

DOI: 10.13382/j.jemi.B2407462

融合 TVF-EMD 和 CNN-GRU 锅炉受热面能效预测*

王楠¹ 胡永涛¹ 王康杰¹ 崔方舒² 史元浩¹

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

摘要: 电站锅炉受热面积灰是导致锅炉热效率降低,甚至影响锅炉出力的重要因素之一,因此对锅炉受热面积灰结垢状况的精准预测是优化提升锅炉能效的前提。针对这一问题,本文以 300 MW 电站锅炉省煤器的清洁因子为研究对象,提出了一种融合基于时变滤波器的经验模态分解 (time-varying filtered empirical mode decomposition, TVF-EMD) 和卷积门控神经网络 (convolutional neural network gated recurrent unit, CNN-GRU) 的组合模型来预测锅炉受热面能效变化情况。首先通过改进的小波阈值法对非线性非平稳的清洁因子原始数据进行预处理,去除噪声和异常值;再通过 TVF-EMD 对处理后的数据进行分解得到预设好的本征模态分量,根据自相关系数对阈值大于 0.2 的分量进行叠加重构,在保留原始数据重要特征的同时降低相关性低的分量对预测精度的影响;最终将重构后的信号利用卷积神经网络 (convolutional neural network, CNN) 强大的特征提取能力和门控循环单元 (gated recurrent unit, GRU) 的时序记忆能力,建立输入与输出之间的非线性关系,实现较为精准的时间序列预测。研究表明,利用 TVF-EMD 进行分解相比直接进行预测可以提升 9.628 67% 的预测精度,为后续优化及制订更加合理的吹灰策略提供了理论和技术支持。

关键词: 清洁因子;时变滤波器;经验模态分解;小波阈值法;卷积门控神经网络

中图分类号: TM621.2;TP183 **文献标识码:** A **国家标准学科分类代码:** 470.20

Fusion of TVF-EMD and CNN-GRU boiler heat surface energy efficiency prediction

Wang Nan¹ Hu Yongtao¹ Wang Kangjie¹ Cui Fangshu² Shi Yuanhao¹

(1. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China;

2. School of Computer Science and Technology, North University of China, Taiyuan 030051, China)

Abstract: Power station boiler heated area ash is one of the important factors leading to the reduction of boiler thermal efficiency and even affecting boiler output, so accurate prediction of boiler heated area ash fouling condition is a prerequisite for optimizing and improving boiler energy efficiency. To address this problem, the paper takes the cleanliness factor of the economizer of a 300MW power station boiler as the research object, and proposes a combined model integrating time-varying filter-based empirical mode decomposition (TVF-EMD) and convolutionally gated neural unit (CNN-GRU) to predict the change of boiler heated surface energy efficiency. Firstly, the non-linear and non-smooth cleanliness factor raw data are preprocessed by the improved wavelet threshold method to remove noise and outliers; then the processed data are decomposed by TVF-EMD to obtain the preset intrinsic modal components, and the components with the threshold value greater than 0.2 are superimposed and reconstructed according to the autocorrelation coefficient, so as to reduce the impact of the low correlation components on the prediction accuracy while retaining the important features of the raw data; finally, the reconstructed model is combined with convolutionally gated neural unit (CNN-GRU) to predict the energy efficiency change of the boiler heating surface. Finally, the reconstructed signal is used to establish the nonlinear relationship between input and output by using the powerful feature extraction capability of convolutional neural network (CNN) and the temporal memory capability of gated recurrent unit (GRU) to achieve more accurate time series prediction. The results show that the decomposition using TVF-EMD can improve the prediction accuracy by 9.628 67% compared with the direct prediction, which provides theoretical and technical support

收稿日期: 2024-04-23 Received Date: 2024-04-23

* 基金项目: 国家自然科学基金(72071183)、山西省基础研究计划(202303021222084)、山西省研究生创新项目基金(2023SJ232)项目资助

for the subsequent optimization and the formulation of more reasonable soot-blowing strategies.

Keywords: cleanliness factor; time-varying filter; empirical modal decomposition; wavelet thresholding method; convolutional gated neural unit

0 引言

随着“智能电厂”^[1]概念的提出,火电企业向着更加高效、节能、绿色的方向不断发展。由于火电企业大多利用煤炭燃烧所产生的热能转化为动能以生产电能,随着时间的推移,锅炉受热面不可避免的出现积灰结垢现象。这种情况的发生不仅会浪费燃料、降低锅炉热效率,更有可能降低锅炉的使用寿命。传统的吹灰操作依赖于技术人员的工作经验和对现场的实际勘测,这就容易陷入习惯性思维导致对吹灰节点的误判、漏判,进而影响企业正常的生产活动,造成不必要的能源和人力浪费。基于以上问题,更加精准的预测锅炉受热面的能效变化情况对于指导技术人员进行吹灰操作,提高火电企业在节能环保方面的经济效益有着实际的工程意义。

众多国内外专家和学者已经对锅炉受热面积灰情况和吹灰时间节点优化进行研究和探索,并取得了一定的成果。李孟威等^[2]在燃煤电站锅炉受热面积灰预测研究中提出了融合经验模态分解(empirical mode decomposition, EMD)和长短期记忆神经网络(long short term memory neural network, LSTM)的深度特征提取模型来预测未来锅炉的积灰情况,王艳婷等^[3]采用双指数函数拟合分析清洁因子退化数据,利用无迹卡尔曼滤波算法对模型参数进行更新,并预测清洁因子未来的变化趋势。谢春等^[4]采用锅炉沾污因数来定量表征锅炉积灰程度并用随机森林回归算法对其进行预测。Xu等^[5]研究了悬浮预热器余热锅炉过热器积灰问题。建立了包括沉积和去除过程在内的综合灰堆积生长模型,并通过实验结果进行了验证。Zhu等^[6]研究了当锅炉在不同负荷下运行时,锅炉内的灰沉积特性会发生相应的变化。从燃烧器高度,位置,灰尘颗粒直径等方面阐述了沉积率与锅炉燃烧特性之间的关系。

上述专家和学者通过对锅炉各结构积灰特性的研究,为锅炉受热面积灰预测奠定了良好的基础。但是对于信号分解中出现的模态混叠及预测结果精度不够这些问题上,目前仍没有较好的解决方案。

当前对锅炉受热面积灰引起能效变化的预测工作仍然存在预测时间长,预测效果不稳定等缺陷。为了在节约能源、时间、人力资源的同时制定更加合理有效的吹灰方案,以锅炉省煤器清洁因子作为受热面积灰的重要表征,采用TVF-EMD分解法联合CNN-GRU神经网络的预测模型来解决能效变化这一非线性时变问题。此模型利

用TVF-EMD高效的频率分离性能和低采样率下的稳定性以及可随时间改变的滤波特性,将分解后的信号代入CNN-GRU中,利用CNN强大的特征提取能力和GRU的时序记忆能力,使得预测结果更加精准,抗噪声能力更强,预测时间更快。为后续燃煤电站的智能运维提供了更多行之有效的策略。

1 数据来源及预处理

1.1 数据来源

以贵州某火电机组 300 MW 燃煤锅炉为例,研究对象是 2 号机组集散控制系统(distributed control system, DCS)采集到的数据经过一系列数值计算得到的清洁因子数据集(CF)。

$$CF = \frac{K_r}{K_0} \quad (1)$$

其中, K_r 表示受热面的实际换热效率, K_0 表示受热面的理想换热效率。该数据集的采样周期为 5 s, 共计采样 24 h, 如图 1 所示。

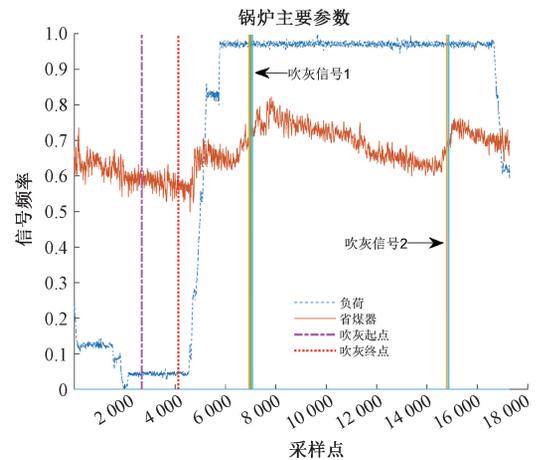


图 1 锅炉省煤器、负荷及吹灰信号曲线

Fig. 1 Boiler economizer, load, and soot blowing signal curve

经过初步分析,在第 2 672 s~4 127 s 之间为锅炉侧省煤器的积灰段,清洁因子数目随时间推移呈自然下降趋势,受机组负荷变动及吹灰信号频率扰动的影响较小,适合作为预测时间区间。在第 2 500 s 之前和第 4 200 s 之后,由于受到负荷变动及运行工况变化的影响,此时省煤器受到多种外界变量影响,从而影响了预测精度。故在数据的选择上截取时间节点为 [2 672, 4 127] 之间的数据作为积灰段原始数据,如图 2 所示。

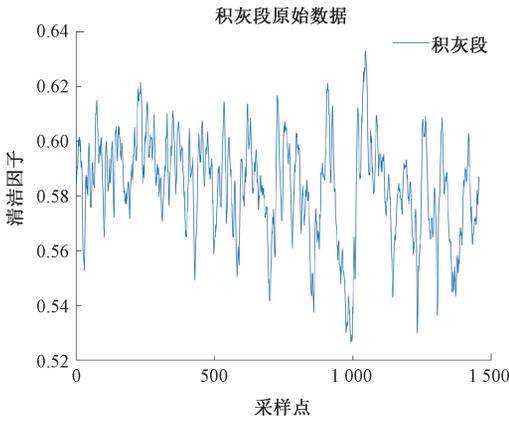


图2 省煤器积灰段原始数据

Fig. 2 Raw data for economizer ash accumulation section

1.2 数据预处理

小波阈值法去噪^[7]作为一种基于小波分析的去噪方法,具有去噪效果好,处理速度快,算法简单易实现等优点。小波阈值法主要分为3个步骤,小波分解(式(2)、式(3)),阈值选择和小波重构(式(4)),小波阈值去噪的流程如图3所示

$$W_{j,k} = \sum_n h_{n-2k}^j \cdot x_n \quad (2)$$

$$V_{j,k} = \sum_n g_{n-2k}^j \cdot x_n \quad (3)$$

$$x_n = \frac{1}{\sqrt{2}} \sum_k h_{n-2k} \cdot W_{j,k} + \frac{1}{\sqrt{2}} \sum_k g_{n-2k} \cdot V_{j,k} \quad (4)$$

其中, j 表示小波变换的层数, k 表示小波系数的位置, x_n 表示原始信号中第 n 个样本的值, h_{n-2k} 和 g_{n-2k} 分别为低通和高通滤波器的系数, $W_{j,k}$ 和 $V_{j,k}$ 表示两个不同的子空间。

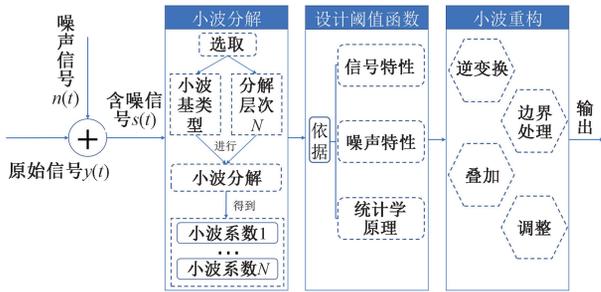


图3 小波阈值法去噪流程

Fig. 3 The denoising process wavelet thresholding method

在以上过程中,小波基类型和分解层数的选择,以及阈值函数的设计,都是影响最终去噪效果的关键因素。通过设计不同的阈值函数对比去噪效果是达到预期效果的方法之一。

传统的硬阈值函数^[8]降噪所得到的峰值信噪比

(peak signal-to-noise ratio, PSNR) 较高,但是有局部抖动现象;软阈值函数^[9]降噪所得到的 PSNR 不如硬阈值函数去噪,虽然结果看起来更平滑,但是简单的平移变换会让原本的信号结构发生改变。这里提出一种固定阈值函数(Sqtwolog)的设计方案,如式(5)所示的公式对信号进行处理以改善降噪效果。其中 N 为信号长度为:

$$\lambda = \sqrt{2 \ln N} \quad (5)$$

图4为3种小波阈值法去噪效果对比图。其中图4(a)为硬阈值去噪,图4(b)为软阈值去噪,图4(c)为固定阈值法去噪,横坐标表示采样点,纵坐标表示清洁因子。通过对比可以看出,小波固定阈值法去噪不仅使原始信号变得更加平滑,还能有效保留原始信号的重要特征,而硬阈值去噪和软阈值去噪甚至改变了图像的部分趋势。

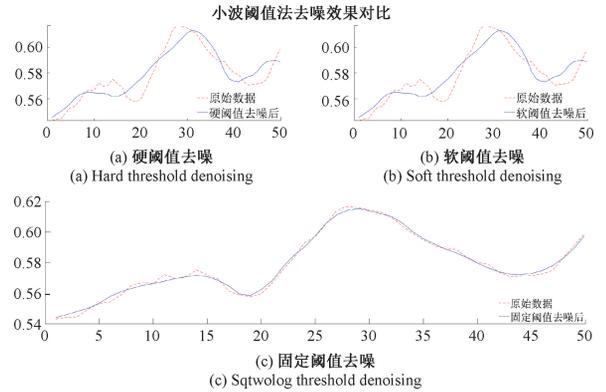


图4 3种小波阈值法去噪效果对比

Fig. 4 Comparison of denoising effects of three wavelet thresholding methods

2 算法介绍

2.1 TVF-EMD 方法简介

由于小波阈值法处理后的省煤器清洁因子数据仍具有非平稳非线性的特点,传统的 EMD 分解^[10-11]虽然在处理非平稳及非线性数据上有明显的优势,但是 EMD 分解时常会出现末端效应和模态混叠问题,对最终的时间序列预测造成干扰。对此可以通过给 EMD 分解加入时变滤波器来改善上述问题,它的筛选过程采用时变滤波技术完成。局部截止频率是通过充分利用瞬时幅度和频率信息自适应设计的。然后采用非均匀 B-样条近似作为时变滤波器。为了解决信号间歇性失真和低采样率下的性能不足的问题,还引入了截止频率重排算法及固有模式函数(intrinsic mode function, IMF)的带宽准则。此外,所提出的方法对噪声干扰具有鲁棒性,能更好地对抗噪声扰动。

TVF-EMD 方法的基本步骤如下:

步骤 1) 对原始信号 $x(t)$ 进行预处理, 分解成有限数量的 IMF 分量和残差。如式(6)所示。

$$x(t) = \sum_{i=1}^n \text{imf}_i(t) + r(t) \quad (6)$$

其中, $\text{imf}_i(t)$ 表示第 i 个 IMF 分量, $r(t)$ 表示残差信号。

步骤 2) 构造时变滤波器, 对信号进行滤波。

(1) 计算 $x(t)$ 的极大值 $u_i, i = 1, 2, 3 \dots, n$ 。

(2) 计算阈值 ρ , 存在阈值 ρ 使得式(7)成立

$$\rho < \frac{\max[\varphi'_{bis}(u_i \leq t \leq u_{i+1})] - \min[\varphi'_{bis}(u_i \leq t \leq u_{i+1})]}{\min[\varphi'_{bis}(u_i \leq t \leq u_{i+1})]} \quad (7)$$

其中, φ'_{bis} 表示局部截止频率。在峰值之间插值得到 φ'_{bis} , 调整 φ'_{bis} 改善模态混叠。

(3) 重构 φ'_{bis} , 得到新信号 $h(t)$, 如式(8)所示。

$$h(t) = \cos\left[\int \varphi'_{bis}(t) dt\right] \quad (8)$$

其中, $\varphi'_{bis}(t)$ 表示 t 时刻的局部截止频率。

(4) 用 B-spline 近似滤波器对输入信号 $x(t)$ 进行滤波, 得到局部均值函数。

(5) 计算准则值 $\theta(t)$, 判断残留信号是否符合截止标准, 如式(9)所示。

$$\theta(t) = \frac{B_{Loughlin}(t)}{\varphi_{avg}(t)} \quad (9)$$

式中: $B_{Loughlin}(t)$ 表示 Loughlin 瞬时带宽, $\varphi_{avg}(t)$ 表示加权平均瞬时频率。若存在一个带宽阈值 ε , 使得 $\theta(t) < \varepsilon$, 则定义该信号为局部窄带信号, 即一个分量信号 IMF。

步骤 3) 根据信号频谱及相关系数判断这一频段的 IMF 对原始信号的重要程度, 选取相关系数大于设定值的 IMF 分量进行叠加重构得到最终结果 $\zeta(t)$, 如式(10)所示。

$$\zeta(t) = \sum_{i=1}^n \theta_i(t) \quad (10)$$

其中, $\theta_i(t)$ 表示第 i 个相关系数大于设定值的分解信号。

步骤 4) 取 $\zeta(t)$ 的值作为纵坐标, 信号观测值(实际值)作为横坐标, 构成信号判断点并绘制最佳拟合度曲线, 观察信号判断点在最佳拟合度曲线周围的分布情况, 判断点越接近拟合度曲线, 信号的分解效果越好。

2.2 CNN-GRU 的结构及原理

CNN^[12-13] 具有特征提取功能, 能够根据提取到的特征对事物进行分类、识别、预测、决策等。其参数共享和多核的特性不仅可以多角度对分解信号进行识别学习, 还能在很大程度上降低运算量。但是, CNN 中的反

向传播算法并不高效, 需要大量的数据支持, 平移不变性也导致数据的微动很难被捕捉到, 同时由于池化层的影响, 会导致很多有价值的信息丢失, 也会忽略数据整体与部分的关系。图 5 为 CNN 的模型内部结构图。

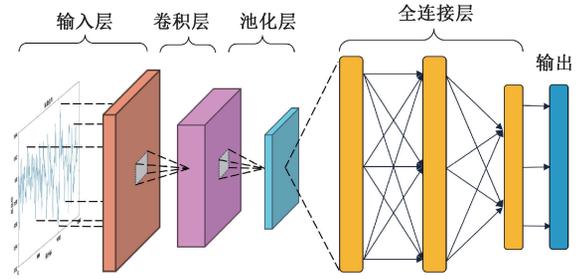


图 5 CNN 模型结构图

Fig. 5 CNN model structure diagram

GRU^[14] 是循环神经网络 (recurrent neural network, RNN) 的一种变体, 特别设计用来处理长序列数据中的长期依赖问题, 这使得它在预测任务, 尤其是那些涉及时间序列分析的任务中非常有效。在故障预测^[15] 和锂电池剩余寿命预测 (remaining useful life, RUL)^[16] 方面, GRU 的应用可以提供更准确和可靠的预测结果。它可以通过“更新记忆”的方式去筛选输入信号中的有用信息。在保留有价值的信息的基础上, 去除无用信息。相比于 LSTM, GRU 拥有更简单的结构, 需要输入的参数较少, 在一定程度上可以防止过拟合现象。图 6 为 GRU 内部结构^[17]。

首先, 通过上一个传输状态 h_{t-1} 和当前节点的输入 x_t 来获取两个门控状态。其中 r_t 控制重置门控, z_t 控制更新门控。

$$z(t) = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (11)$$

$$r(t) = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (12)$$

$$h'_{t-1} = h_{t-1} \odot r_t \quad (13)$$

式中: σ 为 sigmoid 函数, 通过这个函数将数据归一化为 $[0, 1]$ 之间的值, 充当门控信号。 \odot 为哈达玛积。 W_z, W_r, W 作为机器学习的过程, 在每次迭代后替换为新的权值。

得到门控信号后, 首先使用重置门控来得到“重置”之后的数据, 将 h'_{t-1} 与输入 $x(t)$ 进行拼接, 再通过 tanh 激活函数将数据归一化为 $[-1, 1]$ 之间的值, 得到候选值 \tilde{h}_t , \tilde{h}_t 包含了当前输入 $x(t)$ 中的信号特征, 并且将通过学习记录下的新的特征加入。将通过学习记录下的新的特征加入。

$$\tilde{h}_t = \tanh(W \cdot [r_t \times h_{t-1}, x_t]) \quad (14)$$

GRU 最关键的步骤——“更新记忆”^[18], 在式(15)中, 同时进行了“遗忘”和“记忆”。

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \quad (15)$$

门控信号 z_t [19-20] 越接近 1 代表“记忆”下来的数据越多,越接近 0 代表“遗忘”的数据越多。

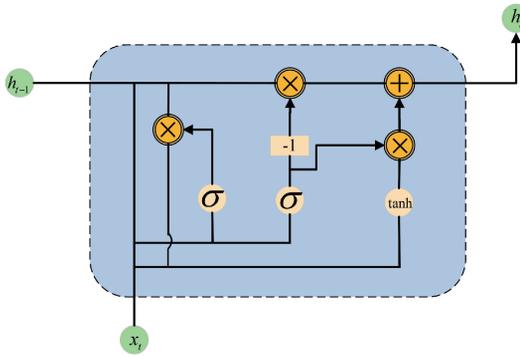


图 6 GRU 模型结构图

Fig. 6 Structure diagram of GRU model

CNN-GRU [21] 融合了 GRU 和 CNN 的优势。一方面, CNN 强大的特征提取能力的用于挖掘数据之间的内部连接,从而降低的规模和复杂性原始数据。另一方面,通过 GRU 神经网络的时序记忆能力学习了数据的变化规律,建立了输入和输出之间的非线性关系,一定程度上避免了信号主要特征丢失。图 7 为 CNN-GRU 模型示意图。

3 结果验证及分析

3.1 算法流程

算法流程如图 8 所示,算法流程可分为以下步骤:

步骤 1) 输入原始数据。

步骤 2) 小波阈值法去噪,分别用硬阈值去噪,软阈值去噪,固定阈值法去噪,根据信噪比 (signal-to-noise

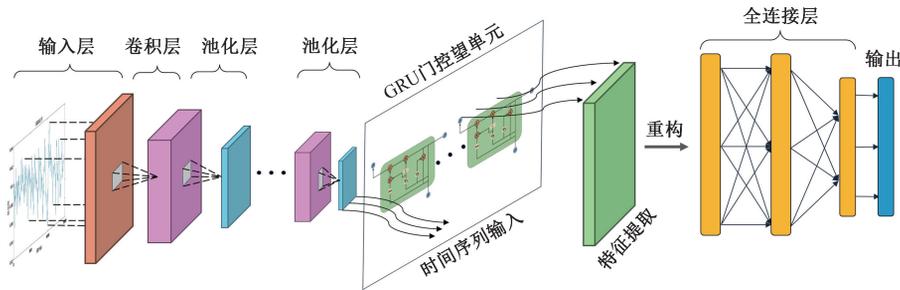


图 7 CNN-GRU 模型结构图

Fig. 7 Structure diagram of CNN-GRU model

ratio, SNR)、均方根误差 (root mean square error, RMSE) 及运行时间等指标对比去噪结果,选取去噪效果最好的方法,保留去噪结果。信噪比及均方根误差公式如式 (16) 及 (17) 所示。

$$SNR = 10 \times \log_{10}(P_s/P_n) \tag{16}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs,i} - X_{bmodel,i})^2}{n}} \tag{17}$$

其中, P_s 为信号的功率, P_n 为噪声的功率, $X_{obs,i}$ 为第 i 个信号的预测值, $X_{bmodel,i}$ 为第 i 个信号的观测值。

步骤 3) 根据先验设定最大 IMF 值,将去噪后的信号进行 TVF-EMD 分解,分解得到的结果根据自相关系数判断,取自相关系数大于设定值 (例如 0.2) 的 n 个 IMF 分量,将这 n 个 IMF 分量叠加重构成新的信号。

步骤 4) 将新的信号代入 CNN-GRU 神经网络进行更新迭代,达到迭代次数后输出最终的预测结果与原始数据进行对比,根据相对误差判断预测结果。

3.2 小波阈值去噪及 TVF-EMD 分解

根据表 1 中结果可以看出,小波固定阈值法的 SNR 和 RMSE 两个指标均优于其他两种方法,故采取固定阈

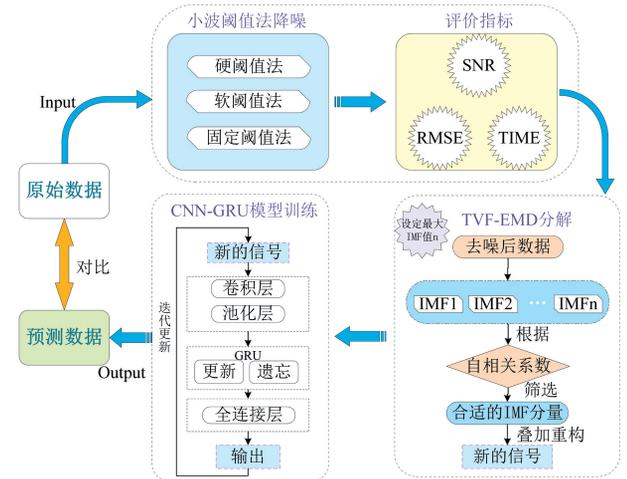


图 8 算法流程图

Fig. 8 Algorithm flowchart

值法对原始信号进行预处理。

设定最大 IMF 分量值为 24,用 TVF-EMD 对小波固定阈值去噪后的序列做分解,得到 24 个子序列,分解后的子序列如图 9 所示,其中 X 轴表示信号周期, Y 轴表示 1~24 个 IMF 分量, Z 轴表示振幅。

表 1 3 种小波阈值法结果

Table 1 Results of three wavelet thresholding methods

	硬阈值	软阈值	固定阈值
信噪比	44.23	42.52	47.21
均方根误差	0.004 36	0.005 07	0.002 54
运行时间/s	0.557 3	0.559 7	0.552 5

TVF-EMD分解结果

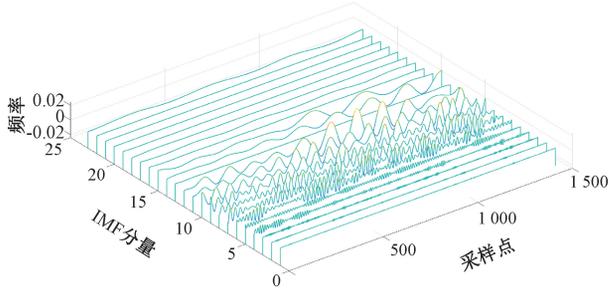


图 9 TVF-EMD 分解结果

Fig. 9 TVF-EMD decomposition results

相关系数曲线如图 10 所示,取相关系数大于 0.2 的 IMF 分量进行叠加重构,选取 IMF7、IMF8、IMF9、IMF10、IMF11、IMF12、IMF13、IMF14、IMF15、IMF24(趋势项)叠加生成分解后的信号。

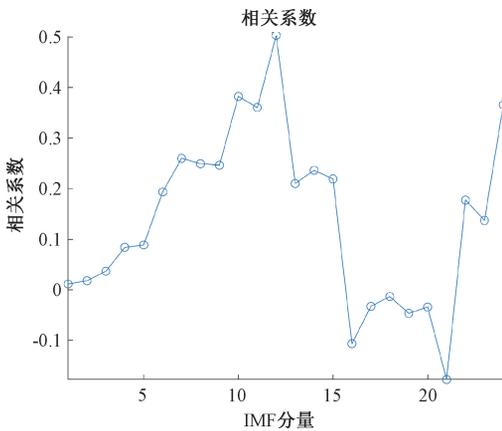


图 10 相关系数曲线

Fig. 10 Correlation coefficient curve

图 11 为分解重构后的信号与原始信号的对比图,从图像中可以看出分解后的信号在保留原始信号特征的基础上曲线变得更加平滑。

通过对比使用 TVF-EMD 分解方法的预测结果(如图 12 所示)和未使用 TVF-EMD 分解方法的预测结果(如图 13 所示)证实了分解的必要性。其中横坐标为数据观测值(实际值),纵坐标为数据模拟值(预测结果)。通过图 12 可以看出,使用 TVF-EMD 分解后的信号观测值和模拟值基本一致且可以落在最佳拟合度曲线上,根据评价指标决定系数(coefficient of determination, r^2)可

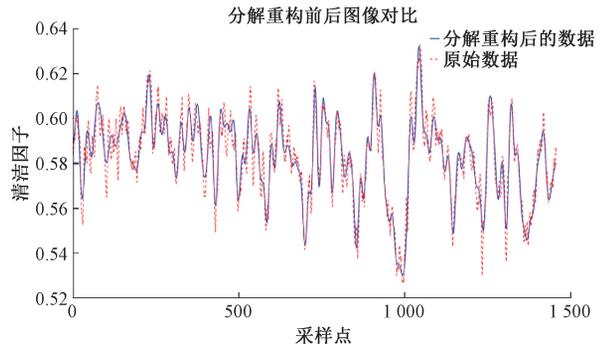


图 11 TVF-EMD 分解前后信号对比图

Fig. 11 Comparison of signals before and after TVF-EMD decomposition

以计算得到,分解后的预测精度提升了:

$$\frac{0.999\ 66 - 0.911\ 86}{0.911\ 86} \times 100\% = 9.628\ 67\% \quad (18)$$

其中, r^2 的计算公式如式(19)所示。

$$r^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (\bar{y}_i - y_i)^2} \quad (19)$$

式中: y_i 为测试集上的真实值, \hat{y}_i 为测试集上的预测值, \bar{y}_i 为测试集所有真实值的平均值。

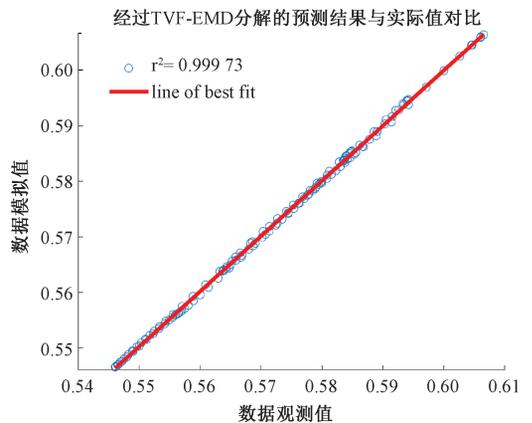


图 12 经过 TVF-EMD 分解的预测结果

Fig. 12 Forecasts after TVF-EMD decomposition

通过 TVF-EMD 分解,信号保留了原信号主要特征,由于通过自相关系数这一指标滤掉了包含噪声的 IMF 分量,使得剩余的 IMF 分量叠加之后的预测结果更精准,同一时刻的信号模拟值更加接近观测值,所以[观测值,模拟值]对应的点能够更加精确地落在最佳拟合度曲线上,由此可以在信号低采样率,神经网络低迭代次数下达到更加精确的预测效果,大大降低了预测周期,同时,由 TVF-EMD 分解得到的 IMF 可以通过频谱对比手动叠加,一定程度上避免了模态混叠的现象,提高了信号分解的

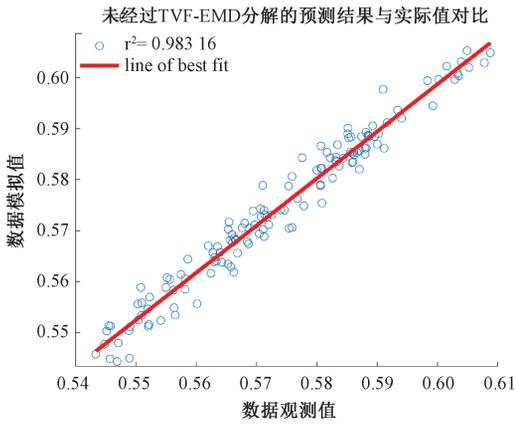


图 13 未经过 TVF-EMD 分解的预测结果

Fig. 13 Forecasts before TVF-EMD decomposition

准确性和精度。

3.3 CNN-GRU 预测及结论

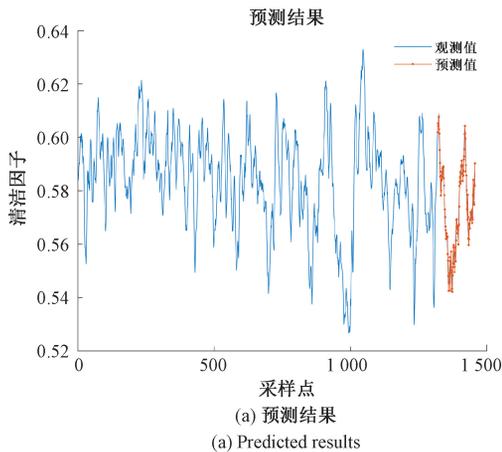
取[2 672,4 127]段 DCS 系统监测到的省煤器清洁因子数目作为样本数据,以 9 : 1 的比例作为训练集和测试集。并以相对误差 δ 作为模型训练结果的评判指标。

$$\delta = \Delta/L \times 100\% \quad (20)$$

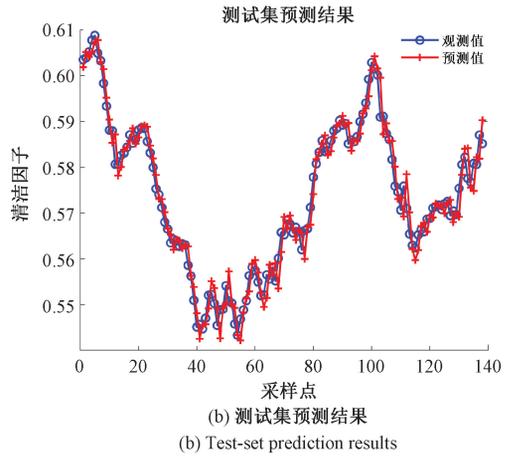
式中: δ 为实际相对误差 Δ 为绝对误差, L 为被测量的实际值。相对误差越小,模型的精度越高。未经过小波阈值法去噪和 TVF-EMD 分解的预测结果及相对误差如图 14 所示。

经过小波阈值法去噪和 TVF-EMD 分解的预测结果及相对误差如图 15 所示。

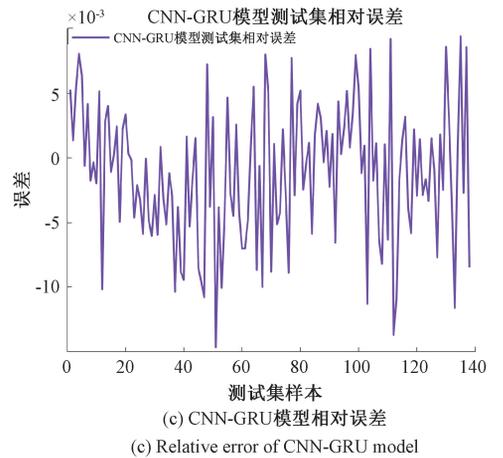
从图 14 和 15 可以看出,经过分解重构后信号的预测结果与实际结果的贴合度更高的同时相对误差更小。实验结果及评价指标表明 TVF-EMD-CNN-GRU 模型比 CNN-GRU 模型的预测精度更高。



(a) 预测结果
(a) Predicted results



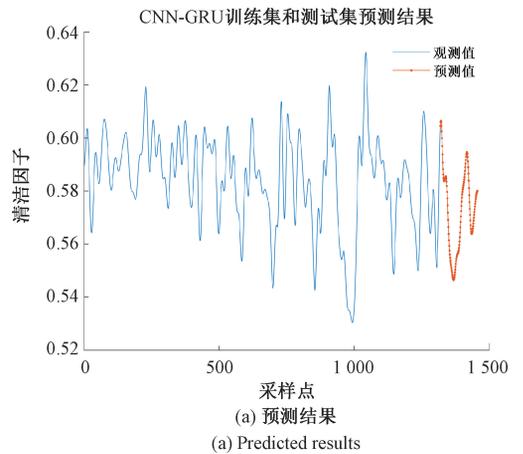
(b) 测试集预测结果
(b) Test-set prediction results



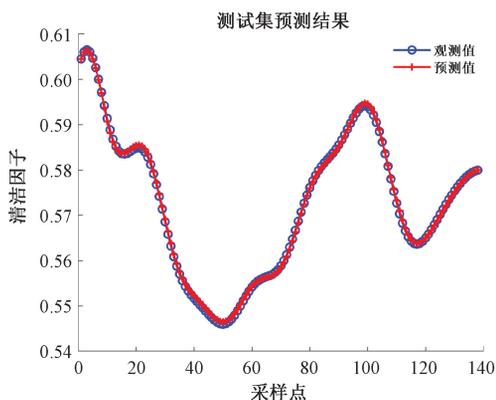
(c) CNN-GRU模型测试集相对误差
(c) Relative error of CNN-GRU model

图 14 未经小波阈值法去噪和 TVF-EMD 分解的预测结果

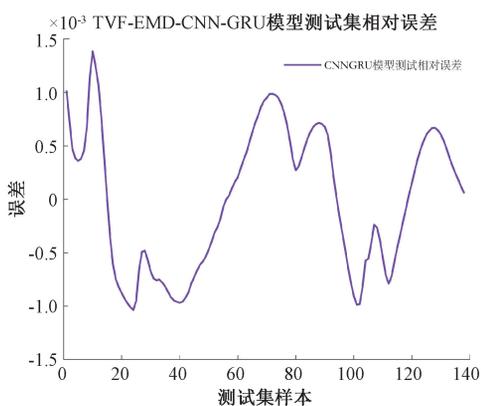
Fig. 14 Prediction results without wavelet denoising and TVF-EMD decomposition



(a) 预测结果
(a) Predicted results



(b) 测试集预测结果
(b) Test-set prediction results



(c) CNN-GRU模型相对误差
(c) Relative error of CNN-GRU model

图 15 经过小波去噪和 TVF-EMD 分解的预测结果

Fig. 15 Prediction results after wavelet denoising and TVF-EMD decomposition

4 结 论

本研究针对实现电站锅炉受热面能效变化的精准预测问题,通过建立融合 TVF-EMD 和 CNN-GRU 的智能组合模型对这一问题进行深入探究,首先使用小波固定阈值法对非线性非平稳的阈值函数进行降噪和去异常值处理;再利用 TVF-EMD 高效的频率分离性能和低采样率下的稳定性对预处理后的时间序列进行分解和重构,减少相关性较低的本征模态分量对预测精度的影响;最后通过 CNN-GRU 对重构后的信号进行预测。研究结果表明,相较于未使用小波阈值法和 TVF-EMD 分解法直接进行时间序列预测结果的精度提升了 9.628 67%,达到了预期效果的同时,验证了该融合模型在锅炉受热面能效预测方面的优越性。在不占用额外计算资源的情况下,为锅炉保持清洁高效运行、延长燃煤电站机组使用寿命、提高企业经济收益、贯彻可持续发展战略提供了可靠的理论和技术支持。本文的研究及工作是后续锅炉能效优

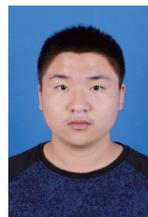
化的基础前提,针对电站锅炉这一高能耗、强耦合系统,实现多层次、全流程、高精度的动态建模和建立对长期影响的跟踪评估机制是完善锅炉高效可持续运行的研究目标和方向,值得进一步深入研究。通过对上述研究方向的探索,期待能够为复杂系统的预测和健康管理的发展做出更大的贡献,并促进相关技术的实际应用和发展。

参考文献

- [1] 窦同新. 火力发电智能电厂的发展与应用[J]. 中国设备工程, 2024(4): 42-44.
DOU X T. Development and application of intelligent power plants for thermal power generation [J]. China Plant Engineering, 2024(4): 42-44.
- [2] 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. Research on gray prediction of heated surface combining EMD and LSTM [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(11): 166-172.
- [3] 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 Instrumentation, 2019, 33(3): 51-57.
- [4] 谢春, 许伟. 基于随机森林回归算法的锅炉沾污因数预测方法 [J]. 上海电气技术, 2022, 15(1): 29-32.
XIE CH, SONG W. Prediction method of boiler fouling factor based on random forest regression algorithm [J]. Journal of Shanghai Electric Technology, 2022, 15(1): 29-32.
- [5] 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.
- [6] 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.
- [7] 李凌志, 潘春荣, 任艳奎, 等. EMD 及小波阈值联合去噪法在磁感应式分选机上的应用 [J]. 有色金属(选矿部分), 2023(6): 140-148.
LI L Z, PAN C R, REN Y K, et al. Application of EMD and wavelet thresholding combined denoising method in magnetic induction separator [J]. Nonferrous Metals (Mineral Processing Section), 2023(6): 140-148.

- [8] ZHU G W, LIU B Y, YANG P, et al. Image denoising method based on improved wavelet threshold algorithm [J]. *Multimedia Tools and Applications*, 2024, 83 (26) : 67997-68011.
- [9] 巩克现, 房家乐, 刘宏华, 等. 基于增强梯度算子的软阈值宽带频谱感知算法 [J]. *通信学报*, 2024, 45(5) : 115-127.
GONG K X, FANG J L, LIU H H, et al. Soft threshold wideband spectrum sensing algorithm based on enhanced gradient operator [J]. *Journal on Communications*, 2024, 45(5) : 115-127.
- [10] WU J, DONG J, WANG Z, et al. A novel hybrid model based on deep learning and error correction for crude oil futures prices forecast [J]. *Resources Policy*, 2023, DOI: 10.1016/j.resourpol.2023.103602.
- [11] ZHOU F, HUANG Z, ZHANG C. Carbon price forecasting based on CEEMDAN and LSTM [J]. *Applied Energy*, 2022, DOI: 10.1016/j.apenergy.2022.118601.
- [12] 毛向向, 王红军, 韩凤霞, 等. 基于深度卷积神经网络的机电系统故障分类识别方法 [J]. *电子测量与仪器学报*, 2021, 35(2) : 87-93.
MAO X X, WANG H J, HANG F X, et al. Fault classification and recognition of electromechanical system based on deep convolutional neural network [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(2) : 87-93.
- [13] 张加劲. 基于注意力机制和 CNN-BiLSTM 模型的航空发动机剩余寿命预测 [J]. *电子测量与仪器学报*, 2022, 36(8) : 231-237.
ZANG J J. Remaining useful life estimation of aeroengine based on CNN-BiLSTM and attention mechanism [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(8) : 231-237.
- [14] LIU W, WANG Q, ZHU Y L, et al. GRU: Optimization of NPI performance [J]. *Journal of Supercomputing*, 2020, 76(5) : 3542-3554.
- [15] 刘艳丽, 王浩, 李佳原, 等. 基于多卷积和结构搜索的电弧故障检测模型 [J]. *电子测量与仪器学报*, 2024, 38(4) : 117-127.
LIU Y L, WANG H, LI J Y, et al. Arc fault detection model based on multi-convolution and structure search [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(4) : 117-127.
- [16] 李强龙, 孙建瑞, 赵坤, 等. 基于 IALO-SVR 的锂电池健康状态预测 [J]. *电子测量与仪器学报*, 2022, 36(1) : 204-211.
LI Q L, SUN J R, ZHAO K, et al. Prediction for the state of health of lithium-ion batteries based on IALO-SVR [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(1) : 204-211.
- [17] MAHJOUB S, CHRIFI-ALAOUI L, MARHIC B, et al. Predicting energy consumption using LSTM, Multi-Layer GRU and Drop-GRU neural networks [J]. *Sensors*, 2022, 22(11) : 4062-4062.
- [18] PIERRE A A, AKIM S A, SEMENYO A K, et al. Peak electrical energy consumption prediction by ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU approaches [J]. *Energies*, 2023, DOI:10.3390/en16124739.
- [19] GUO F, WU X, LIU L, et al. Prediction of remaining useful life and state of health of lithium batteries based on time series feature and savitzky-golay filter combined with gated recurrent unit neural network [J]. *Energy*, 2023, DOI:10.1016/j.energy.2023.126880.
- [20] ZHANG W, LI H, TANG L, et al. Displacement prediction of juxianping landslide using gated recurrent unit (GRU) networks [J]. *Acta Geotechnica*, 2022, 17(4) : 1367-1382.
- [21] ULUOCAK I, BILGILI M. Daily air temperature forecasting using LSTM-CNN and GRU-CNN models [J]. *Acta Geophysica*, 2023, 72 (3) : 2107-2126.

作者简介



王楠, 2021 年于中北大学获得学士学位, 现为中北大学硕士生, 主要研究方向为复杂系统预测与健康管理。

E-mail: wangnanzbdx@163.com

Wang Nan received his B. Sc. degree from North University of China in 2021. Now he is a M. Sc. candidate at North University of China. His main research interests include complex systems prediction and health management.



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 and 数字孪生技术等。

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, master's supervisor in school of electrical and control engineering in North University of China. His main research interests include prognostics and health management, machine learning and digital twins.