

控制与决策

Control and Decision

城市生活垃圾焚烧过程二次风量智能优化设定方法

丁晨曦, 严爱军, 王殿辉

引用本文:

丁晨曦, 严爱军, 王殿辉. 城市生活垃圾焚烧过程二次风量智能优化设定方法[J]. *控制与决策*, 2024, 39(1): 49–58.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0349>

您可能感兴趣的其他文章

Articles you may be interested in

[输入约束不确定系统的点对点迭代学习控制与优化](#)

Point-to-point iterative learning control and optimization for uncertain systems with constrained input

控制与决策. 2021, 36(6): 1435–1441 <https://doi.org/10.13195/j.kzyjc.2019.0908>

[基于数据驱动的浓密-压滤过程协调优化控制](#)

Data driven coordinated optimization control of thickening-filter process

控制与决策. 2021, 36(5): 1095–1100 <https://doi.org/10.13195/j.kzyjc.2019.1151>

[基于多维泰勒网的超前d步预测模型](#)

d-step-ahead predictive model based on multi-dimensional Taylor network

控制与决策. 2021, 36(2): 345–354 <https://doi.org/10.13195/j.kzyjc.2019.0722>

[基于高炉炉况评价和反馈补偿的喷煤量决策优化](#)

Decision-making optimization of coal injection volume based on evaluation of blast furnace condition

控制与决策. 2020, 35(11): 2803–2809 <https://doi.org/10.13195/j.kzyjc.2018.1553>

[基于无标签、不均衡、初值不确定数据的设备健康评估方法](#)

Equipment health risk assessment based on unlabeled, unbalanced data under uncertain initial condition

控制与决策. 2020, 35(11): 2687–2695 <https://doi.org/10.13195/j.kzyjc.2018.1493>

城市生活垃圾焚烧过程二次风量智能优化设定方法

丁晨曦^{1,2}, 严爱军^{1,2,3†}, 王殿辉^{4,5,6}

- (1. 北京工业大学 信息学部, 北京 100124; 2. 数字社区教育部工程研究中心, 北京 100124;
3. 城市轨道交通北京实验室, 北京 100124; 4. 中国矿业大学 人工智能研究院, 江苏 徐州 221116;
5. 东北大学 流程工业综合自动化国家重点实验室, 沈阳 110004;
6. 拉筹伯大学 计算机科学与信息技术系, 墨尔本 VIC 3086)

摘要: 垃圾焚烧过程二次风量通常是依据人工经验设定, 具有主观随意性, 使污染物排放浓度不达标. 针对此问题, 提出一种二次风量智能优化设定方法. 首先, 建立二次风量的案例推理预设模型、设定值的评价与学习模型; 其次, 建立工艺指标的随机配置网络预测模型; 接着, 建立基于径向基神经网络自学习模糊推理的智能补偿模型; 最后, 将二次风量预设模型、工艺指标预测模型、智能补偿模型以及设定值的评价与学习模型有机集成, 设计二次风量智能优化设定方法的结构与功能, 并给出算法实现. 采用某垃圾焚烧厂历史数据进行实验, 结果表明, 所提方法获得的二次风量设定值波动程度更小, 按此设定值运行的控制系统可以减少污染物排放浓度, 促进垃圾焚烧过程运行优化目标的实现.

关键词: 垃圾焚烧; 优化设定; 案例推理; 随机配置网络; 智能补偿; 评价与学习

中图分类号: TP272

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0349

引用格式: 丁晨曦, 严爱军, 王殿辉. 城市生活垃圾焚烧过程二次风量智能优化设定方法[J]. 控制与决策, 2024, 39(1): 49-58.

Intelligent optimal setting method of secondary air flow in municipal solid waste incineration process

DING Chen-xi^{1,2}, YAN Ai-jun^{1,2,3†}, WANG Dian-hui^{4,5,6}

- (1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China; 2. Engineering Research Center of Digital Community of Ministry of Education, Beijing 100124, China; 3. Beijing Laboratory for Urban Mass Transit, Beijing 100124, China; 4. Artificial Intelligence Research Institute, China University of Mining and Technology, Xuzhou 221116, China; 5. State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110004, China; 6. Department of Computer Science and Information Technology, La Trobe University, Melbourne VIC 3086, Australia)

Abstract: Aiming at the secondary air flow of waste incineration process are usually set according to manual experience, which is subjective and arbitrary, so that the pollutant emission concentration does not meet the standard, an intelligent optimal setting method is proposed. Firstly, a case-based reasoning pre-set model, and an evaluation and learning model of secondary air flow setpoint are constructed. Secondly, a stochastic configuration network process index prediction model is established. Then, an intelligent compensation model based on the RBF neural network self-learning fuzzy inference is constructed. Finally, the pre-set model, process index prediction model, intelligent compensation model and evaluation and learning model of setpoint are organically integrated, the structure and function of the intelligent optimal setting method are designed, and algorithm implementation is given. The experimental results based on historical data of a waste incineration plant show that the fluctuation degree of setpoint obtained by this method is less, and the control system running according to the setpoint can reduce the pollutant emission concentration, which can promote the realization of operation optimal goal in the incineration process.

Keywords: waste incineration; optimal setting; case-based reasoning; stochastic configuration network; intelligent compensation; evaluation and learning

收稿日期: 2022-03-07; 录用日期: 2022-07-06.

基金项目: 国家自然科学基金项目(61873009, 62073006); 北京市自然科学基金项目(4212032); 国家重点研发计划项目(2018AAA010030).

责任编辑: 冯俊娥.

†通讯作者. E-mail: yanaijun@bjut.edu.cn.

0 引言

垃圾焚烧由于无害化、资源化、减量化的特点,成为我国常用的垃圾处理方式^[1]. 垃圾稳定充分燃烧是保证经济效益最大且环境影响最小的前提,垃圾不充分燃烧会影响资源回收利用,还会引起有害物质浓度上升. 焚烧过程的二次风从炉膛上方进入,作用是加强气流扰动,使产生的烟气得到高度湍流,为有害物质分解提供条件^[2]. 目前,二次风量通常是由人工设定,具有主观随意性,可能导致烟气排放不符合标准. 因此,研究智能设定方法具有重要意义.

目前,参数设定方法有机理建模设定、知识建模设定、数据建模设定及集成建模设定等. 机理设定根据输入输出变量机理关系建立设定模型,比如,文献[3]通过建立冷风机冷凝温度机理模型计算其最佳设定值;文献[4]采用活性污泥模型获取硝态氮和氨氮最佳设定值. 数据或知识设定是采用支持向量机^[5]、神经网络^[6]等对输出变量数据拟合得到设定值,或通过经验与知识形成专家规则自动给出设定值^[7-8]. 针对传统知识建模设定专家规则的局限性,文献[9]利用部分规则和云模型自动生成大规模规则库以获得设定值. 集成建模设定是将指标预测作为一个组成部分,例如,文献[10]针对浮选选矿过程,利用控制变量和输出预测经济性能,再采用实时优化技术得到预设设定值,利用模型预测技术实现预设设定值补偿;文献[11]采用前馈补偿抑制扰动,并通过指标在线测量得到最优反馈增益,设计出最优加药量控制结构以获得铈浮选过程最优加药量;文献[12]提出了由优化设定、模型预测控制和校正模型组成的多目标优化控制系统,能够获得除铁过程出口亚铁离子浓度最优设定值. 另外,部分学者通过优化算法获取参数设定

值^[13]. 以上所述不同的设定方法在复杂工业过程控制中均有不同程度应用,避免了手动设定的主观性.

就我国垃圾焚烧过程而言,一般是人工调整二次风量以达到优化运行,该方法具有主观随意性,难以保证烟气完全燃烧,使有害物质浓度上升. 在上述工业过程设定方法中,机理设定依赖于构建准确的机理模型,而焚烧过程具有非线性、强耦合等特点,难以构建准确机理模型;知识设定利用专家规则自动给出设定值,未考虑工况复杂多变的影响,且不能动态调整设定值;数据设定利用历史数据建立设定模型,获取参数预测值;集成设定整合多种模型,利用各模型的优势,综合考虑工况变化、指标要求,采用相应算法得到参数优化设定值.

基于上述分析,本文考虑一氧化碳(carbon monoxide, CO)浓度等指标,将案例推理(case-based reasoning, CBR)、随机配置网络(stochastic configuration networks, SCNs)等智能方法用于二次风量设定建模,提出集成建模的智能优化设定方法. 通过预设模型、评价与学习模型、工艺指标预测模型和智能补偿模型计算得到二次风量优化设定值,并通过模拟实验验证其有效性. 本文所提集成建模方法整合了不同功能模型,不需要建立精确数学模型,可避免人工设定的主观随意性,能够根据工艺指标预测值对设定值进行动态补偿,对减少有害物质排放、提高控制性能、满足工艺要求、实现焚烧过程优化运行具有重要意义.

1 焚烧工艺及问题描述

焚烧过程工艺如图1所示. 首先通过进料器使垃圾输送至干燥炉排,在一次风和炉内高温作用下干燥处理. 接着输送至燃烧炉排1和燃烧炉排2,在

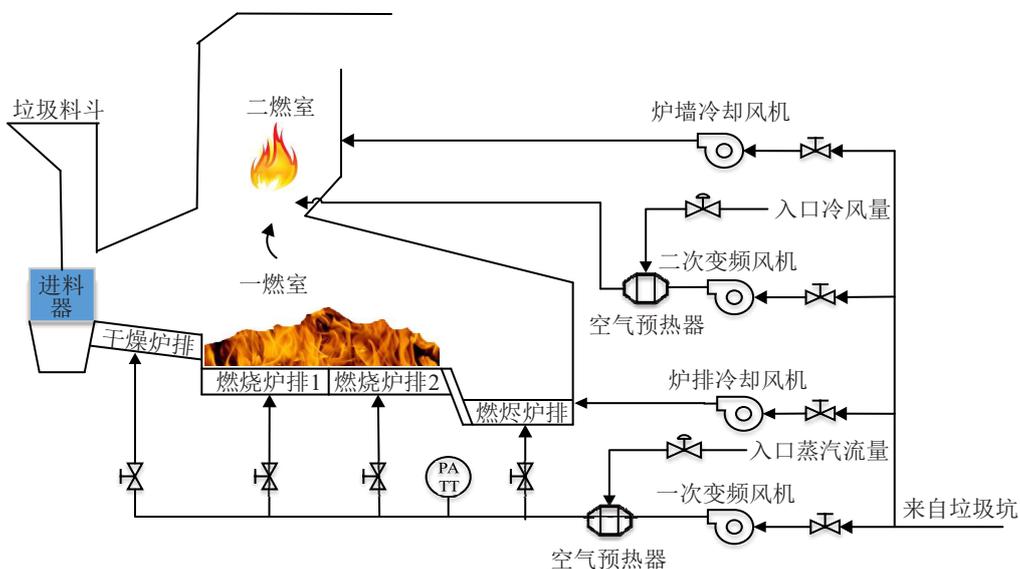


图1 垃圾焚烧工艺流程

一次风作用下达到着火点后开始燃烧并析出挥发份. 与此同时, 燃烧过程产生的烟气在经过二燃室时, 在二次风作用下形成湍流, 促进可燃物与氧气混合使烟气完全燃烧. 最后, 将焚烧后的垃圾输送到燃烬炉排, 未燃成分在此完全燃烬. 由上述可知, 焚烧的核心是炉排上垃圾燃烧及其产生的烟气燃烧.

图1中二燃室所需的二次风量一般是根据炉中所需总风量分配而得, 计算公式^[14]如下:

$$\begin{cases} F = 1000 \times \alpha \times Q_b \times [21\% / (21\% - O_2)] + \delta, \\ F_2 \approx 15\% \times F. \end{cases} \quad (1)$$

其中: F 为燃烧过程所需总风量; Q_b 为出口主蒸汽流量; O_2 为出口烟气含氧量(gas oxygen concentration, GOC); F_2 为烟气燃烧所需二次风量; α 、 δ 为操作人员调试得出的 F 调整系数, α 为 F 与 Q_b 的比例关系, δ 为 F 经验修正值.

式(1)中二次风量 F_2 的精确计算依赖于焚烧机理分析及数学模型构建, 而工况复杂多变使 F_2 设定值机理计算模型难以准确获得. 实际操作中是人工根据一些参数变化调整 F_2 , 以达到烟气充分燃烧、CO浓度完全达标的目标, 可用下式表示:

$$\begin{aligned} \min J &= \min \|x_5(t) - x_{5D}(t)\|^2, \\ F_2 &= f(x_1(t), x_2(t), x_3(t), x_4(t), x_5(t); \Omega(t)); \\ \text{s.t. } &6.0 \leq x_4(t) \leq 8.0 (\%), \end{aligned}$$

$$x_5(t) \leq 50 (\text{mg}/\text{m}^3). \quad (2)$$

其中: J 为性能指标; $x_1(t) \sim x_5(t)$ 分别为进料速度、二次风机出口风压、炉内烟气温度、GOC目标值、CO浓度目标值, $x_1(t) \sim x_3(t)$ 是检测仪表得到的, $x_4(t)$ 和 $x_5(t)$ 根据工艺要求产生; $\omega(t)$ 为不可测干扰因素, 比如垃圾热值波动; $x_{5D}(t)$ 为CO浓度检测值.

在长期实践中, 操作人员通过观察 $x_1(t) \sim x_5(t)$ (以下简写为 $x_1 \sim x_5$)的变化调整二次风量 F_2 , 积累丰富调整经验后, 可实现 F_2 优化设定. 但在人工经验不足的情况下, F_2 设定值可能并不合适, 导致有害物排放浓度超标. 因此, 如何模拟有经验操作人员的设定过程, 自动调整 F_2 是一个急需解决的问题.

2 二次风量智能优化设定方法

本节将CBR、SCNs、径向基函数(radial basis function, RBF)神经网络自学习模糊推理等方法用于二次风量设定建模, 提出智能优化设定方法, 包括设定结构与功能、预设模型、评价与学习模型、工艺指标预测模型、智能补偿模型等. 下面研究上述模型构建与集成、工艺指标相关变量选择、智能补偿实现等难点问题, 并给出解决方法.

2.1 设定结构与功能

智能优化设定方法结构如图2所示, 包括预设模型、工艺指标预测模型、智能补偿模型及设定值的评价与学习模型等, 主要功能如下所述.

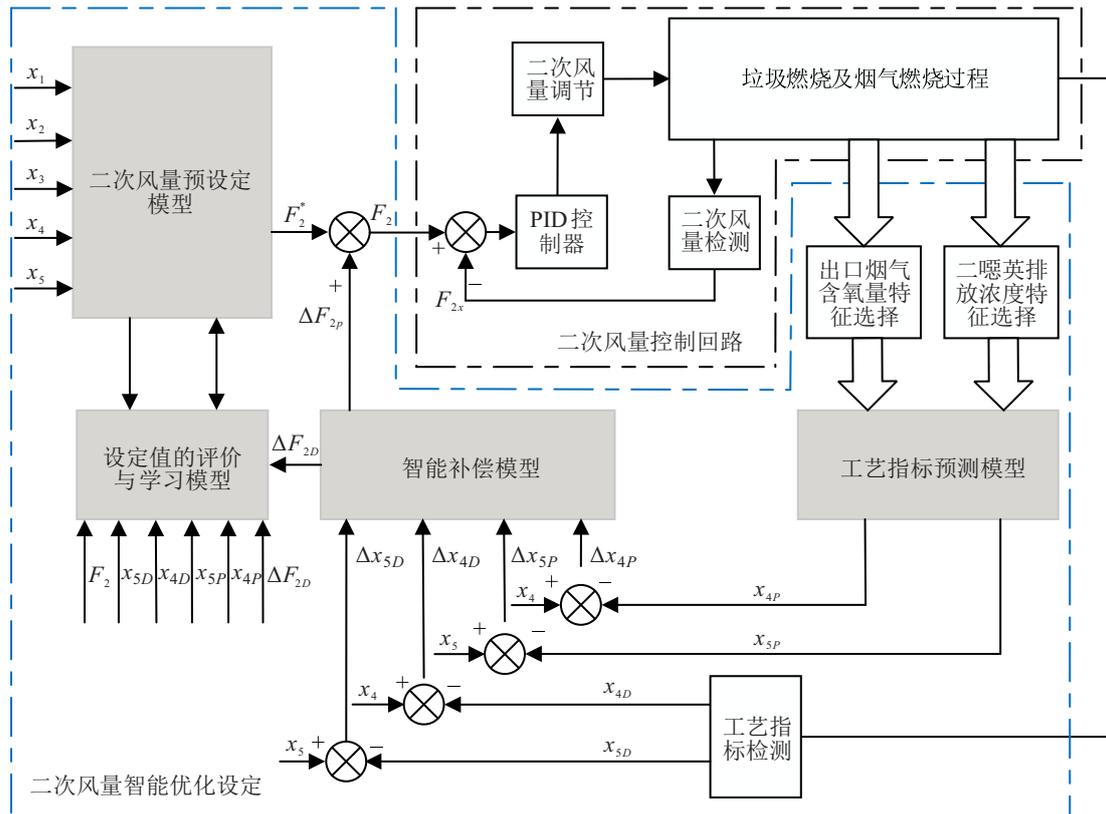


图2 二次风量智能优化设定方法结构

二次风量预设模型根据 $x_1 \sim x_5$ 的值通过 CBR 得到预设值 F_2^* . 智能补偿模型是获取补偿值 ΔF_{2P} 和修正值 ΔF_{2D} , 实现步骤是: 首先, 工艺指标预测模型将特征选择后的变量作为输入, 采用 SCNs 得到 GOC 和 CO 的浓度预测值 x_{4P} 和 x_{5P} , 并计算相应偏差 Δx_{4P} 和 Δx_{5P} ; 然后, 根据 GOC 和 CO 的浓度检测值 x_{4D} 和 x_{5D} 计算相应偏差 Δx_{4D} 和 Δx_{5D} ; 最后, 将 Δx_{4P} 、 Δx_{5P} 和 Δx_{4D} 、 Δx_{5D} 作为智能补偿模型输入, 采用 RBF 神经网络自学习模糊推理方法得到 ΔF_{2P} 和 ΔF_{2D} . 根据 F_2^* 和 ΔF_{2P} 可计算二次风量设定值 $F_2 = F_2^* + \Delta F_{2P}$, 二次风量控制回路按此设定值运行. 评价与学习模型是根据 ΔF_{2P} 、 ΔF_{2D} 、 x_{4P} 、 x_{5P} 、 x_{4D} 、 x_{5D} 对 F_2 进行评价与学习, 目的是获得合理的 F_2 .

2.2 预设、评价与学习模型

CBR 是成熟的问题求解方法, 已广泛应用于工业过程优化^[15]、医疗辅助诊断^[16]等领域. 它通过检索历史案例获得与当前问题相似的案例, 并进行重用与修正, 从而获得当前问题的解. 下面介绍采用 CBR 构建预设、评价与学习模型的过程与算法实现.

2.2.1 模型结构

预设、评价与学习模型结构如图3所示. 首先将 $x_1 \sim x_5$ 组成目标案例在案例库检索相似案例并进行匹配重用得到预设值 F_2^* , 将其与智能补偿模型输出的补偿值 ΔF_{2P} 运算后得到设定值 $F_2 = F_2^* + \Delta F_{2P}$. 然后根据 ΔF_{2P} 评价 F_2 , 若 ΔF_{2P} 满足要求, 则认为 F_2 合理, 否则根据工艺指标 x_{4P} 、 x_{5P} 、 x_{4D} 、 x_{5D} 评价 F_2 , 若满足要求, 则认为 F_2 合理; 否则对 F_2 进行修正, 修正值 ΔF_{2D} 由智能补偿模型得到, 案例存储是将 $x_1 \sim x_5$ 及其合理的 F_2 存入案例库. 最后进行案例维护以实现设定值的学习.

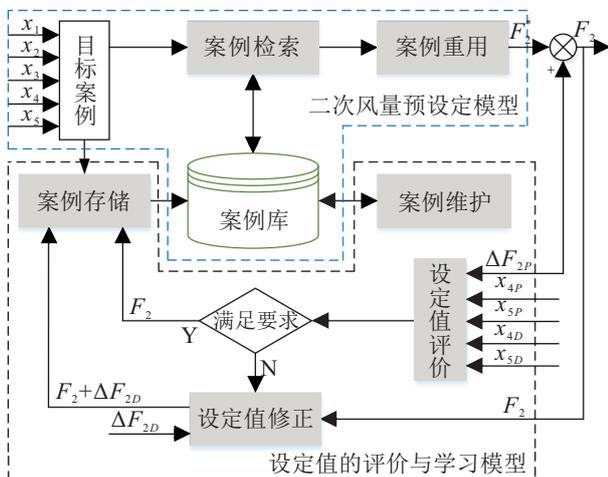


图3 二次风量预设及设定值的评价与学习模型

2.2.2 算法实现

1) 构建案例库. 假设 $x_1 \sim x_5$ 有 n 组历史数据, 相应的有 n 个二次风量设定值 F_2 , 将它们组成源案例构建出案例库, 每条源案例 C_k 可表示为

$$C_k = \langle X_k; F_{2k} \rangle, \quad k = 1, 2, \dots, n. \quad (3)$$

其中: F_{2k} 为第 k 条源案例输出 (即设定值); X_k 为第 n 条源案例输入 (即 $x_1 \sim x_5$ 历史数据), 可表示为

$$X_k = (x_{1k}, x_{2k}, x_{3k}, x_{4k}, x_{5k}), \quad (4)$$

X_{ik} ($i = 1, \dots, 5$) 是特征变量 x_i 的值.

2) 预设. 令目标案例 $T = (t_1, t_2, \dots, t_5)$, 表示 $x_1 \sim x_5$ 当前数据, 为得到相应二次风量设定值, 需在案例库中检索与 T 匹配的案例. 首先对所有数据归一化, 再采用如下欧氏距离相似性度量方法检索:

$$d_k = \sqrt{(t_1 - x_{1k})^2 + \dots + (t_5 - x_{5k})^2}, \quad k = 1, 2, \dots, n. \quad (5)$$

将距离 $d_k \in [0, 5]$ 转换为相似度 $\text{sim}_k \in [0, 1]$, 有

$$\text{sim}_k = 1 - \frac{d_k}{1 + d_k}, \quad k = 1, 2, \dots, n. \quad (6)$$

令目标案例 T 与源案例中 x_k 的最大相似度为

$$S_{\max} = \text{Max}(\text{sim}_k), \quad k = 1, 2, \dots, n. \quad (7)$$

检索出 S_{\max} 对应的案例为匹配案例, 若有多个匹配案例 (即多个相等 S_{\max}), 则选最靠近 GOC 为 7.0 对应的案例 (根据式 (2), GOC 应为 $6.0 \leq x_5 \leq 8.0$), 完成案例检索. 假设 $S_{\max} = \text{sim}_k$, 将案例库中相应案例 $C_k = \langle X_k; F_{2k} \rangle$ 取出重用, 其对应的案例解 F_{2k} 为二次风量预设值, 记为 $F_2^* = F_{2k}$.

3) 评价与学习. 根据 ΔF_{2P} 、 x_{4P} 、 x_{5P} 、 x_{4D} 、 x_{5D} 对二次风量设定值进行评价与修正. 若 $|\Delta F_{2P}/F_2| \leq \lambda$ (λ 为补偿最小阈值), 则认为 F_2 合理; 否则, 通过 x_{4P} 、 x_{5P} 、 x_{4D} 、 x_{5D} 评价 F_2 . 若 $|x_{4P}/x_4| \leq \xi$, 且 $|x_{5P}/x_5| \leq \xi$ 或 $|x_4 - x_{4D}| \leq \xi$ 且 $|x_5 - x_{5D}| \leq \xi$ (ξ 是根据工艺指标要求给定的工艺指标波动阈值), 则认为 F_2 合理; 否则需要修正, 修正公式为 $F_2 + \Delta F_{2D}$ (ΔF_{2D} 是智能补偿模型计算得到的修正值). 将目标案例 T 与合理的 F_2 存于案例库实现增量式学习. 计算 T 与源案例 X_k ($k = 1, 2, \dots, n$) 的相似度, 选 S_{\max} 的一条或几条案例 (多个相等 S_{\max} 时), 比较 GOC 大小. 若相等, 则随机选一条存储; 若不相等, 则选最靠近 7.0 对应的案例存储, 删除其他, 完成案例维护. 为保证数据多样性和差异性, 保留相似度小于 S_{\max} 的案例以实现进一步学习.

2.3 工艺指标预测模型

本节采用文献[17]的SCNs建立GOC和CO浓度等工艺指标预测模型.建模过程采用针对垃圾热值在线预测建模的两个步骤:首先利用互信息(mutual information, MI)^[18]初步选择预测模型输入特征(限于篇幅,不列出具体的特征),算法实现参见文献[19];其次利用SCN替代文献[19]的模糊神经网络,并将粒子群(particle swarm optimization, PSO)与SCNs融合形成PSO-SCN,对输入特征再次选择并得到SCN工艺指标预测模型.算法实现如下:

1) 随机初始化粒子速度和位置.粒子群数量为 P ,最大迭代次数为 S ,随机初始化粒子速度 V_j 和位置 Z_j ,产生初始粒子群.

2) 位置向量转化为特征向量. PSO算法进行特征选择时,粒子每一维对应一个特征.为便于后续算法实现,将MI初步选出的特征表示成0和1组成的向量(粒子位置向量形式),如下所示:

$$Y_j^s = [y_{j1}^s, \dots, y_{jb}^s, \dots, y_{jo}^s]. \quad (8)$$

其中: Y_j^s 为第 s 次迭代粒子 j 的位置; y_{jb}^s 为第 s 次迭代粒子 j 的第 b 维, $y_{jb}^s = 1$ 和 $y_{jb}^s = 0$ 分别表示第 b 维对应特征被选择和被淘汰; o 为初次选出的特征数量.位置向量转化为特征向量的公式为

$$y_{jb}^s = \begin{cases} 1, & z_{jb}^s \geq r_0; \\ 0, & \text{otherwise.} \end{cases} \quad (9)$$

其中: z_{jb}^s 为第 s 次迭代粒子 j 位置矢量的第 b 维分量; r_0 为区间(0.2, 0.8)上的随机数.根据上式将粒子的评价转化为特征向量的评价.

3) 适应度函数.本文选择文献[17]的SC-III算法训练SCN预测模型,并得到工艺指标预测值的均方根误差(root mean square error, RMSE),将其定义为适应度函数,如下所示:

$$\text{fitness}_j^s = \frac{1}{\text{RMSE}_j^s}. \quad (10)$$

其中: fitness_j^s 为 s 次迭代粒子 j 的适应度; RMSE_j^s 为将 s 次迭代粒子 j 对应特征作为模型输入时工艺指标预测值的RMSE.以GOC为例, RMSE_j^s 计算如下:

$$\text{RMSE}_j^s = \sqrt{\frac{\sum_{i'=1}^m [x_{4P}(i') - x_{4D}(i')]^2}{m}}. \quad (11)$$

其中: m 为训练样本数量; x_{4P} 为GOC预测值; x_{4D} 为GOC离线检测值(实际值).

4) 更新粒子的速度位置.第 s 次迭代粒子 j 的速度和位置更新公式为

$$\begin{aligned} V_j^{s+1} &= \\ \omega V_j^s + c_1 r_1 (\text{pbest}_j^s - Z_j^s) + c_2 r_2 (\text{gbest}^s - Z_j^s), \\ Z_j^{s+1} &= Z_j^s + V_j^{s+1}. \end{aligned} \quad (12)$$

其中: s 为迭代次数, ω 为惯性因子, V_j^s 为 s 次迭代粒子 j 的速度, c_1 、 c_2 为加速因子, r_1 、 r_2 为区间[0, 1]上的随机数, pbest 为个体最优解, gbest 为群体最优解, Z_j^s 为 s 次迭代粒子 j 的位置.

5) 变异.变异是为了避免粒子更新时陷入局部最优,出现过早收敛.通过计算每个粒子位置与 gbest 的欧氏距离判定是否聚集到 gbest ,公式为

$$L_j^s = \sqrt{(Z_1^s - \text{gbest}_1^s)^2 + \dots + (Z_P^s - \text{gbest}_P^s)^2}, \quad (13)$$

其中 L_j^s 为第 s 次迭代中粒子 j 的位置与 gbest 的欧氏距离,对 P 个粒子的上述距离求平均值,有

$$\bar{L}_j^s = \frac{1}{P} \sum_{j=1}^P L_j^s. \quad (14)$$

设定距离阈值 $L_m = c_0 L_0$.其中: L_0 为初始粒子群每个粒子与 gbest 欧氏距离的平均值, c_0 为区间(0, 1)上的随机数.若 $\bar{L}_j^s > L_m$,则粒子未聚集到 gbest ,对 gbest 进行 q 次自适应 t 分布变异,公式为

$$\text{gbest}' = \text{gbest} + \sigma_j(s) \cdot t_p. \quad (15)$$

其中: $\sigma_j(s)$ 是变异尺度, t_p 是自由度为 p 时的 t 值. $\sigma_j(s)$ 的计算如下所示:

$$\begin{aligned} \sigma_j(s) &= \left[\beta^s \frac{f_{\max}(s) - f_{\min}(s)}{f_{\max}(s)} + (1 - \beta^s) \beta^s \right] \times \\ &(\text{gbest}_{\max} - \text{gbest}_{\min}). \end{aligned} \quad (16)$$

其中: $f_{\max}(s)$ 为第 s 代最大适应度值; $f_{\min}(s)$ 为第 s 代最小适应度值; $(f_{\max}(s) - f_{\min}(s))/f_{\max}(s)$ 为根据每一代最大和最小适应度值调整的变异尺度; gbest_{\max} 和 gbest_{\min} 分别为群体最优解 gbest 的最大值和最小值; β 为略小于1的常数.

通过以上所述,可以实现输入特征的选择,并从中得到SCN工艺指标预测模型.算法步骤如下.

step 1: 参数初始化.对粒子数量 P ,惯性因子 ω ,加速因子 c_1 、 c_2 ,最大迭代次数 S ,变异次数 q 等参数进行赋值,并对数据进行标准化处理.

step 2: 通过MI方法实现输入特征的初步选择.

step 3: 随机初始化 V_j 和 Z_j ,产生初始粒子群.

step 4: 每个粒子按式(8)和(9)转化成特征向量.

step 5: 通过SC-III算法训练出SCN预测模型.

step 6: 根据式(10)和(11)计算每个粒子的适应度值,将粒子当前位置作为个体历史最优位置,群体最优解 gbest 设置为群体历史最优位置.

step 7: 若 PSO-SCN 算法达到最大迭代次数, 则转入 step 11, 否则转入 step 8.

step 8: 根据式 (12) 更新所有粒子的速度和位置, 计算粒子适应度值, 若 pbest 和 gbest 优于历史最优位置, 则更新 pbest 和 gbest.

step 9: 按式 (13) 和 (14) 计算每个粒子与 gbest 的平均欧氏距离, 若 $\bar{L}_j^s > L_m$, 则转入 step 10, 否则转入 step 7.

step 10: 根据式 (15) 和 (16) 进行 q 次变异操作, 得到 gbest'. 若 gbest' 优于 gbest, 则 gbest = gbest', 返回 step 7, 否则转入 step 11.

step 11: 将迭代过程中的最优解作为特征子集输出, 并训练出相应的 SCN 工艺指标预测模型.

2.4 智能补偿模型

焚烧过程复杂, 干扰因素多, 按二次风量预设值 F_2^* 运行会使烟气不完全燃烧, GOC 和 CO 浓度不满足要求, 所以需根据工艺指标对预设值进行补偿. 模糊推理能处理模糊问题, 被广泛应用于复杂工业过程^[20]、导弹系统^[21]等领域模糊问题求解. RBF 神经网络具有很强的非线性拟和及自学习能力, 学习规则简单, 可用于自适应动态补偿. 本节通过模糊推理和 RBF 神经网络建立智能补偿模型, 能根据工艺指标偏差得到二次风量补偿值和修正值. 以补偿值获取为例给出模型结构 (如图 4) 与算法实现, 修正值获取类似.

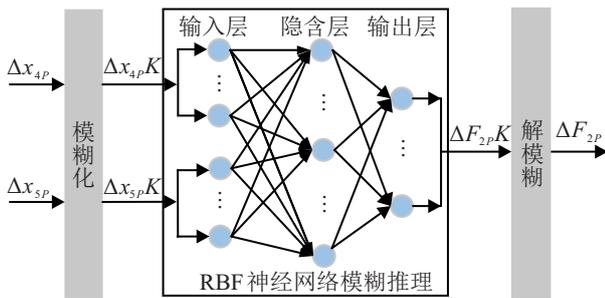


图 4 智能补偿模型结构

算法步骤如下: 首先按模糊操作经验得到表 1 所示模糊推理规则 (Δx_{4P} 和 Δx_{5P} 为 GOC 和 CO 浓度的目标值与预测值的偏差, ΔF_{2P} 为二次风量补偿值). 模糊操作经验是人工根据 GOC 和 CO 浓度调整二次风量的经验. 比如: 当 GOC 和 CO 的浓度基本满足要求, 即 Δx_{4P} 、 Δx_{5P} 均较小时, ΔF_{2P} 为零; 当 GOC 的浓度偏小, CO 的浓度偏大, 即 Δx_{4P} 正偏大, Δx_{5P} 负偏大时, 应增大二次风量使垃圾完全焚烧, 此时 ΔF_{2P} 为正大. 将模糊操作经验按隶属度函数模糊化处理, Δx_{4P} 、 Δx_{5P} 、 ΔF_{2P} 的模糊子集为 NB、

NM、NS、ZO、PS、PM、PB, 分别表示负大、负中、负小、零、正小、正中、正大 7 个模糊等级, Δx_{4P} 、 Δx_{5P} 、 ΔF_{2P} 模糊量化值为 Δx_{4PK} 、 Δx_{5PK} 、 ΔF_{2PK} , Δx_{4PK} 、 Δx_{5PK} 、 $\Delta F_{2PK} \in [-3, 3] \subset Z$. 然后将 Δx_{4PK} 、 Δx_{5PK} 作为输入, ΔF_{2PK} 作为输出, 采用 RBF 神经网络实现模糊推理, 网络结构为 14-10-7. 最后将 ΔF_{2PK} 解模糊化得到 ΔF_{2P} .

表 1 ΔF_{2P} 模糊推理规则表

Δx_{5P}	Δx_{4P}						
	NB	NM	NS	ZO	PS	PM	PB
NB	PS	PS	PS	PS	PM	PM	PB
NM	PS	PS	PS	PS	PM	PM	PB
NS	PS	PS	PS	PS	PS	PM	PB
ZO	ZO	ZO	ZO	ZO	PS	PS	PS
PS	NM	NS	NS	NS	NS	NS	NS
PM	NB	NM	NM	NS	NS	NS	NS
PB	NB	NM	NS	NS	NS	NS	NS

2.5 智能优化设定方法的算法步骤

综上所述, 智能优化设定方法的算法步骤如下.

step 1: 参数初始化, 并设置采样周期 T_s ;

step 2: 将目标案例 T 作为输入, 根据预设模型得到二次风量预设值 F_2^* ;

step 3: 通过工艺指标预测模型得到 x_{4P} 、 x_{5P} , 根据 x_{4P} 、 x_{5P} 和 x_4 、 x_5 计算 Δx_{4P} 、 Δx_{5P} , 并根据工艺指标离线检测值 Δx_{4D} 、 Δx_{5D} 和 x_4 、 x_5 计算 Δx_{4D} 、 Δx_{5D} ;

step 4: 分别将 Δx_{4P} 、 Δx_{5P} 和 Δx_{4D} 、 Δx_{5D} 作为输入, 通过智能补偿模型得到二次风量的补偿值 ΔF_{2P} 和修正值 ΔF_{2D} ;

step 5: 根据 F_2^* 和 ΔF_{2P} 计算得到二次风量的设定值 $F_2 = F_2^* + \Delta F_{2P}$;

step 6: 根据评价与学习模型完成设定值的评价与修正、案例存储和维护, 转入 step 1.

3 实验与结果分析

上节介绍智能优化设定方法的结构、功能及算法, 目标是通过二次风量优化设定使 GOC 和 CO 浓度满足式 (2) 的约束条件. 本节考察设定方法的效果, 包括工艺指标预测和设定方法实验. 实验在 Matlab R2016a 环境下编程实现, 所用计算机 CPU 为 Intel(R) Core(TM) i5-5200U CPU @ 2.20 GHz, 内存为 4 GB.

3.1 工艺指标预测实验

本部分考察特征选择效果及 SCN 预测模型准确率, 设计了两个实验. 实验数据来自某垃圾焚烧厂的

300组历史数据,采用分层抽样方法构造200组训练集和100组测试集。

实验1 特征选择方法对比.考察所提特征选择方法的效果,将其训练得到的SCN预测模型(记为MI-PSO-SCN)与单一特征选择方法得到的SCN预测模型(记为MI-SCN和PSO-SCN)进行对比。

实验1各方法参数设置: PSO算法中,粒子数量 $P = 20$,随机数 $r_0 = 0.5, r_1 = r_2 = 0.5, c_0 = 0.5$,惯性因子 $\omega = 0.8$,加速因子 $c_1 = c_2 = 1.5$,自由度 $p = s + 10$ (s 为迭代次数), $\beta = 0.97$,最大迭代次数 $S = 100$,变异次数 $q = 50$; SCN最大隐含层节点数为100,最大随机配置次数为100,随机参数选择范围 $[-\lambda_i, \lambda_i], \lambda_i = \{0.5, 1, 5, 10, 30, 50\}$,预期误差为0.05。

实验2 不同预测模型对比.考察SCN预测模型的准确率,将所提MI-PSO-SCN特征选择方法得到的特征作为输入,分别采用SCN、BP和RBF模型对工艺指标进行预测,对比分析模型的预测精度。

实验2各模型参数设置: BP模型采用三层网络结构,学习算法为误差逆向传播算法,隐含层节点数为10,激活函数为Sigmoid函数,学习率为0.01,最大训练次数为2000; RBF模型采用三层网络结构,采用梯度下降法调整模型参数,隐含层节点数为10,激活函数为高斯函数,学习率为0.01,最大训练次数为2000; SCN模型采用三层网络结构,选用SC-III算法训练SCN,隐含层节点数为10,最大随机配置次数为100,随机参数选择范围 $[-\lambda_i, \lambda_i], \lambda_i = \{0.5, 1, 5, 10, 30, 50\}$,预期误差为0.05。

3.1.1 特征选择方法的对比实验

图5是根据实验1得到3种特征选择方法对SCN模型预测精度的拟合效果。可以看出,与单次特征选择方法即MI-SCN和PSO-SCN相比,本文MI-PSO-SCN方法对特征变量进行两次优化选择,有效删除了冗余和无关变量,使SCN预测模型对GOC和CO的浓度拟合效果均为最佳。

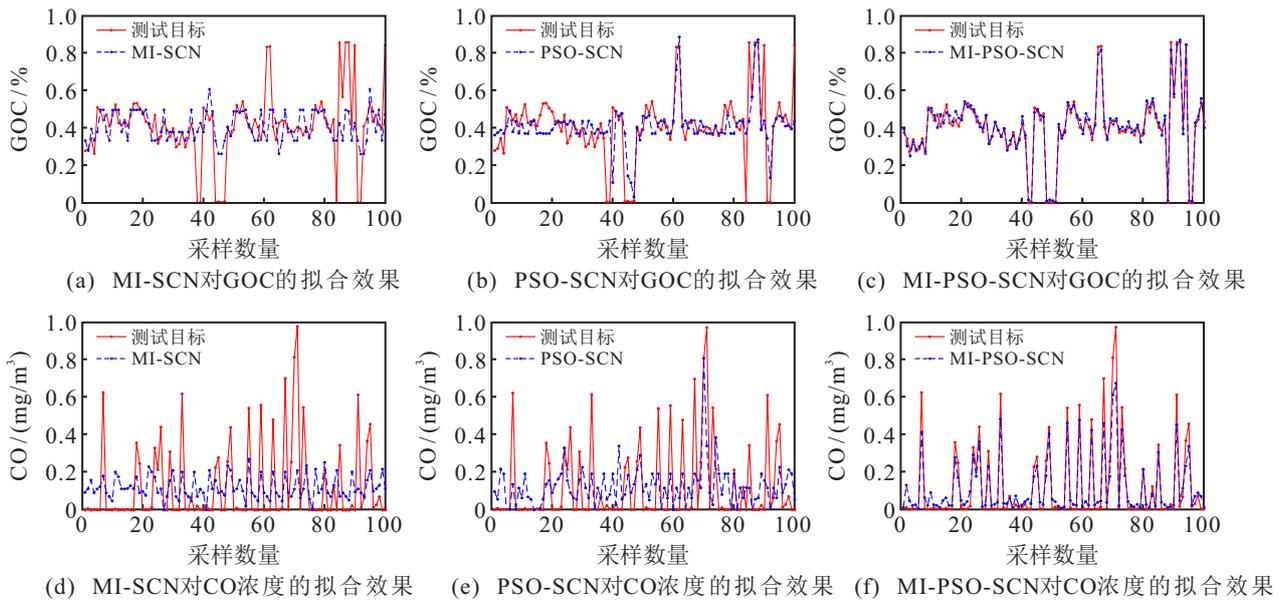


图5 SCN模型对GOC和CO浓度的拟合效果

表2是应用3种特征选择方法得到特征数量、训练集RMSE、测试集RMSE和训练时间的对比结果。PSO-SCN通过后续训练模型准确率评价特征,虽然可以去掉无关和冗余变量,但计算量大,效率低。MI方法与后续训练模型无关,效率高,但训练获得的模型精度低。本文将两者结合,弥补各自不足。从表2可知,MI-PSO-SCN降低了PSO-SCN的训练时间,但相对MI-SCN而言,由于加入PSO寻优,使MI-PSO-SCN的训练时间加长。从RMSE的结果看,MI-PSO-SCN得到的特征数量比MI-SCN显著减少,使SCN预测模型RMSE最小,当模型训练结束在线使用时不会

耗时过长。因此,所提MI-PSO-SCN方法能较好解决GOC和CO的浓度准确预测问题。

表2 3种特征选择方法对SCN模型性能的影响对比

工艺指标	方法	特征数量	训练集 RMSE	测试集 RMSE	训练时间/s
GOC	MI-SCN	17	3.1025	3.2305	13.36
	PSO-SCN	10	2.5689	2.6102	123.89
	MI-PSO-SCN	5	0.9171	0.9548	94.03
CO浓度	MI-SCN	21	4.3697	4.2371	19.84
	PSO-SCN	13	3.2643	3.1583	169.58
	MI-PSO-SCN	7	1.0957	1.0173	102.99

3.1.2 不同预测模型的对比实验

图6是根据实验2得到的3种预测模型的对比实

验.可以看出,与BP、RBF预测模型相比,SCN预测模型对GOC和CO的浓度拟合效果均为最佳.

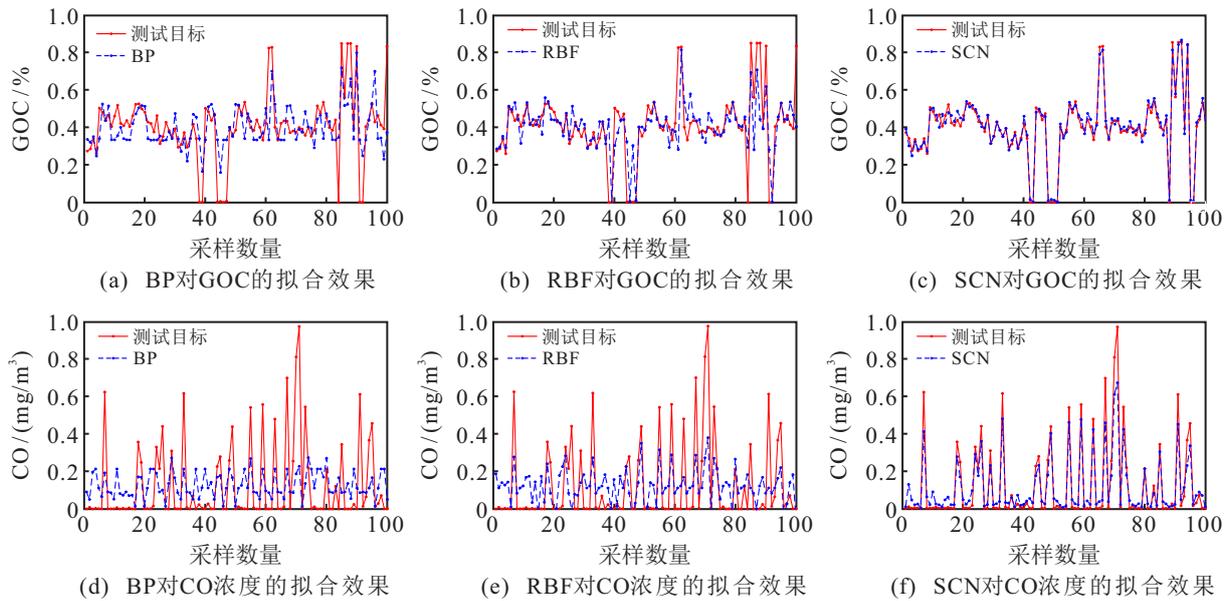


图6 3种模型对GOC和CO浓度的拟合效果

表3是3种模型对工艺指标预测时训练集RMSE、测试集RMSE和训练时间的对比结果.可以看出,SCN模型对GOC和CO浓度预测时的RSME均最小,训练时间均最短,这验证了文献[17]中指出的SCNs具有万能逼近性质和快速学习性能.因此,SCN模型能够更快速准确地预测GOC和CO的浓度.

表3 3种模型对工艺指标预测的结果对比

工艺指标	预测模型	训练集 RMSE	测试集 RMSE	训练时间/s
GOC	BP	2.6426	2.8514	187.6
	RBF	1.5847	1.7456	115.4
	SCN	0.9171	0.9548	94.03
CO浓度	BP	3.6754	3.3256	189.2
	RBF	2.1427	2.0126	133.9
	SCN	1.0123	1.0012	105.4

综合分析表明,本文提出的两步特征选择方法能够有效剔除无关和冗余变量,提高预测模型的精度,采用它训练出的SCN预测模型相比BP、RBF预测模型,具有更高精度和更快的学习速度.

3.2 设定方法实验

本部分设计两个实验考察设定方法的有效性.实验数据来自某垃圾焚烧发电厂200组历史数据.

实验3 智能补偿模型.将CBR单模型设定方法与智能优化设定方法进行对比,测试智能补偿模型的加入与否对二次风量设定值及工艺指标(GOC和CO浓度)的影响情况.

实验4 设定方法.将人工设定方法与智能优化设定方法进行对比,考察不同设定方法对二次风量设定值及工艺指标(GOC和CO浓度)的影响情况.

参数设置:采样周期 $T_s = 2 \text{ min}$,二次风量补偿最小阈值 $\lambda = 3$,GOC和CO的浓度波动阈值 $\xi = 5$,RBF神经网络自学习模糊推理选取3层网络结构,采用梯度下降法调整模型参数,学习率为0.02,训练次数为2000,模糊隶属度函数选取高斯函数.

3.2.1 智能补偿模型

图7是实验3得到的结果.可以看出,与CBR单模型设定相比,采用智能优化设定时的二次风量波动

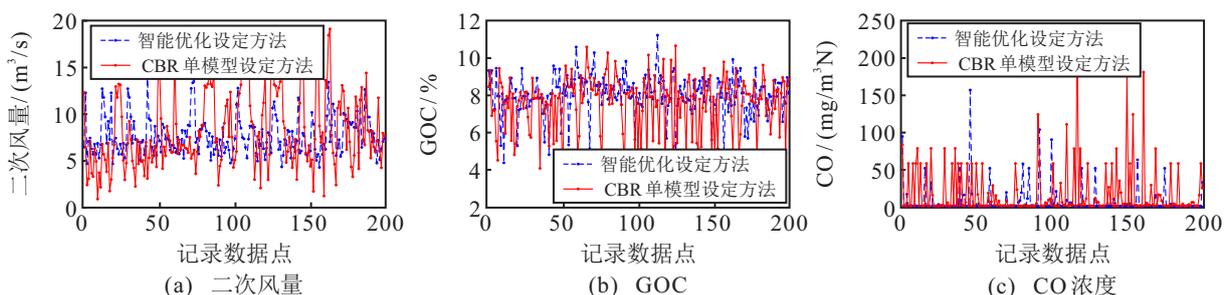


图7 CBR单模型设定方法与智能优化设定方法的效果对比

更小, GOC和CO的浓度不在式(2)约束条件的数据点更少. 将不在式(2)约束条件的数据点个数记为 a , 合格率(qualified rate, QR)计算如下:

$$QR = \frac{200 - a}{200} \times 100\% \quad (17)$$

经统计, 采用CBR单模型设定时, GOC和CO的浓度不在式(2)约束条件的数据点分别为42个和38个; 采用智能优化设定时, GOC和CO的浓度在式(2)约束条件的数据点分别为28个和18个. 通过式(17)计算可知, 采用CBR单模型时GOC和CO的浓度合

格率分别为79%和81%; 加入智能补偿模型后的合格率分别为86%和91%, 分别提高了7%和10%. 结果表明, 加入智能补偿模型后, 能够有效避免工况变化的扰动, 弥补CBR单模型设定方法的缺陷.

3.2.2 设定方法

图8是实验4得到的结果. 可以看出, 与人工设定方法相比, 采用本文智能优化设定方法得到的二次风量设定值波动程度更小, GOC和CO的浓度满足式(2)约束条件的数据点明显增加.

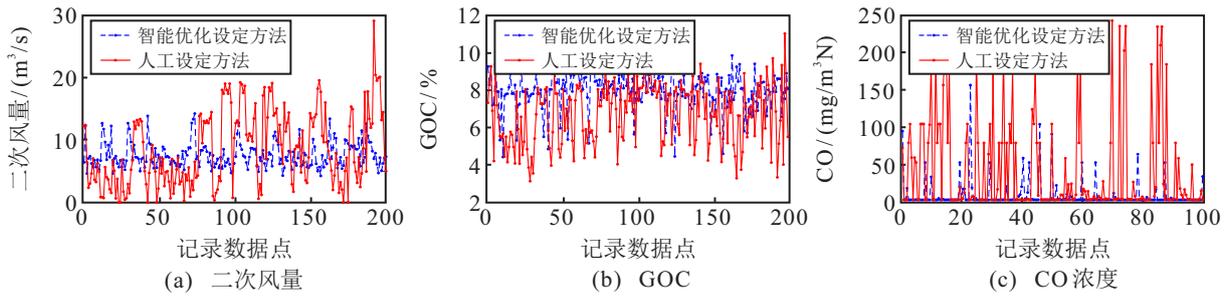


图8 人工设定方法与智能优化设定方法的效果对比

表4是应用人工设定方法与智能优化设定方法得到的二次风量波动最大偏差与标准差(反应波动离散程度)、GOC合格率和CO浓度合格率. 从表4可以看出, 与人工设定方法相比, 采用智能优化设定方法时, 二次风量波动最大偏差与标准差分别减小了14.42和3.19, GOC和CO浓度合格率分别提高了21%和23%. 结果表明, 采用智能优化设定方法得到的二次风量设定值焚烧时, 具有更好的效果.

表4 人工设定和本文智能优化设定的效果对比

评价指标	二次风量波动最大偏差	二次风量波动标准差	GOC合格率	CO浓度合格率
人工方法设定	29.10	5.97	0.65	0.68
智能优化设定	14.68	2.78	0.86	0.91

综上所述, 实验结果表明, 采用智能优化设定方法对二次风量进行设定时, 其波动程度更小、CO浓度更低. 该方法中4个模型为紧密联系的有机整体, 能够根据工况变化调整二次风量, 使焚烧产生的烟气在经过二燃室时达到高度湍流, 促进气态可燃物与氧气混合, 保证烟气稳定完全焚烧.

4 结论

为了获取焚烧过程二次风量的优化设定值, 本文研究了二次风量预设模型、工艺指标预测模型、智能补偿模型和设定值的评价与学习模型, 并将其有机集成, 提出了智能优化设定方法. 通过某焚烧厂的历史数据进行实验, 结果表明采用本文所提的智能优化设定方法具有良好的效果, 在网络规模设置上具有人

工干预少、随机参数范围自适应、泛化性好等优点, 能够满足工业要求, 具有一定的应用价值.

参考文献(References)

- [1] Li Y, Zhao X G, Li Y B, et al. Waste incineration industry and development policies in China[J]. Waste Management, 2015, 46(8): 234-241.
- [2] Hu Z F, Jiang E C, Ma X Q. Numerical simulation on NOX emissions in a municipal solid waste incinerator[J]. Journal of Cleaner Production, 2019, 233: 650-664.
- [3] Chan K T, Yu F W. Optimum setpoint of condensing temperature for air-cooled chillers[J]. HVAC&R Research, 2004, 10(2): 113-127.
- [4] Guerrero J, Guisasola A, Vilanova R. Improving the performance of a WWTP control system by model-based setpoint optimisation[J]. Environmental Modelling & Software, 2011, 26(4): 492-497.
- [5] Sun B, Gui W H, Wang Y L, et al. Intelligent optimal setting control of a cobalt removal process[J]. Journal of Process Control, 2014, 24(5): 586-599.
- [6] Ławryńczuk M. Online set-point optimisation cooperating with predictive control of a yeast fermentation process: A neural network approach[J]. Engineering Applications of Artificial Intelligence, 2011, 24(6): 968-982.
- [7] Wang W, Li H X, Zhang J T. A hybrid approach for supervisory control of furnace temperature[J]. Control Engineering Practice, 2003, 11(11): 1325-1334.
- [8] Wang J S, Ning C X, Yang Y. Rough set based

- operation pattern extraction and set-point optimization of electroslag remelting process[J]. ICIC Express Letters, Part B: Applications, 2014, 5(4): 1185-1191.
- [9] Zhang B C, Zhang Y, Hu G Y, et al. A method of automatically generating initial parameters for large-scale belief rule base[J]. Knowledge-Based Systems, 2020, 199: 105904.
- [10] Chai T Y, Zhao L, Qiu J B, et al. Integrated network-based model predictive control for setpoints compensation in industrial processes[J]. IEEE Transactions on Industrial Informatics, 2013, 9(1): 417-426.
- [11] 李中美, 黄梦哲, 桂卫华. 锑浮选过程加药量自适应迭代学习控制[J]. 控制理论与应用, 2020, 37(10): 2123-2133.
(Li Z M, Huang M Z, Gui W H. Adaptive iterative learning reagents control for antimony flotation process[J]. Control Theory & Applications, 2020, 37(10): 2123-2133.)
- [12] Xie S W, Xie Y F, Huang T W, et al. Multiobjective-based optimization and control for iron removal process under dynamic environment[J]. IEEE Transactions on Industrial Informatics, 2021, 17(1): 569-577.
- [13] Han H G, Zhang J C, Du S L, et al. Robust optimal control for anaerobic-anoxic-oxic reactors[J]. Science China Technological Sciences, 2021, 64(7): 1485-1499.
- [14] Ge Y N, Pan Y Z, Chen B. Intelligent controller design of the incinerator for domestic waste[J]. Measurement and Control Technology, 2008, 27(2): 89-94.
- [15] He G, Zhou C L, Luo T, et al. Online optimization of fluid catalytic cracking process via a hybrid model based on simplified structure-oriented lumping and case-based reasoning[J]. Industrial & Engineering Chemistry Research, 2021, 60(1): 412-424.
- [16] Cai H S, Zhang X Z, Zhang Y H, et al. A case-based reasoning model for depression based on three-electrode EEG data[J]. IEEE Transactions on Affective Computing, 2020, 11(3): 383-392.
- [17] Wang D H, Li M. Stochastic configuration networks: Fundamentals and algorithms[J]. IEEE Transactions on Cybernetics, 2017, 47(10): 3466-3479.
- [18] Gao W F. Class-specific mutual information variation for feature selection[J]. Pattern Recognition, 2018, 79: 328-339.
- [19] 丁晨曦, 严爱军. 城市生活垃圾热值的特征变量选择方法及预测建模[J]. 北京工业大学学报, 2021, 47(8): 874-885.
(Ding C X, Yan A J. Characteristic variable selection method and predictive modeling for municipal solid waste heat value[J]. Journal of Beijing University of Technology, 2021, 47(8): 874-885.)
- [20] Pani A K, Mohanta H K. Online monitoring of cement clinker quality using multivariate statistics and Takagi-Sugeno fuzzy-inference technique[J]. Control Engineering Practice, 2016, 57: 1-17.
- [21] 田福庆, 姜尚, 梁伟阁. 含齿隙弹载舵机的全局反步模糊自适应控制[J]. 自动化学报, 2019, 45(6): 1177-1185.
(Tian F Q, Jiang S, Liang W G. Global backstepping fuzzy adaptive control for ammunition actuator with backlash[J]. Acta Automatica Sinica, 2019, 45(6): 1177-1185.)

作者简介

丁晨曦(1991—), 女, 博士生, 从事过程建模与优化控制的研究, Email: dingcx@emails.bjut.edu.cn;

严爱军(1970—), 男, 教授, 博士生导师, 从事过程建模与控制、人工智能及应用等研究, E-mail: yanaijun@bjut.edu.cn;

王殿辉(1962—), 男, 教授, 博士生导师, 从事工业大数据的机器学习理论及应用等研究, E-mail: dh.wang@deepscn.com.