

DOI: 10.19666/j.rlfed.202401012

可解释的变负荷下燃煤机组 SCR 反应器 入口 NO_x 质量浓度预测模型

李影¹, 卓建坤², 吴逸凡², 樊永刚¹, 姚强^{1,2}, 李水清²

(1.新疆大学电气工程学院, 新疆 乌鲁木齐 830046;

2.清华大学热科学与动力工程教育部重点实验室, 北京 100084)

[摘要] 燃煤电厂灵活调峰过程 NO_x 测量往往存在滞后现象, 导致选择性催化还原(selective catalytic reduction, SCR) 脱硝喷氨控制系统响应不及时, 易造成喷氨量过高或过低, 从而造成 SCR 反应器出口 NO_x 质量浓度波动剧烈和氨逃逸率增大。为实现喷氨阀门的提前快速调节并考虑影响燃煤锅炉 NO_x 排放量的因素存在耦合性, 提出了一种基于卷积神经网络(convolutional neural network, CNN) 和长短时记忆(long short-term memory, LSTM) 神经网络混合模型的 SCR 反应器入口 NO_x 预测模型。利用一台 330 MW 燃煤电站锅炉的运行参数, 通过 Pearson 系数法计算特征变量之间的相关性, 筛选出相关性较大的特征, 并定义模型的输入矩阵和输出矩阵, 采用随机搜索算法进行优化, 以提高预测性能。进一步利用 SHAP 算法对黑箱模型进行解释, 并通过 Simulink 仿真验证了带有 NO_x 预测的控制效果。结果表明: CNN-LSTM 预测模型在调峰负荷变化时, 能够以较高的精度预测 SCR 反应器入口 NO_x 质量浓度的变化, 并能提前 25 s 为喷氨控制系统提供反馈; 优化后的喷氨控制策略降低了出口 NO_x 质量浓度与设定值间的标准差(降低 28%), 并提升了 NH₃/NO_x 的响应速度, 减小最大氨逃逸量 22%。该研究结果可为灵活调峰机组的智慧 SCR 脱硝技术及燃烧优化提出有效的指导。

[关键词] NO_x 预测; 燃煤机组; CNN-LSTM 模型; SHAP; 灵活调峰

[引用本文格式] 李影, 卓建坤, 吴逸凡, 等. 可解释的变负荷下燃煤机组 SCR 反应器入口 NO_x 质量浓度预测模型[J]. 热力发电, 2024, 53(7): 119-128. LI Ying, ZHUO Jiankun, WU Yifan, et al. Interpretable prediction model for NO_x mass concentration at SCR reactor inlet in coal-fired power plants under flexible operating conditions[J]. Thermal Power Generation, 2024, 53(7): 119-128.

Interpretable prediction model for NO_x mass concentration at SCR reactor inlet in coal-fired power plants under flexible operating conditions

LI Ying¹, ZHUO Jiankun², WU Yifan², FAN Yonggang¹, YAO Qiang^{1,2}, LI Shuiqing²

(1.School of Electrical Engineering, Xinjiang University, Urumqi 830046, China;

2.Key Laboratory for Thermal Science and Power Engineering of Ministry of Education, Tsinghua University, Beijing 100084, China)

Abstract: There is a delay in NO_x measurement for flexible operations in coal-fired power plants, which leads to a delayed response in ammonia injection control system of selective catalytic reduction (SCR) reactor, resulting in potential over or under-injection of ammonia and significant fluctuations in NO_x mass concentration at outlet of the SCR reactor. To enable proactive adjustment of ammonia injection and considering the interconnected factors influencing the NO_x emissions from coal combustion, a prediction model for NO_x mass concentration at the SCR reactor inlet is proposed based on convolutional neural networks (CNNs) and long short-term memory neural (LSTM) networks. By using operational parameters from a 330 MW coal-fired power plant, a Pearson coefficient method is employed to calculate the correlation between feature variables. Significant features are extracted to

收稿日期: 2024-01-22

基金项目: 自治区重大科技专项项目(2023A01005-1)

Supported by: Provincial Major Scientific and Technological Special Project (2023A01005-1)

第一作者简介: 李影(1999), 女, 硕士研究生, 主要研究方向为智慧电厂污染物控制等, 3214650576@qq.com。

通信作者简介: 卓建坤(1975), 男, 博士, 副研究员, 主要研究方向为清洁燃烧及智慧电厂等, zhuojk@tsinghua.edu.cn。

define the model input matrix and output matrix. The random search algorithm is used for hyper-parameters optimization to enhance predictive performance. The SHAP algorithm is then applied to interpret the model structure and explain the black-box model. Finally, the control effects of model with NO_x concentration prediction is verified through Simulink simulation. The results indicate that, the CNN-LSTM prediction model demonstrates higher predictive accuracy for the variable NO_x mass concentration at the SCR reactor inlet during the frequent load fluctuations. It can provide feedback to the ammonia injection control system of 25 seconds in advance. The optimized ammonia injection control strategy not only reduces the standard deviation between the NO_x mass concentration at the SCR reactor outlet and the set value by 28%, but also improves the response speed of NH_3/NO_x regulation, reducing the maximum ammonia slip by 22%. The research findings can provide guidance for intelligent SCR denitration system and combustion optimizing operating during flexible operation of coal-fired power plants.

Key words: NO_x prediction; coal-fired power unit; CNN-LSTM model; SHAP; flexible operation

我国的能源结构以煤炭为主,这决定了以燃煤发电为主导的发电结构^[1]。在“双碳”目标下,虽然以风、光为主的可再生能源的大规模发展有助于降低 CO_2 排放,但这些能源具有随机性大、波动性强和间歇性等特点^[2],因此燃煤发电机组需要适应由此带来的灵活调峰需求。燃煤电厂普遍采用选择性催化还原(selective catalytic reduction, SCR)进行烟气脱硝处理,但在机组负荷快速变化时,SCR 反应器入口 NO_x 质量浓度将出现较大扰动,难以满足日益严苛的排放控制^[3]。传统的连续排放检测系统(continuous emissions monitoring system, CEMS)在测量 SCR 反应器入口 NO_x 质量浓度时存在滞后性,滞后时间与烟气取样系统的伴热导管长度有关,通常在 60 s 左右^[4]。此外,现有电厂的喷氨控制策略,如固定摩尔比控制和固定出口 NO_x 质量浓度控制等^[5],无法及时响应 NO_x 质量浓度的快速变化,易导致 NO_x 排放超标或氨逃逸增加^[6],对机组的运行安全及经济性造成不利影响。

燃煤锅炉系统的运行复杂,运行数据具有高维度和大数据量等特点,且影响 NO_x 生成的变量(如风量、给煤量、燃烧温度等)具有非线性、强耦合性、时滞性大^[7],难以通过数值仿真实时计算,也无法精确在线测量重要过程变量。国内外学者利用机器学习方法及逆行软测量,针对 CEMS 测量 NO_x 滞后和氨逃逸问题进行大量的研究。王桂林等^[8]基于支持向量机建立了 300 MW 机组有功功率、排烟氧量等变量与 SCR 反应器入口 NO_x 质量浓度和脱硝效率之间的预测模型,并利用遗传算法对喷氨量进行优化,得到成本最低的喷氨策略,优化后总成本下降约 0.65%。廖永进等^[9]采用径向基函数神经网络法,建立了锅炉负荷、烟气体积流量等 5 个变量与脱硝效率之间的关系,并随机选取负荷在 50%~100% 的 125 组数据进行训练,对脱硝效率及出口 NO_x 质量浓度进行预测。唐振浩等^[10]利用极限学习机误差模

型,选用稳定负荷 4 700 组、升负荷 4 500 组、降负荷 3 900 组数据进行预测,预测模型在不同工况下的预测误差均小于 2%。王英男^[11]利用注意力机制和长短时记忆(long short-term memory, LSTM)神经网络组合模型有效降低预测误差至 0.424%,但在机组负荷变化过大时,会出现模型失配问题。Qiao^[12]利用改进型 LSTM 神经网络,选取 7 212 组数据,综合考虑变量的变化率,最终实现了提前 30 s 预测 NO_x 质量浓度,预测相对误差为 4%。Zhao 等人^[13]利用堆叠综合集成方法,实现了较高的回归系统和较小的均方根误差,具有较强的鲁棒性和泛化能力。上述研究证明了数据驱动方法在 NO_x 质量浓度预测中的可行性,但所选取数据量较小,难以在复杂全工况下保持较高的精确度,模型预测精度还需提升。

针对燃煤电厂深度调峰,脱硝入口 NO_x 质量浓度测量滞后和氨逃逸等问题,本文基于某 330 MW 燃煤电站分散控制系统(distributed control system, DCS)中的锅炉长期运行的时序数据,提出了基于 CNN-LSTM 的 SCR 反应器入口 NO_x 质量浓度预测模型。首先进行数据预处理,并定义预测模型的输入矩阵 \mathbf{X} 和输出矩阵 \mathbf{Y} ,然后使用随机搜索算法对模型进行迭代优化,获得兼顾预测精度与工况适应性的最优模型超参数;接着,利用 SHAP(Shapley additive explanation)算法对黑箱模型进行解释,分析稳定负荷运行和变负荷工况下 NO_x 质量浓度的主要影响参数,并研究各参数对 SCR 反应器入口 NO_x 浓度的协同作用机制;最后,通过 Simulink 设计 SCR 反应器出口 NO_x 控制回路,研究本文提出 CNN-LSTM 预测模型对回路控制的影响。

1 方法

1.1 数据收集及特征选取

本研究以某电厂 330 MW 四角切圆机组为对象,数据来源于 DCS,时间间隔为 5 s,数据量为

812 000 组。每组数据均包含所有变量的有效值，排除丢失数据情况。数据包括负荷上升、下降、稳定 3 种运行状态。

根据燃料型 NO_x、热力型 NO_x、快速型 NO_x 3 种生成机理^[14]，本文选取了总风量、总煤量、A 磨煤机（A 磨）入口风量等 26 个变量，具体见表 1。煤质是影响 NO_x（由于 NO 在 NO_x 中占比较高，本文中 NO 数据即为 NO_x 数据）排放的重要参数，由于 DCS 中没有实时测量煤质数据（如热值、工业分析或元素分析等），煤质的改变会直接影响煤量、风量等运行变量以及 NO_x 生成。因此，可以通过相关参数的时序数据反映煤质的影响。

表 1 运行条件下研究机组的特征变量

Tab.1 The characteristic variables of the studied unit under operating conditions

变量	标签
总风量/(t·h ⁻¹)	Air Flow
总给煤量/(t·h ⁻¹)	Coal
选择后发电机有功功率/MW	Load
A 磨入口风量/(t·h ⁻¹)	A_air
B 磨入口风量/(t·h ⁻¹)	B_air
C 磨入口风量/(t·h ⁻¹)	C_air
D 磨入口风量/(t·h ⁻¹)	D_air
烟气侧省煤器入口温度/℃	Economizer_T
省煤器入口烟气温度（左侧）/℃	Economizer_T_left
汽轮机入口蒸汽压力/MPa	Steam pressure
主蒸汽流量/(t·h ⁻¹)	Steam mass flow
5 号低加抽汽压力/MPa	NO.5 pressure
A 空预器入口氧量/%	Air preheater_O2
A 一次风风机电流/A	A_Primary airflow
B 一次风风机电流/A	B_Primary airflow
二次风挡板开度/%	Baffle opening
SCR 反应器 B 入口烟气温度/℃	SCR_B_T
SCR 反应器 B 入口 O ₂ 体积分数/%	SCR_B_O2
SCR 反应器 B 烟气流量/(t·h ⁻¹)	SCR_B_Flue_gas_Flow
SCR 反应器 B 氨气流量/(t·h ⁻¹)	B_NH3
SCR 反应器 A 入口烟气温度/℃	SCR_A_T
SCR 反应器 A 入口 O ₂ 体积分数/%	SCR_A_O2
SCR 反应器 A 烟气流量/(t·h ⁻¹)	SCR_A_Flue_gas_Flow
SCR 反应器 A 氨气流量/(t·h ⁻¹)	A_NH3
SCR 反应器 A 入口烟气压力/MPa	SCR_A_pressure
SCR 反应器 A 入口 NO 质量浓度/(mg·m ⁻³)	SCR_A_NO

用 Pearson 相关系数（pearson correlation coefficient, PCC）^[15] 衡量任意 2 个变量之间的线性相关性(式(1))，式中 \bar{x} 或 \bar{y} 表示变量 x 或 y 的平均值。

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x}) \sum_{i=1}^n (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

1.2 CNN-LSTM 模型构建及评估

在建模之前，对所有输入值进行归一化处理，以消除量纲的影响^[16]，归一化公式为：

$$\hat{x} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2)$$

式中： \hat{x} 为输入变量的归一化值； x 为输入变量的原始值。

预测 SCR 反应器入口 NO 质量浓度的数据集如下，其中式(3)为训练集和式(4)为测试集：

$$\mathbf{X} = \begin{bmatrix} x(1, t_{i-s}) \dots x(n, t_{i-s}) \\ \dots \\ x(1, t_{i-1}) \dots x(n, t_{i-1}) \\ x(1, t_i) \dots x(n, t_i) \end{bmatrix}, Y_{NO}(t_{i+m}) \quad (3)$$

$$\mathbf{X} = \begin{bmatrix} x(1, t_{j-s}) \dots x(n, t_{j-s}) \\ \dots \\ x(1, t_{j-1}) \dots x(n, t_{j-1}) \\ x(1, t_j) \dots x(n, t_j) \end{bmatrix}, Y_{NO}(t_j) \quad (4)$$

式中： \mathbf{X} 为预测模型的输入特征矩阵； \mathbf{Y} 为预测模型的输出矩阵； t_m 理论上提前预测时间， t_s 为回溯时间，即预测模型中采用前 t_s 时间内变量 \mathbf{X} 的关系对 t_{i+m} 时刻 Y_{NO} 的值进行预测。

使用 Python 语言和框架 TensorFlow 的 Keras 库构建了基于 CNN-LSTM 的燃煤电厂 SCR 反应器入口 NO 质量浓度预测模型。CNN 通过卷积提取数据中的空间特征^[17]，获取 NO 质量浓度的周期性变化或突变，LSTM 神经网络可以通过存储的历史信息捕捉 NO 质量浓度的变化趋势，捕捉时间相关性^[18]，模型结构如图 1 所示。




图 1 预测 SCR 反应器入口 NO 质量浓度算法流程

Fig.1 Predictive algorithm process for NO mass concentration at the SCR reactor inlet

预测模型的性能通过回归系数(R squared, R^2)、均方根误差 (root mean squared error, δ_{RMSE}) [19]以及自定义跟随系数 P_{FC} 来评估, 如式(5)~式(7)所示:

$$\delta_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{real} - y_{pre})^2} \quad (5)$$

$$R^2 = \frac{\sum_{i=1}^N (y_{real} - \bar{y}_{real}) \sum_{i=1}^N (y_{pre} - \bar{y}_{pre})}{\sum_{i=1}^N (y_{real} - \bar{y}_{real})^2 \sum_{i=1}^N (y_{pre} - \bar{y}_{pre})^2} \quad (6)$$

$$P_{FC} = \frac{\sum \{\text{sign}(y_{real}[i+1] - y_{real}[i])\} = \text{sign}(y_{pre}[i+1] - y_{pre}[i])\}}{\text{len}(y_{real}) - 1} \quad (7)$$

式中: δ_{RMSE} 用于判断误差大小; R^2 计算相关性, P_{FC} 评估生成趋势是否一致; y_{real} 为时刻 t_{j+m} 的测量值; y_{pre} 为时刻 t_{j+m} 的预测值。

稳定负荷指的是关键变量在一定时间范围内保持相对稳定, 且波动幅度较小的状态。本文研究对象多数时刻处在低负荷或变负荷工况, 根据《电站锅炉性能试验规程》(GB10184—1988) 各运行参数处于稳定时的波动范围[20], 以 200 MW 为标准负荷, 将标准负荷的 $\pm 6\%$ 范围定义为稳定负荷, 其余定义为变负荷工况。

利用 SHAP 算法对 CNN-LSTM 黑箱模型预测结果进行可解释性分析。SHAP 算法核心是计算每个特征变量的 Shapley Value[21], 表征方式有特征重要性 (variable importance, VI) 图、概要图 (Summary plot) 以及部分依赖 (partial dependence plot, PDP) 图[22]。通过 VI 图对影响 NO_x 质量浓度特征变量的相对重要性进行排序。通过 Summary plot 图显示出变量对目标变量值是正向或负向的影响, 横坐标为 SHAP 值, 红色表示高特征值, 蓝色表示低特征值, 一个点离基线 SHAP 值越远, 则对输出的影响就越强[23]。通过 PDP 图理解重要输入变量与输出变量之间依赖关系的本质, 即通过可视化某一或 2 个特征对 SCR 入口 NO 质量浓度的总体影响趋势。

2 结果和讨论

2.1 特征相关性分析及变量筛选

计算 Pearson 相关系数并绘制热力图, 图 2 和图 3 展示了稳定负荷和变负荷数据的相关热力图。热力图中每个单元格代表 2 个变量之间的线性相关

性, 相关性越大颜色越深。输入变量之间相关系数越高 (尤其当 $|r| > 0.7$), 则两者之间存在较强的多重共线性。结果表明, 稳定负荷和变负荷的 SCR 入口 NO 质量浓度的主要相关变量存在差异。稳定负荷下各变量与 NO 的相关性都较低, 约为 0.2; 而变负荷工况下各变量与 NO 的相关性较高, 约为 0.8。此外, 还验证了在变负荷时, 挡板开度与电流、烟气流与机组负荷存在较强的正相关性。




图 2 稳定负荷相关变量热力图
Fig.2 The heatmap of steady load correlation variables




图 3 变负荷相关变量热力图
Fig.3 The heatmap of variable load correlation variables

使用 Pearson 相关系数筛选不同的输入特征变量对模型进行训练: 1) Group1 相关系数大于 0.7 的变量; 2) Group2 相关系数大于 0.4 的变量; 3) Group3 根据经验选取变量。上述各方法选取的

变量如图 4 所示, 结果见表 2。由表 2 得出, 使用 Group2 模型实验组 δ_{RMSE} 比使用 Group1 和 Group3 模型的 δ_{RMSE} 低, R^2 和 P_{FC} 跟随性较高, 则选用 Group2 特征变量进行后续的研究工作。因模型超参数还未进行优化, 各组相关系数偏低。

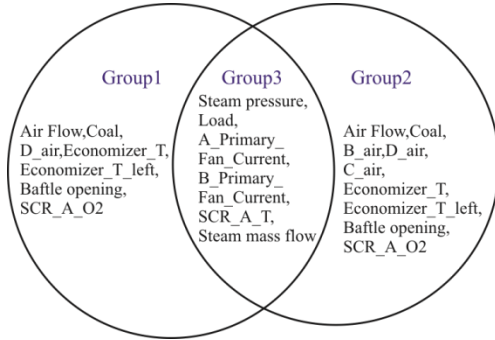


图 4 特征变量分组
Fig.4 Feature variable groups

表 2 3 组特征变量预测结果对比

Tab.2 Comparison of predictive results for three sets of feature variables

项目	Group1 (相关系数>0.7)	Group2 (相关系数>0.4)	Group3 (经验选取)
$\delta_{RMSE}/(\text{mg}\cdot\text{m}^{-3})$	22.65	18.59	30.11
R^2	0.84	0.87	0.79
P_{FC}	0.34	0.50	0.30

2.2 稳定负荷分析

确定工况回溯时间为 60 s, 延迟时间为 90 s, 以 Group2 作为模型输入, 通过随机搜索优化模型的超参数, 结果见表 3。使用优化后的 CNN-LSTM 模型验证其预测性能, 并对稳定负荷和变负荷的工况进行分析。

表 3 CNN-LSTM 模型超参数优化结果

Tab.3 Optimization results of hyper parameters of the CNN-LSTM model

项目	设置
卷积层 Conv	卷积核数量 (filters), 尺寸 (Kernel Size=2), 卷积步长 (Strides=1)
最大池化层 MaxPooling	池化窗口的尺寸 (Pool size=2), 池化层步长 (Strides=1)
LSTM	LSTM 神经元数量 (units), 激活函数 (Activation=relu)
全连接层 Dense	神经元数量 (units=4)
优化器	Adam
学习率	learning_rate=0.001
epoch	100
dropout	0.3
batch_size	512

将测试集定义为 4 个工况进行分析评估。

1) 工况 1, 整个测试集的第 0 至 17 500 组样本序

列; 2) 工况 2, 负荷变化较小 (35% 的数据负荷变化为标准负荷的 $\pm 3\%$, 65% 的数据为标准负荷的 $-20\% \sim +9\%$) 第 0 至 1 300 组样本序列, 用于验证小变化率下 NO_x 的预测精度; 3) 工况 3, 稳定负荷 (标准负荷的 $\pm 3\%$) 第 1 300 至 12 500 组样本序列, 用于测试长期稳定负荷下的准确性; 4) 工况 4, 负荷变化较大 (73% 的数据负荷变化为标准负荷的 $+21\% \sim +78\%$) 第 12 500 至 17 500 组样本序列, 用于验证瞬态较大负荷变化下的精确度, 具体结果如图 5 和图 6 所示。




图 5 预测值与测量值对比

Fig.5 Comparison between the predicted values and the actual values




图 6 负荷变化与预测误差的关系

Fig.6 Relationship between load variations and prediction errors

表 4 为工况对比预测结果。从表 4 预测结果可知, 在稳定负荷 (工况 3) 下模型的 δ_{RMSE} 较低为 $5.410 \text{ mg}/\text{m}^3$, 且预测精度 R^2 较高为 0.95, 说明模型表现出良好的预测能力。预测误差在变负荷时 (工况 2 和工况 4) 的精度比稳定负荷工况 (工况 3) 下低, 工况 2 波峰预测值和测量值对比如图 7 所示。工况 2 波峰负荷变化较小时 NO 的预测值能够提前变化, 在工况 4 负荷变化增大时, 预测偏差增大。

表 4 工况对比预测结果

Tab.4 The prediction results under different operating conditions

项目	工况 1	工况 2	工况 3	工况 4
$\delta_{RMSE}/(\text{mg}\cdot\text{m}^{-3})$	15.880	20.544	5.410	30.250
R^2	0.90	0.87	0.95	0.75
P_{FC}	0.56	0.9	0.83	0.41




图 7 工况 2 波峰预测值和测量值对比

Fig.7 Comparison between the predicted values and actual values for peaks under operating condition 2

2.3 变负荷分析

在工况 4 中, 负荷变化较大, 相关系数 R^2 下降至 0.75, 表明需对变负荷数据进行进一步训练, 以提高预测的准确性。通过设定修正比例, 对测量值和预测值进行修正, 设修正参数 $\phi[0,1]$, $c_{in,NO}$ 修正后的 NO 质量浓度, $c_{t,in,measure}$ 为时刻 t 的 NO 质量浓度的测量值, $c_{t+t_m,in,pre}$ 为时刻 $t+t_m$ 的 NO 质量浓度的预测值, 修正过程为式(8)。修正后的工况 5 如图 8 所示, 相关系数 R^2 提高至 0.95, 高于未修正前工况 1 的 R^2 。设 2 组数据之间的延迟时间 t_m 为 5~40 s, 每间隔 5 s 依次计算二者的相关系数, 当 $t_m=25$ s 时相关系数最高为 0.97, 此时 2 条曲线最重合, 则平均提前时间为 25 s。变负荷数据修正后如图 9 所示, 图 9 中修正后的值能够比同一时刻测量值最大提前时间为 125 s。

$$\phi = 0.7$$

$$c_{in,NO} = \phi c_{t,in,measure} + (1 - \phi) c_{t+t_m,in,pre} \quad (8)$$




图 8 修正后工况 5 变化

Fig.8 The variation of operating condition 5 after modification




图 9 变负荷数据修正后

Fig.9 The load variation data after correction

选取现阶段全部样本的变工况 (工况 6) 数据 (图 10) 进行分析, 预测结果见表 5。由表 5 可见, 工况 6 的相关系数 R^2 为 0.82, 比负荷变化较大的工况 4 精度高。




图 10 变负荷数据

Fig.10 The variable load data

表 5 变负荷对比预测结果

Tab.5 The comparison of predicted results for variable operating load

项目	工况 6	工况 4	工况 5
$\delta_{RMSE}/(mg \cdot m^{-3})$	18.12	30.25	10.52
R^2	0.82	0.75	0.95
P_{FC}	0.51	0.41	0.65

2.4 后解释模型分析

利用 SHAP 算法对 CNN-LSTM 预测模型进行后解释分析^[24]。通过分析平稳和负荷变化较大 2 种负荷情景下 NO 生成的驱动因素, 从历史数据中选取工况 3 进行分析 (图 11、图 12)。图 11 所示的稳定负荷 VI 图中, 影响 SCR 反应器入口 NO 质量浓度较大的变量是 SCR 反应器上游的烟气温度 (如入口温度和省煤器入口温度) 以及 B 磨入口风量。图 12 所示的稳态概要图中, SCR 反应器入口温度、B 磨入口风量、二次风挡板开度、A 一次风机电流

以及蒸汽压力与 NO 质量浓度呈正相关，而省煤器入口烟气温、机组负荷、总风量、B 一次风机电流、蒸汽流量以及 SCR 反应器入口压力呈负相关。SCR 入口 O₂ 体积分数也是影响 NO 质量浓度的重要参数，其特征值较高时，SHAP 值能达到最高或最低，表明 O₂ 体积分数对 NO_x 的生成起到双向作用，与炉内分级燃烧状况密切相关。

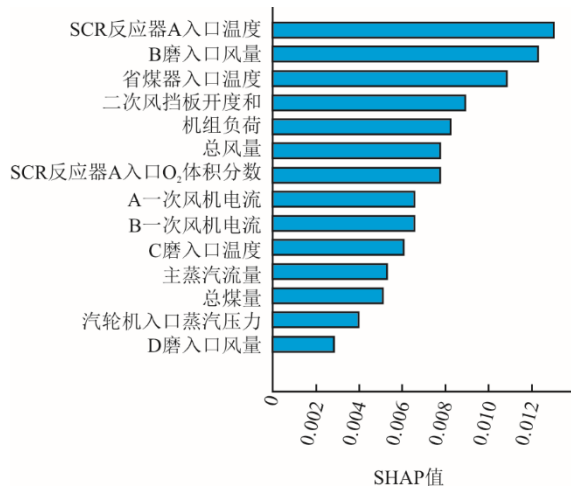


图 11 稳定负荷特征 VI 图
Fig.11 The steady load feature importance plot




图 12 稳定负荷概要
Fig.12 The steady load of summary plot

选取工况 6 负荷变化较大数据进行分析（图 13）。从图 13 变负荷概要图可看出，影响 NO 质量浓度的变量主要有机组负荷、D 磨入口风量、主蒸汽流量以及省煤器入口温度等。但各变量与目标变量 NO 质量浓度均存在正向或负向的相关关系，但并无单向关系。

对于稳定负荷工况各个变量之间的关系，代表性结果如图 14 所示。由图 14 可知：当二次风挡板开度小于 33% 时，总风量较小且对 NO 质量浓度是正向作

用；随着挡板开度增大总风量随之增大，对 NO 生成存在双向的影响，主要分布在负相关方向，表明了在高负荷工况下，炉内空气分级燃烧作用明显，增大二次风挡板开度，有利于降低 NO 质量浓度。

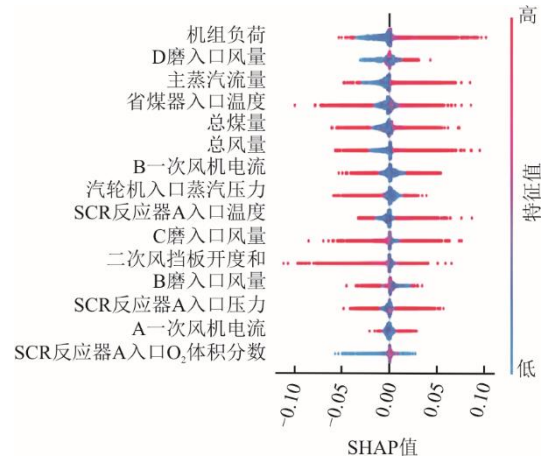


图 13 变负荷概要
Fig.13 The variable load-state of summary plot




图 14 二次风挡板开度和总风量共同影响
Fig.14 The combined effect of the baffle opening of the secondary air damper and total airflow

变负荷时 NO 质量浓度被 SCR 反应器入口 A 温度和总风量共同影响下，NO 质量浓度的结果如图 15 所示。

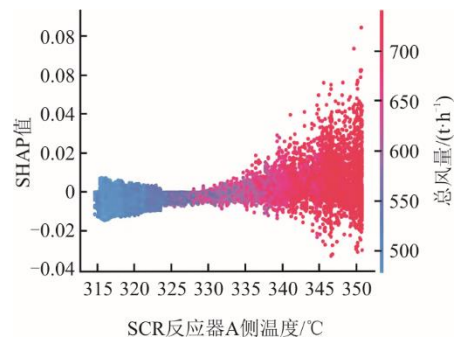


图 15 SCR 反应器入口 A 温度和总风量共同影响
Fig.15 The combined effect of temperature at the SCR reactor inlet A and total airflow

由图 15 可知：在变负荷时当 SCR 反应器入口 A 温度小于 330 °C 时，总风量较小且对 NO 质量浓

度主要是负向作用,说明在较低负荷时,增大负荷可降低NO的生成;当SCR反应器入口A温度升高时增大总风量,对NO的生成逐渐为正向影响。高负荷运行时,增大负荷且增加总风量,将会影响炉内的分级燃烧,增加NO的生成。

3 Simulink 仿真性能评估

在建立SCR反应器入口NO_x质量浓度预测模型的基础上,设计并改进了SCR反应器脱硝智能预测前馈控制系统。主PID控制器对喷氨量进行调节,副PID控制器驱动喷氨阀门开度,控制逻辑框图如图16所示。将前期预测时刻 $t+t_m$ 的SCR反应器入口

NO_x质量浓度修正值作为前馈信号,固定出口NO_x质量浓度为40 mg/m³,补偿氨氮比。

实现SCR脱硝智能预测前馈控制系统的控制逻辑如下:1)利用SCR反应器入口NO质量浓度修正值与SCR反应器出口NO的设定值计算理论脱硝量;2)利用SCR反应器出口NO质量浓度测量值与SCR反应器出口NO质量浓度的设定值计算补偿脱硝量;3)根据理论脱硝量和补偿脱硝量计算氨气设定值;4)利用喷氨格栅喷出的氨气测量值与氨气设定值计算氨气补偿量;5)利用氨氮比乘以0.9516计算得到最大脱硝率;6)根据脱硝率的补数计算SCR反应器出口NO质量浓度。

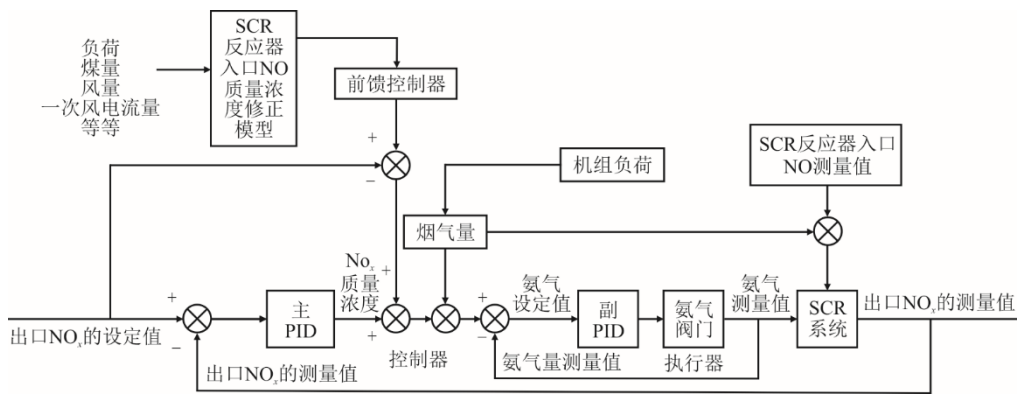


图 16 SCR 脱硝智能预测前馈控制策略框图

Fig.16 Framework of the intelligent predictive feedforward control strategy for SCR denitrification

当外部负荷发生变化时,SCR喷氨控制系统能够提前 t_m 动作,使喷氨量与烟气中的NO_x量相匹配,从而减少系统调节时间。选用500s运行数据,包括负荷变化情况,采用以上控制逻辑,仿真有无前馈控制的NH₃/NO结果如图17所示。由图17可知,当机组负荷变化时,有智能预测前馈控制方法的NH₃/NO先响应。负荷降低可能造成燃烧不完全,NO质量浓度增大,NH₃量增多,则NH₃/NO比值增大。




图 17 变负荷时有无前馈控制 NH₃/NO 结果

Fig.17 The results of NH₃/NO with and without feedforward control during load variation

仿真有无前馈控制的SCR脱硝出口NO_x波动情况对比输出结果如图18和表6所示。由图18和表6可知,有预测前馈控制可有效降低SCR系统出口NO_x质量浓度,波动范围在0.2 mg/m³左右,标准差降低28%。标准差计算公式为:

$$S_x = \sqrt{\frac{\sum (x_i - \bar{x})^2}{n - 1}} \tag{9}$$

式中: S_x 为标准差; \bar{x} 为样本序列平均值; n 为样本序列个数。





图 18 出口NO_x质量浓度仿真结果对比

Fig.18 The simulated NO_x mass concentrations at the outlet

表 6 有无前馈控制优化指标
Tab.6 Optimization indexes with and without feedforward

	无前馈控制	有前馈控制
SCR 反应器出口 NO _x 质量浓度平均值/(mg·m ⁻³)	40.004 1	40.002 3
SCR 反应器出口 NO _x 质量浓度标准差/(mg·m ⁻³)	0.145 7	0.104 0
SCR 反应器出口 NO _x 质量浓度波动/(mg·m ⁻³)	0.3	0.2
平均氨逃逸量/(μL·L ⁻¹)	2.13	1.65

实际 SCR 脱硝反应中 NH₃ 与 NO_x 进行脱硝反应比值近似为 1:1。根据脱硝率计算 SCR 反应器出口氨逃逸并进行折算, 具体如式(10)—式(13)所示^[25]:



$$\eta = \frac{c_{\text{in},\text{NO}_x} - c_{\text{out},\text{NO}_x}}{c_{\text{in},\text{NO}_x}} \quad (11)$$

$$c_{\text{NH}_3} = c_{\text{i},\text{NH}_3} - \eta c_{\text{i},\text{NO}_x} = c_{\text{i},\text{NO}_x} (r - \eta) \quad (12)$$

$$p_{\text{NH}_3} = \frac{c_{\text{NH}_3}}{17} \times 10^6 \quad (13)$$

式中: c_{NH_3} 为 c_{NH_3} 氨逃逸质量浓度; r 为氨氮比; η 为脱硝效率; c_{i,NO_x} 为 SCR 反应器入口 NO_x 质量浓度; $c_{\text{out},\text{NO}_x}$ 为出口 NO_x 的质量浓度; c_{i,NH_3} 为 SCR 反应器入口实际 NH₃ 质量浓度; p_{NH_3} 为基于标况下 (298 K 和 101 kPa) 的氨气密度, 将氨气质量浓度折算后的值。

计算氨逃逸结果如图 19 所示。由图 19 可知, 有前馈控制比无前馈控制降低了氨逃逸, 无前馈控制时氨逃逸量最大为 2.13 μL/L, 有前馈控制时氨逃逸量为 1.65 μL/L, 则有前馈控制降低最大氨逃逸 22%。




图 19 出口氨逃逸仿真结果对比
Fig.19 The simulated ammonia slip at the outlet

4 结 论

本文针对 NO_x 质量浓度测量滞后问题, 提出了

一种 CNN-LSTM 数据驱动模型, 用于预测机组全工况运行时的 NO_x 生成质量浓度, 并应用于某电厂 330 MW 四角切圆锅炉的 NO_x 排放预测, 主要结论包括如下。

1) 通过热力图相关性分析, 发现稳定工况和变负荷时, 影响 SCR 反应器入口 NO 质量浓度生成的主要变量存在显著差异。

2) 将 SCR 反应器入口 NO 质量浓度预测值与测量值设置一定的比例 7:3 修正 SCR 反应器入口 NO 质量浓度, 通过 Simulink 仿真评估, 修正后的 SCR 反应器入口 NO 质量浓度能够提前 25 s 调节喷氨量。优化后的喷氨控制策略降低出口 NO_x 质量浓度与设定值间的标准差 (降低 28%), 并提升了 NH₃/NO_x 调节的响应速度, 减少最大氨逃逸量 22%, 实现了变负荷下的 NO_x 的排放控制。

3) 利用 SHAP 算法对 CNN-LSTM 模型进行分析, 确定了各变量对 SCR 反应器入口 NO 质量浓度的正向或负向影响, 在变负荷时影响 SCR 反应器入口 NO 质量浓度最大的变量是机组负荷和 D 磨入口风量, 反映了不同负荷下炉内分级燃烧的深度存在差异。

[参 考 文 献]

- [1] 中华人民共和国 2021 年国民经济和社会发展统计公报[J]. 中国统计, 2022(3): 9-26.
Statistical Communiqué of the People's Republic of China on the 2021 National Economic and Social Development[J]. China Statistics, 2022(3): 9-26.
- [2] 薛禹胜, 雷兴, 薛峰, 等. 关于风电不确定性对电力系统影响的评述[J]. 中国电机工程学报, 2014, 34(29): 5029-5040.
XUE Yusheng, LEI Xing, XUE Feng, et al. A review on impacts of wind power uncertainties on power systems[J]. Proceedings of the CSEE, 2014, 34(29): 5029-5040.
- [3] 闫来清, 董泽. 基于 k -近邻互信息和 WKOPLS 的 SCR 脱硝系统动态预测模型[J]. 中国电机工程学报, 2019, 39(10): 2970-2980.
YAN Laiqing, DONG Ze. Dynamic prediction model of SCR denitrification system based on k -nearest neighbor mutual information and WKOPLS[J]. Proceedings of the CSEE, 2019, 39(10): 2970-2980.
- [4] 翁卫国, 刘博文, 郭一杉, 等. 基于入口 NO_x 浓度软测量的脱硝系统先进控制研究[J]. 锅炉制造, 2019(5): 17-22.
WENG Weiguo, LIU Bowen, GUO Yishan, et al. Model predictive control utilizing gas soft-sensors on SCR denitrification system in thermoelectric unit[J]. Boiler Manufacturing, 2019(5): 17-22.
- [5] 张晓雯. 燃煤机组 SCR 脱硝系统建模与优化控制研究[D]. 南京: 东南大学, 2021: 1.
ZHANG Xiaowen. Modeling and optimal control of SCR denitrification system for coal-fired units[D]. Nanjing: Southeast University, 2021: 1.

- [6] YANG T, MA K, LV Y, et al. Real-time dynamic prediction model of NO_x emission of coal-fired boilers under variable load conditions[J]. Fuel, 2020, 274: 117811.
- [7] TAN P, HE B, ZHANG C, et al. Dynamic modeling of NO_x emission in a 660 MW coal-fired boiler with long short-term memory[J]. Energy, 2019, 176: 429-436.
- [8] 王桂林, 张宇, 王森, 等. 基于支持向量机的选择性催化还原脱硝系统运行优化[J]. 环境工程学报, 2015, 9(10): 5011-5016.
WANG Guilin, ZHANG Yu, WANG Sen, et al. Operation optimization of selective catalytic reduction system based on support vector machine[J]. Chinese Journal of Environmental Engineering, 2015, 9(10): 5011-5016.
- [9] 廖永进, 范军辉, 杨维结, 等. 基于 RBF 神经网络的 SCR 脱硝系统喷氨优化[J]. 动力工程学报, 2017, 37(11): 931-937.
LIAO Yongjin, FAN Junhui, YANG Weijie, et al. Ammonia spraying optimization of an SCR denitrification system based on RBF neural network[J]. Journal of Power Engineering, 2017, 37(11): 931-937.
- [10] 唐振浩, 柴向颖, 曹生现, 等. 考虑时延特征的燃煤锅炉 NO_x 排放深度学习建模[J]. 中国电机工程学报, 2020, 40(20): 6633-6644.
TANG Zhenhao, CHAI Xiangying, CAO Shengxian, et al. Deep learning modeling for the NO_x emissions of coal-fired boiler considering time-delay characteristics [J]. Proceedings of the CSEE, 2020, 40(20): 6633-6644.
- [11] 王英男. 燃煤锅炉的 NO_x 排放预测与控制研究[D]. 北京: 华北电力大学, 2021: 1.
WANG Yingnan. Research on NO_x emission prediction and control of coal-fired boiler[D]. Beijing: North China Electric Power University, 2021: 1.
- [12] QIAO J. A novel online modeling for NO_x generation prediction in coal-fired boiler[J]. Science of the Total Environment, 2022, 847: 157542.
- [13] YUAN Z, MENG L, GU X, et al. Prediction of NO_x emissions for coal-fired power plants with stacked-Generalization Ensemble Method[J]. Fuel, 2021, 289: 119748.
- [14] 姚强, 李水清, 王宇. 燃烧学导论[M]. 北京: 清华大学出版社, 2009: 1.
YAO Qiang, LI Shuiqing, WANG Yu, et al. An introduction to combustion concepts and applications[M]. Beijing: Tsinghua University Press, 2009: 1.
- [15] 刘菡, 王英男, 李新利, 等. 基于互信息-图卷积神经网络的燃煤电站 NO_x 排放预测[J]. 中国电机工程学报, 2022, 42(3): 1052-1060.
LIU Han, WANG Yingnan, LI Xinli, et al. Prediction of NO_x emission in coal-fired power plants based on mutual information-graph convolutional neural network[J]. Proceeding of the CSEE, 2022, 42(3): 1052-1060.
- [16] 吕玉坤, 彭鑫, 赵锴. 电站锅炉热效率和 NO_x 排放混合建模与优化[J]. 中国电机工程学报, 2011, 31(26): 16-22.
LYU Yukun, PENG Xin, ZHAO Kai. Hybrid modeling optimization of thermal efficiency and NO_x emission of utility boiler[J]. Proceedings of the CSEE, 2011, 31(26): 16-22.
- [17] LI N, HU Y. The deep convolutional neural network for NO_x emission prediction of a coal-fired boiler[J]. IEEE Access, 2020, 8: 85912-85922.
- [18] GUO Y, MAO Z. Long-term prediction model for NO_x emission based on LSTM-transformer[J]. Electronics, 2023, 12(18): 3929.
- [19] 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.
- [20] 电站锅炉性能试验规程: GB/T 10184—1988[S]. 北京: 中国标准出版社, 1988: 1.
Procedures for performance testing of power station boilers: GB/T 10184—1988[S]. Beijing: Standards Press of China, 1988: 1.
- [21] 朱明超. 可解释的机器学习[M]. 北京: 电子工业出版社, 2021: 1.
ZHU Mingchao. Interpretable machine learning[M]. Beijing: Electronic Industry Press, 2021: 1.
- [22] ZHU X, LI Y, WANG X. Machine learning prediction of biochar yield and carbon contents in biochar based on biomass characteristics and pyrolysis conditions[J]. Bioresource Technology, 2019, 288: 121527.
- [23] ASCHER S, WANG X, WATSON I, et al. Interpretable machine learning to model biomass and waste gasification[J]. Bioresource Technology, 2022, 364: 128062.
- [24] 杨昌兰. 基于深度学习及 SHAP 解释的城市空间扩展识别与驱动分析[D]. 武汉: 武汉大学, 2022: 1.
YANG Changlan. Identification and driving analysis of urban spatial expansion through intergrating deep learning models and SHapley additive explanations[D]. Wuhan: Wuhan University, 2022: 1.
- [25] 董建勋, 李永华, 冯兆兴, 等. 选择性催化还原烟气脱硝反应器的变工况运行分析[J]. 动力工程, 2008(1): 142-146.
DONG Jianxun, LI Yonghua, FENG Zhaoxing, et al. Operation analysis of flue gas denitrification reactors with selective catalytic reduction under variable working conditions[J]. Power Engineering, 2008(1): 142-146.

(责任编辑 邓玲惠)