

DOI: 10.19666/j.rlfd.202212226

基于注意力机制组合模型的燃煤-煤气混合燃烧电厂 NO_x 排放预测

钱 虹^{1,2}, 张 俊¹, 徐邦智¹

(1.上海电力大学自动化工程学院, 上海 200090; 2.上海市电站自动化技术重点实验室, 上海 200072)

[摘 要] 针对当前燃煤-煤气锅炉煤气掺烧量不确定情况下对 NO_x 排放量预测不够准确的问题, 提出一种基于注意力机制组合在线预测模型。首先, 通过最大信息系数法与皮尔逊相关系数法相结合确定模型的特征变量; 其次, 对线性相关特征变量采用滑动时间窗口在线构建向量自回归模型 (VAR), 实现多维时序线性相关变量输入下对 NO_x 排放量的预测, 而对于非线性相关特征变量通过构建在线循环极限学习机 (OR-ELM) 模型在线学习非线性相关变量在时序上的关系对 NO_x 排放量进行预测; 最后, 采用注意力机制对 2 个预测模型进行动态赋权以实现趋势预测。采用实际运行数据对该模型验证, 结果表明, 所构建的 VAR-OR-ELM 组合在线预测模型能够准确预测 10 min 后的 NO_x 排放量变化趋势, 并在不同负荷段对 NO_x 质量浓度进行准确预测; 综合预测精度及预测时间, 所构建的组合预测模型比其他单一预测模型的预测效果更好。

[关 键 词] 最大信息系数; 注意力机制; 组合预测; 在线学习; NO_x 排放

[引用本文格式] 钱虹, 张俊, 徐邦智. 基于注意力机制组合模型的燃煤-煤气混合燃烧电厂 NO_x 排放预测[J]. 热力发电, 2023, 52(8): 137-145. QIAN Hong, ZHANG Jun, XU Bangzhi. NO_x emission prediction of coal-gas hybrid combustion plant based on the combination of attention mechanism model[J]. Thermal Power Generation, 2023, 52(8): 137-145.

NO_x emission prediction of coal-gas hybrid combustion plant based on the combination of attention mechanism model

QIAN Hong^{1,2}, ZHANG Jun¹, XU Bangzhi¹

(1.School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;
2.Shanghai Key Laboratory of Power Station Automation Technology, Shanghai 200072, China)

Abstract: Aiming at the problem of inaccurate prediction of NO_x emission concentration when the current coal-gas boiler gas mixture is uncertain and changing, a combined online prediction method based on attention mechanism is proposed. First, the characteristic variables of the model are determined by combining the maximum information coefficient method with the Pearson correlation coefficient method; Secondly, vector autoregressive (VAR) model is constructed online with sliding time window for linearly correlated characteristic variables to realize the prediction of NO_x emission concentration under the input of multi-dimensional time series linear correlation variables. For non-linear-related feature variables, the relationship between NO_x emission concentration is predicted by constructing an online Recurrent extreme learning machine (OR-ELM) model online learning. Finally, Attention Mechanism (AM) is used to dynamically weight the two forecasting models to achieve trend forecasting. Through field data verification, it shows that the VAR-OR-ELM combined online prediction model constructed in this paper can accurately predict the variation trend of NO_x emission concentration after 10 minutes. Combining prediction accuracy and prediction time, the combined prediction model is better than other single prediction models.

Key words: maximal information coefficient; attention mechanism; combined prediction; online learning; NO_x emission

修回日期: 2022-12-12 网络首发日期: 2023-02-24

基金项目: 上海市自然科学基金 (19ZR1420700)

Supported by: Natural Science Foundation of Shanghai (19ZR1420700)

第一作者简介: 钱虹 (1967), 女, 博士, 教授, 主要研究方向为故障诊断、过程控制等, qianhong.sh@163.com。

通信作者简介: 张俊 (1997), 男, 硕士研究生, 主要研究方向为故障诊断、过程控制等, zhangjun_whale@163.com。

燃煤-煤气混合燃烧电厂锅炉中,高炉煤气的掺烧会对锅炉燃烧产生的 NO_x 烟气排放造成不确定的影响。鉴于当前国家的超低排放要求,有必要通过构建准确的 NO_x 排放量预测方法,对未来一段时间的 NO_x 排放量变化进行趋势预测,当预测到 NO_x 排放量变化将超过限值时,在一段可操作的时间内,及时告知运行人员对燃烧系统采取措施,实现烟气 NO_x 的超低排放。

目前,对烟气 NO_x 排放量的预测建模所采用的方法主要有 2 类:1) 通过机理分析建立预测模型;2) 数据驱动建模,即通过历史运行数据建立预测模型。文献[1]通过构建高炉煤气/煤粉混燃锅炉烟气 NO_x 生成机理来控制 NO_x 排放。文献[2-3]通过对脱硝系统化学反应机理分析,建立了 NO_x 质量浓度预测模型,对喷氨量进行控制。但脱硝反应过程过于复杂,机理模型难以完全描述脱硝反应过程,难以满足现场运行条件。

与机理建模相比,数据建模利用历史运行数据构建模型,不需要考虑机理特性。文献[4-5]使用人工神经网络(artificial-neural-network)建立了 NO_x 排放质量浓度的预测模型。文献[6-8]利用随机森林算法建立了 NO_x 排放量预测模型取得了较好的预测效果。文献[9-13]使用长短时记忆(long short term-memory, LSTM)神经网络对多维时间序列数据进行学习,对未来时刻的 NO_x 的排放质量浓度进行预测。虽然神经网络能够较好地学习到时间序列数据在时间上的非线性关系,但是存在超参数难以确定、学习速度慢等问题。因此文献[14]利用粒子群算法,对双向门控循环神经网络的超参数进行寻优,克服了手动调参预测精度低的问题,但粒子群算法运算时间较长,并且容易陷入局部极值点。文献[15-17]利用极限学习机模型构建 NO_x 的排放质量浓度预测模型,达到了较好的预测精度。

除上述利用人工智能算法进行数据建模外,基于统计学方法的数据建模,以时间序列模型为代表,被广泛应用到各个领域。文献[18]构建的自回归移动平均(ARIMA)预测模型对海上风速进行预测,并且与门控循环单元(GRU)与 LSTM 进行了对比。文献[19]构建了多维向量自回归的多变量预测模型对多能源系统中的多个变量进行预测,取得了较好的预测效果。但是上述方法都是单一模型的数据驱动方法且预测长度较短。为了提升预测精度,文

献[20-21]提出时间序列模型与神经网络模型相组合的预测模型,相较于单一预测模型,组合的预测模型的预测精度更高。文献[22]利用熵权法将 3 个预测模型进行组合对光伏的输出功率进行预测,取得了较好的预测效果。

在燃煤-煤气混合燃烧电厂中高炉煤气的掺烧会对锅炉内部的燃烧产生很大影响^[23],进而会影响 NO_x 的排放量。因此在煤气掺烧量不确定的情况下, NO_x 排放量难以预测。对此,提出一种基于注意力机制组合在线预测模型,并通过实际运行案例验证,证明本文的组合模型与单个预测模型相比预测精度更高,相较于其他模型预测精度更高且运算速度更快,更能满足实际生产中对 NO_x 排放预警的需求。

1 基于 MIC 与 PCCs 的 NO_x 排放量相关特征变量

在燃煤-煤气混合燃烧电厂中,煤气通过煤粉燃烧系统引入锅炉,由于煤气是一种超低发热值的气体,所以会对锅炉的燃烧过程造成较大的影响,进而影响 NO_x 排放量。本文基于锅炉运行原理以及脱硝系统运行原理选取负荷、喷氨量、给煤量等 11 个反映锅炉燃烧与 NO_x 排放过程的特征变量,并对这些特征变量进行相关性分析。由于运行环境恶劣,传感器会受到高温等因素影响,所以这些现场数据常含有异常值和噪声。本文采用拉依达准则^[24]对原始数据集中异常数据进行筛选并删除,并使用线性插值补充缺失值。采用(Savitzky-Golay, S-G)滤波进行去噪处理,为了消除量纲的影响,数据滤波后的数据集进行归一化处理:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

式中: X' 为归一化后的数据; X 为初始数据; $X_{\max}$ 与 $X_{\min}$ 分别为初始数据中的最大值与最小值。

利用最大信息系数(maximal information coefficient, MIC)对特征变量之间的相关性进行分析。最大信息系数以互信息为基础,可用于计算变量之间的线性与非线性相关性。对于变量 x 和 y , MIC 的计算公式为:

$$\text{MIC}(x, y) = \max_{xy \in B(n)} \frac{I(x, y)}{\log_2(\min(x, y))} \quad (2)$$

$$I(x, y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log_2 \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (3)$$

式中: $I(x,y)$ 为变量 x 和 y 之间的互信息值; $p(x)$ 、 $p(y)$ 分别为边缘概率分布; $p(x,y)$ 为联合概率分布; $B(n)$ 通常设置为数据量 n 的 0.6 次方。

表 1 为 11 个特征变量与 NO_x 排放量之间的最大信息系数。从表 1 中可见, 负荷值、喷氨流量等 9 个特征变量与 NO_x 排放量存在较强的相关性。如果将较强相关的变量都选取, 会导致信息冗余。

表 1 特征变量与 NO_x 排放量的最大信息系数
Tab.1 MIC coefficient between feature variable and NO_x emission

	特征变量	最大信息系数
强相关	负荷值	0.53
	给煤量	0.54
	喷氨阀门开度	0.51
	喷氨流量	0.50
	入口 NO _x 质量浓度	0.54
	入口烟温	0.54
	入口烟气含氧量	0.54
	主蒸汽温度	0.54
	再热蒸汽温度	0.54
弱相关	氨逃逸体积分数	0.15
	出口烟气含氧量	0.31

由于 MIC 同时适用于线性与非线性相关性, 所以本文使用皮尔逊相关系数 (Pearson product-moment correlation coefficient, PCCs) 进一步对特

征变量进行筛选。对于变量 x 和 y , 皮尔逊相关系数计算公式为:

$$r_{xy} = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{\sqrt{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} \sqrt{n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2}} \quad (4)$$

式中: r_{xy} 为皮尔逊相关系数; n 为样本长度; x_i 和 y_i 均为变量实际值。

图 1 为 12 个特征变量之间的皮尔逊相关性热力图。从图 1 可以看出: 负荷值 L (MW)、入口 NO_x 质量浓度 I (mg/m³)、入口烟温 T_i (°C)、给煤量 C (t/h)、主蒸汽温度 T_1 (°C)、再热蒸汽温度 T_2 (°C) 这些特征变量与 NO_x 排放质量浓度 D (mg/m³) 有着较强的正线性相关, 入口烟气含氧量 ϕ (O₂)(%) 与 NO_x 排放质量浓度 D 有着较强的负线性相关。由于主蒸汽温度 T_1 与再热蒸汽温度 T_2 这 2 个变量与负荷值以及入口烟温有极强的正线性相关, 为了减少信息的冗余, 将这 2 个变量去除。结合表 1 与图 1 可得, 喷氨阀门开度 K (%)、喷氨流量 F (kg/h) 这 2 个特征变量与 NO_x 排放质量浓度 D (mg/m³) 有着较强的非线性关系。由于喷氨阀门开度 K 与喷氨流量 F 之间有极强的线性相关, 所以将喷氨阀门开度 K 这个变量去除。




图 1 特征变量皮尔逊相关性热力图

Fig.1 Heat map of Pearson correlation coefficient of feature variable

通过最大信息系数与皮尔逊相关系数结合选出 4 个线性相关的特征变量以及 1 个非线性相关的特

征变量。其中线性相关的特征变量负荷值 L 、入口 NO_x 质量浓度 I 、入口烟温 T_i 、给煤量 C 与入口烟气

含氧量 $\phi(\text{O}_2)$ 作为向量自回归模型的内因变量与出口 NO_x 质量浓度 D 构建时间序列预测模型, 即:

$$x_{\text{VAR}} = [L_t, I_t, T_{i,t}, C_t, \phi_t(\text{O}_2), D_t] \quad (5)$$

$$y_{\text{VAR}} = D_t \quad (6)$$

非线性相关的特征变量喷氨流量 F 与出口 NO_x 质量浓度 D 作为极限学习机模型的输入特征变量, 构建在线循环极限学习机多维预测模型, 即:

$$x_{\text{OR-ELM}} = [F_t, D_t] \quad (7)$$

$$y_{\text{OR-ELM}} = D_t \quad (8)$$

2 基于注意力机制 NO_x 排放预测模型

本文构建基于向量自回归 (vector auto regression, VAR) 的时间序列预测模型与基于在线循环极限学习机 (OR-ELM) 的多维预测模型, 并基于注意力机制对 2 个预测模型进行变权融合, 对脱硝系统出口 NO_x 质量浓度进行预测。

2.1 基于向量自回归的时间序列预测模型

VAR 模型是一种时间序列模型, 是单变量自回归模型 (AR) 在多变量时序上的扩展。向量自回归模型通过线性拟合的方式对多变量时间序列数据进行描述, 能够较好地刻画变量之间相互影响的动态线性相关关系。本文通过向量自回归模型拟合脱硝系统出口 NO_x 质量浓度等线性相关的特征变量在时间上的线性关系, 建立脱硝系统出口 NO_x 质量浓度时间序列多步预测模型。通过上文分析, 多变量时间序列数据为 $x_{\text{VAR}} = [L_t, I_t, C_t, \phi_t(\text{O}_2), D_t]$, 则 VAR(p) 模型的数学表达式为:

$$y = a_0 + A_1 x_{\text{VAR}}(t-1) + A_2 x_{\text{VAR}}(t-2) + \dots + A_p x_{\text{VAR}}(t-p) + \varepsilon_t \quad (9)$$

式中: a_0 为五维的常数; A_p 为 5×5 维系数矩阵元素; y 为第 t 时刻的 5 个特征变量组成的五维量; $x_{\text{VAR}}(t-p)$ 为滞后 p 时刻的五维的特征变量; ε_t 为白噪声干扰。

为避免伪回归, 保证预测结果的可靠性, 在构建向量自回归模型时需要满足所有的时间序列数据为平稳序列。本文通过单位根 (augmented dickey-fuller test, ADF) 检验法^[25]对选取的 6 个特征变量的时序数据进行平稳性检验。ADF 检验假设序列存在单位根, 若显著性检验统计量小于 10%、5%、1% 3 个置信度, 则对应有 90%、95%、99% 的把握来拒绝原假设。表 2 为平稳性检验结果。从表 2 可见, 6 个特征变量的 ADF 统计量均小于 5% 显著水平, 均可认为是平稳序列。一般线性相关的平稳序列都

满足因果关系。

表 2 特征变量平稳性检验结果
Tab.2 Features variable stationarity check results

特征变量	ADF 统计量	5%显著水平	结论
负荷值	-3.52	-2.86	平稳
入口 NO_x 质量浓度	-5.07	-2.86	平稳
入口烟温	-5.07	-2.86	平稳
给煤量	-3.32	-2.56	平稳
入口烟气含氧量	-7.27	-2.56	平稳
出口 NO_x 质量浓度	-6.57	-2.86	平稳

滞后阶数的确定是向量自回归模型构建过程中一个重要的问题, 如果滞后阶数非常大, 虽然有利于完整反映模型的动态特性, 但是会使模型的参数变复杂, 影响模型的预测效果。本文通过赤化信息准则 (Akaike information criterion, AIC) 及贝叶斯信息准则 (Bayesian information criterion, BIC) 来确定模型中的滞后阶数, 其计算公式为:

$$\text{AIC} = -2\ln(L) + 2k \quad (10)$$

$$\text{BIC} = -2\ln(L) + k\ln(n) \quad (11)$$

式中: L 为似然函数; k 为模型中的参数数量。

计算 1~ p 阶 AIC 与 BIC 的值, 若两者在相同的阶数取得最小值, 则此时的阶数适合构建向量自回归模型。图 2 为不同阶数下的 AIC 与 BIC 值。




图 2 不同阶数下 AIC 与 BIC 值
Fig.2 AIC and BIC values at different orders

从图 2 可得: 在滞后阶数为 5 时, AIC 与 BIC 的值为最小, 因此选择模型的滞后阶数 $p=5$ 。

本文通过滑动时间窗口在线构建 VAR 预测模型以提升模型对时序数据变化的适应性, 图 3 为滑动时间窗口构建 VAR 预测模型的过程。

2.2 基于在线循环极限学习机的多维预测模型

在线循环极限学习机 (online recurrent extreme learning machine, OR-ELM) 是在线顺序极限学习机 (OS-ELM) 的改进型^[26]。OR-ELM 能够进行在

线学习, 在线学习过程中不断更新网络参数以提高模型对数据变化的适应性。OR-ELM 由 3 个网络组成, 包括 1 个循环神经网络 (RNN), 是用于预测的主网络, 以及 2 个单隐层前馈网络 (SLFN), 是用于学习 RNN 网络输入权重和隐藏层权重的 (ELM-auto-encoder) ELM-AE 网络。




图3 向量自回归预测模型构建

Fig.3 Vector auto regression prediction model construction

图4为 OR-ELM 主体网络结构以及 2 个 ELM-AE 网络结构。从图4可以看出, 除了 LN 层外, 在线循环极限学习机的结构与 RNN 相同。

通过上文的分析, 选取非线性相关的特征变量

喷氨流量 F 与出口 NO_x 质量浓度 D 作为在线顺序极限学习机模型的特征变量。OR-ELM 包括初始化阶段和在线学习阶段 2 个阶段。

1) 初始化阶段

通过随机分配均值为 0、方差为 1 的实数来初始化 2 个 ELM-AE 输入层权重 $W_{i,0}$ 与 $W_{h,0}$, 并且通过式(12)初始化 OR-ELM 主网络输出层参数以及 2 个 ELM-AE 输出层权重 $\beta_{i,0}$ 与 $\beta_{h,0}$ 以及辅助矩阵 $P_{i,0}$ 与 $P_{h,0}$ 。

$$\beta_0 = 0, P_0 = \left(\frac{I}{C} \right)^{-1} \quad (12)$$

式中: β_0 为 OR-ELM 主网络输出层权重; P_0 为辅助矩阵; I 为单位对角矩阵; C 为一个常数。

2) 在线学习阶段

首先, 使用 ELM-AE 更新 OR-ELM 的输入权重。ELM-AE 将第 $k+1$ 个输入样本 $x(k+1) \in \mathbb{R}^{n \times 1}$ 前向传播到隐藏层, 其隐藏层输出矩阵 $H_{i,k+1}$ 计算公式为:

$$H_{i,k+1} = g(\text{norm}(W_{i,k+1}x(k+1))) \quad (13)$$

$$\text{norm}(x) = \frac{x - \mu_i}{\sqrt{\sigma_i^2 + \epsilon}}, \mu_i = \frac{1}{L} \sum_{j=1}^L x_j, \sigma_i = \frac{1}{L} \sum_{j=1}^L (x_j - \mu_i)^2$$

式中: $g(\cdot)$ 为激活函数; L 为 ELM-AE 的隐藏层节点数。




图4 在线循环极限学习机模型结构

Fig.4 The model structure of online recurrent extreme learning machine

然后使用递推最小二乘法计算 ELM-AE 的输出层权重, 计算公式为:

$$\beta_{i,k+1} = \beta_{i,k} + P_{i,k+1} H_{i,k+1}^T (x(k+1) - H_{i,k+1} \beta_{i,k}) \quad (14)$$

$$P_{i,k+1} = \frac{1}{\lambda} P_{i,k} - P_{i,k} H_{i,k+1}^T (\lambda^2 + \lambda H_{i,k+1} P_{i,k} H_{i,k+1}^T)^{-1} H_{i,k+1} P_{i,k} \quad (15)$$

式中: λ 为一个为常数的遗忘因子。

将 $\beta_{i,k+1}$ 的转置作为 OR-ELM 主网络的输入权重 W_{k+1} , 即为:

$$W_{k+1} = \beta_{i,k+1}^T \quad (16)$$

OR-ELM 主网络隐藏层权重的更新与输入层权重更新的方式相同, 也是通过递推最小二乘法得到 OR-ELM 主网络隐藏层的权重 V_{k+1} , 即为:

$$V_{k+1} = \beta_{h,k+1}^T \quad (17)$$

通过前馈传播得到 OR-ELM 主网络隐藏层的输出矩阵, 如式(18)所示:

$$H_{k+1} = g(\text{norm}(W_{k+1}x(k+1) + V_{k+1}H_k)) \quad (18)$$

最终 OR-ELM 主网络输出层参数通过式(19)和

式(20)进行更新:

$$\beta_{k+1} = \beta_k + \mathbf{P}_{k+1} \mathbf{H}_{k+1}^T (\mathbf{H}_k - \mathbf{H}_{k+1} \beta_k) \quad (19)$$

$$\mathbf{P}_{k+1} = \mathbf{P}_k - \mathbf{P}_k \mathbf{H}_{k+1}^T (\mathbf{I} + \mathbf{H}_{k+1} \mathbf{P}_k \mathbf{H}_{k+1}^T)^{-1} \mathbf{H}_{k+1} \mathbf{P}_k \quad (20)$$

OR-ELM 模型可以有 m 个隐藏层,在这种情况下,OR-ELM 有 $2m$ 个 ELM-AE。在这种更深层的结构中,OR-ELM 模型能够学习到更复杂的时序非线性关系。

2.3 基于注意力机制的组合模型

虽然向量自回归模型与在线循环极限学习机模型在未知煤气掺烧量的情况下预测性能都有所下降,但是向量自回归模型是由线性相关变量所构建,在线循环极限学习机模型由非线性相关变量所构建,因此两者在不同时间下的预测性能有所差别,本文通过注意力机制动态地计算预测值与真实值之间的相似度为 2 个预测模型进行赋权,实现 2 个模型的动态互补,以达到较好的预测性能。

注意力机制 (attention mechanism, AM) 的核心思想是将更多的注意力分配给重要的信息并减少对其他信息的关注^[27]。注意力机制的本质是通过计算 Query 与 Key 之间的相似度对 Value 的权重进行分配。注意力机制具体计算过程如图 5 所示。




图 5 注意力机制计算流程
Fig.5 Attention mechanism calculation process

从图 5 可知,整个计算过程可分为 3 个阶段。第 1 阶段计算 Q 和 K 的相似度, $f(Q, K)$ 为相似度计算函数,本文使用内积计算相似度:

$$f(Q, K) = Q^T K_i = S_i (i = 1, 2, 3, \dots, n) \quad (21)$$

式中: Q 与 K 分别为 Query 矩阵和 Key 矩阵。

第 2 阶段将第 1 阶段计算得到的相似度 S_i 进行 SoftMax 操作,将相似度进行归一化:

$$w_i = \text{SoftMax} \left(\frac{f(Q, K_i)}{\sqrt{d_k}} \right) \quad (22)$$

第 3 阶段针对计算出来的权重 w_i ,对 V 中所有的值进行加权求和,得到最终的注意力向量,计算公式为:

$$\text{Attention} = \sum_i^n w_i V_i \quad (23)$$

一般来说,在注意力机制中 Key 与 Value 是同一个向量。本文将真实值 y_{real} 作为注意力机制中的 Query,即 $Q=y_{\text{real}}$,将 2 个模型的预测值作为注意力机制中的 Key,即 $K=(y_{\text{VAR}}(t), y_{\text{OR-ELM}}(t))=V$,在每一次预测通过式(21)、式(22)更新 2 个预测模型的权重 w_A 与 w_B ,最终经过式(23)得到组合模型的预测值 $y_{\text{predict}}(t) = w_{\text{BYVAR}}(t) + w_{\text{BYOR-ELM}}(t)$ 。整个组合模型的构建如图 6 所示。




图 6 组合模型构建流程
Fig.6 Combination model construction process

3 案例验证与分析

基于上文构建的组合预测模型,采用 Python 编程实现。基于国内某钢厂 350 MW 燃煤-煤气机组 1 个月现场运行数据,采样间隔为 1 min 的不同工况下的 40 000 组数据进行验证与分析。对经过数据处理后的数据样本进行划分,由于本文构建的为在线预测模型,只需要少量训练集进行训练,因此选取

1 000 组训练集, 选取包括低负荷段的数据 3 000 组、高负荷段数据 2 000 组的测试集进行验证。本文采用均方误差 (mean square error, MSE) 和平均绝对百分比误差 (mean absolute percentage, MAPE) 作为模型的评价指标进行预测和比较分析。

3.1 不同负荷段预测结果分析

基于本文所构建的 VAR-OR-ELM 组合预测模型, 设置滑动时间窗口长度 N 为 500, 在测试集上进行 10 步 (10 min) 预测。图 7 为不同负荷段下变权组合模型的预测结果。由图 7 可见, 无论机组处于低负荷段 (200 MW 以下) 还是高负荷段 (200 MW 以上), 组合预测模型都能较为准确地预测脱硝系统出口 NO_x 质量浓度的变化趋势。




图 7 不同负荷段的预测结果
Fig.7 Forecast results in different load segments

3.2 不同预测模型对比分析

为了验证组合模型的优越性, 使用组合模型与单一预测模型进行对比验证, 部分预测结果结构对比与预测结果散点图如图 8 与图 9 所示。从图 8 和图 9 可见, 组合模型的预测结果相较于单个预测模型更为接近理想直线。表 3 为各模型预测结果评价指标, 从表 3 可得, VAR-OR-ELM 组合预测模型的预测精度相较于单个预测模型都有所提高。相较于

VAR 模型, VAR-OR-ELM 模型均方误差与平均绝对百分比误差分别降低 4.13 mg/m³ 与 3.1%, 相较于 OR-ELM 模型, 均方误差与平均绝对百分比误差分别降低 1.10 mg/m³ 与 0.6%。




图 8 组合模型预测结构对比
Fig.8 Comparison graph of the combination model prediction results




图 9 组合模型预测结果散点图
Fig.9 Prediction results scattered graph of combination model

表 3 评价指标与模型计算时间
Tab.3 Evaluation metrics and model calculation time

预测模型	$\delta_{MSE}/(\text{mg}\cdot\text{m}^{-3})$	$\delta_{MAPE}/\%$	计算时间/s
VAR-OR-ELM	7.94	5.7	10.0
VAR	12.07	8.8	8.0
OR-ELM	9.04	8.8	1.2
LSTM	9.13	5.4	89.0
RF	12.83	7.5	13.0
ELM	17.34	7.7	0.8

图 10 为 VAR-OR-ELM 模型与 LSTM、RF、ELM 在部分高负荷段数据上的对比曲线, 这些模型的特征输入与 OR-ELM 模型的输入相同。从图 10 可见, 出口 NO_x 质量浓度变化较快时 VAR-OR-ELM 模型相较于 ELM、RF 能够更好地适应趋势的变化。从表 3 可得, VAR-OR-ELM 模型的均方误差最低, VAR-OR-ELM 模型的计算时间虽然大于 ELM, 但是远小于 LSTM, 能够满足现场运行需求。




图 10 不同模型预测结果对比

Fig.10 Comparison of prediction results of different models

3.3 不同组合方法对比分析

为了验证注意力机制组合的优越性,本文分别使用客观赋权的熵权法以及等权重对 VAR 与 OR-ELM 预测模型进行组合并且与注意力机制组合进行对比,在测试集上预测结果的评价指标见表 4,部分对比结果如图 11 所示。




图 11 不同组合方法预测结果对比

Fig.11 Comparison of prediction results of different combination methods

从图 11 可以看出,熵权法组合以及等权重组合在 NO_x 排放质量浓度变化较快时组合预测值的偏差较大。从表 4 可得,利用注意力机制组合的预测模型在测试集上的均方误差与平均绝对百分比误差均低于其他组合方法。

表 4 不同组合模型评价指标

Tab.4 Evaluation metrics of different combination models

组合预测模型	$\delta_{\text{MSE}}/(\text{mg}\cdot\text{m}^{-3})$	$\delta_{\text{MAPE}}/\%$
注意力机制组合	7.94	5.7
熵权法组合	9.46	7.5
等权重组合	8.61	6.5

4 结 论

本文提出一种基于向量自回归 (VAR) 与在线

循环极限学习机 (OR-ELM) 组合在线预测模型,对燃煤-煤气电厂 NO_x 排放质量浓度进行预测。基于现场运行数据的验证表明,VAR-OR-ELM 在线预测模型在不同负荷段下能够对脱硝系统出口 NO_x 质量浓度进行准确的预测;综合预测精度及预测时间,所构建的组合预测模型相较于其他单一预测模型的预测效果更好;同时所提出的注意力机制组合赋权法相较于其他赋权法而言效果更好,能够在长时间的预测中保持更好的预测性能。在实际工程应用中,为燃煤-煤气混合燃烧机组未知煤气掺烧量下对 NO_x 排放的多步预测提供一定的借鉴意义。

[参 考 文 献]

- [1] 李伟. 300 MW 高炉煤气煤粉混燃锅炉 NO_x 特性数值模拟及研究[D]. 保定: 华北电力大学, 2013: 1.
LI Wei. Study and numerical simulation of 300 MW blast furnace gas and pulverized coal blended combustion boiler on the optimizing of NO_x [D]. Baoding: North China Electric Power University, 2013: 1.
- [2] 赵晶. 火电厂 SCR 烟气脱硝系统建模与控制策略研究[D]. 保定: 华北电力大学, 2018: 1.
ZHAO Jing. Research on modeling and control strategy of SCR flue gas denitrification system in thermal power plants[D]. Baoding: North China Electric Power University, 2018: 1.
- [3] 毛剑宏. 大型电站锅炉 SCR 烟气脱硝系统关键技术研究[D]. 杭州: 浙江大学, 2011: 1.
MAO Jianhong. Key technology study of SCR flue gas de NO_x system in large power plant boiler[D]. Hangzhou: Zhejiang University, 2011: 1.
- [4] 谷丽景, 李永华, 李路. 电站锅炉燃烧优化混合模型预测[J]. 中国电机工程学报, 2015, 35(9): 2231-2237.
GU Lijing, LI Yonghua, LI Lu. Hybrid model prediction of utility boiler combustion optimization[J]. Proceedings of the CSEE, 2015, 35(9): 2231-2237.
- [5] IRFAN M F, MJALLI F S, KIM S D. Modeling of NH_3 - NO -SCR reaction over $\text{CuO}/\gamma\text{-Al}_2\text{O}_3$ catalyst in a bubbling fluidized bed reactor using artificial intelligence techniques[J]. Fuel, 2012, 93(1): 245-251.
- [6] 钱虹, 张超凡, 柴婷婷. 基于随机森林的 SCR 脱硝系统出口 NO_x 浓度预测研究[J]. 热能动力工程, 2021, 36(3): 122-129.
QIAN Hong, ZHANG Chaofan, CHAI Tingting. Research on outlet NO_x concentration prediction of SCR denitration system based on random forest algorithm[J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(3): 122-129.
- [7] 王伟同, 范海东, 梁成思, 等. 基于随机森林算法的对冲锅炉出口 NO_x 排放量预测模型研究[J]. 热力发电, 2022, 51(4): 96-104.
WANG Weitong, FAN Haidong, LIANG Chengsi, et al. Predictive modeling of NO_x outlet of hedged boiler based on random forest[J]. Thermal Power Generation, 2022, 51(4): 96-104.
- [8] 许壮, 康英伟. 基于随机森林的火电机组 SCR 脱硝反应器建模[J]. 动力工程学报, 2020, 40(6): 486-491.
XU Zhuang, KANG Yingwei. Modeling of SCR denitrification reactor in a thermal power unit based on

- random forest algorithm[J]. Journal of Chinese Society of Power Engineering, 2020, 40(6): 486-491.
- [9] LIU Q, HU H L. Prediction model of the NO_x emissions based on long short-time memory neural network[C]//2020 Chinese Automation Congress (CAC) in Shanghai, China: IEEE, 2020: 2795-2797.
- [10] 高常乐, 司风琪, 任少君, 等. 基于 LSTM 的烟气 NO_x 浓度动态软测量模型[J]. 热能动力工程, 2020, 35(3): 98-104.
GAO Changle, SI Fengqi, REN Shaojun, et al. Dynamic soft sensing model of NO_x concentration in flue gas based on LSTM[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(3): 98-104.
- [11] 杨国田, 张涛, 王英男, 等. 基于长短期记忆神经网络的火电厂 NO_x 排放预测模型[J]. 热力发电, 2018, 47(10): 12-17.
YANG Guotian, ZHANG Tao, WANG Yingnan, et al. Prediction model for NO_x emissions from thermal power plants based on long-short-term memory neural network[J]. Thermal Power Generation, 2018, 47(10): 12-17.
- [12] 潘红光, 裴嘉宝, 苏涛, 等. 基于 LSTM 的燃煤电厂 NO_x 排量软测量[J]. 西安科技大学学报, 2022, 42(2): 362-370.
PAN Hongguang, PEI Jiabao, SU Tao, et al. LSTM-based soft sensor of NO_x emissions from coal-fired power plants[J]. Journal of Xi'an University of Science and Technology, 2022, 42(2): 362-370.
- [13] 钱虹, 柴婷婷, 张超凡. 基于深度循环神经网络的 SCR 烟气脱硝系统出口 NO_x 排放预测研究[J]. 热能动力工程, 2020, 35(8): 77-84.
QIAN Hong, CHAI Tingting, ZHANG Chaofan. NO_x emission prediction model of SCR flue gas denitrification system based on deep recurrent neural network[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(8): 77-84.
- [14] 谢锐彪, 李新利, 王英男, 等. 基于粒子群优化的双向门控循环神经网络燃煤电厂 NO_x 排放预测[J]. 热力发电, 2021, 50(10): 87-94.
XIE Ruibiao, LI Xinli, WANG Yingnan, et al. NO_x emission prediction of coal-fired power plants based on PSO and Bi-GRU[J]. Thermal Power Generation, 2021, 50(10): 87-94.
- [15] TANG Z, WANG S, CAO S, et al. Dynamic prediction model for NO_x emission at the outlet of SCR system based on extreme learning machine[C]//2020 Chinese Automation Congress (CAC) in Shanghai, China: IEEE, 2020: 3226-3229.
- [16] 程琳, 赵文杰. 基于 GA-ELM 的 SCR 脱硝系统动态建模[J]. 热力发电, 2019, 48(6): 29-33.
CHENG Lin, ZHAO Wenjie. Dynamic modeling of SCR denitrification system based on GA-ELM[J]. Thermal Power Generation, 2019, 48(6): 29-33.
- [17] 唐振浩, 王世魁, 曹生现, 等. 基于混合数据驱动算法的 SCR 氮氧化物排放量动态预测模型[J]. 中国电机工程学报, 2022, 42(9): 3295-3307.
TANG Zhenhao, WANG Shikui, CAO Shengxian, et al. Dynamic prediction model for NO_x emission of SCR system based on hybrid data-driven algorithms[J]. Proceedings of the CSEE, 2022, 42(9): 3295-3307.
- [18] LIU X, LIN Z, FENG Z. Short-term offshore wind speed forecast by seasonal ARIMA-A comparison against GRU and LSTM[J]. Energy, 2021, 227: 120492.
- [19] LI Y J, YUAN X I, XU J Y, et al. Medium-term forecasting of cold, electric and gas load in multi-energy system based on VAR model[C]//2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA). Wuhan: IEEE, 2018: 1676-1680.
- [20] 崔建国, 李鹏程, 崔霄, 等. 基于 ARIMA-LSTM 的飞机液压泵性能趋势预测方法[J]. 振动, 测试与诊断, 2021, 41(4): 735-740.
CUI Jianguo, LI Pengcheng, CUI Xiao, et al. Aircraft hydraulic pump performance trend prediction method based on ARIMA-LSTM[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(4): 735-740.
- [21] 王英伟, 马树才. 基于 ARIMA 和 LSTM 混合模型的时间序列预测[J]. 计算机应用与软件, 2021, 38(2): 291-298.
WANG Yingwei, MA Shucan. Time series forecasting based on ARIMA and LSTM hybrid model[J]. Computer Applications and Software, 2021, 38(2): 291-298.
- [22] 杨锡运, 刘欢, 张彬, 等. 基于熵权法的光伏输出功率组合预测模型[J]. 太阳能学报, 2014, 35(5): 744-749.
YANG Xiyun, LIU Huan, ZHANG Bin, et al. A combination method for photovoltaic power forecasting based on entropy weight method[J]. Acta Energiae Solaris Sinica, 2014, 35(5): 744-749.
- [23] 陈刚, 杨轶. 煤粉和高炉煤气混烧锅炉燃烧问题的分析及改造[J]. 电站系统工程, 2003, 19(2): 36-38.
CHEN Gang, YANG Yi. Technical reform of combustion system in pulverized coal and BFG combustion boiler[J]. Power System Engineering, 2003, 19(2): 36-38.
- [24] 郑峰, 王睿, 宦克为, 等. 粳米近红外光谱模型中基于拉依达准则的异常值剔除方法[C]//第十七届全国分子光谱学学术会议论文集, 2012: 135-136.
ZHENG Feng, WANG Rui, HUAN Kewei, et al. Eliminating abnormal values in keng-rice NIRS modeling based on PauTa criterion[C]//Proceedings of the 17th National Conference on Spectroscopy and Spectral Analysis, 2012: 135-136.
- [25] 陈昭. 时序非平稳性 ADF 检验法的理论与应用[J]. 广州大学学报(自然科学版), 2008(5): 5-10.
CHEN Zhao. ADF test for non-stationary time series: theory and application[J]. Journal of Guangzhou University(Natural Science Edition), 2008(5): 5-10.
- [26] LU G, YU E, WANG Y, et al. A novel hybrid machine learning method (OR-ELM-AR) used in forecast of PM_{2.5} concentrations and its forecast performance evaluation[J]. Atmosphere, 2021, 12(1): 78.
- [27] 王璇. 基于注意力机制双向长短期记忆网络的短期负荷滚动预测方法[D]. 天津: 天津大学, 2019: 1.
WANG Xuan. Short-term load rolling forecasting method based on attention mechanism and Bi-directional long short-term memory network[D]. Tianjin: Tianjin University, 2019: 1.

(责任编辑 杜亚勤)