

DOI: 10.19666/j.rlfed.202404086

基于集成学习的 CFB 锅炉氮氧化物 排放质量浓度在线建模研究

吴家标^{1,2,3}, 刘兴高^{1,2}

(1.浙江大学工业控制技术全国重点实验室, 浙江 杭州 310027;

2.浙江大学工业控制科学与工程学院, 浙江 杭州 310027;

3.丽水市杭丽热电有限公司, 浙江 丽水 323010)

[摘要] 针对循环流化床锅炉氮氧化物排放质量浓度变化规律复杂、自相关性强等特点, 利用有关变量及其历史信息, 分别建立了氮氧化物排放质量浓度的整合移动平均自回归 (ARIMA) 和随机森林 (RF)、梯度提升树 (GBDT)、极致梯度提升树 (XGBoost) 等集成学习在线模型, 并对预测效果进行对比择优, 其中以 GBDT 回归器为最优。为了进一步改进模型的预测效果, 提出将一阶差分与 GBDT 回归算法相结合, 建立了 GBDT 差分回归模型。测试表明所建立的 GBDT 差分回归模型比前述模型具有更好的预测性能, 其预测值的均方差比单纯 GBDT 回归器降低了 20.2%, 并比参考文献采用的在线贯序极限学习机 (OS-ELM) 模型低 46.5%。所建的在线模型还充分考虑避免仪表吹扫过程的影响, 具有较强的实用性。

[关键词] 循环流化床锅炉; 氮氧化物; ARIMA; 集成学习; GBDT 差分在线模型

[引用本文格式] 吴家标, 刘兴高. 基于集成学习的 CFB 锅炉氮氧化物排放质量浓度在线建模研究[J]. 热力发电, 2024, 53(12): 86-92. WU Jiabiao, LIU Xinggao. Research on online modeling of nitrogen oxides emission mass concentration of circulating fluidized bed boiler based on ensemble learning[J]. Thermal Power Generation, 2024, 53(12): 86-92.

Research on online modeling of nitrogen oxides emission mass concentration of circulating fluidized bed boiler based on ensemble learning

WU Jiabiao^{1,2,3}, LIU Xinggao^{1,2}

(1.State Key Laboratory of Industry Control Technology, Zhejiang University, Hangzhou 310027, China;

2.College of Control Science & Engineering, Zhejiang University, Hangzhou 310027, China;

3.Lishui City Hangli Cogeneration Co., Ltd., Lishui 323010, China)

Abstract: In view of the complex variation law and strong autocorrelation of nitrogen oxides emission mass concentration of circulating fluidized bed (CFB) boiler, by using relevant variables and their historical information, ensemble learning online models of nitrogen oxides emission mass concentration are established. The ensemble learning online models include the autoregressive integrated moving average (ARIMA), random forest (RF), gradient boosting (GBDT), and eXtreme gradient boosting (XGBoost) model. The prediction results are compared and selected, among which the GBDT regressor is the best. In order to further improve the prediction effect of the model, a GBDT differential regression model is established by combining the first-order difference with the GBDT regression algorithm. The tests show that the established GBDT differential regression model has better prediction performance than the aforementioned models. The mean squared error of the predicted value is 20.2% lower than that of the simple GBDT regressor, and 46.5% lower than that of the online sequential extreme learning machine (OS-ELM) model used in the reference. The online model also fully considers avoiding the influence of the instrument purge process, and has strong practicability.

Key words: CFB boiler; nitrogen oxides; ARIMA; ensemble learning; GBDT differential online model

收稿日期: 2024-04-30

基金项目: 国家重点研发计划项目 (2021YFC2101100); 国家自然科学基金项目 (62073288, 12075212)

Supported by: National Key Research and Development Program (2021YFC2101100); National Natural Science Foundation of China (62073288, 12075212)

第一作者简介: 吴家标 (1977), 男, 硕士, 高级工程师, 主要研究方向为工业过程建模、优化与控制, 1176567249@qq.com。

随着环保形势日趋严峻,人们迫切需要深入了解燃煤设备的环保指标变化规律,以便更加有效地对其进行控制。氮氧化物、二氧化硫、粉尘是燃煤循环流化床锅炉(CFB)的3项主要环保排放指标,其中氮氧化物是控制难度最大的一项。建立循环流化床锅炉氮氧化物的在线预测模型对锅炉的运行监视、控制等具有重要实际意义。

本文以某热电厂一台额定蒸发量为 130 t/h 的高温超高压燃煤循环流化床锅炉为例,进行氮氧化物排放质量浓度的在线模型建模研究。该炉采用选择性非催化还原(SNCR)+选择性催化还原(SCR)联合脱硝法对氮氧化物进行脱除。

目前在氮氧化物排放数据分析中,大部分学者采用支持向量机、神经网络算法和集成学习算法进行建模^[1-6]。其中集成学习算法通过组合不同学习器的优势,提高整个集成模型的泛化能力和鲁棒性,避免单一模型所带来的局限性^[1]。文献[3]也表明集成学习算法之一的梯度提升树(GBDT)比支持向量回归(SVR)和长短期记忆网络(LSTM)更具优势。然而目前研究尚缺乏对不同种类集成学习算法对氮氧化物预测效果的具体比较,以及对集成学习算法进一步改进的有效方法。本文则是采用整合移动平均自回归(ARIMA)和多种集成学习算法分别建立循环流化床锅炉氮氧化物在线预测模型,并进行详细地对比择优,创新性地提出 GBDT 差分回归模型,以进一步提高模型的预测性能。此外,建模时还充分考虑避免受仪表吹扫过程的实际影响。

1 变量的选择

循环流化床锅炉氮氧化物排放(NO_x)变化规律非常复杂,其影响因素包括因变量(NO_x)自身的历史信息,以及其他有关变量的当前值及历史信息。

除因变量(NO_x),可从现场获得的变量主要有燃煤成分(包括水分、灰分、挥发分、低位发热量)、给煤流量、一次风流量、二次风流量、氧量、主蒸汽流量、氨水流量、炉膛出口烟气温度(即 SNCR 反应温度)、SCR 入口烟气温度等。

为避免自变量之间的强相关,本文忽略给煤流量、一次风流量、二次风流量、炉膛出口温度等与锅炉负荷(主蒸汽流量)或烟气含氧量有很强相关性的变量,并采用氨水耗率(氨水流量与主蒸汽流量之比)代替氨水流量。经综合考虑,建模所用的

变量见表 1,各变量在工艺过程中的逻辑关系如图 1 所示。

表 1 建模所用的变量
Tab.1 Variables used in modeling

变量	物理意义	变量	物理意义
$x_1/\%$	燃煤水分	$x_6/(\text{m}^3\cdot\text{t}^{-1})$	氨水耗率
$x_2/\%$	燃煤灰分	$x_7/(\text{t}\cdot\text{h}^{-1})$	主蒸汽流量
$x_3/\%$	燃煤挥发分	$x_8/^\circ\text{C}$	SCR 入口烟温
$x_4/(\text{MJ}\cdot\text{kg}^{-1})$	燃煤低位热值	$y/(\text{mg}\cdot\text{m}^{-3})$	氮氧化物排放质量浓度(标况下)
$x_5/\%$	烟气含氧量		




图 1 建模所用变量在工艺过程中的逻辑关系示意
Fig.1 Schematic diagram of the logical relationship between the variables used in modeling in the process

2 数据的准备

2.1 数据来源

建模数据中,过程数据 x_5-x_8 、 y 来自锅炉连续正常运行 10 日的分散控制系统(DCS)历史记录,采样周期为 30 s,共 28 800 个样本;燃煤成分数据 x_1-x_4 来自每日仅一组的入炉煤工业分析数据,故同一日的样本点采用相同的煤分析数据。

对于历史信息,由于氮氧化物分析仪存在定期或不定期吹扫问题,吹扫期间氮氧化物测量值有大幅度的异常波动,真实数据无法获得,而用插值法也只能等吹扫完成后形成。根据一般吹扫时间,本文设定因变量可利用的历史数据是 3 min 前,即时间点 $t-6$ 及以前的历史数据。煤分析数据之外的自变量不受此限制,可利用时间点 $t-1$ 及以前的历史数据。而煤分析数据为每日更新 1 次,其短期历史信息无变化,故不重复采用。

2.2 数据处理

针对氮氧化物分析仪吹扫期间的异常波动,本文先检测出吹扫期间的最高值,将最高值及其前 2 个、后 1 个时间点数值,采用时间点 $t-3$ 与时间点 $t+2$ 信号进行线性插值。

此外, 本文按 3σ 原则处理其他可能的异常数据, 并将自变量数据采用标准差标准化。

2.3 数据分集

将 28 800 个样本点按 7.0:1.5:1.5 的数量比例进行划分, 按时间先后顺序依次作为训练集 (training set)、验证集 (validation set) 和测试集 (test set), 分别用于模型训练、模型网络结构搜索和模型的最终评估。

3 建模

本文主要使用 Python 编程语言^[7-8]进行建模、模型训练、测试等工作。

3.1 整合移动平均自回归模型 (ARIMA 模型)

氮氧化物排放质量浓度的采样信号具有较强的前后相关性, 可以当作时间序列。ARIMA 模型^[9-10]是针对时间序列的一种常用预测分析方法, 其表达式如下。

$$y'(t) = c + \sum_{i=1}^p \phi_i y'(t-i) + \sum_{j=1}^q \theta_j \varepsilon(t-j) + \varepsilon(t) \quad (1)$$

式中: $y'(t)$ 为经过差分化的时间序列; p 为该模型 AR (自回归) 部分的阶数; q 为该模型 MA (移动平均) 部分的阶数; d 为差分化的阶数; ϕ_i 、 θ_j 为权重, 由机器学习获得; $\varepsilon(t)$ 为时刻 t 的预测误差。

本文采用 6 及其倍数的时间点前的历史信息, 故实际采用下式模型:

$$y'(t) = c + \sum_{i=1}^p \phi_{6i} y'(t-6i) + \sum_{j=1}^q \theta_{6j} \varepsilon(t-6j) + \varepsilon(t) \quad (2)$$

确定 p 、 d 、 q 是 ARIMA 模型建模的重要步骤。使用 statsmodels 库中的 plot_acf 和 plot_pacf 函数分别绘制训练集 NO_x 变量的自相关图 (ACF) 和偏自相关图 (PACF), 具体如图 2 所示。





图 2 NO_x 变量的自相关图和偏自相关图
Fig.2 The autocorrelation graph and partial autocorrelation graph of NO_x variable

由图 2 可以看出, NO_x 变量在时间点 t 之前的多个时间点数值均与时间点 t 的数值有很强的自相关性, 但 1 个时间点 ($t-6$) 之前数值的偏自相关性已锐利截止, 按一般经验可取 $p=1$ 。

差分的主要作用在于将原时间序列变为平稳序列, 而序列是否相对平稳可通过观察序列本身的走势来判断。绘制训练集 NO_x 质量浓度变量部分数值序列及其相应一阶差分序列的变化趋势如图 3 所示 (标况下, 后同)。由图 3 可见, 可见原时间序列平稳性较差, 而一阶差分序列已基本平稳, 按一般经验可取 $d=1$ 。




图 3 NO_x 变量及其一阶差分的平稳性
Fig.3 The stationarity of NO_x variable and its first-order difference

q 的取值使用赤池信息量准则 (Akaike information criterion, AIC) 衡量不同参数下 ARIMA 模型的优劣, 以 AIC 值最低者为最优模型。使用 statsmodels 库的 ARIMA 算法, 将 p 、 d 、 q 设定在 $[0,1,2]$ 范围内, 对训练集数据用不同参数组合的模型进行训练并比较 AIC 值, 得到最优模型对应的 p 、 d 、 q 分别为 1、1、1。可见 p 、 d 最优值与上述经验观察法一致。表 2 显示了排名前 3 的 p 、 d 、 q 组合及其对应 AIC 值。

表 2 排名前 3 的 p 、 d 、 q 组合及其对应 AIC 值
Tab.2 The top 3 combinations of p , d , q and their corresponding AIC values

p	d	q	AIC
1	1	1	16 452.4
2	1	1	16 453.8
1	1	2	16 453.9

程序输出最优模型对应的系数 $ar.L1=0.898$;

$ma.L1=-0.978$, 即最优 ARIMA 模型表达式为:

$$\hat{y}'(t) = 0.898y'(t-6) + (1-0.978)[y(t-6) - \hat{y}(t-6)] \quad (3)$$

上式为差分形式, 为便于理解可转换为非差分形式为:

$$\hat{y}(t) = 0.920y(t-6) - 0.898y(t-12) + 0.978\hat{y}(t-6) \quad (4)$$

用上述最优 ARIMA 模型对测试集数据进行预测, 其中部分预测值的变化趋势与实际值对照如图 4 所示。由图 4 可以看出, 该模型预测值存在明显的滞后性。




图 4 ARIMA 模型对 NO_x 变量的预测效果
Fig.4 The prediction effect of ARIMA model on NO_x variable

3.2 集成学习回归模型

上述 ARIMA 模型只用到因变量的历史信息, 预测存在较强的滞后特性。为此考虑增加自变量当前值及其历史信息作为模型输入信号, 并用集成学习算法输出时刻 t 的预测值。模型表达式为:

$$\hat{y}(t) = f(x_1(t), \dots, x_4(t), x_5(t), \dots, x_8(t), x_5(t-1), \dots, x_8(t-1), x_5(t-2), \dots, x_8(t-2), \dots, x_5(t-n), \dots, x_8(t-n), y(t-6)) \quad (5)$$

式中: $f(x)$ 为某种集成学习回归算法; n 为采用自变量历史信息的时间点数。

较大的 n 值意味着更多的自变量历史信息被引入模型, 在一定范围内提高 n 值有利于提高模型精度, 但 n 值过大容易产生过拟合, 且使模型过于复杂。

为此采用线性回归模型, 对不同的 n 值所构成

的输入信号, 用训练集数据进行线性回归, 并用测试集数据比较预测得分, 其结果如图 5 所示。综合考虑模型精度和模型复杂度, 取 $n=9$ 。




图 5 自变量历史信息时间点对预测效果的影响
Fig.5 The influence of the number of historical information time points of independent variables on the prediction effect

集成学习 (ensemble learning) 是近年发展起来的一类先进的机器学习算法, 其基本思想是对多个弱监督学习模型进行组合, 以期获得一个较强的监督学习模型^[11-12]。针对式(5)中的 $f(x)$, 下文分别采用随机森林 (random forest, RF)^[13-17]、GBDT^[18-21]、极致梯度提升树 (extreme gradient boosting, XGBoost)^[22-25] 3 种主流的集成学习回归器算法进行择优。

上述 3 种回归器都有基础决策树的个数 ($n_estimators$)、树的最大深度 (max_depth) 2 项对模型性能有较大影响的网络结构参数。为此采用网格搜索法进行网络结构调优: 对不同的网络结构参数组合, 用训练集数据进行训练, 并对验证集数据进行预测, 以得分 (score) 高者为优。

上述得分为 Python 机器学习库对回归问题的常用评估参数, 其算法同决定系数 (coefficient of determination, R^2), 表达式为:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

式中: n 为样本数量; y_i 为实际值; \hat{y}_i 为预测值; \bar{y} 为样本均值。

经比选, 3 种回归器最优网络结构参数及相应的验证集得分见表 3。选其中最优的 GBDT 回归器对测试集数据进行预测, 作与图 4 同时间段的预测趋势, 具体如图 6 所示。

由图 6 可见, 集成学习回归模型的拟合效果比 ARIMA 有较大改善, 主要体现在预测值的滞后性明显减小, 但局部存在较大幅度的偏离。

表3 集成学习回归器最优网络结构参数及相应得分
Tab.3 Optimal network structural parameters and corresponding scores of ensemble learning regressors

	RF	GBDT	XGBoost
n_estimators	86	166	94
max_depth	23	4	3
score	0.933	0.943	0.939




图6 GBDT 回归模型对 NO_x 变量的预测效果
Fig.6 The prediction effect of GBDT regression model on NO_x variable

3.3 集成学习差分回归模型

为了进一步提高模型的预测性能，采用 ARIMA 与集成学习相结合的模型，其表达式为：

$$\hat{y}(t) = y(t-6) + \Delta\hat{y}(t) \quad (7)$$

其中，

$$\begin{aligned} \Delta\hat{y}(t) = & g(x_1(t), \dots, x_4(t), x_5(t), \dots, \\ & x_8(t), x_5(t-1), \dots, x_8(t-1), \\ & x_5(t-2), \dots, x_8(t-2), \dots, \\ & x_5(t-n), \dots, x_8(t-n)) \end{aligned} \quad (8)$$

式中： $g(x)$ 为某种集成学习差分回归算法； n 为采用自变量历史信息的时间点数。

式(7)可看作一阶差分形式，是 ARIMA 的特殊形式。不同之处在于差分部分由集成学习回归器进行预测。在此称 $g(x)$ 为集成学习差分回归器，以示区别。差分回归器的输入变量包含原自变量及其前面 n 个时间点的历史数据，不再包含因变量的历史数据 $y(t-6)$ 。综合考虑模型的精度与复杂度，取 $n=9$ 。

差分回归器也采用 RF、GBDT、XGBoost 3 种集成学习回归器进行择优。此时，训练集数据的标签变量由 $y(t)-y(t-6)$ 代替。

同样采用网格搜索法进行差分回归器的网络结构调优。各回归器最优网络结构参数及相应的验证集得分见表 4。

值得注意的是，此处是对差分部分的预测得分，而非对最终 $y(t)$ 的预测得分。

表4 集成学习差分回归器最优网络结构参数及相应得分
Tab.4 The optimal network structural parameters and corresponding scores of ensemble learning differential regressors

	RF 差分	GBDT 差分	XGBoost 差分
n_estimators	40	32	12
max_depth	15	12	11
score	0.329	0.342	0.325

选择其中得分最高的 GBDT 差分回归器，通过式(7)构建的模型对测试集数据进行预测，作与图 4 同时间段的预测趋势，具体如图 7 所示。




图7 GBDT 差分回归模型对 NO_x 变量的预测效果
Fig.7 The prediction effect of GBDT differential regression model on NO_x variable

由图 7 可见，该模型获得了比 ARIMA、常规集成学习回归器更好的拟合度，其预测值滞后性比 ARIMA 明显减小，而局部偏离的幅度比常规集成学习回归器小。

3.4 其他对照模型

用于锅炉氮氧化物在线预测模型的一种常见算法是在线贯序极限学习机 (OS-ELM) [26-27]。作为比较，采用 OS-ELM 模型对本文训练集进行训练，并根据验证集预测得分确定最优隐层节点数为 178。用该模型对测试集数据进行预测，作与图 4 同时间段的预测趋势，具体如图 8 所示。




图8 OS-ELM 模型对 NO_x 变量的预测效果
Fig.8 The prediction effect of OS-ELM model on NO_x variable

由图 8 可见，该模型预测值局部偏离的情况较

为多发,且偏离幅度较大,其拟合度不及本文提出的 GBDT 差分回归模型。

3.5 各类在线模型比较及实际应用探讨

取本文研究的 3 类模型中的最优者,即 ARIMA(1,1,1)模型、GBDT 回归模型、GBDT 差分回归模型及文献[26-27]中的 OS-ELM 模型,分别对测试集数据的 NO_x 进行预测,并分别计算决定系数 (R^2)、绝对平均误差 (δ_{MAE})、均方差 (δ_{MSE}) 3 项性能指标,具体见表 5 和表 6。

表 5 本文研究的 3 类模型性能指标对比

Tab.5 Comparison of three types of model performance indicators studied in this paper

	ARIMA	GBDT	GBDT 差分	GBDT 差分与 GBDT 对比
R^2	0.918	0.948	0.959	1.1%
δ_{MAE}	1.338	1.095	0.973	-11.1%
δ_{MSE}	4.507	2.837	2.264	-20.2%

表 6 本文最优模型与参考文献模型性能指标对比

Tab.6 Performance index comparison between the optimal model in this paper and the model in literature

	OS-ELM	GBDT 差分	对比
R^2	0.923	0.959	3.9%
δ_{MAE}	1.473	0.973	-34.0%
δ_{MSE}	4.229	2.264	-46.5%

可见,本文所提出的集成学习 GBDT 差分回归模型对 NO_x 的预测具有一定的优势,按本文测试数据,其 δ_{MAE} 比次优的单纯 GBDT 回归模型降低了 20.2%,并比 OS-ELM 模型低 46.5%。由于集成学习差分回归模型中,集成学习回归器专用于预测增量,故该模型还具有较好的解释性。

图 9 为将 GBDT 差分回归模型预测值与含有吹扫过程的原 NO_x 信号实际值进行对照。所建模型实现预测的同时,较好地回避了吹扫产生的异常数据。该模型可使运行人员在 NO_x 表计吹扫期间仍能较好地监视 NO_x 的变化,此外该模型也可以为控制系统提供较好的预测作用。




图 9 含吹扫过程的预测效果

Fig.9 Prediction effect with purge process

4 结 语

本文采用不同类型的机器学习算法对 CFB 的氮氧化物排放质量浓度进行在线模型的建模研究。其中,集成学习回归模型比整合移动平均自回归模型具有更好的性能,其中又以 GBDT 回归器为最优。而本文提出的集成学习差分回归模型比常规集成学习模型的预测性能又有一定的提高。测试表明 GBDT 差分回归器预测值的 δ_{MAE} 比单纯 GBDT 回归器降低了 20.2%,并比参考文献采用的 OS-ELM 模型低 46.5%。所建的在线模型还充分考虑避免仪表吹扫过程的影响,对 CFB 环保运行的监视、控制等具有一定的意义。

[参 考 文 献]

- [1] 姚顺春,李龙千,卢志民,等.机器学习驱动锅炉燃烧优化技术的现状与展望[J].洁净煤技术,2024,30(2):228-243.
YAO Shunchun, LI Longqian, LU Zhimin, et al. Current situation and prospect of machine learning-driven boiler combustion optimization technology[J]. Clean Coal Technology, 2024, 30(2): 228-243.
- [2] WANG Z, PENG X, ZHOU H, et al. A dynamic modeling method using channel-selection convolutional neural network: a case study of NO_x emission[J]. Energy, 2024, 290: 130270.
- [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. Review of applications of machine learning in nitrogen oxides reduction in thermal power plants[J]. Thermal Power Generation, 2023, 52(1): 7-17.
- [4] DING X S, FENG C, YU P L, et al. Gradient boosting decision tree in the prediction of NO_x emission of waste incineration[J]. Energy, 2023, 264: 126174.
- [5] 朱一波,茅大钧,陈思勤.考虑混煤煤质特性的脱硝系统入口 NO_x 浓度预测[J/OL].计算机仿真:1-6.(2024-04-19)[2024-04-29].
<https://link.cnki.net/urlid/11.3724.TP.20240419.1344.014>.
ZHU Yibo, MAO Dajun, CHEN Siqin. NO_x concentration at inlet of SCR denitration system considering coal quality characteristics of blended coal predictive research[J/OL]. Computer Simulation: 1-6. (2024-04-19)[2024-04-29].
<https://link.cnki.net/urlid/11.3724.TP.20240419.1344.014>.
- [6] 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.
- [7] 王沁晨. Python 预测分析与机器学习[M].北京:清华大学出版社,2022:1.
WANG Qinchen. Python predictive analysis and machine learning[M]. Beijing: Tsinghua University Press, 2022: 1.
- [8] 屈希峰,党武娟.机器学习实战:基于 Python SKlearn 的解析[M].北京:中国铁道出版社有限公司,2023:1.

- QU Xifeng, DANG Wujuan. Machine learning practice: parsing based on Python SKlearn[M]. Beijing: China Railway Publishing House Co., Ltd., 2023: 1.
- [9] 程伟志, 张军, 张洪征. 基于 ARIMA 模型的我国城市集中供热分析与预测研究[J]. 城市建设理论研究(电子版), 2024(7): 175-177.
CHENG Weizhi, ZHANG Jun, ZHANG Hongzheng. Analysis and prediction of urban central heating in China based on ARIMA model[J]. Theoretical Research in Urban Construction, 2024(7): 175-177.
- [10] 岳建通, 吴迪, 钱金跃. 基于 ARIMA 模型的分布式光伏出力预测方法应用[J]. 农村电工, 2024, 32(2): 31-32.
YUE Jiantong, WU Di, QIAN Jinyue. Application of distributed photovoltaic output prediction method based on ARIMA model[J]. Rural Electrician, 2024, 32(2): 31-32.
- [11] 成佩, 孟勇. 集成学习方法的应用与比较[J]. 统计与决策, 2023, 39(23): 28-33.
CHENG Pei, MENG Yong. Application and comparison of ensemble learning methods[J]. Statistics and Decision Making, 2023, 39(23): 28-33.
- [12] 赵卫东, 董亮. 机器学习[M]. 2 版. 北京: 人民邮电出版社, 2022: 1.
ZHAO Weidong, DONG Liang. Machine learning [M]. 2nd ed. Beijing: Post and Telecom Press, 2022: 1.
- [13] 郭龙, 郭文文. 基于 SVR 和随机森林模型的动力煤高位发热量预测研究[J]. 能源工程, 2024, 44(1): 35-42.
GUO Long, GUO Wenwen. Prediction of higher heating value of fuel coal based on SVR and random forest models[J]. Energy Engineering, 2024, 44(1): 35-42.
- [14] 韩丹. 基于随机森林算法的 CFB 机组给水流量预测[J]. 科技创新与生产力, 2023(2): 124-126.
HAN Dan. Prediction of CFB unit feedwater flow based on random forest algorithm[J]. Scientific and Technological Innovation and Productivity, 2023(2): 124-126.
- [15] 包国强, 顾维根, 穆维国, 等. 基于机器学习的气固流化床最小流化速度预测[J]. 洁净煤技术, 2021, 27(5): 25-31.
BAO Guoqiang, GU Weigen, MU Weiguo, et al. Prediction of minimum fluidization velocity in gas-solid fluidized bed based on machine learning[J]. Clean Coal Technology, 2021, 27(5): 25-31.
- [16] 张程珂, 刘会灯, 朱渝宁, 等. 基于多特征分析提取的随机森林超短期光伏功率预测[J]. 电力需求侧管理, 2023, 25(6): 50-56.
ZHANG Chengke, LIU Huideng, ZHU Yuning, et al. Ultra-short-term photovoltaic power prediction for random forests based on multiple feature analysis and extraction[J]. Power Demand Side Management, 2023, 25(6): 50-56.
- [17] GÜNDÖĞDU S, ELBIR T. A data-driven approach for PM_{2.5} estimation in a metropolis: random forest modeling based on ERA5 reanalysis data[J]. Environmental Research Communications, 2024, 6(3): 035029.
- [18] 邹鑫, 罗涓. 用梯度提升决策树实现电力负荷非线性影响因素分析[J]. 电力科学与工程, 2024, 40(3): 10-19.
ZOU Xin, LUO Juan. The analysis of nonlinear influence factors of electric power load realized by gradient lifting decision tree[J]. Electric Power Science and Engineering, 2024, 40(3): 10-19.
- [19] 姚鹏飞. 基于梯度提升决策树的火电厂汽轮机故障检测研究[J]. 低碳世界, 2024, 14(3): 115-117.
YAO Pengfei. Research on fault detection of steam turbines in thermal power plants based on gradient boosting decision tree[J]. Low Carbon World, 2024, 14(3): 115-117.
- [20] 杨国田, 何雨晨, 李鑫, 等. 基于梯度提升决策树改进双向门限循环单元的锅炉变负荷燃烧系统建模[J]. 热力发电, 2021, 50(12): 6-12.
YANG Guotian, HE Yuchen, LI Xin, et al. Modeling of boiler combustion system at variable load using GBDT-BiGRU[J]. Thermal Power Generation, 2021, 50(12): 6-12.
- [21] GUO G X, ZHU W J, SUN Z Y, et al. An aero-structure-acoustics evaluation framework of wind turbine blade cross-section based on gradient boosting regression tree[J]. Composite Structures, 2024, 337: 118055.
- [22] 柯亮, 李波, 廖凯, 等. 基于 XGBoost 的配电网高阻接地故障检测方法[J]. 电力系统保护与控制, 2024, 52(6): 88-98.
KE Liang, LI Bo, LIAO Kai, et al. High impedance fault detection method in a distribution network based on XGBoost[J]. Power System Protection and Control, 2024, 52(6): 88-98.
- [23] 杨黔, 程斯祥, 周鹏, 等. 基于机理和 XGBoost 算法的 LF 精炼钢水成分预测模型[J]. 自动化应用, 2024, 65(2): 5-7.
YANG Qian, CHENG Sixiang, ZHOU Peng, et al. Prediction model for LF refined steel composition based on mechanism and XGBoost algorithm[J]. Automatic Application, 2024, 65(2): 5-7.
- [24] 雍和忠, 章宁, 黄伟, 等. 基于 XGBoost 的供热系统热力站调控预测方法[J]. 综合智慧能源, 2023, 45(12): 36-42.
YONG Hezhong, ZHANG Ning, HUANG Wei, et al. XGBoost-based regulation and prediction method for the heating station's heating system[J]. Integrated Smart Energy, 2023, 45(12): 36-42.
- [25] SUN X L, FU J Q, ZHOU F, et al. Performance prediction and multi-objective optimization for the Atkinson cycle engine using extreme gradient boosting[J]. Thermal Science and Engineering Progress, 2024, 48: 102402.
- [26] 张京, 孙博, 陈皓. 基于 OS-ELM 的循环流化床锅炉 NO_x 建模研究[J]. 自动化应用, 2017(4): 51-52.
ZHANG Jing, SUN Bo, CHEN Hao. Research on NO_x modeling of circulating fluidized bed boiler based on OS-ELM[J]. Automation Application, 2017(4): 51-52.
- [27] 金鹏. 基于 OS-ELM 算法的燃烧系统建模研究[J]. 电动工具, 2021(2): 14-16.
JIN Peng. Research on modeling of combustion system based on OS-ELM algorithm[J]. Power Tools, 2021(2): 14-16.

(责任编辑 邓玲惠)