

DOI: 10.13382/j.jemi.B2508607

应用两步分解的 HBA-NBEATS 燃煤电站 锅炉能效预测*

崔方舒¹ 王楠² 冀鹏宇¹ 袁泽宇³ 闫俊义¹ 史元浩²

(1. 中北大学计算机科学与技术学院 太原 030051; 2. 中北大学电气与控制工程学院 太原 030051;

3. 极限环境光电动态测试技术与仪器全国重点实验室 太原 030051)

摘要: 燃煤电站锅炉受热面的灰污沉积不仅会引发能效下降,持续累积还可能引发严重的安全事故,因此对锅炉受热面能效状态的精准预测是解决该问题的重要途径。为实现能效预测精度的提升,构建了一种应用两步分解的蜜獾算法(honey badger algorithm, HBA)优化的神经基扩展分析(neural basis expansion analysis, NBEATS)模型的燃煤电站锅炉能效预测模型。该方法以清洁因子作为锅炉受热面能效变化的表征指标,使用小波阈值理论对原始清洁因子数据实施去噪,并运用鲁棒经验模态分解(robust empirical mode decomposition, REMD)联合变分模态分解(variational mode decomposition, VMD)的两步分解获取去噪后数据的多个模态分量。在每个分解得到的模态分量上,应用HBA算法调优超参数的NBEATS模型进行独立预测,叠加所有模态分量预测值生成锅炉能效预测结果。贵州某300 MW燃煤电站锅炉数据集上的实验表明,相较于消融实验中的对比模型,本文模型在多个性能指标上展现出显著优势,均方根误差性能提升幅度在5.43%~93.31%之间;决定系数提高至0.98以上;平均绝对误差最优值达0.0002。

关键词: 能效预测;清洁因子;两步分解;鲁棒经验模态分解;蜜獾优化算法;NBEATS模型

中图分类号: TM621.2; TP183 **文献标识码:** A **国家标准学科分类代码:** 520.20

Energy efficiency prediction for coal-fired power station boilers based on two-step decomposition and HBA-NBEATS model

Cui Fangshu¹ Wang Nan² Ji Pengyu¹ Yuan Zeyu³ Yan Junyi¹ Shi Yuanhao²

(1. School of Computer Science and Technology, North University of China, Taiyuan 030051, China; 2. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China; 3. State key Laboratory of Extreme Environment Optoelectronic Dynamic Measurement Technology and Instrument, North University of China, Taiyuan 030051, China)

Abstract: Ash deposition on the heating surfaces of coal-fired power station boilers causes a significant decrease in energy efficiency. If it accumulates continuously, it may cause serious safety accidents. Therefore, accurate prediction of the energy efficiency of the boiler heating surface is an important way to solve this problem. To achieve the improvement of energy efficiency prediction accuracy, this paper constructs an energy efficiency prediction model for coal-fired power station boilers based on a neural basis expansion analysis (NBEATS) model. This model is optimized by the honey badger algorithm (HBA) that incorporates a two-step decomposition strategy. This method uses the cleanliness factor as an indicator of energy efficiency in the boiler heating surface, and applies wavelet threshold theory to denoise the original cleanliness factor data. The two-step decomposition strategy of robust empirical mode decomposition (REMD) combined with variational mode decomposition (VMD) is used to obtain multiple mode functions of the denoised data. For each decomposed mode function, the HBA algorithm is applied to tune the hyperparameters of the NBEATS model for independent prediction, and the predicted values of all mode functions are superimposed to generate the boiler energy efficiency prediction results. Experiments on the boiler dataset of a 300 MW coal-fired power station in Guizhou Province show that the proposed model outperforms the ablation model in multiple performance metrics, the root mean square error performance is improved by 5.43%~93.31%; the

收稿日期: 2025-07-27 Received Date: 2025-07-27

* 基金项目: 山西省基础研究计划(202303021222084)、山西省基础研究计划(202303021222120)、中北大学研究生校级科技立项(20242066) 资助

coefficient of determination increases to above 0.98; the minimum mean absolute error achieves 0.000 2.

Keywords: energy efficiency prediction; cleanliness factor; two-step decomposition; robust empirical mode decomposition; honey badger algorithm; neural basis expansion analysis model

0 引言

在“双碳”目标下,清洁能源的步伐逐渐加快,但燃煤火力发电在十四五期间仍然是电力行业的主力供应来源。因此燃煤火力发电如何在“双碳”目标下进行清洁转型,建成清洁低碳、安全高效的火力发电过程是亟待解决的问题^[1]。

燃煤发电过程中,燃煤中存在的灰分以及不完全燃烧所产生的积灰和结渣会附着和沉积在锅炉换热器的表面,从而影响换热效率,降低能效,时间过长还可能造成严重的安全事故。解决这一问题的通常方法是吹灰,常规采用高温高压蒸汽作为吹灰介质,也有采用声波等作为吹灰介质。吹灰策略的不合理如过于频繁会导致介质的过分消耗,受热面寿命降低;而吹灰不够及时则会造成换热效率下降,综合能效降低^[2-4]。因而,如何能够对燃煤电站锅炉受热面的能效变化进行科学的评估和趋势预测对制定合理吹灰策略十分必要,对于受热面能效趋势的准确预测是值得研究的问题。

对于燃煤电站锅炉的灰污监测和吹灰优化方面,国内外学者进行了一系列研究和工程实践。20世纪90年代起,霍尼韦尔公司就开始利用数据分析来评估受热面的积灰情况并据此来清除积灰,与常规方法相比能够一定程度提高吹灰效率进而降低成本。Zhang等^[5]采用声学方法实现了对灰污沉积的在线监测。史元浩等^[6-7]在之前的研究中通过一种清洁因子(cleanliness factor, CF)来反映受热面的传热效率,间接实现积灰以及能效的在线监测。灰污监测能够给到锅炉受热面传热效率的科学评估以及吹灰策略的制定。随着节能减排需求的提升,控制要求提高,优化策略的制定对灰污状况以及能效的预测需求越来越高。Xu等^[8]对悬浮预热器余热锅炉过热器灰污沉积问题进行了研究,并构建了一个涵盖灰污沉积与清除过程的综合积灰增长模型,并采用实验数据对该模型的有效性进行了验证。Zhu等^[9]探讨了锅炉变负荷工况下积灰特性的动态变化规律,重点分析了燃烧器高度、灰粒直径等因素对积灰沉积的影响。韩天翔等^[10]提出一种基于互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)与时间卷积网络(temporal convolutional network, TCN)的燃煤电站锅炉受热面积灰预测方法。魏玮等^[11]针对电站负荷波动场景下风机状态预测模型精度下滑的问题,提出一种融合卷积神经网络(convolutional neural

network, CNN)、长短期记忆网络(long short-term memory, LSTM)及注意力机制的动态集成状态预测方案。王楠等^[12]提出一种基于时变滤波器的经验模态分解(time-varying filtered empirical mode decomposition, TVF-EMD)和卷积门控神经单元(convolutional neural network-gated recurrent unit, CNN-GRU)的混合模型对锅炉受热面能效进行预测。

从上述专家和学者对锅炉受热面灰污沉积特性以及能效预测的研究可以看出,近年来信号分解方法因其可将复杂序列分解成可预测性更强的子序列,从而被广泛应用于锅炉能效时序数据的数据预处理部分。Liu等^[13]对传统经验模态分解技术进行改进,提出了稳定性和自适应性更强的鲁棒经验模态分解(robust empirical mode decomposition, REMD)。它能够适应各种复杂序列的特征,充分规避噪声干扰和离群值的影响,从而获得精度和可靠性更高的重构信号。针对波动性显著的能效序列,其分解后的高频分量往往呈现较强的非线性特性。因此,采用二次分解策略处理高频分量可显著提升预测模型的准确性。变分模态分解(variational mode decomposition, VMD)通过变分模型避免了模态混叠问题,因而可用于对高频分量的二次分解处理^[14]。

在序列数据的预测部分,从上述研究基础可知,深度学习是目前锅炉能效预测领域普遍使用的数据驱动方法。它凭借非线性拟合优势和多层网络架构,能够有效捕捉时序数据中潜在的复杂关联规律,因而在时序数据预测任务中展现出显著的优势。然而,深度学习模型,如LSTM、GRU等,一般具有复杂的网络结构与参数,从而使其可解释性较差。于是,Oreshkin等^[15]于2020年提出了一种具有可解释性的用于时间序列预测的深度学习模型:神经基扩展分析(neural basis expansion analysis, NBEATS)模型。它通过堆叠多层神经网络块来捕捉时间序列的趋势、季节性和其他复杂模式,因此具有强大的预测能力,且在多个时间序列预测任务中表现优异^[16-18]。当前,绝大多数模型的超参数主要依赖人工主观设定,这一过程不仅耗费大量时间,还容易使模型陷入局部最优解,进而造成模型预测性能不佳。在此背景下,借助智能优化算法实现超参数的自动寻优成为一种有效的解决方案^[11]。蜜獾优化算法(honey badger algorithm, HBA)是一种基于自然界蜜獾捕食行为的元启发式优化算法,具有结构简单、收敛速度快、全局搜索能力强等特点^[19]。在与鲸鱼、灰狼等智能优化算法的对比研究中,HBA算法展现出更优异的寻优性能,可快速实现全局最优超参

数的搜索^[20-21]。

综合上述分析,本文提出一种基于两步分解的 HBA-NBEATS 的燃煤电站锅炉能效预测方法。该方法首先采用清洁因子来表示锅炉受热面的换热效率;在数据预处理部分,首先使用小波阈值法对原始序列数据进行去噪,然后采用 REMD 和 VMD 两步分解法将去噪后的数据分解为多个子序列;在预测部分,对每个子序列使用经 HBA 优化超参数的 NBEATS 模型进行建模预测,然后将各个子序列的预测结果进行加和,从而得到燃煤电站锅炉能效的预测值;最后,通过实际能效测量数据进行验证,并与多种预测模型的对比分析中可以看出本方法的有效性。

1 相关理论

1.1 REMD

REMD 于 2021 年提出,旨在解决传统经验模态分解中筛选停止准则采用预设阈值法时,不同数据集可能出现分解效果不一致的问题^[13]。REMD 的实施步骤如下:

- 1) 初始化, $j = 1$, 初始化残差 $r_0(t) = x(n)$;
- 2) 找出 $r_{j-1}(n)$ 所有的局部最大值和最小值;
- 3) 分别通过局部最大值和最小值的三次样条插值计算上包络线 $U_j(n)$ 和下包络线 $L_j(n)$;
- 4) 计算包络线的平均值;
- 5) 求出数据与均值之差作为初始固有模态函数 (intrinsic mode functions, IMF); 计算第 j 个分量

$$h_j(n) = r_{j-1}(n) - m_j(n) \quad (1)$$

- 6) 假定 $h_{j0} = h_j(n)$, $m_{jk}(n)$, $k = 0, 1, \dots$, 计算 $h_{jk}(n) = h_{j0} - m_{jk-1}(n)$, 直至满足停止准则:

$$f_{jk}(n) = RMS_{jk} + |EK_{jk}| \quad (3)$$

$$RMS_{jk} = \sqrt{\sum_{n=1}^{N_s} (m_{jk}(n))^2 / N_s} \quad (4)$$

$$EK_{jk} = \frac{\frac{1}{N_s} \sum_{n=1}^{N_s} (m_{jk}(n) - \bar{m}_j)^4}{\left(\frac{1}{N_s} \sum_{n=1}^{N_s} (m_{jk}(n) - \bar{m}_j)^2\right)^2} - 3 \quad (5)$$

其中, $\bar{m}_j$ 为 $m_{jk}(n)$ 的均值。如果零点与极值点的个数相等或者两者之差 < 1 , $f_{k-2} < f_{k-1}$ 且 $f_{k-1} < f_k$, 则停止筛选过程并返回 $k - 2$ 次分解结果;如果不是,则在达到最大迭代次数之前继续筛选。

- (1) 计算第 j 个 IMF: $IMF_j(t) = h_{jk}(n)$;
- (2) 更新残差, $r_j(n) = r_{j-1}(n) - IMF_j(n)$;
- (3) 增加筛选指数 j 并重复步骤 (2) ~ (3)。

最后,初始信号 $x(n)$ 可重建为:

$$x(n) = \sum_{j=1}^N IMF_j(n) + r_N(n) \quad (6)$$

1.2 VMD

VMD 通过最小化子分量带宽的变分框架,有效克服了传统方法中模态混叠、端点效应等不稳定性,能够更为可靠的将复杂信号分解为具有明确物理意义和中心频率的分量^[14]。VMD 通过构建变分框架得到的变分约束模型如下。

满足 $\hat{\lambda}^1$ 约束。

$$\min_{\{u_k\}, \{w_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \quad (7)$$

其中, $u_k = \{u_1, u_1, \dots, u_n\}$ 和 $w_k = \{w_1, w_2, \dots, w_n\}$ 表示 VMD 分解的 k 个模态分量和对应的中心频率; $*$ 表示卷积; $\delta(t)$ 为狄克拉函数; ∂_t 表示对时间求导。VMD 算法具体过程如下:

初始化 $\{u_k^1\}, \{w_k^1\}, \hat{\lambda}^1, n \leftarrow 0$

重复: $n \leftarrow n + 1$

更新所有 $w \geq 0$ 的: $\hat{u}_k, k = 1 : K$:

$$\hat{u}_k^{n+1}(w) \leftarrow \frac{\hat{f}(w) - \sum_{i \neq k} \hat{u}_i^n(w) + \frac{\hat{\lambda}^n(w)}{2}}{1 + 2\alpha(w - w_k^n)^2} \quad (8)$$

式中: α, λ 分别为引入的二次惩罚项和拉格朗日乘数。更新中心频率 w_k :

$$w_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k^{n+1}(w)|^2 dw}{\int_0^\infty w |\hat{u}_k^{n+1}(w)|^2 dw} \quad (9)$$

对所有 $w \geq 0$, 使用对偶上升法:

$$\hat{\lambda}^{n+1}(w) \leftarrow \hat{\lambda}^n(w) + \tau(\hat{f}(w) - \sum_k \hat{u}_k^{n+1}(w)) \quad (10)$$

直到收敛: $\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \varepsilon$ 。

1.3 HBA

HBA 是由 Hashim 等^[19]于 2021 年提出的一种受蜜獾觅食行为启发的优化算法,其分为两个阶段:挖掘阶段和采蜜阶段。在挖掘阶段,蜜獾通过敏锐的嗅觉来探测猎物。当靠近猎物时,它会沿着类似心形的轨迹探索附近。在采蜜阶段,蜜獾与导蜜鸟合作,鸟儿定位蜂巢后,蜜獾提取蜂蜜,HBA 算法步骤如下。

1) 种群初始化,蜜獾初始的位置由以下公式随机生成:

$$x_i = lb_i + r_1 \times (ub_i - lb_i) \quad (11)$$

式中: x_i 为第 i 只蜜獾的当前位置; ub_i, lb_i 分别为搜索范围的上界和下界; r_1 为 $(0, 1)$ 内随机数。

2) 强度定义,强度 I_i 为气味强度,表示猎物对蜜獾的吸引程度。它与猎物的集中程度 S 以及猎物与蜜獾之间的距离 d_i 相关。

3) 密度因子更新,密度因子 $\alpha = C \times \exp(-t/t_{\max})$ 是

控制时变的随机数,以确保在寻优的过程中从勘探阶段到开采阶段的平滑过渡。

4) 个体位置更新,更新阶段模拟蜜獾的两种狩猎模式。在挖掘模式下,蜜獾的运动类似于心形曲线,蜜獾的新位置可以表示为:

$$x_{new} = x_{prey} + F \times \beta \times I \times x_{prey} + F \times r_3 \times \alpha \times d_i \times |\cos(2\pi r_4) \times (1 - \cos(2\pi r_5))| \quad (12)$$

式中: β 是一个大于 1 的常数(通常设为 6),代表蜜獾的捕食能力; r_3, r_4 和 r_5 为(0,1)内 3 个不同的随机数; F 是方向标志变量,用于改变搜索方向。

在蜂蜜模式下,蜜獾的新位置计算如下:

$$x_{new} = x_{prey} + F \times r_7 \times \alpha \times d_i \quad (13)$$

式中: r_7 为(0,1)内的随机数。在 HBA 的每次迭代中,以 50% 的概率随机选择挖掘模式和蜂蜜模式,其中前者对应于优化算法的探索过程,后者对应于优化算法的开发过程。

1.4 NBEATS

NBEATS 模型是一种具有可解释性的广泛用于时间序列预测的神经网络,其核心思想是将时间序列分解为多层全连接,每一层拟合时间序列的部分信息^[15]。该模型有两种独特的模型结构:块和堆栈,并凭借其简单的全连接网络结构优势能够有效捕捉时间序列数据中的短期波动和低频变化。因此,在应对非线性及复杂动态变化的时序数据时,呈现出较强的适应性与处理能效,进而输出准确的预测结果。NBEATS 模型的结构如图 1 所示。




图 1 NBEATS 结构

Fig. 1 Structure diagram of NBEATS

2 REMD-VMD-HBA-NBEATS 预测模型设计

2.1 问题描述与数据来源

以贵州某 300 MW 燃煤电站锅炉为例进行研究,锅炉换热流程示意图如图 2 所示。锅炉为 W 型火焰再热汽包锅炉,其主要换热面包括炉膛、屏式过热器、高温过热器、低温过热器、再热器、省煤器和空气预热器。

锅炉的换热方式主要有辐射换热和对流换热两种。如图 3 所示,以尾部烟道对流换热方式为例,积灰层会降低换热效率。一般情况下,由于锅炉换热面工作条件复杂,无法直接测量换热面积灰状态。因此,积灰状态与间接参数的结合可用来反映换热面的积灰状态,即反映锅

炉的能效状态。本文使用清洁因子来表示燃煤电站锅炉的能效状态,其定义如下:

$$CF = \frac{K_r}{K_0} \quad (14)$$

式中: K_r 为换热面实际换热系数; K_0 为理论换热系数; CF 的值位于[0,1]。

本文对贵州某 300 MW 燃煤电站省煤器和再热器的清洁因子数据集进行特征提取、数据预处理等操作,以构建有效的锅炉受热面能效预测系统,为制定科学的吹灰策略提供支撑。在这两个数据集中,选择清洁因子随时间推移而自然下降的积灰段,并进行数据采样(采样间隔为 1 min),得到了两个数据长度为 594 的时间序列。




图 2 锅炉换热流程
Fig. 2 Flow diagram of boiler heat transfer




图 3 对流换热过程示意图
Fig. 3 Schematic diagram of convective heat transfer process

2.2 基于 REMD-VMD-HBA-NBEATS 预测模型搭建

为了制定合理的吹灰策略,对燃煤电站锅炉受热面能效趋势的准确预测至关重要,因此本文提出了一种新型的 REMD-VMD-HBA-NBEATS 能效预测方法。由于原始数据噪声较强,采用小波阈值理论对原始清洁因子数据进行降噪处理。考虑到去噪后的清洁因子序列仍具有较强的非线性和非平稳特征,本预测模型首先使用鲁棒性更强的 REMD 分解对其进行处理。由于 REMD 分解后的高频分量表现出显著的非线性特征,利用 VMD 对其进行二次分解能有效提高模型的预测精度。然后,使用 NBEATS 模型对每个分量进行建模预测,而 NBEATS 中手动设置的超参数易陷入局部最优解,进而降低燃煤电站锅炉能效的预测准确性。针对该问题,本文采用全局

搜索能力强且收敛速度快的 HBA 算法对 NBEATS 的超参数实施优化,以高效搜索其全局最优超参数组合。REMD-VMD-HBA-NBEATS 模型的总体架构如图 4 所示,具体步骤如下。

1) 特征提取与数据预处理。对贵州某 300 MW 燃煤电站锅炉换热面清洁因子数据集进行特征提取,采用小波阈值法对此原数据进行去噪,再对清洁因子积灰段数据进行数据采样。首先使用 REMD 对采样后的数据进行分解,然后采用 VMD 对 REMD 分解后的高频分量进行二次分解,并将分解后的多个模态分量进行训练集和测试集的划分。

2) HBA-NBEATS 模型。选定 NBEATS 的迭代次数、学习率等作为待优化超参数,构建 HBA 算法的初始种群,并以训练集上的均方根误差作为适应值函数。在迭代优化中,HBA 持续更新其强度和密度因子,评估个体适应值,并记录和更新种群的历史最优位置,以此指导 NBEATS 模型的训练进程。此过程迭代进行,直至达到全局最优解终止准则,此时输出的最优解即为 NBEATS 模型的最佳超参数组合。

3) 燃煤电站锅炉能效预测。采用优化得到的最优超参数配置 NBEATS 模型,依次对各模态分量的测试集进行预测,最后对所有模态分量的预测结果进行加和重构得到最终的能效预测值,并且用性能评价指标对模型的预测效果进行评估。




图 4 REMD-VMD-HBA-NBEATS 模型框架图
Fig. 4 Frame diagram of REMD-VMD-HBA-NBEATS

3 实验与分析

3.1 性能评价指标

针对 REMD-VMD-HBA-NBEATS 模型预测性能的评

估,本文选取均方根误差 (root mean square error, RMSE)、决定系数 (coefficient of determination, R^2) 和平均绝对误差 (mean absolute error, MAE) 作为性能评价指标。RMSE 反映预测误差的离散大小; R^2 代表模型拟合优度,即对数据变异的解释比例; MAE 描述预测误差绝对值的平均水平。RMSE 与 MAE 的值越接近 0, R^2 值越接近 1,则表示模型的预测效果越好。RMSE、 R^2 和 MAE 的计算公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2} \quad (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

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


式中: y_i 为实际测量值; $\hat{y}_i$ 为模型预测值; $\bar{y}$ 为实际测量值的算术平均数; n 为样本总量。

3.2 数据预处理


本文提取的燃煤电站省煤器的清洁因子原始数据如图 5(a) 和 (b) 中实线所示,可以看出其存在显著的噪声干扰。由于燃煤电站锅炉清洁因子数据主要集中于低频信号部分,因此本文去噪的目的在于提取清洁因子原始数据中的低频信号。为评估去噪效果,本文对小波阈值法、REMD 和 VMD 的去噪结果与原始数据进行对比,相关结果如图 5(a) 和 (b) 所示。从图 5 可以发现,相较于 REMD 和 VMD 方法,小波阈值法能更有效地提取原始数据中的低频信号,并且其去噪后的数据更加清晰的反映了清洁因子的变化趋势和非线性波动。

为了制定更加科学的吹灰策略,本文构建的锅炉受热面能效预测系统需要提取清洁因子随时间减小的积灰段,如图 5(a) 中虚线框中所示。这是因为此积灰段受机组负荷变动及吹灰信号频率扰动的影响较小,适合作为预测系统的输入数据。考虑到原始数据以 5 s 为间隔提取清洁因子数据,而该时间尺度下的数据采样对于能效预测的贡献有限,且会显著增加数据处理工作量,因此本文对去噪后的积灰段数据进行重采样处理,将采样间隔调整为 1 min,结果如图 5(c) 所示。


为了提高能效预测的准确度,首先对经过数据预处理后的省煤器积灰段清洁因子数据进行 REMD 分解,结果如图 6(a) 所示。然后,采用 VMD 对 REMD 分解后的高频分量 IMF1 进行二次分解,结果如图 6(b) 所示。同理,对数据预处理后的再热器积灰段清洁因子实施 REMD 分解后的各模态分量如图 7(a) 所示,对 REMD 分解后的 IMF1 进行 VMD 二次分解后的结果如图 7(b) 所示。



(a) 省煤器清洁因子原始数据去噪结果对比
(a) Comparison of denoising results for the original data of cleanliness factor of economizer



(b) 省煤器清洁因子原始数据去噪结果对比 (局部放大)
(b) Comparison of denoising results for the original data of cleanliness factor of economizer (local zoom)




(c) 数据采样后的省煤器积灰段清洁因子数据
(c) Sampled cleanliness factor for the economizer's ash accumulation section

图 5 对省煤器清洁因子数据进行去噪、积灰段提取与采样


Fig. 5 Denoising, ash accumulation section extraction and sampling for cleanliness factor of economizer

3.3 消融实验

为了对所提基于两步分解的 HBA-NBEATS 的燃煤电站锅炉能效预测模型进行客观的性能评估,本文通过



(a) 省煤器积灰段清洁因子REMD分解结果
(a) REMD decomposition results of the cleanliness factor for economizer's ash accumulation section




(b) 省煤器积灰段清洁因子REMD高频分量IMF1的VMD分解结果
(b) VMD decomposition results of the REMD-derived high-frequency component IMF1 for the cleanliness factor in economizer's ash accumulation section

图 6 省煤器积灰段清洁因子两步分解结果


Fig. 6 Two-step decomposition results of the cleanliness factor for economizer's ash accumulation section

消融实验进行对比,其中包括 NBEATS、HBA-NBEATS、VMD-NBEATS、REMD-NBEATS、VMD-HBA-NBEATS、REMD-HBA-NBEATS、REMD-VMD-NBEATS、REMD-VMD-HBA-NBEATS 8 种模型的预测结果对比。对于经过数据预处理后的省煤器和再热器积灰段清洁因子数据,采用前 350 个数据作为训练集,后面余下的数据作为测试集用来实施模型性能评价。这两个清洁因子数据的预测消融实验结果曲线对比分别如图 8 和 9 所示,模型性能评价指标对比结果如表 1 和图 10 所示。

由图 8 可知,在省煤器积灰段清洁因子预测结果对比中,本文所提 REMD-VMD-HBA-NBEATS 方法预测曲线最贴近真实值曲线,特别是在峰值的预测中最接近真实曲线峰值,因此预测精度最高。单一 NBEATS 模型的预测曲线不能很好的跟随清洁因子的退化曲线,而在加



(a) 再热器积灰段清洁因子REMD分解结果
(a) REMD decomposition results of the cleanliness factor for reheater's ash accumulation section



(b) 再热器积灰段清洁因子REMD高频分量IMF1的VMD分解结果
(b) VMD decomposition results of the REMD-derived high-frequency component IMF1 for the cleanliness factor in reheater's ash accumulation section

图 7 再热器积灰段清洁因子两步分解结果

Fig. 7 Two-step decomposition results of the cleanliness factor for reheater's ash accumulation section

入全局寻优能力强的 HBA 算法后,预测效果有所提升。REMD-NBEATS 模型和 VMD-NBEATS 模型比单一 NBEATS 和 HBA-NBEATS 的预测性能有一定提高,其中 REMD-NBEATS 预测效果提升高一些。同样地,这两个基于一步分解的 NBEATS 方法在加入 HBA 算法后,预测性能进一步提高。在同样不使用 HBA 优化算法的情况下,基于两步分解的 NBEATS 模型明显比基于一步分解的 NBEATS 模型的预测精度更高。再热器积灰段清洁因子预测消融实验结果对比如图 9 所示,可以明显看出本文提出的基于两步分解的 HBA-NBEATS 方法的预测效果最好,而其他模型的预测性能对比与在省煤器数据中的对比是类似的。

由表 1 和图 10 中的模型性能评价指标对比结果可以看出,本文所提的 REMD-VMD-HBA-NBEATS 模型具有最佳的预测性能,其中在省煤器数据中 RMSE 为 0.188 2, R^2 为 0.982 9, MAE 为 0.167 0;在再热器数据中, RMSE 为 0.025 3, R^2 为 0.999 3, MAE 为 0.020 3。在省煤器数据的预测结果对比中,本文方法的 RMSE、




图 8 省煤器积灰段清洁因子预测消融实验结果
Fig. 8 Ablation experiment results for the prediction of cleanliness factor in economizer's ash accumulation section





图 9 再热器积灰段清洁因子预测消融实验结果
Fig. 9 Ablation experiment results for the prediction of cleanliness factor in reheater's ash accumulation section

表 1 消融实验模型性能评价指标

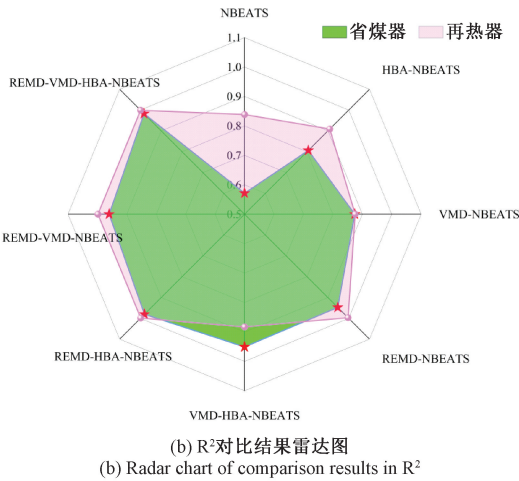
Table 1 Evaluation metrics for model performance in ablation experiment

数据集	模型	RMSE	R ²	MAE
省煤器	NBEATS	0. 943 2	0. 571 3	0. 878 0
	HBA-NBEATS	0. 632 7	0. 806 2	0. 516 4
	VMD-NBEATS	0. 509 6	0. 874 3	0. 473 5
	REMD-NBEATS	0. 329 0	0. 947 6	0. 296 0
	VMD-HBA-NBEATS	0. 318 1	0. 951 0	0. 301 0
	REMD-HBA-NBEATS	0. 199 0	0. 980 8	0. 171 9
	REMD-VMD-NBEATS	0. 287 2	0. 960 1	0. 262 5
	REMD-VMD-HBA-NBEATS	0. 188 2	0. 982 9	0. 167 0
	NBEATS	0. 378 1	0. 838 7	0. 341 2
再热器	HBA-NBEATS	0. 283 4	0. 909 4	0. 256 4
	VMD-NBEATS	0. 331 6	0. 875 9	0. 272 8
	REMD-NBEATS	0. 048 6	0. 997 3	0. 036 7
	VMD-HBA-NBEATS	0. 322 0	0. 883 0	0. 302 9
	REMD-HBA-NBEATS	0. 032 7	0. 998 8	0. 026 3
	REMD-VMD-NBEATS	0. 038 5	0. 998 3	0. 028 8
	REMD-VMD-HBA-NBEATS	0. 025 3	0. 999 3	0. 020 3


R² 和 MAE 比预测效果最差的单一 NBEATS 模型分别提升了 80. 05%、72. 05% 和 80. 98%，比预测性能次优的 REMD-HBA-NBEATS 模型提升了 5. 43%、0. 21% 和 2. 85%。在再热器数据的预测结果对比中, 本文模型的



(a) Radar chart of comparison results in RMSE/%



(b) Radar chart of comparison results in R^2



(c) Radar chart of comparison results in MAE/%

图 10 模型性能评价指标对比结果雷达图
Fig. 10 Radar chart of the comparison results of model performance evaluation indicators

RMSE、 R^2 和 MAE 比预测效果最差的单一 NBEATS 模型分别提升了 93.31%、19.15% 和 94.05%，比预测性能次优的 REMD-HBA-NBEATS 模型提升了 22.63%、0.05%

和 22.81%。因此,采用 REMD-VMD 两步分解法,并使用 HBA 优化算法对 NBEATS 模型的超参数进行优化,能够显著提升模型的预测精度。此外,本文所提方法与 REMD-HBA-NBEATS 对比时,性能指标提高幅度有限而时间代价相应增加,这一矛盾需在燃煤电站锅炉能效预测及后续吹灰策略制定的实际应用中综合考量后确定。

3.4 对比实验

为进一步验证所提 REMD-VMD-HBA-NBEATS 方法的优越性能,以再热器为例,在相同初始条件下,将其预测结果与 REMD-VMD-HBA-LSTM、REMD-VMD-HBA-TCN 模型进行对比。如图 11 与表 2 所示,本文方法明显优于对比模型,其 RMSE、 R^2 和 MAE 比 REMD-VMD-HBA-LSTM 提升了 92.77%、15.95% 和 91.64%,比 REMD-VMD-HBA-TCN 分别提升了 95.45%、53.31% 和 95.91%。综上,本文方法预测性能显著优于现有 LSTM、TCN 等主流算法,从而进一步验证了所提方法的有效性。




图 11 对比实验预测结果

Fig. 11 Comparative experiment prediction results

表 2 对比实验模型性能评价指标
Table 2 Evaluation metrics for model performance in comparative experiment

模型	RMSE	R^2	MAE
REMD-VMD-HBA-LSTM	0.349 9	0.861 8	0.242 7
REMD-VMD-HBA-TCN	0.555 5	0.651 8	0.496 5
REMD-VMD-HBA-NBEATS	0.025 3	0.999 3	0.020 3

4 结 论

燃煤电站锅炉受热面积灰是造成能效下降甚至引发安全事故的重要因素之一,而解决该问题的重要手段在于对锅炉受热面能效水平的精确预测。为了提高能效的预测准确度,本文提出了一种新型的 REMD-VMD-HBA-NBEATS 能效预测模型。该方法采用小波阈值理论实施去噪,能够更清晰的呈现原始数据的变化趋势;使用鲁棒性和自适应性更强的 REMD 对非线性非平稳的清洁因

子数据进行分解,得到具有更高精度和可靠性的模态分量;对 REMD 分解后的具有较强非线性的高频分量采用 VMD 进行二次分解,有效提升预测模型的精度。然后,使用具有可解释性的 NBEATS 模型对每个分量进行建模预测;为解决 NBEATS 中超参数易陷入局部最优而导致的预测精度下降问题,采用 HBA 算法可快速实现对 NBEATS 全局最优超参数的搜索,简化人工调参的繁琐步骤,由此迅速提升模型的预测准确度,实现模型性能的最优化。通过消融实验的对比发现,本文模型明显优于其他模型,其中 RMSE 性能提升幅度达 5.43% 至 93.31%; R^2 提高至 0.98 以上;MAE 降至 0.000 2 的最低水平。此外,相较于 LSTM、TCN 等主流预测方法,本文所提方法的预测精度存在显著优势。

综上所述,本文构建的基于两步分解的 HBA-NBEATS 燃煤电站锅炉能效预测方法能够保持较高的预测准确度和模型效率,为后续吹灰策略的优化及科学化制定提供了重要的理论参考与技术支持。未来工作将致力于机理-数据-知识混合驱动的燃煤电站数字孪生能效预测及优化研究,实现主要能耗设备和系统的自适应动态评估和能效优化,进一步发掘燃煤电站的节能减排潜力。

参考文献

- [1] 孟国情,邱晓燕,张明珂,等.计及柔性负荷和换电站的综合能源系统优化调[J].电子测量技术,2023,46(14): 138-145.
- [2] SHI Y H, WANG J C, LIU Z. On-line monitoring of ash fouling and soot-blowing optimization for convective heat exchanger in coal-fired power plant boiler[J]. Applied Thermal Engineering, 2015(78): 39-50.
- [3] 张泽慧,史元浩.基于 Gamma 加速积灰模型的燃煤锅炉吹灰优化[J].电子测量与仪器学报,2020,34(8): 8-14.
- [4] 付周,邹恒斐,袁景淇.基于 XGBoost 的小型循环流化床锅炉吹灰方案优化[J].控制工程,2025,32(5): 891-896.
- [5] ZHANG S, SHEN G H, AN L S, LI G. Ash fouling monitoring based on acoustic pyrometry in boiler furnaces[J]. Applied Thermal Engineering, 2015(84): 74-81.
- [6] 史元浩,李强,曾建潮,等.基于增量分布的燃煤电厂锅炉受热面吹灰优化研究[J].动力工程学报,2019,39(10): 777-783.
- [7] 史元浩,陈晓龙,温杰,等.基于受热面健康状态预测的电站锅炉吹灰优化[J].电子测量与仪器学报,2019,33(12): 134-138.
- [8] XU S S, SHEN C, WANG K Y, et al. Modelling and simulation of ash accumulation in SP boiler of decomposition kiln[J]. Progress in Computational Fluid Dynamics, 2023, 23(1): 52-63.
- [9] ZHU M X, LU H, ZHAO W J, et al. A numerical study of ash deposition characteristics in a 660MW supercritical tangential boiler[J]. Advanced Theory and Simulations, 2023, DOI:10. 1002/ adts. 202300133.
- [10] 韩天翔,史元浩,李孟威,等.融合 CEEMD 和 TCN 的受热面积灰预测研究[J].电子测量与仪器学报,2022,36(10): 108-114.
- [11] 魏玮,吕游,齐欣宇,等.基于 CNN-LSTM-AM 动态集成模型的电站风机状态预测方法[J].仪器仪表学报,2023,44(4): 19-27.
- [12] 王楠,胡永涛,王康杰,等.融合 TVF-EMD 和 CNN-GRU 锅炉受热面能效预测[J].电子测量与仪器学报,2024,38(9): 67-75.
- [13] LIU Z L, PENG D D, ZUO M J, et al. Improved

- Hilbert-Huang transform with soft sifting stopping criterion and its application to fault diagnosis of wheelset bearings[J]. ISA Transactions, 2022, 125: 426-444.
- [14] 高凯悦, 牟莉. 基于二次分解和 GRU-attention 的时间序列预测研究[J]. 国外电子测量技术, 2023, 42(2): 80-87.
- GAO K Y, MU L. Research on time series forecasting based on quadratic decomposition and GRU-attention[J]. Foreign Electronic Measurement Technology, 2023, 42(2): 80-87.
- [15] ORESHKIN B N, CARPOV D, CHAPADOS N, et al. N-BEATS: Neural basis expansion analysis for interpretable time series forecasting[C]. Proceedings of the International Conference on Learning Representations (ICLR). 2020. arXiv: 1905.10437.
- [16] ORESHKIN B N, DUDEK G, PELKA P, et al. N-BEATS neural network for mid-term electricity load forecasting[J]. Applied Energy, 2021, 293: 116918.
- [17] MA X, YAN B, WANG H, et al. Decision-level machinery fault prognosis using N-BEATS-based degradation feature prediction and reconstruction[J]. Mechanical Systems and Signal Processing, 2023, 198: 110435.
- [18] LIN H, WANG C. DIGWO-N-BEATS: An Evolutionary Time Series Prediction Method for Situation Prediction[J]. Information Sciences, 2024, 664: 120316.
- [19] HASHIM F A, HOUSSEIN E H, HUSSAIN K, et al. Honey Badger Algorithm: New metaheuristic algorithm for solving optimization problems[J]. Mathematics and Computers in Simulation, 2022, 192: 84-110.
- [20] 令宁, 安旺成, 周芸, 等. 基于 HBA-SVR 的光伏发电量预测模型研究[J]. 电气应用, 2023, 42(2): 72-78.
- LING N, AN W CH, ZHOU Y, et al. Research on prediction model of photovoltaic power generation based on HBA-SVR[J]. Electrotechnical Application, 2023, 42(2): 72-78.
- [21] 朱婷, 颜七笙. 基于 CEEMDAN 和 HBA-BiGRU-SelfAttention 的短期负荷预测[J]. 南京信息工程大学学报, 2025, 17(4): 478-493.
- ZHU T, YAN Q SH. Short-term load prediction based on CEEMDAN and HBA-BiGRU-SelfAttention [J/OL]. Journal of Nanjing University of Information Science and Technology, 2025, 17(4): 478-493.

作者简介



崔方舒, 2018 年于上海交通大学获得工学博士学位, 现为中北大学计算机科学与技术学院讲师, 主要研究方向为复杂系统预测与健康管理、机器学习。

E-mail: fscui@nuc.edu.cn

Cui Fangshu received her Ph. D. degree from Shanghai Jiao Tong University in 2018. Now she is a lecturer at the School of Computer Science and Technology in North University of China. Her main research interests include prognostics and health management of complex systems, machine learning.



史元浩 (通信作者), 2015 年于上海交通大学获得工学博士学位, 现为中北大学电气与控制工程学院副教授、硕士生导师。主要研究方向为复杂系统预测与健康管理、机器学习和数字孪生。

E-mail: yhshi@nuc.edu.cn

Shi Yuanhao (Corresponding author) received his Ph. D. degree from Shanghai Jiao Tong University in 2015. Now he is an associate professor, M. Sc. supervisor at the School of Electrical and Control Engineering in North University of China. His main research interests include prognostics and health management of complex systems, machine learning and digital twin.