

基于 LightGBM-CatBoost 的循环流化床锅炉 NO_x 排放浓度预测研究

武洁^{1,2}, 周会成^{2,3}, 梅文^{2,3}, 刘小恺¹, 云达娜¹, 王峰^{2*}, 唐忠锋³, 张志勇¹

(1. 内蒙古电力(集团)有限责任公司内蒙古电力科学研究院分公司, 内蒙古呼和浩特 010020;

2. 内蒙古工业大学能源与动力工程学院, 内蒙古呼和浩特 010051;

3. 中国科学院上海应用物理研究所, 上海 201800)

摘要:为实现燃煤机组变负荷下循环流化床(Circulating Fluidized Bed, CFB)锅炉的 NO_x 排放浓度预测,采用数据驱动-集成学习的 4 种算法构建了 6 个预测模型。以某 300 MW 燃煤机组的 CFB 锅炉为例,采用 6 个模型算法研究了不同负荷、给煤量和一次风量对 CFB 锅炉 NO_x 排放浓度的影响,并对其 NO_x 排放浓度进行了预测。研究表明,与其他 5 个模型相比,LightGBM-CatBoost(L-C)模型的平均绝对误差和均方根误差分别为 0.12 和 0.16,拟合优度为 0.98,预测精度和稳定性最佳。随 CFB 锅炉的负荷变化,NO_x 排放浓度预测值与实测值最大相对误差小于 13.9%,预测值相对误差小于 3%。给煤量变化时,XGBoost-CatBoost 和 LightGBM-NGBoost 2 模型预测的 NO_x 排放浓度值与实测值最大相对误差为 9%,小于 L-C 模型预测的相对误差 13.9%。在 NO_x 浓度高于 120 mg/m³ 时,L-C 模型预测的 NO_x 排放浓度值与实测值最大偏差小于 5%。L-C 模型能够保证宽负荷条件下对 CFB 锅炉 NO_x 排放浓度值精准预测。本研究可以为选择性非催化还原技术的低氮氧化物燃烧及控制提供新的思路,对 CFB 锅炉的灵活性改造提供了重要的方法和数据支持。

关键词:数据驱动;循环流化床;NO_x;集成学习;烟气脱硝

中图分类号:K221

文献标志码:A

文章编号:0253-4320(2026)06-0244-08

DOI:10.16606/j.cnki.issn0253-4320.2026.06.038

Prediction of NO_x emission concentration in circulating fluidized bed boiler based on LightGBM-CatBoost.

WU Jie^{1,2}, ZHOU Hui-cheng^{2,3}, MEI Wen^{2,3}, LIU Xiao-kai¹, YUN Da-na¹,
WANG Feng^{2*}, TANG Zhong-feng³, ZHANG Zhi-yong¹

(1.Inner Mongolia Electric Power Scientific Research Institute Branch, Inner Mongolia Electric Power (Group) Co., Ltd., Hohhot 010020, China; 2.College of Energy and Power Engineering, Inner Mongolia University of Technology, Hohhot 010051, China; 3.Shanghai Institute of Applied Physics, Chinese Academy of Sciences, Shanghai 201800, China)

Abstract:NO_x emission concentration of circulating fluidized bed (CFB) boilers were predicted by six prediction models consisted four data-driven ensemble learning algorithms.The effects of load, coal feed and primary airflow on NO_x emission concentration were investigated and a 300 MW CFB boiler was employed as an example.Compared with the other five models,the LightGBM-CatBoost (L-C) model displayed the best prediction accuracy and stability with an MAE and RMSE of 0.12 and 0.16, which R-squared was 0.98.The maximum relative error between the predicted and measured NO_x emission concentration was less than 13.9% with the changes of load,and most of relative error of the predicted values was less than 3%.The maximum relative error was 9% between the NO_x emission concentration values predicted by the XGBoost-CatBoost and LightGBM-NGBoost models and the measured values when the coal feed varies, which was smaller than the relative error of 13.9% predicted by the L-C model.The maximum deviation of NO_x emission concentration values predicted by the L-C model was less than 5% when the measured values of NO_x emission concentrations were higher than 120 mg/m³.The L-C model ensures the accurate prediction of NO_x emission concentration for CFB boiler under the condition of wide load.It provides an advanced theory for selective non-catalytic reduction technology in low NO_x combustion control and supports theoretical foundations and data for the implementation of flexibility retrofits in CFB boilers.

Key words:data-driven; circulating fluidized bed; NO_x; ensemble learning; flue gas denitrification

收稿日期:2025-07-21;修回日期:2026-03-30

基金项目:中央引导地方科技发展资金项目(2023ZY0006);内蒙古电力集团(有限)责任公司内蒙古电力科学研究院分公司自筹科技项目(2024-ZC-2-04)

作者简介:武洁(1986-),女,博士生,高级工程师,研究方向为能源与环境保护,wujiegongda@126.com;王峰(1981-),女,博士,教授,研究方向为碳捕集技术、储热材料等,通讯联系人,wangfeng@imut.edu.cn。

循环流化床(circulating fluidized bed, CFB)锅炉凭借高燃烧效率、广泛的燃料适应性、出色的调峰能力以及低污染物排放的特性,在燃煤电厂中得到了广泛应用^[1-3]。为满足超低排放要求,大部分 CFB 锅炉采用选择性非催化还原技术(selective non-catalytic reduction, SNCR)来减少 NO_x 排放,该技术通过控制 CFB 锅炉炉膛或旋风分离器入口的氨基还原剂喷入量,将 NO_x 还原为 N₂,进而大幅度减少 NO_x 排放^[4]。为实现可再生能源消纳,燃煤电厂中 CFB 锅炉需承担调峰任务。当燃煤机组进行调峰时,CFB 锅炉的炉膛内温度、氧量等发生变化,炉膛内燃烧环境的变化使 NO_x 生成量高于常规工况^[5-6],同时由于机组调峰运行导致烟气温度难以达到 SNCR 投运温度范围^[7],致使还原剂与 NO_x 反应速率变慢,NO_x 脱除效率降低,排放浓度增大^[8]。调峰状态下如何对 CFB 锅炉中 NO_x 排放浓度进行精准预测和控制至关重要,目前已经成为研究的热点。

近年来,采用机器学习方法对 CFB 锅炉的 NO_x 排放浓度进行预测已成为研究热点。随着人工智能的快速发展,以及大量工业数据的收集与保存,为 NO_x 排放浓度的预测提供了数据支撑^[9]。Xu 等^[10]通过将改进的文化算法与长短期记忆神经网络结合,建立了具有自适应能力的 CFB 锅炉动态燃烧模型,优化后算法提升了模型 NO_x 排放浓度的预测精度,最大相对误差不超过 4%。任少君等^[11]将煤量、氧量及燃尽风开度等数据嵌入到神经网络中,提出了一种基于物理信息神经网络的锅炉 NO_x 排放浓度预测方法,该方法拟合优度达到 0.96,均方根误差值为 5。研究者分别采用神经网络、极端随机树、集成学习等方法建立了 CFB 锅炉脱硝预测模型并优化,优化算法的加入有效降低了模型的平均绝对误差,使模型 NO_x 排放浓度预测精度提升到 93%以上^[12-16]。Hoque 等^[17]采用集成学习方法对燃气轮机 NO_x 排放量进行预测,研究表明,极端梯度提升算法(XGBoost)的预测精度为 91.5%,特征提升算法(CatBoost)的预测精度为 92.8%。综上所述,CFB 锅炉 NO_x 排放浓度预测主要聚焦于传统机器学习算法及优化^[18-20],主要目标是提升预测精度。研究者采用集成学习算法对 CFB 锅炉中 NO_x 排放浓度进行简单预测,未考虑利用算法间的互补性及适应性进行预测^[21-22]。基于数据驱动-集成学习预测 CFB 锅炉 NO_x 排放浓度的模型构建及泛化能力研

究鲜有报道。

本文中以某 300 MW 燃煤电厂 CFB 锅炉进行建模,采用集成学习算法对其 NO_x 排放浓度的影响因素进行分析,充分考虑算法间的互补性和适应性后将 4 种集成学习算法进行组合,构建了 6 个均值集成模型,针对 6 个模型开展稳定性、准确性等开展对比评价。结果表明轻量梯度提升机-特征提升(LightGBM-CatBoost, L-C)模型预测的 NO_x 排放浓度值与实测值偏差最小,NO_x 排放浓度大于 120 mg/m³ 时偏差小于 5%,L-C 模型能够保证宽负荷条件下对燃煤机组 CFB 锅炉 NO_x 排放浓度精准预测。构建的集成学习预测模型在预测 CFB 锅炉污染物排放浓度方面具有很好的适用性和有效性,为深度调峰期间 CFB 锅炉 NO_x 排放及控制提供了可靠的方法和数据支撑。

1 模型的构建及计算

1.1 输入条件

本文中以某 300 MW 燃煤机组的 CFB 锅炉为研究对象,其中 CFB 锅炉的组成包括单炉膛、全吊结构、全钢架 II 型布置,配备 2 台 50% 容量的一次风机、二次风机及引风机,选用 2 台电袋除尘器。CFB 炉膛横截面尺寸为 28.3 m×39.9 m,自然循环,采用膜式水冷壁。为化简模型建立条件,CFB 锅炉过热器出口蒸气压力值为 17.4 MPa、再热器进出口蒸气压力值为 3.48 MPa。煤质特性会影响燃烧过程中 NO_x 生成,但在工程实际中,一定周期内电厂煤质基本维持不变^[23],因此建模数据时间范围内,煤质特性设定为定值。由于在煤燃烧过程中,含氮量和挥发分含量相关,本文中选用设计煤种的特性参数作为模型输入,所选用的混煤主要由煤矸石、洗中煤和煤泥组成。所选煤种为低热值、低水分、高灰分、高挥发分的劣煤烟煤,收到基低位发热量 $Q_{\text{net,ar}}$ 为 12 350 kJ/kg。

1.2 数据采集与特征提取

CFB 锅炉气体排放浓度的数据集源自内蒙古某电厂 300 MW 燃煤机组 CFB 锅炉分布式控制系统(DCS)和烟气在线监测系统(CEMS)中可以测得的实测数值(表 1)。由于收集到的数据中 SNCR 内氨氮摩尔比接近于 1,且变化很小,因此将氨氮比设置为 1。CFB 锅炉 NO_x 排放关键特征参数见表 1,其中发电机功率、瞬时给煤量等参数取自锅炉分布式控制系统。数据集涉及 25 个特征变量和 1 个目标变量。其中 N1 表示发电机的功率,N2 表示总排口

处烟气中 O₂ 浓度, N3 表示所有给煤机平均瞬时给煤量, N4~N9 表示 CFB 锅炉负荷变化时 5 个风道点火器的一次风量, N10~N12 表示 CFB 锅炉负荷变化时 3 个监测点测得的排气压力, N13 表示炉膛内部烟气温度, N14 表示在总排口处的烟气温度, N15~N25 表示 CFB 锅炉负荷变化时炉膛内 11 个不同位置的二次风箱风量门开度。

表 1 CFB 锅炉 NO_x 排放关键特征参数

标签	描述
N1/MW	发电机功率
N2/%	O ₂ 浓度
N3/(t·h ⁻¹)	瞬时给煤量
N4~N9/(t·h ⁻¹)	点火器入口一次风量
N10~N12/Pa	排气压力
N13/°C	炉烟气温度
N14/°C	总排口处烟气温度

煤燃烧产生的 NO_x 主要包括一氧化氮(NO)、二氧化氮(NO₂)和少量一氧化二氮(N₂O)^[24], 燃烧过程中产生的燃料型 NO_x 浓度与过剩空气系数及瞬时给煤量呈正线性相关关系^[25]。图 1 描述了瞬时给煤量、一次风量等参数与 NO_x 排放浓度之间的关联强度。本数据集中大部分特征变量相关性较强, 但数据集中依然存在部分冗余特征, 这些特征与 NO_x 排放浓度相关性小, 在模型学习过程中可将其简化分析^[26]。




图 1 各参数关系热图

图 1 为根据表 1 中数据生成的各参数关系热图, 横纵坐标均为特征参数标签, 每一方格内数值为 2 对特征参数的线性相关系数, 相关系数越大表示变量间线性相关性越强。从图 1 可以得出, 相关系数主要集中于 0.5~1.0。其中 N6、N7 与 y 即 NO_x

生成浓度的相关系数达到了 0.69, 说明在本数据集建模过程中一次风量与 NO_x 浓度具有强线性相关关系。N1、N3、N10 和 N12 与 NO_x 生成浓度的相关系数均大于 0.65, 表示发电机功率、瞬时给煤量和排气压力都与 NO_x 生成浓度具有较强的线性相关性, 故有必要将上述特征作为模型输入。此外, 烟气中 O₂ 量与 NO_x 生成相关系数为 0.15, 与其余参数相比数值较小, 在本文中数据集中烟气含 O₂ 量与 NO_x 浓度线性相关程度较弱, 故作简化处理。

1.3 计算方法

通过对 4 种集成学习模型进行组合, 并对 CFB 锅炉在不同负荷条件下 NO_x 排放浓度进行建模计算。模型选用发电机功率、瞬时给煤量、一次风作为模型输入变量, NO_x 排放浓度为目标变量。NO_x 排放浓度预测技术路线如图 2 所示。由于将预测模型直接应用于工程实际中涉及的成本较高, 且获取的数据可能不具有良好的代表性, 因此将现有数据划分为训练集和测试集, 采用训练集对模型进行训练, 采用测试集对模型预测能力进行评估, 从而实现对现有场景的有效预测。原数据集经预处理后获得 4 956 组样本作为 NO_x 排放预测的数据集, 将该数据集按照 8:2 的比例划分为训练集和测试集, 其中 3 961 组样本作为训练集, 995 组样本作为测试集。须对训练集与测试集各组数据进行归一化, 以消除不同变量量纲之间的差异对建模的影响, 公式如下:

$$X_n = (X - X_{min}) / (X_{max} - X_{min}) \quad (1)$$

式中, X 为实测数据; X_n 为归一化后结果; X_{max} 和 X_{min} 分别为数据中的最大值与最小值。

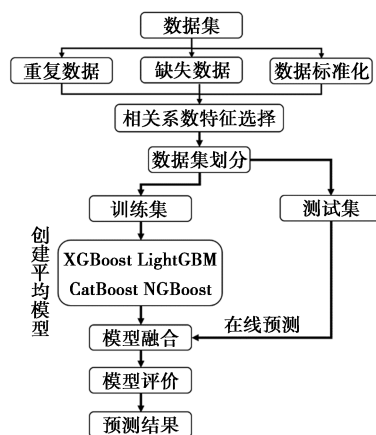


图 2 NO_x 排放浓度预测技术路线

通过 Boosting 方法分别对 CatBoost、NGBoost、LightGBM 和 XGBoost 进行集成后构建了 6 个预测模型, 将归一化后的结果输入到 6 个预测模型中, 训练集数据用于模型训练, 并结合验证集采用早期停

止策略,以防止模型过拟合。预测结果将根据集成算法的数量取平均值作为最终的预测结果。最后通过引入评价函数对模型预测性能及模型数据拟合程

度进行评估。为了对模型在不同负荷条件下的预测能力进行对比评估,本研究选择了表2中的负荷条件作为评估条件。

表2 不同负荷下输入条件

锅炉调峰比率	100%	90%	80%	70%	60%	50%	40%	30%	25%
锅炉负荷/MW	300.7	270.5	240.1	210.2	180.4	149.9	120.3	90.1	75.1
给煤量/(t·h ⁻¹)	206.8	197.6	177.1	161.9	135.9	113.6	99.9	83.5	70.9
一次风量/(t·h ⁻¹)	274.4	260.9	231.6	216.1	215.2	182.7	179.5	174.7	173.9
总二次风量/(t·h ⁻¹)	622.2	584.6	475.3	245.1	217.2	128.6	102.6	99.3	47.9

1.4 模型评价方法

通过引入拟合优度(R^2)、均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)作为模型的评价指标。 R^2 系数数值在0~1之间,数值越接近于1表示模型与数据的拟合度越高。为保证模型预测准确性和泛化能力,本文中主要将RMSE和 R^2 作为主要评价指标。其 R^2 计算见公式(2)。均方根误差反映了模型预测值与实测值之间的平均偏差大小, RMSE计算见公式(3)。平均绝对误差表示了预测值与实测值之间绝对误差的平均,计算公式见公式(4)。

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

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - y'_i)^2}{n}} \quad (3)$$

$$MAE = \left(\sum_{i=1}^n |y_i - y'_i| \right) / n \quad (4)$$

式中, n 为样本量; y_i 为样本实测值; y'_i 为预测值; \bar{y} 为所有测试样本的平均值。

2 结果与讨论

2.1 模型验证

表3列出了6个预测模型的RMSE、MAE和 R^2 。由表3可以看出,L-C模型的RMSE为0.16,为所有模型中的最小值,表明该模型的预测精度优于其他模型。L-C模型与C-N模型的MAE同为0.12,且在6个模型中MAE最小,进一步证明了其

表3 模型评价指标

模型	RMSE	MAE	R^2
C-N(CatBoost-NGBoost)	0.17	0.12	0.97
L-C(LightGBM-CatBoost)	0.16	0.12	0.97
L-X(LightGBM-XGBoost)	0.22	0.16	0.94
X-N(XGBoost-NGBoost)	0.20	0.15	0.96
X-C(XGBoost-CatBoost)	0.18	0.14	0.96
L-N(LightGBM-NGBoost)	0.19	0.15	0.95

预测误差较小。C-N和L-C模型 R^2 系数同为0.97,表明这2个模型都具有较高的数据拟合优度。而L-X的模型 R^2 为0.94,表明该模型的数据拟合度较差,且该模型变异性解释能力较弱,同时最大RMSE值仅为0.22。综上,L-C模型由于具有最小RMSE及最大 R^2 ,同时MAE最小,表现出最佳的预测准确性及模型稳定性。

2.2 负荷变化对NO_x排放浓度的影响

图3为变负荷条件下,6个模型NO_x排放浓度预测值与实测值之间的变化趋势,当机组负荷逐渐增大的过程中,NO_x排放浓度呈现上升趋势,但在低负荷区域部分样本点NO_x浓度高于40 mg/m³,最高达到120 mg/m³,这是因为机组处于低负荷时为保证锅炉稳定燃烧,增大了总风量,导致燃料型NO_x浓度上升。在高负荷区域NO_x浓度样本点分布在40~140 mg/m³,这是因为机组负荷升高时给煤量和风量增加导致NO_x排放浓度升高,为使NO_x达到排放标准,通过增加NH₃喷入量降低了NO_x的排放浓度。模型预测值与实测值在不同负荷范围内的平均误差如表4所示,当机组负荷在50~150 MW范围内时,6个模型的平均误差相近,分布在10%左右,其中X-C模型预测值与实测值间的平均误差为10.1%,为6个模型平均误差中的最小值。L-C模型的平均误差为10.3%,与X-C模型相近,仅相差2%,同样表现出较好预测准确性。当机组负荷在150~250 MW范围内运行时,模型的预测准确性差异逐渐明显,L-C模型在该范围内的平均误差为5%,为6个模型中的最小值,X-C模型在此负荷范围的平均误差为5.3%,预测准确性与L-C模型相近。当机组负荷继续上升在250~300 MW范围内时,L-C模型的平均误差为1.9%,为最小值。因此,若机组长期处于50~150 MW的低负荷运行时,X-C模型具有更好的预测准确性,当机组需进行全负荷调峰时,L-C模型具有更准确的预测准确性。

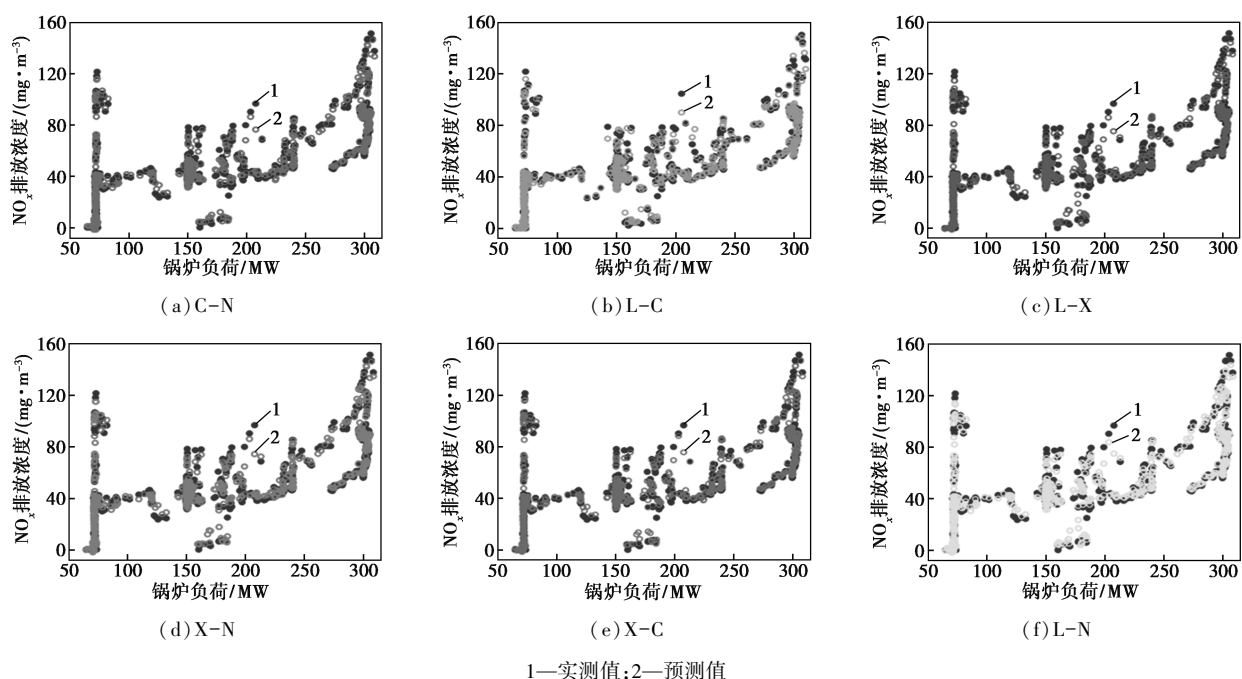


图 3 CFB 锅炉不同负荷下 NO_x 排放浓度

表 4 不同负荷范围下模型预测值平均误差分布

负荷范围/ MW	C-N/ %	L-C/ %	L-X/ %	X-N/ %	X-C/ %	L-N/ %
50~150	10.7	10.3	10.5	11	10.1	10.4
150~250	6.4	5	6.1	6.8	5.3	6.6
250~300	2.9	1.9	2.5	3	2.3	2.9

2.3 给煤量变化对 NO_x 排放浓度的影响

图 4 展示了给煤量变化对 NO_x 排放浓度预测

值与实测值的变化关系。当给煤量低于 80 t/h 时部分样本点处 NO_x 排放浓度偏高达到了 120 mg/m³,这是因为给煤量在此范围内时,机组处于调峰运行条件,为保证炉膛内的稳定燃烧,风量的增大使燃料型 NO_x 含量上升。当给煤量达到 200 t/h 以上时,由于 NO_x 的生成与煤量呈现正相关关系,因此导致 NO_x 浓度上升。如表 5 所示,为 6 个模型的预测值与实测值在给煤量不同区间下平均误差的分布情况。当给煤量在 50~110 t/h 范围内时,X-C 模型的预测效

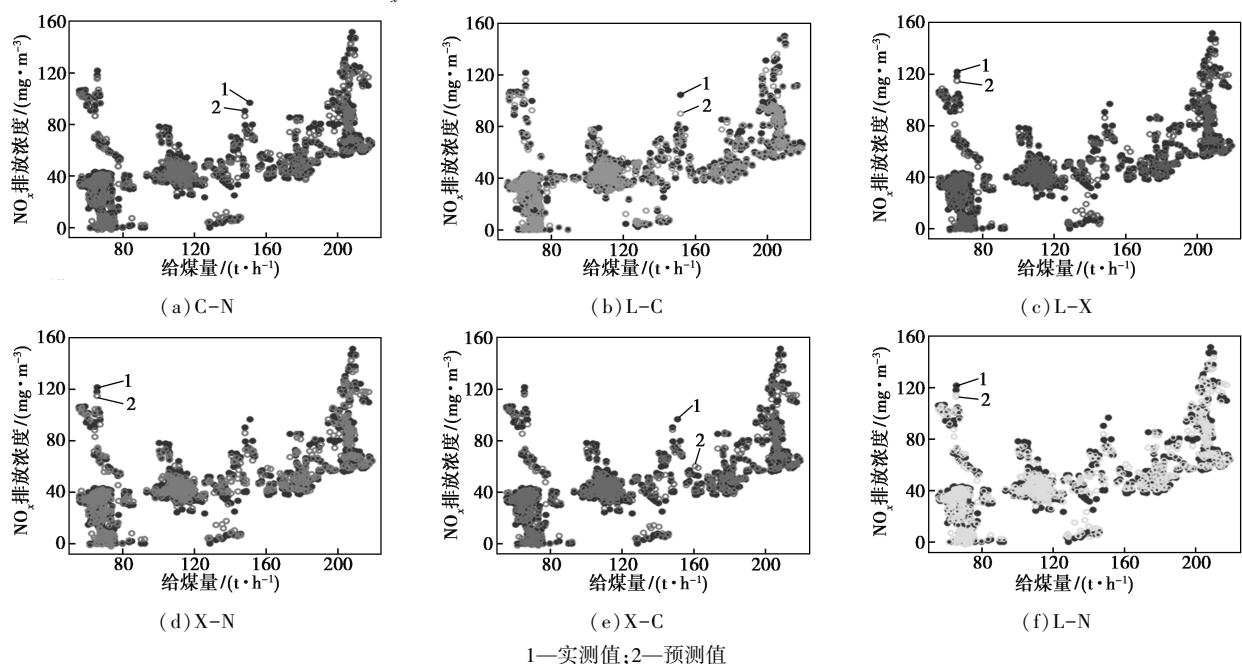


图 4 CFB 锅炉中不同给煤量下 NO_x 排放浓度

表5 不同给煤量范围下模型平均误差分布

给煤量/ (t·h ⁻¹)	C-N/ %	L-C/ %	L-X/ %	X-N/ %	X-C/ %	L-N/ %
50~110	10.4	9.9	10.1	10.5	9.6	9.9
110~170	6.7	5.2	6.8	7.1	5.6	7.2
170~220	3.6	2.2	2.8	3.9	2.9	3.5

果最好,平均误差为 9.6%,表现出较好的预测准确性,但当煤量继续上升时准确性开始下降。在该给煤量范围内,L-C 模型和 L-X 模型的平均误差为 9.9%,与 X-C 模型预测准确性接近。当给煤量在 110~170 t/h 范围内时,L-C 模型预测值与实测值间的平均误差为 5.2%,为 6 个模型中的最小值,X-C 模型的平均误差为 5.6%,与 L-C 模型相差 0.4%,在此区间 X-C 模型的预测准确性较 L-C 模型弱。L-X 模型在该范围的平均误差为 7.2%,预测准确性下降。当煤量继续增大在 170~220 t/h 范围内时,L-C 模型的平均误差为 2.2%,小于其余 5 个模型,其中 X-C 模型的平均误差为

2.9%,比 L-C 模型高 0.7%。因此,当给煤量在 110~220 t/h 范围内时,L-C 仍能保持较好的预测效果,L-C 模型在给煤量的全区间范围内表现出最好的预测准确性。

2.4 一次风量变化对 NO_x 排放浓度的影响

图 5 显示了一次风量变化对 NO_x 排放浓度的预测值与实测值之间变化关系,通过观察图中数据样本点的分布与变化趋势,可以发现,一次风量与 NO_x 的排放浓度呈现正相关关系,当一次风量增大时,NO_x 排放浓度上升。当一次风量在 130~180 t/h 范围时,部分样本点 NO_x 浓度达到 43~120 mg/m³,这是因为当一次风量在该范围内时机组正处于调峰条件下,此时虽然一次风量和给煤量减少,但炉膛内部依然处于高温状态,导致燃料型 NO_x 生成量下降,热力型 NO_x 生成量上升,但随着温度下降热力型 NO_x 生成量逐渐下降。一次风量变化条件模型平均误差的分布如表 6 所示,当一次风量在 130~180 t/h 范围内时,L-C、L-X、X-C 和 L-N 模型的平均误差分布在 9.8%左右,因此在该范围内一次风

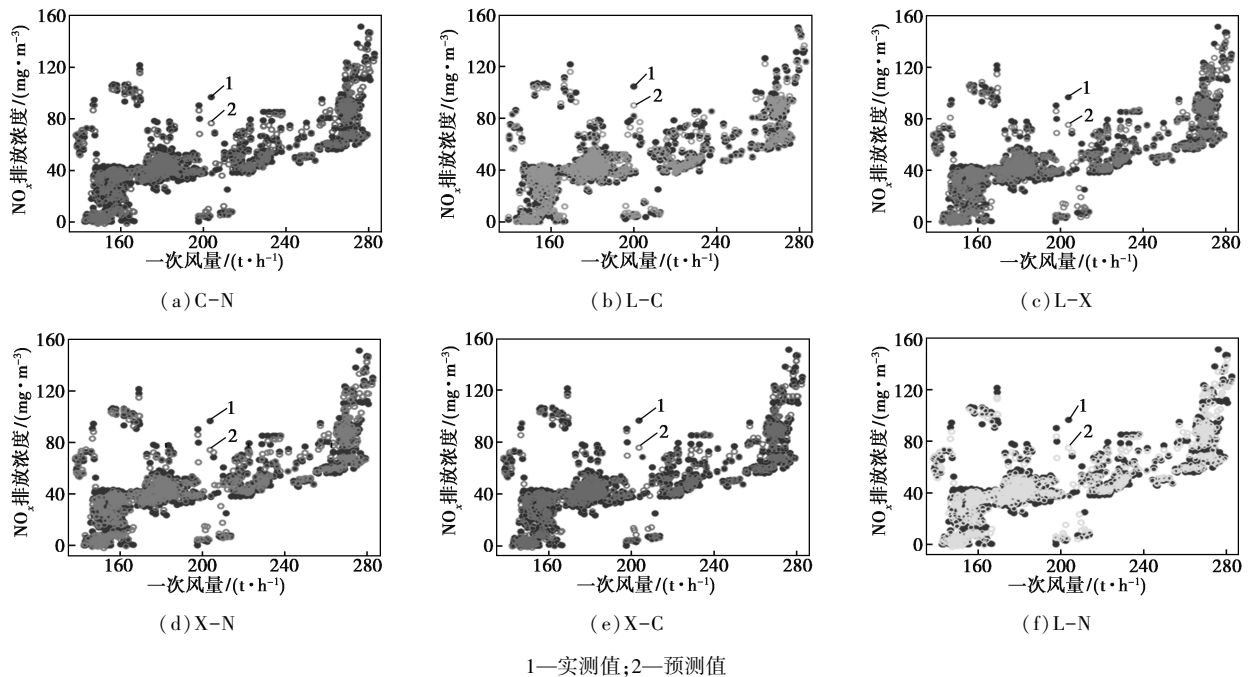
图5 CFB 锅炉不同一次风量下 NO_x 排放浓度

表6 一次风量变化下不同模型预测平均误差分布

一次风量/ (t·h ⁻¹)	C-N/ %	L-C/ %	L-X/ %	X-N/ %	X-C/ %	L-N/ %
130~180	10.4	9.6	9.9	10.5	9.7	9.9
180~230	6.8	5.6	6.6	7.1	5.6	7.0
230~280	3.2	2.1	2.6	3.4	2.5	3.1

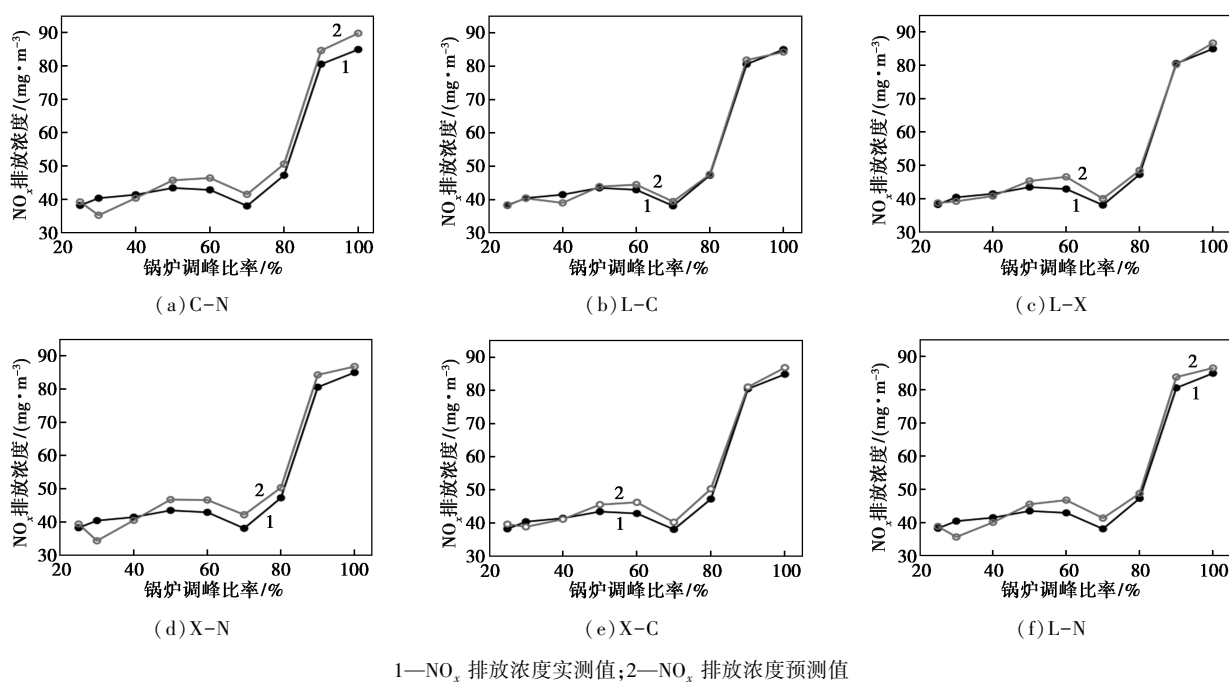
量对模型预测效果的影响较小,以上 4 模型均具有较好的预测效果。当一次风量在 180~230 t/h 范围内时,不同模型预测的准确性出现差异,L-C 模型与 X-C 模型的平均误差都为 5.6%,表现出相同的准确性。一次风量在 230~280 t/h 范围内时,L-C 与 X-C 模型的平均误差分别为 2.1%和 2.5%,L-C 在该范围内的预测准确性更好。因此,L-C 与 X-C

模型在一次风量变化条件均表现出较高的预测准确性,但在一次风量大于 230 t/h 时,L-C 模型表现出的预测准确性更高,全区间范围内的预测稳定性最强。

2.5 NO_x 排放浓度预测值与实测值的偏差分析

为研究深度调峰期间不同工况条件下,NO_x 排放浓度预测值与实测值的偏差,本文中选用了 9 种不同工况条件下的负荷、给煤量和一次风量等参数(具体数值如表 2 所示)。图 6 为 9 个工况条件下 CFB 锅炉 NO_x 排放浓度。图 6 中可知,当机组负荷大于 80% 时,C-N、X-N 模型预测值与实测值最大

偏差达到 15%,其他模型表现良好,在 80% 以上负荷偏差均小于 5%。当机组负荷处于 25%~70% 负荷时,L-X 模型预测值与实测值之间存在多处样本点偏差,最大偏差为 9%,在该负荷下 L-X 模型预测稳定性较差;而 X-C 模型在 25%~70% 负荷工况范围内表现较好,最大误差为 6.8%。L-N 模型在 25%~70% 负荷工况范围内的最大误差为 11.8%,表示该模型的预测稳定性较差。相比之下,L-C 模型在 80% 负荷运行时出现最大偏差为 7%,但在其他负荷条件下最大偏差均未超过 3%。因此,L-C 模型在精确度及稳定性方面均优于其他模型。



1—NO_x 排放浓度实测值;2—NO_x 排放浓度预测值

图 6 模型 NO_x 预测值偏差分析图

3 结论

(1) 与其他 5 个预测模型相比,L-C 模型的 RMSE 值为 0.16、MAE 值为 0.12,均为 6 个模型中最小值, R^2 为 0.97,表明该模型具有较优的拟合优度。

(2) 负荷变化条件下,L-C 模型预测的 NO_x 排放浓度中模型预测值与实测值的平均误差在 1.9%~10.3% 之间;给煤量变化时,L-C 模型的预测平均误差在 2.2%~9.9% 之间;在一次风量变化时,模型预测平均误差在 2.1%~9.6% 之间。L-C 模型在宽负荷条件下的准确度高,适应性较强。

(3) 在 9 种负荷工况下对 CFB 锅炉中 NO_x 排放浓度值进行了预测。在 60% 负荷工况下 L-C 模型预测的 NO_x 排放浓度值与实测值的偏差为 7%,而

在其他 8 种负荷工况下,偏差值均小于 3%。

综上所述,所构建的 L-C 模型能精确预测 CFB 锅炉在负荷变化条件下 NO_x 排放浓度,本研究方法可以为采用循环流化床机组的燃煤电厂提供可靠的预测方法。

参考文献

- [1] 唐晶,欧阳昊东,孙文涛,等. SNCR 脱硝过程中固体聚合脱硝剂的性能研究[J]. 动力工程学报, 2024, 44(4): 616-621.
- [2] 李月娥,吴彦丽,郑立星,等. 燃煤机组深度调峰脱硝性能提升技术分析[J]. 洁净煤技术, 2024, 30(9): 1-16.
- [3] 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.
- [4] 张文祥,晏海能,孙志军,等. 超临界 660 MW 循环流化床锅炉 NO_x 排放控制困难分析及处理[J]. 热力发电, 2024, 53(5):

- 109-114.
- [5] 田继林,朱建国,朱书骏,等.60 t/h 煤粉预热燃烧锅炉宽负荷运行特性研究[J].热力发电,2024,53(4):133-140.
- [6] 吕清刚,朱书骏,朱建国,等.煤粉预热燃烧技术研发进展[J].中国电机工程学报,2022,42(18):6535-6547.
- [7] 杨希刚,陈国庆,黄林滨,等.尿素法 SNCR 对大型电站煤粉锅炉运行影响的工业试验[J].化工进展,2022,41(7):3573-3581.
- [8] 欧阳子区,王宏帅,吕清刚,等.煤粉锅炉发电机组深度调峰技术进展[J].中国电机工程学报,2023,43(22):8772-8790.
- [9] Fang Z Q, Tao B, Yu X H, et al. Achieving an ultra low emission of nitrogen oxides by using activated carbon with hydrophobic modification[J]. Journal of Cleaner Production, 2021, 315: 128165.
- [10] Xu W T, Huang Y J, Song S H. On-line combustion optimization framework for coal-fired boiler combining improved cultural algorithm, deep learning, multi-objective evolutionary algorithm with improved case-based reasoning technology [J]. Fuel, 2024, 358: 130225.
- [11] 任少君,朱保宇,翁琪航,等.基于物理信息神经网络的燃煤锅炉 NO_x 排放浓度预测方法[J].中国电机工程学报,2024,44(20):8157-8165.
- [12] Dušan S N, Marko A, Jurij A, et al. Optimization of an old 200 MW coal-fired boiler with urea injection through the use of supervised machine learning algorithms to achieve cleaner power generation [J]. Journal of Cleaner Production, 2021, 90: 125200.
- [13] Matsuzaki A, Kiribuchi D, Shimizu K. Machine learning approach to NO_x prediction for SCR process of thermal power plant[J]. IFAC-PapersOnLine, 2023, 56(2):2858-2864.
- [14] Nikhil P. An emission predictive system for CO and NO_x from gas turbine based on ensemble machine learning approach [J]. Fuel, 2024, 366: 131421.
- [15] Liu G F, Yu Z, Shen D K, et al. Anticipatory NH₃ injection control for SCR system based on the prediction of the inlet NO_x concentration[J]. Journal of the Energy Institute, 2021, 94: 167-175.
- [16] Wen X Q, Li K C, Wang J G. NO_x emission predicting for coal-fired boilers based on ensemble learning methods and optimized base learners [J]. Energy, 2023, 264: 126171.
- [17] Hoque K E, Hossain T, Haque A M, et al. NO_x emission predictions in gas turbines through integrated Data-Driven machine learning approaches [J]. Journal of Energy Resources Technology, 2024, 146(7):071201.
- [18] 苏连成,朱娇娇,郭高鑫,等.基于 XGBoost 和 Wasserstein 距离的风电机组塔架振动监测研究[J].太阳能学报,2023,44(1):306-312.
- [19] 张子洵,魏业文,张轲钦,等.基于 ICOA-XGBoost 的光伏阵列复合故障诊断研究[J].太阳能学报,2025,46(5):251-259.
- [20] 陈林,陶润哲,谢雨池,等.基于 LightGBM 的 ASIC 芯片互连线延迟预测模型[J].微电子学,2025,55(1):134-139.
- [21] Qiu H, Xia Y P, Xiang C L, et al. Prediction of hydrogen storage in metal-organic frameworks using CatBoost-based approach [J]. International Journal of Hydrogen Energy, 2024, 79: 952-961.
- [22] Zhou Y F, Wang S L, Xie Y X, et al. Remaining useful life prediction and state of health diagnosis of lithium-ion batteries with multi-scale health features based on optimized CatBoost algorithm [J]. Energy, 2024, 300: 131575.
- [23] Yan P L, Fan W J, Zhang R C. Predicting the NO_x emissions of low heat value gas rich-quench-lean combustor via three integrated learning algorithms with Bayesian optimization [J]. Energy, 2023, 273: 127227.
- [24] Tang H, Liu Z D, Han X J, et al. Experimental study on combustion characteristics of a 40 MW pulverized coal boiler based on a new low NO_x burner with preheating function [J]. Energy, 2024, 305: 132319.
- [25] 蔡晋,单露,王志宁,等.超临界 350 MW 循环流化床锅炉变负荷特性[J].热力发电,2020,49(9):98-103,108.
- [26] Li Y X, Yan C W, Zhang J, et al. Prediction of coal gangue volcanic ash activity based on machine learning [J]. Construction and Building Materials, 2024, 443: 137737. ■

(上接第 243 页)

维护成本,保障设备传热效率与连续运行能力。综上,低温蒸发技术可高效实现垃圾渗滤液 RO 浓缩液的减量化和冷凝液达标排放,但需结合软化预处理与清洗策略以控制结垢。研究成果为填埋场膜浓缩液的工程化处置提供了关键设计参数与运行经验,对推动我国渗滤液“零排放”技术的规模化应用具有重要参考价值。

参考文献

- [1] 王凯,武道吉,彭永臻,等.垃圾渗滤液处理工艺研究及应用现状浅析[J].北京工业大学学报,2018,44(1):1-12.
- [2] 范茂军.垃圾渗滤液膜浓缩液处理技术的研究进展[J].节能,2019,38(11):145-147.
- [3] 张净瑞,郑铭灏,郑飞龙,等.我国生活垃圾渗滤液的产生、处理现状及发展趋势[J].环境工程学报,2025,19(11):2724-2734.
- [4] 徐昌文,王声东.垃圾渗滤液及膜浓缩液处理技术探讨与分析[J].环境与可持续发展,2020,45(5):72-75.
- [5] 丁晶,关淑妍,赵庆良,等.垃圾渗滤液膜浓缩液处理技术研究与应用进展[J].哈尔滨工业大学学报,2021,53(11):1-13.
- [6] 王潇潇,钟溢健,李金城,等.垃圾渗滤液膜浓缩液处理技术研究进展[J].桂林理工大学学报,2024,44(4):677-683.
- [7] 苏增琛,刘永德,宋雪,等.垃圾渗滤液膜浓缩液处理技术研究[J].河南科技,2025,52(12):84-87.
- [8] 宋薇,李丽,王玉如.低温真空蒸发处理垃圾渗滤液膜浓缩液[J].环境工程学报,2017,11(10):5417-5423.
- [9] 李向东,陈方方,姚鹏,等.低温蒸发技术处理垃圾渗滤液膜浓缩液[J].中国给水排水,2025,41(3):84-88.
- [10] 张文贞,王少东,陈福达,等.垃圾渗滤液膜浓缩液处理工艺应用研究[J].广东化工,2024,51(1):103-107.
- [11] 吴梦瑶.熟石灰软化—氧化剂氧化—蒸发法处理垃圾渗滤液膜浓缩液试验研究[D].北京:中国地质大学,2023. ■