✓	✓	0.046	0.027	88.95	2.547
VMD-IDBO-TABiLSTM	✓	✓	✓	0.027	0.018	94.35	1.764

注: ✓ 为预测模型融合该模块; — 为预测模型未融合该模块.

由表 8 可知: 对比 T 的拟合度, 可知 VMD-IDBO-TABiLSTM 模型比 LSTM 提高 48.93 个百分点, 比

VMD-BiLSTM 提高 32.89 个百分点,比 IDBO-TABiLSTM 提高 7.27 个百分点.对比得出,VMD-IDBO-TABiLSTM 模型的预测值与真实数据的拟合程度最高且耗时最短.

3.6 寿命损耗分数准则

寿命损耗准则^[18]假设某种材料在承受应力 σ 、温度 B 和运行时间 l 的条件下,其寿命损耗分数为 l/l_r ,其中 l_r 为该材料的断裂时间.如果温度和应力在运行过程中是变化的,部件将在其寿命损耗分数累积达到 1 时发生破坏,即

$$\sum_{i=1}^n l_r(\sigma_i, B_i) \Delta l_i = 1. \quad (13)$$

将式(13)写成积分形式:

$$\int_0^l \frac{dl}{l_r(\sigma, B)} = 1; \quad (14)$$

$$l_r = A\sigma^{-w} e^{\frac{Q}{GH}}. \quad (15)$$

式中: A 为物质常数; w 为应力指数; Q 为活化能; G 为气体常数; H 为绝对温度.

假设温度、压力均为常数,但随着操作时间的增加,炉管的磨损减薄程度也随之增大,由计算炉管薄膜应力的公式得到^[19]:

$$\sigma = \frac{pD_i}{2(\delta - lV)} = \sigma(t, V). \quad (16)$$

式中: V 为磨损速度, mm/h; p 为工作压力, MPa; D_i 为炉管中径; δ 为原始壁厚, mm.

将式(16)代入式(14)可得

$$\sum_0^{l_z} \frac{dl}{l_r(l, V)} = 1. \quad (17)$$

式中: l_z 为炉管的总寿命.

在一定的温度、压力和磨损速率下,则剩余寿命 l_s 为

$$l_s = l_z - l_L. \quad (18)$$

式中: l_L 为从启动到目前为止的累积运行时间.

3.7 可靠性预测模型

由磨损点计算炉内的最大应力,并确定其极限状态方程:

$$g_1(x) = l_c - l_g. \quad (19)$$

式中: $g_1(x)$ 为用于评估设备可靠性的极限状态函数; l_c 为使用寿命损失标准算出的寿命; l_g 为已知的工作时间,如果计算出来的寿命低于一定的工作时间,则可将其视为在一定的工作周期内发生故障^[20].

根据炉管材料的高温力学性能建立依据强度理论的失效判据:

$$\sigma_{\max} \geq \sigma_{sT}. \quad (20)$$

式中: $\sigma_{\max}$ 为材料在实际工作条件下承受的最大应力; σ_{sT} 为材料的高温屈服极限.

极限状态函数可表示为

$$g_2(x) = \sigma_{sT} - \sigma_{\max}. \quad (21)$$

将式(21)代入式(16)可得

$$g_2(x) = \frac{(p_{st} - p_{\max}) D_i}{2(\delta_{st} - lV) (\delta_{\max} - lV)}. \quad (22)$$

式中: p_{st} 为材料的许用应力对应的安全压力; $p_{\max}$ 为最大运行工作压力; δ_{st} 为材料的安全厚度; $\delta_{\max}$ 为最大允许磨损厚度.

$g_2(x) \leq 0$ 为失效状态,由此看出预测模型的目标函数是与 p 和 l 具有相关性的函数.选择 1 台已报废的煤气化炉作为测试集,对比 4 种模型在理想情况下的预测效果,结果如图 8 所示.由图 8 可知:VMD-IDBO-TABiLSTM 的预测效果最好.采用 R^2 作为指标,分别对 3 台煤气化炉进行预测,煤气化炉剩余寿命预测的拟合度结果如表 10 所示.由表 10 可知:所提模型的预测效果较前 3 种模型的预测精度均有较大提升.




图 8 煤气化炉预测结果对比

表 10 煤气化炉剩余寿命预测拟合度 单位: %

模型	QHL01	QHL02	QHL03
LSTM	67.48	71.89	60.31
VMD-BiLSTM	70.32	72.01	75.35
IDBO-TABiLSTM	71.78	79.14	80.65
VMD-IDBO-TABiLSTM	93.88	91.75	96.72

4 总结

- 1) 已有的传感器数据采集和模型搭建便于模型的应用部署,可以减少人工经验判断,有助于企业对设备的正常运行管理,可为企业的生产计划提供依据和理论支撑.
- 2) VMD 被运用在变工况煤气化炉剩余寿命预测模型中,通过降低序列的复杂度和非线性,能够大幅度提高模型对于高维数据的处理能力,有效提升模型的预测精度,同时达到克服模态混叠的目的.
- 3) 与现有模型相比,改进的 IDBO 算法和融入三重注意力机制的 VMD-IDBO-TABiLSTM 模型在预测精度方面具有更好的效果,消融实验结果证明以上改进的优越性.
- 4) 由于煤气化炉的数据有限,模型在收敛速度上呈现波动较大和不稳定的情况.
- 5) 由于训练数据为单一固定型号的两段式煤气化炉运行数据,所提出的模型对其他类型煤气化炉的普适性不强,还需要另外收集预测型号的全生命周期数据进行模型训练.

参考文献:

[1] FERNANDEZ O. Improved bounds and high-accuracy estimates for remaining life expectancy via quadrature rule-based methods[J]. Demographic Research, 2023, 48: 809-828.

[2] XUE B, YI W J, JING F, et al. Complex ISAR target recognition using deep adaptive learning[J]. Engineering Applications of Artificial Intelligence, 2021, 97: 104025.

[3] QIU X H, WU W X, WANG S F. Remaining useful life prediction of lithium-ion battery based on improved cuckoo search

- particle filter and a novel state of charge estimation method[J]. *Journal of Power Sources*, 2020, 450: 227700.
- [4] HU Y Y, BAI Y T, FU E, et al. A novel remaining useful life probability prediction approach for aero-engine with improved Bayesian uncertainty estimation based on degradation data[J]. *Applied Sciences*, 2023, 13(16): 9194.
- [5] 王恺洲,韩洋,仇鹏,等.基于BPNN-SVM-ELM融合算法的气化炉预测模型[J].*华东理工大学学报(自然科学版)*,2024,50(2):161-169.
- [6] XUE B, HE Y, JING F, et al. Dynamic coarse-to-fine ISAR image blind denoising using active joint prior learning[J]. *International Journal of Intelligent Systems*, 2021, 36(8): 4143-4166.
- [7] LIU Q, JIANG X Y, WANG X H. Control of sewage treatment based on optimization and deep learning algorithm[C]//2023 International Conference on New Trends in Computational Intelligence (NTCI). IEEE, 2023: 231-236.
- [8] 李志军,徐博,杨金荣,等.基于VMD-改进最优加权法的短期负荷变权组合预测策略[J].*国外电子测量技术*,2024,43(2):1-8.
- [9] 段宇,黄君,杨关友,等.基于RIME-VMD-SSA-LSTM法研究非生态因素影响的来水预报模型[J].*云南水力发电*,2024,40(5):44-50.
- [10] 郭晓静,徐晓慧,郭佳豪.基于改进GRU的航空发动机寿命预测自注意力优化算法[J].*航空动力学报*,2024,39(12):447-457.
- [11] XUE B, HE Y, JING F, et al. Robot target recognition using deep federated learning[J]. *International Journal of Intelligent Systems*, 2021, 36(12): 7754-7769.
- [12] SUN C, QU A, ZHANG J, et al. Remaining useful life prediction for lithium-ion batteries based on improved variational mode decomposition and machine learning algorithm[J]. *Energies*, 2023, 16(1): 313.
- [13] 韩素敏,赵国帅,尚志豪,等.基于改进DBO优化BiLSTM的IGBT老化预测模型[J].*电子测量技术*,2024,47(1):46-54.
- [14] FANG M K, ZHANG F F, YANG Y, et al. The influence of optimization algorithm on the signal prediction accuracy of VMD-LSTM for the pumped storage hydropower unit[J]. *Journal of Energy Storage*, 2024, 78: 110187.
- [15] XUE B, ZHENG Q H, LI Z N, et al. ISAR weak feature enhancement with perturbation defense using hybrid clustering oversegmentation[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2024, 60(5): 6256-6274.
- [16] CEN Z L, HU S L, HOU Y D, et al. Remaining useful life prediction of machinery based on improved Sample Convolution and Interaction Network[J]. *Engineering Applications of Artificial Intelligence*, 2024, 135: 108813.
- [17] 张诗云,朱菊香,张涛,等.基于VMD-DBO-LSTM的空气质量预测[J].*国外电子测量技术*,2024,43(3):58-66.
- [18] LIU L S, WANG S J, LIU D T, et al. Quantitative selection of sensor data based on improved permutation entropy for system remaining useful life prediction[J]. *Microelectronics Reliability*, 2017, 75: 264-270.
- [19] GU M Y, CHEN Y L. Two improvements of similarity-based residual life prediction methods[J]. *Journal of Intelligent Manufacturing*, 2019, 30(1): 303-315.
- [20] LI Y H, SUN K X, YAO Q, et al. A dual-optimization wind speed forecasting model based on deep learning and improved dung beetle optimization algorithm[J]. *Energy*, 2024, 286: 129604.