

DOI: 10.19666/j.rlfd.202605116

基于 BO-XGBoost 与改进 NSGA-II 的锅炉 燃烧多目标优化

王伟杰¹, 梁洋洋², 王建光¹, 方思晗³, 刘开通¹, 钱能², 陈刚强², 薛亚丽³

(1. 国电建投内蒙古能源有限公司, 内蒙古 鄂尔多斯 017209;

2. 北京新叶科技股份有限公司, 北京 100085; 3. 清华大学能源与动力工程系, 北京 100084)

[摘要] 【目的】对燃煤锅炉燃烧开展多目标优化是实现锅炉高效环保运行的重要途径。【方法】本文基于 XGBoost 模型建立锅炉排烟温度、飞灰含碳量和 NO_x 排放质量浓度的预测模型, 进一步建立锅炉效率模型。采用贝叶斯优化 (BO) 算法对 XGBoost 预测模型的超参数进行全局寻优, 同时搭建 BO-LSSVM 和 BO-BP 预测模型进行对比。在传统 NSGA-II 基础上引入超立方拉丁取样策略和 NDX 交叉算子实现算法改进, 以提升锅炉效率和降低 NO_x 排放质量浓度为多目标进行协同寻优。【结果】结果表明: BO-XGBoost 模型在预测准确性及泛化性能上均表现最优; 与传统 NSGA-II 相比, 改进 NSGA-II 算法提高了初始种群质量, 增强了算法全局寻优能力, 提升了 Pareto 解的质量; 改进 NSGA-II 寻优可获得大量优于原始工况的运行方案, 通过 TOPSIS 决策法得到的权衡解可实现锅炉效率提升和 NO_x 排放质量浓度降低的双重目标。【结论】本文融合 BO-XGBoost 模型预测、改进 NSGA-II 寻优和 TOPSIS 决策的集成技术路线可实现燃煤锅炉复杂燃烧的协同寻优。

[关键词] 多目标优化; 锅炉效率; NO_x 排放质量浓度; BO-XGBoost; 改进 NSGA-II

[引用本文格式] (本段作者勿动) 作者姓名. 中文标题[J]. 热力发电, 年, 卷(期): 起始页码-终止页码. 作者姓名. 英文标题[J]. Thermal Power Generation, 年, 卷(期): 起始页码-终止页码.

Multi-objective optimization of boiler combustion based on BO-XGBoost and improved NSGA-II

Wang Weijie¹, Liang Yangyang², Wang Jianguang¹, Fang Sihan³, Liu Kaitong¹, Qian Neng²,
Chen Gangqiang², Xue Yali³

(1. Guodian Jiantou Inner Mongolia Energy Investment Co., Ltd., Ordos 017209, China;

2. Beijing New Leaf Technology Co., Ltd., Beijing 100085, China;

3. Department of Energy and Power Engineering, Tsinghua University, Beijing 100084, China)

Abstract: [Objective] Multi-objective optimization of coal-fired boiler combustion is a critical strategy to achieve high-efficiency and environmentally friendly boiler operation. However, due to the strong nonlinearity, multivariable coupling, and inherent conflict between boiler efficiency and NO_x emission, it is particularly challenging to identify optimal operating parameters using traditional trial-and-error approaches. [Methods] This study systematically builds prediction models for boiler exhaust flue gas temperature, carbon content in fly ash and NO_x emission mass concentration based on the XGBoost model. Subsequently, the various heat losses are calculated, and a boiler efficiency model is further constructed using the anti-balance method. The global optimization of XGBoost hyperparameters is performed using Bayesian optimization (BO). To enable a comparative analysis, the corresponding BO-LSSVM and BO-BP models are also established. Based on the traditional NSGA-II, the hypercube Latin sampling strategy and NDX crossover operator are introduced to improve the algorithm.

收稿日期: 2026-05-29 修回日期: 2026-07-07 接受日期: 2026-07-27 网络首发日期: XXXX-XX-XX

基金项目: 国家重点研发计划项目 (2023YFB4102901)

Supported by: National Key Research and Development Program (2023YFB4102901)

第一作者简介: 王伟杰 (1996), 男, 助理工程师, 主要研究方向为热工仪表自动化, 20066044@ceic.com。

通信作者简介: 薛亚丽 (1975), 女, 博士, 副研究员, 主要研究方向为能源系统动态特性与控制, xueyali@tsinghua.edu.cn。

Collaborative optimization is carried out aiming at both enhancing boiler efficiency and lowering NO_x emission mass concentration. The optimization decision variables include the furnace oxygen content, primary air pressure, secondary air damper openings and over-fire air damper openings. [Results] The results demonstrate that BO-XGBoost achieves a lower mean absolute error (E_{MAE}) and a higher coefficient of determination (R^2) on the test set compared to the other two models, which reveal that the BO-XGBoost model yields superior prediction accuracy and generalization performance. Relative to the traditional NSGA-II, the improved NSGA-II yields superior initial populations, reinforces global exploration capability, and effectively avoids the problem of local optima. As a result, the quality of Pareto solutions is significantly improved. The improved NSGA-II algorithm can generate many operating schemes superior to the original working conditions. The TOPSIS decision-making is adopted to select a trade-off solution from the Pareto solutions that balances boiler efficiency and NO_x emission mass concentration. Statistical analysis over 200 operating conditions shows that the average boiler efficiencies for the original condition, the NSGA-II and improved NSGA-II trade-off solutions are 94.036 1%, 94.356 9%, and 94.506 8%, respectively, with the corresponding average NO_x emission mass concentration of 173.13, 150.16, and 139.32 mg/m^3 . Accordingly, the trade-off solution obtained by the TOPSIS decision-making method successfully realizes the dual objectives of improving boiler efficiency and reducing NO_x emission mass concentration. [Conclusion] This study establishes an integrated “prediction-optimization-decision” framework, which effectively combines BO-XGBoost prediction, improved NSGA-II optimization, and TOPSIS decision-making to achieve the collaborative optimization of complex combustion processes in coal-fired boilers. Moreover, the proposed framework provides a systematic and practical solution for multi-objective optimization of boiler combustion systems.

Key words: multi-objective optimization; boiler efficiency; NO_x emission mass concentration; BO-XGBoost; improved NSGA-II

目前我国主要的电力供应来源仍为燃煤电站, 燃煤电站锅炉运行主要兼顾锅炉效率和 NO_x 排放 2 个核心指标^[1-2]。提升锅炉效率可以改善燃烧经济性从而实现节能降耗, 控制 NO_x 排放可以缓解环保治理压力。因此, 开展燃煤锅炉燃烧的多目标优化, 对于实现锅炉高效低污染运行, 推动电力行业的节能减排具有重要意义。

对锅炉进行燃烧优化的前提是采用智能预测算法对关键参数建立准确的预测模型, 现阶段应用广泛的智能预测算法包含支持向量机 (SVM)、最小二乘支持向量机 (LSSVM) 与神经网络, 以及随机森林 (RF) 和极端梯度提升 (XGBoost) 等决策树集成模型。如苏涛等^[3]采用 SVM 建立烟气含氧量预测模型, 顾燕萍等^[4]采用 LSSVM 建立飞灰含碳量、 NO_x 排放质量浓度等预测模型, 徐文韬等^[5]采用 BP 神经网络建立锅炉效率和 NO_x 排放质量浓度预测模型, 孙胡彬^[6]采用 RF 建立炉膛出口的 NO_x 质量浓度模型。陈植元等^[7]采用 K 邻近、RF 和 XGBoost 模型建立锅炉飞灰含碳量模型, 对比表明 XGBoost 模型的综合预测精度最高。

上述用于建模的智能预测算法均具有若干个超参数, 对模型预测精度有着重要影响。朱予东等^[8]采用改进型遗传算法对排烟温度和 NO_x 排放质量浓度的 LSSVM 模型超参数进行寻优, 李杨等^[9]采用粒子群优化算法 (PSO) 对锅炉效率的 LSSVM 模

型超参数进行寻优, 苏涛等^[3]采用改进 PSO 算法对烟气含氧量的 SVM 模型超参数进行寻优。贝叶斯优化 (BO) 属于高效全局优化算法, 可以较少的评估成本逼近最优解, 在模型超参数寻优上应用广泛^[10-12]。孙胡彬^[6]采用 BO 对炉膛出口 NO_x 质量浓度的 RF 模型超参数进行寻优, 效果明显优于传统的网格搜索。周旭等^[13]采用 BO 对煤自燃分级预警的 XGBoost 模型超参数进行寻优, 效果明显优于未寻优、网格搜索和随机搜索。

锅炉效率最大化和 NO_x 排放质量浓度最小化作为锅炉燃烧优化两大目标通常存在相互制约和彼此互斥的特性, 非支配遗传排序算法 II (NSGA-II) 是用来获取此类多目标优化问题 Pareto 解的典型方法^[14]。相较于 NSGA, NSGA-II 通过快速非支配排序、密度估计算子保多样性及精英保留机制的引入, 大幅提升了多目标优化性能。采用 NSGA-II 对锅炉效率和 NO_x 排放质量浓度进行双重优化, 得到的 Pareto 解在提高锅炉效率的同时可以降低 NO_x 排放质量浓度^[15]。实际用于锅炉燃烧等多目标寻优时, 大多研究者采用改进 NSGA-II 策略提升优化效果。如采用拉丁超立方取样替代随机方式生成初始种群, 解决样本扎堆和种群分布不均问题^[16]; 采用正态分布交叉 (NDX) 算子替代模拟二进制交叉 (SBX) 算子, 缓解局部最优和进化不稳定弊端^[5]; 在普通锦标赛选择策略基础上融入惩罚机制, 缓解

种群样本多样性衰减问题^[17]。

本文采用 XGBoost 模型建立排烟温度、飞灰含碳量和 NO_x 排放质量浓度的预测模型,进一步建立锅炉效率模型。采用 BO 算法对模型超参数进行寻优,采用改进 NSGA-II 算法对锅炉效率和 NO_x 排放质量浓度进行协同优化,得到 Pareto 解,然后采用 TOPSIS 决策^[18-19]筛选出兼顾锅炉效率和 NO_x 排放质量浓度的权衡解。该融合 BO-XGBoost 模型预测、改进 NSGA-II 寻优和 TOPSIS 决策的集成技术路线,为燃煤锅炉兼顾经济环保的多目标协同优化研究提供参考。

1 算法介绍

1.1 XGBoost 介绍

XGBoost 是基于 Boosting 框架优化的梯度提升集成算法,以 CART 决策树为基学习单元。算法迭代训练不断生成新决策树,修正前期模型预测偏差,持续优化拟合效果。训练完成后,通过加权融合多个决策树的输出结果构建泛化性强的预测模型^[20]。

XGBoost 最终预测结果为

$$y_{pred,i} = \sum_{n=1}^N f_n(x_i) \quad (1)$$

式中: x_i 为输入; f_n 为决策树; N 为决策树数量; $y_{pred,i}$ 为预测结果。

目标函数综合模型损失和模型复杂性:

$$obj = \sum_{i=1}^M L_i(y_i, y_{pre,i}) + \sum_{n=1}^N \Omega(f_n) \quad (2)$$

式中: L 为损失函数; Ω 体现决策树复杂度:

$$\Omega(f_n) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (3)$$

式中: T 为决策树叶子节点数; ω 为叶子分数; γ 和 λ 为超参数; γ 限制树的分裂; λ 为正则化系数。

1.2 BO 介绍

BO 用到的贝叶斯定理如下^[21]:

$$p(f | D_{1:n}) = \frac{p(D_{1:n} | f) p(f)}{p(D_{1:n})} \quad (4)$$

$$D_{1:n} = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (5)$$

$$y_n = f(x_n) + \varepsilon_n \quad (6)$$

式中: f 为目标函数; $D_{1:n}$ 为已观测集; x_n 为决策变量; y_n 为观测值; ε_n 为观测误差; $p(D_{1:n}|f)$ 为 f 的似然分布; $p(f)$ 为 f 的先验概率分布; $p(D_{1:n})$ 为 f 的边际似然分布; $p(f|D_{1:n})$ 为 f 的后验概率分布。BO 主

要包括概率代理模型与采集函数。

1.2.1 概率代理模型

根据观测数据建立的概率代理模型用于对目标函数的近似,本文采用非参数的高斯过程模型,可表示为连续空间上的统计模型^[22]:

$$f(x) = GP(m(x), k(x, x')) \quad (7)$$

式中: m 为均值函数,通常设为恒为 0; k 为半正定协方差函数,根据已观测集合训练得到。对于新的观测点 x_{n+1} ,高斯分布可以预测该点目标函数值的后验概率分布:

$$P(f_{n+1} | D_{1:n}, x_{n+1}) \sim N(\mu, \sigma^2) \quad (8)$$

高斯过程依托现有样本数据,可对未观测区域进行预测建模,将每个未知样本点拟合为服从均值 μ 、方差 σ^2 的高斯分布。对于距离观测样本较远的区域,高斯过程预测的后验方差明显增大,代表模型的预测不确定性更高。因此,高斯过程能够输出完备的概率评估信息,精准量化预测不确定度,可为全局优化搜索提供有力支撑。

1.2.2 采集函数

采集函数用于选取下一次最具潜力的评估点,需参考代理模型的预测值并量化预测结果的不确定性,权衡确定性收益与未知区域探索性。本文采用 EI 期望提升策略,提升概率同时表征提升幅度差异。

1.2.3 BO 步骤

BO 算法主要分为 4 步:

- 1) 根据高斯过程代理模型预测目标函数;
- 2) 根据采集函数评估下一次最优观测点;
- 3) 将新观测点加入历史集中,更新代理模型;
- 4) 循环进行 1) — 3) 步,直到迭代终止。

1.3 BO 优化 XGBoost 介绍

BO 优化 XGBoost 流程如图 1 所示。首先输入数据集与超参数搜索范围,随机初始化多组超参数并进行模型训练构建初始观测集。随后迭代更新高斯过程代理模型,通过采集函数筛选潜力超参数样本并扩充观测集,直至达到迭代上限。最终筛选最优超参数完成 XGBoost 模型构建。




图1 贝叶斯优化 XGBoost 流程

Fig.1 Process of Bayesian optimization for XGBoost

1.4 改进 NSGA-II 介绍

1.4.1 拉丁超立方取样

传统 NSGA-II 采用随机方式生成初始化染色体, 容易出现样本扎堆、种群分布不均、区域遗漏和大片参数空间没被搜索的问题。本文采用拉丁超立方取样策略, 在 n 维抽样空间中高效生成初始样本点, 样本规模为 m , 主要步骤为^[16]:

1) 将各变量定义域 m 等分, 原空间离散为 m^n 个立方体;

2) 生成 $m \times n$ 的拉丁超立方阵, 每列均为 $1 \sim m$ 的随机全排列;

3) 按照矩阵行规则遴选小超立方体, 各区域随机单点布样, 形成 m 个样本集。

拉丁超立方取样可以使初始种群在整个搜索空间内分布均匀, 用少量种群覆盖所有关键区域, 为优化算法提供高质量的初始种群。

1.4.2 交叉算子改进

传统 NSGA-II 采用 SBX 算子, 搜索范围较窄, 在多目标复杂问题的寻优求解中容易出现局部最优, 影响全局搜索效果。本文采用 NDX 算子, 引入与父代染色体差异成正比的正态分布随机扰动, 生成的子代染色体成对称分布, 提升了种群多样性, 增强了算法全局寻优能力, 有效摆脱了局部最优束缚^[5]:

$$\begin{cases} S_{1,i} = \frac{y_{1,i} + y_{2,i}}{2} + 1.481|N(0, 1)| \frac{y_{1,i} - y_{2,i}}{2} \\ S_{2,i} = \frac{y_{1,i} + y_{2,i}}{2} - 1.481|N(0, 1)| \frac{y_{1,i} - y_{2,i}}{2} \end{cases} \quad u \leq 0.5$$

$$\begin{cases} S_{1,i} = \frac{y_{1,i} + y_{2,i}}{2} - 1.481|N(0, 1)| \frac{y_{1,i} - y_{2,i}}{2} \\ S_{2,i} = \frac{y_{1,i} + y_{2,i}}{2} + 1.481|N(0, 1)| \frac{y_{1,i} - y_{2,i}}{2} \end{cases} \quad u > 0.5$$

式中: $S_{1,i}$ 和 $S_{2,i}$ 为子代染色体; $y_{1,i}$ 和 $y_{2,i}$ 为父代染色体; $|N(0, 1)|$ 为正态分布随机变量; u 为 $(0, 1)$ 区间内均匀分布的随机数。

2 燃烧优化模型

2.1 模型数据

选取某 660 MW 前后墙对冲机组, 时间范围为 2025 年 3 月至 2025 年 12 月, 经过异常数据检测和稳态工况判断等处理筛选出 1 488 组样本数据, 涵盖锅炉运行的各个负荷段。

锅炉效率 η 采用反平衡法计算:

$$\eta = 100 - (L_c + L_G + L_m + L_R) \quad (10)$$

上式包含锅炉未燃碳热损失 L_c 、干烟气热损失 L_G 、水分热损失 L_m 和散热损失 L_R ^[23], 各项损失通过排烟温度、参考温度等运行参数, 以及飞灰含碳量、煤质等化验数据计算得到。

根据对锅炉燃烧机理的分析, 以及各运行参数与被测量之间的相关性分析, 最终选择表 1 所示的 31 个运行参数作为模型的输入特征。其中炉膛氧量、一次风压、燃烧器二次风门和燃尽风门开度为直接调整的操作量, 其余不直接调整。共 12 个燃烧器二次风门, 其中有 3 组 (每组各 2 个) 为层操 (作为一个特征量), 剩余 6 个为非层操; 共 8 个燃烧器燃尽风门, 均为非层操。

表 1 模型输入特征
Tab.1 Input features of the model

特征量	个数	取值范围	是否直接调整
负荷/MW	1	195~660	否
煤热值/(MJ·kg ⁻¹)	1	17.47~21.87	否
水煤比	1	5.0~7.2	否
环境温度/°C	1	-5.3~39.0	否
一次风总风量/(t·h ⁻¹)	1	230~463	否
炉膛氧量/%	1	1.8~10.6	是
总风量/(t·h ⁻¹)	1	969~2057	否
一次风压/kPa	1	7.0~10.6	是
磨 A—F 给煤量/(t·h ⁻¹)	6	0~56.2	否
燃烧器二次风门开度/%	9	0~100	是
燃烧器燃尽风门开度/%	8	0~100	是

2.2 模型建立

排烟温度有效样本为全部的 1 488 组；飞灰含碳量为间隔 8 h 取样的化验结果,有效样本量为 514 组；NO_x 排放质量浓度由于部分时间段存在数据丢失,有效样本量为 1 072 组。将各自的有效样本按 6:2:2 比例划分训练集、验证集和测试集。基于 XGBoost 模型分别建立排烟温度、飞灰含碳量和 NO_x 排放质量浓度的预测模型,以训练集和验证集作为模型训练和超参数调优数据集。采用 BO 算法对 XGBoost 模型超参数进行全局寻优,参数设置及寻优结果如表 2 所示。

表 2 BO-XGBoost 模型超参数寻优区间及最终结果

Tab.2 Hyperparameter bounds and optimized solutions of the BO-XGBoost models

超参数	搜索范围	排烟温度 /°C	飞灰含碳量 /%	NO _x 排放 质量浓度 /(mg·m ⁻³)
决策树数量	[50,400]	356	355	257
树的最大深度	[2,10]	9	9	9
学习率	[0.01,0.3]	0.0347	0.0956	0.0744
子节点最小权重和	[1,15]	1.547	3.208	2.520
行采样比例	[0.5,1.0]	0.585	0.887	0.643
列采样比例	[0.5,1.0]	0.939	0.980	0.514

2.3 模型精度

以测试集的预测结果对模型精度进行评估,指标采用平均绝对误差 E_{MAE} 和决定系数 R^2 :

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_{p,i} - y_i| \quad (11)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{p,i} - y_i)^2}{\sum_{i=1}^n (y_{p,i} - \bar{y})^2} \quad (12)$$

基于 BO-XGBoost 模型建立的排烟温度、飞灰含碳量和 NO_x 排放质量浓度 3 个预测模型在测试集的对比曲线分别如图 2—图 4 所示,评价指标 E_{MAE} 和 R^2 见表 3。可以看出,3 个模型的 E_{MAE} 分别为 1.073、0.073 和 11.509, R^2 分别为 0.977、0.946 和 0.853。从拟合效果看,预测数据可较好还原真实数据特征,说明该模型具备较强的泛化性能。




图 2 测试集排烟温度的预测结果

Fig.2 Prediction results of exhaust flue gas temperature on test data




图 3 测试集飞灰含碳量的预测结果

Fig.3 Prediction results of carbon content in fly ash on test data




图 4 测试集 NO_x 排放质量浓度的预测结果

Fig.4 Prediction results of NO_x emission mass concentration on test data

表 3 测试集 BO-XGBoost 模型预测精度

Tab.3 Prediction accuracy of XGBoost models on test data

模型	E_{MAE}	R^2
排烟温度	1.073	0.977
飞灰含碳量	0.073	0.946
NO _x 排放质量浓度	11.509	0.853

为验证 BO-XGBoost 模型预测的准确性,以排

烟温度为例,采用 BO-LSSVM 和 BO-BP 两个模型在测试集上进行对比,如图 5 所示, E_{MAE} 和 R^2 指标如表 4 所示。




图 5 测试集排烟温度的不同模型预测结果对比
Fig.5 Comparison of exhaust flue gas temperature on test data using different models

表 4 排烟温度测试集不同模型预测指标对比
Tab.4 Evaluation indexes of different models for exhaust temperature on test data

模型	E_{MAE}	R^2
BO-XGBoost	1.073	0.977
BO-LSSVM	2.450	0.914
BO-BP	2.428	0.920

从图 5 可知, BO-XGBoost 模型排烟温度预测值与实际值拟合得更好。从表 4 可知: BO-XGBoost 模型的 E_{MAE} 指标为 1.073, 低于 BO-LSSVM 模型的 2.450 和 BO-BP 模型的 2.428; BO-XGBoost 模型的 R^2 指标为 0.977, 高于 BO-LSSVM 模型的 0.914 和 BO-BP 模型的 0.920。因此, BO-XGBoost 模型在预测性能和泛化适配能力上表现最佳。从算法机理层面分析, BP 神经网络在梯度寻优中易陷入局部极值, 优化稳定性不足; LSSVM 因最小二乘解丢失样本稀疏性, 所有训练样本均参与运算, 多特征耦合下对异常值更敏感, 泛化性能受限; XGBoost 通过梯度提升迭代修正残差及双重正则化抗噪机制, 在拟合强非线性的同时有效抑制过拟合, 对强非线性和高噪声的锅炉燃烧数据适应性更强。对于飞灰含碳量和 NO_x 排放质量浓度的预测, 也是 BO-XGBoost 模型精度最高, 本文后续燃烧优化计算均基于 BO-XGBoost 预测模型。

图 6 为测试集样本锅炉效率的对比曲线。其中效率实际值是通过排烟温度、参考温度等 DCS 运行数据, 以及飞灰含碳量、煤质等化验数据计算得到。效率预测值的排烟温度和飞灰含碳量采用 XGBoost 模型计算结果。可知二者表现出高度一致性, 平均绝对误差为 0.030%, 表明建立的锅炉效率模型可以用来对锅炉效率进行可靠评估, 从而衡量锅炉运行的经济性。





图 6 测试集 BO-XGBoost 模型对锅炉效率的预测
Fig.6 Prediction of boiler efficiency on test data using the BO-XGBoost model

2.4 后解释模型


排烟损失 (包括干烟气热损失和水分热损失) 为锅炉效率的最大损失项, 排烟温度是影响排烟损失的关键因素。为定量表征各调整变量的贡献程度, 分别基于排烟温度和 NO_x 排放质量浓度的 BO-

XGBoost 预测模型开展 SHAP 归因分析, 结果如图 7 所示。其中二次风门和燃尽风门为对应的所有风门贡献之和。

对排烟温度而言, 稳定工况下, 二次风门直接调控炉内火焰中心位置和主燃区温度, 是影响排烟温度的核心运行变量, SHAP 贡献值最高; 燃尽风门通过高位补风推动燃烧后移, 影响次之; 炉膛氧量影响弱于前两类配风。对 NO_x 排放质量浓度而言, 炉膛氧量直接决定炉内整体氧化燃烧氛围, 是主导因素, SHAP 贡献值最高; 二次风门在主燃区营造还原性气氛以抑制 NO_x 生成, 影响次之; 燃尽风门延迟补风, 控氮作用相对较弱。一次风压主要用于煤粉输送及保证燃烧器出口所需安全风速, 对排烟温度和 NO_x 影响最弱。



a) 排烟温度 SHAP 分析



b) NO_x 排放质量浓度 SHAP 分析

图 7 基于 SHAP 的预测模型调整变量贡献度排序
Fig.7 SHAP-based feature importance ranking for prediction models

3 燃烧优化实现

3.1 优化问题

燃烧优化以保障机组安全运行为前提, 兼顾锅炉效率最大化与 NO_x 排放质量浓度最小化。锅炉运行过程中可作为燃烧优化的直接调整变量共 19 个 (见表 1)。寻优过程中, 层操风门作为整体参与寻优, 非层操风门单独寻优。为限制参数偏离原基准工况的幅度, 避免优化结果与机组常态运行工况偏差过大, 氧量和一次风压寻优区间为当前指令的 $\pm 15\%$, 二次风门开度和燃尽风门开度寻优区间为 ± 15 开度, 再结合不同参数实际允许的安全上下限

确定最终寻优区间。

多目标优化问题描述如下:

$$\begin{cases} \left[\max(f_{\eta}(x)), \min(f_{\text{NO}_x}(x)) \right] \\ x_{i,\min} \leq x_i \leq x_{i,\max}, 1 \leq i \leq 19 \end{cases} \quad (13)$$


式中: $f_{\eta}(x)$ 为锅炉效率模型; $f_{\text{NO}_x}(x)$ 为 NO_x 排放质量浓度模型; x 为可调整的寻优变量; $x_{i,\min}$ 和 $x_{i,\max}$ 分别为各寻优变量的寻优下限和上限。

优化目标中锅炉效率最大化与 NO_x 排放质量浓度最小化之间相互制约, 不存在使二者同时达到最优的唯一解, 而是存在一组 Pareto 最优解集。解集内任意解均无法在不恶化其中一项指标前提下改善另一项目标, 即无法同时实现锅炉效率更高和 NO_x 排放质量浓度更小。采用改进 NSGA-II 算法求解式(13), 迭代次数为 300, 种群数量为 200, 交叉概率为 0.7, 变异概率为 0.07。

3.2 优化结果

为检验燃烧优化的求解结果, 选择低负荷 (230 MW)、中负荷 (435 MW) 和高负荷 (650 MW) 3 个典型工况分析, 原工况、NSGA-II 寻优和改进 NSGA-II 寻优得到的 Pareto 解的对比如图 8 所示。可知: 原工况解位置均位于 NSGA-II 和改进 NSGA-II 解曲线的右下方, 即 NSGA-II 和改进 NSGA-II 均寻优得到了大量比原工况更优的解, 提升锅炉效率的同时实现 NO_x 减排, 充分验证了 NSGA-II 算法求解锅炉复杂多目标优化问题的实际效果。

对比 NSGA-II 和改进 NSGA-II 的 Pareto 解曲线, 可知 3 个工况下改进 NSGA-II 的解均优于传统 NSGA-II 解, 主要是因为拉丁超立方取样为优化算法提供了高质量的初始种群, NDX 算子扩大了算法的全局搜索能力, 避免了算法陷入局部最优。



a) 230 MW 工况




图8 不同工况燃烧优化结果对比
Fig.8 Combustion optimization results under diverse operating scenarios

为进一步验证 NSGA-II 和改进 NSGA-II 的优化计算结果,将对样本扩大到包含锅炉正常运行各个负荷段的 200 个工况。对寻优结果进行统计分析,表 5 列出了原工况、上端点(锅炉效率最大化)和下端点(NO_x 排放质量浓度最小化)的统计平均值。

表 5 不同工况优化结果统计
Tab.5 Statistical on combustion optimization results under diverse operating scenarios

参数	锅炉效率 平均值/%	NO_x 排放质量浓度平均值 /($\text{mg}\cdot\text{m}^{-3}$)
原工况	94.0361	173.13
NSGA-II 上端点	94.5623	177.06
NSGA-II 下端点	94.1979	145.33
NSGA-II 权衡解	94.3569	150.16
改进 NSGA-II 上端点	94.7850	177.12
改进 NSGA-II 下端点	94.1775	129.72
改进 NSGA-II 权衡解	94.5068	139.32

与原工况对比, NSGA-II 上端点将锅炉效率从 94.036 1% 提升至 94.562 3%, 幅度为 0.526 2 百分点, 而 NO_x 排放质量浓度从 173.13 mg/m^3 仅提升至

177.06 mg/m^3 , 幅度为 2.3%; 下端点将 NO_x 排放质量浓度从 173.13 mg/m^3 降低至 145.33 mg/m^3 , 幅度为 16.1%, 且锅炉效率也从 94.036 1% 提升至 94.197 9%, 幅度为 0.161 8 百分点。与 NSGA-II 对比, 改进 NSGA-II 上端点将锅炉效率从 94.562 3% 提升至 94.785 0%, 幅度为 0.222 7 百分点, 而 NO_x 排放质量浓度几乎不变; 下端点将 NO_x 排放质量浓度从 145.33 mg/m^3 降低至 129.72 mg/m^3 , 幅度为 10.7%, 但锅炉效率也从 94.197 9% 降低至 94.177 5%, 幅度为 0.020 4 百分点。可知, 改进 NSGA-II 扩充了 NSGA-II 解的范围, 提升了可实现的最高锅炉效率, 降低了可实现的最低 NO_x 排放质量浓度。

3.3 TOPSIS 决策

改进 NSGA-II 得到最优解集之后, 需依据各优化目标的重要性差异进一步筛选出整体最佳的权衡解。关注经济性指标则选择锅炉效率最大化的上端点, 关注环保指标则选择 NO_x 排放质量浓度最低的下端点, 更多的是选择锅炉效率和 NO_x 排放质量浓度兼顾的权衡解。

TOPSIS 决策作为一种经典多目标综合评价模型, 广泛应用于各类复杂工程场景。其原理是评价各备选方案与正负理想解之间的差异, 尽可能趋于最优的同时远离最差, 可公正判别各决策方案的综合优劣^[18-19]。主要步骤如下:

1) 构建决策矩阵: Pareto 解集中每个候选解对应锅炉效率和 NO_x 排放质量浓度 2 个指标, 构成二维初始决策矩阵。

2) 归一化处理: 将锅炉效率和 NO_x 排放质量浓度归一化至 0~1 区间, 消除量纲差异。

3) 确定正负理想解: 以解集中锅炉效率最高、 NO_x 排放质量浓度最小作为正理想解, 以锅炉效率最低、 NO_x 排放质量浓度最大为负理想解, 二者分别代表理论最优与最差工况。

4) 计算相对贴近度: 分别计算各解到正负理想解的欧氏距离 D_i^+ 和 D_i^- , 再根据式(14)计算相对贴近度。

$$C_i = \frac{D_i^-}{D_i^- + D_i^+} \quad (14)$$

相对贴近度位于 0~1 之间, 值越大越接近正理想解。

5) 决策输出: 以相对贴近度最大的解作为权衡解。

表 5 同样列出了 200 个工况 TOPSIS 决策得到

的权衡解的统计信息。原工况、NSGA-II 权衡解和改进 NSGA-II 权衡解的锅炉效率分别为 94.036 1%、94.356 9%、94.506 8%，NO_x 排放质量浓度分别为 173.13、150.16、139.32 mg/m³，改进 NSGA-II 权衡解的锅炉效率和 NO_x 排放质量浓度均优于 NSGA-II 权衡解。

表 6 列出了某 300 MW 原工况与改进 NSGA-II 寻优所得权衡解的调整变量寻优结果对比。原工况炉膛氧量为 5.07%，权衡解将炉膛氧量降至 4.79%，适度降低了炉膛整体氧浓度，在减小排烟热损失的同时抑制了热力型 NO_x 生成。二次风门和燃尽风门优化配风调整，在维持炉膛燃烧稳定前提下，使风粉混合充分，降低飞灰未燃碳，减少燃烧初期燃料型 NO_x 生成。一次风压适度提升保证合理的煤粉浓度和一次风刚性。上述措施协同作用下，锅炉效率从 94.355 6% 提升至 95.134 6%，NO_x 排放质量浓度从 177.98 mg/m³ 降至 172.75 mg/m³，同时实现锅炉效率提升与 NO_x 减排。

表 6 原工况与改进 NSGA-II 优化结果对比

Tab.6 Adjustable variable values under original condition and improved NSGA-II optimization

参数	原工况	权衡解
氧量/%	5.07	4.79
一次风压/kPa	8.62	9.73
前墙第一层二次风门开度（层操）/%	99.86	93.95
后墙第一层二次风门开度（层操）/%	99.84	99.87
前墙第二层二次风门开度（层操）/%	98.64	99.68
后墙第二层左侧二次风门开度/%	98.80	98.53
后墙第二层右侧二次风门开度/%	97.37	85.32
前墙第三层左侧二次风门开度/%	21.52	34.47
前墙第三层右侧二次风门开度/%	21.19	6.19
后墙第三层左侧二次风门开度/%	21.35	6.56
后墙第三层右侧二次风门开度/%	21.88	27.13
前墙第一层左侧燃尽风门开度/%	66.07	71.35
前墙第一层右侧燃尽风门开度/%	73.51	78.72
后墙第一层左侧燃尽风门开度/%	66.06	65.42
后墙第一层右侧燃尽风门开度/%	71.81	86.81
前墙第二层左侧燃尽风门开度/%	25.19	10.19
前墙第二层右侧燃尽风门开度/%	23.52	32.02
后墙第二层左侧燃尽风门开度/%	25.32	33.56
后墙第二层右侧燃尽风门开度/%	25.65	20.89
锅炉效率/%	94.355 6	95.134 6
NO _x 排放质量浓度/(mg·m ⁻³)	177.98	172.75

4 结论

本文以 BO-XGBoost 模型为基础，建立锅炉排烟温度、飞灰含碳量和 NO_x 排放质量浓度预测模型，进一步建立锅炉效率模型；采用改进 NSGA-II 算法对锅炉效率和 NO_x 排放质量浓度进行协同优化；采用 TOPSIS 决策得到兼顾锅炉效率和 NO_x 排放质量浓度的权衡解。结论如下：

1) 与 BO-LSSVM 和 BO-BP 模型相比，BO-XGBoost 模型对排烟温度、飞灰含碳量和 NO_x 排放质量浓度的预测精度最高，泛化能力最强。

2) 与 NSGA-II 相比，改进 NSGA-II 为优化算法提供了高质量的初始种群，增强了算法全局寻优能力，有效摆脱了局部最优困扰，提升了 Pareto 解质量。

3) 不同工况下，改进 NSGA-II 均寻优得到大量比原工况更优的解。根据 TOPSIS 决策法得到的权衡解在提高锅炉效率的同时降低了 NO_x 排放质量浓度，表明改进 NSGA-II 优化算法对于锅炉多目标寻优这一复杂问题的有效性。

【参考文献】

- [1] 陈鸿. 基于改进遗传算法的火电厂锅炉燃烧优化技术[J]. 自动化应用, 2025, 66(3): 258.
Chen H. Optimization technology of thermal power plant boiler combustion based on improved genetic algorithm[J]. Automation Application, 2025, 66(3): 258.
- [2] 乔日平, 张卓, 邹家平, 等. 基于大数据寻优的锅炉燃烧优化系统研究[J]. 工业加热, 2025, 54(12): 19.
Qiao R P, Zhang Z, Zou J P, et al. Research on boiler combustion optimization system based on big data optimization[J]. Industrial Heating, 2025, 54(12): 19.
- [3] 苏涛, 潘红光, 黄向东, 等. 基于改进 PSO-SVM 的燃煤电厂烟气含氧量软测量[J]. 西安科技大学学报, 2020, 40(2): 342.
Su T, Pan H G, Huang X D, et al. Soft sensor of flue gas oxygen content based on improved PSO-SVM in coal-fired power plant[J]. Journal of Xi'an University of Science and Technology, 2020, 40(2): 342.
- [4] 顾燕萍, 赵文杰, 吴占松. 基于最小二乘支持向量机的电站锅炉燃烧优化[J]. 中国电机工程学报, 2010, 30(17): 91.
Gu Y P, Zhao W J, Wu Z S. Combustion optimization for utility boiler based on least square-support vector machine[J]. Proceedings of the CSEE, 2010, 30(17): 91.
- [5] 徐文韬, 黄亚继, 曹歌瀚, 等. 基于 BP-改进 NSGA-II 锅炉燃烧多目标优化[J]. 东南大学学报(自然科学版), 2022, 52(5): 943.
Xu W T, Huang Y J, Cao G H, et al. Multi-objective combustion optimization for boiler based on BP-improved NSGA-II[J]. Journal of Southeast University (Natural Science Edition), 2022, 52(5): 943.
- [6] 孙胡彬, 杨建国, 金宏伟, 等. 基于贝叶斯优化-随机森林回归的燃煤锅炉 NO_x 预测模型[J]. 动力工程学报, 2023, 43(7): 910.
Sun H B, Yang J G, Jin H W, et al. NO_x prediction model for coal-fired boiler based on Bayesian optimization-random forest regression[J]. Journal of Chinese Society of Power Engineering, 2023, 43(7): 910.
- [7] 陈植元, 谭厚章, 成思扬, 等. 基于机器学习的飞灰含碳量预测模型比较研究[J]. 热力发电, 2023, 52(7): 64.
Chen Z Y, Tan H Z, Cheng S Y, et al. Comparison of prediction models of carbon content of fly ash based on machine learning[J]. Thermal Power Generation, 2023, 52(7): 64.

- [8] 朱予东, 王星久, 王天龙, 等. 基于自适应遗传算法参数优化的锅炉燃烧特性建模[J]. 应用能源技术, 2011, 8: 31.
Zhu Y D, Wang X J, Wang T L, et al. Boiler combustion characteristics modeling based on parameter optimization by adaptive genetic algorithm[J]. Applied Energy Technology, 2011, 8: 31.
- [9] 李杨, 蓝茂蔚, 赵国钦, 等. 基于 PCA-PSO-LSSVM 的电站锅炉效率预测模型研究[J]. 热力发电, 2021, 50(12): 43.
Li Y, Lan M W, Zhao G Q, et al. Study on prediction model of utility boiler efficiency based on PCA-PSO-LSSVM[J]. Thermal Power Generation, 2021, 50(12): 43.
- [10] 李亚茹, 张宇来, 王佳晨. 面向超参数估计的贝叶斯优化方法综述[J]. 计算机科学, 2022, (S1): 86.
Li Y R, Zhang Y L, Wang J C. Survey on Bayesian optimization methods for hyper-parameter tuning[J]. Computer Science, 2022, (S1): 86.
- [11] 姜宇恒, 乔宗良, 李逗, 等. 基于聚类算法与贝叶斯优化的 BP 神经网络实时碳排放量预测模型[J]. 热力发电, 2025, 54(11): 126.
Jiang Y H, Qiao Z L, Li D, et al. Real-time prediction model for carbon emission using BP neural network based on clustering algorithm and Bayesian optimization[J]. Thermal Power Generation, 2025, 54(11): 126.
- [12] 陆佳恩, 赵健, 李小勇. 基于贝叶斯优化超参数的光伏功率区间预测方法[J]. 太阳能学报, 2026, 47(3): 644.
Lu J C, Zhao J, Li X Y. Photovoltaic power interval prediction method based on Bayesian optimization to improve deep learning model hyperparameters[J]. Acta Energiae Solaris Sinica, 2026, 47(3): 644.
- [13] 周旭, 王认卓, 代亚勋, 等. 基于 BO-XGBoost 的煤自燃分级预警研究[J]. 煤炭工程, 2022, 54 (8): 108.
Zhou X, Wang R Z, Dai Y X, et al. Classified early warning of coal spontaneous combustion based on BO-XGBoost[J]. Coal Engineering, 2022, 54 (8): 108.
- [14] Deb K, Partap A, Agarwal S, et al. A fast and elitist multi-objective genetic algorithm: NSGA-II[J]. IEEE Trans on Evolutionary Computation, 2002, 6(22): 182.
- [15] 余廷芳, 朱洪震, 彭春华. 基于 NSGA-II 算法的锅炉燃烧多目标优化[J]. 南昌大学学报 (工科版), 2013, 35(1): 58.
Yu T F, Zhu H Z, Peng C H. Multi-objective optimization of a coal-fired boiler combustion based on NSGA-II algorithm[J]. Journal of Nanchang University (Engineering & Technology), 2013, 35(1): 58.
- [16] 潘晓英, 朱 静. 一种改进的基于 NSGA-II 和 DE 的多目标混合进化算法[J]. 计算机应用研究, 2016, 33(12): 3638.
Pan X Y, Zhu J. Improved differential evolution-based hybrid NSGA-II for multi-objective optimization[J]. Application Research of Computers, 2016, 33(12): 3638.
- [17] 庞梦媛, 赵文杰. 基于改进 NSGA-II 算法的 W 火焰锅炉燃烧系统多目标优化[J]. 电力科学与工程, 2024, 40(9): 71.
Pang M Y, Zhao W J. Multi-objective optimization of W-flame boiler combustion system based on improved NSGA-II algorithm[J]. Electric Power Science and Engineering, 2024, 40(9): 71.
- [18] 徐振国. 主汽温 PID 参数整定的多目标遗传优化研究[J]. 中国舰船研究, 2011, 6(1): 64.
Xu Z G. Multi-Objective genetic optimization of PID parameters for setting main steaming temperature[J]. Chinese Journal of Ship Research, 2011, 6 (1): 64.
- [19] 赵钦, 白清俊, 聂坤堃, 等. 基于 NSGA-III 算法与 TOPSIS 决策下的区域水资源多目标优化配置[J]. 排灌机械工程学报, 2022, 40(12): 1233.
Zhao Q, Bai Q J, Nie K K, et al. Multi-objective optimization allocation of regional water resources based on NSGA-III algorithm and TOPSIS decision[J]. Journal of Drainage and Irrigation Machinery Engineering, 2022, 40(12): 1233.
- [20] 张潇远, 苏巧梅, 赵财胜, 等. 一种利用贝叶斯算法优化 XGBoost 的滑坡易发性评价方法[J]. 测绘科学, 2023, 48(6): 140.
Zhang X Y, Su Q M, Zhao C S, et al. A landslide susceptibility evaluation method using Bayesian algorithm to optimize XGBoost[J]. Science of Surveying and Mapping, 2023, 48(6): 140.
- [21] Rasmussen C E, Williams C K I. Gaussian processes for machine learning. The MIT Press, 2006.
- [22] 崔佳旭, 杨博. 贝叶斯优化方法和应用综述. 软件学报, 2018, 29(10): 3068.
Cui J X, Yang B. Survey on Bayesian optimization methodology and applications[J]. Journal of Software, 2018, 29(10): 3068.
- [23] 张小桃, 王培红. 一种新的锅炉效率的计算模型[J]. 电站系统工程, 1999, 15(4): 16.
Zhang X T, Wang P H. New computing model for boiler efficiency[J]. Power System Engineering, 1999, 15(4): 16.

(责任编辑 李国)