

基于混合建模方法循环流化床锅炉深度调峰 NO_x 排放预测

张鹏新¹, 高明明¹, 郭炯楠¹, 于浩洋¹, 黄中², 周托²

(1. 华北电力大学 新能源电力系统国家重点实验室, 北京 102206; 2. 清华大学 能源与动力工程系, 北京 100084)

摘要:为响应碳达峰、碳中和目标,我国循环流化床锅炉大规模参与深度调峰运行,导致锅炉 NO_x 排放浓度波动范围大,控制效果不佳,难以满足污染物超低排放需求,因此对深度调峰 NO_x 排放浓度进行精准建模预测有重要意义。以即燃碳模型为基础,深度剖析炉内 NO_x 生成和还原机理,建立炉内即燃碳燃烧模型、O₂ 动态平衡模型、CO 软测量模型、NO_x 生成与还原模型,完成 SNCR 入口 NO_x 浓度机理计算;选取给煤量、床温、烟气温度及含氧量、一二次风量、尿素溶液流量作为 NO_x 排放浓度的输入变量,将 SNCR 入口 NO_x 浓度计算值作为拓展输入变量,对所有输入变量与 NO_x 排放浓度进行相关性分析和延迟补偿,完成数据集重构;采用长短期记忆神经网络对重构数据集进行训练和预测,并将鲸鱼优化算法用于长短期记忆神经网络的参数优化,建立循环流化床锅炉深度调峰 NO_x 排放浓度机理——数据混合预测模型。仿真验证表明混合预测模型不同工况下预测性能和泛化能力好,能够实现循环流化床锅炉变负荷时 NO_x 排放浓度的实时预测,相较其他预测模型的各项误差性能指标均显著提升,平均绝对误差 δ_{MAE} 达 2.14 mg/m³,平均相对百分误差 δ_{MAPE} 达 5.68%,决定系数 R^2 达 0.902 1。混合预测模型能精准预测循环流化床锅炉深度调峰下 NO_x 排放浓度,为循环流化床锅炉超低排放智能控制系统的设计提供参考。

关键词:循环流化床锅炉;深度调峰;NO_x 排放浓度;延迟补偿;混合预测模型

中图分类号:TM621.2;TK229.6 文献标志码:A 文章编号:1006-6772(2024)09-0085-10

Prediction of NO_x emissions from deep peaking circulating fluidized bed boilers based on a hybrid modelling approach

ZHANG Pengxin¹, GAO Mingming¹, GUO Jiongnan¹, YU Haoyang¹, HUANG Zhong², ZHOU Tuo²

(1. State Key Laboratory of Alternate Electrical Power System With Renewable Energy Sources, North China Electric

Power University, Beijing 102206, China; 2. Department of Energy and Power Engineering, Tsinghua University, Beijing 100084, China)

Abstract: In response to the goal of Carbon peak Carbon neutral, China's circulating fluidized bed boilers participate in deep peaking operation on a large scale, resulting in large fluctuation ranges of NO_x emission concentration in boilers, poor control effect, and difficulty in meeting the demand for ultra-low emission of pollutants, so it is important to accurately model and predict the NO_x emission concentration in deep peaking. Based on the instantaneous carbon model, the NO_x generation and reduction mechanism in the furnace was deeply analyzed, and the instantaneous carbon combustion model, O₂ dynamic balance model, CO soft measurement model, NO_x generation and reduction model were established to complete the calculation of the mechanism of the NO_x concentration at the entrance of the SNCR. The amount of coal feed, bed temperature, flue gas temperature and oxygen content, the first and second airflow, and the flow rate of the urea solution were selected as the input variables for the NO_x emission concentration, and the NO_x emission concentration was predicted by the SNCR inlet model. The SNCR inlet NO_x concentration was used as an extended input variable, and the data set was reconstructed by correlation analysis and delay compensation between all input variables and NO_x emission concentration. The reconstructed data set was

收稿日期:2024-07-06;责任编辑:戴春雷 DOI:10.13226/j.issn.1006-6772.LHX24070601

基金项目:国家重点研发计划资助项目(2022YFB4100304)

作者简介:张鹏新(2000—),男,山西大同人,硕士研究生。E-mail: 1912179047@qq.com

通讯作者:高明明(1979—),男,山西吕梁人,教授,博士。E-mail: gmm1@ncepu.edu.cn

引用格式:张鹏新,高明明,郭炯楠,等.基于混合建模方法循环流化床锅炉深度调峰 NO_x 排放预测[J].洁净煤技术,2024,30(9):85-94.

ZHANG Pengxin, GAO Mingming, GUO Jiongnan, et al. Prediction of NO_x emissions from deep peaking circulating fluidized bed boilers based on a hybrid modelling approach[J]. Clean Coal Technology, 2024, 30(9): 85-94.



移动阅读

trained and predicted by using long and short-term memory neural network, and whale optimization algorithm was used for the optimization of parameters of the long and short-term memory neural network to establish a NO_x emission concentration model, the mechanism-data hybrid prediction model, for deep peaking of circulating fluidized bed boilers. The simulation validation shows that the hybrid prediction model has good prediction performance and generalization ability under different working conditions, and is able to realize real-time prediction of NO_x emission concentration in circulating fluidized bed boilers at variable loads, and significantly improves all the error performance indexes compared with other prediction models, with an average absolute error δ_{MAE} up to 2.14 mg/m^3 , an average relative percentage error δ_{MAPE} up to 5.68%, and a coefficient of determination R^2 up to 0.902 1. The hybrid prediction model can accurately predict the NO_x emission concentration under deep peaking in circulating fluidized bed boilers, which provides a reference for the design of the ultra-low emission intelligent control system of circulating fluidized bed boilers.

Key words: circulating fluidized bed boiler; deep peaking regulation; NO_x emission concentration; delayed compensation; hybrid predictive model

0 引言

循环流化床(Circulating Fluidized Bed, CFB)锅炉因其蓄能热力强,超低负荷工况下稳燃性能好^[1]等优点得到快速发展^[2]。近年来,我国CFB机组大规模运行在深度调峰,快速变负荷的工况之下,用以平抑新能源并网发电产生的波动性与不确定性。然而CFB锅炉在参与深度调峰中炉内燃烧温度场,气体流场状态多变,容易出现 NO_x 排放浓度波动大,瞬时值易超标等,无法满足日益严格的污染物排放标准^[3]。现场运行人员为降低 NO_x 排放,往往在脱硝系统中喷入过量氨水,容易导致喷枪的磨损和报废,严重影响运行的经济性与安全性,还会导致氨逃逸增加,造成环境污染,危害人体健康。因此对深度调峰中 NO_x 排放浓度的精准建模与预测有重要意义,成为国内外学者研究热点。

目前CFB机组 NO_x 排放浓度建模一般分为机理模型与数据驱动模型2类。在机理建模方面,高明明等^[4]基于即燃碳模型,考虑炉内 NO_x 双步竞争反应机理建立了炉外 NO_x 浓度模型,精度高,基本满足工程实际需求。KE等^[5]分析机组变负荷过程中关键参数变化与 NO_x 变化的非线性关系及影响,用CFB锅炉一维两相综合数学模型定量分析 NO_x 排放特性。张冲冲^[6]将CFB锅炉划分为11个小室,对每一个小室的燃烧分别建模,并分析给煤量、一二次风与 NO_x 的动态排放特性。蒋海威等^[7]以即燃碳模型为基础,建立炉内燃烧, NO_x 生成与脱除模型,并分析影响 NO_x 排放浓度变化的关键状态变量。然而机理模型建模较复杂,计算实时性对硬件要求极高,动态适用性受制约因素很多。

在数据驱动建模方面,深度学习因其极强的理解、学习和处理信息间非线性关系的能力,广泛运用于CFB机组 NO_x 浓度建模与预测。张媛媛等^[8]利用遗传算法优化BP神经网络的模型结构与参数,

实现超低负荷下 NO_x 浓度建模,预测性能好。YU等^[9]基于量子遗传算法优化的极限学习机建立 NO_x 浓度模型,优化后模型的预测精度和泛化性能均显著提高。尹贵豪等^[10]建立基于欧氏距离聚类的锅炉不同工况下脱硝入口 NO_x 浓度LSTM预测模型,相关系数达0.89。相比于机理模型,数据驱动模型属于忽略参数内部状态的黑箱模型,无法体现深度调峰中炉内反应的动态特性;且对数据的依赖性极强,数据波动大时,往往出现预测值偏离实际趋势的情况。

针对以上问题,笔者将机理建模的先验知识纳入数据驱动模型之中,基于即燃碳理论建立CFB锅炉选择性非催化还原(SNCR)入口 NO_x 浓度动态平衡模型;选取 NO_x 排放浓度特征变量构建原始数据集,将SNCR入口 NO_x 浓度机理模型计算值作为拓展输入变量,并分析深度调峰中锅炉各运行参数与 NO_x 排放浓度之间动态迟延,完成数据集重构;用WOA-LSTM对重构数据集进行预测和优化;实现CFB锅炉 NO_x 排放浓度的机理与数据驱动混合建模预测。预测某350 MW超临界循环流化床锅炉深度调峰 NO_x 排放浓度,将预测结果与其他模型进行对比验证,结果表明,笔者提出的模型拟合效果更好,泛化能力更强,能为现场脱硝智能控制策略设计提供一定参考。

1 CFB锅炉 NO_x 排放浓度混合预测模型

1.1 SNCR入口 NO_x 浓度动态平衡模型

我国现役的循环流化床锅炉一般用选择性非催化还原(SNCR)进行烟气脱硝,将尿素按一定比例稀释为尿素溶液后,由喷枪喷入CFB锅炉的炉膛出口烟道中,在烟道的高温环境下迅速反应生成氨气,再与炉内燃烧产生的 NO_x 反应生成氮气和水,实现烟气脱硝,未经反应的部分 NO_x 将随烟气进入烟囱排进大气中,图1为SNCR脱硝过程。

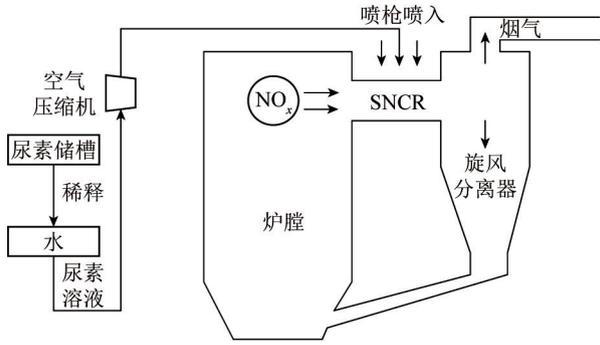


图1 SNCR脱硝过程

Fig.1 SNCR denitrification process

可见 SNCR 入口 NO_x 浓度将直接影响最终 NO_x 排放浓度,然而由于 SNCR 入口处烟气温度高且受负荷波动影响大,严重削弱检测装置的检测效果,工程现场一般不设测点对 SNCR 入口 NO_x 浓度检测。因此本节将基于即燃碳模型,合理简化炉内燃烧机理,建立 SNCR 入口 NO_x 浓度动态平衡模型。

1.1.1 燃烧模型

CFB 锅炉入炉燃料一般为粒径相对大的煤颗粒,且炉膛底部存在大量床料,煤颗粒和床料经一、二次风的混合在炉膛中燃烧,少量挥发分和粒径小的燃料在流化作用下进入炉膛上部的水平烟道,大部分粒径大的燃料通过内循环向炉膛下部流动继续燃烧后,经水平烟道进入旋风分离器回到炉膛,燃料不断循环经历以上过程,需几分钟甚至十几分钟才能燃尽,因此引入即燃碳存量表征炉内存碳量。根据质量守恒定律,即燃碳存量增加的部分来源于给煤中的碳,即燃碳存量减少主要来自燃烧消耗,少量来自飞灰和排渣的损失^[11]。因此即燃碳存量可表示为:

$$\frac{dJ}{dt} = W_c C_{ar} - R_c - W_{fa} \varphi_{c,fa} - W_{ds} \varphi_{c,ds}, \quad (1)$$

式中, J 为即燃碳存量,kg; t 为时间,s; W_c 为给煤量,kg/s; C_{ar} 为燃料收到基碳质量分数,%; R_c 为即燃碳燃烧速率,kg/s; W_{fa} 、 W_{ds} 分别为飞灰和排渣速率,kg/s; $\varphi_{c,fa}$ 、 $\varphi_{c,ds}$ 分别为飞灰和排渣含碳质量分数,%。由于飞灰和排渣造成的碳损失很少,且实时测量难度高,因此将飞灰和排渣中碳质量分数折算到收到基碳质量分数中^[12]。

即燃碳燃烧速率:

$$R_c = \frac{6M_c k_s C(O_2)}{d_c \rho_c} J, \quad (2)$$

式中, M_c 为碳摩尔质量,g/mol; k_s 为即燃碳燃烧速率常数; $C(O_2)$ 为炉内氧气物质的量浓度,mol/m³; d_c 为单颗碳颗粒半径,m; ρ_c 为碳颗粒密度,kg/m³; J 为

即燃碳存量,kg。

即燃碳燃烧速率常数 k_s 计算方法如下^[13]:

$$k_s = \frac{1}{\frac{1}{k_c} + \frac{1}{k_g}} = \frac{1}{\frac{1}{k_c} + \frac{d_c}{shD_g}}, \quad (3)$$

式中, k_c 为燃烧反应速率; k_g 为氧气扩散速率; sh 为碳颗粒的舍伍德数; D_g 为氧气扩散系数^[14],m²/s。

炉内氧气浓度动态平衡模型如下:

$$\frac{dC(O_2)}{dt} = \frac{1}{V} (k_q W_d - 1000R_c/M_c - W_d C(O_2)), \quad (4)$$

式中, V 为炉膛体积,m³; k_q 为摩尔换算系数; W_d 为总送风量,m³/s。

炉内即燃碳燃烧的主要产物为 CO 和 CO₂,CO 生成速率 $R(CO)$ 为:

$$R(CO) = (2 - \frac{2}{\zeta}) R_c, \quad (5)$$

式中, ζ 为表征 CO 与 CO₂ 平衡关系的机械因子,计算方法如下所示^[15]:

$$\zeta = \frac{2p + 2}{p + 2}, \quad (6)$$

$$p = 2500 \exp\left(\frac{-1.59 \times 10^3}{RT}\right), \quad (7)$$

式中, p 为表征即燃碳燃烧产物中 CO 与 CO₂ 的摩尔比系数; R 为摩尔气体常数; T 为床温,℃。

CO 会继续氧化生成 CO₂,其反应速率 $R(CO_2)$ 为^[16]:

$$R(CO_2) = C(O_2)^{0.5} C(CO) k(CO_2), \quad (8)$$

式中, $C(CO)$ 为 CO 物质的量浓度,mol/m³; $k(CO_2)$ 为 CO 氧化速率常数。

CO 在炉内参与反应结束后,剩余量将进入尾部烟道进一步处理排放至大气中,结合式(5)与式(8)可知炉内 CO 浓度的动态平衡模型为:

$$\frac{dC(CO)}{dt} = \frac{1}{V} (R(CO) - R(CO_2) - W_d C(CO)). \quad (9)$$

1.1.2 NO_x 初始生成模型

煤炭中氮一般分为挥发分氮和焦炭氮,挥发分氮的转化为 NO_x 机理极为复杂,中间产物多,且反应时间很短,因此认为挥发分氮进入炉膛后瞬间生成 NO_x 进入水平烟道。焦炭氮转化为 NO_x 时间很长,一般认为与即燃碳燃烧速率有关^[17],炉内 NO_x 初始生成量 $J(NO_x)$ 计算方法如下:

$$J(NO_x) = \zeta_N N_{ar} \left[W_c V_{daf} + \frac{(1 - V_{daf}) R_c}{C_{ar}} \right], \quad (10)$$

式中, ζ_N 为燃料氮转化率, %; N_{ar} 为燃料中氮元素的质量分数, %; V_{daf} 为燃料中挥发分质量分数, %。

一般认为燃料氮生成 NO_x 转化率与煤中挥发分含量有关, 其经验计算公式为^[18]:

$$\zeta_N = -2.8412 \times 10^{-4} Z^3 + 0.01364 Z^2 - 0.3063 Z + 15.756 \quad (11)$$

Z 与燃料中挥发分含量有关, 计算方法如下:

$$Z = V_{daf} - 30.637 \quad (12)$$

1.1.3 NO_x 自还原模型

即燃碳不完全燃烧的产物 CO 有一定还原性, 会与炉内 NO_x 产生还原反应。CFB 锅炉内一般加入石灰石作为脱硫剂脱除炉内 SO_2 , 加入石灰石对 NO_x 生成与还原均有一定促进作用, 但其对 NO_x 生成促进作用更突出, 忽略石灰石对 NO_x 还原作用, 因此仅考虑 CO 对 NO_x 还原反应, 反应速率 $R(NO_x)$ 计算方法如下^[19]:

$$R(NO_x) = k(NO_x)C(NO_x)C(CO)^{0.3} J \quad (13)$$

式中, $k(NO_x)$ 为 NO_x 自还原反应速率常数; $C(NO_x)$ 为炉内 NO_x 物质的量浓度, mol/m^3 。

综上, 燃料燃烧产生的 NO_x 部分参与与 CO 自还原反应, 另一部分随烟气进入 SNCR 中脱硝, 可建立 SNCR 入口 NO_x 浓度动态平衡模型:

$$\frac{dC(NO_x)}{dt} = \frac{1}{V}(J(NO_x) - R(NO_x) - W_d C(NO_x)) \quad (14)$$

1.2 WOA-LSTM 神经网络

鲸鱼优化算法 (Whale Optimization Algorithm, WOA) 是模拟座头鲸狩猎过程的元启发式算法, 主要模拟鲸鱼捕食中收缩包围机制、螺旋更新机制和随机搜索机制^[20]。

1) 收缩包围机制

WOA 一般假设当前最佳候选解为全局最优解, 即为目标猎物的位置, 确定目标猎物后, 其余鲸鱼将对其进行收缩包围, 该行为表示方法如下:

$$P(k+1) = P^*(k) - AD \quad (15)$$

式中, $P(k+1)$ 为迭代 $k+1$ 次时当前鲸鱼个体位置; $P^*(k)$ 为迭代 k 次时目标猎物位置; A 为系数向量; D 为当前鲸鱼个体与目标猎物之间距离。

2) 螺旋更新机制

鲸鱼会用收缩包围机制逼近猎物, 还会螺旋产生气泡网逼近猎物, 该过程可用螺旋更新公式表示:

$$P(k+1) = e^{zl} \cos(2\pi l) P^*(k) D \quad (16)$$

式中, z 为决定鲸鱼螺旋前进路径的常数; l 为 $[-1, 1]$ 之间随机数。

3) 随机搜索机制

当 $|A| > 1$ 时, 为鲸鱼开始随机搜索猎物, 该机制相当于捕食的搜索阶段^[21]。该机制随机选择鲸鱼位置作为最优解位置, 表达式如下:

$$P(k+1) = P_{rand}(k) - AD \quad (17)$$

式中, $P_{rand}(k)$ 为迭代 k 次时随机选择的鲸鱼个体的位置。

长短期记忆神经网络 (Long Short-Term Memory, LSTM) 解决了传统人工神经网络处理大惯性、大延迟和强非线性问题出现的梯度消失与梯度爆炸等, 在电力行业各对象的数据驱动建模中得到大规模应用^[22-23]。但预测效果受参数设置影响大, 而 WOA 原理简单、寻优能力强、速度快、鲁棒性强, 通过模仿鲸鱼不同的捕食行为, 能动态调整其搜索机制, 在搜索空间中快速全面探索潜在的最优解, 避免陷入局部最优。因此将 WOA 用于 LSTM 学习率和隐含层节点数进行寻优, 获取最优参数设置, 能提高 LSTM 预测精度, 形成 WOA-LSTM 神经网络模型。

1.3 混合预测模型构建

1.3.1 特征变量拓展

CFB 锅炉特殊燃烧方式造就其燃烧系统的大延迟、大惯性。在深度调峰中, 给煤量、床温和一、二次风量等参数无法直观表征锅炉实时燃烧热量及气氛实时变化与动态特性, 而笔者建立的即燃碳模型、 O_2 和 CO 动态平衡模型一定程度能快速准确反映锅炉宽负荷运行下炉内温度场和气氛场动态变化, 且以上述模型为基础建立的 SNCR 入口 NO_x 浓度模型更直观地反映未经脱硝处理的原始 NO_x 浓度变化趋势。因此将 SNCR 入口 NO_x 浓度机理模型计算值作为 WOA-LSTM 神经网络模型的拓展输入变量, 解决了数据驱动模型与机理模型动态特性结合问题。

1.3.2 基于滑动窗口的最大互信息系数计算

由于 CFB 锅炉燃烧及脱硝存在大延迟、大惯性, 且烟气连续排放监测系统 (CEMS) 测量存在一定滞后性, 同一时刻测得参数值间时序并不统一, 如直接将未经延迟补偿的原始数据用于 WOA-LSTM 神经网络建模预测, 将严重影响模型的预测精度。因此用一种基于滑动窗口的最大互信息系数计算方法, 对各输入变量与 NO_x 排放浓度间进行动态延迟时间计算和补偿。

互信息系数 (MI) 通过计算变量之间概率密度分布描述变量间相关性^[24], 互信息系数越大, 表示变量间相关性越强, 计算方法如下:

$$\delta_{MI(x,y)} = \sum_{x \in X} \sum_{y \in Y} p(x,y) \log_2 \frac{p(x,y)}{p(x)p(y)} \quad (18)$$

式中, $\delta_{MI(x,y)}$ 为 X、Y 的互信息系数; x, y 属于 X、Y 的样本; X 为输入样本; Y 为输出样本; $p(x, y)$ 为 X 和 Y 的联合概率密度函数; $p(x)$ 为输入样本 X 的边缘概率密度函数; $p(y)$ 为输出样本 Y 的边缘概率密度函数。

基于滑动窗口的最大互信息系数计算如下:

1) 对某输入变量, 选择总数为 n 的样本, 生成数据集;

2) 定义时间窗口长度 $length$;

3) 计算该变量窗口内与 NO_x 排放浓度的互信息系数;

4) 窗口向后滑动一步, 增加一个新的数据, 并剔除队首前端一个数据, 重复步骤 3;

5) 将互信息系数最大时刻作为该变量与 NO_x 排放浓度的最佳延迟时间。

整体流程如图 2 所示。

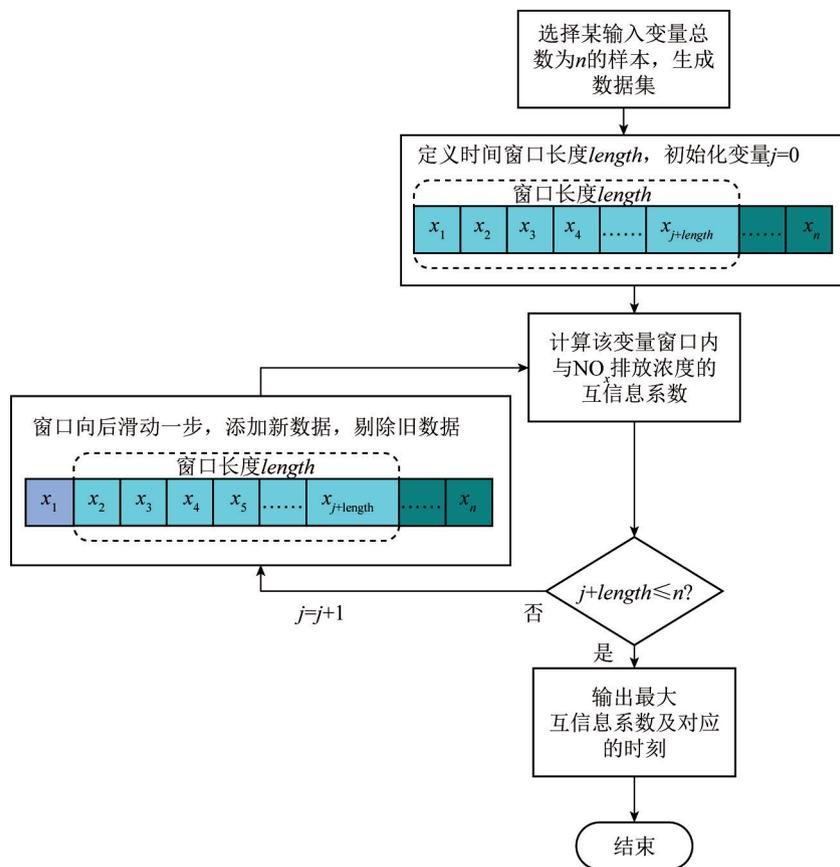


图 2 基于滑动窗口的最大互信息系数计算流程

Fig.2 Flow of maximum mutual information coefficient calculation based on sliding window

1.3.3 模型预测与优化

将经延迟补偿后数据集划分为训练集、测试集和验证集, 对其进行归一化处理, 方法如下:

$$\bar{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, \quad (19)$$

式中, \bar{x}_i 为当前变量第 i 个归一化后的数据, x_i 为当前变量第 i 个原始数据, x_{\min} 和 x_{\max} 为当前变量最小值和最大值。

将归一化后数据集代入 LSTM 神经网络进行训练、测试和验证。预测结束后计算测试集适应度, 以适应度最小为寻优目标, 用 WOA 对 LSTM 学习率和隐含层节点数寻优, 将寻优结果返回 LSTM 神经网络重新训练、测试和验证, 直到达到 WOA 所设置的迭代次数后输出 LSTM 最优参数设置与预测结果。

测试集适应度 F 计算方法如下:

$$F = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (20)$$

式中, n 为样本个数; y_i 和 \hat{y}_i 分别为输出变量第 i 个实际值和预测值。

综上, 混合预测模型预测流程如下:

1) 根据机理模型计算 SNCR 入口 NO_x 浓度;

2) 选择输入输出变量, 构建数据集;

3) 根据滑动窗口最大互信息计算方法计算输入输出变量最大互信息系数及最佳延迟时间, 完成延迟补偿;

4) 数据集归一化处理, 代入 LSTM 神经网络进行训练;

5) 计算测试集适应度, 以适应度最小为寻优

目标;

6) 开始迭代,使用 WOA 寻优 LSTM 学习率和隐含层节点个数;

7) 将当前学习率和隐含层节点个数返回

LSTM,重新训练;

8) 重复第 5、6、7 步,直到达到设置的迭代次数;

9) 输出当前最优预测结果。

混合预测模型结构如图 3 所示。

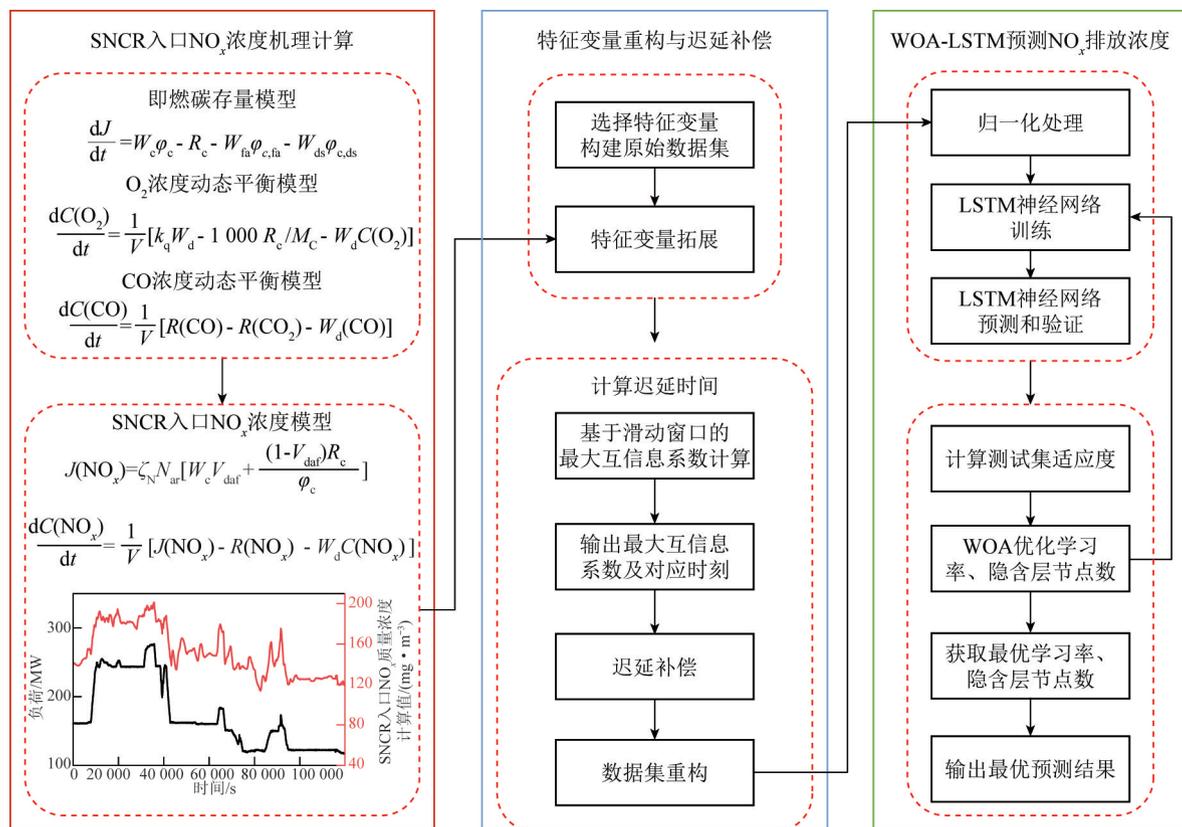


图 3 混合预测模型结构

Fig.3 Hybrid forecasting model structure

2 数据集重构与模型超参数选取

2.1 对象说明

以某 350 MW 超临界循环流化床机组为研究对象,锅炉型号为 SG-1204/25.4-M4601,采取强

制循环方式。选取该机组参与深度调峰连续运行 33 h 17 min 45 s 历史运行数据进行 NO_x 排放浓度混合建模预测,负荷变化范围 33% ~ 80% ECR (117 ~ 275 MW)。该机组设计煤种煤质分析参数见表 1。

表 1 煤质分析参数

Table 1 Parameters of coal quality analysis

工业分析			元素分析					%
M_{ar}	A_{ar}	V_{daf}	C_{ar}	H_{ar}	O_{ar}	N_{ar}	S_{ar}	
7.50	44.35	46.76	34.35	2.39	9.70	0.63	1.08	

2.2 数据集重构

2.2.1 特征变量选取

柯希玮等^[25]分析了 CFB 锅炉 NO_x 生成和排放动态特性,认为影响 NO_x 原始生成的因素除燃料元素组成与热解特性外,主要与 CFB 锅炉炉内的温度场和还原性气氛强弱有关,造成温度场变化的主要因素有负荷、给煤量、床温和炉膛出口烟气温度;还原性气氛的强弱则由一二次风配比和炉膛出口烟气

含氧量决定。影响 SNCR 脱硝效率的主要因素为尿素溶液流量。因此选取负荷、给煤量、床温、烟气温、烟气含氧量、一二次风量、尿素溶液流量作为 WOA-LSTM 神经网络模型输入变量,选择对应时刻的 NO_x 排放浓度作为输出变量,完成混合预测模型原始数据集构建。

2.2.2 SNCR 入口 NO_x 浓度计算

根据建立的 CFB 机组 SNCR 入口 NO_x 浓度动态

平衡模型,对所选取的数据段计算 SNCR 入口 NO_x 浓度,数据段负荷变化及 SNCR 入口 NO_x 质量浓度计算结果如图 4 所示。

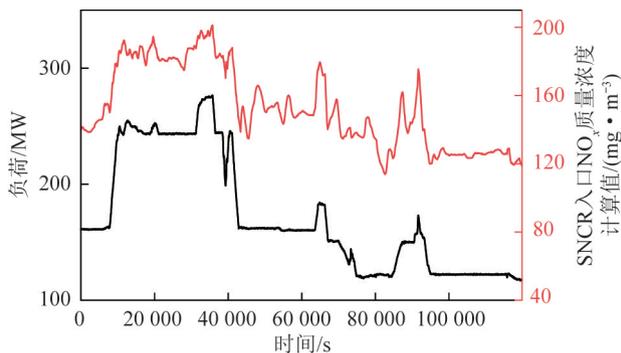


图 4 负荷变化范围与 SNCR 入口 NO_x 质量浓度计算结果

Fig.4 Calculated range of load variation and SNCR inlet NO_x mass concentration

将计算结果加入选取的特征变量数据集中,完成特征变量拓展。

2.2.3 延迟补偿

数据采样时间为 15 s,根据经验假设 CFB 锅炉一个完整的燃烧和脱硝周期为 180 s。用基于滑动窗口的最大互信息系数计算方法对选取的输入变量与 NO_x 浓度之间最大互信息计算及最佳延迟时间进行计算,结果见表 2。

表 2 最大互信息系数及最佳延迟时间

Table 2 Maximum mutual information coefficient and optimum delay time

变量	最大互信息系数	最佳延迟时间/s
负荷	0.688	120
给煤量	0.667	120
床温	0.579	105
一次风量	0.461	105
二次风量	0.632	105
烟气温度	0.712	75
烟气含氧量	0.719	75
尿素溶液流量	0.636	15
SNCR 入口 NO _x 质量浓度	0.859	15

根据计算结果对各输入变量进行手动动态延迟补偿,将负荷、给煤量向前平移 8 个数据点,将床温、一二次风量向前平移 7 个数据点,将烟气温度和含氧量向前平移 5 个数据点,将尿素溶液流量和 SNCR 入口 NO_x 浓度向前平移 1 个数据点,实现输入输出变量之间时序统一,完成了数据集重构。

2.3 模型超参数调试

数据驱动模型的超参数设置会对预测结果产生极大影响,不同超参数间组合是否合适往往需大量

试验调整,以获取模型最佳预测性能和泛化能力。数据驱动模型在 MATLAB 环境下编程实现,用 trainingOptions 函数配置 LSTM 模型的训练参数,并将其传递给 trainNetwork 函数用以构建 LSTM 神经网络,经多次调试,得到调试次数内最优的 WOA 和 LSTM 超参数初始化设置分别见表 3、表 4。

表 3 鲸鱼优化算法的超参数初始化设置

Table 3 Parameter initialisation settings for the whale optimisation algorithm

种群个数	算法维度	迭代次数	学习率下降因子
25	2	20	0.2

表 4 LSTM 的超参数初始化设置

Table 4 Parameter initialisation settings of LSTM

最大训练次数	初始隐含层节点数	隐含层节点数寻优范围	初始学习率	学习率寻优范围
5 000	10	[2,30]	0.005	[0.001,0.020]

3 仿真验证与误差分析

3.1 仿真验证设计

将时间尺度 33 h 17 min 45 s 的重构后数据集划分为训练集、测试集和验证集,进行 NO_x 排放浓度混合建模预测。其中训练集时长 22 h 10 min 45 s,测试集时长 5 h 33 min 30 s,验证集时长 5 h 33 min 30 s。

用平均绝对误差 (mean absolute percentage error, δ_{MAE})、平均绝对百分误差 (mean absolute percentage error, δ_{MAPE}) 和决定系数 (R -square, R^2) 3 种误差性能指标进行误差的定量分析,计算公式分别如下:

$$\delta_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i^{\wedge} - y_i|, \quad (21)$$

$$\delta_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i^{\wedge} - y_i}{y_i} \right| \times 100\%, \quad (22)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i^{\wedge} - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (23)$$

式中, n 为输出变量样本个数; y_i^{\wedge} 为输出变量第 i 个预测值; y_i 为输出变量第 i 个实际值; \bar{y} 为输出变量平均值。

图 5 为混合预测模型适应度迭代曲线,进行 20 次迭代,在第 1~5 次迭代中,适应度下降速度很快,表明此时鲸鱼优化算法快速收敛,全局搜索最优适

度的个体;第6~20次迭代中适应度不变,认为此时已达最优适应度,为 6.703×10^{-3} 。

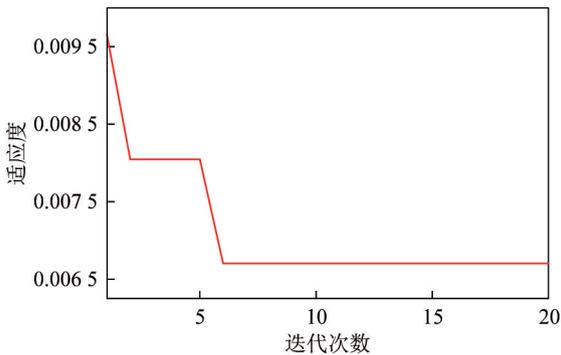


图5 混合预测模型适应度曲线

Fig.5 Hybrid prediction model fitness curves

3.2 不同超参数对模型结果影响

为进一步说明 WOA-LSTM 神经网络模型所选取的不同超参数组合对模型预测性能影响,基于预测结果准确性和计算时效性2种指标,分析手动调试不同超参数组合下模型的性能表现,模型预测结果见表5。

表5 不同超参数组合下模型预测性能

Table 5 Model prediction performance with different combinations of hyperparameters

组合	种群个数	迭代次数	初始学习率	学习率下降因子	$\delta_{MAE}/(\text{mg} \cdot \text{m}^{-3})$	计算时间/s
1	25	20	0.005	0.2	2.14	106
2	25	20	0.010	0.2	2.34	108
3	25	20	0.005	0.1	2.27	121
4	20	20	0.005	0.2	2.41	97
5	25	25	0.005	0.2	2.12	136

由表5可见,提高学习率和降低学习率下降因子可能导致模型无法稳定收敛到最优解,使模型准确率降低,同时会对模型求解速度造成一定影响;减少WOA的种群个数能缩短模型求解时间,提高求解效率,但会导致模型预测结果误差增大,限制模型预测精度;增加模型求解迭代次数虽能一定程度减小预测误差,但模型求解时间大幅提升,不利于模型预测的实时性。综合以上几点,选取的超参数组合1为最优。

3.3 数据集重构对模型结果影响

为验证 SNCR 入口 NO_x 浓度计算结果及输入变量迟延补偿对模型预测精度影响,将原始数据集与重构数据集分别建模预测和验证,测试集和验证集结果如图6和图7所示。

由图6可知机组负荷呈现快速上升与下降的动态变化, NO_x 排放浓度大范围波动,此时重构数据集

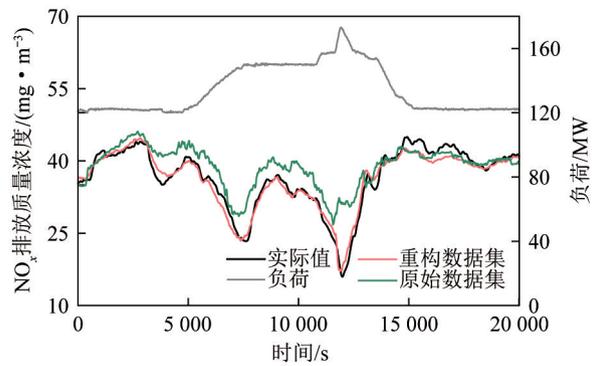


图6 重构数据与原始数据测试集结果

Fig.6 Test results of reconstructed dataset and original dataset

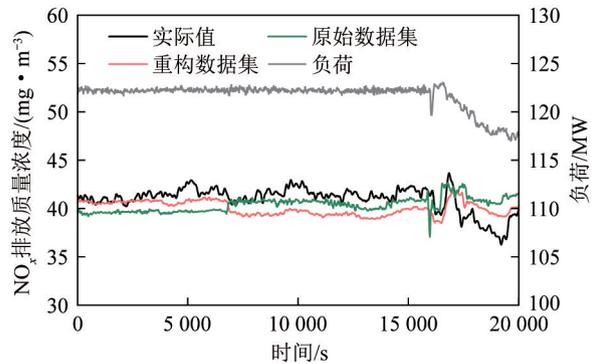


图7 重构数据与原始数据验证集结果

Fig.7 Validation results of reconstructed dataset and original dataset

的预测结果能准确拟合变化趋势,还能保证预测值数值的精确性;而原始数据集预测结果对该变化趋势的拟合不够明显,且预测值数值较实际值有大程度偏移。

由图7可知在稳态工况下,原始数据集验证结果在15000s左右出现阶跃上升与下降,这种现象对现场脱硝控制系统自动运行极为不利;而重构数据集仍能保证好的预测性能,预测值趋势较平稳,一定程度验证了其稳态工况下泛化能力。

对重构数据集和原始数据集整体预测结果进行定量误差分析,各项误差性能指标见表6。

表6 重构数据集与原始数据集预测结果误差指标

Table 6 Error indicators of the prediction results of the reconstructed dataset and the original dataset

项目	$\delta_{MAE}/(\text{mg} \cdot \text{m}^{-3})$	$\delta_{MAPE}/\%$	R^2
重构数据集	2.14	5.68	0.902 1
原始数据集	2.44	6.59	0.714 3

由表6可知重构数据集 δ_{MAE} 下降 $0.3 \text{ mg}/\text{m}^3$, δ_{MAPE} 降低 0.51% , R^2 提高 $0.187 8$,各项误差性能指标均大程度提升。原因是重构数据集扩展了SNCR入口 NO_x 浓度计算值作为输入变量,同时实现不同

输入变量与输出变量间相关性最强时刻的时序统一,极大提高模型参数之间相关性,提高建模精度。

3.4 LSTM 参数优化对模型结果影响

为验证利用 WOA 对 LSTM 结构参数寻优对模型预测精度产生影响,将重构数据集代入 BP 神经网络、LSTM 神经网络和 WOA-LSTM 神经网络进行建模预测和验证,测试集和验证集结果如图 8 和图 9 所示。

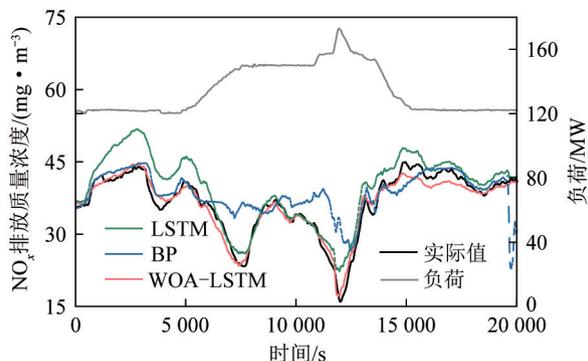


图 8 不同数据驱动模型测试集结果

Fig.8 Results of different data-driven model test sets

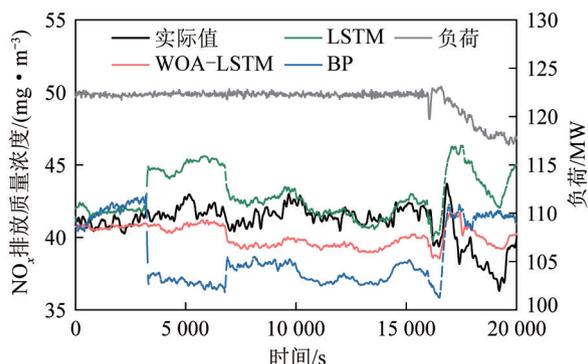


图 9 不同数据驱动模型验证集结果

Fig.9 Results of different data-driven model validation sets

由图 8 可知,在负荷大范围变动的工况下,BP 神经网络出现大程度模型失配现象,预测值与实际值数值偏差大,还出现预测值阶跃上升与下降的现象;LSTM 神经网络虽然能一定程度反映 NO_x 变化趋势,但其预测值数值较实际相差大;WOA-LSTM 能较好反映出实际值变化趋势,模型匹配效果更好,预测值数值更接近真实值。说明 WOA-LSTM 在处理强非线性长时间序列问题时未出现梯度消失与梯度爆炸的问题,经 WOA 对 LSTM 学习率和隐含层节点数优化,使其训练和预测中对输入输出数据之间依赖关系捕捉能力更强。图 9 所示结果对以上结论进行更进一步验证。

对不同数据驱动模型整体预测结果进行定量误差分析,各项误差性能指标见表 7。由表 7 可知利用 WOA 对 LSTM 结构参数进行寻优后, δ_{MAE} 降低

0.22 mg/m³, δ_{MAPE} 降低 0.54%, R^2 提高 0.089 2。量化说明 WOA 对 LSTM 结构参数优化结果取得一定成效,提高模型预测性能。

表 7 不同数据驱动模型预测结果误差指标

Table 7 Error indicators for the prediction results of different data-driven models

项目	$\delta_{MAE}/(\text{mg} \cdot \text{m}^{-3})$	$\delta_{MAPE}/\%$	R^2
WOA-LSTM 神经网络	2.14	5.68	0.902 1
LSTM 神经网络	2.36	6.22	0.812 9
BP 神经网络	4.06	10.91	0.636 8

4 结 论

1)以即燃碳模型为基础,根据机理分析,建立了 CFB 锅炉 O₂ 浓度、CO 浓度、NO_x 生成和自还原浓度动态平衡模型,利用某超临界 CFB 锅炉现场运行数据实现 SNCR 入口 NO_x 浓度机理计算模拟;计算值与 NO_x 实际排放浓度间互信息系数达 0.859,验证了其作为 NO_x 排放浓度预测模型输入变量的可行性。

2)将 SNCR 入口 NO_x 浓度计算值作为拓展输入变量,并通过滑动窗口最大互信息系数动态延迟补偿方法实现输入输出变量之间时序统一,使 NO_x 排放浓度混合预测模型在深度调峰下预测精度大幅提高,与原始数据集预测结果平均绝对误差和平均相对误差分别降低 0.3 mg/m³ 和 0.51%。

3)通过鲸鱼优化算法对 LSTM 神经网络参数寻优,使混合预测模型在变负荷工况和稳态工况下预测性能均显著提升,模型适配性能和泛化能力更强。混合预测模型预测值与实际值整体平均绝对误差达 2.41 mg/m³,平均相对误差达 5.68%,能实现 CFB 锅炉深度调峰 NO_x 排放浓度精准动态预测,为 SNCR 脱硝系统的智能优化控制提供模型基础。

参考文献 (References):

- [1] YUE G, CAI R, LU J, et al. From a CFB reactor to a CFB boiler—The review of R&D progress of CFB coal combustion technology in China [J]. Powder Technology, 2017, 316: 18–28.
- [2] 黄中, 杨娟, 车得福. 大容量循环流化床锅炉技术发展应用现状[J]. 热力发电, 2019, 48(6): 1–8.
HUANG Zhong, YANG Juan, CHE Defu. Current status of development and application of large-capacity circulating fluidised bed boiler technology [J]. Thermal Power Generation, 2019, 48(6): 1–8.
- [3] 中华人民共和国生态环境部, 关于印发《全面实施燃煤电厂超低排放和节能改造工作方案》的通知 [EB/OL]. (2015-12-11) [2024-06-10]. https://www.mee.gov.cn/gkml/hbb/bwj/201512/t20151215_319170.htm.

- [4] 高明明,郭炯楠,于浩洋,等.适应深度调峰的循环流化床 NO_x 排放建模[J].洁净煤技术,2023,29(6):24-31.
GAO Mingming, GUO Jiongnan, YU Haoyang, et al. Modelling of NO_x emissions from circulating fluidised beds for deep peaking[J]. Clean Coal Technology, 2023, 29(06): 24-31.
- [5] KE X, ZHU S, HUANG Z, et al. Issues in deep peak regulation for circulating fluidized bed combustion: Variation of NO_x emissions with boiler load [J]. Environmental Pollution, 2023, 318: 120912.
- [6] 张冲冲.循环流化床锅炉变负荷过程中污染物排放动态特性研究[D].太原:太原理工大学,2019.
- [7] 蒋海威,高明明,张开萍,等.循环流化床大气污染物机理模型及关键状态变量研究[J].动力工程学报,2024,44(4):622-631.
JIANG Haiwei, GAO Mingming, ZHANG Kaiping, et al. Mechanistic modeling of atmospheric pollutants and key state variables in circulating fluidized beds [J]. Journal of Power Engineering, 2024, 44(04): 622-631.
- [8] 张媛媛,曲江源,王鹏程,等.超低负荷循环流化床机组 NO_x 超低排放的 GA-BP 算法优化模型[J].热力发电,2021,50(12):35-42.
ZHANG Yuanyuan, GU Jiangyuan, WANG Pengcheng, et al. Optimisation model of GA-BP algorithm for ultra-low emission of NO_x from ultra-low load circulating fluidised bed unit [J]. Thermal Power Generation, 2021, 50(12): 35-42.
- [9] YU H, GAO M, ZHANG H, et al. Dynamic modeling for SO_2 - NO_x emission concentration of circulating fluidized bed units based on quantum genetic algorithm-Extreme learning machine [J]. Journal of Cleaner Production, 2021, 324: 129170.
- [10] 尹贵豪,赵中阳,李钦武,等.基于入口 NO_x 质量浓度修正的脱硝系统多模型预测控制策略及其应用案例[J].环境工程学报,2022,16(6):1879-1891.
YIN Guihao, ZHAO Zhongyang, LI Qinwu, et al. Multi-model predictive control strategy for denitrification system based on the correction of inlet NO_x mass concentration and its application cases [J]. Journal of Environmental Engineering, 2022, 16(6): 1879-1891.
- [11] ZHANG H F, GAO M M, YU H Y, et al. A dynamic nonlinear model used for controller design of a 600 MW supercritical circulating fluidized bed boiler-turbine unit [J]. Applied Thermal Engineering, 2022, 212: 118547.
- [12] 洪烽.基于蓄能深度利用的循环流化床机组动态优化控制[D].北京:华北电力大学,2019.
- [13] ZHANG H F, GAO M M, FAN H H, et al. A dynamic model for supercritical once-through circulating fluidized bed boiler-turbine units [J]. Energy, 2022, 241: 122914.
- [14] 潘江海.准能矸电 330 MW 循环流化床锅炉动态特性的仿真研究[D].北京:华北电力大学,2013:16-17.
- [15] ZHOU W, ZHAO C S, DUAN L B, et al. Two-dimensional computational fluid dynamics simulation of coal combustion in a circulating fluidized bed combustor [J]. Chemical Engineering Journal, 2011, 166(1): 306-314.
- [16] YU H Y, GAO M M, ZHANG H F, et al. Dynamic modeling of key operating parameters for supercritical circulating fluidized bed units based on data-knowledge-driven method [J]. Journal of Thermal Science, 2024, 33(3): 1216-1230
- [17] 贾宁.循环流化床锅炉 SNCR 脱硝控制过程优化研究[D].吉林:东北电力大学,2022.
- [18] SUN W Y, YE M M, GAO Y H, et al. Effect of catalyst inlet flow field distribution characteristics on outlet NO concentration distribution in SCR denitration reactor based on monte carlo method [J]. Atmosphere, 2022, 13(6).
- [19] 刘春,高明明,张洪福,等.300 MW 亚临界循环流化床机组 NO_x 排放建模[J].洁净煤技术,2023,29(8):109-115.
LIU Chun, GAO Mingming, ZHANG Hongfu, et al. NO_x emission model of 300 MW subcritical circulating fluidized bed unit [J]. Clean Coal Technology, 2023, 29(8): 109-115.
- [20] BHANDAKKAR A A, MATHEW L. Merging slime mould with whale optimization algorithm for optimal allocation of hybrid power flow controller in power system [J]. Journal of Experimental & Theoretical Artificial Intelligence, 2023, 35(7): 973-1000.
- [21] ZAMAN K, ZHAOYUN S, SHAH B, et al. Efficient power management optimization based on whale optimization algorithm and enhanced differential evolution [J]. Alexandria Engineering Journal, 2023, 79: 652-670.
- [22] 刘岳,于静,金秀章.基于特征优化和改进长短期记忆神经网络的 NO_x 质量浓度预测[J].热力发电,2021,50(7):162-169.
LIU Yue, YU Jing, JIN Xiuzhang. NO_x mass concentration prediction based on feature optimization and improved LSTM network [J]. Thermal Power Generation, 2021, 50(7): 162-169.
- [23] 李秀昊,刘怀西,张智勇,等.基于VMD-LSTM的超短期风向多步预测[J].南方能源建设,2023,10(1):29-38.
LI Xiuhao, LIU Huaixi, ZHANG Zhiyong, et al. Very short-term wind direction multistep forecast based on VMD-LSTM [J]. Southern Energy Construction, 2023, 10(1): 29-38.
- [24] 赵文杰,张楷.基于互信息变量选择的SCR烟气脱硝系统非线性自回归神经网络建模[J].热力发电,2018,47(9):22-26.
ZHAO Wenjie, ZHANG Kai. Nonlinear autoregressive neural network modeling of SCR flue gas denitrification system based on mutual information variable selection [J]. Thermal Power Generation, 2018, 47(9): 22-26.
- [25] 柯希玮,张曼,杨海瑞,等.循环流化床锅炉 NO_x 生成和排放特性研究进展[J].中国电机工程学报,2021,41(8):2757-2771.
KE Xiwei, ZHANG Aman, YANG Hairui, et al. Progress of NO_x generation and emission characteristics in circulating fluidised bed boilers [J]. Chinese Journal of Electrical Engineering, 2021, 41(8): 2757-2771.