

DOI: 10.19666/j.rlfd.202507080

基于结渣因子监测与机器学习的水冷壁 精准吹灰算法研究

史建忠¹, 洪兵¹, 温小豪^{2,3}, 施子福^{2,3}, 李培^{2,3}, 周永刚^{2,3}

(1. 国能浙江宁海发电有限公司, 浙江 宁波 315612;

2. 浙江大学能源工程学院, 浙江 杭州 310027;

3. 浙江大学能源高效清洁利用全国重点实验室, 浙江 杭州 310027)

[摘要] 【目的】针对传统定时定量吹灰模式易导致水冷壁局部过吹、欠吹的问题, 依托有效监测手段开展研究, 旨在构建精准吹灰算法。【方法】利用新型水冷壁结渣监测传感器获取水冷壁炉内壁温, 对比了 3 种机器学习方法构建水冷壁洁净状态下的理论炉内壁温模型, 提出一种水冷壁结渣因子的计算方法, 并据此构建精准吹灰算法, 通过实际应用并与原定时定量吹灰模式进行对比, 验证了该算法的优化效果。【结果】研究表明: 随机森林回归方法建立的理论炉内壁温模型表现最佳, R^2 为 0.92、 δ_{MSE} 为 73.77、 δ_{MAPE} 为 1.16%; 精准吹灰算法实施后效果明显优于原定时定量吹灰模式, 吹灰频次大幅度降低, 且未造成水冷壁结渣状态恶化。【结论】该算法在保证锅炉运行安全性的前提下, 有效降低了吹灰蒸汽消耗量, 具有极高的工程应用价值。

[关键词] 机器学习; 结渣监测; 结渣因子; 吹灰优化

[引用本文格式] 史建忠, 洪兵, 温小豪, 等. 基于结渣因子监测与机器学习的水冷壁精准吹灰算法研究[J]. 热力发电, 2026, 55(4): 140-147. SHI Jianzhong, HONG Bing, WEN Xiaohao, et al. Research on precise soot blowing algorithm for waterwall soot blowing based on slagging factor monitoring and machine learning[J]. Thermal Power Generation, 2026, 55(4): 140-147.

Research on precise soot blowing algorithm for waterwall soot blowing based on slagging factor monitoring and machine learning

SHI Jianzhong¹, HONG Bing¹, WEN Xiaohao^{2,3}, SHI Zifu^{2,3}, LI Pei^{2,3}, ZHOU Yonggang^{2,3}

(1. CHN Energy Zhejiang Ninghai Power Generation Co., Ltd., Ningbo 315612, China;

2. College of Energy Engineering, Zhejiang University, Hangzhou 310027, China;

3. State Key Laboratory of Clean Energy Utilization, Zhejiang University, Hangzhou 310027, China)

Abstract: [Objective] Against the problem that the conventional timed and quantitative soot blowing mode is prone to cause local over-blowing and under-blowing of the waterwall, studies are carried out by relying on effective monitoring methods. As slag deposition on waterwall is a key factor affecting the safe and economic operation of thermal power boilers, long-term unresolved local over-blowing or under-blowing will not only accelerate the corrosion and wear of the waterwall, but also increase energy consumption and operational costs of power plants. Therefore, the core goal of this research is to establish a precise soot blowing algorithm to replace the conventional timed and quantitative soot blowing mode and realize adaptive and efficient soot blowing control. [Methods] A new type of waterwall slagging monitoring sensor was used to monitor the in-furnace waterwall surface temperature, which can collect real-time, continuous and high-precision temperature data to lay a reliable foundation for subsequent model construction. Three machine learning methods, including eXtreme gradient boosting (XGBoost), light gradient boosting machine (LightGBM) and random forest regression (RFR), were compared to construct theoretical in-furnace waterwall surface temperature models under clean waterwall conditions, and a calculation

收稿日期: 2025-07-29 修回日期: 2025-09-07 接受日期: 2025-09-16

基金项目: 能源高效清洁利用全国重点实验室自主课题 (ZJUCEU2025012)

Supported by: Independent Project of State Key Laboratory of Energy Efficient and Clean Utilization (ZJUCEU2025012)

第一作者简介: 史建忠 (1969), 男, 高级工程师, 主要研究方向为发电厂运行、检修管理及技术创新, 20039287@chnenergy.com.cn。

通信作者简介: 李培 (1986), 男, 博士, 专职研究员, 主要研究方向为锅炉智能化改造, princeleego@zju.edu.cn。

method for waterwall slagging factor was proposed. On this basis, a precise soot blowing algorithm was established. To verify the optimization effect of this algorithm, a 3-month practical application test was carried out in a 1 030 MW thermal power unit, and the operation data was compared with the original timed and quantitative soot blowing mode. [Results] The research shows that the theoretical in-furnace waterwall surface temperature model established by the random forest regression method performed the best, with an R^2 of 0.92, δ_{MSE} of 73.77, and δ_{MAPE} of 1.16%. The implementation of the precise soot blowing algorithm is significantly better than the original quantitative soot blowing mode, with a significant reduction in soot blowing frequency and no deterioration of the waterwall slagging state, and the local maximum temperature of the waterwall is controlled within the safe range, avoiding the risk of tube explosion caused by overheating. [Conclusion] This algorithm reduces the consumption of soot blowing steam while ensuring the safety of boiler operation, which directly reduces the daily operation cost of the power plant. Moreover, the reduction of soot blowing frequency also reduces the influence of high-temperature steam on the waterwall, effectively extending the service life of the waterwall and reducing the maintenance cost of the boiler. It can be popularized and applied in thermal power plants of different capacities, and has extremely high application value.

Key words: machine learning; slag monitoring; slagging factor; soot blowing optimization

在“双碳”目标驱动下,我国煤电行业正通过燃料结构调整与运行方式优化实现低碳转型^[1]。电厂燃用新疆高碱煤、掺烧生物质及污泥的多元化燃料策略,既是响应国家能源安全与循环经济政策的实践,也为降低碳排放提供了重要路径。然而,新疆煤因其碱金属含量高的特性,易在高温下粘附于水冷壁形成结渣^[2];生物质与污泥中富含的钾、氯及重金属元素,会加剧灰渣粘结性^[3]。与此同时,随着燃煤电厂调峰深度加大及频次增加,锅炉长期处于高低负荷频繁切换或持续低负荷运行状态,严重偏离其最佳运行工况。这一运行方式导致炉内热负荷分布不均,同样显著提升了水冷壁结渣风险^[4]。

水冷壁结渣会干扰锅炉正常传热过程,对运行安全性和经济性产生不利影响^[5]。结渣会大幅降低受热面传热效率,导致炉膛出口烟温升高,增加排烟热损失,降低锅炉效率;同时,灰渣在管壁的附着会加剧高温腐蚀,加速管壁减薄,缩短设备寿命;此外,结渣可能引发局部超温,造成水冷壁管膨胀不均或水循环失效,严重时导致爆管事故^[6];大渣块脱落还会冲击冷灰斗,可能引发二次燃烧或设备损坏。

目前针对水冷壁除渣最直接有效的方法是采用蒸汽吹灰^[7]。由于缺乏有效的监测手段,大多数电厂仍采用定时定量的吹灰策略,该模式极易造成水冷壁局部区域出现欠吹或过吹的问题。针对该问题,国内外学者提出多种解决方案。徐力刚等^[8]根据炉膛出口烟温建立了炉膛整体结渣监测模型;高峰等^[9]通过水冷壁鳍片处热流密度的变化来监测结渣状态;针对掺烧新疆煤的锅炉,黄书益等^[10]根据炉内火焰碱金属含量,对当前燃烧状态下的结渣趋势进行预判,为预防结渣和进行燃烧调整提供参考; Bilirgen^[11]通过在锅炉上安装 FEGT 红外温度计

监测炉膛出口温度来监测炉膛结渣程度; Taler 等人^[12]基于热流计实现水冷壁结渣在线监测;本文作者^[13]设计了水冷壁结渣监测传感器,通过水冷壁向火侧壁温的变化监测传感器附近水冷壁的结渣量。在此基础上,深度学习方法通过挖掘锅炉运行大数据,可构建高精度的结渣状态软测量模型,如马晓春等^[14]基于长短期记忆(LSTM)算法对结渣过程进行建模,开发水冷壁结渣监测模型;李孟威^[15]、刘俊^[16]、Dhanuskodi^[17]、Teruel^[18]、Peña 等人^[19]通过神经网络算法建立受热面污染状态监测模型,进而实现吹灰决策指导。

以上研究根据新型传感器、传热学原理或深度学习算法对水冷壁受热面污染状态进行监测,一定程度上改善了传统吹灰的盲目性,但未考虑锅炉工况变化对监测数据的影响。本文基于新型水冷壁结渣监测传感器,利用机器学习算法消除了锅炉运行工况对传感器数据的影响,并提出了以结渣因子为特征的精准吹灰算法,对每台吹灰器独立制定控制策略,为提升锅炉运行经济性、安全性提供了理论支撑与技术路径。

1 研究对象及方法

1.1 研究对象

以国内某燃煤电厂 1 030 MW 超超临界直流锅炉水冷壁为研究对象。该锅炉主要设计参数见表 1。水冷壁墙式吹灰器分布如图 1 所示,共有 64 台吹灰器,分为 4 层,由下至上编号为 A1—A16、B1—B16、C1—C16、D1—D16。电厂原吹灰方式为定时定量吹灰,吹灰周期为 48 h。

1.2 监测方法

水冷壁结渣监测传感器如图 2 所示^[20]。当水

冷壁发生结渣时，结渣层增加了传热热阻，导致水冷壁实际吸热量减小，壁温降低，反之壁温升高。传感器监测数据如图 3 所示。在阶段 2 中，锅炉负荷基本稳定，水冷壁结渣状态监测传感器所测水冷壁向火侧壁温（炉内壁温）先呈下降趋势，当执行吹灰动作后，水冷壁炉内壁温突变上升

约 100 ℃，与传热学原理一致，表明采用的水冷壁结渣监测传感器可以直观反映水冷壁局部污染状态。除了上述吹灰动作的影响，水冷壁炉内壁温在阶段 1 及阶段 3 呈现随锅炉负荷的变化而变化的规律，表明水冷壁炉内壁温受锅炉运行参数影响较大。

表 1 锅炉主要设计参数
Tab.1 Main design parameters of the boiler

项目	BMCR 工况数值	项目	BMCR 工况数值
过热蒸汽流量/(t·h ⁻¹)	3 091.0	再热器出口蒸汽压力/MPa	5.86
过热器出口蒸汽压力/MPa	27.46	再热器进口蒸汽温度/℃	374
过热器出口蒸汽温度/℃	605	再热器出口蒸汽温度/℃	603
再热蒸汽流量/(t·h ⁻¹)	2 580.9	省煤器进口给水温度/℃	298
再热器进口蒸汽压力/MPa	6.06		




图 1 炉膛吹灰器布置示意
Fig.1 Schematic diagram of the arrangement of soot blowers in furnace




图 2 水冷壁结渣监测传感器结构
Fig.2 Structural diagram of the waterwall slagging monitoring sensor




图 3 水冷壁炉内壁温典型趋势
Fig.3 Typical trend of fire-side wall temperature of the waterwall

2 水冷壁结渣量化监测算法构建

2.1 理论炉内壁温建模

为消除锅炉运行参数对水冷壁炉内壁温的影响,构建可量化表征表面结渣状态的数学模型。采用机器学习方法建立水冷壁洁净状态下的理论炉内壁温(t_m)预测模型。为确定最合适的算法和参数,选用极限梯度提升(XGBoost)、轻量级梯度提升机(LightGBM)和随机森林回归(random forest regression, RFR)等3种机器学习算法进行建模,并对比计算结果。

建模的输入特征选择如下运行参数:给水流量(Q_w)、给煤量(m_c)、一次风量(Q_p)、二次风量(Q_s)、炉膛出口氧量(ϕ_{O_2})。并构造3个衍生特征:风煤比(R_{a-c})、水煤比(R_{w-c})和一二二次风配比(R_{p-s})。为降低特征冗余度,采用皮尔逊相关系数(Pearson correlation coefficient, PCC)分析特征间的线性关系,基于互信息(mutual information, MI)分析特征与炉内壁温的依赖关系,从而筛选关键特征。构造的 R_{a-c} 、 R_{w-c} 、 R_{p-s} 计算公式如下:

$$R_{a-c} = \frac{Q_p + Q_s}{m_c} \quad (1)$$

$$R_{w-c} = \frac{Q_w}{m_c} \quad (2)$$

$$R_{p-s} = \frac{Q_p}{Q_s} \quad (3)$$

采集近3个月锅炉DCS运行数据,采样周期20 s,数据总量约39万。分析图3可知,吹灰后15 min内炉内壁温未下降,可认为水冷壁在该时段内仍处于洁净状态,因此取每次吹灰后15 min内的炉内壁温数据构建理论炉内壁温模型的建模数据库,其中80%为训练集,20%为测试集。训练完成后计算决定系数(R^2)、均方误差(δ_{MSE})和平均绝对百分比误差(δ_{MAPE})评估模型,计算公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

$$\delta_{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

$$\delta_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (6)$$

式中: y_i 为真实值; $\hat{y}_i$ 为预测值; $\bar{y}$ 为真实值的均值; n 为样本数。

2.2 精准吹灰算法

将实际炉内壁温归一化成无量纲常数,记作结渣因子 C_p ,其公式为:

$$C_p = \frac{1 - e^{-3\kappa}}{1 - e^{-3}} \quad (7)$$

$$\kappa = \begin{cases} \frac{t_m - t}{\max\{t_m^i - t^i \mid i = 1, 2, \dots, n\}} & t_m \geq t \\ 0 & t_m < t \end{cases} \quad (8)$$

式中: t 为实际炉内壁温, $^{\circ}\text{C}$; t_m 为理论炉内壁温, $^{\circ}\text{C}$ 。

从式(7)一式(8)可以看出, C_p 越大表明炉内壁温越低,水冷壁结渣越严重。因此以 C_p 为特征构建每台吹灰器的精准吹灰算法,逻辑框架如图4所示。算法启动后读取锅炉运行数据及炉内壁温数据并计算 C_p ,若 C_p 大于临界值则输出吹灰需求信号,表示该处水冷壁需要吹灰;反之则等到下一分钟重新读取数据并计算 C_p 。每次吹灰执行后,根据吹灰后炉内壁温上升幅度(温升)修正 C_p 的临界值,若温升过低则上调临界值,反之下调。




图4 精准吹灰算法逻辑框架

Fig.4 Logical framework of the precise soot blowing algorithm

3 结果与分析

3.1 理论炉内壁温建模结果分析

3.1.1 特征分析

输入特征分析结果如图5和图6所示。由PCC矩阵可知 m_c 、 Q_p 、 Q_s 和 ϕ_{O_2} 均与 Q_w 呈现强相关性;MI的结果表明, Q_w 是预测 t_m 最关键的特征,且构

造的 3 个衍生特征 R_{a-c} 、 R_{w-c} 、 R_{p-s} 相比原始运行参数 m_c 、 Q_p 、 Q_s 等具有更高的依赖度。综上，删除共线性较强且依赖度较低的 m_c 、 Q_p 、 Q_s ，用其他特征进行机器学习模型训练。




图 5 输入特征的 PCC 矩阵
Fig.5 PCC matrix of the input features




图 6 炉内壁温对各输入特征的依赖度
Fig.6 The dependence of fire-side wall temperature of the waterwall on various input features

3.1.2 建模结果对比

采用贝叶斯优化寻找 3 种机器学习模型的最优超参数组合，设初始采样点为 10，迭代次数 30，3 种模型超参数搜索范围及最优值见表 2。表 3 对比了 3 种模型优化后的性能，其中 RFR 算法的 R^2 最高、 δ_{MSE} 和 δ_{MAPE} 最低，性能显著优于其他 2 种算法，故最终选用 RFR 算法进行 t_m 建模。

3.2 精准吹灰算法结果分析

在每台吹灰器附近的水冷壁上安装一个结渣监测传感器，获取每台吹灰器附近的水冷壁炉内壁温，并计算结渣因子 C_p ，结渣因子的变化特性如图 7 所示。阶段 1 中 C_p 呈指数级增长而后骤降，期间 C_p 最大值为 0.89，该趋势表明水冷壁虽然结渣，但结渣较为疏松，在炉内空气动力场或重力的作用

下会自行掉落；阶段 2 中， C_p 同样先呈指数级增长，但当 $C_p > 0.90$ 后增长速度放缓，并稳定在 0.98 以上，可以认为此时水冷壁结渣不易掉落，需要吹灰干预。因此算法中 C_p 初始临界值设置为 0.90。

表 2 超参数搜索范围及最优值
Tab.2 Scopes and optimal values of hyperparameter search

模型	超参数名称	搜索范围	最优值
XGBoost	提升轮次	[50,200]	77
	最大树深度	[3,15]	14
	学习率	[0.01,0.3]	0.23
	样本采样比例	[0.6,1.0]	0.98
	特征采样比例	[0.6,1.0]	0.96
	L1 正则化系数	[0,1]	0.60
	L2 正则化系数	[0,1]	0.92
LightGBM	提升轮次	[50,200]	65
	最大树深度	[3,15]	9
	学习率	[0.01,0.3]	0.11
	样本采样比例	[0.6,1.0]	0.98
	特征采样比例	[0.6,1.0]	0.97
RFR	叶子节点数	[10,100]	92
	决策树数量	[50,200]	166
	最大树深度	[3,15]	11
	节点分裂最小样本数	[2,20]	2
	叶节点最小样本数	[1,10]	4
	特征采样比例	[0.1,1.0]	1.0

表 3 模型性能对比
Tab.3 Performance comparison between and among different models

模型	R^2	δ_{MSE}	δ_{MAPE}
XGBoost	0.91	126.54	1.52%
LightGBM	0.86	165.23	1.74%
RFR	0.92	73.77	1.16%

选取吹灰优化前后各 30 天的数据进行分析，其中 A 层吹灰器吹灰温升对比情况如表 4 和图 8 所示。传统吹灰模式的温升分布在 9.8~216.7℃，数据离散度大，平均四分位距达 67.05℃；精准吹灰模式实施后，平均值提升 21.56℃，平均四分位距降低至 23.69℃，较实施前降低了 64.67%，数据更加集中。精准吹灰模式一方面通过减少非必要吹灰操作使吹灰温升最低值提升至 60.60℃，另一方面增加了易结渣区域的吹灰频次，将水冷壁结渣程度控制在安全范围内。优化前后炉膛负压对比如图 9 所示。传统吹灰模式下曾多次出现掉渣引起的炉膛负压瞬时值^[1]大于 500 Pa 的情况，而投运精准吹灰模式后负压明显更稳定，炉膛负压瞬时最大值仅在 200 Pa 左右。




图 7 吹灰前后 C_p 变化特性
Fig.7 Characteristics of C_p changes before and after soot blowing

表 4 优化前后 A 层吹灰温升统计值对比
Tab.4 Comparison of statistical values of soot blowing temperature rise in layer A before and after optimization

组别	最大值	最小值	平均值	四分位距
传统吹灰模式	216.70	9.80	103.45	67.05
精准吹灰模式	188.03	60.60	125.01	23.69




图 8 优化前、后 A 层各吹灰器吹灰温升对比
Fig.8 The soot blowing temperature rise of each soot blower in layer A before and after optimization




图 9 优化前、后炉膛负压对比
Fig.9 The furnace draft pressures before and after optimization

吹灰优化前后炉膛的吹灰频次对比结果见表 5。优化后共计吹灰 574 次, 日均吹灰 19.13 次, 较优化前降低约 40.22%。

表 5 吹灰频次对比
Tab.5 Comparison of blowing frequency

组别	总吹灰频次/次	日均吹灰频次/次	降低幅度/%
传统吹灰模式	960	32.00	40.22
精准吹灰模式	574	19.13	

4 结 论

本文采用新型水冷壁结渣监测传感器获取水冷壁炉内壁温, 并基于机器学习方法建立了理论炉内壁温模型, 进而构建精准吹灰算法, 并与传统定时定量吹灰策略进行对比分析, 主要结论如下。

1) 通过 PCC 和 MI 联合分析方法, 揭示了给水流量在炉内壁温预测中的主导作用, 同时发现风煤比、水煤比与一二次风配比等衍生特征相比原始运行参数具有更高的信息量。基于随机森林回归构建的理论壁温模型具有更高的精度和鲁棒性, 经贝叶斯优化后其性能指标 ($R^2=0.92$, $\delta_{MSE}=73.77$, $\delta_{MAPE}=1.16\%$) 显著优于 XGBoost 和 LightGBM 模型。

2) 基于理论炉内壁温构建的结渣因子 C_p 能够反映结渣的不同状态, 若 C_p 呈指数级增长后骤降, 表明水冷壁结渣较为疏松, 可以自行掉落; 若 C_p 增长速度减缓并稳定在 0.98 以上, 则认为水冷壁结渣不易掉落, 需要吹灰干预。

3) 将精准吹灰算法与传统定时定量吹灰模式进行对比, 结果表明吹灰优化后吹灰温升最低值从 9.8 °C 提升至 60.60 °C, 平均值提升 21.56 °C, 平均四分位距降低至 23.69 °C, 较实施前降低 64.67%, 大幅减少了无效吹灰次数; 日均吹灰频次从 32.00 次/日降低至 19.13 次/日, 降低约 40.22%, 显著提升吹灰经济性及机组安全性。

【参 考 文 献】

- [1] 杨勇平, 陈衡, 郝俊红, 等. “双碳”目标下我国燃煤发电转型升级发展路径[J]. 中国电机工程学报, 2024, 44(17): 6900-6910.
YANG Yongping, CHEN Heng, HAO Junhong, et al. Development pathways for the transformation and upgrading of China's coal-fired power generation under the goals of carbon peak and carbon neutrality[J]. Proceedings of the CSEE, 2024, 44(17): 6900-6910.
- [2] 卢啸风, 李建波, 刘卓, 等. 燃准东煤电站锅炉沾污结渣特性及防治措施研究进展[J]. 中国电机工程学报, 2024, 44(18): 7247-7264.

- LU Xiaofeng, LI Jianbo, LIU Zhuo, et al. Research progress on the characteristics and countermeasures of ash slagging and fouling in boilers burning Zhundong coal[J]. Proceedings of the CSEE, 2024, 44(18): 7247-7264.
- [3] 王侨, 李雪怡, 陈北洋, 等. 燃煤电厂协同焚烧处置污泥成分影响及结渣特性[J]. 中国给水排水, 2025, 41(12): 33-40.
WANG Qiao, LI Xueyi, CHEN Beiyang, et al. Influence of sludge composition on co-incineration disposal in coal-fired power plant and its slagging characteristics[J]. China Water & Wastewater, 2025, 41(12): 33-40.
- [4] 苗建杰. 深度调峰下影响燃煤锅炉安全运行的因素分析[D]. 保定: 华北电力大学, 2023: 1.
MIAO Jianjie. Analysis of factors affecting the safe operation of coal fired boilers under deep peak load regulation[D]. Baoding: North China Electric Power University, 2023: 1.
- [5] 林东海. 电厂锅炉运行中炉内结渣的成因与预防[J]. 产业与科技论坛, 2015, 14(14): 70-71.
LIN Donghai. Causes and prevention of slagging in power plant boilers during operation[J]. Industrial & Science Tribune, 2015, 14(14): 70-71.
- [6] 岑可法, 樊建人, 池作和, 等. 锅炉和热交换器的积灰、结渣、磨损和腐蚀的防止原理和计算[M]. 北京: 科学出版社, 1994: 1.
CEN Kefa, FAN Jianren, CHI Zuohe, et al. Principles and calculations for preventing fouling, slagging, wear and corrosion of boilers and heat exchangers[M]. Beijing: Science Press, 1994: 1.
- [7] 李文华, 鲍昕, 沈利, 等. 管式 GGH 蒸汽吹灰器改造数值模拟及工程验证[J]. 热力发电, 2020, 49(3): 118-123.
LI Wenhua, BAO Ting, SHEN Li, et al. Numerical simulation and practical verification of soot-blowing system retrofitting for tubular gas-gas heater[J]. Thermal Power Generation, 2020, 49(3): 118-123.
- [8] 徐力刚, 黄亚继, 王健, 等. 基于炉膛结渣监测模型的吹灰优化[J]. 东南大学学报(自然科学版), 2018, 48(1): 63-70.
XU Ligang, HUANG Yaji, WANG Jian, et al. Soot-blowing optimization based on model of slagging monitoring around boiler furnace[J]. Journal of Southeast University (Natural Science Edition), 2018, 48(1): 63-70.
- [9] 高峰, 隋海涛, 石书雨, 等. 燃煤锅炉水冷壁热流监测在炉膛吹灰优化中的应用研究[J]. 工程技术研究, 2023, 8(19): 48-50.
GAO Feng, SUI Haitao, SHI Shuyu, et al. Research on the application of water wall heat flux monitoring of coal-fired boiler in furnace soot blowing optimization[J]. Engineering and Technological Research, 2023, 8(19): 48-50.
- [10] 黄书益, 王志超, 白彬, 等. 耦合炉内气相碱金属检测的结渣预报系统研究[J]. 热力发电, 2023, 52(7): 99-105.
HUANG Shuyi, WANG Zhichao, BAI Bin, et al. Investigation of slagging prediction system in boilers coupling measurement of gaseous alkali metal in furnace[J]. Thermal Power Generation, 2023, 52(7): 99-105.
- [11] BILIRGEN H. Slagging in PC boilers and developing mitigation strategies[J]. Fuel, 2014, 115: 618-624.
- [12] TALER J, TALER D, LUDOWSKI P. Measurements of local heat flux to membrane water walls of combustion chambers[J]. Fuel, 2014, 115: 70-83.

- [13] SHI Z, LI P, ZHOU Y G, et al. Numerical study and structural optimization of water-wall temperature-measurement device for ultra-supercritical boiler[J]. *Sensors*, 2024, 24(18): 6038.
- [14] 马晓春, 刘相宏, 陈晶, 等. 火力发电厂分时线性智能吹灰模型的应用[J]. *发电设备*, 2024, 38(1): 30-35.
MA Xiaochun, LIU Xianghong, CHEN Jing, et al. Application on intelligent soot blowing model of thermal power plant based on time sharing linearity[J]. *Power Equipment*, 2024, 38(1): 30-35.
- [15] 李孟威. 基于神经网络的燃煤电站锅炉受热面积灰预测研究[D]. 太原: 中北大学, 2022: 1.
LI Mengwei. Research on ash prediction of heating area of coal-fired power station boiler based on neural network[D]. Taiyuan: North University of China, 2022: 1.
- [16] 刘俊, 黄亚继, 徐文韬, 等. 基于热损失分析的水冷壁结渣监测和吹灰优化[J]. *洁净煤技术*, 2024, 30(增刊2): 501-507.
LIU Jun, HUANG Yaji, XU Wentao, et al. Monitoring of slagging and soot-blowing optimization in waterwall based on heat loss analysis[J]. *Clean Coal Technology*, 2024, 30(Suppl.2): 501-507.
- [17] DHANUSKODI R, KALIAPPAN R, SURESH S, et al. Artificial neural networks model for predicting wall temperature of supercritical boilers[J]. *Applied Thermal Engineering*, 2015, 90: 749-753.
- [18] TERUEL E, CORTÉS C, DÍEZ L I, et al. Monitoring and prediction of fouling in coal-fired utility boilers using neural networks[J]. *Chemical Engineering Science*, 2005, 60(18): 5035-5048.
- [19] PEÑA B, TERUEL E, DÍEZ L I. Towards soot-blowing optimization in superheaters[J]. *Applied Thermal Engineering*, 2013, 61(2): 737-746.
- [20] LI P, LI K, ZHOU Y, et al. An effective strategy for monitoring slagging location and severity on the waterwall surface in operation coal-fired boilers[J]. *Energies*, 2023, 16(24): 7925.

(责任编辑 邓玲惠)