

基于大数据平台的 SO_2 排放 GWO-N-BEATS 预测算法

曾庆华¹,冉 鹏²,董 坤³,刘 旭³

- (1. 国网湖南省电力有限公司电力科学研究院 高效清洁发电技术湖南省重点实验室,湖南 长沙 410007;
2. 华北电力大学 河北省低碳高效发电技术重点实验室,河北 保定 071003;
3. 华北电力大学 能源动力与机械工程学院,河北 保定 071003)

摘要:为了更精确地预测 SO_2 排放质量浓度,解决非线性随机预测问题,提出了一种基于随机森林特征选择的 GWO-N-BEATS 算法。通过随机森林算法筛选输入参数的特征,使用灰狼优化算法对 N-BEATS 算法的超参数进行优化;与长短期记忆网络 (Long Short-Term Memory, LSTM)、门控循环神经网络 (Gated Recurrent Unit, GRU) 以及 N-BEATS 算法对比分析,验证了 GWO-N-BEATS 算法的有效性。将本算法应用于某大型电网公司大数据平台,探索了复杂智能算法在大数据平台上开展污染物排放预测的可行性。研究结果表明,相较于长短期记忆网络、门控循环神经网络和 N-BEATS 方法,GWO-N-BEATS 算法预测误差更小,其中平均绝对百分比误差 MAPE 为 1.50%,相对均方误差 RMSE 为 0.42,平均绝对误差 MAE 为 0.33,决定系数 R^2 为 0.97。

关键词:随机森林;特征选择;灰狼优化算法;大数据平台;N-BEATS; SO_2 预测

中图分类号:TK284 文献标识码:A DOI:10.16146/j.cnki.rndlge.2024.03.016

[引用本文格式]曾庆华,冉 鹏,董 坤,等.基于大数据平台的 SO_2 排放 GWO-N-BEATS 预测算法[J].热能动力工程,2024,39(3):125-131. ZENG Qing-hua, RAN Peng, DONG Kun, et al. SO_2 emission prediction by GWO-N-BEATS algorithm based on big data platform[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(3): 125-131.

SO₂ Emission Prediction by GWO-N-BEATS Algorithm based on Big Data Platform

ZENG Qing-hua¹, RAN Peng², DONG Kun³, LIU Xu³

- (1. Hunan Province Key Laboratory of Efficient & Clean Thermal Power Generation Technologies, State Grid Hunan Electric Power Corporation Limited Research Institute, Changsha, China, Post Code: 410007;
2. Hebei Key Laboratory of Low Carbon and High Efficiency Power Generation Technology, North China Electric Power University, Baoding, China, Post Code: 071003; 3. School of Energy Power and Mechanical Engineering, North China Electric Power University, Baoding, China, Post Code: 071003)

Abstract: To predict SO_2 emission mass concentration more accurately and to solve the nonlinear stochastic prediction problem, a novel grey wolf optimization (GWO) deep learning architecture N-BEATS algorithm based on random forest feature selection was proposed. The features of the input parameters were screened by the random forest algorithm, and the hyperparameters of the N-BEATS model were optimized using the GWO algorithm; the effectiveness of the proposed algorithm was verified by comparing it with long short-term memory network (LSTM), gated recurrent unit (GRU) and N-BEATS. The algorithm was applied to a large power grid company's big data platform to explore the feasibility of complex intelligent algorithms to carry out pollutant emission prediction on a big data platform. The results show that the GWO-N-BEATS algorithm has less error compared to LSTM, GRU and N-BEATS methods,

where MAPE is 1.50%, RMSE is 0.42, MAE is 0.33, and R^2 is 0.97.

Key words: random forest, feature selection, grey wolf optimization (GWO) algorithm, big data platform, N-BEATS, SO₂ prediction

引言

现阶段,大气质量管控存在措施滞后、手段针对性不强等问题^[1]。若能构建高质量的大气质量监测、预警及提前干预体系,将对大气环境的改善起到至关重要的作用^[2]。为实现上述目的,湖南电网基于阿里云平台建设了“湖南省电力环保智慧监管平台”。该平台是集数据采集、传输、存储、计算以及可视化于一体的大数据平台,可结合数据平台的历史数据以及实时流数据进行深层次的数据挖掘与分析。该平台包含大气污染物贡献度分析模块,可在准确预测 SO₂ 排放质量浓度的基础上,结合污染物大气扩散模型,反演计算火电企业 SO₂ 排放的污染物贡献度。故准确预测火电机组的 SO₂ 排放质量浓度是解决上述问题的关键环节。

现有的 SO₂ 排放质量浓度预测方法主要包括,基于统计模型和基于深度学习模型的两种预测方法。传统的基于统计模型的方法,如多元线性回归、时间序列分析等,需要人工选择变量,且对数据的分布做了一定的假设,导致预测精度受到限制。近年来,深度学习算法在电厂污染排放预测领域的应用越来越受到人们的关注,并取得了良好的预测效果^[3],如人工神经网络 (Artificial Neural Network, ANN)^[4]、支持向量机 (Support Vector Machine, SVM)^[5]与长短时记忆网络 (Long Short-Term Memory, LSTM)^[6]。相比统计模型,基于深度学习模型的方法可以自动学习数据的特征和规律,不需要预先做出假设,且具有更高的灵活性和预测精度。张文广等人^[7]通过优化误差反向传播神经网络建立了预测精度达到 93.4% 的 NO_x 预测模型。裴旭倩^[8]建立了一种基于粒子群优化的双向门控循环神经网络的 NO_x 预测模型,通过粒子群算法对双向门控循环神经网络的超参数进行学习与训练,结果显示,其相对误差由传统门控循环神经网络的 5% 缩小至 2.5% 左右。何璞祯等人^[9]采用双向 LSTM 模型对

NO_x 排放进行预测,此模型解决了普通递归神经网络的梯度消失以及梯度爆炸等问题。根据测试结果,其误差小于传统 LSTM。蒋星明等人^[10]建立了一种基于双向门控循环神经网络的 SO₂ 预测模型,结果显示,其平均绝对百分比误差比 LSTM 分别下降了 0.718%。

深度学习算法的参数设置对预测结果的影响是巨大的。杨蓉等人^[11]采用遗传算法对长短期记忆神经网络的参数进行优化,以提高对柴油机 NO_x 排放的预测效果。刘艳华等人^[12]和李昌庆^[13]采用了遗传算法优化反向传播神经网络,验证了优化算法对深度学习参数调整的意义。然而,目前已有的机器学习模型在 SO₂ 排放质量浓度预测中仍然存在一些局限。例如,ANN 需要手动设置网络结构和参数,且容易受到数据噪声和异常值的干扰;SVM 对数据量的要求较高,且对超参数的选择敏感。同时,算法在大数据平台部署的过程中,可能会存在数据的质量差异较大、预处理步骤复杂以及模型泛化能力不一定能适应不同场景和数据分布变化的问题。因此,需要寻找一种更加高效和准确的算法来解决深度学习参数设置的问题。

为了解决上述问题,提出一种基于随机森林特征选择的灰狼算法 (Grey Wolf Optimizer, GWO) 优化 N-BEATS 预测算法,并将其应用于 SO₂ 质量浓度预测。N-BEATS 体系结构在模型结构、深度、学习方式和预测能力等方面都具有创新性。相比于传统的基于机器学习模型的方法,本文所提出的 GWO-N-BEATS 算法不受数据分布的限制,具有更高的灵活性和预测精度。

本文基于某燃煤机组多维运行数据建立了该机组 SO₂ 排放质量浓度预测模型,并基于真实数据预测结果验证了本模型的有效性。将本文所提出的 GWO-N-BEATS 算法在“湖南省电力环保智慧监管平台”进行了部署实施,探索了复杂智能算法在大数据平台上进行污染物预测的可行性,为电厂排放进行统一预测提供了借鉴。

1 SO₂预测数据采集与预处理

以数据平台中某火电厂一号机组为研究对象,采集该厂SO₂排放数据集,结合数据清洗、特征工程等技术,预选取与SO₂排放质量浓度相关性较大的18种不同运行参数作为备选特征参数,具体如表1所示。同时,为了避免不同输入数据的量纲及数值差异较大的问题,在特征选择前对所有特征参数按公式(1)进行归一化处理:

$$\tilde{x} = \frac{(x - \bar{x})}{\sigma} \quad (1)$$

式中: \bar{x} — x 的平均值; σ — x 的标准差; \tilde{x} —标准化后的值。

表1 特征参数

Tab. 1 Characteristic parameters

序号	指标名称
1	主蒸汽温度
2	出口NO _x 实测质量浓度
3	进口SO ₂ 实测质量浓度
4	进口O ₂ 实测质量浓度
5	吸收塔浆液H值
6	主蒸汽压力
7	吸收塔实测液位1
8	吸收塔实测液位2
9	吸收塔实测液位3
10	进口烟尘折算浓度
11	吸收塔供浆调门开度
12	浆液循环泵A电流
13	浆液循环泵B电流
14	浆液循环泵C电流
15	出口烟尘折算浓度
16	发电机功率
17	出口烟气温度
18	出口实测烟气流速

考虑到SO₂预测模型训练数据维度较高,需要对相关特征变量进行筛选,采用RF算法对其进行特征筛选。RF算法是一种基于决策树的集成算法^[14,15],用来对数据进行降维。其由多个决策树组成,每个决策树独立地对数据进行决策,并通过投票或平均值得出最终结果。与单个决策树相比,RF具有更高的准确性和鲁棒性。由于每棵决策树的特征选择都是随机的,因此对于同一个特征其在不同决

策树上的重要性指标可能不同。因此可以将每个特征在所有决策树上的重要性指标求平均值得到其最重要的重要性指标。在计算特征重要性的基础之上,将18组特征按降序排列。选取特征重要性排在前面的6个特征作为输入参数。基于RF特征筛选的6个特征重要性如图1所示。

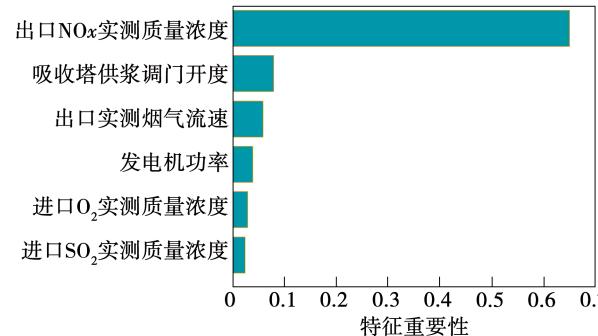


图1 随机森林特征重要性排序图

Fig. 1 Random forest feature importance ranking chart

2 N-BEATS 深度学习预测模型与GWO 优化算法

2.1 N-BEATS

N-BEATS是一种深度学习预测模型,其在时间序列预测中具有较强的优越性。N-BEATS采用了一种块模型结构,每个块由一个全连接层和两个残差连接层组成。这种结构可以让模型更加灵活地适应不同的时间序列数据,同时还能够减少过拟合的风险。N-BEATS不仅使用了块模型,还可以堆叠多个块来构建更深的神经网络。这种做法可以进一步提高模型的表现力和泛化能力,而且可以同时预测多个时间尺度的数据。同时可以让模型更好地捕捉时间序列的长期趋势和短期波动,从而提高预测的准确性。本文采用N-BEATS作为SO₂的预测模型,借助N-BEATS网络架构的特点,可较好地捕捉SO₂随时间变化的非线性关系。

N-BEATS是一种基于全连接层非线性回归器的深度学习网络架构,其不仅训练速度快且可解释性高^[16,17]。其网络的整体结构类似于残差网络,即网络的输入与输出之间存在着一个捷径连接。这种连接使得输入数据可以直接被传递到输出层,从而提高网络的学习效率和泛化能力。所建立的N-BEATS神经网络结构如图2所示。

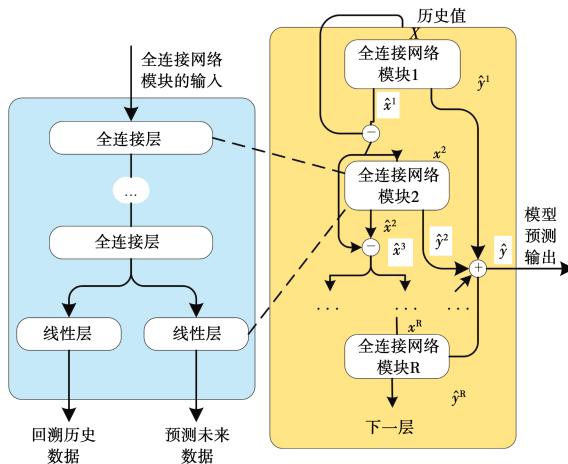


图 2 N-BEATS 网络结构

Fig. 2 N-BEATS network structure

由图 2 可知,该模型利用每个栈分别预测,最后累加得到预测值。其中每个栈由多个块构成(每个块是一个完全连接的层序列),使用 Relu 激活函数用作共享的隐藏层。假设有 R 个残差块,每一个有 L 个隐藏层,令 x (其中 $x \in R^w$)作为输入,使用残差块与层上标 (r, ℓ) 表示全连接层的权重 $(W^{r,\ell})$ 和偏差 $(b^{r,\ell})$ 。N-BEATS 的具体公式如下:

$$FC_{r,t}(h^{r,\ell-1}) \equiv \text{Relu}(W^{r,\ell}h^{r,\ell-1} + b^{r,\ell}) \quad (2)$$

$$x^r = \text{Relu}[x^{r-1} - \hat{x}^{r-1}] \quad (3)$$

$$h^{r,1} = FC_{r,1}(x^r), \dots, h^{r,L} = FC_{r,L}(h^{r,L-1}) \quad (4)$$

$$\hat{x}^r = B^r h^{r,L}, \hat{y}^r = F^r h^{r,L} \quad (5)$$

式中:FC—全连接层; r, t —索引为 r 的第 t 个全连接层。

假设 $\hat{x}^0 = 0$, $x^0 = 0$, 映射矩阵维度是 $B^r \in R^{w \times d_h}$, $F^r \in R^{H \times d_h}$, 最终的预测结果是残差块的预测结果之和 $\hat{y} = \sum_r \hat{y}^r$ 。

2.2 灰狼优化算法

灰狼优化算法是一种新颖的种群智能优化算法,是通过模仿灰狼的社会等级和群体狩猎机制进行研究与推理而建立的算法模型^[18]。采用灰狼算法优化深度学习算法的参数,通过选取对预测结果影响较大的参数,将预测误差设置为适应度函数,通过优化参数得到最佳的预测结果。

灰狼是一种严格区分社会等级的种群,一般分为 4 个社会等级,分别是狼群的领导者 α ,协助领导者 α 的 β 和 σ ,以及捕猎具体实施者 ω 。其中, ω 为狼群搜寻猎物的位置, α, β, σ 为 ω 规划移动方向。

在灰狼的狩猎行为中,狼群会通过跟踪、环绕逼近的方法捕猎,其捕猎一般分为 3 个步骤:(1) 寻找与逼近;(2) 追捕与包围;(3) 攻击猎物。位置以如下方式更新:

$$D = |CX_p(t) - X(t)| \quad (6)$$

$$X(t+1) = X_p(t) - A \times D \quad (7)$$

式中: t —迭代次数; $X_p(t)$ —迭代后的猎物位置; $X(t)$ —负责搜索的个体当前位置; D —个体与猎物之间的距离;控制参数 A —灰狼与猎物之间的距离关系;控制参数 C —在不同情况下灰狼与猎物距离的不确定性。其计算方式如下:

$$A = 2ar_1 - a \quad (8)$$

$$C = 2r_2 \quad (9)$$

$$a(t) = 2\left(1 - \frac{t}{T_{\max}}\right) \quad (10)$$

式中: r_1, r_2 —位于 0 与 1 之间的随机向量; a —在迭代过程中线性递减,由 2 递减到 0; T_{\max} —最大迭代次数。

狼群的具体捕猎过程如下:

$$D_i = |C_i \times X_i - X| \quad (11)$$

$$\begin{cases} X_\alpha = X_\alpha - A_1 \times D_\alpha \\ X_\beta = X_\beta - A_2 \times D_\beta \\ X_\sigma = X_\sigma - A_3 \times D_\sigma \end{cases} \quad (12)$$

$$X(t+1) = \frac{1}{3}X_t \quad (13)$$

式中: i —狼群的 α, β, σ 角色; D_i — i 与猎物寻找者 ω 的距离; X —狼群个体当前位置; X_i — ω 经过移动 D_i 后的位置; C_i —不同个体的控制参数; X_α, X_β 和 X_σ —经历 t 次迭代后其距离被追寻的猎物的距离。

2.3 模型评价指标

选取平均绝对百分比误差 MAPE、相对均方误差 RMSE、平均绝对误差 MAE、决定系数 R^2 评价模型预测的精度,具体公式如下:

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (14)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (15)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (16)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (17)$$

式中: \hat{y}_i —第*i*个数据的预测值; y_i —第*i*个数据的实际值; \bar{y}_i —第*i*个数据的平均值;*n*—样本的数量。

3 实验结果与分析

3.1 模型工作流程

该模型具体工作流程如图3所示。

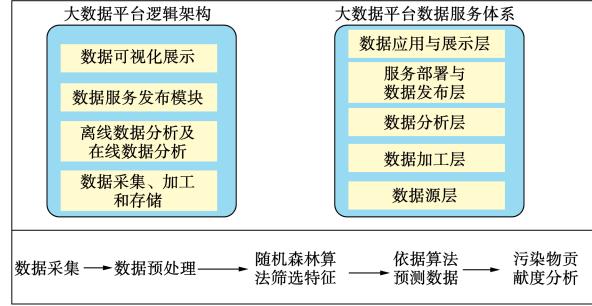


图3 平台预测算法流程

Fig. 3 Platform prediction algorithm process

共选取100天的燃煤电厂运行数据进行研究,前80天的数据进行训练,其余20天的数据用于测试与验证。此模型的输出参数为SO₂的排放质量浓度,输入特征参数分别为:进口O₂实测质量浓度、进口SO₂实测质量浓度、发电机功率、出口实测烟气流速、吸收塔1供浆调门开度和出口NO_x实测质量浓度。设置初始种群数量为100,最大迭代次数为100。

3.2 模型效果对比

GWO优化的N-BEATS预测算法的适应度进化曲线如图4所示,GWO-N-BEATS算法对SO₂排放质量浓度的预测结果如图5所示。

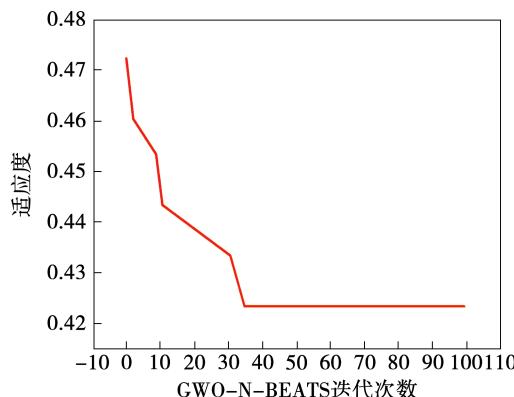
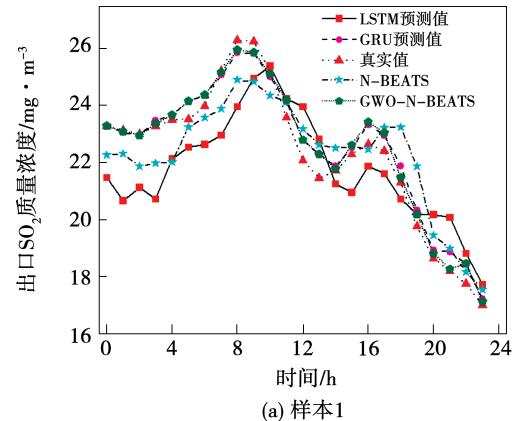


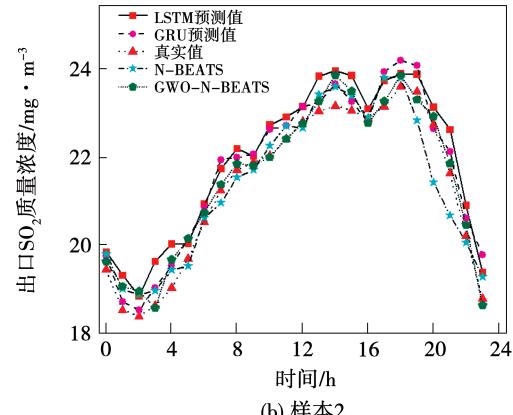
图4 GWO-N-BEATS预测算法的适应度进化曲线

Fig. 4 Fitness evolution curve of GWO-N-BEATS prediction algorithm

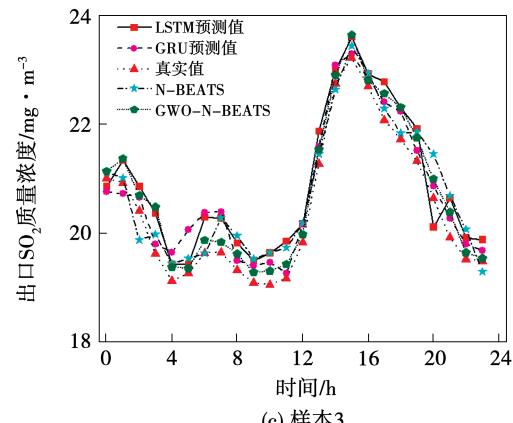
N-BEATS在经过GWO优化后适应度在迭代次数小于40次时达到最小值。由于适应度函数是以预测的误差为基准,因此适应度达到最小值时预测误差指标也达到最小值。可见,N-BEATS经过优化后能更好地对SO₂进行预测。



(a) 样本1



(b) 样本2



(c) 样本3

图5 GWO-N-BEATS算法对SO₂排放质量浓度的预测结果

Fig. 5 Results of SO₂ emission mass concentration predicted by GWO-N-BEATS algorithm

由于测试集数据众多,为验证本文所提出GWO-N-BEATS算法对SO₂排放质量浓度的预测效

果,随机选取测试集中的 3 天的数据用来更直观地观察模型的优越性,并将其与 N-BEATS、LSTM 以及 GRU 算法的预测效果进行了对比。由图 5 可知,GRU 相比 LSTM 算法模型拟合度较高;同时,N-BEATS 也能够很好地捕捉 SO₂ 的变化规律,尤其本文所提出的 GWO-N-BEATS 算法是经过 GWO 优化后的 N-BEATS,其拟合度更高。

不同算法测试集数据的总预测误差如表 2 所示。其中,GRU 的 MAPE 相比于 LSTM 降低了 4.14%,其他误差指标均有不同程度的降低,表明 GRU 具有良好的预测结果。同时 N-BEATS 预测算法的预测误差比 LSTM 的预测精度高,在经过 GWO 算法优化后的 N-BEATS 算法,即 GWO-N-BEATS 算法达到了最佳的预测效果,其 MAPE 值为 1.50%,比未优化前效果提升了 0.47%,其他误差指标均有所提升。

表 2 不同算法的预测误差表

Tab. 2 Prediction errors of different algorithms

算法	R ²	MAPE/%	MAE	RMSE
GRU	0.96	1.82	0.39	0.45
GWO-N-BEATS	0.97	1.50	0.33	0.42
LSTM	0.63	5.96	1.33	1.49
N-BEATS	0.93	1.97	0.45	0.65

通过上述实验比较,验证了基于大数据平台的 GWO-N-BEATS 算法在火电厂 SO₂ 排放质量浓度的预测中的有效性和优越性。首先,将传统机器学习模型和 GWO-N-BEATS 算法进行对比实验,结果表明,GWO-N-BEATS 算法在预测火电厂 SO₂ 排放质量浓度时具有更好的性能和更高的准确度;其次,进行了模型参数和结构的优化实验,结果表明,调整模型参数和结构可以进一步提高 GWO-N-BEATS 算法的预测性能;最后,将模型分别选取不同的测试集,以测试模型的泛化能力,结果表明,GWO-N-BEATS 算法在 3 个不同的时间段内都能够很好地预测火电厂 SO₂ 排放质量浓度,验证了其鲁棒性和可靠性。

4 结 论

基于大数据平台,提出了 GWO-N-BEATS 预测算法,并将该预测算法作为大数据平台监控污染的重要一环,进行实时 SO₂ 分析与预测。选取湖南某火电厂 1 号机组真实运行数据,开展了 SO₂ 的质量

浓度预测研究。得出以下结论:

(1) GWO-N-BEATS 通过 RF 对 18 个特征参量进行预筛选,通过随机森林算法处理并筛选出 6 个对 SO₂ 的排放影响最大的特征,分别为出口 NO_x 实测质量浓度、吸收塔 1 供浆调门开度、出口实测烟气流速、发电机功率、进口 SO₂ 实测质量浓度和进口 O₂ 实测质量浓度。

(2) 通过 GWO 对 N-BEATS 的参数进行优化,并与 GRU、LSTM 和 N-BEATS 进行对比分析,本文所提出算法误差更小,其中 MAPE 为 1.50%,RMSE 为 0.42,MAE 为 0.33,R² 为 0.97,预测结果优于其他 3 个基准模型。

(3) GWO-N-BEATS 是一种端到端学习的模型,可以直接从原始数据中学习时间序列的特征,避免了手动特征工程的繁琐过程,同时本模型依托于真实的大数据平台,探索了复杂智能算法模型应用于大数据平台实现污染监管与预测的可行性。

参考文献:

- [1] 刘福国,崔福兴,刘豪杰. 电厂日常煤耗检测的不确定度分析 [J]. 热能动力工程,2019,34(3):140–146.
LIU Fu-guo, CUI Fu-xing, LIU Hao-jie. Uncertainty analysis of daily coal consumption rate detection in generator unit by positive balance method [J]. Jouonal of Engineering for Thermal Energy and Power,2019,34(3):140–146.
- [2] 马利君,尚江峰,王涛,等. 基于 GWO 算法的脱硫系统出口 SO₂ 排放浓度目标值预测 [J]. 热能动力工程,2021,36(6):119–125.
MA Li-jun, SHANG Jiang-feng, WANG Tao, et al. Target value prediction of SO₂ emission concentration at the outlet of desulfurization system based on GWO algorithm [J]. Jouonal of Engineering for Thermal Energy and Power,2021,36(6):119–125.
- [3] 朱斌. 基于 BP 神经网络的燃煤机组 NO_x 排放浓度预测系统 [J]. 电力科技与环保,2015,31(3):12–14.
ZHU Bin. Prediction system of coal-fired power plants NO_x emission concentration based on BP neural network [J]. Electric Power Technology and Environmental Protection,2015,31(3):12–14.
- [4] DEBNATH K B, MOURSHEDE M. Forecasting methods in energy planning models [J]. Renewable & Sustainable Energy Reviews, 2018,88:297–325.
- [5] 李一琨,车权,赵慧荣,等. 基于 PSO-SVM 的电网调度电厂耗煤基准值滚动预测 [J]. 中国电力,2020,53(2):142–149.
LI Yi-kun, CHE Quan, ZHAO Hui-rong, et al. PSO-SVM-based rolling forecast of coal consumption reference value for the power plants dispatched by power grid [J]. Electric Power, 2020, 53(2):142–149.

- [6] 邓威,郭钇秀,李勇,等.基于聚类及趋势指标的长短期神经网络配网负荷短期预测[J].湖南电力,2021,41(4):27-33.
- DENG Wei, GUO Yi-xiu, LI Yong, et al. Short-term lines load prediction of LSTM distribution network based on clustering and trend indicators[J]. Hunan Electric Power, 2021, 41(4): 27 - 33.
- [7] 张文广,张越.基于PLS和ε-FT的电站锅炉NO_x排放特性研究[J].动力工程学报,2017,37(3):186-191.
- ZHANG Wen-guang, ZHANG Yue. Study on NO_x emission characteristics of utility boilers based on PLS and ε-FT [J]. Journal of Chinese Society of Power Engineering, 2017, 37(3): 186 - 191.
- [8] 裴旭倩.基于ADMS的火电厂高架源排放二氧化硫浓度分布特征研究[D].太原:太原理工大学,2015.
- PEI Xu-qian. Research on concentration distribution characteristics of SO₂ discharged from coal-fired power plant elevated source based on ADMS [D]. Taiyuan: Taiyuan University of Technology, 2015.
- [9] 何璞祯,吴尚平.燃气与燃煤电厂主要大气污染排放物的对比分析[J].广州化工,2020,48(20):99-103.
- HE Pu-zhen, WU Shang-ping. Major atmospheric pollution comparison of gas and coal power plants [J]. Guangzhou Chemical Industry, 2020, 48(20): 99 - 103.
- [10] 蒋星明,曹顺安,王民军,等.双向门控循环神经网络的SO₂排放浓度预测模型[J].应用化工,2021,50(12):3519-3523.
- JIANG Xing-ming, CAO Shun-an, WANG Min-jun, et al. Prediction model of SO₂ emission concentration based on bidirectional gated recurrent neural network [J]. Applied Chemical Industry, 2021, 50(12): 3519 - 3523.
- [11] 杨蓉,杨林,谭盛兰,等.基于遗传算法优化长短期记忆神经网络的柴油机瞬态NO_x排放预测模型研究[J].内燃机工程,2022,43(1):10-17.
- YANG Rong, YANG Lin, TAN Sheng-lan, et al. Prediction model for transient NO_x emission of diesel engine based on GA-long short term memory(LSTM) neural network [J]. Chinese Internal Combustion Engine Engineering, 2022, 43(1): 10 - 17.
- [12] 刘艳华,张承中,王小平,等.基于遗传神经网络的采暖季PM10浓度预测[J].安徽农业科学,2009,37(16):7650-7651.
- LIU Yan-hua, ZHANG Cheng-zhong, WANG Xiao-ping, et al. Prediction of PM10 pollution concentration in heating season based on genetic algorithms and neural network [J]. Journal of Anhui Agricultural Sciences, 2009, 37(16): 7650 - 7651.
- [13] 李昌庆.基于过滤-封装法与GA-BP神经网络的大小型客车气态物排放预测[D].长沙:湖南大学,2020.
- LI Chang-qing. Gas emission prediction of large and small buses based on filter-wrapper method and GA-BP neural network [D]. Changsha: Hunan University, 2020.
- [14] ANTONIO C. Decision forests: A unified framework for classification, regression, density estimation, manifold learning and semi-supervised learning [J]. Foundations & Trends in Computer Graphics & Vision, 2011, 7(2/3): 81 - 227.
- [15] BREIMAN L. Random forests [J]. Machine Learning, 2001, 45(1): 5 - 32.
- [16] ORESHKIN B N, DUDEK G, PEKA P, et al. N-BEATS neural network for mid-term electricity load forecasting [J]. Applied Energy, 2021, 293(1): 116918.
- [17] PUTZ D, GUMHALTER M, AUER H. A novel approach to multi-horizon wind power forecasting based on deep neural architecture [J]. Renewable Energy, 2021, 178: 494 - 505.
- [18] SM A, SMM B, Al A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69(3): 46 - 61.

(姜雪梅 编辑)