

DOI: 10.19666/j.rlfed.202502032

基于增强灰狼优化 LSTM 神经网络的 火电机组 SCR 脱硝反应器建模

吴磊¹, 顾华¹, 姚一鸣¹, 张军^{2,3}, 苏军¹, 陈依¹

(1. 国网上海青浦供电公司, 上海 201700;

2. 上海电力大学自动化工程学院, 上海 200090;

3. 上海市电站自动化技术重点实验室, 上海 200090)

[摘要] 针对传统机理建模方法预测选择性催化还原技术 (SCR) 脱硝反应器出口 NO_x 质量浓度精度不高的问题, 提出了一种结合增强型灰狼优化算法 (EGWO) 与长短时记忆 (LSTM) 神经网络的混合预测模型。首先, 基于主成分分析 (PCA) 对原始数据进行处理与筛选, 实现输入变量的降维。然后, 利用 EGWO 优化 LSTM 神经网络的超参数。最终, 将输入变量作为 EGWO-LSTM 模型的输入, 预测出口 NO_x 质量浓度。以国内某超超临界 1 000 MW 火电机组为例, 仿真结果表明, 该模型在误差控制方面表现最优, 均方根误差较传统 LSTM 模型下降 50.36%, 较 BP 模型下降 76.14%, 模型平均绝对百分比误差仅为 1.01%。EGWO 相对于 GWO 收敛至最优解时的迭代次数更少, 且具有更高的收敛精度。

[关键词] SCR 脱硝反应器; 预测模型; NO_x ; LSTM; 主成分分析; 增强灰狼优化算法

[引用本文格式] 吴磊, 顾华, 姚一鸣, 等. 基于增强灰狼优化 LSTM 神经网络的火电机组 SCR 脱硝反应器建模[J]. 热力发电, 2025, 54(11): 136-141. WU Lei, GU Hua, YAO Yiming, et al. Modeling of SCR denitrification reactor for thermal power units based on improved grey wolf optimization LSTM network[J]. Thermal Power Generation, 2025, 54(11): 136-141.

Modeling of SCR denitrification reactor for thermal power units based on improved grey wolf optimization LSTM network

WU Lei¹, GU Hua¹, YAO Yiming¹, ZHANG Jun^{2,3}, SU Jun¹, CHEN Yi¹

(1. State Grid Shanghai Qingpu Electric Power Supply Company, Shanghai 201700, China;

2. School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

3. Shanghai Key Laboratory of Power Station Automation Technology, Shanghai 200090, China)

Abstract: A hybrid prediction model combining enhanced grey wolf optimization algorithm (EGWO) and long short-term memory (LSTM) neural network is proposed to address the problem of low accuracy in predicting the mass concentration of NO_x at the outlet of selective catalytic reduction (SCR) denitrification reactors using conventional mechanism modeling methods. Firstly, based on principal component analysis (PCA), the raw data is processed and filtered to achieve dimensionality reduction of input variables. Then, the EGWO is used to optimize the hyperparameters of LSTM. Finally, the input variables are used as inputs for the EGWO-LSTM model to predict the mass concentration of NO_x at the outlet. Taking a 1 000 MW ultra supercritical thermal power unit in China as an example, simulation results show that the proposed model performs the best in error control, with root mean square error reduces by 50.36% compared to the conventional LSTM model, and by 76.14% compared to the BP model, and the mean absolute percentage error of the model is only 1.01%. The EGWO has fewer iterations and higher convergence accuracy compared to the GWO when converging to the optimal solution.

Key words: SCR denitrification reactor; prediction model; NO_x ; LSTM; principal component analysis; enhanced grey wolf optimization algorithm

收稿日期: 2025-02-24

基金项目: 国家自然科学基金项目 (61273190); 上海市电站自动化技术重点实验室资助项目 (13DZ2273800)

Supported by: National Natural Science Foundation of China (61273190); Funding Project of Shanghai Key Laboratory of Power Station Automation Technology (13DZ2273800)

第一作者简介: 吴磊 (1996), 男, 硕士, 助理工程师, 主要研究方向为非线性系统建模、控制与优化, 电网运维, 1784646353@qq.com。

通信作者简介: 张军 (1966), 男, 博士, 副教授, 主要研究方向为机器学习、复杂系统智能控制与优化, 86610598@qq.com。

在全球倡导绿色发展与可持续能源战略的大背景下,火电作为能源供应的重要支柱,其环保性能备受关注^[1]。SCR 脱硝技术凭借其高效的脱硝能力,成为火电厂控制 NO_x 排放的关键手段,是实现火电绿色转型的核心技术之一。火电厂的 NO_x 排放水平与运行成本,和 SCR 脱硝反应器的性能息息相关。所以,构建精确的 SCR 脱硝反应器模型,对优化脱硝系统运行、减少 NO_x 排放极为关键。然而 SCR 脱硝反应器的运行过程极为复杂,涉及复杂的化学反应、多变的工况条件以及众多相互关联的运行参数,这些因素导致传统的机理建模难以准确预测反应器出口的 NO_x 质量浓度^[2]。

随着监控信息系统(SIS)在火电厂信息化建设领域的普遍应用,存储的运行数据为构建数据驱动模型创造了基础条件^[3]。因此,运用机器学习等数据分析技术,可有效利用电厂运行历史数据库构建高精度的 SCR 脱硝反应器模型。

目前对 SCR 脱硝反应器进行建模的方法有很多,如文献[4]利用小波去噪、PCA 和自适应神经模糊推理系统(adaptive neuro-fuzzy inference system, ANFIS)构建 SCR 脱硝系统模型。文献[5]建立 SCR 脱硝反应一维模型,通过数值仿真来优化燃煤电厂 SCR 脱硝性能。文献[6]利用混合数据驱动建模方式对 SCR 脱硝系统出口 NO_x 排放浓度进行预测。文献[7]将互信息与双向长短时记忆(LSTM)神经网络相结合,实现 NO_x 质量浓度排放预测。文献[8]构建卷积神经网络(CNN)和 LSTM 神经网络的混合模型对 SCR 脱硝反应器入口 NO_x 进行预测,但未开展针对 LSTM 神经网络超参数的优化。文献[9]虽然利用 GWO 算法对 LSTM 神经网络神经元个数和学习率进行优化,但其采用的线性迭代更新收敛因子调整机制存在一定缺陷。

为此,本文提出通过非线性策略对收敛因子实施动态更新,运用变异策略提升 GWO 算法的性能,针对 LSTM 的超参数,即神经元个数、学习率和迭代次数,运用优化后的 EGWO 算法进行调优,有效提升了模型的预测能力。

1 PCA 算法

PCA 算法是一种基于最大方差投影理论的数据降维技术^[3]。该算法通过对原始变量实施线性变换,将原始样本转化为彼此线性不相关的主成分,以此削减原始输入变量的复杂度。在本文的研究

中,应用 PCA 算法的主要目的是对 SCR 脱硝反应器的输入变量进行降维操作,一方面提高原始数据的品质,另一方面缩短模型构建时长,最终确保模型不仅拥有较高的精度,还具备良好的泛化能力。该 PCA 算法能够有效应对不同场景下的任务需求。

1.1 最大方差投影理论

设原始 SCR 脱硝反应器的运行数据集为 $\mathbf{X} = [x_1^T; x_2^T; \dots; x_m^T] \in \mathbb{R}^{m \times p}$, 其中 m 为样本数量, $x_i \in \mathbb{R}^p$ 表示第 i 个样本的 p 维工况参数。协方差矩阵定义为:

$$\mathbf{C} = \frac{1}{m-1} \mathbf{X}^T \mathbf{X} \in \mathbb{R}^{p \times p} \quad (1)$$

通过特征值分解可得:

$$\mathbf{C} \mathbf{v}_j = \lambda_j \mathbf{v}_j \quad (j=1, 2, \dots, p) \quad (2)$$

其中 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ 为特征值, 对应正交特征向量 $\mathbf{v}_j \in \mathbb{R}^p$, 称为最佳投影向量^[10]。构造投影矩阵 $\mathbf{A} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_l] \in \mathbb{R}^{p \times l}$, 满足方差最大化准则:

$$\max_A \text{tr}(\mathbf{A}^T \mathbf{C} \mathbf{A}) \quad \text{s.t.} \quad \mathbf{A}^T \mathbf{A} = \mathbf{I} \quad (3)$$

1.2 PCA 算法实施流程

步骤 1) 对原始数据矩阵进行 Z-score 标准化

$$\tilde{x}_{ij} = \frac{x_{ij} - \mu_j}{\delta_j} \quad (i=1, 2, \dots, m; j=1, 2, \dots, p) \quad (4)$$

$$\mu_j = \frac{1}{m} \sum_{i=1}^m x_{ij} \quad (5)$$

$$\delta_j^2 = \frac{1}{m-1} \sum_{i=1}^m (x_{ij} - \mu_j)^2 \quad (6)$$

步骤 2) 协方差矩阵计算

标准化后数据的协方差矩阵为:

$$\tilde{\mathbf{C}} = \frac{1}{m-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}} \in \mathbb{R}^{p \times p} \quad (7)$$

步骤 3) 特征空间分解

求解特征方程:

$$\tilde{\mathbf{C}} \mathbf{v}_j = \lambda_j \mathbf{v}_j \quad (j=1, 2, \dots, p) \quad (8)$$

按特征值降序排列得 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ 。

步骤 4) 主成分筛选

计算方差贡献率及累计贡献率:

$$\eta_j = \frac{\lambda_j}{\sum_{k=1}^p \lambda_k}, \Gamma_l = \sum_{j=1}^l \eta_j \quad (9)$$

选择最小 l 使得 $\Gamma_l \geq 85\%$, 构建投影矩阵 $\mathbf{A} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_l]$ 。

步骤 5) 数据降维映射

得到降维后数据集:

$$Y = \tilde{X} A \in \mathbb{R}^{m \times l} \quad (10)$$

其中，第 i 行 $y_i=[y_{i1}, y_{i2}, \dots, y_{il}]$ 为样本 x_i 的 l 维主成分特征。

2 LSTM 神经网络

LSTM 神经网络是针对传统循环神经网络 (RNN) 时序建模缺陷提出的改进型架构^[11]。LSTM 神经网络通过创新性地引入细胞状态 (cell state) 与三重门控结构，成功攻克了 RNN 长期困扰的梯度消失与梯度爆炸难题^[12]，其结构如图 1 所示。其中包括遗忘门、输入门、输出门和 h_t 隐含层单元输出量，其计算公式可参考文献^[13]。




图 1 LSTM 神经网络结构示意图

Fig.1 Structure diagram of the LSTM neural network

3 基于灰狼的 LSTM 神经网络

3.1 GWO 算法

2014 年，Mirjalili 等人^[14]从自然界灰狼群体的捕猎行为中汲取灵感，提出了一种群智能优化算法—GWO 算法。该算法具有较强的搜索能力和较快的收敛速度、所需参数少，易实现等特点，被广泛应用于函数优化、机器学习等领域。狼群个体间严格执行等级制度分级图 (图 2)，其中 α 狼负责领导群体， β 和 δ 狼协助 α 狼做出决策， ω 狼服从其他狼的指挥。




图 2 灰狼等级制度分级

Fig.2 Hierarchical diagram of grey wolf social hierarchy system

通过不断更新狼的位置，逐步逼近猎物，更新方式如式(11)、式(12)所示：

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (11)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (12)$$

式中： t 为迭代次数； \vec{C} 和 \vec{A} 为向量系数； \vec{X} 为当前位置； \vec{D} 为灰狼和猎物间的距离； \vec{X}_p 为更新之前种群个体的位置。其中向量系数的更新公式为：

$$\vec{C} = 2\vec{r}_2 \quad (13)$$

$$\vec{A} = 2\vec{\alpha} \cdot \vec{r}_1 - \vec{\alpha} \quad (14)$$

式中： \vec{r}_1 和 \vec{r}_2 均为闭区间 $[0,1]$ 内的一个随机数； $\vec{\alpha}$ 为收敛因子，其表达式为：

$$\vec{\alpha} = 2 - 2t/T_{\max} \quad (15)$$

式中： T_{\max} 为最大迭代次数。

可以看出，随着迭代的不断进行， $\vec{\alpha}$ 按照线性规律，由 2 逐步递减至 0。

捕猎过程的更新过程如式(16)一式(18)所示。式(16)是灰狼个体追踪猎物位置的数学描述，式(17)是 ω 狼向 α 、 β 、 δ 狼靠近的数学描述，式(18)是 ω 狼最终位置的数学描述。

$$\begin{cases} \vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \\ \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \\ \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \end{cases} \quad (16)$$

$$\begin{cases} \vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 * \vec{D}_\alpha \\ \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 * \vec{D}_\beta \\ \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 * \vec{D}_\delta \end{cases} \quad (17)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (18)$$

式中： \vec{D}_α 、 \vec{D}_β 、 \vec{D}_δ 分别为当前个体 α 、 β 、 δ 到猎物的距离； \vec{X}_α 、 \vec{X}_β 、 \vec{X}_δ 分别为 α 、 β 、 δ 的位置； \vec{C}_1 、 \vec{C}_2 、 \vec{C}_3 为随机向量； \vec{X} 为当前位置。

3.2 GWO 算法的改进

在传统 GWO 算法里，位置更新过度依赖于 α 狼，这使得算法在局部寻优时表现出色，却造成了全局寻优能力不足的问题。而 SCR 脱硝反应器建模预测出口 NO_x 质量浓度过程中，算法的搜索过程呈现出较高的复杂性，线性收敛因子难以契合搜索时

的实际状况，这极易导致算法被困于局部最优解，拉低算法的精度。因此本文对标准 GWO 算法进行如下改进：

1) 非线性策略更新收敛因子

收敛因子更新策略不同会严重影响算法的性能^[15]，本文采用非线性策略更新收敛因子，计算公式如下：

$$\bar{\alpha} = 2 \left[1 - \sin \left(\frac{\pi}{2} \cdot \frac{t}{T_{\max}} \right) \right] \quad (19)$$

改进后的收敛因子在迭代前期快速递减，有利于灰狼种群在搜索区域内快速开展全面搜索，确定目标搜索区域；到了迭代后期，收敛因子递减速度放缓，灰狼种群在目标搜索区域仔细进行局部搜索，提高了算法收敛至全局最优解的概率。这样的改进能有效平衡整个算法的全局最优和局部最优。

2) 变异策略

为了解决标准 GWO 算法容易陷入局部最优问题，对式(18)进行高斯变异：

$$\vec{X}(t+1) = \vec{X}(t+1) \cdot \left[1 + \frac{\bar{\alpha}}{2} \cdot N(0,1) \right] \quad (20)$$

灰狼算法在初期提高扰动，增强算法的全局搜索能力，在末期降低扰动，防止最优解波动，进而加快算法收敛速度。

3.3 EGWO 优化 LSTM 算法流程

图 3 为 EGWO-LSTM 预测模型的框架结构。

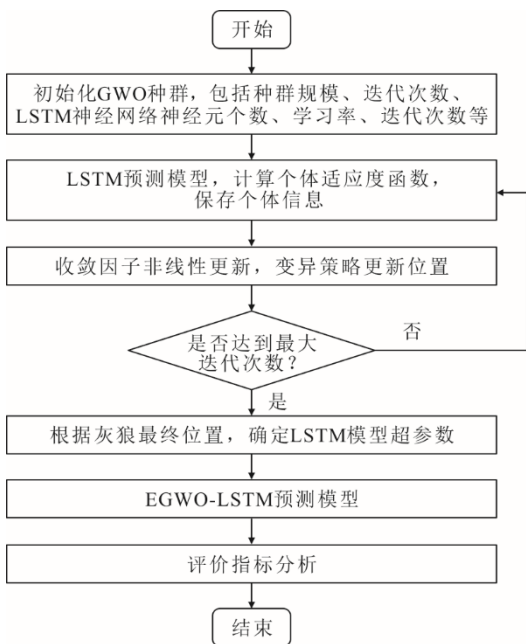


图 3 EGWO-LSTM 预测模型框架结构
Fig.3 Framework diagram of the EGWO-LSTM prediction model

步骤 1) 初始化 GWO 种群，包括种群规模、迭代次数，设置 LSTM 神经网络神经元个数、学习率、迭代次数等。

步骤 2) 搭建 LSTM 预测模型，并对灰狼个体的适应度函数进行计算，保留适应度最好的 α 、 β 、 δ 狼的信息。

步骤 3) 利用非线性策略更新收敛因子，变异策略更新个体位置

步骤 4) 确认当前迭代次数是否达到预先设定的最大迭代次数。若尚未达到，则程序返回步骤 2) 继续执行；若达到，则根据灰狼最终位置，确定 LSTM 神经网络超参数，构建 EGWO-LSTM 模型，输出出口 NO_x 预测值，并开展评价指标分析。

4 实例仿真研究

4.1 PCA 筛选输入变量

前文提到 SCR 脱硝反应器的运行过程极为复杂，传统机理建模方式导致出口 NO_x 质量浓度预测精度低。SIS 中保留 SCR 脱硝反应器的各项运行数据，其中锅炉负荷、温度、压力、SCR 入口 NO_x 质量浓度、入口烟气氧量、锅炉送风量、脱硝效率、耗煤量等都会对出口 NO_x 质量浓度有直接的影响。采用 PCA 方法对 16 个工艺参数及出口 NO_x 质量浓度进行特征提取。通过计算各主成分的累计贡献率（表 1），前 6 个主成分的累计贡献率为 86.91%，因此将这 6 个主成分选定为模型输入变量。同时，考虑到出口 NO_x 质量浓度具有时间序列相关性，将上一采样时刻的 NO_x 质量浓度纳入输入变量集，最终确定 7 个特征参数作为 EGWO-LSTM 预测模型的输入参数。

表 1 各主成分对应的特征值和累计贡献率
Tab.1 The eigenvalues and cumulative contribution rates corresponding to each principal component

各主成分	特征值	贡献率/%	累计贡献率/%
SCR 入口 NO _x 质量浓度	8.127 1	0.406 3	0.406 3
锅炉负荷	4.115 8	0.205 7	0.612 0
SCR 入口温度	1.974 7	0.097 5	0.709 5
SCR 入口烟气氧量	1.396 4	0.069 6	0.779 1
SCR 入口烟气量	1.001 9	0.050 2	0.829 3
NH ₃ 入口流量	0.797 1	0.039 8	0.869 1

4.2 仿真实证

研究数据来源于国内某超超临界 1 000 MW 燃煤发电机组的 SIS 历史运行数据，数据采样间隔为 1 s，选取 1 400 组用于预测实验，含 800 组训练集、300 组测试集、300 组验证集。经检测无异常数据，

为确保 LSTM 模型的预测稳定性,对输入数据进行归一化预处理,设最大值为 0.9,最小值为 0.1。

本文采用均方根误差 (δ_{RMSE}) 和平均绝对百分比误差 (δ_{MAPE}) 作为模型效果的量化评估依据。通过结合 2 种具有互补特性的统计量 (前者反映绝对偏差幅度,后者刻画相对误差水平),构建多维度的性能评价体系,其表达式为:

$$\delta_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2} \quad (21)$$

$$\delta_{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - f(x_i)|}{y_i} \times 100\% \quad (22)$$

式中: y_i 为实际值; $f(x_i)$ 为预测输出值; n 为预测样本总数。

考虑 LSTM 神经网络隐含层层数的不同会对预测精度影响较大^[16]。因此,本文研究基于 Python 2.0 深度学习框架,构建了 3 种不同结构的预测模型:单层 LSTM (PCA-LSTM1)、双层 LSTM (PCA-LSTM2) 和 3 层 LSTM (PCA-LSTM3)。各模型采用相同数据集,3 种不同隐含层层数的 LSTM 神经网络的均方根误差分别为 1.92、1.59、2.14 mg/m³,平均绝对百分比误差分别为 2.84%、2.35%、3.15%。2 层隐含层比 1 层和 3 层隐含层预测精度分别提高了 17.20% 和 25.50%。表明在一定范围内,模型预测精度随隐含层数量增加呈现正向改善趋势。然而随着隐含层层数的不断增加,误差开始增大,出现过拟合现象,模型泛化能力降低。因此,后续仿真实验中 LSTM 隐含层设为 2 层。LSTM 神经网络的神经元数量、学习率和迭代次数会对预测精度造成较大影响,故建立 5 种模型进行对比,分别为收敛因子采用常规线性更新迭代的 PCA-GWO-LSTM2、动态非线性更新收敛因子和高斯变异的 PCA-EGWO-LSTM2,以及构建的 PCA-LSSVM 和 PCA-BP 网络,各模型采用相同数据集。LSSVM 中采用径向基函数 (radial basis function, RBF) 作为核函数, BP (back propagation) 神经网络隐含层采用 tanh 激活函数, Adam 优化器。

灰狼算法种群数量为 5,迭代次数为 100 次。设置 LSTM 神经网络各隐含层的神经元数量在 [1, 100],学习率的调节区间设置为 [0.001, 0.01],同时训练迭代次数的取值范围限定在 [100, 800]。表 2 为上述各模型的预测性能对比。

在预测精度方面,PCA-BP 模型的预测误差最大,PCA-LSSVM 模型次之,PCA-LSTM2 模型相对于 BP 和 LSSVM 预测精度分别提高了 51.93% 和

42.44%,表明 LSTM 神经网络更加适合处理长时间序列数据。PCA-GWO-LSTM2 相对于 PCA-LSTM2 预测精度提高了 18.25%。PCA-EGWO-LSTM2 模型误差最小,预测效果最好,其均方根误差为 0.68 mg/m³,平均绝对百分比误差为 1.01%,相对于采用常规线性更新收敛因子的 PCA-GWO-LSTM2 模型预测精度提高了 39.29%;相对于 PCA-LSTM2 和 PCA-BP,均方根误差分别减小了 50.36% 和 76.14%,平均绝对百分比误差减小了 50.25% 和 76.01%。

在训练模型耗时方面,PCA-EGWO-LSTM2 模型耗时最短,仅为 189.06 s,较 PCA-BP 和 PCA-LSSVM 模型耗时分别缩短了 77.43% 和 68.32%。EGWO 模型相较于 GWO 模型,计算效率提升了 29.38%。综上,灰狼算法可以对 LSTM 神经网络进行优化,以获取最佳超参数组合。采用动态非线性更新收敛因子和高斯变异策略优化灰狼算法可以进一步提升 LSTM 神经网络的预测性能。

表 2 不同模型的预测性能对比
Tab.2 Performance comparison of different models

模型	$\delta_{RMSE}/(\text{mg} \cdot \text{m}^{-3})$	$\delta_{MAPE}/\%$	训练模型 耗时/s
PCA-LSTM2	1.37	2.03	429.85
PCA-GWO-LSTM2	1.12	1.65	267.73
PCA-EGWO-LSTM2	0.68	1.01	189.06
PCA-LSSVM	2.38	3.52	596.70
PCA-BP	2.85	4.21	837.65

图 4 展示了常规 GWO 与 EGWO 算法优化 LSTM 神经网络时适应度变化。由图 4 可见,同等迭代次数下,采用非线性更新收敛因子和高斯变异策略的 EGWO 收敛到最小值更快。前 40 次迭代,GWO 陷入局部最优的频次远超 EGWO。随着迭代的进行,GWO 第 36 步获全局最优值,而 EGWO 第 9 步就可以获得全局最优值。可见,EGWO 全局寻优能力更强,收敛速度更快,陷入局部最优概率低,更易找到理想最优解。

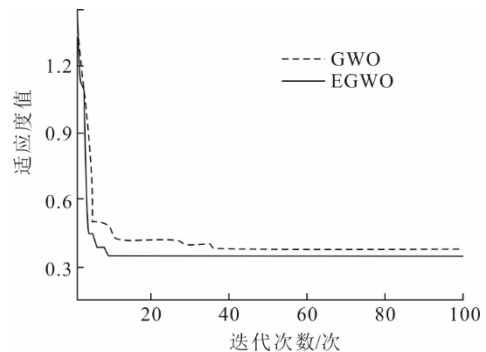


图 4 各模型适应度变化
Fig.4 Changes in the fitness of each model

5 结 论

1) SCR 脱硝反应器运行复杂, 机理建模难以精准预测出口 NO_x 质量浓度, 构建 PCA-EGWO-LSTM 预测模型, 利用实际数据仿真验证模型的有效性。

2) 利用 PCA 算法降低了模型的输入变量, 优化模型的预测精度, 提高了泛化能力。相对于 GWO, EGWO 为 LSTM 提供更优的参数组合。本文所建模型的均方根误差降低至 0.68 mg/m^3 , 平均绝对百分比误差仅为 1.01%。

3) 利用动态非线性迭代更新收敛因子和变异策略优化 EGWO 算法, 使得 EGWO 算法获得最优解时的迭代次数更少, 且全局寻优能力更强、收敛速度更快, 收敛精度更高。

[参 考 文 献]

- [1] 柴有国, 何晓燕, 苏永健, 等. 考虑安全环保及补偿的火电机组调峰经济性研究[J]. 中国电力, 2021, 54(11): 199-205.
CHAI Youguo, HE Xiaoyan, SU Yongjian, et al. Economic study on peak shaving of thermal power units considering safety, environmental protection, and compensation[J]. Electric Power, 2021, 54(11): 199-205.
- [2] 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 for thermal power units based on random forest[J]. Journal of Power Engineering, 2020, 40(6): 486-491.
- [3] 张珑慧, 林德海, 王颖, 等. 机器学习在火电厂 NO_x 减排中的应用综述[J]. 热力发电, 2023, 52(1): 7-17.
ZHANG Longhui, LIN Dehai, WANG Ying, et al. Overview of the application of machine learning in NO_x reduction in thermal power plants[J]. Thermal Power Generation, 2023, 52(1): 7-17.
- [4] 张晓雯, 向文国, 陈时熠, 等. 基于小波去噪和 PCA-ANFIS 的 SCR 脱硝系统建模[J]. 热力发电, 2021, 50(6): 114-120.
ZHANG Xiaowen, XIANG Wenguo, CHEN Shiyi, et al. Modeling of SCR denitrification system based on wavelet denoising and PCA-ANFIS[J]. Thermal Power Generation, 2021, 50(6): 114-120.
- [5] 徐圆圆, 龚德鸿, 邓传记, 等. SCR 反应器入口参数与反应温度对脱硝性能的交互作用[J]. 环境工程学报, 2023, 17(11): 3721-3729.
XU Yuanyuan, GONG Dehong, DENG Chuanji, et al. The interaction between SCR reactor inlet parameters and reaction temperature on denitrification performance[J]. Journal of Environmental Engineering, 2023, 17(11): 3721-3729.
- [6] AN B, TANG M, QIU J, et al. Dynamic NO_x prediction model for SCR denitrification outlet of coal-fired power plants based on hybrid data-driven and model ensemble[J]. Industrial & Engineering Chemistry Research, 2023, 62(36): 14286-14299.
- [7] JUNJIE K, YUGUANG N, BO H, et al. Dynamic

- modeling of SCR denitrification systems in coal-fired power plants based on a bi-directional long short-term memory method[J]. Process Safety and Environmental Protection, 2021, 148(1): 867-878.
- [8] 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. Explainable predictive model for NO_x mass concentration at the inlet of SCR reactor in coal-fired power units under variable load[J]. Thermal Power Generation, 2024, 53(7): 119-128.
- [9] 陆必伟, 李捷辉. 基于 GWO-LSTM 的柴油机 NO_x 排放预测[J]. 车用发动机, 2024(3): 80-87.
LU Biwei, LI Jiehui. Prediction of NO_x emissions from diesel engines based on GWO-LSTM[J]. Automotive Engines, 2024(3): 80-87.
- [10] 董浩, 李明星, 张淑清, 等. 基于核主成分分析和极限学习机的短期电力负荷预测[J]. 电子测量与仪器学报, 2018, 32(1): 188-193.
DONG Hao, LI Mingxing, ZHANG Shuqing, et al. Short term power load forecasting based on kernel principal component analysis and extreme learning machine[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(1): 188-193.
- [11] 胡阳, 杨泽, 房方, 等. 火电机组供电碳减排高维运行特征提取及其最优基准值确定[J]. 中国电机工程学报, 2021, 41(增刊 1): 210-220.
HU Yang, YANG Ze, FANG Fang, et al. High dimensional operation feature extraction and optimal benchmark value determination for carbon emission reduction in power supply of thermal power units[J]. Proceedings of CSEE, 2021, 41(Suppl.1): 210-220.
- [12] HOCHREITER S J, UUM L, SCHMIDHUBER R. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735.
- [13] 吴磊, 康英伟. 基于改进粒子群优化长短时记忆神经网络的脱硝系统 SO_2 预测模型[J]. 热力发电, 2021, 50(12): 66-73.
WU Lei, KANG Yingwei. SO_2 prediction model for desulfurization system based on improved particle swarm optimization long short-term memory neural network[J]. Thermal Power Generation, 2021, 50(12): 66-73.
- [14] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advance in Engineering Software, 2014, 69: 46-61.
- [15] 左剑, 张程稳, 肖逸, 等. 基于灰狼优化算法的多机电力系统稳定器参数最优设计[J]. 电网技术, 2017, 41(9): 2987-2995.
ZUO Jian, ZHANG Chengwen, XIAO Yi, et al. Optimal design of stabilizer parameters for multi machine power systems based on grey wolf optimization algorithm[J]. Grid Technology, 2017, 41(9): 2987-2995.
- [16] 全卫国, 郭超宇, 赵如意. 基于变量选择和 MGWO-LSTM 的浆液 pH 值预测[J]. 控制工程, 2024, 31(12): 2140-2148.
TONG Weiguo, GUO Chaoyu, ZHAO Ruyi. Prediction of pH value of slurry based on variable selection and MGWO-LSTM[J]. Control Engineering, 2024, 31(12): 2140-2148.

(责任编辑 杜亚勤)