

# 融合历史过程与未来工况的污泥热解 气化废气排放动态预测

黄 强<sup>1,2,3</sup>, 张 欢<sup>1,2,3,\*</sup>, 曲 申<sup>1,2,3,\*</sup>

(1. 北京理工大学 能源与环境政策研究中心, 北京 100081; 2. 北京理工大学 管理学院, 北京 100081;  
3. 碳中和系统工程北京实验室, 北京 100081)

**摘要:** 污泥热解气化在资源回收方面优势显著,但运行中产生的 SO<sub>2</sub> 等废气制约了该技术的推广。精准预测废气排放并优化工艺参数,是提升其应用价值的关键。本研究基于某工厂连续 45 天的分钟级运行数据(共 64 801 条、106 维),构建了一种融合历史过程与未来工况的时序预测框架,系统对比了极端梯度提升(XGBoost)、梯度提升(CatBoost)、非线性模型(NLinear)及时域融合变换(TFT)等模型的预测性能,并结合模型可解释性分析(SHAP)与累计局部效应(ALE)可解释方法解析了工艺机理。结果表明,融合动态特征与滞后效应的时序框架能显著提升复杂工业过程的建模精度。在所有模型中,CatBoost 表现最优,决定系数( $R^2$ )达到 76.5%,较未引入时序框架的截面模型( $R^2=22.5%$ )有大幅提升,同时平均绝对误差(MAE)降低了 50.36%,表明该框架能有效捕捉复杂工业的动态变化与滞后影响。此外,研究还揭示了气化炉出口温度、燃烧炉炉内温度等关键因素对 SO<sub>2</sub> 排放的非线性影响,并提出将蒸汽压力、气化炉出口温度和燃烧炉炉内温度分别控制在 0.28~0.30 MPa、100~160 °C 和 800~900 °C 区间,可在提高资源回收效率的同时有效控制 SO<sub>2</sub> 排放。本研究为废气精准预测与工艺优化提供了数据-机理融合的解决方案,也为其他工业过程调控提供了方法论参考。

**关键词:** 污泥热解气化; 时序预测; 机器学习; 可解释分析; 实时排放控制

中图分类号: X505; X705 文献标识码: A

## Dynamic Prediction of Sludge Pyrolysis-Gasification Exhaust Emissions by Integrating Historical Processes and Future Operating Conditions

HUANG Qiang<sup>1,2,3</sup>, ZHANG Huan<sup>1,2,3,\*</sup>, QU Shen<sup>1,2,3,\*</sup>

(1. Center for Energy and Environmental Policy Research, Beijing Institute of Technology, Beijing 100081, China; 2. School of Management, Beijing Institute of Technology, Beijing 100081, China; 3. Beijing Lab for System Engineering of Carbon Neutrality, Beijing 100081, China)

**Abstract:** The pyrolysis-gasification process has emerged as a cutting-edge technology for sludge treatment and disposal because of its resource-recovery potential and high efficiency. However, the emissions of harmful gases such as SO<sub>2</sub> during operation limit the widespread adoption of this technology. Achieving accurate emission prediction and optimizing process parameters to improve both economic and environmental performance are therefore crucial. In this study, we used a high-resolution industrial dataset of 106 variables and 64 801 minute-level records collected continuously over a 45-day

收稿日期: 2026-01-24

修回日期: 2026-03-14

接受日期: 2026-03-16

DOI: 10.20078/j.eep.20260319

基金项目: 国家杰出青年科学基金资助项目(52425005); 国家自然科学基金面上资助项目(52370189); 国家自然科学基金重大资助项目(52595722)

第一作者: 黄 强(2001—),男,四川成都人,博士研究生,主要研究方向为工业过程建模。E-mail: 3120255092@bit.edu.cn

\*通讯作者: 张 欢(1993—),女,天津人,副研究员,主要研究方向为环境人工智能。E-mail: zhanghuan19@bit.edu.cn

曲 申(1986—),男,北京人,教授,主要研究方向为环境系统工程、环境管理及相关数据科学方法与复杂系统建模。

E-mail: squ@bit.edu.cn

operational period at a full-scale plant. We developed a comprehensive time-series prediction framework that integrates historical process records with future operating conditions. The predictive performance of representative algorithms—including XGBoost, CatBoost, NLinear, and the Temporal Fusion Transformer (TFT)—was systematically evaluated and validated. Experimental results show that the proposed multi-source time-series prediction framework, which accounts for process dynamics and lag effects, is essential for modeling complex industrial gasification processes. Among the tested models, CatBoost performed best, achieving a mean absolute error (MAE) of 269.17 and a coefficient of determination ( $R^2$ ) of 76.53%. To assess the reliability of these results for production guidance, we compared the framework with a traditional non-temporal cross-sectional baseline model. The baseline attained an  $R^2$  of 22.51% and an MAE of 542.20. Thus, the proposed framework improved the  $R^2$  by 54.02 percentage points and reduced MAE by 50.36%, indicating that traditional models fail to capture critical temporal correlations and the delayed response of pollutant generation to control inputs. In contrast, the proposed framework effectively leverages historical inertia and future setpoints to provide robust, actionable insights for industrial regulation. By combining interpretable tools such as SHAP and ALE with process knowledge, we identified the complex nonlinear factors affecting  $\text{SO}_2$  concentration fluctuations. The interpretability analysis reveals a high sensitivity of emissions to temperature gradients, suggesting that coordinated control of the gasification and combustion stages is key to emission suppression. Specifically, the results indicate that optimizing steam pressure to approximately 0.28–0.30 MPa, gasifier outlet temperature to about 100–160 °C, and combustion furnace temperature to about 800–900 °C can maximize resource recovery while effectively reducing  $\text{SO}_2$  emissions. In conclusion, by integrating process mechanisms with advanced data-driven analysis, this study achieves precise emission prediction and operational optimization for sludge gasification and provides a generalizable methodology for intelligent modeling of other dynamic industrial systems.

**Keywords:** Sludge pyrolysis–gasification; Time-series prediction; Machine learning; Interpretability analysis; Real-time emission control

## 0 引 言

伴随我国城镇化进程推进与污水处理设施建设的不断完善,城镇污水处理能力已突破 2 亿  $\text{m}^3/\text{d}$ , 位居全球首位, 由此伴生的污泥年产量(按 80% 含水率计)超过 6 000 万  $\text{m}^3$ <sup>[1–2]</sup>。在此背景下, 污泥热解气化技术因其处理效率高与环境影响低, 成为一种极具前景的解决方案<sup>[3–5]</sup>。

污泥热解气化流程涉及复杂的物理化学反应。污泥在缺氧或无氧的条件下被加热生成以  $\text{CO}$ 、 $\text{H}_2$ 、 $\text{CH}_4$  为主, 包含  $\text{H}_2\text{S}$ 、气态焦油、水蒸气等成分的可燃合成气, 同时生成无机固态炉渣<sup>[6–7]</sup>。通过燃烧将合成气中的化学能转化为热能, 用于厂区的供热、发电等, 从而实现能量的回收利用<sup>[8–9]</sup>。与传统方式相比, 污泥热解气化不仅具有更高的处理效率, 还能避免污泥中有害成分对土壤和水源的污染, 减少燃烧过程中的温室气体排放以及飞灰生成, 显著提高污泥的资源化利用效率<sup>[10–12]</sup>。然

而, 该工艺在运行中产生的  $\text{SO}_2$  等有害气体, 以及当前普遍采用的末端治理模式所衍生的高昂成本, 成为制约该技术推广的关键因素<sup>[13–15]</sup>。因此, 精准预测废气排放、识别关键影响参数并实现前端优化, 是提升该技术经济与环境双重效益的核心。

近年来, 机器学习因其强大的非线性拟合能力, 在工业过程建模与排放预测领域展现出巨大潜力<sup>[16–17]</sup>。在污水处理、烟气脱硫等场景中, XGBoost、神经网络等模型已被成功应用于关键指标的软测量与预警<sup>[18–20]</sup>。然而, 针对污泥热解气化这一特定工艺的排放预测研究仍较为稀缺。

首先, 模型适配性研究不足。多数研究仅基于少数随机选择的模型评估预测精度, 缺乏针对污染物(如  $\text{SO}_2$ )生成机理的系统性模型对比与选择标准, 导致难以确定何种算法最适合刻画该过程的非线性特征<sup>[21–24]</sup>。其次, 热解气化是一个典型的动态过程, 物料与反应工况的动态变化对最终排放的影响存在数分钟至十几分钟的滞后效

应。然而, 现有模型框架多基于静态截面数据, 忽视了过程中关键的动态特征与滞后效应, 导致模型无法体现时序因果关系, 在真实动态场景下的预测精度下降<sup>[25-26]</sup>。此外, 模型可解释性的缺失阻碍了其工业应用。缺乏可解释性使得“黑箱”模型无法回答为何排放超标以及如何调整工艺参数等核心问题, 从而难以转化为工程师信赖的在线诊断与决策支持工具<sup>[27-29]</sup>。

为了解决上述问题, 本研究提出了一种融合历史过程与未来工况信息的时序预测框架。该框架的核心思想是设计一种能够同时融合历史运行记录和预设操作计划的时序特征处理机制, 使模型不仅能够学习历史状态对未来排放的延续影响, 还能根据预设的操作计划调整排放趋势。模型的输入包括历史废气排放浓度、历史工艺参数、历史物料投加量以及未来计划投入的工艺参数和物料投加量, 输出为未来的废气排放浓度。所构建的时序模型从工艺特征出发, 通过不断滚动回溯窗口与预测窗口的训练过程, 旨在有效捕捉废气排放的滞后效应与动态变化特征。

在此基础上, 本研究以郑州新区污水处理厂分钟级运行数据为基础, 构建融合历史过程与未来工况的时序预测框架, 系统对比多种机器学习模型对  $\text{SO}_2$  排放的预测性能。进一步地, 通过结合可解释分析方法, 识别影响  $\text{SO}_2$  排放浓度的关键工艺参数, 并揭示其非线性作用机理。通过上述工作, 旨在揭示污泥热解气化过程工况对废气排放的非线性与滞后影响, 并为前端控制与工艺参数优化提供决策支持, 从而实现废气排放最小化, 提升污泥热解气化技术的经济可行性与环境友好性。

## 1 数据及研究方法

### 1.1 数据来源及预处理

河南省郑州新区污水处理厂为国内首座采用污泥热解气化技术的千吨级处置工厂, 年处理能力约 36.5 万吨, 可消纳郑州市约 50% 的市政污泥。该污泥热解气化工艺线始于气化炉, 污泥在其中缺氧或限氧条件下发生热解和气化反应, 被转化为粗合成气与化学性质稳定的无机炉渣, 炉渣可直接作为建筑材料实现资源化利用。随后, 粗合成气被引入燃烧炉, 通入足量空气使其完全燃烧, 将化学能释放为高温烟气的热能。高温烟气继续进入余热回收系统, 用于产生蒸汽以供热

或发电, 同时烟气自身冷却。冷却后的烟气首先通过布袋除尘器去除颗粒物, 随后采用尿素喷酒 (SNCR) 进行选择非催化还原, 以脱除氮氧化物, 随后进入脱硫塔并最终从总排口排出。

本研究收集了该厂在 2025 年 5 月 2 日 08:00 至 2025 年 6 月 16 日 08:00 期间的分钟级分辨率运行数据, 共 64 801 条记录, 数据覆盖脱硫/脱硝单元之前的关键工段, 包括气化炉、燃烧炉、余热锅炉、布袋除尘器及公辅系统。数据包含 106 个装置运行与物料投加变量(如炉底风机频率、渣层温度、干馏温度、蒸汽压力、气化剂压力等), 同时监测了尾气  $\text{SO}_2$  浓度。与传统实验室数据相比, 本研究所使用的分钟级时间分辨率数据, 能够更真实且准确地反映污泥热解气化过程的动态特征。在原始数据质量控制方面, 考虑到工业现场传感器噪声、设备启停及偶发故障可能引入异常值与非稳态工况, 本研究进一步执行了如下处理流程。

(1) 人工判断合理区间: 首先, 基于工艺机理与设备量程, 设定了各变量的物理合理阈值(如温度不低于环境温度、压力非负等), 将超出合理范围的数值标记为异常。

(2) 异常值识别与处理: 采用滑动窗口统计方法。具体步骤: 首先, 设定窗口时间跨度为 30 min; 其次, 在每个窗口内依次计算各数据点的局部均值、中位数及标准差; 随后, 若某数据点与窗口中位数的偏差超过 3 倍标准差, 则将其判定为异常值; 最后, 对于识别出的异常值, 采用线性插值方法予以替换, 若异常值位于数据序列首尾, 则以中位数进行填充。

完成上述数据清洗后, 对剩余数据进行了时间戳对齐、线性插补缺失值及标准化处理, 以提升模型训练的稳定性。

### 1.2 算法选择

本研究对比了 4 类机器学习模型, 包括 XGBoost、CatBoost、NLinear 及 TFT。其中, XGBoost 和 CatBoost 均基于梯度提升决策树 (GBDT) 框架, 每一轮训练拟合一棵 CART 回归树以逼近当前损失的负梯度, 并对所有树的输出加权累加以逐步降低训练误差。选择前两个模型的原因是该类模型擅长刻画特征间的非线性与交互关系, 对表格型工业数据具有良好的稳健性与可解释性。NLinear 对每个时间窗口内各变量的历史序列分别标准化, 在此基础上通过单一线性层完成多步预测。该模型结构极简、训练高效, 可作

为强力且稳定的线性基线,有助于衡量非线性模型带来的增益。TFT 则结合了长短期记忆网络(LSTM)的时序建模能力与 Transformer 的注意力机制,使模型不仅能捕捉局部动态和中长期趋势,并通过变量选择网络在多变量、多步预测中突出关键时刻与关键特征,且模型结构天然支持“已知未来协变量”的引入,适用于复杂的多变量、多步预测。为确保模型预测精度的可比性,4种模型使用相同的输入特征预测,并按时间顺序和7:1:2的比例将数据划分为训练集、验证集和测试集,以避免训练和优化过程中的信息泄露。后续超参数仅在验证集上调优,测试集仅用于最终评估。

### 1.3 融合历史与未来工况的时序框架

为刻画热解气化过程中工况对尾气排放的滞后影响并利用已知的未来设定值提升预测精度,本文构建了融合历史过程与未来工况信息的时序

建模框架。采样间隔为 1 min,在任意预测时刻  $t$ ,历史回溯窗口  $L=12$ (即  $t-12\sim t-1$ ),预测窗口  $H=12$ (即  $t\sim t+11$ ),如图 1 所示,模型的输入特征由 3 个维度的时序信息构成:(1)历史  $t-12\sim t-1$  时刻尾气的  $\text{SO}_2$  浓度序列;(2) $t-12\sim t-1$  的历史物料投加量和工艺参数序列,如污泥料位(m)、气化炉炉顶料仓重量(kg)、蒸汽流量(kg/h)、气化剂压力(kPa)、热风炉沼气压力(kPa)、余热锅炉尿素流量( $\text{m}^3/\text{h}$ )、气化炉炉底风机频率(Hz)、出口温度( $^\circ\text{C}$ )、渣层温度( $^\circ\text{C}$ )、热风炉炉内温度( $^\circ\text{C}$ )、主火风机风压(kPa)、余热锅炉蒸发器压力(Pa)、省煤器压力(Pa)、布袋除尘器引风机频率(Hz)、冷凝器频率(Hz)、锅炉给水流量( $\text{m}^3/\text{h}$ )、气泡给水泵频率(Hz)、液站油位(mm)等;(3)未来  $t$  至  $t+11$  时刻在控制系统中已规划的物料投加量与设备参数设定值。



图 1 融合历史与未来工况的时序建模框架

Fig. 1 Temporal modeling framework integrating historical and future operating conditions

模型的预测目标是  $t\sim t+11$  的  $\text{SO}_2$  浓度,该框架通过在时间轴上滚动回溯窗口与预测窗口,同时利用历史运行记录与预设操作计划信息,使模型学习物料投加、设备参数与废气排放的非线性与滞后关系,从而更贴近在线预报与前端控制的实际使用场景。

### 1.4 模型回测

为了进一步提高模型的预测精度并获得在滚动预测中表现稳定的超参数组合,本研究在验证集上采用回测机制进行调优。不同于在整段验证集上静态训练评估,回测机制按时间顺序逐点推

进,每次仅考虑回溯窗口内的历史协变量和未来计划协变量以预测废气浓度,这种方式更加贴近实际生产场景。同时,短期评估下某些超参数虽表现优异,但在滚动预测中误差易累积,而回测机制有助于识别在长期预测中表现更加稳定的超参数。为确保验证集全部样本参与评估,首个验证起点所需的历史窗口取自训练集尾部,仅作为初始序列输入以启动回测流程,不参与参数优化,因而不会造成提前优化或信息泄露。最终,采用网格搜索遍历学习率、网络层数、隐藏单元数以及树深与树数量等超参数,并以回测期的平均表现

为准则选取最优组合。

### 1.5 模型评价及可解释分析

在对比模型精度时,采用平均绝对误差(MAE)、均方根误差(RMSE)、对称平均绝对百分比误差(sMAPE)和决定系数( $R^2$ )作为评估指标,从多个角度全面衡量预测精度。同时,为了识别影响工艺废气排放的关键因素,利用SHAP可解释方法对模型结果进行分析<sup>[30]</sup>。通过全局分析,量化了每个特征对模型预测输出的平均贡献,识别影响SO<sub>2</sub>浓度的最关键因素。此外,通过绘制关键特征的局部累积效应图(ALE),直观展示了不同特征在不同取值区间下对废气排放预测值的影响方向和大小,并进一步分析了最优参数运行区间<sup>[31]</sup>。

## 2 结果、发现和讨论

### 2.1 模型预测精度对比

为实现对SO<sub>2</sub>排放浓度的精准动态预测,本研究基于融合历史过程与未来工况的时序预测框架,评估了基线模型NLinear、两类代表性机器学习模型(XGBoost、CatBoost)与代表性时序预测深度学习模型(TFT)的预测性能。如图2和图3所示,首先,梯度提升决策树(GBDT)模型表现出最

优的整体性能。经过相同的模型初始化和超参数优化后,XGBoost和CatBoost在测试集上的MAE分别为271.56和269.17,sMAPE仅为7.59%和7.66%。从等值线图(图3)来看,二者的预测散点近似均匀地分布在45°参考线( $x=y$ )两侧,带宽较窄。这表明模型能够较为准确地刻画SO<sub>2</sub>浓度的动态变化趋势与幅度。该结果表明,基于GBDT框架的决策树模型通过捕捉物料投加、设备参数对SO<sub>2</sub>浓度的滞后影响与交互效应,有效刻画了特征与目标间的非线性关系,从而显著提升模型预测精度。

在数据中发现SO<sub>2</sub>浓度超过4500 mg/m<sup>3</sup>的极端样本相对稀缺。由于此类样本数量的不足,XGBoost与CatBoost模型在处理高浓度尾部样本时表现较弱,导致模型在验证和测试阶段对这一区间的SO<sub>2</sub>浓度产生估计偏低。此现象表明,当训练数据中尾部样本较为稀缺时,模型往往优先优化常规数据区间的拟合,从而牺牲对极端值的拟合质量。为了进一步解决该问题,未来研究应考虑对高浓度尾部数据进行增强,或者采取重采样技术来提高模型在极端样本上的表现。

NLinear模型在时序框架下的MAE为281.37,sMAPE为8.28%,尽管误差仍在可接受范围内,但

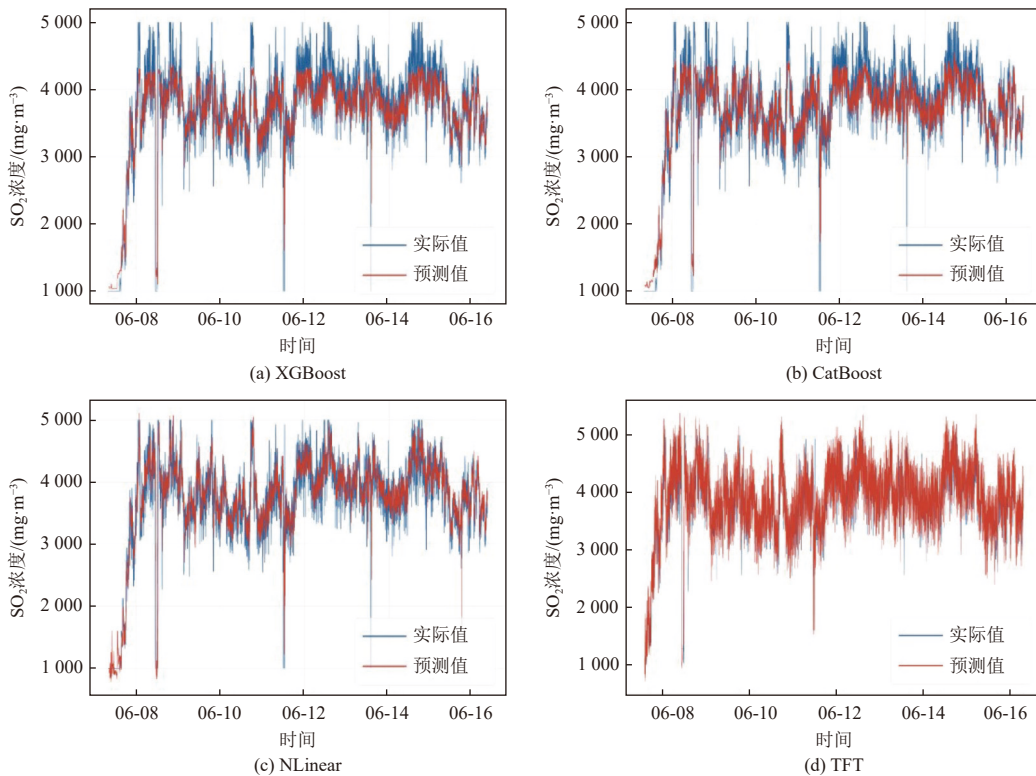
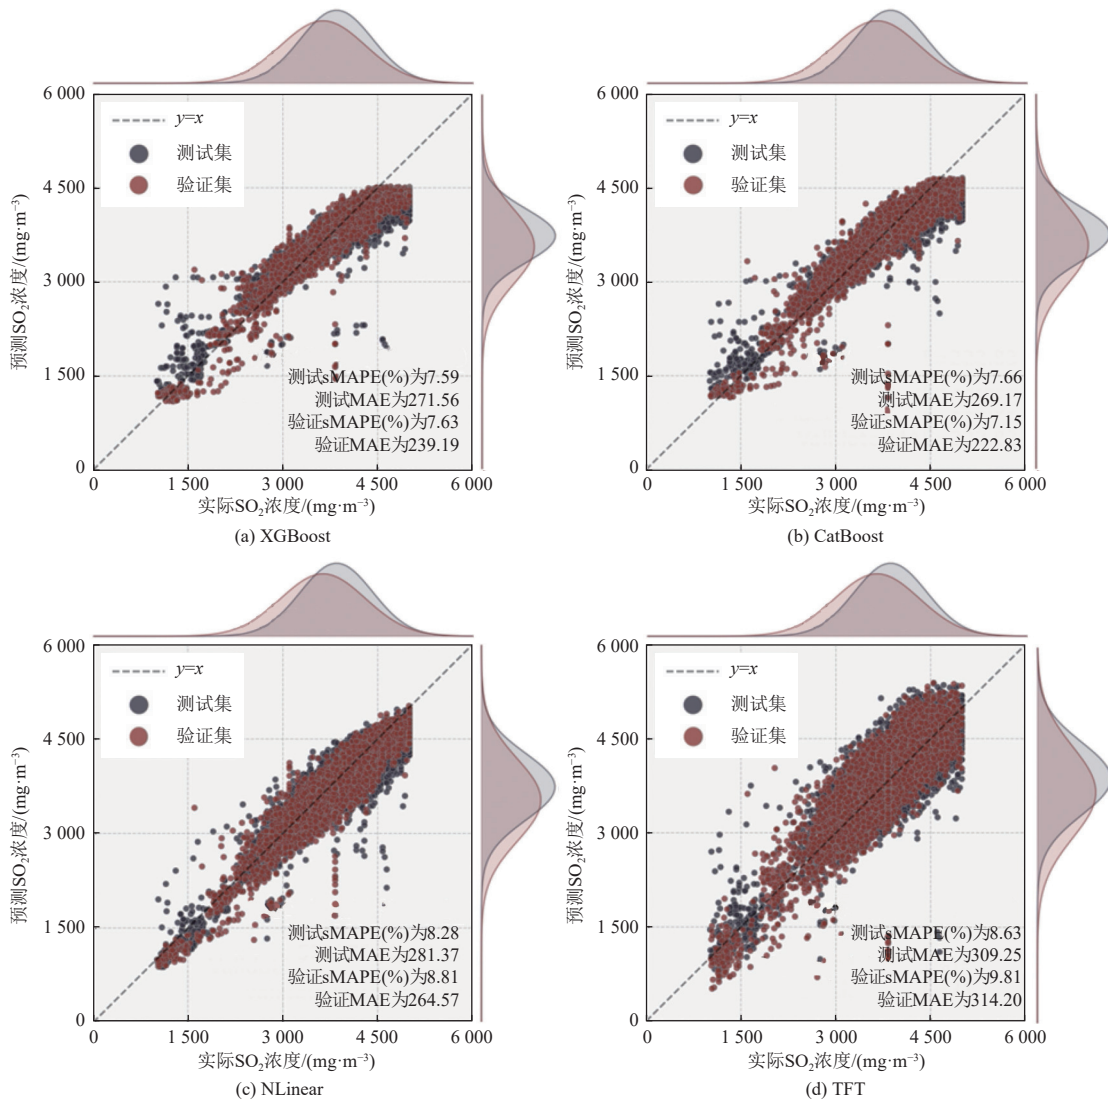


图2 各模型预测值与实际值的曲线图对比

Fig. 2 Comparison of predicted and experimental values across different models



注: 主图为验证集(红)与测试集(灰)的预测值-实际值散点图, 对角虚线为 1:1 参考线; 顶部与右侧分别为两组样本实际浓度与预测浓度的核密度估计曲线, 显示模型在不同浓度区间的预测分布特征, 余同。

图 3 各模型预测值与实际值的等值线图

Fig. 3 Parity plots of predicted versus actual values for various models

整体精度和稳定性未能达到 GBDT 模型的水平。特别是在捕捉复杂的非线性关系和长短期依赖时, NLinear 未能充分发挥深度学习模型应有的优势。相比之下, 深度学习模型 TFT 的性能相对逊色, 测试集上的 MAE 为 309.25, sMAPE 为 8.63%。等值线图显示, 验证集和测试集的散点带较宽, 表明模型在实际应用中存在较大的系统偏差。这种表现可能源于 TFT 模型较高的复杂度和大量参数, 在数据噪声较大且未引入强正则化的情况下, 导致其泛化能力不足。

为了全面评估 4 个模型的预测能力, 对 4 个模型的 MAE、RMSE、sMAPE 和  $R^2$  指标分别进行了标准化处理, 然后赋予相同权重并计算综合得

分。在  $\text{SO}_2$  浓度预测任务中, XGBoost 和 CatBoost 均表现出色。CatBoost 的 MAE 和 RMSE 分别为 269.17 和 366.96, 均低于其他模型; 同时, 其  $R^2$  达到 76.52%, 在所有模型中最高。XGBoost 模型的 sMAPE 为 7.59%, 表现最佳, 其他 3 项指标 (MAE 为 271.56, RMSE 为 369.14,  $R^2$  为 75.24%) 也紧随其后 (见图 4、表 1)。综合分析, CatBoost 在综合预测精度上最为突出, 其次为 XGBoost。NLinear 与 TFT 模型作为基线模型, 在本数据规模与任务设定下未能超越树模型。这表明, 在工业场景中, 树模型具有处理特征交互的显著优势, 同时相较于深度学习模型, 树模型在计算效率和可解释性方面更具优势, 尤其在数据噪声较大的实际应用

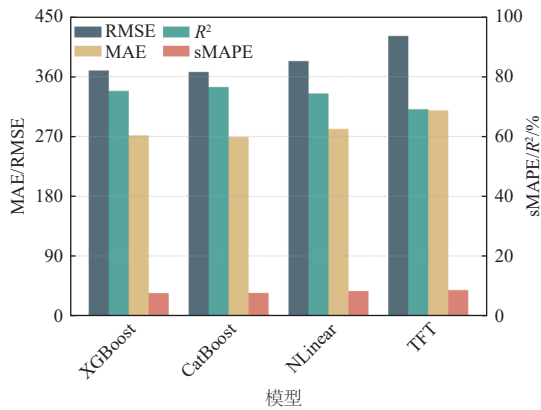


图4 模型统计精度对比

Fig. 4 Statistical accuracy comparison of different models

中表现更为稳定。

## 2.2 时序建模与截面建模

为进一步验证模型预测能力的提升源自融合历史过程与未来工况的时序预测框架,而非单纯的模型选择,本研究设计了对照实验,将 CatBoost 分别以两种特征输入方式进行对比。(1)截面特

表1 模型统计精度对比

Table 1 Comparison of statistical accuracy of various models

模型	MAE	RMSE	sMAPE/%	R <sup>2</sup> /%
XGBoost	271.56	369.14	7.59	75.25
CatBoost	269.17	366.96	7.66	76.53
NLinear	281.37	383.48	8.28	74.37
TFT	309.25	421.17	8.63	69.08

征: 在每个预测时刻,将时间序列数据压平成单次观测,仅输入同一时刻的特征;(2)时序特征:输入包含历史运行记录与未来操作计划的协变量序列,考虑工艺过程中的滞后效应及前馈控制信息。

实验结果表明,截面 CatBoost 在测试集上的误差显著较高,MAE 为 542.20, RMSE 为 673.91, sMAPE 为 15.75%, R<sup>2</sup> 为 22.51%; 而时序 CatBoost 的对应指标则更优(见图 5、表 2)。该结果表明,在具有动态特征与滞后效应的工业过程中,将时间序列简单处理为截面特征会丢失特征与目标间

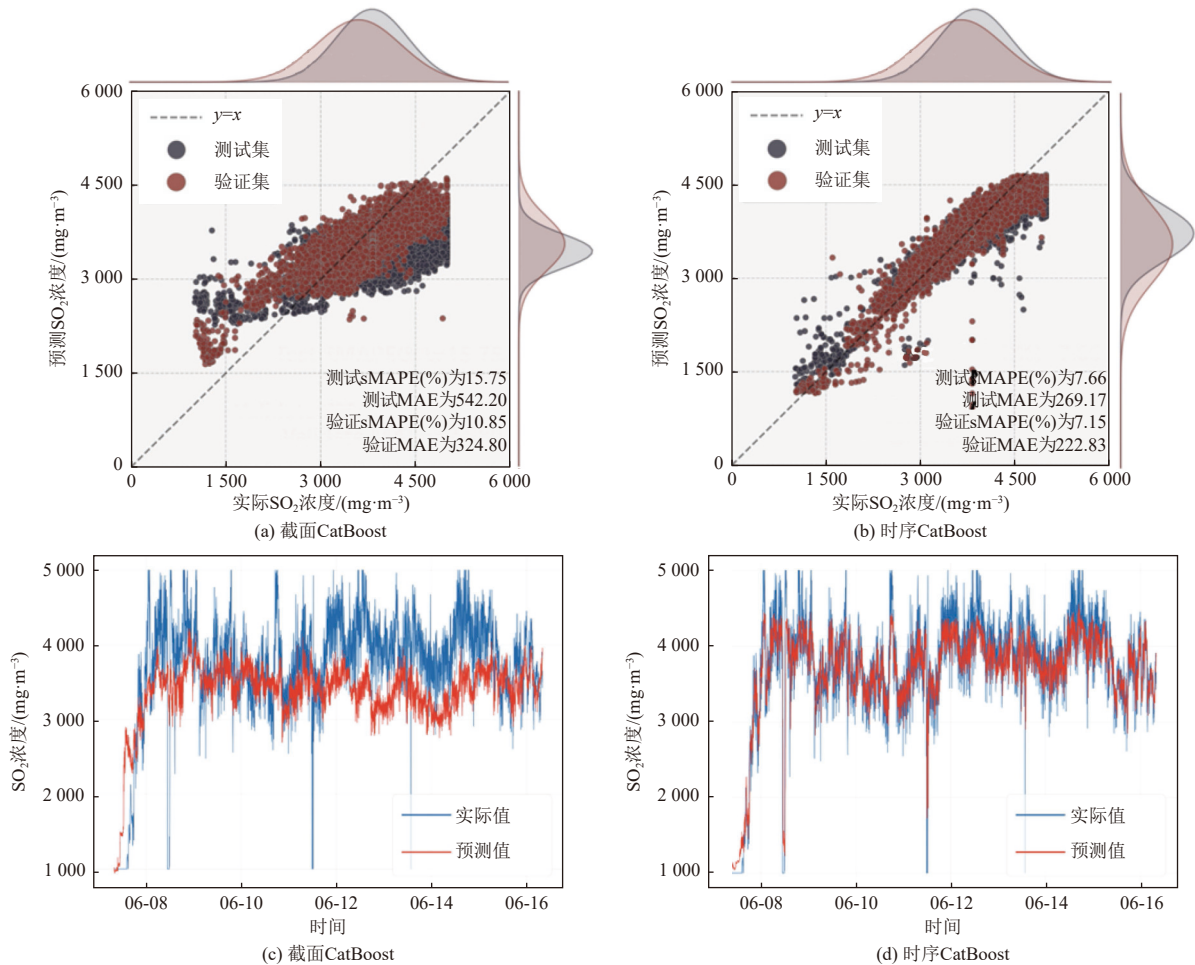


图5 截面 CatBoost 与时序 CatBoost 预测值与实际值的等值线图对比

Fig. 5 Comparison of parity plots for cross-sectional CatBoost and time-series CatBoost predicted versus actual values

的关键时序关系。具体来说,截面模型未能充分捕捉历史工况对未来排放的延续作用,且无法准确建模污染物生成的滞后效应。此外,截面特征也未能有效利用控制系统中已知的未来设定值,进而未能对排放趋势进行及时修正,导致整体预测精度的显著下降。相反,融合历史过程与未来工况的时序预测框架显著提升了模型对动态工业过程的预测能力。

表 2 截面 CatBoost 与 CatBoost 统计精度对比

Table 2 Comparison of statistical accuracy between cross-sectional CatBoost and standard CatBoost

模型	MAE	RMSE	sMAPE/%	R <sup>2</sup> /%
截面CatBoost	542.20	673.91	15.75	22.51
时序CatBoost	269.17	366.96	7.66	76.53

综合上述模型对比结果,本研究提出的时序预测框架在结合 XGBoost 与 CatBoost 等树模型后,展现出显著的性能优势。与 NLinear、TFT 等时序模型相比,基于 GBDT 的模型在该数据集上表现更为稳健。同时,相较于传统的静态建模方法,该框架通过考虑滞后影响与前馈控制,将 SO<sub>2</sub> 预测的 R<sup>2</sup> 从 22.51% 大幅提升至 76.53%。该结果有力地证明,针对污泥热解气化这类具有显著滞后效应的复杂工艺,单纯依赖先进算法而忽视输入特征的时间结构,并不能保证模型的有效性。

## 2.3 可解释分析

### 2.3.1 全局分析

为了识别影响 SO<sub>2</sub> 浓度变化的主要因素,本研究对基于时序预测框架的 CatBoost 模型进行了 SHAP 可解释分析。根据图 6,发现在所有特征中,气化炉出口温度(G.T\_out)对 SO<sub>2</sub> 浓度的影响最大,其次是气化炉炉底风机流量(G.F\_FBF)、燃烧炉炉内温度(CF.T\_2)、燃烧炉出口温度(CF.T\_out203)、气化炉干燥层温度(G.T\_dry\_125)以及公辅系统高压分汽缸压力(UAS.P\_hp)等因素。这表明在污泥热解气化过程中,多个关键工艺参数共同作用,影响着 SO<sub>2</sub> 的排放水平。

值得注意的是,大部分因素对 SO<sub>2</sub> 浓度的影响方向并非单一线性关系。这是由于硫的转化过程受到多种因素的强耦合影响,且系统具有显著的非线性、滞后性以及交互作用。例如,气化炉出口温度(G.T\_out)作为一个关键的工艺参数,能够有效反映系统的反应程度。污泥中常含有钙、铁等金属氧化物,这些物质在中低温条件下可与

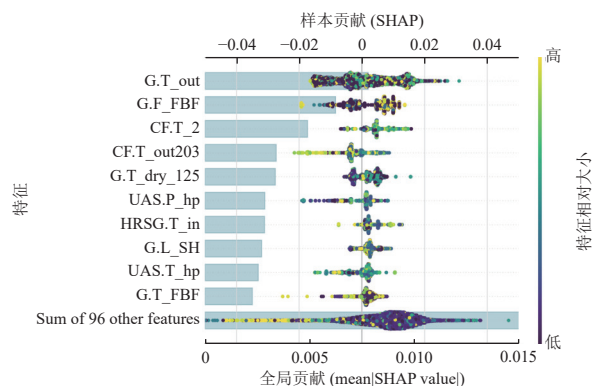


图 6 特征贡献度分析

Fig. 6 Feature contribution analysis

SO<sub>2</sub> 和 H<sub>2</sub>S 反应,生成稳定的硫酸盐(如 CaSO<sub>4</sub>)。然而,当炉内温度超过 850 °C 时,硫酸盐开始发生逆分解反应,固定的硫重新释放为 SO<sub>2</sub>,从而导致排放浓度的上升。在较低的炉温下,固硫剂活化不充分,脱硫效率较低,且低温环境导致热解反应不完全,未裂解的含硫有机物在冷凝后可能造成管道腐蚀或二次污染<sup>[32]</sup>。

对于气化炉炉底风机流量(G.F\_FBF)的调整,若风机流量过大,氧气的通入量过多,导致污泥中的碳与氧气发生过度燃烧反应,释放大量热量;与此同时,与蒸汽发生的水煤气反应却不足,这不仅导致炉内温度升高,还抑制了还原剂 H<sub>2</sub> 的产生。此外,在高温(>700 °C)且富氧的环境中,原本以 H<sub>2</sub>S 和 COS 等形式存在的还原性硫化物会被氧化为 SO<sub>2</sub>。进一步地,风机流量过大会缩短物料的停留时间,从而降低了固硫效率,导致 SO<sub>2</sub> 的排放无法得到有效控制。

以上分析结果表明,气化过程中的温度、风机流量及其他工艺参数的交互作用对 SO<sub>2</sub> 浓度的变化起到了重要作用。通过 SHAP 分析能够识别出这些关键参数的相对影响力,并为进一步优化工艺提供了重要依据。

### 2.3.2 样本分析

除了全局分析之外,随机抽取若干单个样本,以具体分析各因素对 SO<sub>2</sub> 浓度的影响程度及方向。如图 7 所示,在样本 1 中,燃烧炉的出口温度为 141.24 °C,炉底风机流量为 856.8 Nm<sup>3</sup>/h,燃烧炉炉内温度为 882.4 °C,这 3 个因素是导致该样本预测值高于全局平均值(0.504)的主要原因。在样本 2 中,尽管烧炉主火风机流量(CF.F\_FDF)和主火风机电流(CF.I\_FDF)对 SO<sub>2</sub> 浓度产生抑制,但其他因素的提升效应更为显著,导致该样本的预

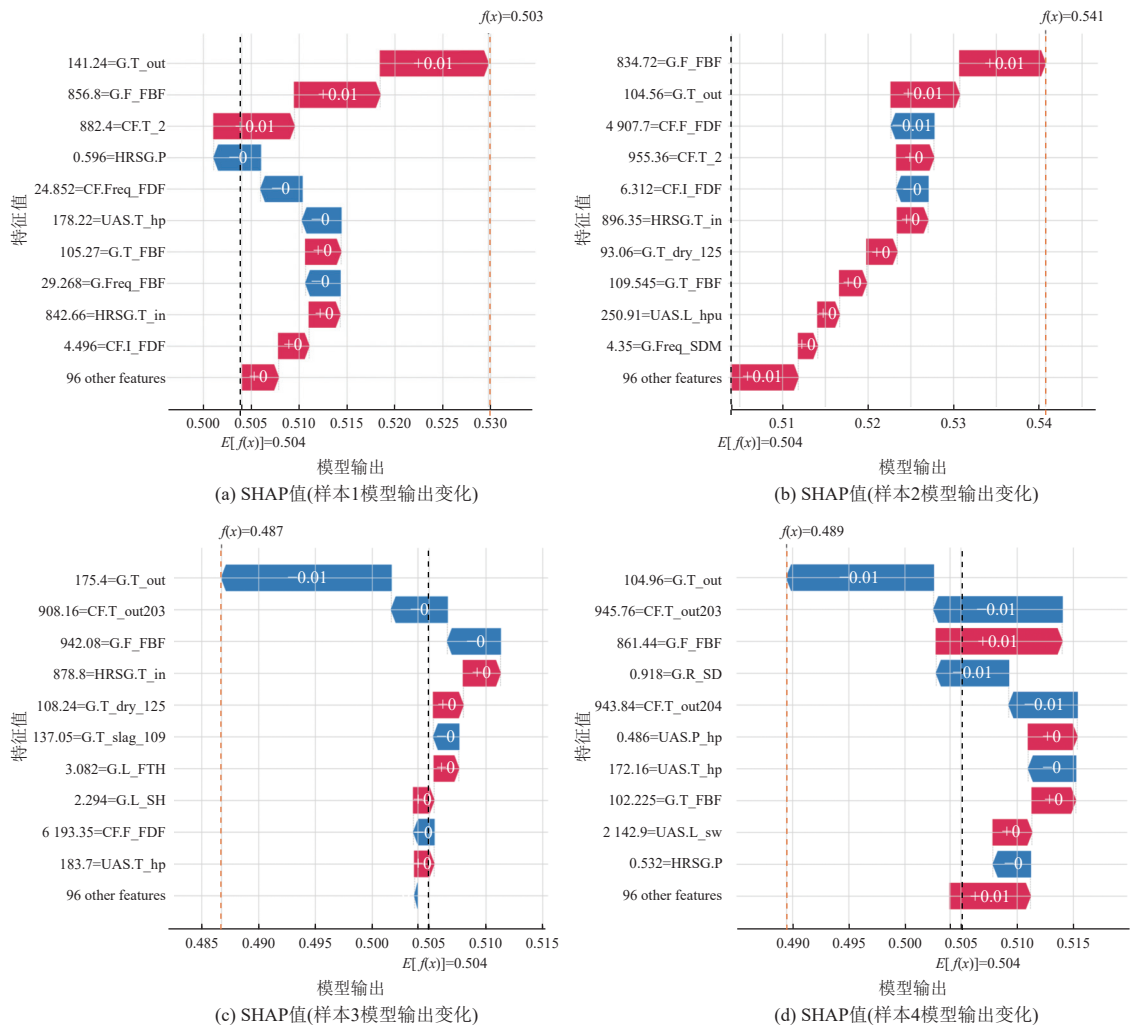


图 7 样本特征贡献度分析

Fig. 7 Feature contribution analysis for individual samples

测值相对于全局平均值偏离更大, 达到了 0.541。

在样本 3 中, 气化炉出口温度升高至 175.4 °C, 燃烧炉出口温度和气化炉炉底风机流量也有所增加, 但 SO<sub>2</sub> 浓度却低于全局平均值。这表明, 在实际工艺运行过程中, SO<sub>2</sub> 浓度的变化是多种因素共同作用的结果, 不能单纯依赖某一单一参数的变化分析 SO<sub>2</sub> 浓度的变化方向及幅度。进一步分析样本 4 的参数贡献度, 发现气化炉出口温度为 104.96 °C, 这一数值与样本 2 中的气化炉出口温度相近, 但其对 SO<sub>2</sub> 浓度的影响方向却完全相反。

这些分析结果进一步验证了在工业过程模型中, 单纯依赖机理模型无法有效捕捉各个工艺参数对目标变量的非线性影响及其交互作用。对于复杂的工业过程, 多个因素的耦合影响使得单一参数分析无法准确预测 SO<sub>2</sub> 浓度的变化。因此, 综合考虑多因素的交互效应和非线性关系, 对于精确预测废气排放波动至关重要。

### 2.3.3 工艺参数调整

为将模型预测转化为具体的工艺优化指导, 本研究基于 CatBoost 模型的累计局部效应(ALE)分析, 量化了关键参数对 SO<sub>2</sub> 排放的非线性影响, 并识别了其最优运行区间。如图 8 所示, 蒸汽压力对 SO<sub>2</sub> 排放的影响呈复杂的非单调性, 这反映了蒸汽的化学效应与物理稀释效应在不同区间的竞争关系。当蒸汽压力控制在 0.20~0.22 MPa 区间时, 累计局部效应为负, 表明此时的蒸汽压力能够有效抑制尾气中 SO<sub>2</sub> 浓度上升。这主要归因于适量蒸汽促进了水煤气反应及水煤气变换反应, 从而增强了炉内的还原性气氛, 使硫倾向于转化为 H<sub>2</sub>S 而非 SO<sub>2</sub><sup>[33]</sup>。同时, 适量蒸汽还可抑制焦油生成, 减少含硫有机物的不完全裂解<sup>[34]</sup>。然而, 随着蒸汽压力增大至 0.22~0.25 MPa 区间, 蒸汽的稀释效应开始显现, 炉内热效率降低, 影响了硫的转化路径, 导致 SO<sub>2</sub> 浓度转而上升<sup>[35]</sup>。值得注意

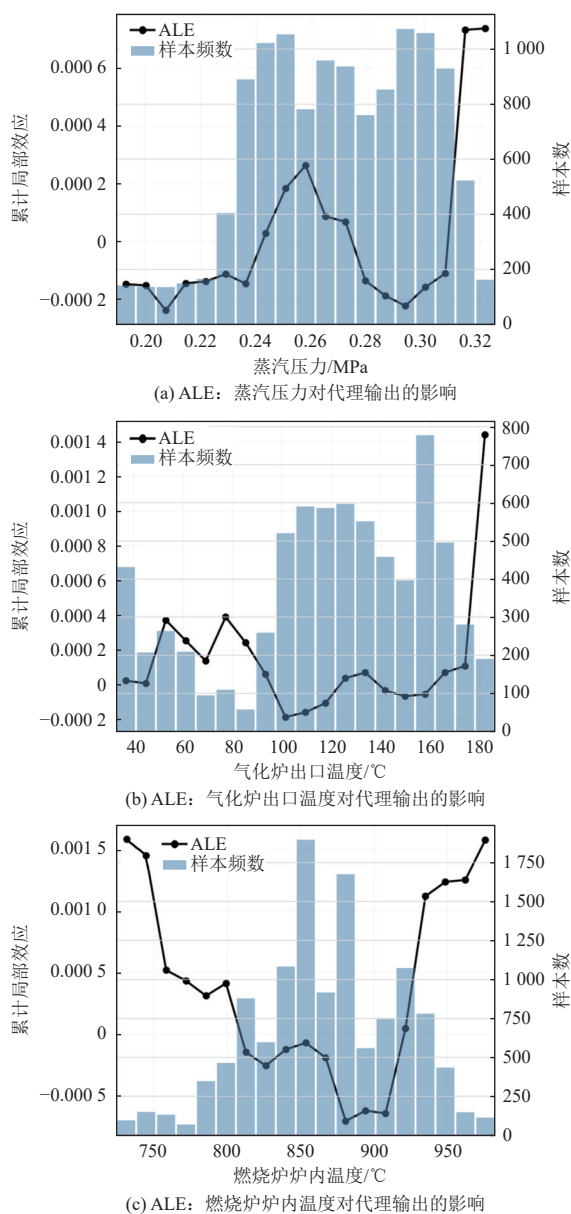


图 8 关键特征累计局部效应分析

Fig. 8 Accumulated local effects of key features

的是,在 0.28~0.30 MPa 压力区间,SO<sub>2</sub> 浓度上升的趋势趋于缓和,甚至再次出现抑制效应。这是因为此时较高的蒸汽压力促进了 COS、H<sub>2</sub>S 等气态硫化物的水解反应,并增强飞灰中 CaO 等碱性成分的水合活性,生成了更易与 SO<sub>2</sub> 反应的 Ca(OH)<sub>2</sub>,从而在后续烟气段间接提升了固硫效率<sup>[36-37]</sup>。若蒸汽压力超过此范围,SO<sub>2</sub> 浓度则再次显著升高,这表明蒸汽的物理稀释负面效应已占据绝对主导,严重破坏了燃烧稳定性与系统热平衡,导致所有潜在的固硫收益均被抵消。

裂解气在进入燃烧炉前会通过余热回收系统回收部分热能,导致该测点温度低于气化裂解气温度(500~800 °C)。ALE 分析表明,该温度是预

示 SO<sub>2</sub> 排放行为的关键动态指标。当出口温度低于 100 °C 时,SO<sub>2</sub> 排放升高。这是因为过度冷却导致裂解气中大量气态硫化物(如 COS、有机硫)及携带硫的焦油蒸汽冷凝并吸附于管道或颗粒物表面<sup>[38]</sup>。当这些物质在燃烧炉内瞬间受热释放并氧化时,引发了 SO<sub>2</sub> 浓度的快速升高。将出口温度控制在 100~160 °C 区间时,其影响趋于中性。这并非该温度本身直接促进了有利反应,而是因为其标志着一个优化的工艺状态,此时既避免了上述不利于硫转化反应的深度冷凝现象,又能有效分离水分和部分重杂质,使硫以更均匀且易处理的气态形式(主要为 H<sub>2</sub>S)进入燃烧炉,从而实现了更平稳、更彻底的燃烧和硫转化<sup>[39]</sup>。这一发现具有重要的实践意义,说明气化炉出口温度不仅是一个状态参数,更是预测硫是否会发生不利形态转化的预警指标。在实际工程中,应通过实时监控和调控该点温度,减小 SO<sub>2</sub> 排放的波动频率与幅度,确保尾气排放的稳定性。

燃烧炉炉内温度对 SO<sub>2</sub> 浓度的影响则更为复杂且敏感。根据 ALE 分析,当炉内温度低于 800 °C 时,工艺运行伴随较高浓度的 SO<sub>2</sub> 排放。此时 H<sub>2</sub>S 被氧化后,飞灰中 CaO 的固硫反应速率较低,导致 SO<sub>2</sub> 脱除效率低下<sup>[40-41]</sup>。将炉内温度控制在 800~900 °C 区间时,SO<sub>2</sub> 排放得到最佳控制。此温度窗口实现了燃烧效率与脱硫效率的协同,一方面确保合成气完全燃烧,H<sub>2</sub>S 彻底转化为 SO<sub>2</sub>,另一方面,CaO 的固硫反应速率达到峰值,且生成的 CaSO<sub>4</sub> 在此温度下稳定存在。然而,当炉温超过 900 °C 时,SO<sub>2</sub> 排放再次升高。这是由于在高温下,CaSO<sub>4</sub> 开始变得不稳定并发生热分解,已被固定的硫重新释放;此外,高温还可能引发飞灰熔融,包裹住活性 CaO,进一步降低固硫能力。因此,燃烧炉炉内温度稳定在 800~900 °C 区间内,是实现高效能源回收与低 SO<sub>2</sub> 排放协同优化的关键。

### 2.3.4 关键参数的交互效应分析

蒸汽压力与气化炉出口温度往往协同波动,二者的耦合效应可能对 SO<sub>2</sub> 排放产生非线性放大或抵消作用。为量化这一交互影响,本研究基于训练完成的 CatBoost 模型,采用网格扫描方法构建了蒸汽压力与气化炉出口温度的二维累积局部效应(2D ALE)模型,量化蒸汽压力与气化炉出口温度的交互影响。

图 9 热力图中颜色由蓝至红表示 SO<sub>2</sub> 预测浓

度由低到高。低排放区域(蓝色)主要分布在图的左侧,对应蒸汽压力 0.18~0.26 MPa 的较宽范围内。这一发现与 2.3.3 节的 ALE 分析相呼应,在低压区,蒸汽主要通过促进还原性气氛抑制  $\text{SO}_2$  生成,且这一效应受气化炉出口温度影响较小。值得注意的是,图中左上角(蒸汽压力<0.22 MPa、气化炉出口温度 100~160  $^{\circ}\text{C}$ )存在一个深蓝色区域,这与单因素分析中 2 个参数各自的最优区间完全吻合,验证了结论的稳健性。

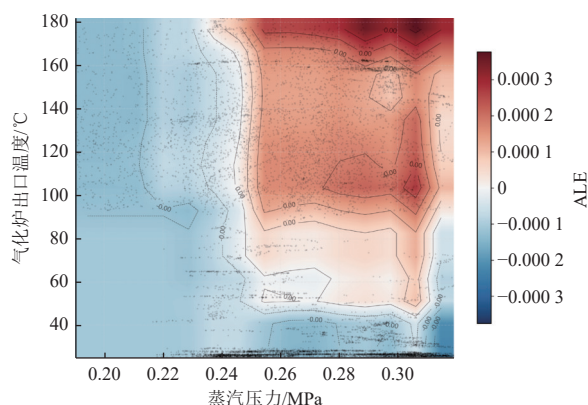


图 9 蒸汽压力与气化炉出口温度的交互效应对  $\text{SO}_2$  排放的影响

Fig. 9 Interactive effects of steam pressure and gasifier outlet temperature on  $\text{SO}_2$  emissions

高排放区域(红色)则集中出现在图的右上角,对应蒸汽压力在 0.28 MPa 以上且气化炉出口温度超过 160  $^{\circ}\text{C}$  的区间。这一发现具有重要的实践意义,说明当 2 个参数同时处于高位时,会触发协同负面效应。高温导致气化段硫挥发加剧,且可能使  $\text{CaSO}_4$  趋于分解。同时,高压蒸汽的物理稀释效应严重破坏燃烧稳定性与系统热平衡。

#### 2.4 机理与数据结合提升工业应用潜力

本研究提出的时序预测框架从工艺特征出发,全面考虑了历史物料投加、设备参数及未来操作计划对废气排放的综合影响。通过建立沿时间轴滚动更新的特征输入与预测机制,使得模型结构更加契合工艺的实际运行过程,进一步提高了模型的预测精度与稳定性。

在此基础上,综合对比了机器学习与深度学习模型的性能,发现对于中等规模的工厂级数据,深度学习模型(如 TFT)由于其结构复杂且参数空间较大,容易出现过拟合现象。NLinear 虽然训练效率较高,但在捕捉特征与目标变量间的非线性关系及特征交互效应方面存在局限性。相比之

下,GBDT 模型通过其决策树结构,更擅长刻画特征间的交互效应,同时能够自动忽略无关变量的影响。因此,在实际工业应用中,GBDT 模型的预测结果较为稳定,具有较高的鲁棒性。

此外,本研究中的可解释性分析超越了单纯的模型解释,成功构建了一个数据驱动预测与污泥热解气化底层化学原理之间的坚实桥梁。模型的可解释性结果与既定工艺知识高度一致,极大地增强了数据驱动方法的可信度。SHAP 分析清晰地揭示了气化炉出口温度、炉底风机频率、燃烧炉炉内温度等是影响  $\text{SO}_2$  浓度波动的主导因素,证明了模型不仅学习到了数据中的关联关系,而且捕捉了实际的物理化学规律。通过进一步的 ALE 分析,我们优化了关键工艺参数的选择范围,旨在最大化资源回收效率的同时,降低工艺的环境成本;不仅为实时工艺优化提供了理论支撑,还为实现低排放、高效率的工业操作提供了重要的决策依据。

### 3 结 论

本研究基于郑州新区污水处理厂污泥热解气化工序的分钟级运行数据,构建了融合历史过程与未来工况的时序预测框架。相较于忽视时间依赖的截面模型( $R^2=22.51\%$ ),融合滞后效应与前馈信息的时序 CatBoost 模型将  $\text{SO}_2$  预测的  $R^2$  提升至 76.53%, MAE 降低至 269.17,验证了充分考虑工艺动态特征对复杂工业过程建模的必要性。此外,基于梯度提升的树模型(XGBoost、CatBoost)在预测精度与稳定性上均优于 NLinear 与 TFT,更适合作为工业现场部署的可靠选择。

在此基础上,本研究结合可解释性工具,对基于时序 CatBoost 预测  $\text{SO}_2$  浓度的动态变化进行了深入分析,不仅验证了气化炉出口温度、燃烧炉炉内温度等是最关键的影响因素,还精确量化了不同工艺参数的最优运行区间。当将蒸汽压力、气化炉出口温度和燃烧炉炉内温度分别控制在 0.28~0.30 MPa、100~160  $^{\circ}\text{C}$  和 800~900  $^{\circ}\text{C}$  区间时,可以协同实现高效能源回收与控制  $\text{SO}_2$  排放。通过以上工作,成功地将模型从单纯的排放预测工具转变为故障诊断与工艺优化的决策支持系统。同时,通过数据科学深度解析了工艺机理,也为推动人工智能的工业场景应用奠定了坚实基础。

本研究所选模型虽具有代表性,但未能充分体现工艺中的复杂物理化学过程,预测精度仍有

提升空间。未来研究可引入更多符合工艺机理的特征表征方法,探索物理信息神经网络(PINN)等混合建模手段,并通过分析特征在不同时间步的滞后影响,明确提前干预的时间窗口,进一步增强模型的工业应用价值。

#### 参考文献 (References) :

- [1] 戴晓虎, 张辰, 章林伟, 等. 碳中和背景下污泥处理处置与资源化发展方向思考 [J]. *给水排水*, 2021, 57(3): 1-5. DAI Xiaohu, ZHANG Chen, ZHANG Linwei, et al. Thoughts on the development direction of sludge treatment and resource recovery under the background of carbon neutrality[J]. *Water & Wastewater Engineering*, 2021, 57(3): 1-5.
- [2] 古励, 盛国荣, 潘伟亮, 等. 城市污水处理厂污泥特征分析及针对性减量方案 [J]. *净水技术*, 2025, 44(11): 91-97. GU Li, SHENG Guorong, PAN Weiliang, et al. Characteristics analysis of urban WWTPs sludge and targeted scheme for sludge reduction[J]. *Water Purification Technology*, 2025, 44(11): 91-97.
- [3] 刘杏, 李旭芳, 余波, 等. 两段式干化+热解气化工艺碳排放核算及碳减排策略 [J]. *中国给水排水*, 2025, 41(24): 44-51. LIU Xing, LI Xufang, YU Bo, et al. Carbon emissions calculation and carbon emission reduction strategy of two-stage drying + pyrolysis and gasification process[J]. *China Water & Wastewater*, 2025, 41(24): 44-51.
- [4] GU Chaohai, YU Hanqing. Turning sewage sludge into valuable catalysts through atomic-level circularity[J]. *Nature Reviews Materials*, 2025, 10(10): 725-726.
- [5] HUANG C, MOHAMED B A, LI L Y. Comparative life-cycle assessment of pyrolysis processes for producing bio-oil, biochar, and activated carbon from sewage sludge[J]. *Resources, Conservation and Recycling*, 2022, 181: 106273.
- [6] BAI Lijun, WU Bing, CAO Jianglin, et al. Advancements in sludge pyrolysis: Integrated resource recovery and process-derived pollutant mitigation[J]. *Journal of Analytical and Applied Pyrolysis*, 2025, 190: 107137.
- [7] 马雯, 呼世斌. 以城市污泥为掺料制备烧结砖 [J]. *环境工程学报*, 2012, 6(3): 1035-1038. MA Wen, HU Shibin. Application of municipal sewage sludge in the process of sintering brick[J]. *Techniques and Equipment for Environmental Pollution Control*, 2012, 6(3): 1035-1038.
- [8] CHU Zhiwei, LI Yingjie, ZHANG Chunxiao, et al. A review on resource utilization of oil sludge based on pyrolysis and gasification[J]. *Journal of Environmental Chemical Engineering*, 2023, 11(3): 109692.
- [9] 陈晓旭, 孔庆玲, 裴育峰, 等. 基于固体废物等离子化与污泥热解耦合的多联产集成系统性能分析 [J]. *热能动力工程*, 2025, 40(9): 107-117. CHEN Xiaoxu, KONG Qingling, PEI Yufeng, et al. Performance analysis of a poly-generation integrated system based on the coupling of solid waste plasma gasification and sludge pyrolysis[J]. *Journal of Engineering for Thermal Energy and Power*, 2025, 40(9): 107-117.
- [10] 刘欣瑜. 城市生活垃圾热解气化技术资源化潜力分析 [J]. *中国资源综合利用*, 2025, 43(10): 118-120. LIU Xinyu. Analysis of resource utilization potential for urban domestic waste pyrolysis gasification technology[J]. *China Resources Comprehensive Utilization*, 2025, 43(10): 118-120.
- [11] ZHENG Min, HU Zhetai, LIU Tao, et al. Pathways to advanced resource recovery from sewage[J]. *Nature Sustainability*, 2024, 7(11): 1395-1404.
- [12] HU Mian, HU Hongyu, YE Zhiheng, et al. A review on turning sewage sludge to value-added energy and materials via thermochemical conversion towards carbon neutrality[J]. *Journal of Cleaner Production*, 2022, 379: 134657.
- [13] CHANG Huimin, YUAN Jiayi, ZHAO Yan, et al. Carbon footprints of incineration, pyrolysis, and gasification for sewage sludge treatment[J]. *Resources, Conservation and Recycling*, 2025, 212: 107939.
- [14] JIN Junwei, LI Yanan, ZHANG Jianyun, et al. Influence of pyrolysis temperature on properties and environmental safety of heavy metals in biochars derived from municipal sewage sludge[J]. *Journal of Hazardous Materials*, 2016, 320: 417-426.
- [15] JOSHUA ABIOYE K, RAJAMANICKAM R, OGUNJINMI T, et al. Advancements in biomass waste conversion to sustainable biofuels via gasification[J]. *Chemical Engineering Journal*, 2025, 505: 159151.
- [16] 唐云琪, 葛李, 冯虞芯, 等. 基于自动化集成机器学习的污水处理碳排放预测模型构建 [J]. *环境科学学报*, 2025, 45(12): 449-458. TANG Yunqi, GE Li, FENG Yuxin, et al. Construction of a carbon emission prediction model for urban wastewater treatment plants based on automated integrated machine learning[J]. *Acta Scientiae Circumstantiae*, 2025, 45(12): 449-458.
- [17] 刘显芬, 毕雪, 彭辉, 等. 基于机器学习的生活污水处理厂全氟和多氟烷基化合物排放负荷预测 [J]. *环境污染与防治*, 2025, 47(7): 11-18. LIU Xianfen, BI Xue, PENG Hui, et al. Prediction of per- and polyfluoroalkyl substances emission load in domestic wastewater treatment plant based on machine learning[J]. *Environmental Pollution and Control*, 2025, 47(7): 11-18.
- [18] LYU Jiaqiang, DU Lili, LIN Hongyong, et al. Enhancing effluent quality prediction in wastewater treatment plants through the integration of factor analysis and machine learning[J]. *Bioresour Technol*, 2024, 393: 130008.
- [19] JABLONKA K M, CHARALAMBOUS C, SANCHEZ FERNANDEZ E, et al. Machine learning for industrial processes: Forecasting amine emissions from a carbon capture plant[J]. *Science Advances*, 2023, 9(1):

- eadc9576.
- [20] WANG Chen, ZHOU Dengji, WANG Xiaoguo, et al. Multiscale graph based spatio-temporal graph convolutional network for energy consumption prediction of natural gas transmission process[J]. *Energy*, 2024, 307: 132489.
- [21] HU Yuchen, WEI Renke, YU Ke, et al. Exploring sludge yield patterns through interpretable machine learning models in China's municipal wastewater treatment plants[J]. *Resources, Conservation and Recycling*, 2024, 204: 107467.
- [22] SINGH K P, GUPTA S, KUMAR A, et al. Linear and nonlinear modeling approaches for urban air quality prediction[J]. *Science of the Total Environment*, 2012, 426: 244–255.
- [23] ZHU Junjie, SIMA N Q, LU Ting, et al. Adaptive soft sensing of river flow prediction for wastewater treatment operation and risk management[J]. *Water Research*, 2022, 220: 118714.
- [24] YANG Hongrui, HUANG Kuan, ZHANG Kai, et al. Predicting heavy metal adsorption on soil with machine learning and mapping global distribution of soil adsorption capacities[J]. *Environmental Science & Technology*, 2021, 55(20): 14316–14328.
- [25] TRIPATHY K P, MISHRA A K. Deep learning in hydrology and water resources disciplines: Concepts, methods, applications, and research directions[J]. *Journal of Hydrology*, 2024, 628: 130458.
- [26] ZHOU Qi, QU Shen, WANG Qianzi, et al. Sliding window-based machine learning for environmental inspection resource allocation[J]. *Environmental Science & Technology*, 2023, 57(44): 16743–16754.
- [27] ZHU Junjie, YANG Meiqi, REN Z J. Machine learning in environmental research: Common pitfalls and best practices[J]. *Environmental Science & Technology*, 2023, 57(46): 17671–17689.
- [28] YANG Zhengwu, ZHANG Xinwan, HU Huawei, et al. Multi-objective interpretation machine learning framework for Synergistically optimizing energy consumption and surface quality in electrolytic copper foil production[J]. *Journal of Cleaner Production*, 2025, 525: 146617.
- [29] LIU Xian, LU Dawei, ZHANG Aiqian, et al. Data-driven machine learning in environmental pollution: Gains and problems[J]. *Environmental Science & Technology*, 2022, 56(4): 2124–2133.
- [30] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[C]//*Neural Information Processing Systems*, 2017.
- [31] APLEY D W, ZHU Jingyu. Visualizing the effects of predictor variables in black box supervised learning models[J]. *Journal of the Royal Statistical Society Series B (Statistical Methodology)*, 2020, 82(4): 1059–1086.
- [32] ISMAIL T M, EL SALAM M A. Parametric studies on biomass gasification process on updraft gasifier high temperature air gasification[J]. *Applied Thermal Engineering*, 2017, 112: 1460–1473.
- [33] 李卓, 王志伟, 陈高峰, 等. 生物质水蒸气气化催化制氢研究进展全文替换[J]. *现代化工*, 2024, 44(7): 20–25.  
LI Zhuo, WANG Zhiwei, CHEN Gaofeng, et al. Research progress in catalytic hydrogen production from biomass steam gasification[J]. *Modern Chemical Industry*, 2024, 44(7): 20–25.
- [34] 徐乃光, 刘涛涛, 宋薇, 等. 生物质气化过程中焦油减量研究进展[J]. *化工进展*, 2025, 44(11): 6174–6186.  
XU Naiguang, LIU Taotao, SONG Wei, et al. Research progress on tar reduction in biomass gasification process[J]. *Chemical Industry and Engineering Progress*, 2025, 44(11): 6174–6186.
- [35] 何丕文, 焦李, 肖波. 水蒸气流量对污水污泥气化产气特性的影响[J]. *湖北农业科学*, 2013, 52(11): 2529–2532.  
HE Piwen, JIAO Li, XIAO Bo. Influence of steam flow on the syngas characteristics of sewage sludge gasification[J]. *Hubei Agricultural Sciences*, 2013, 52(11): 2529–2532.
- [36] 姜欢, 艾天浩, 李佳欣, 等. 钢铁工业煤气中羰基硫的吸附和催化水解[J/OL]. *环境化学*: 1–17[2026-03-16]. <https://link.cnki.net/urlid/11.1844.X.20250707.1641.010>.  
JIANG Huan, AI Tianhao, LI Jiaxin, et al. Adsorption and catalytic hydrolysis of COS in steelworks gas[J/OL]. *Environmental Chemistry*: 1–17[2026-03-16]. <https://link.cnki.net/urlid/11.1844.X.20250707.1641.010>.
- [37] 王世昌, 姚强, 徐旭常. 水合反应和氧化铁对 CaO 颗粒脱硫反应作用的 Arrhenius 表达[J]. *热能动力工程*, 2004, 19(6): 567–571.  
WANG Shichang, YAO Qiang, XU Xuchang. Arrhenius expression of the effect of hydration reaction and Fe<sub>2</sub>O<sub>3</sub> particles on the desulfurization reaction with CaO particles[J]. *Journal of Engineering for Thermal Energy and Power*, 2004, 19(6): 567–571.
- [38] 米铁, 徐玲娜, 袁羽书, 等. 生物质热解过程中焦油形成机理的研究[J]. *华中师范大学学报(自然科学版)*, 2013, 47(5): 671–675.  
MI Tie, XU Lingna, YUAN Yushu, et al. Study of tar formation and variation mechanism for biomass pyrolysis gasification[J]. *Journal of Huazhong Normal University (Natural Sciences)*, 2013, 47(5): 671–675.
- [39] 郭玉乾, 张健, 张瑞娜, 等. 沼渣热解中硫释放与迁移研究[J]. *生物质化学工程*, 2025, 59(2): 30–38.  
GUO Yuqian, ZHANG Jian, ZHANG Ruina, et al. Sulfur release and migration in digestate pyrolysis[J]. *Biomass Chemical Engineering*, 2025, 59(2): 30–38.
- [40] 王中慧, 赵雪卿, 霍晓东, 等. 电石渣和煤矸石对型煤固硫性能的影响及作用机制研究[J]. *煤炭转化*, 2024, 47(4): 104–113.  
WANG Zhonghui, ZHAO Xueqing, HUO Xiaodong, et al. Study on effects and mechanism of calcium carbide slag and coal gangue on sulfur fixation performance of briquette[J]. *Coal Conversion*, 2024, 47(4): 104–113.
- [41] WENG Wubin, ALDÉN M, LI Zhongshan. Quantitative SO<sub>2</sub> detection in combustion environments using broad band ultraviolet absorption and laser-induced fluorescence[J]. *Analytical Chemistry*, 2019, 91(16): 10849–10855.