

DOI:10.19651/j.cnki.emt.2211167

# 基于数据去噪和 CNN-BiGRU 的 $\text{SO}_2$ 排放预测<sup>\*</sup>

孙 坤 尹晓红

(青岛科技大学自动化与电子工程学院 青岛 266061)

**摘要:** 石灰石-石膏湿法烟气脱硫(WFGD)是火电厂烟气脱硫的主要方法,对大气环境保护起到重要作用,但也会出现腐蚀、结垢等问题影响运行效率。为了优化湿法脱硫系统的运行,采用数据驱动方法对  $\text{SO}_2$  烟气排放进行动态建模。首先利用完全自适应噪声集合经验模态分解(CEEMDAN)对  $\text{SO}_2$  排放数据进行分解,得到若干个本征模态分量(IMFs)。使用小波阈值去噪对含有噪声的本征模态分量进行去噪处理,得到纯净分量。然后设计了卷积神经网络(CNN)和双向门控循环单元(BiGRU)相结合的深度学习模型对  $\text{SO}_2$  排放进行预测。在对比了对分量分别预测后进行重构和将分量重构后进行预测两种方案后,发现前者的均方根误差和平均绝对误差比后者分别降低了 0.135 7 和 0.284 3。基于第 1 种方案与其他基准模型进行了对比实验,所提模型的均方根误差和平均绝对误差分别为 0.699 6 和 0.355 3,均为最低。结果表明所提模型在对  $\text{SO}_2$  排放浓度预测方面有显著优势。

**关键词:** 湿法脱硫;时间序列预测;CEEMDAN;小波阈值去噪;卷积神经网络;门控循环单元

中图分类号: X701.3 文献标识码: A 国家标准学科分类代码: 470.30

## SO<sub>2</sub> emission prediction based on data denoising and CNN-BiGRU

Sun Kun Yin Xiaohong

(School of Automation &amp; Electronic Engineering, Qingdao University of Science &amp; Technology, Qingdao 266061, China)

**Abstract:** Limestone-gypsum wet flue gas desulfurization (WFGD) is the main method of flue gas desulfurization in thermal power plants and plays an important role in atmospheric environmental protection, but it can also suffer from corrosion and fouling problems that affect the operational efficiency. In order to optimize the operation of the wet WFGD system, a data-driven approach is used to model the  $\text{SO}_2$  flue gas emissions dynamically. Firstly, the  $\text{SO}_2$  emission data are decomposed using the complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) to obtain several intrinsic mode functions (IMFs). The intrinsic mode functions containing noise are denoised using wavelet threshold denoising to obtain the pure components. Then a deep learning model combining convolutional neural network (CNN) and bi-directional gated recurrent unit (BiGRU) is designed for  $\text{SO}_2$  emission prediction. After comparing the two schemes of predicting the components separately and then reconstructing them and reconstructing the components and then predicting them, it is found that the root mean square error and the mean absolute error of the former are reduced by 0.135 7 and 0.284 3, respectively, compared with the latter. Experiments are conducted based on the first scheme in comparison with other benchmark models, the root mean square error and the mean absolute error of the proposed model are 0.699 6 and 0.355 3, which are the lowest. The results indicate that the proposed model has significant advantages in predicting  $\text{SO}_2$  emission concentration.

**Keywords:** wet desulfurization; time series prediction; CEEMDAN; wavelet threshold denoise; convolutional neural network; gated recurrent unit

## 0 引言

火力发电是我国发电的主要方式。火力发电通常依靠煤炭的燃烧,产生的尾气中含有多种有害气体,会对大气环

境、人体造成污染和伤害,因此需要对尾气进行处理。随着对环境保护越来越重视,国家也发布了相关规定对火力发电污染气体的排放做出了严格的限制。 $\text{SO}_2$  是火力发电产生的主要污染气体之一,是形成酸雨的主要物质。石灰石-

收稿日期:2022-08-24

\*基金项目:山东省重点研发项目(重大科技创新工程)(2020CXGC011402)资助

石膏湿法脱硫(wet flue gas desulfurization, WFGD)是对烟气中 SO<sub>2</sub> 进行脱除的一种常用且高效的技术手段,其原理是通过石灰石浆液与 SO<sub>2</sub> 气体的反应生成石膏从而达到烟气脱硫的目的<sup>[1]</sup>。石灰石-石膏湿法脱硫具有脱硫效率高、吸收剂利用率高、工作的可靠性高等优点,但是在设备的运行过程中,也会产生腐蚀,结垢,磨损等问题。对湿法脱硫系统的运行进行优化,有助于提高机组运行效率,保护环境,同时降低机组的运行成本,提高经济效益。为了对湿法脱硫系统进行优化,关键是要得到脱硫系统的模型,因此对湿法脱硫系统进行建模的研究引起了国内外学者的广泛关注。

为了得到湿法脱硫系统的机理模型,马双忱等<sup>[2]</sup>对脱硫塔进行有限元分割和数值模拟,并利用 MATLAB 软件求解微分方程,为湿法脱硫机组运行优化提供了指导;张悦等<sup>[3]</sup>将吸收塔分割为“小室”,建立了其数学模型并验证了精准性。在国外学者的研究中,Mcchabe 等<sup>[4]</sup>建立了 SO<sub>2</sub> 吸收的微分方程综合模型,该模型包含 4 个子模型,并验证了该模型在不同操作条件下的有效性。Dabaghao 等<sup>[5]</sup>提出了一个详细的多尺度动态模型。讨论了用于模拟湿法脱硫系统的复杂化学性质,并采用非线性模型预测控制来优化系统的运行。然而湿法脱硫系统具有很强的非线性和不确定性,因此机理模型的建立过程极为复杂和耗时,很难用简洁的形式表达清楚。此外,模型中的一些参数难以测量和确定,建立的模型也不具有普遍性。

随着大数据、机器学习等技术近来的飞速发展,数据驱动建模在各个领域中发挥着越来越重要的作用。数据驱动的建模方法不需要考虑过程的机制,而是直接分析输入变量和输出变量之间的关系,非常适合对强非线性系统进行建模。它所需要的知识比机理建模少得多,也更方便。

郑茗友等<sup>[6]</sup>利用粒子群算法优化套索算法(least absolute shrinkage and selection operator, LASSO)对 SO<sub>2</sub> 浓度进行预测;梁伟灿等<sup>[7]</sup>提出一种针对湿法脱硫系统的混合加权最小二乘支持向量机建模方法,并采用一种局部搜索竞争粒子群算法来进行优化,对 SO<sub>2</sub> 排放浓度进行预测。为了更好地对数据进行特征提取和噪声消除,对输入数据进行分解的方法被广泛应用于多个领域。刘备等<sup>[8]</sup>使用小波变换对全球导航卫星系统水汽数据进行分解,然后利用径向基函数(radial basis function, RBF)神经网络进行预测;王荣茂等<sup>[9]</sup>利用经验模态分解(empirical mode decomposition, EMD)方法对数据进行分解,根据相关性选择合适的本征模态分量(intrinsic mode function, IMF)输入长短期记忆神经网络(long short term memory, LSTM)进行台区负荷预测取得良好效果;金秀章等<sup>[10]</sup>将经验模态分解应用到湿法脱硫系统中,对特征变量进行分解,利用 LSTM 进行 SO<sub>2</sub> 的浓度预测,也取得了不错的效果。但是 EMD 分解算法容易出现模态混叠现象。完全自适应噪声集合经验模态分解(complete ensemble empirical mode

decomposition with adaptive noise, CEEMDAN)是 EMD 分解的一种改进方法,能够有效克服 EMD 分解的模态混叠现象。杨彦茹等<sup>[11]</sup>利用 CEEMDAN 对锂离子电池运行参数中提取的健康因子进行分解,使用支持向量回归对电池寿命做预测,具有较高的预测精度。在国外学者的研究中,Sánchez 等<sup>[12]</sup>分别采用 Elman 神经网络,自回归综合移动平均模型(autoregressive integrated moving average model, ARIMA)和两种模型的组合方法建立了 SO<sub>2</sub> 排放预测模型;Krzywanski 等<sup>[13]</sup>采用人工神经网络算法建立了循环流化床锅炉 SO<sub>2</sub> 排放量的广义预测模型。该方法考虑到多个影响因素,适用于循环流化床单元的模拟和优化。

湿法脱硫系统的腐蚀等问题会给传感器采集到的数据带来噪声,并且湿法脱硫系统具有强非线性,时延性的特点,机理模型不易得到。因此,为了更加准确的掌握湿法脱硫 SO<sub>2</sub> 排放的动态变化,优化脱硫机组的运行,本文提出了一种基于完全自适应噪声集合经验模态分解联合小波阈值去噪的方法对数据进行去噪处理;然后建立卷积神经网络,双向门控循环单元结合的组合模型对 SO<sub>2</sub> 浓度进行预测。首先从机组中采集 SO<sub>2</sub> 排放数据,使用 CEEMDAN 方法将数据分解成若干个 IMF 分量,对其中包含噪声的分量进行小波阈值去噪,得到平滑数据序列。使用卷积神经网络(convolutional neural network, CNN)对去噪后的数据中非线性特征进行自动提取,并结合双向门控循环单元(bi-directional gated recurrent unit, BiGRU)对数据中的时间联系进行挖掘以消除湿法脱硫系统的时延性。最后对各个分量分别进行预测,对预测结果进行线性重构得到最终的预测数据。实验表明,所提出的方法能够较为精确的预测 SO<sub>2</sub> 排放的浓度变化,可以为湿法脱硫机组运行的优化和调控提供一定的参考。

## 1 方法和原理

### 1.1 完全自适应噪声集合经验模态分解

针对 EMD 算法分解信号时容易出现的模态混叠问题,集合经验模态分解(ensemble empirical mode decomposition, EEMD)算法通过在待分解的信号中加入一对正负高斯白噪声来缓解。然而,这种改进方法也会带来问题,在分解后的信号的模态分量中会留下白噪声,给信号的后续分析和处理带来困难。

CEEMDAN 分解方法在 EMD 的基础上加以改进,同时借用了 EEMD 方法中加入高斯噪声和通过多次叠加并平均以抵消噪声的思想。通过下列改进解决了上述问题:EEMD 方法是将添加白噪声后的若干个信号直接做 EMD 分解,然后相对应的 IMF 间直接求均值;CEEMDAN 方法则是每求完一阶 IMF 分量,又重新给残值加入白噪声(或白噪声的 IMF 分量)并求此时的 IMF 分量均值,并逐次迭代。因为每次迭代添加都是最初始的那些白噪声的 IMF 分量(第 1 次迭代添加的是原始白噪声),这样便有效地解

解决了白噪声从高频到低频的转移传递问题<sup>[14]</sup>。CEEMDAN 的分解步骤如下：

1) 将高斯白噪声加入待分解序列  $s(t)$ , 得到新信号  $s(t) + (-1)^q \epsilon v^j(t)$ ,  $v^j$  为满足正态分布的高斯白噪声,  $\epsilon$  为噪声的标准差。对其进行 EMD 分解, 得到第 1 阶段的本征模态分量  $D_1$ 。

$$EMD(s(t) + (-1)^q \epsilon v^j(t)) = D_1^j(t) + Res^j \quad (1)$$

2) 对产生的  $M$  个本征模态分量进行总体平均即可得到 CEEMDAN 分解的第 1 个本征模态分量  $\overline{D_1(t)}$ :

$$\overline{D_1(t)} = \frac{1}{M} \sum_{j=1}^M D_1^j(t) \quad (2)$$

3) 去除第 1 个本征模态分量, 得到第 1 个残差  $Res_1(t)$ :

$$Res_1(t) = s(t) - \overline{D_1(t)} \quad (3)$$

4) 在第 1 个残差中加入正负成对的高斯白噪声得到新的信号, 对得到的信号再次进行 EMD 分解, 得到第 1 阶模态分量  $K_1^j$ , 据此可以得到 CEEMDAN 分解的第 2 个本征模态分量  $\overline{D_2(t)}$ :

$$\overline{D_2(t)} = \frac{1}{M} \sum_{j=1}^M K_1^j(t) \quad (4)$$

5) 去除第 2 个本征模态分量, 得到第 2 个残差  $Res_2(t)$ :

$$Res_2(t) = Res_1(t) - \overline{D_2(t)} \quad (5)$$

6) 重复步骤 1)~5), 直到残差信号不能再被分解, 算法结束。此时得到的本征模态分量个数为  $I$ , 则原始信号  $s(t)$  最终被分解为:

$$s(t) = \sum_{i=1}^I \overline{D_i(t)} + Res_I(t) \quad (6)$$

## 1.2 小波阈值去噪

小波阈值去噪可以有效地抑制信号中的无用部分。小波阈值去噪步骤为<sup>[15]</sup>:

1) 分解: 选择合适的小波函数和分解层数对信号进行分解, 将其分解为细节分量和近似分量;

2) 阈值处理: 通过选择适当的阈值, 对分析后得到的各层系数信息进行阈值处理, 把低于阈值的信息看作噪音并置为零以实现去噪的目的, 从而获得估计小波系数;

3) 重构: 重构去噪后的小波系数, 得到去噪后的信号。小波阈值去噪的流程如图 1 所示。

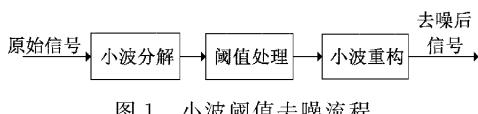


图 1 小波阈值去噪流程

## 1.3 卷积神经网络

特征提取可以从原始数据中提取主要信息, 帮助预测模型获得准确的预测结果, 是深度学习中非常关键的一步操作。这对于时间序列预测问题也是至关重要的, 因为时间序列数据中隐藏着许多动态的历史特征。近年来, 卷积

神经网络在图像处理领域取得了显著的成果。但最近也有学者将其应用于时间序列的处理, 取得了良好的效果<sup>[16~18]</sup>。利用卷积运算自动进行特征提取, 比人工操作更有效率。卷积神经网络主要由卷积层、池化层和全连接层组成。其结构如图 2 所示。

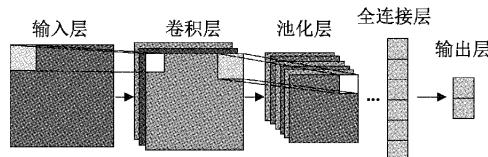


图 2 卷积神经网络结构

## 1.4 双向门控循环单元

门控循环单元(gated recurrent unit, GRU)是循环神经网络(recurrent neural network, RNN)的一种特殊形式, 是为了解决循环神经网络“梯度爆炸”问题而提出的。但是与LSTM神经网络相比, 它的单元内部更加简化, LSTM内部有3个门控结构而GRU只有两个-更新门和重置门, 进而让整个结构运算变得更加简化且性能得以增强。门控结构可以保留关键信息并且滤去部分不重要的信息。因此, GRU可以解决RNN的梯度爆炸问题, 捕捉序列中的关系, 被广泛应用于时间序列预测问题中<sup>[19~20]</sup>。由于WFGD反应机理的特点和SO<sub>2</sub>浓度测量的滞后性, 脱硫控制系统具有较大的延迟。因此, 本文使用GRU来预测出口处的SO<sub>2</sub>浓度。能够深度挖掘时间序列, 捕捉长期依赖关系。同时相比LSTM能够简化计算, 加快训练过程<sup>[21]</sup>。GRU的内部结构如图 3 所示, 在GRU单元内部所发生的信息的传递如式(7)~(11)所示。

$$r_t = \sigma(\mathbf{W}_r \cdot [h_{t-1}, x_t]) \quad (7)$$

$$z_t = \sigma(\mathbf{W}_z \cdot [h_{t-1}, x_t]) \quad (8)$$

$$h'_t = \tanh(\mathbf{W}_{h'} \cdot [r_t \cdot h_{t-1}, x_t]) \quad (9)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot h'_t \quad (10)$$

$$y_t = \sigma(\mathbf{W}_o \cdot h_t) \quad (11)$$

其中,  $r_t$  表示重置门,  $z_t$  表示更新门, 门控信号的范围为 0~1。门控信号越接近 1, 代表“记忆”下来的数据越多; 而越接近 0 则代表“遗忘”的越多。 $h_{t-1}$  为上一节点传输过来的状态,  $x_t$  为当前的输入;  $h'_t$  是当前节点隐藏状态,  $h_t$  是最终得到的当前时间状态。 $\mathbf{W}_r, \mathbf{W}_z, \mathbf{W}_{h'}, \mathbf{W}_o$  均为权重矩阵。

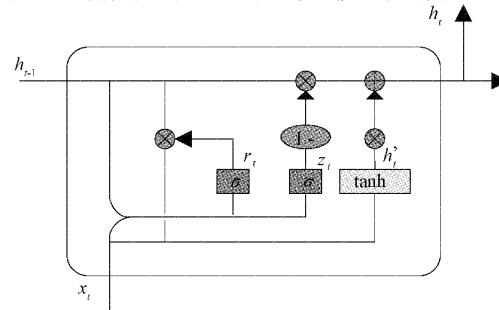


图 3 GRU 内部结构

双向门控循环单元是将两个不同方向的 GRU 网络层堆叠起来,如图所示,BiGRU 可以从正反两个方向对信息进行分析和处理,不仅能利用到过去的信息,还能捕捉到来未来信息对当前状态的影响,因此能够更加深入的挖掘时间序列上的联系。BiGRU 的结构如图 4 所示。

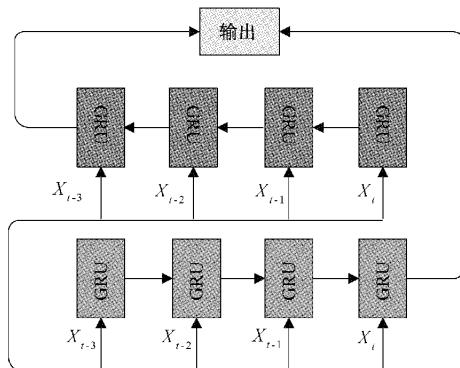


图 4 BiGRU 结构图

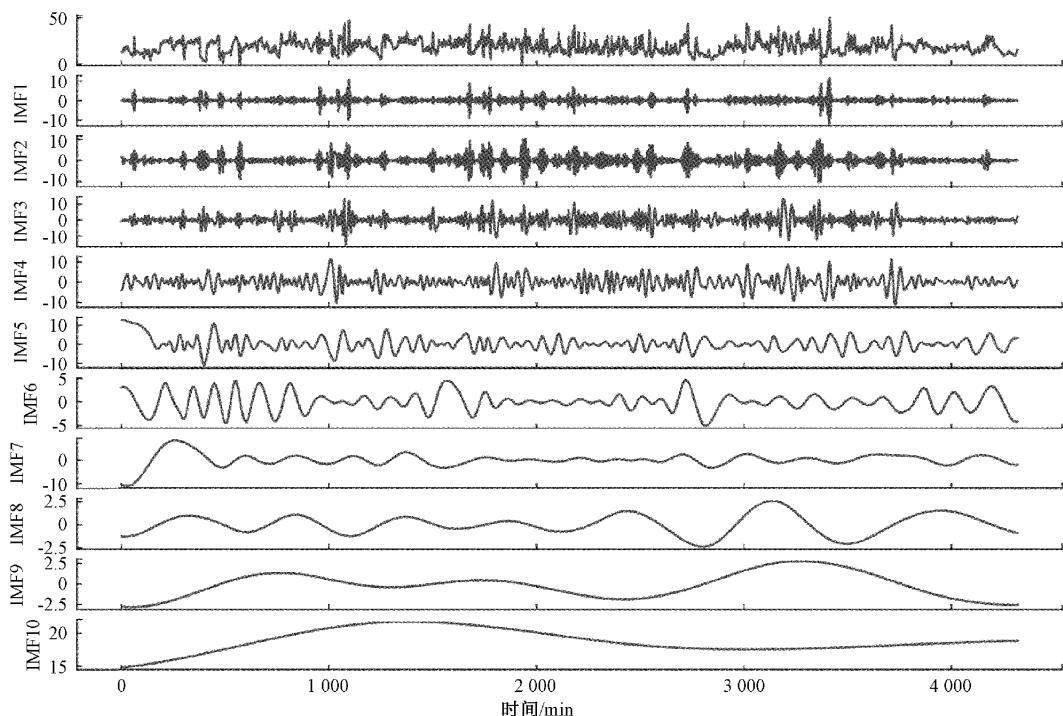
## 2 实例分析

### 2.1 数据去噪处理

由于湿法脱硫系统运行时间久会出现老化、结垢、腐蚀等问题,会产生噪声并影响到监测系统对数据的采集,因此采取适当的方法对数据进行去噪,有利于对数据的进一步处理。本实验所用数据均采集自一真实湿法脱硫机组运行数据,采样时间为 1 min,共采集时间跨度 3 天 4 320 组数据。对湿法脱硫机组出口处 SO<sub>2</sub> 浓度序列进行 CEEMDAN 分解,加入标准差为 0.2 的正负高斯白噪声。共分解得到 10 个 IMF 分量,结果如图 5 所示。

对得到的各个 IMF 分量与原始数据进行相关性分析,使用 Pearson 相关系数进行计算,Pearson 相关系数可以考察两个变量之间的相关程度,其计算如式(12)所示,其中 X,Y 为两个变量,cov 为协方差,σ 为标准差。

$$\rho_{XY} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} \quad (12)$$

图 5 SO<sub>2</sub> 浓度序列和 CEEMDAN 分解的本征模态分量波形图

得到的结果列在表 1 中,数字越大表示相关程度越高。由表中结果可以看出,IMF1 和 IMF2 分量,IMF8-IMF10 分量与原始序列的相关性相对较低,均小于 0.3,为弱相关。而其中 IMF1、IMF2 分量为高频分量,其频率与原始序列相比较为杂乱,基本无规律可循,通常认为其中包含较多的噪声,因此需要对其进行去噪处理。而 IMF8-IMF10 分量为低频分量,包含的信息较少,因此无需进行特别的降噪处理。因此使用小波阈值去噪对高频分量

IMF1 和 IMF2 进行去噪处理。

小波函数选取为“db8”,分解层数为 3 层,阈值函数为软阈值函数,阈值选取为通用阈值。在对高频信号做完去噪处理后,将其与其他 IMF 分量进行重构,最后得到去噪后的脱硫机组出口 SO<sub>2</sub> 浓度序列,部分序列如图 6 所示。由图像可以看出,与去噪之前的序列对比,去噪重构后的序列曲线更加平滑。证明该种方法去噪效果良好,基本上去除了隐藏在原始序列中的噪声。同时通过计算与原序

表 1 本征模态分量和原始序列 Pearson 相关系数

IMF 分量	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10
Pearson 相关系数	0.164 6	0.279 9	0.433 0	0.418 9	0.434 6	0.312 7	0.317 0	0.147 4	0.227 1	0.081 7

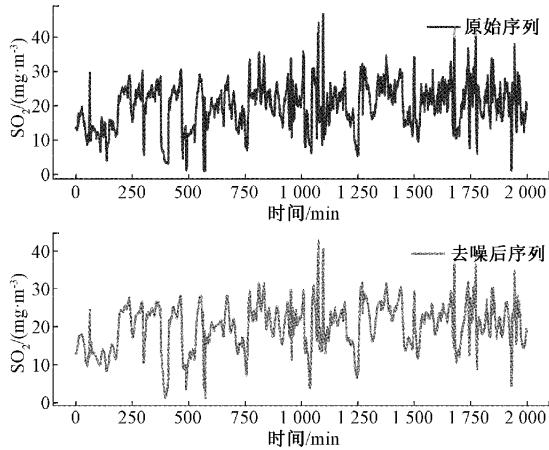


图 6 去噪前后部分序列对比

列的相关系数, 得到 Pearson 相关系数为 0.954 6, 证明 CEEMDAN 结合小波阈值去噪的方法在去除噪声的同时能够保留原始数据中的特征。

## 2.2 SO<sub>2</sub> 排放浓度预测

为了验证 CEEMDAN 分解对数据中隐含特征的提取作用, 本文对比了两种预测方案: 1) 对做完去噪处理后的各个 IMF 分量分别预测, 然后将预测结果重构得到最终预测结果; 2) 将各 IMF 分量重构为完整序列后再作预测。通过构建 CNN-BiGRU 模型对比了两种预测方案的不同。对数据进行归一化处理, 将数据缩放到 [0, 1] 范围, 能够加速模型的训练。归一化公式如下:

$$x_{nor} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (13)$$

其中,  $x_i$  表示第  $i$  个数据点的数据,  $x_{\max}$  是序列中的最大值,  $x_{\min}$  是序列中的最小值,  $x_{nor}$  是归一化后的数据。

本研究中的 SO<sub>2</sub> 排放预测模型是使用 Keras 库和 TensorFlow 后端建立的。训练混合模型比训练单一的神经网络模型更困难, 因为有可能出现梯度爆炸和过拟合。为了解决这一问题, 本文使用 Adam 优化器来优化训练过程, 学习率设置为 0.000 1, 最大迭代次数设置为 100。本文将时间窗口大小设置为 8, 每次滑动一步, 这表示使用前 8 min 的历史数据来预测下 1 min 的 SO<sub>2</sub> 排放浓度。80% 的数据被用作训练集, 20% 被用作测试集。模型包含一层一维卷积层, 卷积核数量为 60, 大小为 5, 激活函数为线性整流函数(rectified linear unit, ReLU); 一层池化层, 池化窗口大小为 2; 两层 BiGRU 层, 神经元个数分别为 64 和 32, 激活函数为双曲正切函数(hyperbolic tangent function, tanh); 一层全连接层, 神经元个数为 32, 激活函数为线性整流函数; 最后为一层输出层, 用来输出预测结

果。引入了均方根误差(root mean squared error, RMSE)和平均绝对误差(mean absolute error, MAE)作为评价指标。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (15)$$

其中,  $n$  为数据样本点,  $y_i$  表示原始数据,  $\hat{y}_i$  表示预测得到的数据。误差值越小表示预测结果越准确。

两种预测方案在测试集上的预测结果如图 7 所示, 由图像可以看出, 对各个分量分别预测, 再对得到的结果进行重构的预测方案, 得到的预测结果更加准确, 曲线更加贴近真实值, 且波动更小。由表 2 也可以看到, 预测后再重构的预测方案的 RMSE 和 MAE 误差值比分量重构后再进行预测分别降低了 0.135 7 和 0.284 3。这是因为通过 CEEMDAN 分解和小波阈值去噪后, 原始数据不仅变得更加平滑, 噪声减少, 其中隐含的特征被分解到各个 IMF 分量之中, 因而更加容易被预测模型识别和提取, 从而能够提升预测结果的准确度。而当将数据进行重构后, 特征提取则变得相对困难。因此最终本文决定采用对 IMF 分量分别进行预测再进行重构的预测方案。最终的湿法脱硫 SO<sub>2</sub> 排放浓度预测结构如图 8 所示。

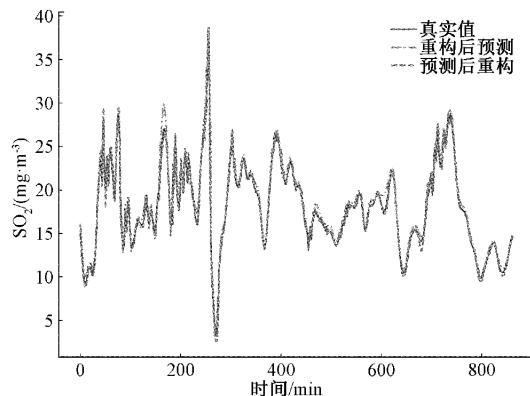


图 7 两种预测方案在测试集上的预测结果

表 2 两种预测方案在测试集上的误差值

预测方案	RMSE	MAE
预测后重构	0.699 6	0.355 3
重构后预测	0.835 3	0.639 6

为了验证本文所提出的 CNN-BiGRU 模型的效果, 引入了 BiGRU 模型、LSTM 模型和 CNN 模型与本文提出的模型做对比实验。实验结果如图 9 和表 3 所示。本文提出

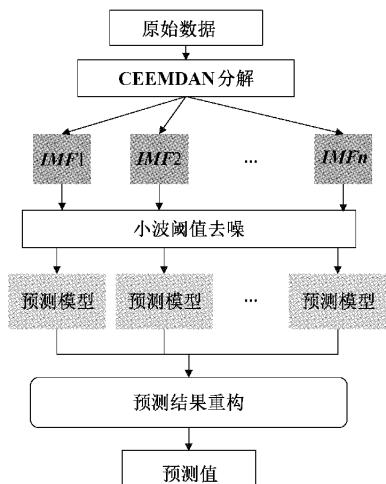


图 8 整体预测结构

的 CNN-BiGRU 模型平均每组分量训练时间为 593.91 s, 较多于单一的 CNN 模型的 158.15 s, 但是仍优于单一的 BiGRU 模型的 602.72 s 和 LSTM 模型的 1 137.85 s。LSTM 模型训练时间最长, 因其包含 3 个门结构, 计算最为复杂; 而单一的 CNN 模型由于其结构可以实现数据并行处理, 因此训练时间最短。但是在预测结果上, CNN-BiGRU 模型良好的跟踪了 SO<sub>2</sub> 排放的趋势, 与真实值的偏差最小。RMSE 值为 0.699 6, MAE 值为 0.355 3, 均为最低。而因为缺少 CNN 在前端的特征提取作用, 单一的 BiGRU 和 LSTM 模型对数据特征的挖掘上不够深入, 因而在预测结果的表现上要差于 CNN-BiGRU 模型。同样的, 缺少了后端对所提取时序特征数据处理的部分, CNN 的预测误差也相对较大。而单一的 LSTM 模型的表现不及 BiGRU 模型, 这可能是因为 LSTM 模型只从单一方向对时间序列进行处理, 而忽略了数据相反方向上的时序联系; 而 BiGRU 模型从两个方向上对 SO<sub>2</sub> 排放序列数据的时间联系进行挖掘进行, 所以表现要好于单一方向的 LSTM。总体上, CNN-BiGRU 模型的预测结果表现最好, 能较好的表现 SO<sub>2</sub> 排放的动态变化。

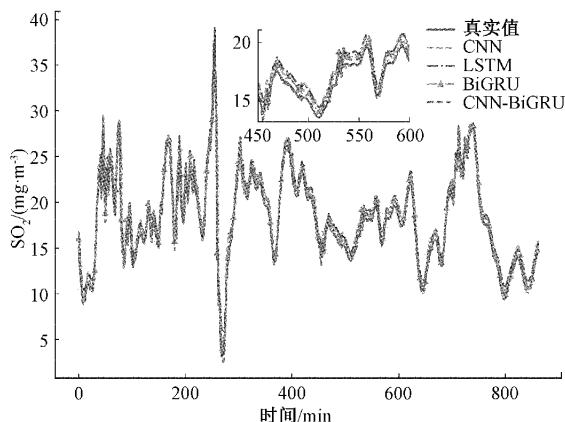


图 9 不同模型在测试集上的预测结果

表 3 不同模型在测试集上的表现

模型	RMSE	MAE	平均每组分量 训练时间/s
CNN-BiGRU	0.699 6	0.355 3	593.31
BiGRU	0.942 6	0.697 1	602.72
LSTM	1.200 7	1.018 7	1 137.85
CNN	1.229 3	0.844 7	158.15

### 3 结 论

针对石灰石-石膏湿法脱硫系统的运行优化问题, 提出了一种 CEEMDAN 分解和小波阈值去噪结合的数据去噪方法, 并结合 CNN-BiGRU 模型对 SO<sub>2</sub> 排放浓度进行预测。通过对比对分解变量预测后重构和重构后预测两种方案, 验证了 CEEMDAN 分解对数据特征提取上的有效性。最后对比了 CNN-BiGRU 模型与其他基准模型对 SO<sub>2</sub> 排放浓度预测的效果, 验证了 CNN-BiGRU 方法的可靠性和准确性。本文所提方法对火电厂石灰石-石膏湿法脱硫机组的运行优化具有一定的参考价值。

本文所提出方法仅使用到湿法脱硫系统 SO<sub>2</sub> 排放浓度单一数据, 未将系统中其他对 SO<sub>2</sub> 排放具有影响的特征变量考虑到模型构建中, 在后续的研究中可以考虑到多种变量的影响, 进一步增加模型的准确性。

### 参考文献

- [1] OCHOA G R, DÍAZ S M, MARTÍNEZ T M R. Influence of limestone characteristics on mercury re-emission in WFGD systems [J]. Environmental Science & Technology, 2013, 47(6): 2974-2981.
- [2] 马双忱, 周权, 曹建宗, 等. 湿法脱硫系统动态过程建模与仿真[J]. 化工学报, 2020, 71(8): 3741-3751.
- [3] 张悦, 韩璞, 张想. 石灰石-湿法烟气脱硫吸收塔仿真模型设计与研究[J]. 系统仿真学报, 2019, 31(2): 238-247.
- [4] MCHABE D, EVERSON R C, RAMACHANDRAN P A, et al. Development of an integrated model for absorption of sulphur dioxide in limestone slurry[J]. Chemical Engineering Science, 2021, 229: 116050.
- [5] DABADGHAO V, BIEGLER L T, BHATTACHARYYA D. Multiscale modeling and nonlinear model predictive control for flue gas desulfurization [J]. Chemical Engineering Science, 2022, 252: 117451.
- [6] 郑茗友, 王伟, 赵文杰, 等. 基于 PSO-Lasso 算法的电站湿法脱硫出口 SO<sub>2</sub> 浓度预测[J]. 华北电力大学学报(自然科学版), 2022, 49(1): 112-117.
- [7] 梁伟灿, 周宾, 王汗青. 基于 LS-CSO 优化 MWLS-SVM 的 SO<sub>2</sub> 排放浓度软测量建模[J]. 计算机应用与

- 软件, 2022, 39(5): 60-67.
- [8] 刘备, 任栋. 基于小波变换与 RBF 神经网络的 GNSS 水汽值预测研究[J]. 大地测量与地球动力学, 2021, 41(12): 1216-1218.
- [9] 王荣茂, 谢宁, 于海洋, 等. 基于 EMD-LSTM 模型的台区负荷短期预测方法[J]. 实验室研究与探索, 2022, 41(1): 62-66, 79.
- [10] 金秀章, 刘岳, 于静, 等. 基于变量选择和 EMD-LSTM 网络的出口 SO<sub>2</sub> 浓度预测[J]. 中国电机工程学报, 2021, 41(24): 8475-8484.
- [11] 杨彦茹, 温杰, 史元浩, 等. 基于 CEEMDAN 和 SVR 的锂离子电池剩余使用寿命预测[J]. 电子测量与仪器学报, 2020, 34(12): 197-205.
- [12] SÁNCHEZ A B, ORDÓÑEZ C, LASHERAS F S, et al. Forecasting SO<sub>2</sub> pollution incidents by means of Elman artificial neural networks and ARIMA models [C]. Abstract and Applied Analysis. Hindawi, 2013, DOI: 10.1155/2013/238259.
- [13] KRZYWANSKI J, CZAKIERT T, BLASZCZUK A, et al. A generalized model of SO<sub>2</sub> emissions from large-and small-scale CFB boilers by artificial neural network approach: Part 1. The mathematical model of SO<sub>2</sub> emissions in air-firing, oxygen-enriched and oxycombustion CFB conditions[J]. Fuel Processing Technology, 2015, 137: 66-74.
- [14] 王海龙, 赵岩, 王海军, 等. 基于 CEEMDAN-小波包分析的隧道爆破信号去噪方法[J]. 爆炸与冲击, 2021, 41(5): 125-137.
- [15] 施晶, 朱明, 沈华, 等. 基于 VMD 和小波阈值的水听器信号去噪方法[J]. 传感技术学报, 2020, 33(7): 1003-1012.
- [16] 何彦, 肖圳, 李育锋, 等. 基于 CNN-SVR 的汽车组合仪表组装质量预测方法[J]. 中国机械工程, 2022, 33(7): 825-833.
- [17] 黄婕, 张丰, 杜震洪, 等. 基于 RNN-CNN 集成深度学习模型的 PM<sub>2.5</sub> 小时浓度预测[J]. 浙江大学学报(理学版), 2019, 46(3): 370-379.
- [18] 邢红涛, 郭江龙, 刘书安, 等. 基于 CNN-LSTM 混合神经网络模型的 NO<sub>x</sub> 排放预测[J]. 电子测量技术, 2022, 45(2): 98-103.
- [19] 丁宁, 邵丁, 闫勇, 等. 基于门控循环单元的动态过程中两相 CO<sub>2</sub> 质量流量测量[J]. 仪器仪表学报, 2021, 42(10): 112-120.
- [20] 颜清云, 宋连庆, 何永康. 基于经验模态二次分解的改进门控循环单元风速超短期组合预测模型[J]. 国外电子测量技术, 2021, 40(6): 6-13.
- [21] 赵兵, 王增平, 纪维佳, 等. 基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J]. 电网技术, 2019, 43(12): 4370-4376.

### 作者简介

孙坤, 硕士, 主要研究方向为复杂系统建模与优化。  
E-mail: 1224310521@qq.com

尹晓红(通信作者), 博士, 主要研究方向为复杂系统建模与优化、预测控制理论及其应用、绿色建筑节能优化。  
E-mail: yxh@qust.edu.cn