文章编号:1001-2060(2025)04-0132-11

基于 TCN-BiGRU-Attention 与残差修正的 SCR 入口 NO_x 质量浓度预测

鲁润旭,茅大钧

(上海电力大学 自动化工程学院,上海 200090)

摘 要:为解决燃煤电厂对选择性催化还原烟气脱硝系统(Selective Catalytic Reduction, SCR)入口 NO_x 质量浓度的 测量延迟较大且准确度低的问题,针对某在役 600 MW 超临界机组,提出基于互信息系数的动态延迟时间分析法, 分析输入特征对 NO_x 质量浓度的延迟影响;在此基础上,提出基于时序卷积网络与双向门控循环单元融合注意力 机制(TCN-BiGRU-Attention)的燃煤电厂 SCR 入口 NO_x 质量浓度的预测方法,并引入残差修正提高模型预测效果。 实验结果表明:动态延迟分析法能够捕捉输入特征的最优时序映射关系,提升模型的预测效果;与传统 LSTM 和 TCN-GRU 等模型对比,预测方法在预测精度和鲁棒性方面具有显著优势;考虑输入特征对预测结果的延迟影响并 提出 TCN-BiGRU-Attention 与残差修正的预测方法,能够实现对 SCR 入口 NO_x 质量浓度的准确预测,为脱硝提供 有效技术指导。

关键 词:SCR 脱硝系统;动态延迟时间;TCN;双向门控循环单元;注意力机制;残差修正

中图分类号:TK221 文献标识码:A DOI:10.16146/j. cnki. rndlgc. 2025.04.015

[引用本文格式] 鲁润旭, 茅大钧. 基于 TCN-BiGRU-Attention 与残差修正的 SCR 入口 NO_x 质量浓度预测[J]. 热能动力工程, 2025, 40(4):132-142. LU Runxu, MAO Dajun. Prediction of SCR inlet NO_x mass concentration based on TCN-BiGRU-Attention with residual correction[J]. Journal of Engineering for Thermal Energy and Power, 2025, 40(4):132-142.

Prediction of SCR Inlet NO_x Mass Concentration based on TCN-BiGRU-Attention with Residual Correction

LU Runxu, MAO Dajun

(College of Automation Engineering, Shanghai University of Electric Power, Shanghai, China, Post Code: 200090)

Abstract: To solve the problem of large delay and low accuracy in measurement of NO_x mass concentration at the inlet of selective catalytic reduction (SCR) flue gas denitrification system in coal-fired power plants, based on an in-service 600 MW supercritical unit, a dynamic delay time analysis method based on mutual information coefficients was proposed to analyze the delay effect of input features on NO_x mass concentration; then, a prediction method for NO_x mass concentration at the inlet of SCR in coal-fired power plants was proposed based on the fusion of time-sequence convolutional network and bi-directionally gated recurrent unit attention mechanism (TCN-BiGRU-Attention), and the residual correction was introduced to improve the model prediction effect. The experimental results show that the proposed dynamic delay analysis method is able to capture the optimal temporal mapping relationship of the input features and improve the prediction effect of the model. The proposed prediction method has significant advantages in terms of prediction accuracy and robustness compared with traditional models such as LSTM and TCN-

Fund-supported Project Science and Technology Projects of China Huaneng Group Co., Ltd. in 2022 (HNKJ22-HF22)

收稿日期:2024-09-30; 修订日期:2024-11-26

基金项目:中国华能集团有限公司 2022 年度科技项目(HNKJ22-HF22)

作者简介:鲁润旭(2001 –),男,上海电力大学硕士研究生.

通信作者:茅大钧(1966-),男,上海电力大学教授.

GRU. The proposed prediction method of TCN-BiGRU-Attention with residual correction with considering the delayed effect of input features on the prediction results can realize accurate prediction of NO_x mass concentration at the SCR inlet and provide effective technology guidance for denitrification.

Key words: SCR denitrification system, dynamic delay time, TCN, bi-directionally gated recurrent unit (BiGRU), attention mechanism, residual correction

引 言

近年来,随着"双碳"目标的不断推进,控制氮 氧化物的排放量是燃煤电厂的重要任务之一^[1]。 我国燃煤电厂普遍采用选择性催化还原技术对烟气 进行脱硝^[2],然而由于锅炉燃烧过程十分复杂,从 调整燃烧到 NO_x 的质量浓度发生变化,这一过程具 有较大的滞后性。同时大部分电厂使用的连续排放 监测系统(Continuous Emission Monitoring System, CEMS)无法实时准确地测量 SCR 入口处 NO_x 质量 浓度,导致不能准确控制喷氨量,从而造成氨逃逸或 排放不达标等问题^[3],因此建立准确高效的 SCR 入 口处 NO_x 质量浓度预测模型具有重要意义。

近些年,国内外采用数值模拟和工程设计等方 法对 SCR 系统进行研究^[4-8],但是影响 SCR 系统的 因素繁多且复杂,同时 SCR 系统与锅炉有着高度耦 合关系,而锅炉是一个多参数、非线性且具有大滞后 和大惯性的系统,难以用明确的数学模型准确描述 这一关联。

随着电站信息化与智能化的快速发展和深度学 习算法的逐渐成熟,通过深度学习建立模型并预测 的方法已成为新的研究方向^[9-15]。王桂林等人^[16] 基于支持向量机建立了脱硝系统入口 NO_x 质量浓 度和脱硝效率的预测模型,并通过遗传算法对喷氨 量进行优化。吕游等人^[17]结合偏最小二乘法和最 小二乘支持向量机,建立 NO_x 排放特性模型,该模 型泛化能力比传统模型更好。金秀章等人^[18]提出 基于 ARIMA-OSELM 残差优化的组合模型来预测 SCR 入口 NO_x 质量浓度,与单一模型相比,该组合 模型效果更优。

针对燃煤电站锅炉热工过程的大滞后、大惯性 等特点,本文采用互信息系数对所用数据进行动态 延迟时间分析,得到最佳延迟时间,并重构数据集。 由于 SCR 系统入口的 NO_x 质量浓度受锅炉燃烧、烟 气流动等多因素的动态影响,这些影响的本质是时序 依赖性和复杂的非线性关系,为此本文建立一种结合 时序卷积网络 TCN、双向门控循环单元 BiGRU 和注 意力机制 Attention 的深度学习模型。其中利用 TCN 时序卷积网络保留时间序列因果关系的能力,处理 NO_x 质量浓度随时间变化的动态特征; BiGRU则能 捕捉输入特征中双向的时间依赖性,适合于像 SCR 系统这种多参数耦合的动态过程,同时融合注意力 机制,提高模型对延迟时间分析后的输入特征的学 习。基于提出的 TCN-BiGRU-Attention 模型进行建 模及训练,为进一步提高模型对非线性关系的预测 能力,引入基于支持向量机的残差修正模型,将验证 集的误差与验证集的特征输入支持向量机进行建 模,并对测试集进行残差预测与补偿,最终将主模型 的预测结果与残差预测值相加,得到最终模型的 SCR 入口 NO_x 质量浓度预测结果。

1 模型理论基础

1.1 互信息系数 MI

互信息系数 MI 是一种基于信息熵理论的数据 统计方法,用于度量两个随机变量之间的相互依赖 性。互信息系数 MI 量化了一个变量所包含的关于 另一个变量的信息量,即知道一个变量后,能减少另 一个变量的不确定性有多少。该方法通过计算变量 间的概率分布来确定变量间的信息包含程度。MI 的计算公式为:

$$I(x,y) = \sum_{x \in X} \sum_{y \in Y} p(x,y) \log\left(\frac{p(x,y)}{p(x)p(y)}\right) \quad (1)$$

式中:I(x,y)—变量x 和y之间的互信息值;p(x)、 p(y)—边缘概率分布;p(x,y)—联合概率分布; X、Y—变量x 和y的数据集。

为解决锅炉燃烧特性中的大延迟和大惯性问题,需要量化不同特征对 SCR 入口 NO_x 质量浓度的时间滞后效应。滞后效应直接反映锅炉的燃烧特

性,如煤质、负荷和烟气温度等与 NO_x 生成的耦合 关系,本文利用基于互信息系数的动态延迟时间分 析,使模型能够捕捉输入特征的最优时序映射关系。

1.2 时序卷积网络 TCN

时序卷积网络是一种用于处理时序数据的卷积 神经网络,是卷积神经网络(Convolutional Neural Network,CNN)的一种特殊类型,其特点是加入了因 果卷积和扩张卷积。在因果卷积中,卷积核在计算 时只涉及当前和之前的输入数据x_i,确保输出序列 中的每个元素y_i不依赖于未来的输入,保持了数据 的时间顺序;扩张卷积则通过在卷积核之间引入扩 张因子,增加了卷积核的感受野,使 TCN 能够捕捉 更长时间跨度的依赖关系,扩张因果卷积结构如图 1 所示。



图1 扩张因果卷积结构

Fig. 1 Dilated causal convolutions structure

扩张因果卷积运算可定义为:

$$F(x_{t}) = (x \times f)(x_{t}) = \sum_{i=0}^{k-1} f_{i} \cdot x_{t-d \cdot i}$$
(2)

式中: $F(x_i)$ —TCN 神经元的输出; x_i —时间序列数据;f—筛选器;k—卷积核大小;d—扩张因子。

为了解决深层网络带来的梯度消失问题,TCN 模型采用多个残差模块,在各残差块中,输入数据经 过扩张因果卷积和激活函数后,被送到下一个残差 块,使 TCN 网络拥有跨层传递信息的功能,并加快 收敛速度。残差模块结构如图 2 所示。

SCR 入口 NO_x 质量浓度的动态变化受锅炉燃 烧过程和烟气特性的影响,而这些因素可能存在长 时间跨度的依赖关系,NO_x 质量浓度与锅炉负荷、 煤质变化的关联需要捕捉数分钟甚至更长时间的特征变化。通过TCN的扩张卷积,可以在有限的网络深度下扩大感受野,捕捉输入特征随时间变化的长期依赖关系,同时残差结构避免了处理深层网络时梯度消失的问题,使模型训练过程更加稳定。



图 2 残差模块结构 Fig. 2 Structure of residual module

1.3 双向门控循环单元 BiGRU

长短时记忆网络(Long Short Term Memory Network, LSTM)引入了遗忘门、输入门、输出门以及细 胞状态来解决循环神经网络(Recurrent Neural Network, RNN)存在的梯度消失或梯度爆炸的问题, 但LSTM 的训练时间较长、参数数量较多且内部计 算较为复杂,导致LSTM 在某些应用场景中对模型 的效率和性能产生负面影响。为克服这些缺点,门 控循环单元 GRU 通过将LSTM 中的遗忘门和输入 门合并为一个更新门,同时合并细胞状态与隐藏状 态,简化了网络的结构和计算复杂度。

双向门控循环网络 BiGRU 是 GRU 的进一步改进,由两个方向相反的 GRU 网络组成,分别处理输入序列的正向与反向信息。在每一个时间步上,输入数据同时经过两个相反方向的 GRU 处理,最终的输出通过拼接或加权的方式与这两个单向 GRU 的输出结合。BiGRU 能够更全面地捕捉序列数据中的前后关系,BiGRU 网络结构如图 3 所示。





相比于单向 GRU 模型, BiGRU 模型的双向处 理方式具有更高的预测准确率。BiGRU 的具体计 算公式如下:

$$\begin{cases} \vec{h}_{i} = \text{GRU}(x, \vec{h}_{i-1}) \\ \vec{h}_{i} = \text{GRU}(x, \vec{h}_{i-1}) \\ h_{i} = w_{i}\vec{h}_{i} + v_{i}\vec{h}_{i} + b_{i} \end{cases}$$
(3)

式中: \vec{h}_i 、 \vec{h}_i —前向和反向输出; w_i —前向传播权重; v_i —反向传播权重; b_i —偏置项。

锅炉燃烧系统具有多参数耦合特性,NO_x 质量 浓度的时序变化需要依赖双向建模。BiGRU 能够 捕捉锅炉燃烧过程中各特征的动态变化及相互作 用,获得更高的预测精度。

1.4 注意力机制 Attention

注意力机制是一种通过加权概率模拟人脑注意 力的机制。与人类在观察事物时会专注于特定的部 分而忽略其他部分一样,注意力机制通过强调更重 要的信息,提高模型的准确性。为实现该行为,注意 力机制通过为输入特征计算"得分"来确定该特征 对当前任务的重要性。例如,将输入元素x_i与查询 向量 q 通过计算相关性得分s_i来量化在当前任务中 的重要性。

$$s_i = \boldsymbol{q}^{\mathrm{T}} \boldsymbol{x}_i \tag{4}$$

通过 softmax 函数将得分 s_i 进行归一化,得到注意力权重 α_i 。

$$\alpha_i = \operatorname{sofmax}(s_i) \tag{5}$$

通过将得分转化为权重,使所有权重的总和等于1,从而表示每个输入元素的相对重要性,最终通

过加权求和得到输出的注意力值 V。

$$V = \sum_{i=1}^{N} \alpha_i x_i \tag{6}$$

注意力机构结构如图4所示。



图4 注意力机制结构图

Fig. 4 Structure diagram of attention mechanism

与传统固定权重的模型不同,注意力机制能够 根据输入特征的变化动态调整特征的权重,适应锅 炉运行工况的波动。同时,引入注意力机制可突出 延迟分析后的输入特征对 NO_x 质量浓度的影响,提 升模型对关键因果关系的建模能力。

1.5 支持向量机回归

支持向量机(Support Vector Machines, SVM)算 法适合于小样本问题的分类与回归,在分析回归问 题时,样本数据过大,采用 SVM 求解会变得非常复 杂且耗时。因此通过引入支持向量机回归(SVR), 利用核函数将输入数据映射到高维特征空间,在该 空间内将问题转化为求解线性方程组,实现对复杂 数据的回归预测。支持向量机回归表达式为:

 $f(x) = \boldsymbol{\omega}\varphi(x) + b$ (7) 式中:f(x)—输入为 x 时的预测值; $\boldsymbol{\omega}$ —权重向量; $\varphi(x)$ —非线性映射函数;b—偏置。

利用松弛变量和惩罚因子,得到有约束的最优 问题:

$$\begin{cases} \min_{\boldsymbol{\omega},\boldsymbol{b}} \frac{1}{2} \| \boldsymbol{\omega} \|^2 + C \sum_{i=1}^{N} (\xi_i + \xi_i^*) \\ \\ \text{s. t.} \begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_i) \geq \varepsilon + \xi_i^* \\ \\ \xi_i, \xi_i^* \geq 0 \end{cases} \end{cases}$$
(8)

式中:C—惩罚参数; ξ_i 、 ξ_i^* —松弛变量; ε —不敏感 损失因子; y_i —实际值; $f(x_i)$ —输入为 x_i 时的预 测值。

采用拉格朗日乘法算子和对偶原理,并引入核函数 *K*(*x_i*,*x_i*),最终 SVR 表达式为:

$$f(x) = \sum_{i=1}^{N} (\alpha_i - \alpha_i^*) K(x_i, x_j) + b$$
 (9)

式中: α_i —*i*时刻正向最优拉格朗日乘子; a_i^* —*i*时刻反向最优拉格朗日乘子。

针对机器学习模型因过拟合或欠拟合情况所 造成的误差以及对训练情况之外的复杂情况的学 习不充分导致预测模型稳定性与鲁棒性不足的问 题,本文采用支持向量回归 SVR 模型,对主预测模 型进行残差修正,提高模型的预测精度。为避免残 差模型训练时造成数据泄露问题,严格划分训练 集、验证集与测试集,并采用验证集对 SVR 模型进 行训练。

SVR 可通过核函数处理非线性关系,从而捕捉 到主模型残差中的非线性特征。支持向量机通过控 制模型复杂度和误差来优化泛化性能,并采用不敏 感损失函数,使模型对低噪声具有鲁棒性,不会受到 过多的影响。因此,SVR 在残差修正中能够帮助过 滤掉由数据噪声引起的误差,非常适用于弥补主模 型的不足。

2 实例验证

2.1 数据预处理

选用某在役 600 MW 超临界机组在 2022 年 12 月 13 日~2022 年 12 月 17 日的实际运行数据共 10 000 组,采样周期为 30 s。对其中前 6 000 组数据 进行训练,2 000 组数据进行验证,2 000 组数据进行 测试。由于受温度、湿度及设备故障或干扰等影响, 从分散控制系统(Distributed Control System, DCS)中 采集的数据存在明显的异常值及缺失值,影响模型 的训练,因此需先将数据进行预处理,采用 3σ 准则 确定异常值,并用异常值前 5 个值的均值进行替换, 对数据进行归一化处理。

2.2 特征相关性分析及变量筛选

对于燃煤电厂来说,锅炉燃烧与 SCR 系统的大量参数相互关联,同时电厂 DCS 系统的实际数据中含有大量潜在的特征变量,SCR 入口 NO_x 质量浓度受许多参数的影响。然而引入冗余的数据特征会降低模型的预测精度并减少训练时间,导致网络模型

的泛化能力下降,因此需要进行特征相关性分析,并 剔除对目标量影响较小的特征。

常见的相关性分析方法有皮尔逊相关系数法、 斯皮尔曼相关系数法和肯德尔相关系数法等。皮尔 逊相关系数法通常应用于两个特征线性相关的情况,对于异常值和非正态分布的特征非常敏感;肯德 尔相关系数法通常用于反应分类特征的相关性。

对于影响特征多且变化情况复杂的 SCR 入口 NO_x 质量浓度来说,斯皮尔曼相关系数法更适合用 于分析非线性特征。在处理非线性强的数据时,斯 皮尔曼相关系数法具有更强的鲁棒性和适用性,可 以更有效地发现特征之间的关联性。因此本文将 DCS 系统中采集的各类特征和 SCR 入口 NO_x 质量 浓度进行斯皮尔曼相关性分析,计算公式为:

$$\rho = 1 - \frac{6\sum d_i^2}{n(n^2 - 1)} \tag{10}$$

式中: *ρ*—斯皮尔曼相关系数; *n*—采样点个数; *d_i*— 第 *i* 个数据的等级差。

本文选用的原始数据为实际采样数据,包括负荷、主蒸汽温度、总煤量、入口氧气含量和总风量等 16个特征变量。

对该 16 个特征进行斯皮尔曼相关性分析后,得 到的分析结果如图 5 所示。





SCR 入口 NO_x 质量浓度与炉膛温度、煤质和运行参数等多种因素有关,为此本文采用斯皮尔曼相

关性系数进行特征筛选,筛选完的特征参数包括混 煤热值和硫分等煤质因素,主蒸汽温度和入口氧气 含量等运行因素,从16个特征中选取了9个特征, 剔除了其他7个相关性较低的特征,避免增加模型 训练时间和降低模型预测精度,具体如表1所示。

表 1 特征参数选取 Tab. 1 Feature parameter selection

输入特征	最大值	最小值
主蒸汽温度/℃	541.44	531.43
负荷/MW	626.38	322.57
实时热值/kJ·kg ⁻¹	17 495.38	15 396.20
实时硫分/%	0.72	0.36
总煤量/t·h ⁻¹	389.36	117.58
入口氧气含量/%	7.3371	1.5204
入口烟气温度/℃	376.972	352.266
原烟气入口 SO2质量浓度/mg·m ⁻³	3 000	934.78
总风量/t·h ⁻¹	3 513.701 4	3 091.847 2

2.3 动态延迟时间分析

SCR 入口处烟气是从锅炉出口流出,经省煤器 进入 SCR 系统,因此入口处烟气参数与锅炉燃烧 存在密切关系。由于锅炉燃烧系统存在大延迟及 大惯性的特点,t 时刻的 SCR 入口 NO_x 质量浓度与 t-x 时刻的特征变量存在时序关系,同时,由于电 厂中 DCS 系统和燃煤电厂烟气排放连续检测系统 (Continuous Emission Monitoring System,CEMS)会受 到传感器延迟而产生滞后时间,导致直接使用现有 数据集建立的 SCR 入口 NO_x 质量浓度模型具有不 稳定性,不能准确体现输入特征与 SCR 入口 NO_x 质量浓度的非线性动态映射关系。

因此采用互信息系数方法 MI 计算各特征与入口 NO_x 质量浓度之间的延迟时间。MI 是基于熵的概念定义的,通过计算不同时间延迟下的特征变量和入口 NO_x 质量浓度的互信息值,可以确定使互信息值最大的延迟时间,即找到两个变量之间关系最强的时间延迟。

根据电厂运行经验,锅炉燃烧产生 NO_x 至烟 气,经由各管道送入 SCR 系统,整个过程延迟时间 通常在 0~360 s,该数据集采样间隔为 30 s,因此设 定分析 12 个采样点之间的延迟影响。为了使模型 能够捕捉到时间段内的特征变化信息,本文设计了 可以计算 12 个采样点内特征延迟时间的滑动窗口, 每移动滑动窗口则对窗口内的特征进行互信息计算,求解得到窗口内特征的延迟时间,MI最大的时刻即是该窗口的延迟时间。整体流程如图6所示。



图6 最佳延迟时间分析结构图

Fig. 6 Structure diagram of optimal delay time analysis

根据计算结果对数据集进行重建,按延迟时间 将各特征与目标量入口 NO_x 质量浓度重新对齐,并 重建数据集。重建后的新数据集用于下一步的模型 训练。特征最佳延迟时间计算结果如表 2 所示。

表 2 特征最佳延迟时间(s)

Tab. 2	Optimal	delay	time of	characteristic	parameters (s)
--------	---------	-------	---------	----------------	--------------	----

参 数	延迟时间
主蒸汽温度	120
负荷	150
实时热值	60
实时硫分	30
总煤量	120
人口氧气含量	60
入口烟气温度	60
原烟气入口 SO2质量浓度	90
总风量	120

2.4 预测模型

本文提出基于 TCN-BiGRU-Attention 与残差优

化的 SCR 系统入口 NO_x 质量浓度预测模型,整体

模型流程如图7所示。





3 实验结果与分析

采用数据集后 2 000 组数据作为测试集。为了 对比不同模型的预测精度,采用平均百分比误差 (MAPE)、均方根误差(RMSE)、平均绝对误差 (MAE)、均方误差(MSE)和拟合优度(*R*²)作为模型 的评价指标。MAPE 体现预测误差的相对大小, RMSE 体现预测误差的总体波动性, MAE 体现预测 误差的平均水平, MSE 体现预测值偏离实际值的程 度,具体公式为:

MAPE =
$$\frac{1}{n} \sum_{i=1}^{n} \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%$$
 (11)

RMSE =
$$\sqrt{\frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2}$$
 (12)

MAE =
$$\frac{1}{n} \sum_{i=1}^{n} |y_i - \hat{y}_i|$$
 (13)

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

式中: \hat{y}_i 一预测值。

3.1 延迟时间对预测结果的影响

为验证基于滑动窗口的延迟时间分析对模型预测的影响,对考虑延迟时间延迟的数据集以及不考虑时间延迟的原始数据集分别进行基于 LSTM 和 TCN-BiGRU-Attention 的模型训练。通过真实值和 预测值的散点图来观察模型的预测精度,如图 8 和 图 9 所示。图中直线代表真实值和预测值的理想拟 合曲线,若点越靠近曲线,则代表模型的预测值越接 近真实值。



图 8 时间延迟对 LSTM 模型的影响

Fig. 8 Effect of time delay on LSTM model





可以发现,图中大多数散点分布在理想拟合曲 线附近,表明模型在这些点上的预测较为准确。经 过延迟时间分析的模型散点更密集地分布在理想拟 合曲线附近,说明其预测精度更高。而没有延迟时 间分析的模型,散点在理想拟合曲线周围的离散程 度更大,表明预测误差较大,模型难以准确捕捉数据 的动态变化。

通过计算两种模型的评价指标来分析时间延迟 对预测结果的影响,其结果如表 3 所示。以 MAPE 为例,LSTM 降低了 22.8%,TCN-BiGRU-Attention 降 低了 48.7%。由此可见,在考虑延迟时间后,模型 的预测精度得到了改善。

表 3 不同预测模型的评价指标

Tab. 3 Evaluation indicators for different prediction models

模型	MAPE/%	RMSE
LSTM 无延迟时间分析	4.96	10.382
LSTM 有延迟时间分析	3.83	7.603
TCN-BiGRU-Attention 无延迟时间分析	1.87	4.071
TCN-BiGRU-Attention 有延迟时间分析	0.96	2.648

延迟时间分析是一种用于时间序列预测的技术,通过考虑数据中的延迟特征,模型可以更好地捕捉序列中的动态变化。在没有延迟时间分析的模型中,模型仅基于当前或过去的观测数据进行预测,容易忽略数据中潜在的时间依赖性。通过引入延迟时间分析,模型可以充分利用历史数据,从而更好地捕捉时序特征,反映出数据间的潜在依赖关系。

以 TCN-BiGRU-Attention 模型为例,对采用延迟时间分析后重构的数据集和没有延迟时间分析的原数据集分别进行训练,其预测结果如图 10 所示。



2025 年

在没有引入延迟时间分析的情况下,虽然模型 能够得到一定的预测结果,但由于忽略了锅炉内热 工过程中的时间延迟特点,模型在处理具有复杂时 序关系的数据时表现出明显的不足。锅炉内的热工 过程通常伴随着一定的传热、传质时间延迟,这种时 间延迟现象使得输入特征的变化不会立即反映在输 出上,而是经过一段时间后才显现出来。因此,忽略 时间延迟因素的预测模型无法准确捕捉动态过程中 的复杂关系。图 10 选择了入口 NO_x 质量浓度剧烈 波动的阶段,在截取的上升与下降区域,由于没有延 迟时间分析的预测曲线,因此无法准确追踪数据中 的复杂波动趋势,导致在趋势变化时出现了明显的 滞后与偏差。而通过引入延迟时间分析的模型,在 应对数据波动方面表现出更高的灵敏度,其预测曲 线能够紧密贴合真实数据的波动,表现出更高的预 测精度,在发生剧烈波动时,模型能够迅速调整并做 出准确预测,避免了滞后和偏差问题。

3.2 残差修正对预测结果的影响

在 SCR 系统入口 NO_x 质量浓度预测中,尽管 主模型能够捕捉大部分的 NO_x 质量浓度变化趋势, 但由于模型训练过拟合或欠拟合、数据非线性复杂 性及噪声等因素,主模型仍会存在一定程度的预测 误差,这些误差可能导致系统预测性能的下降。为 了进一步提升模型的预测精度,本文提出基于 SVR 残差修正的模型,通过预测主模型的残差来提高整 体预测的准确性。预测残差修正值分布如图 11 所示。



图 11 预测残差修正值分布图

Fig. 11 Distribution diagram of predicted residual correction values

为了验证基于 SVR 的残差修正模型对预测结 果的影响,采用两种不同的预测模型,即 LSTM 和 TCN-BiGRU-Attention 模型,分别对有/无残差修正 的预测结果进行对比分析。

为更直观地展示模型预测结果的误差分布情况,采用小提琴图结合箱型图的方式,如图 12 和图 13 所示。小提琴图能够展示预测误差的概率密度 分布,也就是说图中类似小提琴的部分为各数据点 预测误差的分布情况。同时结合箱型图,可以清晰 地看到误差的中位数以及所有误差的离散情况。此 外,为了突出显示修正模型对误差分布中位数的改 善效果,通过在图中加入直线,表示有残差修正后模 型的误差中位数。



图 12 残差修正对 LSTM 模型的影响

Fig. 12 Effect of residual correction on LSTM model



图 13 残差修正对 TCN-BiGRU-Attention 模型的影响 Fig. 13 Effect of residual correction on TCN-BiGRU-Attention model

有残差修正的模型具有更集中在零点附近的绝 对误差,代表引入残差修正的模型其预测偏差与方 差更小。 从图 12~图 13 中可以看出,残差修正模型有效地缩小了误差分布的范围,尤其在误差中位数方面,更加集中在零点附近。通过残差修正,LSTM 和 TCN-BiGRU-Attention 模型的预测结果在整体上更加集中,并且误差分布的尾部得到了明显的收缩,减少了较大误差的发生。

通过绘制雷达图来对比 TCN-BiGRU-Attention 模型加入残差修正后的性能表现,如图 14 所示。图 中展示了加入残差修正前后的平均百分比误差 MAPE、均方根误差 RMSE、平均绝对误差 MAE、均 方误差 SMSE 和拟合优度 *R*²,更形象地展示残差修 正模型对于提升模型预测精度的效果。各评价指标 如表 4 所示。



图 14 评价指标雷达图

Fig. 14 Radar chart of evaluation indicators

表4 残差修正模型的评价指标

 Tab. 4 Evaluation indicators for residual

correct	tion	mod	els

模型	MAPE/%	RMSE	MAE	MSE	R^2
TCN-BiGRU-Attention 无残差修正	1.23	3.271	2.593	8.051	0.794
TCN-BiGRU-Attention 有残差修正	0.67	1.621	1.229	3.292	0.974

3.3 不同模型对预测结果的影响

为验证 TCN-BiGRU-Attention 残差优化模型的 预测效果,分别用 GRU 预测模型、TCN-GRU 预测模 型、TCN-BiGRU 预测模型与 TCN-BiGRU-Attention 残差优化模型进行比较。各模型的预测曲线和绝对 误差分布,如图 15 和图 16 所示。



图 15 不同模型的预测结果对比

Fig. 15 Comparison of prediction results of different models



图 16 绝对误差分布图 Fig. 16 Absolute error distribution chart

从图 16 可以看出,不同模型的绝对误差在零点 附近的集中程度有所不同。TCN-BiGRU-Attention 模型的绝对误差分布明显更为集中且更接近零点, 表明该模型大多数预测值与真实值的差异较小,能 够较为精确地捕捉 NO_x 质量浓度的变化趋势。相 比之下,其他 3 个模型的绝对误差分布远离零点,对 复杂的时序数据表现出一定的局限性。不同模型的 预测效果如表 5 所示。

表 5 不同模型的预测评价指标

Tab. 5 Predictive evaluation indicators for different models

模型	MAPE/%	RMSE	R^2
GRU	4.96	10.381	0.794
TCN-GRU	3.83	8.603	0.835
TCN-BiGRU	1.51	3.871	0.907
TCN-BiGRU-Attention	0.67	1.621	0.974

从实验结果可以看出,相较于其他模型,TCN-BiGRU-Attention 模型尤其是在误差的控制和拟合能力上表现更加优越。这是因为Attention 机制的引入使得模型能够更加有效地识别和关注时间序列中的重要特征,而TCN与BiGRU的结合进一步提升了模型的长短期依赖建模能力。同时,残差优化模型的加入,提高了模型预测效果精度,进一步有效降低 MAPE、RMSE,实现了对 SCR 系统入口 NO_x 质量浓度的准确预测,对燃煤电厂实际生产具有指导作用。

4 结 论

(1)由于燃煤电厂锅炉燃烧是个复杂的过程, 且 SCR 系统存在滞后性,通过基于信息熵理论的互 信息系数与滑动窗口结合后的延迟时间分析,获得 了数据集中各特征的最佳延迟时间,并重构数据集, 可以有效提高 SCR 系统入口 NO_x 质量浓度的预测 精度,在处理波动性较大的情况时,模型的稳定性和 鲁棒性增强。

(2) 通过对 LSTM 和 TCN-BiGRU-Attention 这 两种不同模型与有残差修正的模型进行对比,得出 残差修正能够更好地实现对 SCR 系统入口 NO_x 质 量浓度的预测,提高整体模型的预测精度。

(3) 将基于残差修正的 TCN-BiGRU-Attention 预测模型与其他预测模型进行对比,相较于预测效果 最好的 TCN-BiGRU,基于残差修正的 TCN-BiGRU-Attention 预测模型 MAPE 降低了 55.6%, RMSE 降 低了 58.1%, R²为 0.974,表明该模型具有更高的预 测精度,可以为燃煤电厂实际 SCR 系统入口 NO_x 质量浓度测量提供参考。

参考文献:

- [1] 董 泽,闫来清. SCR 脱硝系统 NO_x 排放浓度建模与仿真
 [J]. 系统仿真学报,2020,32(2):172-181.
 DONG Ze, YAN Laiqing. Modelling and simulation for NO_x emission concentration of SCR denitrification system [J]. Journal of System Simulation,2020,32(2):172-181.
- [2] 周洪煜,张振华,张 军,等.超临界锅炉烟气脱硝喷氨量混结构-径向基函数神经网络最优控制[J].中国电机工程学报,2011,31(5):108-113.

ZHOU Hongyu, ZHANG Zhenhua, ZHANG Jun, et al. Mixed structure-radial basis function neural network optimal control on spraying ammonia flow for supercritical boiler flue gas denitrification [J]. Proceedings of the CSEE, 2011, 31(5):108 - 113.

[3] 谭增强,李元昊,牛拥军,等.火电厂 NO_x 的均布优化及预测 研究[J].环境工程,2023,41(S1):349-353. TAN Zengqiang,LI Yuanhao,NIU Yongjun, et al. Research on uniform distribution optimization and prediction of NO_x in thermal power plants [J]. Environmental Engineering, 2023, 41 (S1): 349-353.

- [4] NAZARI S, SHAHHOSEINI O, SOHRABI-KASHANI A, et al. Experimental determination and analysis of CO₂, SO₂, and NO_x, emission factors in Iran's thermal power plants [J]. Energy, 2010, 35(7);2992 2998.
- [5] 饶德备,谭 鹏,李壮扬,等. 燃煤电站 SCR 脱硝系统机理建模
 [J]. 热力发电,2019,48(8):36-41.
 RAO Debei, TAN Peng, LI Zhuangyang, et al. Research on mechanism modeling of SCR denitrification system in coal-fired power plants[J]. Thermal Power Generation,2019,48(8):36-41.
- [6] DEVARAKONDA M, TONKYN R, TRAN D, et al. Modeling species inhibition of NO oxidation in Urea-SCR catalysts for diesel engine NO_x control[J]. Journal of Engineering for Gas Turbines and Power, 2011, 133(9):092805.
- [7] 秦天牧,吕 游,杨婷婷,等. SCR 烟气脱硝系统自适应混合动态模型[J]. 仪器仪表学报,2016,37(12):2844-2850.
 QIN Tianmu,LYU You,YANG Tingting, et al. Self-adaptive hybrid dynamic model of SCR flue gas denitration system [J]. Chinese Journal of Scientific Instrument,2016,37(12):2844-2850.
- [8] 姚 楚,龙东腾,吕 游,等.火电厂 SCR 脱硝系统机理建模与 控制研究[J].热能动力工程,2018,33(5):78-84.
 YAO Chu,LONG Dongteng,LYU You, et al. Study on mechanism modelling and control of SCR denitration system in thermal power plant[J]. Journal of Engineering for Thermal Energy and Power, 2018,33(5):78-84.
- [9] 丁续达,金秀章,张 扬. 基于最小二乘支持向量机的改进型 在线 NO_x 预测模型[J]. 热力发电,2019,48(1):61-67.
 DING Xuda, JIN Xiuzhang, ZHANG Yang. An improved online NO_x prediction model based on LSSVM[J]. Thermal Power Generation,2019,48(1):61-67.
- [10] XIE P,GAO M,ZHANG H, et al. Dynamic modeling for NO_x emission sequence prediction of SCR system outlet based on sequence to sequence long short-term memory network[J]. Energy, 2020,190:116482.
- [11] 杨 浩,周东阳,曹 军,等. 基于 DJMI-GRU 的 SCR 烟气脱 硝系统出口 NO_x 动态软测量建模[J]. 热力发电, 2021, 50(12):51-58.

YANG Hao,ZHOU Dongyang,CAO Jun, et al. Dynamic soft sensing model of NO_x concentration at outlet of SCR flue gas denitration system based on DJMI-GRU[J]. Thermal Power Generation, 2021,50(12):51–58.