

DOI: 10.13382/j.jemi.B2003090

融合 EMD 和 LSTM 的受热面积灰预测研究*

李孟威 史元浩 杨彦茹 张泽慧 刘文海

(中北大学 电气与控制工程学院 太原 030000)

摘要:针对锅炉受热面积灰将会降低传热效率和安全性,采用清洁因子作为健康指标来监测锅炉受热面健康状况,并且提出融合经验模态分解(EMD)和长短期记忆网络(LSTM)的模型来预测未来锅炉积灰。经验模态分解可以将时间序列分解为一系列频域稳定的本征模态函数,长短期记忆网络拥有记忆功能,它能够通过学习来挖掘时间序列之间隐藏的长期依赖关系,二者结合,增加了对于时间序列预测的准确度。通过仿真软件验证,该模型对锅炉受热面积灰状况的预测有较为满意的精度,并与两种常用模型进行对比发现,预测精度分别提升了 67.7%与 59.2%,验证了该模型的可行性与有效性。

关键词: 清洁因子;锅炉积灰;经验模态分解;长短期记忆网络

中图分类号: TN05;TK227 **文献标识码:** A **国家标准学科分类代码:** 470.20

Research on gray prediction of heated surface combining EMD and LSTM

Li Mengwei Shi Yuanhao Yang Yanru Zhang Zehui Liu Wenhai

(School of Electrical and Control Engineering, North University of China, Taiyuan 030000, China)

Abstract: In view of the fact that the ash in the heated surface of the boiler will reduce the heat transfer efficiency and safety, uses the cleanliness factor as a healthy indicator to monitor the health of the heated surface of the boiler, and proposes a model that combines empirical mode decomposition (EMD) and long short-term memory (LSTM) to predict future boiler ash deposit. EMD can decompose a time series into a series of intrinsic mode functions which are stable in frequency domain, both LSTM has a memory function, it can learn to mine hidden long-term dependencies between time series, the combination of the two increases the accuracy of time series prediction. It is verified by simulation software that the model has satisfactory accuracy in the prediction of the ash condition of the heated surface of the boiler, and compared with two commonly used models, it was found that the prediction accuracy increased by 67.7% and 59.2% respectively and the feasibility and validity of the model are verified.

Keywords: cleanliness factor; boiler ash deposit; empirical mode decomposition; long short-term memory

0 引言

现阶段我国火力发电站的发电方式主要依靠燃煤锅炉进行热电交换,而在燃煤过程中受热面将不可避免地产生积灰与结渣^[1]。随着受热面的健康状况不断变差,造成的后果可能会从传热效率的降低演变为停炉甚至是严重安全事故。吹灰操作对于维持受热面健康行之有效,但吹灰的频率却很难把控,过于频繁的吹灰带来的是

能源消耗巨大,受热面的寿命不断降低;而吹灰不彻底又会造成积灰的加重^[2-4]。所以预测未来受热面的灰污状况可以更好地指导吹灰操作。因此对于锅炉受热面的吹灰优化研究十分有必要。

众多研究学者已经对于灰污监测和吹灰优化进行研究,并取得一定的成果。Tong等^[5]结合小波分析和支持向量回归来建立低温过热器灰污热阻实时监测系统,并在测试集上获得98.5%的准确率。邓喆等^[6]使用BP神经网络建立起各种因素与理想炉膛出口烟温的非线性映

收稿日期:2020-04-24 Received Date: 2020-04-24

* 基金项目:国家自然科学基金(61533013)、山西省重点研发计划项目(201703D111011)、山西省自然科学基金(201801D121159)、山西省青年自然科学基金(201801D221208)、山西省研究生教育创新项目(2020SY405,2020SY408)资助

射,再利用理想炉膛出口烟温和实际炉膛出口烟温判断炉膛结渣状况。贾志琴等^[7]利用 Elman 神经网络建立锅炉受热面积灰结渣状况预测模型,但该预测方法属于长期滚动预测,预测误差的不断累积可能将最终使得预测结果失去意义。耿欣等^[8]采用基于模型驱动的吹灰优化方案,但积灰的影响因素较多,不确定性较大难以获得精确的模型,实际使用受到限制。王艳婷等^[9]采用的吹灰优化策略是一种统计分析的数据驱动实时预测方法,其向后预测时间有限,可能无法为吹灰操作预留一定的准备时间。

对此,针对现阶段吹灰优化方案欠佳,本文采用清洁因子 (clearness factor, CF) 来表征受热面健康状况^[10],由实际传热系数和理论传热系数的比值构成,具有提取难度小的特点。并采用经验模态分解 (empirical mode decomposition, EMD) 和长短期记忆网络 (long short term memory network, LSTM) 相结合的预测方式,建立了 EMD-LSTM 预测模型。该模型利用 EMD 对于波动性数据的处理能力以及 LSTM 对时间序列的预测能力来预测未来锅炉受热面积灰状况,并为吹灰操作预留足够时间。最后与常用模型 EMD-Elman 和 EMD-MLP 进行对比发现,所提模型可以获得较好的预测效果。

1 数据预处理

小波变换具有良好的局部时频分析能力^[11],在信号去噪方面具有一定优势。小波变换可以将信号分解为一系列不同尺度时间的小波函数的叠加,而这些小波函数均由一个小波母函数经过尺度伸缩以及平移来得到。在通常情况下,噪声信号所对应的小波分解系数幅值较小,通过阈值去噪的方法可以有效地过滤掉噪声。小波阈值去噪步骤如下。

1) 根据原始信号的特点确定小波基函数以及分解层数,对信号进行小波变换获得小波分解系数。

2) 选择合适的阈值函数^[12],对小波分解系数的幅值进行量化处理。本文采用软阈值函数对小波系数进行处理,软阈值去噪函数如下所示:

$$w\lambda \begin{cases} \operatorname{sgn}(w) \cdot (|w| - \lambda), & |w| \geq \lambda \\ 0, & |w| < \lambda \end{cases} \quad (1)$$

式中: $w\lambda$ 经过为软阈值函数处理的小波系数。

3) 对经过软阈值量化处理的小波系数进行逆小波变换,最终得到去噪后的信号。

2 算法介绍

2.1 EMD

EMD 是由 Huang 等提出,是对非线性和非平稳性信

号分析的强有力的工具^[13]。EMD 分解作为一种信号自适应分析方法,完全依靠信号本身来自适应确定所分解获得的模态分量个数,其对于处理清洁因子退化曲线这种波动性较大的时间序列具有一定优势。

EMD 分解后的各本征模态分量 (intrinsic mode function, IMF) 需要满足如下两个条件^[14]。

1) 原始信号极值点和过零点的数目必须相等或者至多只相差一个。

2) 由极大值点定义的上包络线和由极小值点定义的下包络线的平均值为 0,即信号的上下包络线关于时间轴对称。

EMD 分解过程如下。

1) 将 $x(t)$ 中所有局部极值点用 3 次样条插值曲线连接起来,形成上下包络线和 m_{low} 。

2) 包络线的均值曲线 $m_1(t) = [m_{up} + m_{low}]/2$ 。

3) 再计算差值 $h_1(t) = x(t) - m_1(t)$ 若其不满足 IMF 分量的两个充分条件,则用 $h_1(t)$ 代替 $x(t)$,重复步骤 1) 与 2),直至 k 次迭代后 $h_k(t)$ 满足两个条件。

4) IMF1 分量为 $c_1(t) = h_1(t)$, 相对应剩余分量为 $r_1(t) = x(t) - c_1(t)$ 。

5) 将剩余分量 $r_1(t)$ 作为原始序列重复上述步骤进行分解,最终得到 n 个 IMF 分量和一个残差分量 $r_n(t)$,其中残差分量为单调序列或者常值序列。

6) 最终得到 EMD 分解公式如下:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (2)$$

2.2 LSTM 网络

一般循环神经网络 (recurrent neural network, RNN) 具有记忆性,对处理非线性时间序列具有一定的优势,但其存在长期依赖性,训练时梯度消失,梯度爆炸等问题^[15-16]。LSTM 是由 Hochreither & Schmidhuber 提出,该网络对一般 RNN 网络进行改进,通过设置输入门 (input gate),遗忘门 (forget gate) 和输出门 (output gate) 来选择性保留或遗忘一些信息,可以有效的克服一般循环神经网络所产生的问题^[17-18]。近年来,随着深度学习的不断发展,LSTM 在股票预测、机器翻译、情感分析等诸多领域得到广泛的应用。一个 LSTM 神经元结构如图 1 所示。

1) 输入门的作用是向长期状态增添新的有用信息。输入门的实现公式为:

$$i_t = \delta(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

2) 遗忘门的作用是决定在长期状态中所要丢弃的信息。遗忘门的实现公式为:

$$f_t = \delta(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

3) 输出门的作用是计算输出和决定向下一短期状态所传递的信息。输出门的实现公式为:

$$o_t = \delta(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

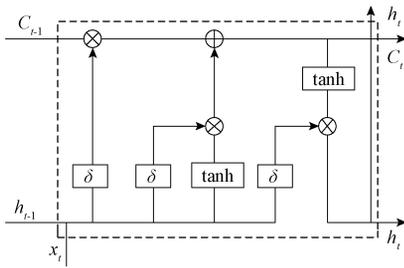


图 1 LSTM 内部结构

Fig. 1 LSTM internal structure

4) 长期状态以及短期状态更新公式为:

$$h_t = o_t \cdot \tanh(c_t) \tag{6}$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \tag{7}$$

式中: i_t, f_t, o_t 分别为输入门、遗忘门、输出门的状态值; c_t, h_t 分别为当前时刻的长期状态和短期状态值; w_i, w_f, w_o, w_c 分别为输入门、遗忘门、输出门、长期状态的权重矩阵; b_i, b_f, b_o, b_c 分别为输入门、遗忘门、输出门、长期状态的偏置向量。

利用时间反向传播算法 (back propagation through time, BPTT) 对建立的 LSTM 模型进行训练, 并优化模型内部参数。本文梯度下降优化算法采用自适应矩估计 (adaptive moment estimation, Adam), 相较于传统随机梯度下降 (stochastic gradient descent, SGD) 拥有固定学习率的特点, Adam 通过计算梯度的一阶矩估计和二阶矩估计而为不同的参数设计独立的自适应性学习率, 可以获得较好的收敛速度与学习效果^[19]。

LSTM 网络中含有较多的超参数, 优化超参数可以提高模型收敛速度和预测精度。本文实验中, 隐含层神经元个数和 Epoch 数对预测结果有着显著的影响。如隐含层神经元过多将会造成过拟合问题, 一般表现为在训练集上误差很小, 但预测值与真实值相差较大; 而隐藏层神经元数目较少则会造成训练不足, 对于序列信息不能很好的提取。不同隐含层神经元数目和 Epoch 数目对预测的影响如表 1 所示。

表 1 超参数实验结果对比

Table 1 Comparison of hyperparameters experiment results

序号	神经元个数	Epoch	平均绝对百分比	均方根误差
			误差 (MAPE)	(RMSE)
0	110	50	0.053 8	0.031 6
1	110	100	0.023 8	0.007 6
2	110	150	0.008 8	0.007 0
3	130	50	0.030 1	0.015 7
4	130	100	0.008 6	0.007 4
5	130	150	0.007 3	0.006 2
6	150	50	0.036 1	0.032 1
7	150	100	0.010 5	0.008 6
8	150	150	0.009 8	0.008 1

2.3 EMD-LSTM

针对锅炉清洁因子退化曲线具有非线性非平稳性的特点, 若只用神经网络模型进行预测很难有良好的预测精度。本文建立 EMD 和 LSTM 融合的模型, 不仅利用 EMD 对退化曲线分解, 获得频域较为稳定的一系列时间序列, 而且结合 LSTM 具有通过学习来挖掘时间序列之间隐藏的长期依赖关系, 获得较好的预测结果。图 2 所示为清洁因子预测框架图。

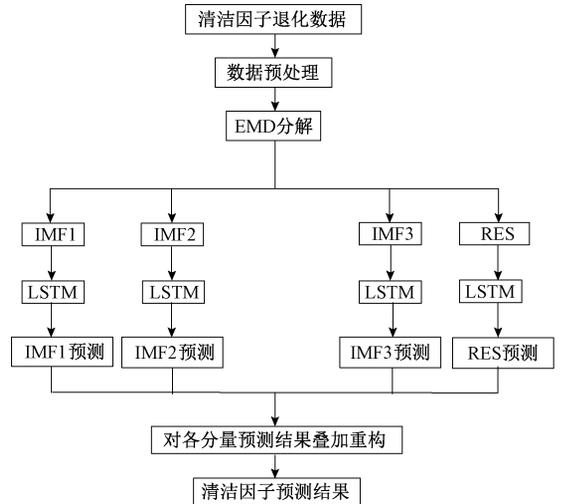


图 2 清洁因子预测框架图

Fig. 2 Cleanliness factor prediction framework

在训练集建立阶段, 按照一定的时间长度, 获得一组样本 (x_1, x_2, \dots, x_n) , 后将该样本延时间轴整体向后推移一个时间单位获得下一组样本 $(x_2, x_3, \dots, x_{n+1})$, 以此类推获得 n 组样本, 每一组样本的目标值为该组样本的下一个时间单位数据。

在预测阶段先以上述方法获得一组样本, 如 (x_1, x_2, \dots, x_n) , 然后使用已经训练好的网络对第 $n+1$ 个数据进行预测, 再用第 $n+1$ 个数据的预测值代替真实 $(x_2, x_3, \dots, x_n, x_{n+1})$ 继续对第 $n+2$ 个数据进行预测。但这种滚动预测方法会使误差累积, 对于进行长期预测效果欠佳。

3 实例分析

3.1 数据来源以及预处理

为证明所提出模型的有效性, 以贵州某火力发电厂 300 MW 燃煤锅炉省煤器为例, 图 3 所示为在机组的 DCS 系统监测下清洁因子一天的变化数据。清洁因子值越小代表锅炉受热面越洁净, 清洁因子值越大表示受热面的污染越严重。从图中积灰段可以看出受热面的污染程度不断增加, 清洁因子的值不断下降。在吹灰段中, 由于吹灰操作, 受热面清洁程度提高, 清洁因子的值也在不断上升。

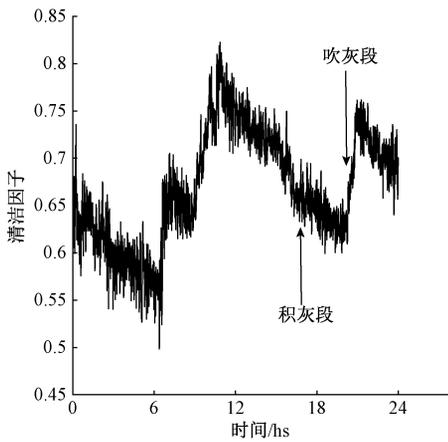


图 3 受热面清洁因子变化曲线

Fig. 3 Heating surface cleaning factor curve

为减弱数据中的噪声对预测结果的影响,先要对数据进行去噪平滑。图 4 所示为小波阈值去噪后的清洁因子曲线(只截取积灰段)。从图 4 去噪后的真实值曲线可以看出清洁因子退化时间序列具有强非线性,非平稳性的特点,增大了清洁因子预测的难度。具体原因考虑是由于烟气在通过对流受热面时,烟气的灰污会沉积在受热面造成清洁因子的下降,同时烟气的通过会吹走一部分灰污造成清洁因子的升。吹灰阈值设定为 $CF_{\min} = 0.64$ 。

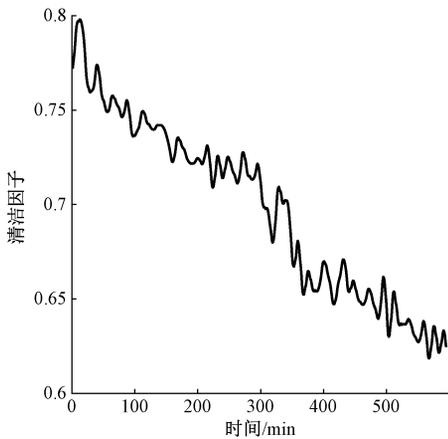


图 4 去噪后清洁因子变化曲线

Fig. 4 Curve of cleaning factor after denoising

3.2 评价指标

评价指标可以更好地反映真实值与预测值之间的差距,便于调整模型内部参数以及对模型做出评估,本文评价指标选取 MAPE 和 RMSE,其公式如下:

$$MAPE = \frac{1}{n} \sum_{i=1}^n |y_i - y_p| / y_i \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_p)^2} \quad (9)$$

式中: y_i 与 y_p 分别为第 i 时刻对应的实际值和预测值; n 表示用于验证的数据长度。

3.3 退化曲线 EMD 分解

EMD 分解无需与小波分解一样确定基函数以及分解层数,其根据信号本身来自适应确定的。对于清洁因子退化曲线进行 EMD 分解,其结果如图 5 所示。EMD 分解将退化曲线分解为 4 个分量,分别为 IMF1、IMF2、IMF3 以及残差分量。IMF1~IMF3 是 3 个频率域较为稳定的本征模态分量,残差分量是曲线的总体退化趋势,表征了锅炉在持续工作时积灰面的健康状况也同时在不断下降。

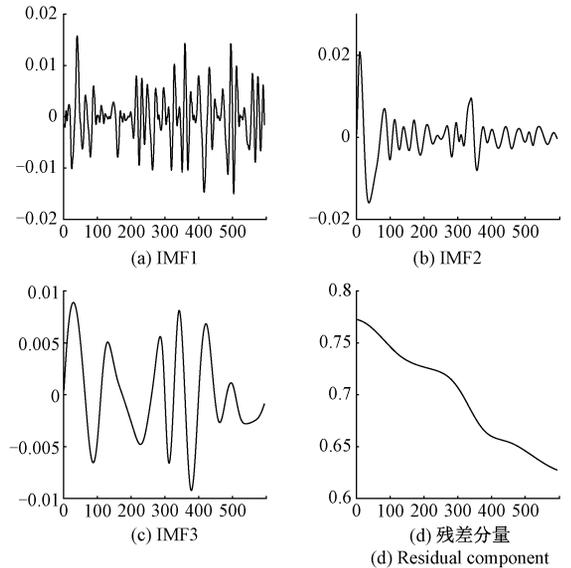


图 5 退化曲线的 EMD 分解

Fig. 5 EMD decomposition of degradation curve

3.4 实验结果

本文预测方法采用滚动型预测,长期滚动预测不可避免地会带来预测精度的降低,经过不断尝试,确定向后滚动预测 15 步拥有较好的预测结果,继续增大滚动预测步数将会造成预测结果的误差较大以及稳定性较差。分别以 $T_1 = 250 \text{ min}$, $T_2 = 350 \text{ min}$, $T_3 = 450 \text{ min}$ 3 个预测起始点得到预测结果如图 6 与 7 所示。可以看出,随着预测起点的提前,训练样本数将会减少,预测精度也不可避免的降低,但由于模型将 EMD 对于波动性时间序列的处理能力和 LSTM 对于时间序列的预测能力相结合,故所设计的 EMD-LSTM 方法仍然可以得到令人满意的结果。

3.5 对比实验

为进一步增强对比效果,证明模型的可行性,选取其他两种方法进行对比分析。两种方法分别为 Elman 神经网络和多层感知机 (multi-layer perceptron, MLP)。预测结果图和预测误差分析表如图 8.9 和表 2 所示。对于基

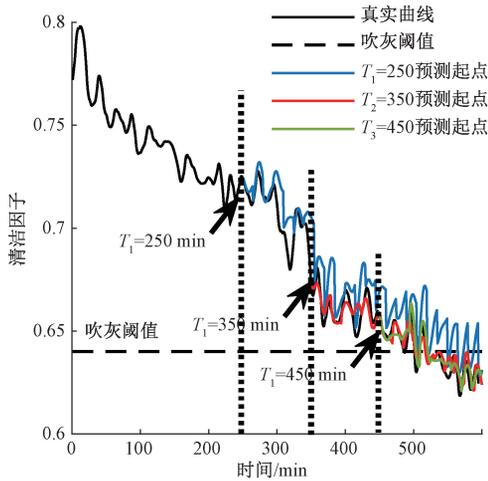


图 6 不同预测起始点对比结果

Fig. 6 Comparison of different prediction starting points

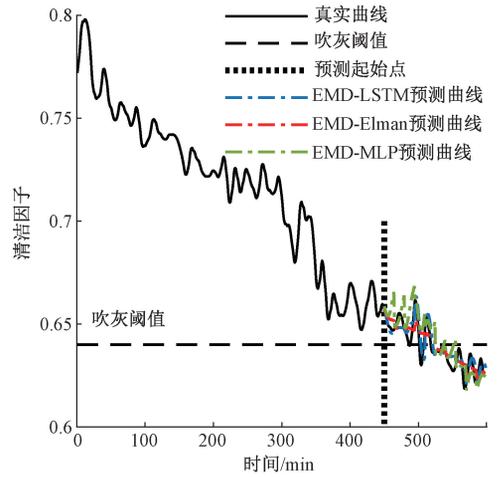


图 8 三种方法比较结果

Fig. 8 Comparison of three methods

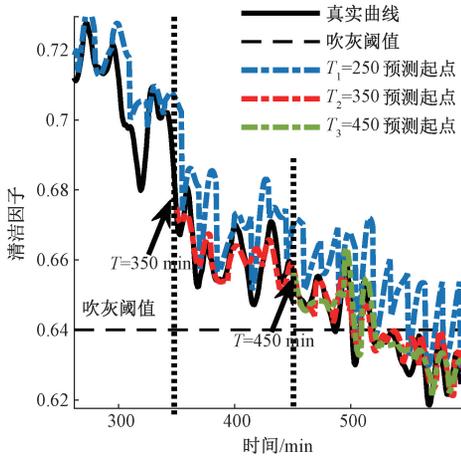


图 7 不同预测起始点对比结果的局部放大

Fig. 7 Local magnification of comparison results of different prediction starting points

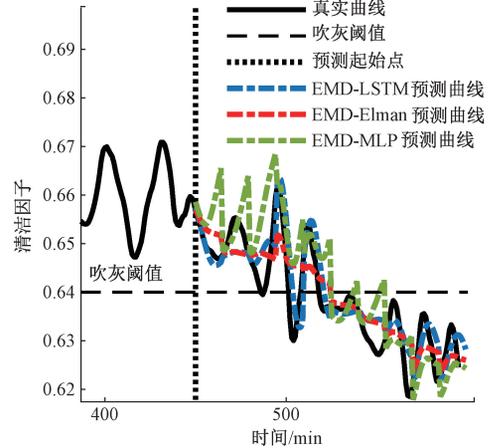


图 9 三种方法比较结果的局部放大

Fig. 9 Local magnification of comparison results of three methods

本的 Elman 神经网络,其在 MLP 的基础上增加了连接层,构成了局部反馈,将过去的状态与下一时刻的网络输入一起作为隐藏层的输入,所以连接层可以使整个网络拥有动态记忆功能,对于时间序列具有不错的预测效果。从表 2 可知,EMD-Elman 比 EMD-MLP 在 MAPE 与 RMSE 分别降低了 26.4%、20.4%。EMD-LSTM 这种深度学习方法在处理长期依赖的时间序列比 EMD-Elman 更为有效,其在 MAPE 与 RMSE 分别降低 59.2%、58.1%。

表 2 三种方法误差比较表

Table 2 Error comparison table of three methods

预测方法	MAPE	RMSE
EMD-LSTM	0.007 1	0.005 7
EMD-Elman	0.017 4	0.013 6
EMD-MLP	0.022 0	0.017 1

4 结 论

本文针对目前吹灰优化方案欠佳,提出融合 EMD-LSTM 锅炉受热面灰污状况的预测模型。引入清洁因子作为衡量受热面灰污状况的健康指标。为验证模型的可行性,采用锅炉 DCS 系统所采集的数据为例,利用该模型对数据进行训练以及有限步滚动预测,并使用仿真软件得到精确的预测结果,在不同的预测起始点均具有较为满意的预测效果。最后与其余常用的两种方法进行比较获得更高的预测精度,证明了该模型的可行性与有效性,从而为吹灰优化工作提供可靠的理论指导。

参考文献

[1] 吕浩. 火力发电厂锅炉调整吹灰技术与燃烧调整技术方法[J]. 科技创新导报, 2019, 16(26): 38, 40.

- LYU H. Boiler adjustment ash blowing technology and combustion adjustment technology method in thermal power plant [J]. *Science and Technology Innovation Herald*, 2019, 16(26):38,40.
- [2] 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.
- SHI Y H, LI Q, ZENG J CH, et al. Study on optimization of heating surface soot blowing in a coal-fire boiler based on increment distribution [J]. *Journal of Chinese Society of Power Engineering*, 2019, 39(10):777-783.
- [3] 李强,史元浩,曾建潮. 基于剩余时间预测的电站锅炉吹灰优化研究[J]. *电子测量与仪器学报*, 2018, 32(10):59-64.
- LI Q, SHI Y H, ZENG J CH. Study on soot blowing optimization of utility boiler based on residual time prediction [J]. *Journal of Electronic Measurement and Instrumentation*, 2018, 32(10):59-64.
- [4] SIVATHANU A K, SUBRAMANIAN S. Extended Kalman filter for fouling detection in thermal power plant reheater [J]. *Control Engineering Practice*, 2018, 73:91-99.
- [5] 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):59.
- [6] 邓喆,李庚生,安连锁,等. 基于声学测温与人工神经网络的炉膛结渣在线监测方法[J]. *现代电力*, 2011, 28(4):70-72.
- DENG ZH, LI G SH, AN L S, et al. On-line monitoring method of furnace slag based on acoustic temperature measurement and artificial neural network [J]. *Modern Electrical Power*, 2011, 28(4):70-72.
- [7] 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 ZH Q, SHI Y H, LIANG J Y, et al. Dynamic prediction of heated area gray based on Elman neural network [J]. *Journal of Electronic Measurement and Instrument*, 2019, 33(9):50-56.
- [8] 耿欣,林中达. 锅炉灰污在线监测及吹灰优化预测模型的研究[J]. *发电设备*, 2011, 25(2):91-93, 105.
- CENG X, LIN ZH D. Study on on-line monitoring of boiler ash pollution and optimization prediction model of blowing ash [J]. *Power Generation Equipment*, 2011, 25(2):91-93, 105.
- [9] 王艳婷,史元浩,陈晓龙. 基于无迹卡尔曼滤波预测的锅炉吹灰优化 [J]. *电子测量与仪器学报*, 2019, 33(3):51-57.
- WANG Y T, SHI Y H, CHEN X L. Boiler soot blowing optimization based on Unscented Kalman filter prediction [J]. *Journal of Electronic Measurement and instruments*, 2019, 33(3):51-57.
- [10] 史元浩,王景成,王斌. 燃煤电站锅炉受热面灰污沉积动态监测模型研究 [C]. 第三十届中国控制会议, 2011.
- SHI Y H, WANG J CH, WANG B. Study on dynamic monitoring model of ash fouling deposition on heating surface of coal-fired power station boiler [C]. 30th China Control Conference, 2011.
- [11] 杨铮,王伟兵,李仁华,等. 基于轴承仿真信号的小波阈值及阈值函数的优化 [J]. *工具技术*, 2020, 54(3):78-81.
- YANG ZH, WANG W B, LI R H, et al. Optimization of wavelet threshold and threshold function based on bearing simulation signal [J]. *Journal of Tool Technology*, 2020, 54(3):78-81.
- [12] 刘玉桥,邓红位,吴路波,等. 基 VMD 联合小波阈值去噪法的微震监测信号去噪研究 [J]. *矿业研究与开发*, 2020, 40(2):98-103.
- LIU Y Q, DENG H W, WU L B, et al. Study on signal denoising of microseismic based on combined variational mode decomposition and wavelet threshold method [J]. *Mining Research and Development*, 2020, 40(2):98-103.
- [13] WANG J J, ZHANG W Y, LI Y N, et al. Forecasting wind speed using empirical mode decomposition and Elman neural network [J]. *Applied Soft Computing Journal*, 2014, 23:452-459.
- [14] 贾红雨,周晨昕,王宇涵,等. 基于 EEMD-PSO-LSSVM 的中国沿海散货运价指数预测研究 [J/OL]. *大连海事大学学报*, 2020, 46(1):107-113.
- JIA H Y, ZHOU CH X, WANG Y H, et al. The prediction research of CBFI on EEMD-PSO-LSSVM [J/OL]. *Journal of Dalian Maritime University*, 2020, 46(1):107-113.
- [15] MOHANTY S N, LYDIA E L, ELHOSENY M, et al. Deep learning with LSTM based distributed data mining model for energy efficient wireless sensor networks [J]. *Physical Communication*, 2020, 40:101097.
- [16] LI X Y, ZHANG L, WANG Z P, et al. Remaining useful life prediction for lithium-ion batteries based on a hybrid model combining the long short-term memory and Elman neural networks [J]. *Journal of Energy Storage*, 2019, 21, DOI: 10.1016/j.est.2018.12.011.

[17] 吕鲜,戚湧,张伟斌. 基于长短期记忆模型的交通拥堵预测方法[J]. 南京理工大学学报, 2020, 44(1): 26-32, 48.
LYU X, QI Y, ZHANG W B. Traffic congestion prediction method based on long short-term memory model[J]. Journal of Nanjing University of Science and Technology, 2020, 44(1): 26-32, 48.

[18] 明彤彤,王凯,田冬冬,等. 基于 LSTM 神经网络的锂离子电池荷电状态估算[J]. 广东电力, 2020, 33(3): 26-33.
MING T T, WANG K, TIAN D D, et al. Estimation on state of charge of lithium battery based on LSTM neural network[J]. Guangdong Electric Power, 2020, 33(3): 26-33.

[19] WU J, HUA K, CHENG Y W, et al. Data-driven remaining useful life prediction via multiple sensor signals and deep long short-term memory neural network [C]. ISA Transactions, 2020: 241-250.

作者简介



李孟威, 2019 年于山西工程技术学院获得学士学位, 现为中北大学硕士研究生, 主要研究方向是复杂系统的故障预测与健康管理。

E-mail: 1240459451@qq.com

Li Mengwei received his B. Sc. degree from Shanxi Institute of Technology, now he is a M. Sc. candidate at North China University. His main research interests include prognostics and health management.