

基于 EMD—SVR 的火电厂选择性催化还原脱硝系统出口 NO_x 浓度预测研究

王 博, 赵 亮, 赵长春, 党 宁
(西安建筑科技大学 信息与控制工程学院, 西安 710055)

摘要: 针对火电厂选择性催化还原 (selective catalytic reduction, SCR) 脱硝系统出口 NO_x 浓度预测准确率低的问题, 提出一种基于经验模态分解 (empirical mode decomposition, EMD) 和支持向量机回归 (support vector machine for regression, SVR) 的火电厂脱硝系统出口 NO_x 浓度预测模型; 首先, 利用 EMD 算法将出口 NO_x 浓度数据序列进行分解, 得到不同时间尺度下有限个本征模函数 (intrinsic mode function, IMF); 然后引入 SVR 算法对 NO_x 浓度分解数据进行建模预测; 最后, 将所有 IMF 的预测结果求和作为出口 NO_x 浓度的最终预测值; 通过对提出的 EMD—SVR 与标准的 SVR、BP、ELM、EMD—BP 和 EMD—ELM 模型进行对比验证, 结果表明, 基于 EMD—SVR 模型的预测精度较高, 预测结果与真实值相比较, 方向变化统计量 (directional statistics, dstat)、平均绝对百分比误差 (mean absolute percentage error, MAPE) 和均方根误差 (root mean square error, RMSE) 为 0.914、1.51% 和 0.346 mg/Nm³。

关键词: 脱硝系统; NO_x 浓度预测; 经验模态分解; 支持向量机回归

Prediction of NO_x Concentration at outlet of SCR Denitrification System in Thermal Power Plant Based on EMD—SVR

Wang Bo, Zhao Liang, Zhao Changchun, Dang Ning

(College of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: Aiming at the problem of low prediction accuracy of NO_x concentration at the outlet of selective catalytic reduction (SCR) denitrification system in thermal power plants, a prediction model of NO_x concentration at the outlet of denitrification system in thermal power plant based on empirical mode decomposition (EMD) and support vector machine for regression (SVR) was proposed. Firstly, the empirical mode decomposition (EMD) algorithm was used to decompose the data series of NO_x concentration at the outlet of denitrification system in thermal power plants, and a finite number of intrinsic mode functions (IMF) were obtained at different time scales. Then, the SVR algorithm was used to model and predict the decomposition data of NO_x concentration. Finally, the prediction results of all IMFs were added up. The sum is used as the final predictor of the concentration of NO_x at the outlet. By comparing the proposed EMD—SVR with standard SVR, BP, ELM, EMD—BP and EMD—ELM models, the results showed that the prediction accuracy based on EMD—SVR model was higher. Compared with the real values, the directional statistics (Dstat), mean absolute percentage error (MAPE) and root mean square error (RMSE) were 0.914, 1.51% and 0.346 mg/Nm³, respectively.

Keywords: denitrification system; NO_x concentration prediction; empirical mode decomposition; support vector machine for regression

0 引言

随着经济的快速发展, 电力工业发展迅速, 火力发电过程中排放的烟气中含有大量污染空气的物质, 其中 NO_x 是主要污染物之一^[1]。环境空气质量指标 (PM_{2.5}、PM₁₀、SO₂、NO₂、O₃ 和 CO) 中多数指标与 NO_x 有关。目前应

用最多的控制氮氧化物 (NO_x) 的技术为 SCR 脱硝法^[2-6]。针对 SCR 烟气脱硝系统喷氨量的大延迟特性, 通过建立模型与控制器紧密联系的完整脱硝控制体系是未来的发展目标。准确的 NO_x 浓度预测模型可以作为脱硝喷氨系统的前馈。

国内外学者对 SCR 脱硝系统进行了大量研究: 主要分为两大类: 对影响脱硝效率的多因素进行研究和对 SCR 反应器内的催化反应进行研究。对影响脱硝效率的多因素进行研究: 利用机器学习算法对数据集进行训练测试, 构建基于最优参数的 NO_x 浓度预测模型^[7-13]。对 SCR 反应器内的催化反应进行研究: 从物理化学角度定量分析了 NO_x 浓度的变化规律^[14-18]。从国内外研究现状来看, 对影响脱硝效率的多因素进行研究, 分析了更多的影响因素, 实用性

收稿日期: 2019-10-08; 修回日期: 2019-11-01。

基金项目: 国家自然科学基金项目 (51878548, 51209167); 陕西省自然科学基金 (2019JM-474)。

作者简介: 王 博 (1993-), 男, 山东菏泽人, 硕士研究生, 主要从事脱硝系统建模与仿真方向的研究。

赵 亮 (1980-), 男, 陕西西安人, 博士, 副教授, 主要从事控制理论及控制工程方向的研究。

较强；对 SCR 反应器内的催化反应进行研究，催化作用已充分利用，效率很难得到更大的提升。而且，火电厂工况复杂，出口 NO_x 浓度的影响因素较多。当前国内外学者利用多影响因素的方法进行出口 NO_x 浓度预测的研究不多，而且现有的基于多影响因素的出口 NO_x 浓度模型预测精度也需要提升。为了提升火电厂脱硝系统出口 NO_x 浓度的预测精度，提出一种基于 EMD-SVR 的火电厂脱硝系统出口 NO_x 浓度预测模型。首先，利用经验模态分解 (EMD) 算法把出口 NO_x 浓度数据信号分解成不同时间尺度的特征信号；然后利用 SVR 算法对影响出口 NO_x 浓度的数据和分解后出口 NO_x 浓度的数据进行建立模型并进行回归预测。最后，将不同时间尺度的特征信号的预测结果求和作为脱硝系统出口 NO_x 浓度的最终预测值。采用火电厂厂级监控信息系统中实时运行数据进行实验，并与其他预测模型进行了比较，实验结果表明 EMD-SVR 模型对出口 NO_x 浓度具有较高的预测精度。

1 基本原理

1.1 经验模态分解

经验模态分解 (EMD) 方法由黄锬等^[19]提出：将原始数据序列分解成有限个本征模函数 (IMF) 和一个代表原始信号总体趋势的趋势项 (Res)，所分解出来的各个 IMF 分量包含了原始数据的不同时间尺度的局部特征信号。非平稳的原始数据序列经过 EMD 分解成多个平稳信号，这些经过 EMD 分解后得到的各个平稳信号能够表示出 EMD 算法分解前的原始数据信号的动态特性，所以经过 EMD 分解后，使非平稳的原始信号数据能够得到平稳化处理。通过 EMD 分解得到本征模函数 (IMF) 需要满足以下两个约束条件^[20]：(1) 在整个序列数据段内，极值点的个数和过零点的个数必须保持一致或者至多相差一个；(2) 在任何一个数据点，由极大值确定的上包络线和极小值确定的下包络线的平均值必须为零。

取原始数据信号为 $x(t)$ ，EMD 分解步骤^[21]如下。

步骤一：标记出 $x(t)$ 的所有局部极大值点和极小值点，然后使用 3 次样条插值法分别拟合得到原始数据信号的上包络线 $E_1(t)$ 和下包络线 $E_2(t)$ ，通过计算可以得出上下包络线的平均值曲线 $m_1(t)$ ：

$$m_1(t) = \frac{E_1(t) + E_2(t)}{2} \quad (1)$$

步骤二：原始数据信号 $x(t)$ 减去上下包络线的平均值 $m_1(t)$ 得到一个新的数据信号 $h_1(t)$ ：

$$h_1(t) = x(t) - m_1(t) \quad (2)$$

步骤三：判断新的数据信号 $h_1(t)$ 是否满足本征模函数 (IMF) 的条件，若 $h_1(t)$ 不是一个本征模函数 (IMF)，则将 $h_1(t)$ 的上下包络线的平均值曲线定义为： $m_{11}(t)$ ，将 $h_1(t)$ 减去 $m_{11}(t)$ ，得到 $h_{11}(t)$ ：

$$h_{11}(t) = h_1(t) - m_{11}(t) \quad (3)$$

重复公式 (3) k 次，有：

$$h_{1k}(t) = h_{1(k-1)}(t) - m_{1k}(t) \quad (4)$$

式 (4) 中， $h_{1k}(t)$ 为第 k 次分解得到的信号， $h_{1(k-1)}(t)$ 为第 $k-1$ 次分解得到的信号， $m_{1k}(t)$ 为 $h_{1k}(t)$ 的平均包络线。当满足 IMF 条件时， $h_{1k}(t)$ 变为第一个 IMF 分量，记为 $f_1(t)$ 。

步骤四：用原始数据信号 $x(t)$ 减去 $f_1(t)$ 得到一个残余量信号 $r_1(t)$ ：

$$r_1(t) = x(t) - f_1(t) \quad (5)$$

将残余量信号 $r_1(t)$ 看作是新的数据信号 $x(t)$ ，重复上述步骤，可依次得到 $f_2(t), f_3(t), \dots$ 。当 $r_n(t)$ 变成常量或者单调函数时，EMD 分解结束，此时 $r_n(t)$ 称为趋势项，它表示原始数据信号的总体趋势。即原始数据信号 $x(t)$ 可表示为一组 IMF 分量和一个趋势项的和：

$$x(t) = \sum_{j=1}^n f_j(t) + r_n(t) \quad (6)$$

数据 $h_{1(k-1)}(t), h_{1k}(t)$ 之间的标差 SD 停止定义是：

$$SD = \sum_{t=0}^T \left[\frac{|(h_{1(k-1)}(t) - h_{1k}(t))|^2}{h_{1k}^2(t)} \right] \quad (7)$$

SD 的取值范围一般设为 $[0.2, 0.3]$ 。

1.2 支持向量机回归

支持向量机 (SVM) 是一种基于统计学习理论的机器学习方法，它是由 Corinna 和 Vapnik 于 1995 年提出的^[22]。与传统神经网络相比，SVM 在样本少、非线性、高维特征空间及局部最优问题上具有优势。支持向量机回归 (SVR) 是在 SVM 分类的基础上产生的，它对非线性时间序列存在稳定的预测能力^[23]。设含有 n 个训练样本的训练集样本对为 $\{(x_i, y_i), i = 1, 2, 3, \dots, n\}$ ，其中， $x_i (x_i \in R^d)$ 是第 i 个训练样本的输入列向量， $x_i = [x_i^1, x_i^2, x_i^3, \dots, x_i^d]^T, y_i \in R$ 是相应的输出值。SVR 函数为：

$$f(x) = \omega \varphi(x) + b \quad (8)$$

式 (8) 中， $\varphi(x)$ 为非线性映射函数， ω 为权重向量， b 为常数。

SVM 的基本思想是为了把两类样本分开寻找一个最优分类面，而 SVR 的基本思想是为了得到一个距离所有训练样本误差最小的最优分类面。在统计学习原理中运用结构风险最小化原理，优化问题的目标函数即为：

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (9)$$

$$s.t. \begin{cases} y_i - \omega^T \cdot x_i - b \leq \varepsilon + \xi_i \\ \omega^T \cdot x_i + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0 \\ \xi_i^* \geq 0, i = 1, 2, \dots, n \end{cases}$$

式 (9) 中， $\min \frac{1}{2} \|\omega\|^2$ 是为了保证最大间隔分类， ξ_i, ξ_i^* 表示松弛变量， C 表示正则化常数。

通过引入拉格朗日乘子 $u_i \geq 0, u_i \geq 0, a_i \geq 0, a_i \geq 0$ ，使用拉格朗日乘子法可得到的非线性回归函数：

$$f(x) = \sum_{i=1}^n (\hat{a} - a_i) k(x, x_i) + b \quad (10)$$

式(10)中, $k(x, x_i)$ 是映射函数, 我们选用核参数为 σ 的高斯径向基函数 (Radial Basis Function, RBF) 来作为 SVR 的映射函数, 即: $k(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right)$ 。

1.3 EMD-SVR 预测模型

火电厂 SCR 脱硝系统出口 NO_x 浓度数据序列是非平稳信号, 它受多种运行因素影响。通过将经验模态分解和支持向量机回归 (EMD-SVR) 结合, 构建基于 EMD-SVR 的火电厂 SCR 脱硝系统出口 NO_x 浓度预测模型。EMD-SVR 预测模型结构图如图 1 所示。EMD-SVR 预测模型结构图的过程可以归纳为以下四个步骤。

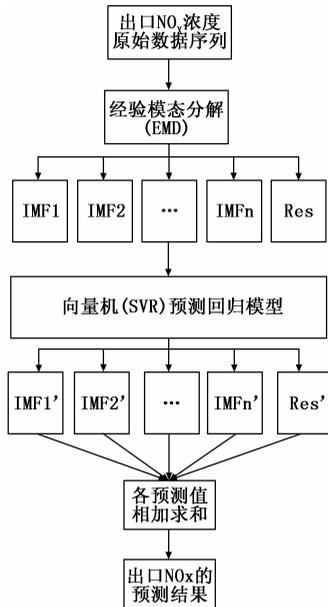


图1 EMD-SVR 预测模型结构图

步骤一: 从某火电厂厂级监控信息系统得到脱硝入口烟气温度、脱硝进出口压差、脱硝氨气流量、脱硝入口 NO_x 浓度、脱硝稀释风流量、机组负荷, 脱硝出口 NO_x 浓度数据, 并对得到的数据进行预处理分析。

步骤二: 利用 EMD 分解算法对脱硝系统出口 NO_x 浓度数据序列进行分解, 得到一组 IMF 分量和一个趋势项 Res。

步骤三: 确定输入变量和输出变量, 并利用 SVR 算法进行训练。其中脱硝入口烟气温度、脱硝进出口压差、脱硝氨气流量、脱硝入口 NO_x 浓度、脱硝稀释风流量、机组负荷作为输入变量, 输出值为未来 1 h 的脱硝系统出口 NO_x 浓度数据。

步骤四: 把 IMF 分量和趋势项 Res 的预测结果求和, 作为基于 EMD-SVR 的火电厂 SCR 脱硝系统出口 NO_x 浓度的最终预测结果。

2 实验分析

2.1 评价指标

为验证模型的预测性能, 利用方向变化统计量 (Dstat)、平均绝对百分比误差 (MAPE) 和均方根误差

(RMSE) 3 个指标来衡量各模型的预测结果, 三个评价指标的计算公式如下:

$$D_{stat} = \frac{1}{n} \sum_{t=1}^n a_t \times 100\%$$

$$\begin{cases} a_t = 1 & \text{if } (y_{t+1} - y_t)(\hat{y}_{t+1} - y_t) \geq 0, \\ a_t = 0 & \text{otherwise} \end{cases} \quad (11)$$

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{\hat{y}(t) - y(t)}{y(t)} \right| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}(t) - y(t))^2} \quad (13)$$

式中, n 是测试集的数量, $y(t)$ 是出口 NO_x 浓度数据的真实值, $\hat{y}(t)$ 是出口 NO_x 浓度数据的预测值。

2.2 数据选取和对比模型表述

从 2019 年 5 月 1 日至 2019 年 5 月 8 日的前 180 h 采集到的脱硝系统运行参数数据作为实验数据 (选取实验数据的前 80% 作为训练数据, 剩下的 20% 为测试数据), 其中实验数据的采样周期为 2 min/次, 所采集的项目包括脱硝入口烟气温度、脱硝进出口压差、脱硝氨气流量、脱硝入口 NO_x 浓度、脱硝稀释风流量、机组负荷和脱硝出口 NO_x 浓度数据, 所采集的项目数据都来自于火电厂厂级监控信息系统提供的实时运行信息。采样周期内参数范围、部分参数数据分别如表 1 和表 2 所示。

表 1 采样周期内参数范围

项目	上限	下限
脱硝入口烟气温度/(°C)	600	0
脱硝进出口压差/(Pa)	1500	0
脱硝氨气流量/(kg/h)	160	0
脱硝入口 NO _x 浓度/(mg/Nm ³)	1000	0
脱硝稀释风流量/(m ³ /h)	8000	0
机组负荷/(MW)	350	0
脱硝出口 NO _x 浓度/(mg/Nm ³)	300	0

脱硝系统运行参数数据的预处理分为 2 个步骤。

1) 小时数据平均:

由于 1 h 内脱硝系统运行参数数据的数值变化较小, 因此将脱硝系统运行参数数据按小时平均进行平滑处理, 因为采集周期为每 2 min 采集一次数据, 所以脱硝系统运行参数数据每小时数据值 X_h 即每 30 个采样点进行一次平均:

$$X_h = \frac{X_1 + X_2 + \dots + X_{30}}{30} \quad (14)$$

2) 归一化处理:

由于脱硝系统运行参数的量纲差别较大, 为提高预测的准确性, 对脱硝系统运行参数数据进行归一化处理, 计算式为:

$$Y^* = \frac{(Y_{\max} - Y_{\min}) * (X - X_{\min})}{X_{\max} - X_{\min}} + Y_{\min} \quad (15)$$

式中, $Y_{\max} = 1$, $Y_{\min} = -1$, X_{\max} - 最大值, X_{\min} - 最小值, Y^* - 归一化值。

表 2 采样周期内部分参数数据

时间点	脱硝入口烟气温度/℃	脱硝进出口压差/Pa	脱硝氨气流量/(kg/h)	脱硝入口 NO _x 浓度/(mg/Nm ³)	脱硝稀释风流量/(m ³ /h)	机组负荷/MW	脱硝出口 NO _x 浓度/(mg/Nm ³)
2019.05.01 00:00	370.80	333.99	87.30	550.17	5807.37	166.33	17.89
2019.05.01 01:00	370.70	330.09	86.82	543.80	5764.40	166.70	17.62
2019.05.01 02:00	370.70	332.85	87.68	542.60	5752.31	166.34	16.63
2019.05.01 03:00	370.70	341.52	85.80	543.89	5751.47	166.86	17.92
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2019.05.08 22:00	371.30	343.11	84.34	546.51	5820.80	163.95	14.29
2019.05.08 23:00	371.30	346.68	82.61	549.08	5738.62	163.84	14.86

为验证 EMD-SVR 预测模型的性能, EMD-SVR 预测模型除了与标准 SVR 模型、BP 模型、ELM 模型进行实验对比外, 还选择了与 EMD-BP 模型、EMD-ELM 模型进行实验对比。

2.3 预测结果及分析

利用 EMD-SVR 预测模型对未来 1 h 的脱硝系统出口 NO_x 浓度预测, 基于 EMD 的出口 NO_x 浓度序列分解结果如图 2 所示。

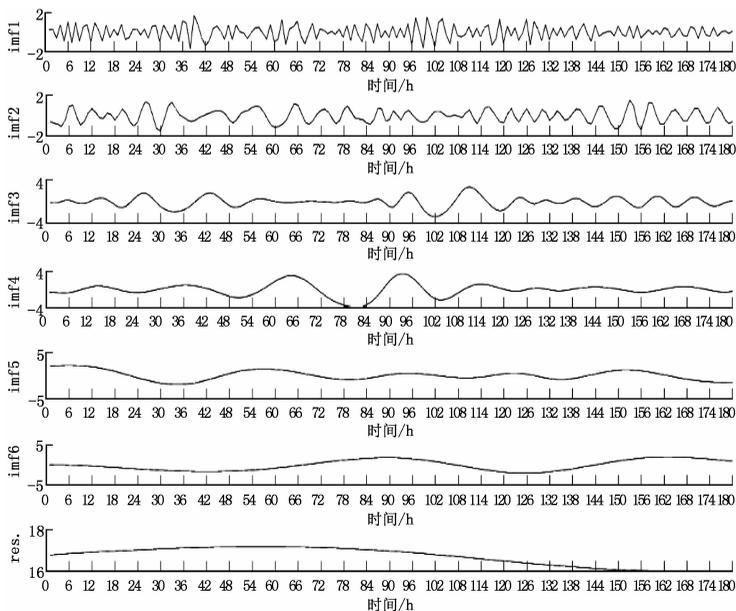


图 2 基于 EMD 的出口 NO_x 浓度序列分解结果

实验流程如图 1 所示, 利用 SVR 模型对 EMD 分解所得的各 IMF 分量和趋势项 Res 进行训练和预测, 利用遗传算法不断优化调整预测模型参数 c 和 g , 然后对各 IMF 分量和趋势项 Res 的预测结果相加得到脱硝系统出口 NO_x 浓度最终预测结果。

提出的 EMD-SVR 预测模型分别与标准 SVR 模型、BP 模型、ELM 模型、EMD-BP 模型和 EMD-ELM 模型进行对比分析, 各预测模型的预测结果如图 3 所示。

通过对比图 3 中真实值与各预测值曲线, 直观上看, SVR、BP 和 ELM 的预测结果都不理想, 部分时间点预测值出现严重误差; 相比于 SVR 模型、BP 模型和 ELM 模型, EMD-SVR 模型、EMD-BP 模型和 EMD-ELM 模型的预测精度大幅度提高; 在这些混合模型中, 将 EMD 的数据处理能力和 SVR 的非线性拟合能力相结合的 EMD-SVR 模型的预测结果最好, 与 NO_x 浓度真实值基本一致。表 3 为不同模型的评价指标比较。

表 3 不同模型的评价指标比较

	Dstat	MAPE/(%)	RMSE(mg/Nm ³)
SVR	0.543	4.97	1.102
BP	0.457	5.72	1.270
ELM	0.514	5.75	1.343
EMD-SVR	0.914	1.51	0.346
EMD-BP	0.857	2.03	0.420
EMD-ELM	0.829	1.85	0.385

由表 3 可知, EMD-SVR 模型的预测精度最高, Dstat, MAPE 和 RMSE 分别为 0.914、1.51% 和 0.346 mg/Nm³, 与 SVR 模型相比, Dstat 提高了 68.3%, MAPE 和 RMSE 分别降低了 69.6% 和 68.6%; 与 BP 模型相比 Dstat 提高了 100%, MAPE 和 RMSE 分别降低了 73.6% 和 72.8%; 与 ELM 模型相比, Dstat 提高了 77.8%, MAPE 和 RMSE 分别降低了 73.7% 和 74.2%; 与 EMD-BP 模型相比, Dstat 提高了 6.65%, MAPE 和 RMSE 分别降低了 25.6% 和 17.6%; 与 EMD-ELM 模型相比, Dstat 提高了 10.30%, MAPE 和 RMSE 分别降低了 18.4% 和 10.1%。综合来看, EMD-SVR 模型与其他全部对比模型相比, Dstat 平均提高了

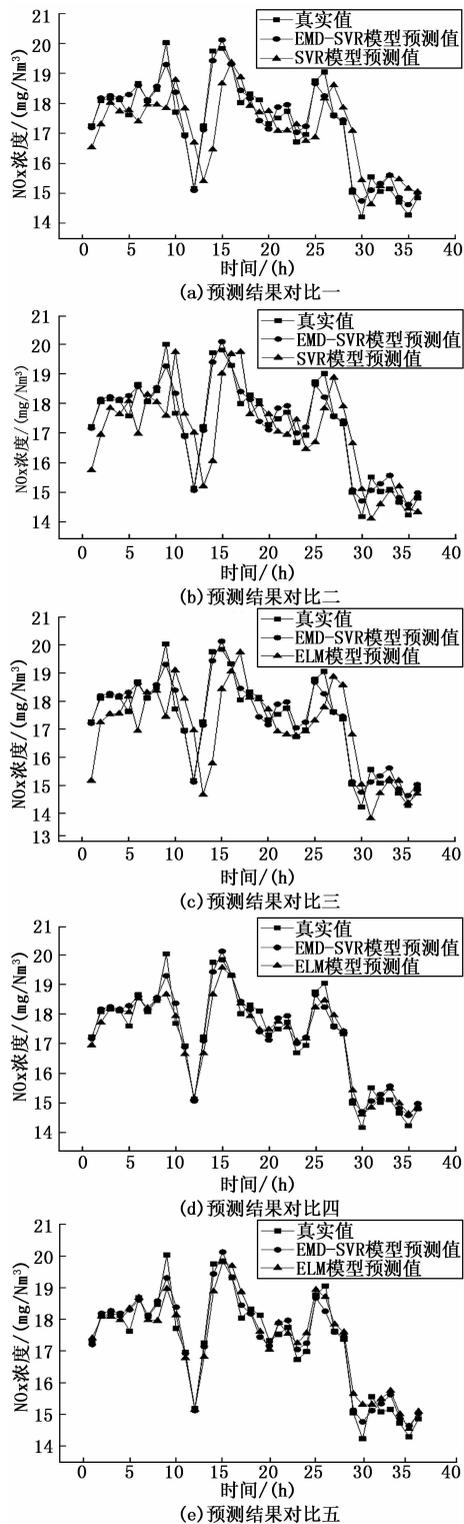


图3 不同模型的预测结果对比

52.61%, MAPE 和 RMSE 分别平均降低了 52.18% 和 48.66%。由此, 基于 EMD-SVR 的 NO_x 浓度预测模型比其他混合模型预测精度更高, 预测结果明显优于单一 NO_x 预测模型, 该模型在提高火电厂 SCR 脱硝系统 NO_x 浓度预测准确率方面具有显著优势。

3 结束语

通过实验对比研究, 得出以下两个结论: (1) EMD-SVR 模型与 SVR、BP、EMD-BP 和 EMD-ELM 模型相比, 出口 NO_x 浓度预测效果最好, 最接近现场真实值; (2) 由于经验模态分解技术可以有效地消除与出口 NO_x 浓度数据序列相关的非平稳特性, 因此, 基于经验模态分解技术的混合预测模型比单一预测模型表现更好。

参考文献:

- [1] 马北玲, 吕欣, 陈星, 等. 火电厂大气排放监测大数据分析 & 政策影响研究 [J]. 中国人口·资源与环境, 2019, 29 (7): 73-79.
- [2] Shin S B, Skau K I, Menon M, et al. A modelling approach to kinetics study and novel monolith channel design for selective catalytic reduction (SCR) applications [J]. Chemical Engineering Research & Design, 2019, 142: 412-428.
- [3] Chen H, He H, Wan Y, et al. Research progress of coal-fired flue gas denitrification technology [J]. Applied Chemical Industry, 2019, 48 (5): 1146.
- [4] 牛玉广, 潘岩, 李晓彬. 火力发电厂烟气 SCR 脱硝自动控制研究现状与展望 [J]. 热能动力工程, 2019, 34 (4): 1-9.
- [5] 庄焯, 张东辉, 褚玥, 等. SCR 脱硝在燃煤电厂超低排放中的适用性分析 [J]. 环境工程学报, 2017, 11 (7): 4183-4189.
- [6] Kang L I U, Zhi-Jun X, Xiao-De T a N, et al. Application for selective catalytic reduction technology for flue gas denitrification [J]. Electric Power, 2009, 42 (8): 75-79.
- [7] 吕游, 刘吉臻, 杨婷婷, 等. 基于 PLS 特征提取和 LS-SVM 结合的 NO_x 排放特性建模 [J]. 仪器仪表学报, 2013, 34 (11): 2418-2424.
- [8] 赵毅, 周建国, 梁怀涛. 基于灰色支持向量机组合模型的我国火电 NO_x 排放量预测 [J]. 环境科学研究, 2011, 24 (5): 489-496.
- [9] 王林, 侯玉婷, 薛建中, 等. 基于主元分析的 SCR 烟气脱硝系统入口 NO_x 生成量预测模型 [J]. 热力发电, 2015, 44 (8): 84-89.
- [10] 李楠, 卢钢, 李新利, 等. 基于集成深度玻尔兹曼机和最小二乘支持向量回归的燃烧过程 NO_x 预测算法 [J]. 动力工程学报, 2016, 36 (8): 615-620.
- [11] 唐振浩, 张海洋, 曹生现. 变负荷工况下 NO_x 排放量预测控制 [J]. 化工进展, 2018, 37 (1): 343-349.
- [12] 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.
- [13] Fengqi Si, Carlos E. Romero, Zheng Yao, Eugenio Schuster, Zhigao Xu, Robert L. Morey, Barry N. Liebowitz. Optimization of coal-fired boiler SCR based on modified support vector machine models and genetic algorithms [J]. Fuel, 2008, 88 (5).
- [14] Hsunling Bai, Jong-Wen Chwu. Theoretical Analysis of Selective Catalytic Reduction Catalysts [J]. Journal of Environmental Engineering, 1997, 123 (5).