

DOI: 10.13382/j.jemi.B2205547

# 融合 CEEMD 和 TCN 的受热面积灰预测研究\*

韩天翔 史元浩 李孟威 梁建宇 杨彦茹 王江

(中北大学电气与控制工程学院 太原 030000)

**摘要:**对锅炉受热面积灰程度的有效预测,可为锅炉提升生产效率和故障预警提供重要依据。采用清洁因子来评估受热面的灰污沉积状况,针对其序列非线性、非平稳性的特点,提出一种基于互补集合经验模态分解与时间卷积网络的受热面积灰预测方法。首先,通过互补集合经验模态分解将经过小波阈值去噪处理后的原始序列分解为一组子序列分量;然后,针对不同子序列分别构建基于时间卷积网络的时序预测模型,并优化网络超参数提升预测准确性;最后,将各 IMF 分量的预测结果叠加得出清洁因子的预测数值。由实验结果可得,相较于其他两种模型,预测精度分别提高 62.1% 和 57.1%,CEEMD-TCN 模型对受热面积灰状况预测精度最高,验证了该模型的准确性和可靠性。

**关键词:** 清洁因子; 锅炉积灰; 互补集合经验模态分解; 时间卷积网络

**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

## Study on the prediction of heated area ash fused with CEEMD and TCN

Han Tianxiang Shi Yuanhao Li Mengwei Liang Jianyu Yang Yanru Wang Jiang

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

**Abstract:** Effective prediction of the degree of ash in the heated area of the boiler can provide an important basis for boiler production efficiency and fault early warning. The cleaning factor is used to evaluate the ash deposition status of the heated surface, and according to the characteristics of nonlinearity and non-stationariness of the sequence, a method of predicting the heated area ash based on the empirical modal decomposition and time convolutional network of complementary sets is proposed. Firstly, the original sequence after wavelet threshold denoising is decomposed into a set of sub-sequence components by complementary set empirical mode decomposition, then the time series prediction model based on the time convolutional network is constructed for different sub-sequences, and the network hyperparameters are optimized to improve the prediction accuracy; finally, the prediction results of each IMF component are superimposed to obtain the prediction values of the cleaning factor. Compared with the other two models, the prediction accuracy is improved by 62.1% and 57.1%, respectively, and the CEEMD-TCN model has the highest prediction accuracy for the ash condition of the heated area, which verifies the accuracy and reliability of the model.

**Keywords:** cleaning factor; boiler ash deposit; complementary set empirical modal decomposition; time convolutional network

## 0 引言

碳中和是我国近些年来针对资源环境约束突出问题做出的重大战略决策,虽然清洁能源发展迅速,但现阶段我国电能的生产很大程度上还是依赖于燃煤发电,在环

境问题日益严重的时代背景下,对于燃煤电站在节能减排方面的要求也在不断提升<sup>[1]</sup>。锅炉受热面在日常生产活动中必定会有灰污的沉积,对传热效率有很大的影响,进而阻碍日常生产效率,降低燃煤能量的利用率,甚至危及到生产安全<sup>[2]</sup>。由此,对受热面进行吹灰操作是十分有必要的,也是国内外电力行业高度重视的节能减排方

收稿日期: 2022-05-31 Received Date: 2022-05-31

\* 基金项目: 国家自然科学基金(72071183)、山西省自然科学基金(201901D111164)、山西省回国留学人员科研资助项目(2020-114)、中国高校产学研创新基金项目(2019ITA0cxy0023)资助

式。吹灰操作的频率是关键因素之一,考虑到吹灰操作的频繁进行不但会提升成本浪费能源,而且对于受热面的损耗也有一定程度的影响<sup>[3]</sup>;而低频次的吹灰又将导致灰污积累严重。因此,对锅炉受热面积灰程度的有效预测才能保证吹灰操作的效益最大化,进而提升生产效率,实现节能减排<sup>[4]</sup>。

目前,众多国内外学者对电站锅炉受热面积灰情况监测和优化过程进行了大量研究。Manivasagam 等<sup>[5]</sup>引入压电负载池用于测量煤粉燃烧产生的积灰量的重量,提供了锅炉内部灰污的准确水平。但由于锅炉在运行期间内部环境复杂,所提方法会受到温度以及气流等多种因素的影响。史元浩等<sup>[6]</sup>提出一种优化模型,该模型以监控时间间隔、以预防性吹灰阈值作为优化变量,以燃煤锅炉运行费用率平均值最小作为目标函数。陈晓龙等<sup>[7]</sup>在文中提出用改进的粒子滤波与历史数据相结合的方法,对清洁因子的变化模型及实时数据进行统计。张泽慧等<sup>[8]</sup>考虑到吹灰成本的相关问题,提出一种基于 Gamma 加速积灰模型的吹灰优化方法,确定出最佳的吹灰优化方法到达吹灰所用的费用最少。但仅考虑吹灰不能恢复如新的状况,且以最小吹灰成本为最终目标,在模型的性能方面有一定的不足。李孟威等<sup>[9]</sup>则给出了 EMD-LSTM 的模型来估计未来锅炉积灰情况,该模型运用了 EMD 对波动性数据的处理的优化能力和 LSTM 的估计能力,来预计了未来受热表面灰污沉积情况。上述研究通过对锅炉状态的监测工作,提出不同方法指导吹灰的优化,同时对受热面灰污累积的预测也为优化吹灰过程奠定良好基础。

针对目前受热面吹灰优化工作在吹灰最佳时机的判断方面仍有待提升,且当前阶段节能减排对燃煤电站锅炉吹灰优化工作提出了更高要求,对未来一定时期内锅炉受热面健康状况进行预测,提前准备好吹灰工作,避免浪费能源,进一步提高节能潜力,是一个十分值得深入研究的课题。本文以燃煤锅炉省煤器集散控制系统(distributed control system, DCS)的实测数据为例,受热面受污状况以清洁因子(cleaness factor, CF)取值为指标构建互补集合经验模态分解(complementary EEMD, CEEMD)与时间卷积网络预测模型。此模型利用 CEEMD 处理不同时间尺度信息间相互耦合问题的能力以及 TCN 在时间序列预测方面优秀的性能来预测受热面灰污沉积情况,避免错过吹灰的最佳时机。根据实验预测以及与传统预测模型对比的结果表明,本文提出的 CEEMD-TCN 模型预测精度更高,可以给吹灰优化工作提供有效的理论基础。

## 1 数据预处理

小波阈值去噪方法属于时频局部化分析方法<sup>[10]</sup>,它

对信号进行小波变换之后,信号被分解为数个子频带的时域分量。可选取适当的阈值滤除小波系数较小的噪声信号,阈值选取过大将造成有效信息的损失,而阈值选取过小会造成噪声信号的残留,都会影响预测结果的精度<sup>[11]</sup>。

小波阈值去噪的步骤如下:

1) 根据原始信号特征以及应用背景选定合适的小波基,并求得层数,运用小波分解处理包含噪声的原始信号,并获取小波系数。

2) 在选定合适的阈值后,通过阈值函数量化处理各层系数。考虑到硬阈值函数导致重构信号产生振荡,针对文中的数据特征选择了软阈值函数来处理信号。

软阈值函数的公式如下:

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

式中: $\sigma\lambda$  为软阈值函数处理后的小波系数。

3) 用软阈值函数处理小波系数获得去除噪声后的信号。

## 2 算法介绍

### 2.1 互补集合经验模态分解

1998 年, Huang 等<sup>[12]</sup>以经验模态分解(empirical mode decomposition, EMD)算法把非平稳信号层层分解成多个固有模态函数(intrinsic mode function, IMF)以及一个残余量。然而,经过 EMD 方法进行分解的 IMF 分量具有模态混叠(mode mixing, MM)现象,这样不同时间尺度 IMF 信号将整合为独立的 IMF 信号,同一时间尺度出现于不同 IMF。

针对分量受模态混叠影响的问题,由 Wu 等<sup>[13]</sup>提出集合经验模态分析方法(ensemble EMD, EEMD)。该算法能够有效减少因间歇性高频分量等原因而引起的模态混叠。但是 EEMD 并没有真正彻底消除噪音,有算法重构误差大和分解完备性差等缺陷。

2010 年 Yeh 等<sup>[14]</sup>给出了互补集合经验模态分解 CEEMD。CEEMD 减少了 EEMD 方法分析后所遗留的白噪声,并解决了 EEMD 重构偏差过大、方法分析的完备性差等问题<sup>[15]</sup>。其主要计算过程包括如下 3 方面:

1) 在原始序列  $C$  上添加  $a$  组互为相反数的正负白噪声,从而得到  $I_1, I_2$ 。

$$\begin{bmatrix} I_1 \\ I_2 \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} C \\ N \end{bmatrix} \quad (2)$$

式中: $I_1, I_2$  分别为加入白噪声后正、负噪声序列, $C$  为原始序列, $N$  为添加的白噪声。

2) 通过  $I_1, I_2$  序列分解得到  $b$  个 IMF 分量,并将得到

第  $i$  个序列第  $j$  个 IMF 分量记为  $C_{ij}$ , 其中  $i=1, \dots, a; j=1, \dots, b$ 。

3) 对所有 IMF 分量进行平均得到最后分解结果:

$$IMF_j = \frac{1}{2a} \sum_{i=1}^{2a} C_{ij} \quad (3)$$

式中:  $IMF_j$  表示得到的第  $j$  组 IMF 分量。

### 2.2 时间卷积网络

时间卷积网络 (time convolutional network, TCN) 是在卷积神经网络 (convolutional neural network, CNN) 基础上发展起来的算法之一<sup>[16]</sup>。TCN 采用一维卷积网络, 由膨胀因果卷积和残差模块组成。

时间卷积网络扩展因果卷积结构如图 1 所示, 可以通过调节感受野尺寸受层数, 卷积核尺寸和膨胀系数以满足不同长度序列感知需求, 从而解决 CNN 中时间建模长度受卷积核尺寸限制这一难题<sup>[17]</sup>。且与长短期神经网络 (long-short term memory, LSTM) 和反向传播神经网络 (back propagation, BP) 等传统神经网络相比, TCN 没有梯度消失与梯度爆炸问题, 拥有占用内存少、梯度稳定、并行性好、感受野灵活等优势<sup>[18]</sup>。设一维序列的输入是  $l = \{s_1, s_2, \dots, s_{n-1}\} \in R^n$  与卷积核  $f: \{0, \dots, n-1\} \rightarrow R$ , 其序列元素  $s$  的卷积运算  $F$  的表达式为:

$$F(s) = (l_d^* f)(s) = \sum_{i=0}^{n-1} f(i) \cdot x_{s-d-i} \quad (4)$$

TCN 中残差模块的结构如图 2 中残差链接使网络能够跨层数进行信息传递, 从而避免层数过多而造成信息损失。引入残差卷积进行跳层连接, 并进行  $1 \times 1$  卷积操作, 保证输入与输出保持一致。

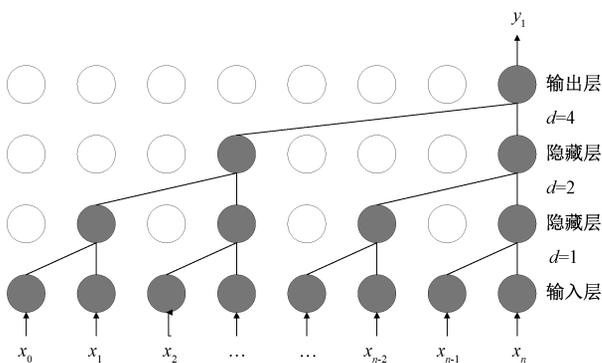


图 1 膨胀因果卷积结构

Fig. 1 Expansion causal convolutional structure diagram

### 2.3 CEEMD-TCN

锅炉清洁因子发展过程本身具有不平稳的波动特征, 且在锅炉温度、烟气、以及机器损耗等因素的影响下, 使其序列具有一定程度的非线性和非平稳的特性, 直接运用传统神经网络模型对其序列进行预测对预测精度的提升较为有限<sup>[19]</sup>。本文考虑到互补集合经验模态分解

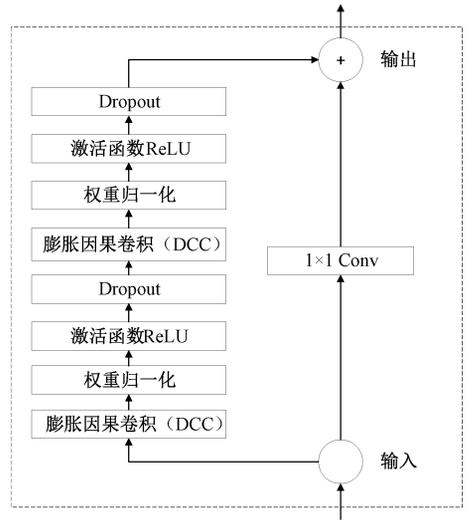


图 2 TCN 残差模块结构

Fig. 2 Structural diagram of the TCN residual module

在时间序列平稳化处理方面的优异表现以及时间卷积网络在时间序列模型预测的优势, 针对清洁因子退化曲线非线性非平稳的特性提出一种 CEEMD-TCN 组合预测模型, 组合模型具体建模过程如图 3 所示。

1) 用小波阈值去噪的方法对原始清洁因子数据预处理, 去除噪声信号;

2) 针对清洁因子退化曲线的非线性非平稳的特性, 采用 CEEMD 方法对其进行分解处理, 得到各 IMF 分量以及残差分量;

3) 针对各子序列分量分别建立 TCN 模型, 并采用 Adam 算法对模型的超参数进行优化;

4) 利用经过优选的 TCN 模式对训练集进行训练, 可以得到对各分量的估计结果, 并通过对各分量叠加重构得出清洁因子的估计结论。

## 3 实例分析

### 3.1 数据来源及预处理

本文以贵州某火电厂 300 MW 燃煤锅炉省煤器为例, 研究对象是机组在 DCS 检测系统下所获得之清洁因子数据, 取该数据中之 24 h 数据作为本文的试验对象, 如图 4 所示。可以观察到在一天中的数据中有 3 个较为明显的清洁因子急速提升的阶段 S1, S2 和 S3, 其中 S2 和 S3 都是锅炉吹灰阶段, 而 S1 阶段主要是因为此时机组负荷急剧增加, 烟气流速急剧上升。带走的灰烬质量远大于烟气带来的灰烬质量, 其作用类似于吹灰。从吹灰点前和吹灰点后图上清洁因子数据变化趋势可知: 吹灰运行前, 锅炉受热面由于受热面投产后积灰程度越来越高, 其清洁因子数值不断降低, 吹灰运行后受热面被污染

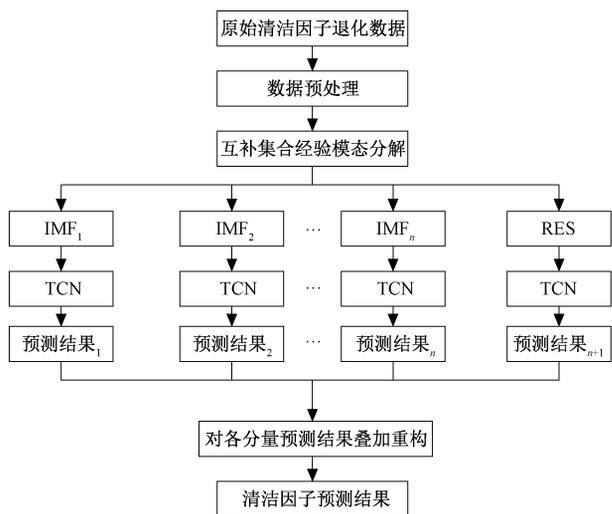


图 3 CEEMD-TCN 预测模型结构

Fig. 3 CEEMD-TCN prediction model structure diagram

程度急剧降低,其清洁因子值急剧升高,可见吹灰运行对于受热面积灰具有明显的清洁作用。

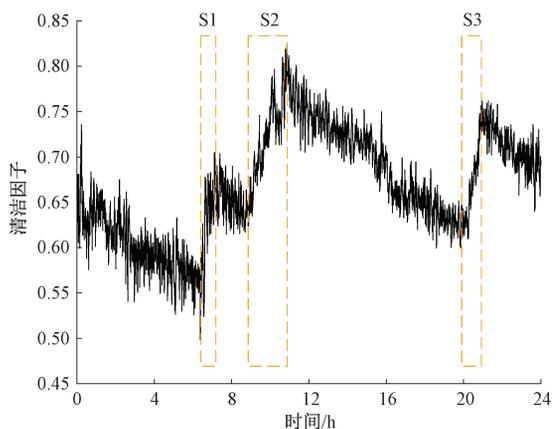


图 4 清洁因子变化曲线

Fig. 4 Cleanliness factor change curve

由于模型预测精度受原数据中噪声对的影响较大,需要针对原始数据做小波阈值去噪处理,最大程度去除噪声对预测结果的不利影响,图 5 是截取 S2 和 S3 阶段中间的 510 min 积灰段数据经过小波阈值降噪处理后清洁因子的变化曲线,从图像中可以很直观地观察到降噪处理之后清洁因子序列表现出很强的非线性与非平稳性对于预测精度的提升造成一定的困难。

### 3.2 CEEMD 分解

运用 CEEMD 方法对小波阈值去噪后的序列做分解操作,得到 8 个子序列,分解后的子序列如图 6 所示。由图 6 所示,区别于原序列较大的波动范围,分解后得到的各 IMF 分量波动范围较小,且随着分解逐步进行,分量的波动趋于平缓,说明 CEEMD 方法可以降低序列的非平

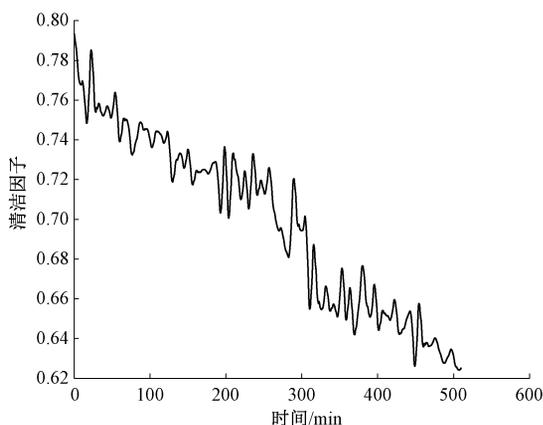


图 5 去噪后清洁因子变化曲线

Fig. 5 Cleanliness factor change curve after denoising

稳性。7 个 IMF 分量是影响序列非线性和非平稳性的高频分量,残差分量则表示序列的总体趋势。由此,对各分量分别运用 TCN 模型预测,对于降低其非线性和非平稳性非常有效。

### 3.3 预测模型评价指标

预测模型精度可以用 2 个常用的标准来评价:MAPE (mean absolute percentage error, MAPE) 和 RMSE (root mean square error, RMSE), MAPE 与 RMSE 越小,误差越小,预测结果精度较高。两种预测性绩效评估指标表达式如下:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n |x_i - x_p| / x_i \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - x_p)^2} \quad (6)$$

式中: $x_i, x_p$  分别为各 IMF 分量的实际值和预测值; $n$  表示验证数据集个数; $i$  表示预测序列的编号。

### 3.4 实验结果

以吹灰段 510 min 的机组监测数据为样本数据,将前面 385 min 数据设为训练集,后面 125 min 作为测试集,通过小波阈值去噪和 CEEMD 分解之后,分别对各成分训练集数据进行 TCN 模型训练,得到预测模型。其中,模型中的超参数由 Adam 算法优化更新,将 batch\_size 设定为 32,将 dropout\_rate 设定为 0.1,将学习率  $lr$  设定为 0.001,迭代周期为 150。利用预测模型对最后的 125 min 进行了预测,得到了各分量的预测结果,并通过叠加和重构得到了 CEEMD-TCN 的总预测结果。

为证明此模型的可行性,选取 TCN 模型预测方法与 CEEMD-TCN 模型方法进行对比,验证 CEEMD 的有效性,选取 CEEMD-LSTM 模型预测方法以及 CEEMD-BP 模型预测方法验证 CEEMD-TCN 模型的有效性。预测结果如图 7、8 所示,可以清楚的看到本文所提的 CEEMD-TCN

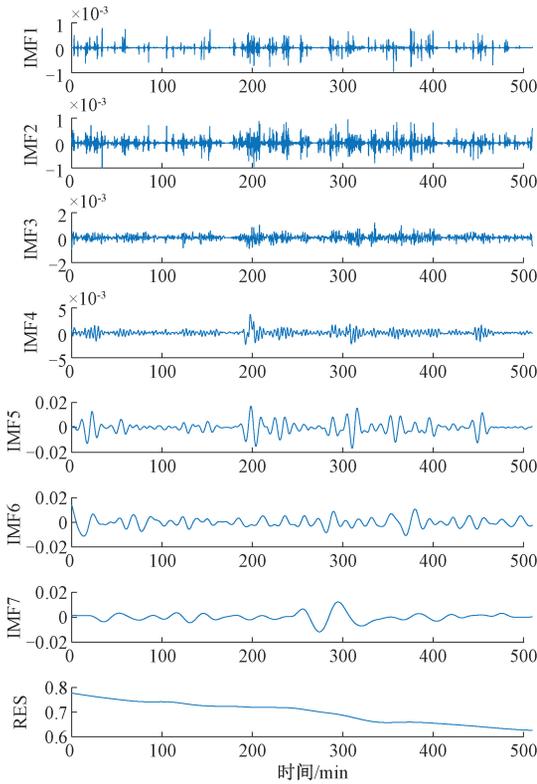


图 6 退化曲线的 CEEMD 分解

Fig. 6 CEEMD decomposition of the degradation curve

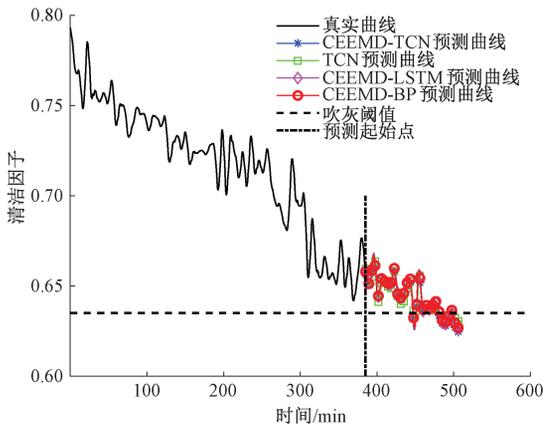


图 7 省煤器不同预测模型预测结果

Fig. 7 Prediction results of different prediction models for the economizer

预测模型效果最佳。相较于单纯使用 TCN 模型预测精度提升较大,主要是由于在经过 CEEMD 分解过后有效的解决了不同频域间信号对预测精度的影响。且通过与 CEEMD-LSTM 以及 CEEMD-BP 两种模型的预测结果对比,体现出 TCN 模型优秀的捕捉序列间信息的能力和高效的数据处理能力。预测结果的误差表如表 1 所示,图 9 为各个模型分别与清洁因子真实值的对比图,通过图 9

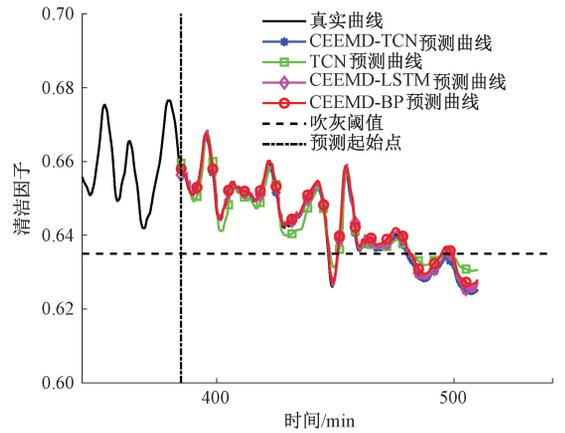


图 8 省煤器不同预测模型预测结果局部放大

Fig. 8 Local enlargement of prediction results from different prediction models for the economizer

可以更加清晰的观察到本文所提 CEEMD-TCN 模型与清洁因子退化曲线的误差程度相较于其他模型误差最小。通过对比预测值结果可知,CEEMD-TCN 模型相较于 TCN 模型预测精度更高,在 MAPE 和 RMSE 分别降低了 79.3% 和 47.4%, CEEMD-TCN 模型相较于 CEEMD-LSTM 模型和 CEEMD-BP 模型在 MAPE 分别减少 47.4% 和 62.1%, 在 RMSE 分别减少了 45.5% 和 57.1%, CEEMD-TCN 模型对受热面积灰状况预测精度最高,验证了该模型的准确性和可靠性。

表 1 4 种预测模型误差评估

Table 1 Error assessment of four prediction models for the economizer

预测方法	MAPE/%	RMSE
CEEMD-TCN	0.067 4	0.000 6
TCN	0.353 1	0.002 9
CEEMD-LSTM	0.128 1	0.001 1
CEEMD-BP	0.177 7	0.001 4

为了避免实验结果的偶然性,选取同一时间段锅炉中的再热器清洁因子数据做相同实验,预测结果如图 10 所示,预测结果的误差表如表 2 所示。可以清楚的看到,虽然采用不同数据集对各模型结果有一定的影响,但本文所提的 CEEMD-TCN 预测模型效果仍然最佳。CEEMD-TCN 模型对再热器清洁因子退化曲线预测精度最高,验证了该模型的有效性。

## 4 结 论

本文结合深度学习研究热点就锅炉受热面吹灰优化

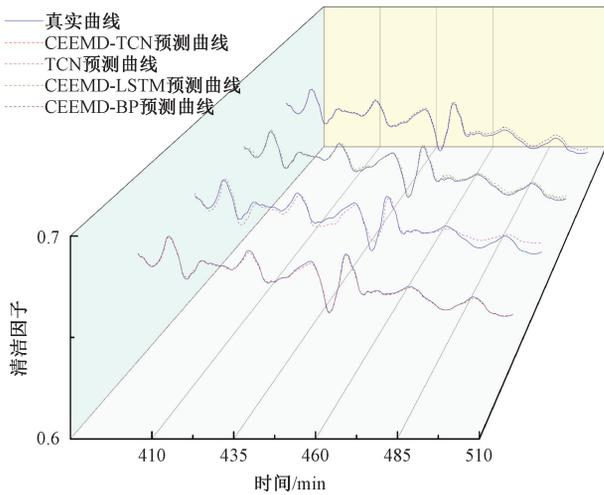


图 9 省煤器不同模型预测结果与真实曲线对比  
Fig. 9 Comparison of predicted results of different models of the economizer with real curves

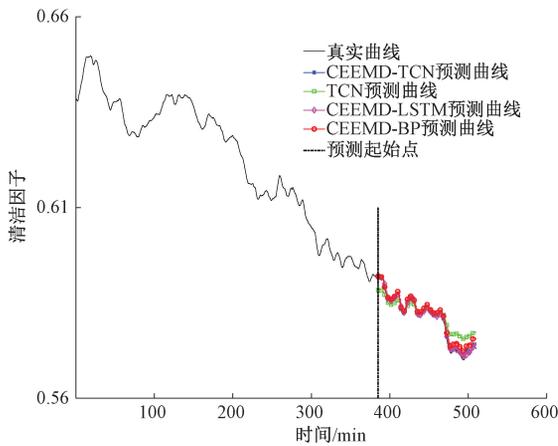


图 10 再热器不同预测模型预测结果  
Fig. 10 Prediction results of different prediction models for the reheater

表 2 再热器的 4 个预测模型的误差评估  
Table 2 Error assessment of four prediction models for the reheater

预测方法	MAPE/%	RMSE
CEEMD-TCN	0.081 2	0.000 6
TCN	0.371 7	0.002 8
CEEMD-LSTM	0.087 4	0.000 7
CEEMD-BP	0.197 7	0.001 3

方案提出了一种 CEEMD-TCN 模型。首先,用小波阈值去噪方法解决了原始信号中存在不必要的小故障和噪声等问题,突出有效信号。其次,用 CEEMD 方法处理具有非线性和非平稳性的受热面清洁因子时间序列,有效解决不同频段间信号对预测精度的影响,且通过对比

CEEMD-TCN 模型与 TCN 模型的预测结果可得出 CEEMD 的可行性。最后,采用 TCN 模型对 CEEMD 分解得到的各分量进行预测,利用其优秀的捕捉序列间信息的能力和高效的数据处理能力,极大的提高了预测精度,并在不同数据集环境下与 CEEMD-LSTM 模型以及 CEEMD-BP 模型的预测模型结果对比,验证了 CEEMD-TCN 模型在吹灰优化工作中的有效性、先进性以及必要性。此外,由于预测模型涉及深度学习模型,其预测精度与数据集本身的适应性和参数调整密切相关。如何获得更高、更稳定的预测能力,以满足“预警”的要求,将是未来研究的重点。

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 soot blowing technology and combustion adjustment technology method of thermal power plant[J]. Science and Technology Innovation Herald, 2019, 16(26) : 38, 40.

[ 2 ] SIVATHANU A K, SUBRAMANIAN S. Extended Kalman filter for fouling detection in thermal power plant reheater[J]. Control Engineering Practice, 2018, 73: 91-99.

[ 3 ] SHI Y, LI M, WEN J, et al. Heat transfer efficiency prediction of coal-fired power plant boiler based on CEEMDAN-NAR considering ash fouling[J]. Energies, 2021, 14(13) : 4000.

[ 4 ] SHI Y, LI M, CUI F, et al. A neural-network-based method for ash fouling prediction of heat transfer surface in coal-fired power plant boiler[J]. IEEE Access, 2021, 9: 109584-109604.

[ 5 ] MANIVASAGAM R, RICHARD S P. Instant ash monitoring using a load cell in the boiler[J]. Materials Today: Proceedings, 2021, 39: 1754-1761.

[ 6 ] 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.  
SHI Y H, CHEN X L, WEN J, et al. Sootblowing optimization of power station boiler based on heating surface health prediction [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 ( 12 ) : 134-138.

[ 7 ] 陈晓龙,史元浩,曾建潮,等. 基于改进粒子滤波算法预测健康状态的锅炉吹灰优化[J]. 热能动力工程, 2019, 34(10) : 84-89.  
CHEN X L, SHI Y H, ZENG J CH, et al. Boiler sootblowing optimization based on improved particle filtering algorithm to predict healthy state[J]. Thermal

- Energy Power Engineering, 2019, 34(10): 84-89.
- [ 8 ] 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.
- ZHANG Z H, SHI Y H. Sootblowing optimization of coal-fired boiler based on Gamma accelerated ash accumulation model [ J ]. Journal of Electronic Measurement and Instrumentation, 2020, 34(8): 8-14.
- [ 9 ] 李孟威, 史元浩, 杨彦茹, 等. 融合 EMD 和 LSTM 的受热面积灰预测研究[J]. 电子测量与仪器学报, 2020, 34(11): 166-172.
- LI M W, SHI Y H, YANG Y R, et al. Prediction of heated area ash fused with EMD and LSTM[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(11): 166-172.
- [ 10 ] 马愈昭, 刘逵, 张岩峰, 等. CEEMD 结合改进小波阈值的激光雷达信号去噪算法[J/OL]. 系统工程与电子技术: 1-11[2022-05-27].
- MA Y ZH, LIU K, ZHANG Y F, et al. CEEMD combined with improved wavelet threshold lidar signal denoising algorithm [ J/OL ]. Systems Engineering and Electronics: 11[2022-05-27].
- [ 11 ] 韩敏, 刘玉花, 席剑辉, 等. 基于小波变换阈值决策的混沌信号去噪研究[J]. 信息与控制, 2005(5): 33-37.
- HAN M, LIU Y H, XI J H, et al. Research on denoising of chaotic signal based on wavelet transform threshold decision[J]. Information and Control, 2005(5): 33-37.
- [ 12 ] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [ 13 ] WU Z, HUANG N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [ 14 ] YEH J R, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method [ J ]. Advances in Adaptive Data Analysis, 2010, 2(2): 135-156.
- [ 15 ] 丁严, 许德合, 曹连海, 等. 基于 CEEMD 的 LSTM 和 ARIMA 模型干旱预测适用性研究——以新疆为例[J]. 干旱区研究, 2022, 39(3): 734-744.
- DING Y, XU D H, CAO L H, et al. Study on the applicability of drought prediction based on CEEMD LSTM and ARIMA models: A case study of Xinjiang[J]. Arid Zone Research, 2022, 39(3): 734-744.
- [ 16 ] HE Y, ZHAO J. Temporal convolutional networks for anomaly detection in time series[C]. Journal of Physics: Conference Series. IOP Publishing, 2019, 1213(4): 042050.
- [ 17 ] 于重重, 宁亚倩, 秦勇, 等. 基于 T-SNE 样本熵和 TCN 的滚动轴承状态退化趋势预测[J]. 仪器仪表学报, 2019, 40(8): 39-46.
- YU ZH ZH, NING Y Q, QIN Y, et al. Prediction of state degradation trend of rolling bearings based on T-SNE sample entropy and TCN [ J ]. Chinese Journal of Scientific Instrument, 2019, 40(8): 39-46.
- [ 18 ] 杨海晶, 孙运全, 朱伟, 等. 基于 CEEMD-TCN 模型的变压器油中溶解气体浓度预测方法[J]. 电子器件, 2021, 44(4): 887-892.
- YANG H J, SUN Y Q, ZHU W, et al. Prediction method of dissolved gas concentration in transformer oil based on CEEMD-TCN model[J]. Electronic Devices, 2021, 44(4): 887-892.
- [ 19 ] 闫俊泉, 李东明, 孙学锋, 等. 基于改进神经网络的电机轴承故障的诊断[J]. 国外电子测量技术, 2019, 38(1): 5-10.
- YAN J Q, LI D M, SUN X F, et al. Diagnosis of motor bearing faults based on improved neural network [ J ]. Foreign Electronic Measurement Technology, 2019, 38(1): 5-10.

## 作者简介



韩天翔, 2018 年于北京交通大学海滨学院获得学士学位, 现为中北大学硕士研究生, 主要研究方向为故障预测与健康管。E-mail: 2104869896@qq.com

**Han Tianxiang** received his B. Sc. degree from Beijing Jiaotong University Haibin College in 2018. Now he is a M. Sc. candidate at North University of China. His main research interests include prognostics and health management.