

基于CEEMDAN-KELM的锅炉对流受热面状态预测研究

董利斌,杨程,赵海晓,刘传奇

(浙江大唐乌沙山发电有限责任公司,浙江宁波315722)

摘要:为了解决表征锅炉受热面表面健康状态的清洁因子在未来时间段内预测时呈现非平稳问题,以省煤器受热面为例,提出一种结合核极限学习机(Kernel Extreme Learning Machine, KELM)和自适应噪声完备集成经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)的清洁因子预测方法。首先,通过CEEMDAN分解算法对省煤器表面清洁因子序列进行分解和降低复杂程度,获得各固有模态函数(Intrinsic Mode Function, IMF);其次,利用皮尔逊相关性分析确定主蒸汽流量、进出口烟温等9个参数为输入,建立核极限学习机模型对清洁因子的各IMF进行预测;最后,将各IMF预测结果相加获得最终预测结果。结果表明:与基本核极限学习机、支持向量机等预测模型相比,本文模型具有较高的预测精度和较优预测时间,可为基于受热面状态开展的锅炉智慧吹灰应用提供参考。

关键词:受热面;清洁因子;核极限学习机;自适应噪声完备集成经验模态分解

中图分类号:TK223.3 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2023.06.014

[引用本文格式]董利斌,杨程,赵海晓,等.基于CEEMDAN-KELM的锅炉对流受热面状态预测研究[J].热能动力工程,2023,38(6):122-128. DONG Li-bin, YANG Cheng, ZHAO Hai-xiao, et al. Prediction and research of boiler convection heating surface state based on CEEMDAN-KELM[J]. Journal of Engineering for Thermal Energy and Power, 2023, 38(6): 122-128.

Prediction and Research of Boiler Convection Heating Surface State based on CEEMDAN-KELM

DONG Li-bin, YANG Cheng, ZHAO Hai-xiao, LIU Chuan-qi

(Zhejiang Datang Wushashan Power Generation Co., Ltd., Ningbo, China, Post Code:315722)

Abstract: In order to solve the non-stationary problem when the cleaning factor that characterizes the health state of the boiler heating surface is predicted in the future time period, taking the heating surface of the economizer as an example, this paper proposed a cleaning factor prediction method combining the kernel extreme learning machine (KELM) and complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN). Firstly, CEEMDAN algorithm was used to decompose and reduce the complexity of the surface cleaning factor sequence of the economizer, and the intrinsic modal functions (IMF) were obtained; secondly, Pearson correlation analysis was used to determine nine parameters such as main steam flow, inlet and outlet smoke temperatures, etc. as the input, and the KELM model was established to predict each IMF of cleaning factor; finally, the final forecast result was obtained by summing the IMF forecast results. The result shows that compared with several prediction models such as basic KELM and SVM, the model presented in this paper has higher prediction accuracy and better prediction time, which can provide reference for the application of intelligent soot blowing in boiler based on the state of heating surface.

Key words: heating surface, cleaning factor, kernel extreme learning machine (KELM), complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN)

引言

作为当前主流发电形式,燃煤机组在运行过程中,各受热面不可避免的发生积灰和结渣。而掺烧与设计煤种差异较大的煤种,则增加上述缺陷发生频率,造成锅炉整体效率下降,影响机组的安全与经济运行^[1]。虽然锅炉自炉膛到尾部烟道各受热面已增设吹灰系统,但仅根据运行经验或受热面壁温参数进行吹灰,或导致“过吹”,造成蒸汽损耗增加和受热面吹损严重;或导致“欠吹”,造成吹灰不净和受热面传热效率降低^[2]。因此,建立精准的受热面积灰监测模型,在线掌握受热面表面状态,对运行人员吹灰操作具有重要意义。

针对受热面积灰监测和吹灰研究,国内外学者已开展相关研究。Tong 等人^[3]通过小波分析和支持向量机算法建立低温过热器热阻监测模型,经测试,模型准确率不低于 98.5%;阎维平等^[4]人和徐力刚等人^[5]分别建立稳定负荷和变负荷工况下对流受热面的积灰监测模型;贾志琴等人^[6]采用 Elman 神经网络建立受热面积灰结渣预测模型,但因属于长期滚动预测,模型预测误差将会不断累积;Sivathanu 等人^[7]以对流管束的积灰层高度为表征对象,进行吹灰方式的优化;耿欣等人^[8]设计了基于模型驱动的吹灰优化方案,然而因吹灰不确定因素较大导致实际应用受限。

本文以清洁因子作为受热面清洁状态的表征参数,并采用自适应噪声完备集成经验模式分解和核极限学习机相结合的预测方法,建立 CEEMDAN-KELM 预测模型。该模型充分利用 CEEMDAN 对波动数据的高效处理能力和 KELM 的精准预测能力,实现锅炉受热面积灰状态的实时预测,并为吹灰运行提供及时指导。

1 预测算法原理

1.1 自适应噪声完备集成经验模式分解

作为经典信号处理手段,经验模式分解算法广泛应用于信号提取领域^[9]。尽管可较好处理非线性信号,但实际应用时易发生模态混频现象。对此,

Wu 等人^[10]提出集成经验模式分解方法,即对信号增加噪声以消除模态混频,然而该方法因白噪声未能完全消除会产生较大重建误差。Zhang 等人^[11]提出自适应噪声完备集成经验模式分解方法,通过添加自适应白噪声,在解决模态混频的同时,消除重构误差。该算法步骤如下:

(1) 将自适应白噪声加入到待分解信号 $y(t)$ 中,获得新信号 $z(t)$,对新信号进行经验模态(Empirical Mode Decomposition, EMD)分解,获得第 1 个本征模态分量 $C_1(t)$ 。

(2) 对 N 个模态分量进行总体平均,获得 CEEMDAN 分解第 1 个本征模态分量 $\bar{C}_1(t)$ 。

$$\bar{C}_1(t) = \frac{1}{N} \sum_{j=1}^n C_j(t) \quad (1)$$

式中: N —模态分量个数; $C_1(t)$ —第 1 个本征模态分量; j —第 j 个模态分量。

(3) 计算去除第 1 个本征模态分量得残余量 $r_1(t)$:

$$f_1(t) = y(t) - \bar{C}_1(t) \quad (2)$$

式中: $r_1(t)$ —原始信号去除第 1 个本征模态分量后余量。

(4) 在 $r_1(t)$ 中加入正负成对自适应白噪声获得新信号,以新信号为载体进行 EMD 分解,得到第 1 阶模态分量 $D_1(t)$ 。由此可获得 CEEMDAN 分解的第 2 个本征模态分量 $C_2(t)$ 。

$$\bar{C}_2(t) = \frac{1}{N} \sum_{j=1}^n C_j(t) \quad (3)$$

式中: $C_2(t)$ —第 2 个本征模态分量。

(5) 计算去除第 2 个模态分量后的残差 $r_2(t)$ 。

$$r_2(t) = r_1(t) - \bar{C}_2(t) \quad (4)$$

式中: $r_2(t)$ —去除第 2 模态分量后的残差。

(6) 重复上述步骤,直到获得的残差信号为单调函数时算法结束。此时得到的本征模态分量数量为 K ,则原始信号 $y(t)$ 被分解:

$$y(t) = \sum_{k=1}^K \bar{C}_k(t) + r_k(t) \quad (5)$$

式中: $\bar{C}_k(t)$ —第 k 个本征模态分量; $r_k(t)$ —去除第 k 模态分量后的残差。

1.2 KELM 预测模型原理介绍

为对受热面状态参数进行精准预测,本文基于

遗传算法优化的核函数,建立核极限学习机预测模型。

极限学习机(Extreme Learning Machine, ELM, ELM)是由 Huang 等人^[12]提出的一种单隐藏层前向神经网络,较 BP 神经网络需要更少的人工调整参数,可在较短时间内实现样本数据的训练,具有学习速率快、泛化能力强的特点。其回归函数与输出层权值为:

$$\begin{cases} f(x) = \mathbf{h}(x)\beta = \mathbf{H}\beta \\ \mathbf{H}^T \left(\frac{1}{C} + \mathbf{H}\mathbf{H}^T \right)^{-1} T \end{cases} \quad (6)$$

式中: $f(x)$ —模型输出; x —样本输入; $\mathbf{h}(x)$ 和 \mathbf{H} —隐藏层映射矩阵; β —隐藏层与输出层连接权值; C —正则化参数; T —样本输出向量。

当样本参数存在潜在共线性现象时,常规 ELM 预测模型(采用最小二乘法求解)趋于不稳定输出。因此,Huang 等人^[12]采用核函数优化的核极限学习机(KELM)。基于核函数原理,KELM 可将共线性的输入样本投射至高维空间,从而显著提高模型的拟合与泛化能力。此外,本模型无需人工设置隐藏层节点数目,减少空间训练位数和训练时间。模型输出公式为:

$$f(x) = \begin{bmatrix} K(x, x_1) \\ K(x, x_N) \end{bmatrix}^T \left(\frac{1}{C} + \boldsymbol{\Omega}_{\text{ELM}} \right)^{-1} \quad (7)$$

式中: $K(x, x_j)$ —核函数; $\boldsymbol{\Omega}_{\text{ELM}}$ —核矩阵,其计算公式为:

$$\begin{cases} \boldsymbol{\Omega}_{\text{ELM}} = \mathbf{H}\mathbf{H}^T \\ \boldsymbol{\Omega}_{\text{ELM},ij} = h(x_i)h(x_j) = K(x_i, x_j) \end{cases} \quad (8)$$

式中: x_i 和 x_j —样本输入向量, i 和 j 取 $[1, N]$ 内的正整数; $K(x_i, x_j)$ —核函数,本文中核函数采用 RBF 核函数,即:

$$K(x_i, x_j) = \exp\left(-\frac{\|x - x_i\|^2}{\gamma}\right) \quad (9)$$

式中: γ —核函数参数。

1.3 CEEMDAN-KELM 预测模型框架

本文所提出的预测受热面清洁因子序列的 CEEMDAN-KELM 模型流程框架如图 1 所示。首先,对根据传热机理所获得的省煤器清洁因子信号

采用 CEEMDAN 算法进行分解,获得多个模态分量和一个残差;然后,以锅炉负荷、进出口烟温等 9 个参数作为输入,建立 KELM 模型对清洁因子的各模态分量分别进行预测;最后,将各模态分量预测结果合并,获得最终省煤器清洁因子的预测结果。

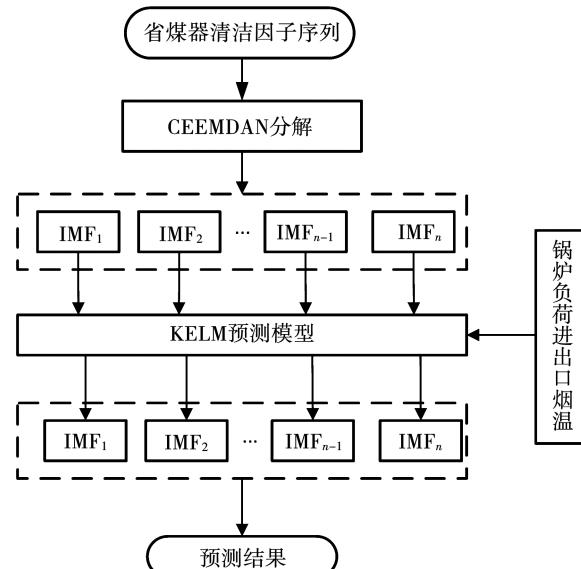


图 1 CEEMDAN-KELM 预测框架

Fig. 1 Prediction framework of CEEMDAN-KELM model

2 相关性分析

2.1 数据描述

所用的模型构建及训练均基于 Tensorflow 的 Keras 框架下进行。硬件平台采用 Intel Core i7 9750H, 2.6 GHz, 8 G 内存下运行。以某机组锅炉省煤器作为研究对象,选取其 DCS 部署的智慧吹灰系统某段时间内的清洁因子变化数据(清洁因子计算方法见文献[5])以及锅炉负荷、进出口烟温等众多参数开展预测研究。实验数据选取自某次吹灰时刻起的两个吹灰周期内省煤器清洁因子的变化情况。图 2 为反映省煤器受热面清洁因子变化趋势图。由图可知,吹灰后受热面的清洁因子最高,随着运行时间的增加,受热面积灰逐渐增加,对应的受热面清洁因子逐渐增加,而当积灰至一定程度达到动态平衡,此时清洁因子将在较小范围内波动。在此工况下,省煤器换热效率降低,烟气热量传递至工质的阻力增加,省煤器出口排烟温度将升高。

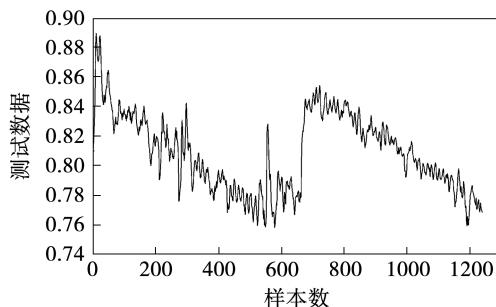


图2 省煤器受热面清洁因子变化趋势

Fig. 2 Change trend of cleaning factor on heating surface of economizer

2.2 数据预处理

由于模型中各参数的数值范围不同,且某些参数的数值跨度较大,对预测模型训练精度造成较大影响。为此,本文在模型训练前,首先对数据采用归一化处理,转化为 $[0, 1]$ 区间内数值。归一化公式为:

$$x = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (10)$$

式中: x —变量的归一化值; X —变量的原始值。

2.3 变量相关性分析

为对锅炉受热面清洁因子与相关因素间的影响程度进行分析,采用皮尔逊相关性系数^[13-14]进行预处理。该系数可表征随机变量 X 与 Y 相关程度,取值范围在 $[-1, 1]$ 。相关系数绝对值越大,表明 X 与 Y 相关度越高。计算公式为:

$$\rho_{X,Y} = \frac{\text{cov}(X, Y)}{\delta_X \delta_Y} = \frac{E((X - \mu_X)(Y - \mu_Y))}{\delta_X \delta_Y} \quad (11)$$

式中: δ_X, δ_Y —样本 X, Y 标准差; μ_X, μ_Y —样本 X, Y 平均值。

选取排烟温度、主汽流量、主汽压力、汽包压力和省煤器出口烟温等14个影响因素,与尾部烟道高温省煤器清洁因子进行相关性分析。部分影响因素与清洁因子的皮尔逊相关性系数如下:排烟温度与省煤器清洁因子的皮尔逊相关系数为-0.3112,主汽流量与省煤器清洁因子的皮尔逊相关系数为0.3561,主汽温度与省煤器清洁因子的皮尔逊相关系数为0.2636,省煤器出口烟温与省煤器清洁因子为0.4840。

以省煤器出口排烟温度与清洁因子为例,两者

间相关性系数为0.4840,表明两者负相关,即省煤器出口烟温越高,清洁因子越小。以此为依据,选取对清洁因子影响较大的排烟温度、主汽流量、主汽温度、省煤器入口水温、省煤器入口烟温、省煤器出口烟温、给煤量、给水流量和省煤器出口水温9个参数作为主要因素,置入模型作为模型输入,以省煤器清洁因子经CEEMDAN分解后的各模态分量作为输出,采用KELM模型进行预测。

3 仿真实验

3.1 误差指标

为评估本文模型有效性,并与其他模型进行对比,引入均方根误差(RMSE)和平均绝对百分比误差(MAPE)两个性能评价参数,计算公式为:

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

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (13)$$

式中: n —样本总数; i —第 i 个样本; y_i —第 i 个样本对应数值; \hat{y}_i —样本预测值。

3.2 基于CEEMDAN-KELM的受热面清洁因子预测

在利用KELM进行预测时,利用遗传算法对KELM模型参数进行寻优。其中,遗传算法设置为:进化代数为100,种群个数为8,交叉概率为0.85,变异概率为0.15。优化后的正则化系数 $\gamma = 680$,核参数 $\sigma^2 = 1$ 。

为降低省煤器受热面清洁因子序列数据的复杂程度,本文将信号分解和深度学习耦合建立预测模型。为验证本文所提出模型的有效性,分别建立支持向量机(SVM)、极限学习机(ELM)、核极限学习机(KELM)、经验模态分解-核极限学习机(EMD-KELM)等对比模型。其中SVM、ELM、KELM为直接对清洁因子信号进行预测;EMD-KELM建模流程与本文所提模型类似,区别在于其采用EMD进行信号的分解。图3为清洁因子时序信号经CEEMDAN分解后各IMF的分布情况。由该图可看出,分解后各IMF的复杂程度明显降低,且高频IMF的变化规律更加明显,这有利于后续预测模型精度的提升。

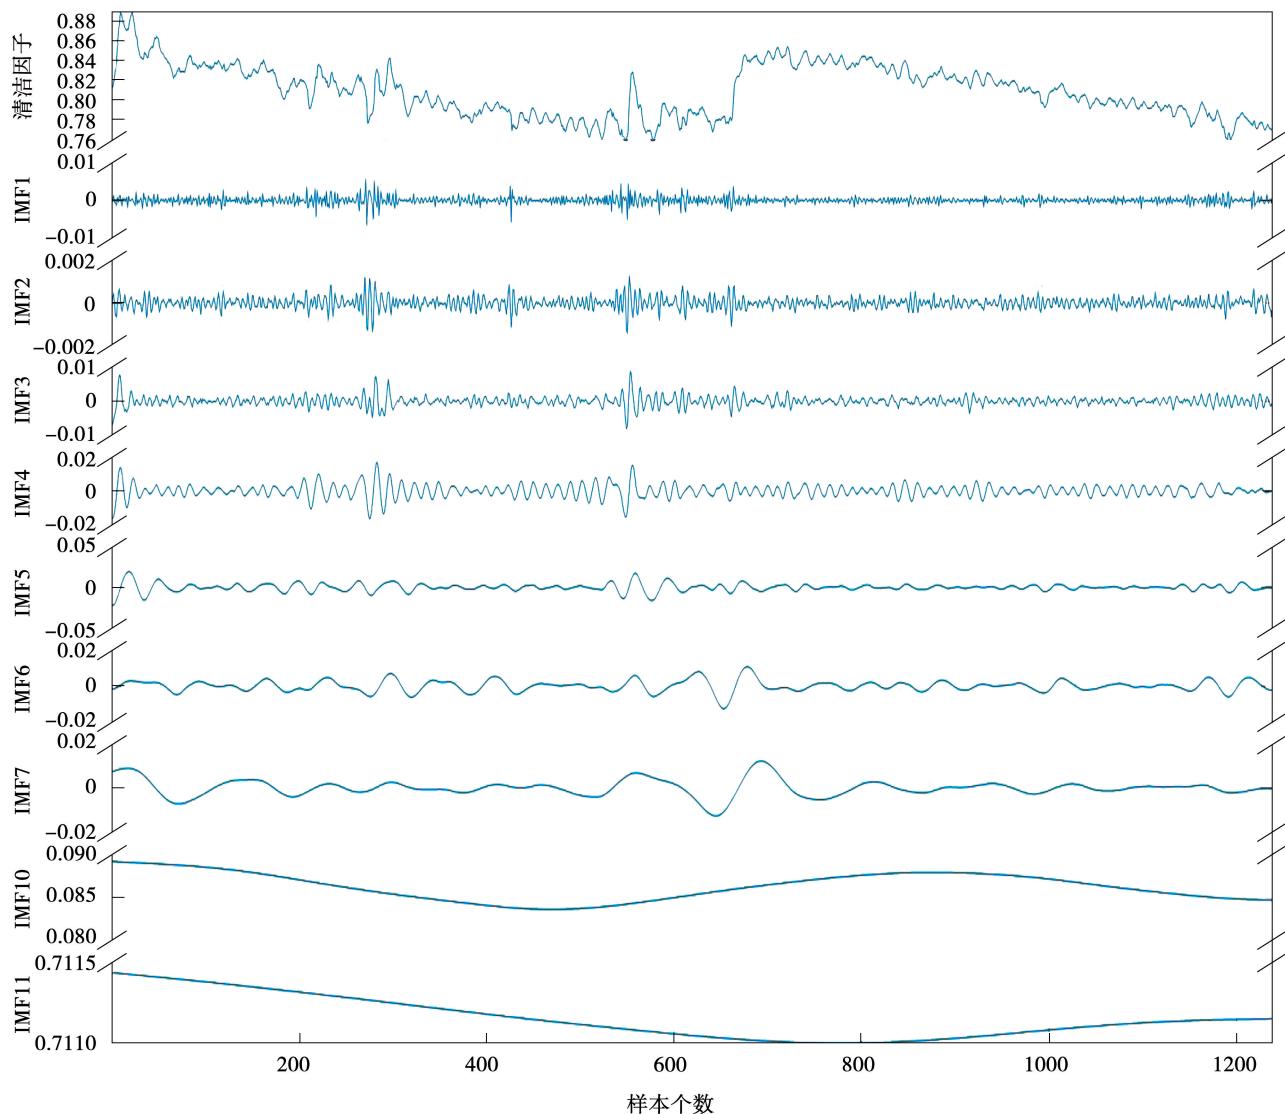


图 3 省煤器受热面清洁因子序列 CEEMDAN 分解

Fig. 3 CEEMDAN decomposition of cleaning factor sequence of heating surface of economizer

图 4 和图 5 分别为各模型对省煤器清洁因子的预测结果及对应的相对误差。

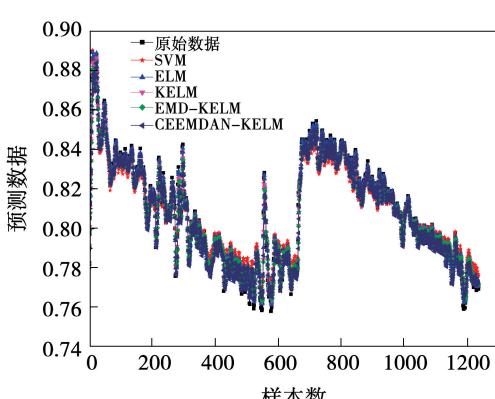


图 4 省煤器清洁因子预测结果

Fig. 4 Prediction results of cleaning factor of economizer

各模型的误差指标如表 1 所示。由图 4 和图 5 可看出, CEEMDAN-KELM 模型具有最高的预测精度,且鲁棒性更好。其中, SVM、ELM、KELM 模型和 EMD-KELM 模型的最大相对误差分别为 20.91%, 28.70%, 32.25% 和 31.31%, 而 CEEMDAN-KELM 模型的最大相对误差为 11.26%, 明显低于其模型。

由表 1 可知, CEEMDAN-KELM 模型具有最低的预测误差。与 KELM 模型相比, RMSE、MAE 和 MAPE 分别降低了 25.45%, 25.17% 和 25.10%, 较 EMD-KELM 模型的 RMSE、MAE 和 MAPE 分别降低了 14.73%, 5.31% 和 23.83%, 说明清洁因子信号通过 CEEMDAN 分解后,可使复杂度降低,可预测性提高。

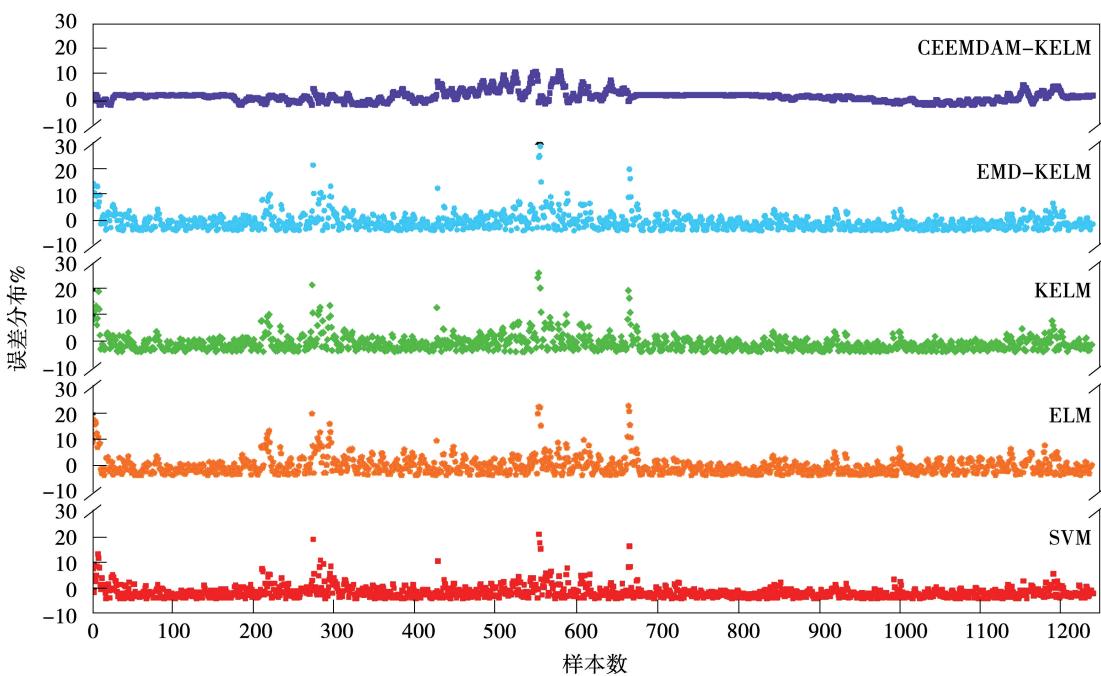


图5 各模型相对误差

Fig. 5 Relative error of each model

表1 各模型的误差指标

Tab. 1 Error indicators of each model

模型	RMSE	MAE	MAPE/%
CEEMDAN-KELM	0.024 9	0.010 7	1.79
EMD-KELM	0.029 2	0.011 3	2.35
KELM	0.033 4	0.014 3	2.39
ELM	0.028 6	0.016 3	2.44
SVM	0.036 5	0.028 4	2.57

参考文献:

- [1] 陈刚,方庆艳,张成,等.电站锅炉配煤掺烧及经济运行[M].北京:中国电力出版社,2013.
CHEN Gang, FANG Qing-yan, ZHANG Cheng, et al. Coal blending and economic operation of utility boilers [M]. Beijing: China Electric Power Press, 2013.
- [2] 苏春莉.火电厂锅炉吹灰控制系统的设计与实现[D].西安:西安电子科技大学,2012.
SU Chun-li. The design and implementation of thermal power boiler soot blowing control system [D]. Xi'an: Xidian University, 2012.
- [3] TONG S,ZHANG X,TONG Z, et al. Online ash fouling prediction for boiler heating surfaces based on wavelet analysis and support vector regression[J]. Energies,2020,13(1):59-67.
- [4] 阎维平,朱予东,谭蓬,等.变负荷工况下锅炉对流受热面污染的监测[J].动力工程,2007,27(1):58-61.
YAN Wei-ping, ZHU Yu-dong, TAN Peng, et al. Ash fouling monitoring of boiler's convective heat-delivery surfaces during variable load operation [J]. Journal of Power Engineering, 2007, 27 (1): 58-61.
- [5] 徐力刚,黄亚继,岳俊峰,等.600 MW超临界锅炉半辐射受热面积灰监测模型研究[J].动力工程学报,2015,35(11):871-877.
XU Li-gang, HUANG Ya-ji, YUE Jun-feng, et al. Monitoring model

4 结论

结合自适应噪声完备集成经验模态分解算法和核极限学习机,建立锅炉典型对流受热面-省煤器清洁因子预测模型,得到以下结论:

(1) 模型采用的自适应噪声完备集成经验模态分解算法能够降低清洁因子信号序列数据的复杂程度,进而提升核极限学习机预测模型对各固有模态函数的可预测性。

(2) 相较于EMD-KELM、KELM等模型,本文所提模型的MAPE、RMSE等评价指标降低5.31%~25.45%之间,表明模型在对省煤器清洁因子时序信号进行预测时具有较高精度,能够为锅炉受热面吹灰的运行调度和节能提供参考。

- for ash fouling on semi-radiation heating surface of a 600 MW supercritical boiler [J]. Journal of Power Engineering, 2015, 35(11):871–877.
- [6] 贾志琴,史元浩,梁建宇,等.基于 Elman 神经网络的受热面积灰动态预测[J].电子测量与仪器学报,2019,33(9):50–56.
JIA Zhi-qin,SHI Yuan-hao,LIANG Jian-yu, et al. Dynamic prediction of heated area ash deposit based on Elman neural network [J]. Journal of Electronic Measurement and Instrumentation, 2019,33(9):50–56.
- [7] SIVATHANU A K,SUBRAMANIAN S. Extended Kalman filter for fouling detection in thermal power plant reheat[J]. Control Engineering Practice,2018,73:91–99.
- [8] 耿欣,林中达.锅炉灰污监测及吹灰优化预测模型的研究[J].发电设备,2011,25(2):91–93.
GENG Xin, LIN Zhong-da. On-line monitoring of ash fouling in boiler and predictive model for the soot-blowing optimization [J]. Power Equipment,2011,25(2):91–93.
- [9] MANJU B R,REMA P. A performance based comparative study on the modified version of empirical mode decomposition with traditional empirical mode decomposition [J]. Procedia Computer Science,2020,171:2469–2475.
- [10] WU Z H,HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis,2009,1(1):1–41.
- [11] ZHANG Z C,HONG W C. Electric load forecasting by complete ensemble empirical mode decomposition adaptive noise and support vector regression with quantum-based dragonfly algorithm [J]. Nonlinear Dynamics,2019,98(2):1107–1136.
- [12] HUANG G,HUANG G B,SONG S J, et al. Trends in extreme learning machines: a review [J]. Neural Networks, 2015, 61: 32–48.
- [13] 杨茂,马剑,李大勇,等.基于熵权综合关联度数据挖掘的风电功率实时预测研究[J].太阳能学报,2019,40(12):3578–3585.
YANG Mao, MA Jian, LI Da-yong, et al. Research on real time prediction of wind power based on entropy weight comprehensive association data mining [J]. Acta Energiae Solaris Sinica, 2019, 40(12):3578–3585.
- [14] 韩晟,韩坚舟,赵璇,等.距离权重改进的 Pearson 相关系数及应用[J].石油地球物理勘探,2019,54(6):1363–1370.
HAN Sheng,HAN Jian-zhou,ZHAO Xuan, et al. A Pearson correlation coefficient improved by spatial weight [J]. Oil Geophysical Prospecting, ,2019,54(6):1363 – 1370.

(姜雪梅 编辑)