

doi: 10.7690/bgzdh.2023.12.016

基于 MI-PCA 和 ML-AE-ELM 的脱硝系统入口 NO_x 质量浓度预测

靳 果^{1,2}, 屈保中^{1,2}, 朱清智^{1,2}(1. 河南工业职业技术学院自动化工程学院, 河南 南阳 473000;
2. 河南工业职业技术学院河南省工业机器人应用工程技术研究中心, 河南 南阳 473000)

摘要: 为提高脱硝系统入口氮氧化物(nitrogen oxide, NO_x)质量浓度的预测精度, 提出一种基于互信息的主成分分析(principal component analysis, PCA)和多层自编码结构的极限学习机(extreme learning machine, ELM)组合算法的预测模型。对输入变量的选取方式进行完善, 并加入历史NO_x质量浓度, 对预测算法的网络结构进行优化。实验结果表明: 与其他预测算法模型相比, 该模型具有较高的预测效率, 在不同工况下均具有较高的预测精度, 表现出良好的抗噪能力和泛化能力。

关键词: 脱硝系统; NO_x质量浓度; 互信息; 主成分分析; 极限学习机; 预测模型**中图分类号:** TP272 **文献标志码:** A

Prediction of NO_x Mass Concentration at Inlet of Denitrification System Based on MI-PCA and ML-AE-ELM

Jin Guo^{1,2}, Qu Baozhong^{1,2}, Zhu Qingzhi^{1,2}(1. School of Automation Engineering, He'nan Polytechnic Institute, Nanyang 473000, China;
2. He'nan Engineering Research Center of Industrial Robot Application,
He'nan Polytechnic Institute, Nanyang 473000, China)

Abstract: In order to improve the prediction accuracy of nitrogen oxides (NO_x) mass concentration at the inlet of denitrification system, a combination algorithm prediction model of principal component analysis (PCA) and an extreme learning machine (ELM) with multi-layer self-coding structure based on mutual information is proposed. The selection of input variables is improved, and the network structure of the prediction algorithm is optimized by adding the historical NO_x mass concentration. The experimental results show that compared with other prediction algorithm models, the proposed model has higher prediction efficiency and higher prediction accuracy under different working conditions, and shows good anti-noise ability and generalization ability.

Keywords: denitrification system; NO_x mass concentration; MI; PCA; ELM; prediction model

0 引言

近些年, 我国对燃煤发电机组氮氧化物(NO_x)排放量的要求日益严格, 利用选择性催化还原(selective catalytic reduction, SCR)技术的脱硝系统在测量入口NO_x质量浓度的过程中有较大迟延和惯性^[1], 而且NO_x含量波动频繁^[2], 因此, 采用预测技术建立准确有效的入口NO_x质量浓度预测模型对NO_x排放具有重要意义。

1) NO_x质量浓度受多种变量因素影响, 且变量间相互耦合^[3]。主成分分析(PCA)算法可以降低输入变量维度^[4]; 但是PCA主要运用于线性系统。核主成分分析(kernel principal component analysis, KPCA)、互信息(mutual information, MI)算法可以弥补非线性问题的不足^[5-6], 但是这些算法没有考

虑到NO_x质量浓度在不同系统中或者同一系统的不同时段, 所对应的主导变量并不完全相同这一问题。

2) 脱硝系统具有大迟延的特点^[7], 笔者选取的某火电厂锅炉燃烧时间不超过20 min; 因此, 设计预测结果为未来20 min内的入口NO_x质量浓度值。

3) 脱硝系统具有大惯性的特点, 在预测模型的输入变量中加入历史NO_x质量浓度值^[8]进行训练和预测, 以提高预测精度。

4) 人工神经网络(artificial neural network, ANN)及其优化算法的拟合能力较强, 但结构复杂, 容易陷入局部收敛^[9]; 遗传算法(genetic algorithm, GA)和随机森林(random forest, RF)算法对输入变量的数据量要求较高^[10-11]; 支持向量机(support vector machine, SVM)及其优化算法具有较好的泛

收稿日期: 2023-08-15; 修回日期: 2023-09-05

基金项目: 河南省2021年科技发展计划(212102210527); 2022年度河南省高等学校重点科研项目(22A120004); 2020年南阳市科技计划项目(KJGG207)

第一作者: 靳果(1985—), 男, 河南人, 硕士。

化能力, 但是容易陷入局部最优^[12]; 长短期记忆 (long and short term memory, LSTM) 算法的预测模型结果稳定, 但结构复杂, 需要优化的参数较多^[13]; 极限学习机 (ELM) 算法可以得到较高的预测精度和效率, 但网络结构需要进一步优化^[14-15]。

针对上述问题, 笔者提出一种基于互信息的 PCA 和结构优化的 ELM 组合算法的脱硝系统入口 NO_x 质量浓度预测模型。通过加入历史 NO_x 质量浓度数据、数据标准化、主导变量提取、预测算法结构优化等步骤预测未来 20 min 内的 NO_x 质量浓度。基于某火电厂的现场运行数据, 对笔者所提的预测模型进行算例仿真, 验证预测模型的应用效果。

1 预测算法

影响脱硝系统入口 NO_x 质量浓度的相关因素^[16]涉及多个变量, 通过互信息和主成分分析可以筛选出与 NO_x 质量浓度相关性最大的变量, 提高预测模型运算速率和精度; 多层自编码极限学习机具有多层隐层的网络结构, 需要通过实验进一步明确隐层数和节点数。

1.1 基于互信息的主成分分析

笔者使用的某火电厂监控系统原始数据变量共 57 个, 包括输出变量——NO_x 质量浓度以及与其相关的输入变量——机组负荷、总煤量、总风量、二次风风门开度、磨煤机瞬时煤量、磨煤机一次风压、磨煤机一次风温等共 56 个, 且各输入变量之间存在一定的相关性, 为准确描述影响 NO_x 质量浓度各输入变量之间的关系, 得到最佳的输入变量降维结果, 提出一种基于互信息的主成分分析算法^[17]。

1) 假设样本数量为 n , 每个样本包括 m 个变量, 则全部样本构成的指标矩阵为:

$$\mathbf{x} = \begin{bmatrix} x_{11} & \cdots & x_{1j} & \cdots & x_{1n} \\ \vdots & & \vdots & & \vdots \\ x_{i1} & \cdots & x_{ij} & \cdots & x_{in} \\ \vdots & & \vdots & & \vdots \\ x_{m1} & \cdots & x_{mj} & \cdots & x_{mn} \end{bmatrix} = \begin{bmatrix} \mathbf{x}_1 \\ \vdots \\ \mathbf{x}_i \\ \vdots \\ \mathbf{x}_m \end{bmatrix}。 \quad (1)$$

式中: x_{ij} 为第 j 个样本的第 i 个变量; \mathbf{x}_i 为每个样本的第 i 个变量构成的向量 ($i=1, 2, \dots, m$; $j=1, 2, \dots, n$)。

2) 计算原始样本指标矩阵 \mathbf{x} 的标准化矩阵 \mathbf{x}^* , 则 x_{ij}^* 和 \mathbf{x}_i^* 分别表示 x_{ij} 和 \mathbf{x}_i 的标准化结果。

3) 根据标准化矩阵 \mathbf{x}^* 计算互信息矩阵:

$$\mathbf{R} = \begin{bmatrix} r_{11} & \cdots & r_{1q} & \cdots & r_{1m} \\ \vdots & & \vdots & & \vdots \\ r_{p1} & \cdots & r_{pq} & \cdots & r_{pm} \\ \vdots & & \vdots & & \vdots \\ r_{m1} & \cdots & r_{mq} & \cdots & r_{mm} \end{bmatrix}; \quad (2)$$

$$r_{pq} = \sum_{x_{ph}^* \in \mathbf{x}_p^*} \sum_{x_{qh}^* \in \mathbf{x}_q^*} f(x_{ph}^*, x_{qh}^*) \log_2 \frac{f(x_{ph}^*, x_{qh}^*)}{f(x_{ph}^*) f(x_{qh}^*)}。 \quad (3)$$

式中: r_{pq} 为第 p 个变量与第 q 个变量的互信息值, 且 $r_{pq}=r_{qp}$ ($p, q=1, 2, \dots, m$); $f(x_{ph}^*, x_{qh}^*)$ 为变量 \mathbf{x}_p^* 和 \mathbf{x}_q^* 的联合概率分布函数, $f(x_{ph}^*)$ 为变量 \mathbf{x}_p^* 的边缘概率分布函数, $f(x_{qh}^*)$ 为变量 \mathbf{x}_q^* 的边缘概率分布函数。

4) 计算 \mathbf{R} 的特征值并排序: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$, 以及 λ_i 对应的特征向量 \mathbf{u}_i ($i=1, 2, \dots, m$)。

5) 计算每个主成分的贡献率, 以及前 t 个主成分的累计贡献率。

当累计贡献率超过一定数值(笔者取 0.9)后, 则认为可以用这 t 个主成分表示原始输入变量, 即:

$$\left. \begin{array}{l} y_1 = u_{11}x_1 + u_{12}x_2 + \dots + u_{1m}x_m \\ y_2 = u_{21}x_1 + u_{22}x_2 + \dots + u_{2m}x_m \\ \vdots \\ y_t = u_{t1}x_1 + u_{t2}x_2 + \dots + u_{tm}x_m \end{array} \right\}。 \quad (4)$$

式中: y_1, y_2, \dots, y_t 表示新的指标变量; x_1, x_2, \dots, x_m 表示原始指标变量, 通常情况下 $t < m$ 。

1.2 多层自编码极限学习机

ELM 由输入层、隐层和输出层组成, 各层之间采用随机生成的权值矩阵和偏置向量, 网络结构中容易引入非最优的随机模型参数, 导致部分网络节点无效。笔者采用自编码极限学习机 (auto-encoder ELM, AE-ELM), 避免了随机参数的引入, 克服了 ELM 节点无效的问题^[18]。

假设样本空间为 $\{\mathbf{x}_j \mathbf{y}_j\}^T$, 样本数量为 N , 即样本输入矩阵和输出矩阵分别为 $\mathbf{X}=[\mathbf{x}_1 \dots \mathbf{x}_j \dots \mathbf{x}_N]$ 和 $\mathbf{Y}=[\mathbf{y}_1 \dots \mathbf{y}_j \dots \mathbf{y}_N]$, 其中 \mathbf{x}_j 和 \mathbf{y}_j 分别表示第 j 组样本的输入向量和输出向量。

首先, 令 $\mathbf{X}=\mathbf{Y}=[\mathbf{x}_1 \ \mathbf{x}_2 \dots \mathbf{x}_N]$, 如图 1 所示, 在输入层与隐层之间引入正交权值矩阵 \mathbf{W} 和偏置向量 \mathbf{b} , 其中 $\mathbf{W}=[\mathbf{w}_1 \ \dots \ \mathbf{w}_s \ \dots \ \mathbf{w}_t]^T$, \mathbf{w}_s 表示所有输入层节点与隐层第 s 个节点之间的正交随机权值向量, $\mathbf{b}=[b_1 \ b_2 \ \dots \ b_t]$ 。

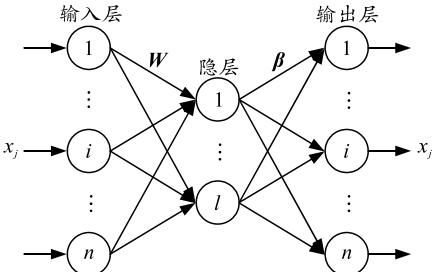


图 1 AE-ELM 算法

可得：

$$\mathbf{H} = \begin{bmatrix} f(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) & \cdots & f(\mathbf{w}_l \cdot \mathbf{x}_1 + b_l) \\ \vdots & & \vdots \\ f(\mathbf{w}_1 \cdot \mathbf{x}_n + b_1) & \cdots & f(\mathbf{w}_l \cdot \mathbf{x}_n + b_l) \end{bmatrix}。 \quad (5)$$

式中： \mathbf{H} 为隐层的输出矩阵； $f(x)$ 为激活函数。

其次，通过 $\mathbf{X} = \beta\mathbf{H}$ 将 \mathbf{H} 重构为 \mathbf{X} ， β 可由下式求出：

$$\beta = \mathbf{X}(\mathbf{I}/C + \mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T。 \quad (6)$$

式中： \mathbf{I} 为单位矩阵； C 为正则项系数。

利用最小二乘法，并用 \mathbf{Y} 代替式(6)中的 \mathbf{X} 得到 β^* ，即：

$$\beta^* = \mathbf{Y}(\mathbf{I}/C + \mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T。 \quad (7)$$

最后，将 β^T (β 的转秩矩阵) 作为网络结构中输入层与隐层的权值矩阵， β^* 作为网络结构中隐层与输出层的权值矩阵，如图 2 所示。

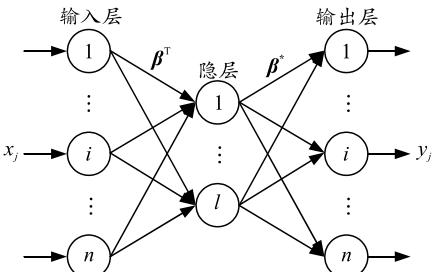


图 2 AE-ELM 结构

多层自编码极限学习机 (multi-layer AE-ELM, ML-AE-ELM) 以 AE-ELM 算法和结构为基础，网络结构包含多层隐层，如图 3 所示。

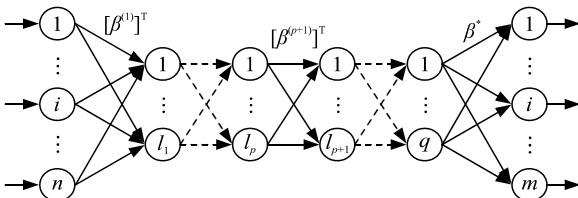


图 3 ML-AE-ELM 网络结构

2 实验结果与分析

笔者采用 Matlab 完成脱硝系统入口 NOx 质量浓度预测模型的仿真实验，从预测效率和精度等方

面对算法模型进行评价，并将笔者所提预测算法模型与 BP 算法、SVM 算法和 LSTM 算法模型进行对比。

2.1 评价指标

笔者采用训练时间和预测时间表征预测模型的工作效率，采用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) 表征预测模型的预测精度，其中：

$$MAPE = \frac{1}{N} \sum_{i=1}^N |(y_{ai} - y_{fi}) / y_{ai}|； \quad (8)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{ai} - y_{fi})^2}。 \quad (9)$$

式中： N 为待测样本个数； y_{ai} 和 y_{fi} 分别为第 i 个待测样本的实际值和预测值。

2.2 ML-AE-ELM 网络结构设置

笔者通过实验确定 ML-AE-ELM 的最优网络结构。首先设置隐层数为 1，隐层节点数从 50 开始，并以 50 为变化步长，得到每个节点数对应的 MAPE 值和 RMSE 值，当评价指标达到极小值点时，对应的节点数为第 1 层的最优节点数，然后以此为基础增加一层新的隐层并采用相同的方法确定该层的最佳节点数，以此类推可以得到最佳的网络结构参数。实验中，评价指标数值取多次实验结果的平均值。

表 1 为不同总层数下，对应的 ML-AE-ELM 最优网络结构。实验结果发现，当总层数为 5 时，预测误差最小，训练和测试时间较短。隐层数不足会带来网络结构缺失，造成预测误差值增大；隐层数过多会引起训练和预测时间的增加，同时会产生过度拟合现象，造成误差值的增大。当 ML-AE-ELM 网络结构为“输入层—隐层 (400—1 250—700—750—750)—输出层”时，可以得到最佳的预测效率和精度。

2.3 算例分析

选取某火电厂脱硝系统 2 400 组原始数据，采样时间连续但不包括吹扫时刻，采样周期为 5 s。训练样本用于确定最优的网络结构参数，共 1 920 组，其中第 1 个训练样本的输入和输出变量分别为第 1 组原始数据的 57 个原始变量和第 241 组的 NOx 质量浓度值，第 2 个训练样本的输入和输出变量分别为第 2 组原始数据的 57 个原始变量和第 242 组的入

口 NO_x 质量浓度值, 其余样本以此类推。测试样本用于预测未来 240 个采样点的 NO_x 质量浓度值, 共 240 个, 取第 1 921~2 160 组的 57 个原始变量。对

比样本的 NO_x 质量浓度作为真实值与预测值进行对比, 共 240 个, 取第 2 161~2 400 组数据的 NO_x 质量浓度值。

表 1 ML-ELM-AE 在不同总层数下的最优节点数

ML-ELM-AE 网络隐层层数									MAPE/%	RMSE/kW	训练时间/s	测试时间/s
$k=1$	$k=2$	$k=3$	$k=4$	$k=5$	$k=6$	$k=7$	$k=8$	$k=9$				
400	—	—	—	—	—	—	—	—	1.59	11.68	0.83	0.35
400	1 250	—	—	—	—	—	—	—	1.34	10.47	2.65	0.86
400	1 250	700	—	—	—	—	—	—	1.29	10.10	1.84	0.67
400	1 250	700	750	—	—	—	—	—	1.24	9.76	2.93	1.01
400	1 250	700	750	750	—	—	—	—	1.12	8.79	3.85	1.09
400	1 250	700	750	750	750	—	—	—	1.30	10.15	5.62	1.28
400	1 250	700	750	750	750	750	—	—	1.37	10.73	6.89	1.46
400	1 250	700	750	750	750	750	750	—	1.42	11.07	7.58	1.53
400	1 250	700	750	750	750	750	750	750	1.46	11.41	7.83	1.69

预测模型的运算流程如图 4 所示, 分别对脱硝系统在稳工况和变工况 2 种工作条件下的入口 NO_x 质量浓度值进行预测, 并与 BP 算法、SVM 算法、LSTM 算法模型进行对比。为提高实验结果的准确度, 避免偶然性影响预测结果, 所有实验数据均为同一条件下运行 20 次的算数平均值。

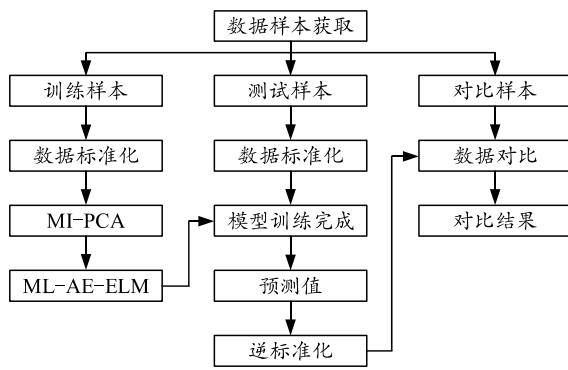


图 4 预测流程

2.3.1 预测模型效率分析

为验证预测模型的运行效率, 选取训练时间和测试时间作为评价指标。表 2 为各种算法模型的训练时间和测试时间实验结果, 其中, “本文中模型*”表示在利用本文中预测模型过程中, 输入变量未经过 MI-PCA 算法处理, 直接代入 ML-AE-ELM 算法。

表 2 不同算法模型的效率值 s

项目	BP	SVM	LSTM	本文中模型	本文中模型*
训练时间	3.08	3.66	5.38	3.85	25.43
测试时间	0.87	1.02	1.38	1.09	17.31

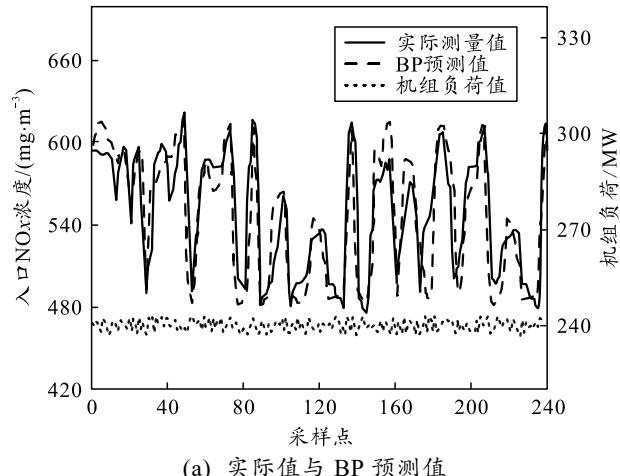
通过对不同算法模型的训练和测试时间可以发现: 本文中预测模型的训练和测试时间略长于 BP

模型和 SVM 模型, 原因是本文中预测模型所选取的输入和输出变量为脱硝系统的原始变量, 未经过筛选处理, 需要经过 MI 和 PCA 算法进行冗余信息去除和变量降维, 而 BP 模型、SVM 模型的输入和输出变量已经经过筛选, 变量数量的减少带来了运算效率的优势, LSTM 模型结构复杂, 待确定的结构参数较多造成运行时间较长。同时, 实验结果也表明了 MI-PCA 算法在本文中预测模型中的重要作用, 未经 MI-PCA 算法处理的原始变量分别需要 25.43 和 17.31 s 完成训练和测试, 不利于改善脱硝系统的迟滞和延时效应。

2.3.2 预测模型精度分析

笔者分别在稳工况和变工况 2 种运行环境下, 对所提预测模型的预测精度进行仿真实验, 采用 MAPE 值和 RMSE 值作为评价指标。

稳工况环境下, 本文中预测模型与 BP 模型、SVM 模型、LSTM 模型的预测结果如图 5 所示。



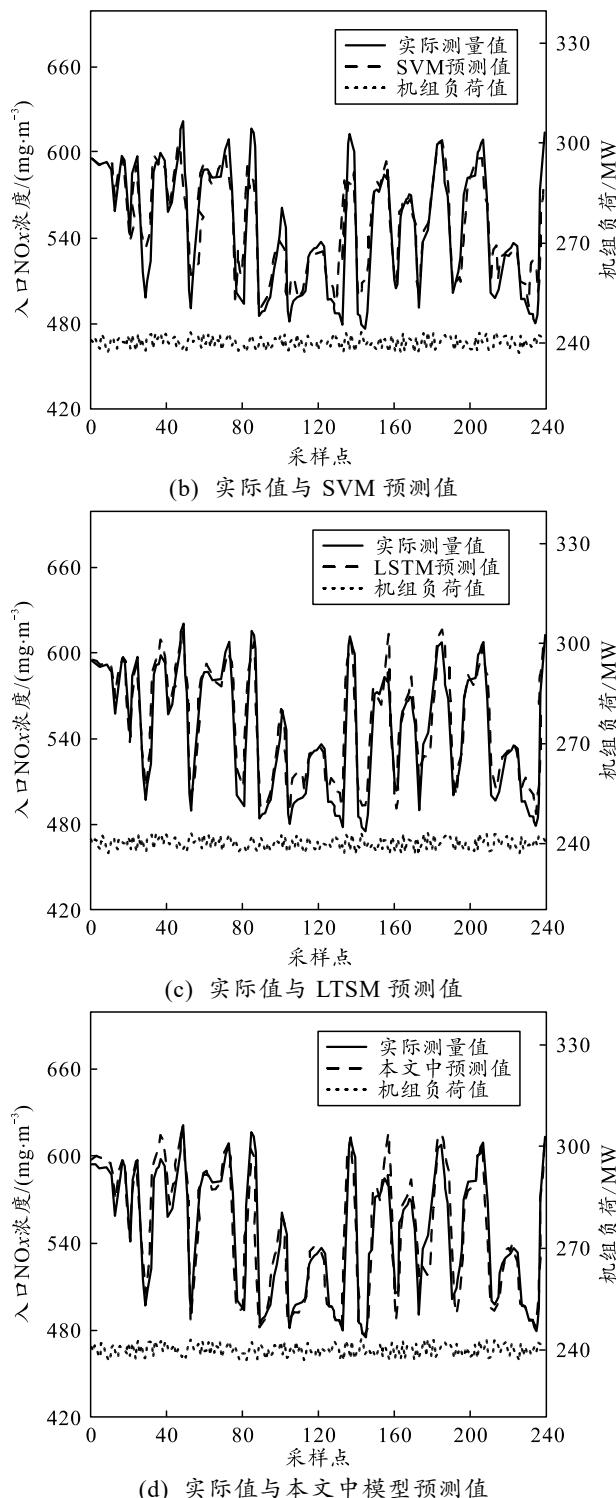


图 5 稳工况预测结果

稳工况下不同算法模型的 MAPE 值和 RMSE 值如表 3 所示。

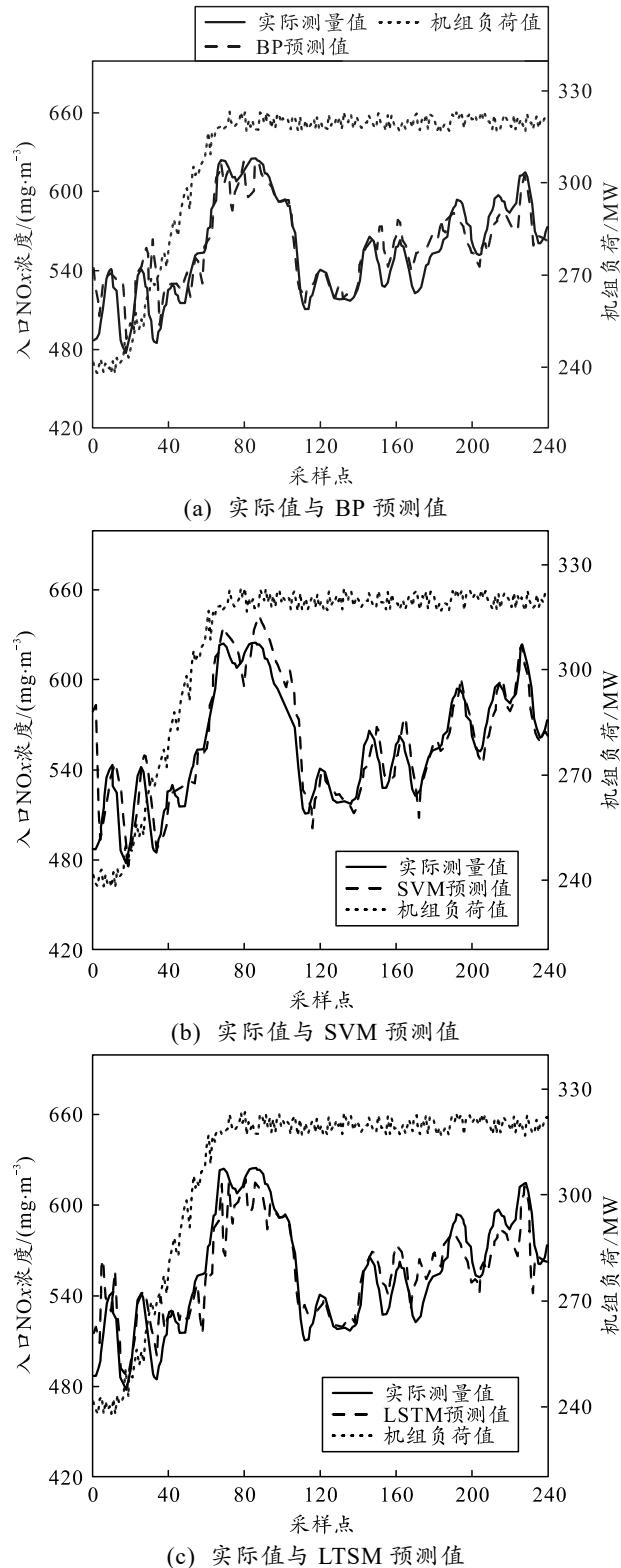
表 3 稳工况预测误差值

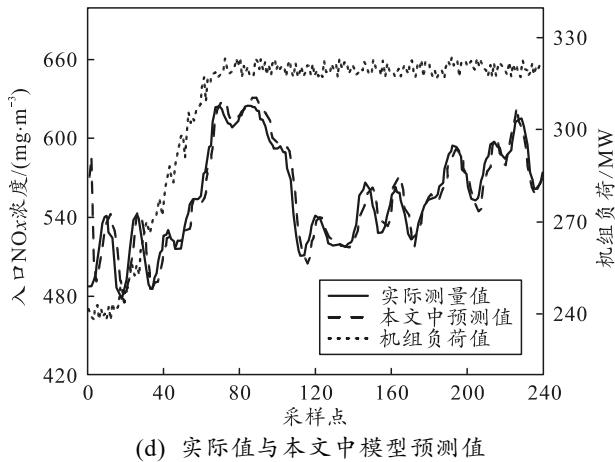
项目	BP	SVM	LSTM	本文中模型
MAPE/%	3.22	1.96	1.32	1.12
RMSE/MW	23.64	15.06	9.36	8.79

由图 5 和表 3 可以发现, BP 模型的 MAPE 值

和 RMSE 值较大, 出现一定程度的过拟合现象, LSTM 模型、SVM 模型和本文中预测模型的稳工况预测精度较高, 本文中预测模型的 MAPE 值和 RMSE 值分别为 1.12% 和 8.79 MW。

变工况环境下, 本文中预测模型与 BP 模型、SVM 模型、LSTM 模型的预测结果如图 6 所示。





(d) 实际值与本文中模型预测值

图 6 变工况预测结果

变工况下不同算法模型的 MAPE 值和 RMSE 值如表 4 所示。

表 4 不同算法模型的变工况预测误差值

项目	BP	SVM	LSTM	本文中模型
MAPE/%	2.12	1.95	2.13	1.58
RMSE/MW	16.22	15.18	16.21	13.17

由图 6 和表 4 可以发现, 4 种算法模型的变工况预测精度均较高, 本文中预测模型的 MAPE 值和 RMSE 值分别为 1.58% 和 13.17 MW。

结合不同算法模型在稳工况和变工况条件下的预测结果, 可以得到: BP 模型的预测精度较低, 在变工况条件下的预测结果比稳工况更为准确, 是由于 BP 算法误差对权值变化不敏感, 容易陷入极小值点而无法得到全局最优解^[19]; SVM 模型的预测精度不是最高, 但是在稳工况和变工况条件下具有十分接近的预测结果, 表现出较高的预测稳定性, 是由于 SVM 算法能够更好地适应非线性系统^[20]; LSTM 模型和本文中算法模型的预测精度较高, 稳工况条件下的预测精度高于变工况, 表明工作环境变化对 2 种算法的预测精度有一定的影响^[21]。

本文中预测模型在 2 种工作条件下都具有最小的预测误差, 表现出较高的预测精度和泛化能力, 一方面, 是由于预测模型选取的输入变量范围包含了尽可能多的与 NO_x 质量浓度有关的变量信息; 另一方面, ML-AE-ELM 预测算法具有较强的非线性映射能力, 避免了结构参数随机赋值的偶然性, 具有良好的预测精度和鲁棒性。

3 结论

笔者针对 NO_x 质量浓度值预测所需要解决的主要问题, 提出一种基于 MI-PCA 和 ML-AE-ELM 的预测模型, 引入历史 NO_x 质量浓度值作为输入变

量, 在保证预测效率的同时保留了更多的输入变量信息, 得到未来 20 min 的 NO_x 质量浓度值预测结果。实验结果表明, 本文中预测模型虽然引入了更多的输入变量, 但是训练和预测时长可以满足脱硝系统入口 NO_x 质量浓度值预测的应用要求; 与其他预测算法模型进行对比, 本文中预测模型在稳工况和变工况条件下都得到较小的误差值, 表现出较高的预测精度和良好的抗噪能力与泛化能力。

参考文献:

- [1] 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.
- [2] ZHAI Y J, DING X D, JIN X Z, et al. Adaptive LSSVM based iterative prediction method for NO_x concentration prediction in coal-fired power plant considering system delay[J]. Applied Soft Computing Journal, 2020, 89: 85912–85919.
- [3] 赵乾. SCR 烟气脱硝系统模拟优化及喷氨量最优控制[D]. 重庆: 重庆大学, 2012.
- [4] 李刚, 贾晓静, 武宝会, 等. 基于主导因素分析的 SCR 烟气脱硝系统喷氨量控制[J]. 热力发电, 2016, 45(8): 99–103.
- [5] 赵文杰, 张楷. 基于互信息变量选择的 SCR 烟气脱硝系统非线性自回归神经网络建模[J]. 热力发电, 2018, 47(9): 22–26.
- [6] 马平, 李珍, 梁薇. 基于互信息的辅助变量筛选及在火电厂 NO_x 软测量模型中的应用[J]. 科学技术与工程, 2017, 17(22): 249–254.
- [7] 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.
- [8] 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.
- [9] 刘威, 刘尚, 白润才, 等. 互学习神经网络训练方法研究[J]. 计算机学报, 2017, 40(6): 1291–1305.
- [10] 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.
- [11] 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.
- [12] YANG T, CUI C, LYU Y, et al. Modeling on SCR process of a coal-fired boiler using LSSVM method[C]//Proceedings of the Control and Decision Conference. Qingdao: IEEE, 2015: 4025–4028.
- [13] 温鑫, 钱玉良, 彭道刚, 等. 基于深度双向 LSTM 的 SCR 系统 NO_x 排放预测模型研究[J]. 热能动力工程, 2020, 35(10): 57–64.

- [14] 秦天牧, 林道鸿, 杨婷婷, 等. SCR 烟气脱硝系统动态建模方法比较[J]. 中国电机工程学报, 2017, 37(10): 2913–2919.
- [15] 程港, 林小峰, 宋绍剑, 等. 基于 PCA-GA-ELM 的光伏发电功率预测研究[J]. 可再生能源, 2019, 37(10): 1440–1447.
- [16] 邹堃, 王丹秋. SCR 烟气脱硝系统出口烟道 NO_x 测点技术改造[J]. 发电技术, 2019, 40(2): 155–160.
- [17] 刘文慧, 徐遵义, 张旭冉, 等. 基于互信息和 PCA 理论的湿法烟气脱硫工况特征提取方法[J]. 中国电力, 2020, 53(8): 158–163.

(上接第 54 页)

综合式的显示控制特点决定了航电显控系统功能仿真是一个有限状态、多输入多输出的时序逻辑决策问题, 可应用有限状态机理论进行处理。笔者以某型多用途战斗机综合航电系统为研究对象, 提出基于有限状态机的显控系统功能仿真设计思路, 并应用 Simulink/Stateflow 进行了仿真实现。该仿真结果已应用于某型教学训练模拟器。结果表明, 通过隔离逻辑判断与显示画面仿真模块, 合理划分航电系统/子系统状态, 使用 Simulink/Stateflow 的图形化开发环境便于直观、快速地构建模型并生成 C++ 代码, 避免了直接使用文本编程时大量的逻辑判断语句导致的调试、修改不便的问题, 提高了开发效率, 降低了系统状态更新的难度。考虑到第三代战斗机综合航电系统的相似性, 开发的仿真程序具有较好可移植性。

参考文献:

- [1] 梁青阳. 综合航空电子系统原理[M]. 北京: 航空工业出版社, 2020: 1–3.
- [2] Collinson R P G. 航空电子系统导论[M]. 史彦斌, 高宪军, 王远达, 等, 译. 北京: 国防工业出版社, 2013:
- [3] MOIRI, SEABRIDGEA G. Military Avionics Systems[M]. New York: John Wiley & Sons Ltd, 2006: 1–2.
- [4] 赵育良, 周胜明, 王淑娟. 新型侦察设备多功能显控系统仿真研究[J]. 兵工自动化, 2015, 34(12): 13–15.
- [5] 邵帆, 张安. 航电综合系统中飞机显示控制系统的仿真与实现[J]. 电光与控制, 2010, 17(11): 89–92.
- [6] 欧爱辉, 卢卫国, 李程鹏, 等. 某直升机综合航电显控仿真系统的开发与实现[J]. 火力与指挥控制, 2013, 38(1): 141–144.
- [7] 张建东, 高晓光, 吴勇, 等. 综合航电显控仿真系统的设计与实现[J]. 火力与指挥控制, 2006, 31(2): 40–43.
- [8] 吴华兴, 鲁艺, 黄伟, 等. 基于多型航电系统的显控界面仿真[J]. 系统仿真学报, 2009, 21(23): 7456–7459.
- [9] 尹伟, 马晋, 张新, 等. 显控系统软件仿真模式研究[J]. 航空电子技术, 2017, 48(1): 39–43.
- [10] 杨立亮, 董海涛. 航电系统作战飞行程序仿真运行环境研究[J]. 航空电子技术, 2011, 42(4): 24–28.
- [11] 谭同超. 有限状态机及其应用[D]. 广州: 华南理工大学, 2013.
- [12] 刘芮淵, 邓杨, 史伟娜, 等. 基于量子框架和 Stateflow 模型的嵌入式系统软件设计[J]. 兵工自动化, 2018, 37(11): 44–48.

- [18] 靳果, 朱清智, 孟阳, 等. 基于多层极限学习机的电能质量扰动多标签分类算法[J]. 电力系统保护与控制, 2020, 48(8): 96–105.

- [19] 王天堃. 基于神经网络模型及预测控制 DMC 的火电机组脱硝控制策略[J]. 中国电力, 2019, 52(12): 140–145.

- [20] 乔源, 邢波涛, 赵文杰, 等. 基于改进 Adaboost 算法的 SCR 脱硝系统多模型集成建模[J]. 华北电力大学学报(自然科学版), 2021, 48(1): 90–97.

- [21] 高常乐, 司凤琪, 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.

1–5.