



基于多目标粒子群算法的城市固废焚烧过程智能操作优化

蒙西 侯启正 乔俊飞

Intelligent Operational Optimization of Municipal Solid Waste Incineration Process Based on Multi-objective Particle Swarm Algorithm

MENG Xi, HOU Qi-Zheng, QIAO Jun-Fei

在线阅读 View online: <https://doi.org/10.16383/j.aas.c240044>

您可能感兴趣的其他文章

面向城市固废焚烧过程的二英排放浓度检测方法综述

Dioxin Emission Concentration Measurement Approaches for Municipal Solid Wastes Incineration Process: A Survey

自动化学报. 2020, 46(6): 1063–1089 <https://doi.org/10.16383/j.aas.c190005>

一种基于自适应模糊支配的高维多目标粒子群算法

Many-objective Particle Swarm Optimization Based on Adaptive Fuzzy Dominance

自动化学报. 2018, 44(12): 2278–2289 <https://doi.org/10.16383/j.aas.2018.c170573>

城市污水处理过程动态多目标智能优化控制研究

Research on Dynamic Multiobjective Intelligent Optimal Control for Municipal Wastewater Treatment Process

自动化学报. 2021, 47(3): 620–629 <https://doi.org/10.16383/j.aas.c190154>

数据和知识驱动的城市污水处理过程多目标优化控制

Data-knowledge Driven Multiobjective Optimal Control for Municipal Wastewater Treatment Process

自动化学报. 2021, 47(11): 2538–2546 <https://doi.org/10.16383/j.aas.c210098>

基于参考点预测的动态多目标优化算法

Dynamic Multi-objective Optimization Algorithm Based on Reference Point Prediction

自动化学报. 2017, 43(2): 313–320 <https://doi.org/10.16383/j.aas.2017.c150811>

城市污水处理过程优化设定方法研究进展

Perspectives on Optimal Setting Methods for Municipal Wastewater Treatment Processes

自动化学报. 2020, 46(10): 2092–2108 <https://doi.org/10.16383/j.aas.c200294>

基于多目标粒子群算法的城市固废焚烧过程智能操作优化

蒙西^{1,2,3} 侯启正^{1,2,3} 乔俊飞^{1,2,3}

摘要 城市固废焚烧 (Municipal solid waste incineration, MSWI) 技术因兼具减量化、无害化、资源化等特点, 已成为治理固废污染的主要方式。由于城市固废成分复杂, 含水率、热值动态波动, 固废燃烧、余热利用、烟气净化等环节耦合冲突, 实际工业过程难以高效运行。为此, 本文提出了一种基于多目标粒子群算法的城市固废焚烧过程智能操作优化方法, 以期实现燃烧效率和烟气净化效率的协同优化。首先, 设计自组织径向基函数 (Self-organizing radial basis function, SORBF) 神经网络建立运行指标模型, 实现城市固废焚烧过程运行性能的在线评价; 其次, 引入区域拥挤度指标提出了一种改进的多目标粒子群优化算法, 以获取操作变量的 Pareto 解集; 然后, 利用熵权法确定操作变量最佳设定值, 实现城市固废焚烧过程高效运行; 最后, 通过北京某城市固废焚烧厂的实际运行数据对所提方法进行验证, 实验结果表明基于多目标粒子群算法的智能操作优化方法可以实现燃烧效率与脱硝效率的协同提升。

关键词 城市固废焚烧过程, 燃烧效率, NO_x 排放, 运行指标模型, 多目标粒子群算法

引用格式 蒙西, 侯启正, 乔俊飞. 基于多目标粒子群算法的城市固废焚烧过程智能操作优化. 自动化学报, 2024, 50(12): 2462-2473

DOI 10.16383/j.aas.c240044 **CSTR** 32138.14.j.aas.c240044

Intelligent Operational Optimization of Municipal Solid Waste Incineration Process Based on Multi-objective Particle Swarm Algorithm

MENG Xi^{1,2,3} HOU Qi-Zheng^{1,2,3} QIAO Jun-Fei^{1,2,3}

Abstract Municipal solid waste incineration (MSWI) technology has become the main way to address solid waste pollution due to its characteristics of reduction, harmlessness, and resource utilization. However, it is difficult for actual industries to operate efficiently due to the complex composition of municipal solid waste, dynamic fluctuations in moisture content and calorific value, coupling conflicts in solid waste combustion, waste heat utilization and flue gas purification. To enhance combustion efficiency and flue gas purification efficiency, this paper proposes an intelligent operational optimization method of MSWI process based on multi-objective particle swarm algorithm. First, operational index models are established by designing self-organizing radial basis function (SORBF) neural networks to achieve online evaluation of operational performance in MSWI process. Second, an improved multi-objective particle swarm optimization algorithm is presented by incorporating regional congestion degree index to obtain the Pareto solutions of operating variables. Then, the entropy weight method is employed to determine the optimal set value of operating variables, achieving efficient operation of MSWI process. Finally, the proposed method is verified through actual operational data from a MSWI plant in Beijing, and the experimental results demonstrate that the intelligent operational optimization method based on multi-objective particle swarm algorithm can improve combustion efficiency and reduce nitrogen oxide emissions.

Key words Municipal solid waste incineration (MSWI) process, combustion efficiency, NO_x emissions, operational index model, multi-objective particle swarm algorithm

Citation Meng Xi, Hou Qi-Zheng, Qiao Jun-Fei. Intelligent operational optimization of municipal solid waste incineration process based on multi-objective particle swarm algorithm. *Acta Automatica Sinica*, 2024, 50(12): 2462-2473

收稿日期 2024-01-17 录用日期 2024-05-16

Manuscript received January 17, 2024; accepted May 16, 2024

国家自然科学基金 (62273013, 62021003), 北京市科技新星计划 (20230484310), 科技创新 2030“新一代人工智能”重大项目 (2021ZD0112301) 资助

Supported by National Natural Science Foundation of China (62273013, 62021003), Beijing Nova Program (20230484310), and the National Key Research and Development Project of China (2021ZD0112301)

本文责任编辑 李鸿一

Recommended by Associate Editor LI Hong-Yi

1. 北京工业大学信息学部 北京 100124 2. 智慧环保北京实验室 北京 100124 3. 智能感知与自主控制教育部工程研究中心 北

城市固废 (Municipal solid waste, MSW), 又称生活垃圾, 是指在日常生活或为日常生活提供服务时产生的固体废弃物。随着人口增长和经济发展, 城市固废产生量与日俱增。据世界银行预测, 2050 京 100124

1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124 2. Beijing Laboratory of Smart Environmental Protection, Beijing 100124 3. Engineering Research Center of Intelligent Perception and Autonomous Control, Ministry of Education, Beijing 100124

年全球城市固废将达到 34 亿吨, 固废污染已成为世界各国共同面临的环境问题^[1]. 堆肥、填埋、焚烧是处理城市固废的三种方式. 其中, 城市固废焚烧 (Municipal solid waste incineration, MSWI) 在高温富氧环境下, 通过热解、燃烧将有机物转化为无机物, 可以实现固体废弃物减容减量的同时回收部分热能. 因其具有无害化、减量化和资源化等优势, 已成为国内外治理固废污染的主流方式^[2]. 自上世纪 90 年代, 我国开始陆续引进焚烧技术. 尽管起步晚, 但发展迅速, 目前我国城市固废焚烧工艺技术、设备已达到国际先进水平. 然而, 由于我国城市固废成分复杂, 含水率、热值随季节、区域动态波动, 实际运行调控仍以人工操作为主, 自动化水平较低. 以人工经验为主的操作难以保证高效、稳定运行, 固废燃烧不充分、烟气排放超标等问题时有发生. 以固废燃烧和氮氧化物 (Nitrogen oxides, NO_x) 脱除为例, 为了确保固废充分燃烧, 通常会在实际运行中提高燃烧温度、增加氧气供应量、延长停留时间. 这些操作又会促使氮气与氧气反应生成 NO_x, 从而导致 NO_x 排放增加. 因此, MSWI 过程的操作优化问题也成为学术界和工业界共同关注的难点问题.

明晰 MSWI 过程演化规律, 能为寻找最佳操作方式、实现优化运行提供突破口^[3-5]. 因此, 部分学者聚焦于 MSWI 过程建模研究, 旨在获取不同操作设定下 MSWI 系统的演化规律, 进而确定最佳操作方式. 在分析焚烧炉中固相与气相特性的基础上, Liang 等^[6] 建立了 MSWI 过程仿真模型, 探索了不同炉排速度及氧含量设定对固废燃烧和 NO_x 排放的影响, 进而给出最佳操作方式. 文献 [7] 模拟了焚烧炉中固体废物床内燃烧、气体挥发物床外燃烧以及选择性非催化还原 (Selectivenon-catalytic reduction, SNCR) 等过程, 通过分析不同喷射位置、喷射速度对 SNCR 性能的影响, 实现了 MSWI 脱硝过程操作优化. 基于计算流体动力学 (Computational fluid dynamics, CFD) 方法, Hu 等^[8] 模拟了移动炉排焚烧炉中固废燃烧与 SNCR 过程, 获取了还原剂最佳喷射位置、喷射速度以及喷射比. 针对某座固废日处理量为 350 吨的城市固废焚烧厂, 文献 [9] 结合多种子过程模型求解质量、动量、能量和物质的控制方程对固体废物与床外燃烧过程进行仿真模拟, 研究了不同送风方式对 NO_x 去除性能的影响, 结果表明合适的配风操作能显著减少 NO_x 排放. Huai 等^[10] 构建了一种模拟往复式焚烧炉中固体废物和炉膛上方气相燃烧的数学模型, 获取炉内燃烧特性, 分析了床层厚度、过量空气系数、二次风等对固废燃烧状态的影响, 最后给出了最佳操作方式. 然而, MSWI 反应机理复杂, 运行工况多变, 仅通过

演化规律探求最佳操作策略难以遍历所有情况, 无法保证实际工业过程的稳定和优化运行.

随着智能计算的快速发展, 智能优化算法被用于解决复杂工业过程优化问题, 并取得了一定成效^[11-14]. 因此, 相关学者将智能优化算法用于 MSWI 过程操作优化研究中. 在对某 MSWI 发电厂进行热力学和经济评估的基础上, Huang 等^[15] 利用遗传算法对汽轮机进气温度、压力比等变量优化设定, 可以在提高能源转化效率的同时降低运行成本. Costa 等^[16] 建立了焚烧炉燃烧室三维 CFD 模型, 然后采用多目标遗传算法对二次风量和耐火墙传热系数进行优化设定, 减少了 NO_x 和二噁英的排放. 相较于遗传算法, 非优势排序遗传算法 II (Non-dominant sorting genetic algorithm II, NSGA-II) 因引入了非支配排序、精英策略等, 更具优化求解能力和鲁棒性^[17-18]. 文献 [19] 从能源转化、运行成本与环境效益三方面对某 MSWI 发电厂进行综合评估, 选取汽轮机入口温度、进口压力、出口温度等重要参数作为决策变量, 并应用 NSGA-II 对其进行优化设定, 以提高能源转化率、降低运行成本. 由于 MSWI 过程优化目标与约束条件众多, 其优化问题具有较大的解空间. 相比通过寻找演化规律确定操作设定的方法, 引入智能优化算法可以在解空间中广泛搜索, 更高效地找到最优或接近最优的解决方案. 然而, 上述研究仍建立在机理建模表征 MSWI 过程的基础上, 存在因假设过多导致模型适应度下降, 进而影响后续优化设定精准度的问题. 海量数据的获取使得数据驱动的建模方法成为解决复杂工业问题的有效途径, 支持向量机、神经网络等被用于复杂工业过程中^[20-21]. 为实现 MSWI 过程优化运行, 部分学者将数据驱动建模方法与智能优化算法相结合. 例如, Anderson 等^[22] 利用径向基函数神经网络建立运行指标模型, 然后采用多目标遗传算法搜索最佳的固废进料率和停留时间, 在满足温度约束的前提下实现了固废进料率最大化和未燃烧碳最小化. 相比遗传算法, 粒子群优化 (Particle swarm optimization, PSO) 算法在进化过程中仅通过当前搜索过程中的最优解共享信息, 具有较快的收敛速度, 也被用于 MSWI 过程操作优化研究中. 为提高燃烧效率并降低 NO_x 排放, 文献 [23] 利用前馈神经网络建立 MSWI 过程运行指标模型, 然后设计分阶段多目标粒子群算法获取一次风及二次风流量的最终设定值. Sun 等^[24] 在利用模糊神经网络建立运行指标模型的基础上, 采用自适应突变粒子群算法, 获取烟气氧含量最优设定值, 实现了燃烧效率和脱硝效率协同提升. 综上所述, 如何建立准确的 MSWI 过程运行指标模型、设计高效的优化算法、获取操作变量最优设定值是当前研究 MSWI 过程优化运

行所面临的挑战。

针对上述问题, 本文提出一种基于多目标粒子群算法的 MSWI 过程智能操作优化方法, 主要工作如下:

1) 设计了一种自组织径向基函数神经网络用于构建运行指标模型, 实现对 MSWI 过程运行性能的在线评价, 为后续寻优设定提供精准指导。

2) 提出了一种改进的多目标粒子群优化算法, 引入区域拥挤度指标构建全局最优粒子候选组, 提高种群搜索性能, 获取 MSWI 过程中操作变量的 Pareto 解集。

3) 利用熵权法选取操作变量最优设定值, 实现了 MSWI 过程中燃烧效率与脱硝效率的协同提升。

1 MSWI 过程优化问题描述

1.1 MSWI 过程简介

以北京某城市固废焚烧厂为例, MSWI 过程主要包括固废堆酵、固废燃烧、余热利用、烟气净化 4 个工艺环节。首先, 为降低固废含水率, 提高入炉热值, 城市固废在固废池中经过 5 ~ 7 天的发酵。然后, 经过发酵充分的固废通过进料器运送至焚烧炉内, 经历干燥、燃烧和燃烬三个阶段。在干燥段, 固废在高温环境下完成水分蒸发, 并析出挥发分, 达到着火点。在燃烧段, 挥发分与氧气发生剧烈的气相燃烧反应, 产生高温烟气、释放热量, 同时固定碳进行固相燃烧反应。经燃烧段的固废进入燃烬段, 确保残余固废完全燃烬, 并排出焚烧后产生的灰渣。随后, 焚烧炉内的高温烟气进入余热锅炉进行换热冷却, 产生高温蒸汽以驱动汽轮机作业, 将热能转换为电能^[25]。最后, 为防止二次污染, 利用脱酸塔、布袋除尘器、选择性催化还原 (Selective catalytic reduction, SCR) 系统等装置去除烟气中的氯化氢 (Hydrogen chloride, HCl)、二氧化硫 (Sulfur dioxide, SO₂) 及 NO_x 等污染物, 完成烟气净化处理, 实现污染物排放达标。

为保证焚烧过程中固废的充分燃烧, 通常会在实际操作中提高炉内含氧量与温度。然而, 过高的温度与氧气供应, 又会促进氮气与氧气反应, 生成 NO_x, 导致烟气污染排放增多。因此, 仅凭人工经验的调控难以实现在固废充分燃烧的同时降低 NO_x 排放。作为 MSWI 过程中两个重要的操作变量, 一次风和二次风对炉内温度及含氧量有较大的影响。从炉膛下方通入的一次风可以提供足够的氧气支持固废初期燃烧, 推动固废在高温条件下达到着火点。从炉膛上部引入的二次风, 除了提供额外的氧气支持挥发分的完全燃烧外, 还有助于调节炉温, 避免炉体损坏和减少污染物的产生。此外, 焚烧炉的炉

排速度也是一个重要的操作参数。在燃烧过程中, 炉排的机械运动可以翻转搅拌固废, 使其充分接触空气, 进而提高燃烧效率。综上所述, 通过对炉排速度、一次风和二次风等操作变量精准设定, 可以达到理想的燃烧效果并控制 NO_x 排放。

1.2 MSWI 过程操作优化问题描述

结合第 1.1 节过程分析, 本文所研究 MSWI 过程操作优化的目标是在确保固废燃烧充分的前提下, 降低 NO_x 排放, 可以将其描述为:

$$\begin{aligned} \min \mathbf{F} &= [-f_1(\mathbf{x}), f_2(\mathbf{x})] \\ \mathbf{x} &= [x_1, x_2, x_3, x_4] \\ \text{s.t. } LB_d &\leq x_d \leq UB_d \end{aligned} \quad (1)$$

其中, $f_1(\mathbf{x})$ 代表燃烧效率; $f_2(\mathbf{x})$ 代表 NO_x 排放浓度; x_1, x_2, x_3, x_4 分别表示炉排速度、一次风入口流量、一次风出口压力、二次风入口流量。同时考虑到系统运行的稳定性与实际工业情况, 对操作变量设置调节范围, LB_d 表示第 d 个变量的调节下限, UB_d 表示调节上限。由于一氧化碳是固废燃烧不完全的主要产物, 因此, 可基于一氧化碳 (Carbonic oxide, CO) 和二氧化碳 (Carbon dioxide, CO₂) 浓度衡量燃烧效率 (Combustion efficiency, CE)^[26]:

$$CE = \frac{C_{CO_2}}{C_{CO_2} + C_{CO}} \times 100\% \quad (2)$$

其中, C_{CO} 为一氧化碳浓度, C_{CO_2} 为二氧化碳浓度。

然而, 由于 MSWI 过程具有多变量、非线性、强耦合等复杂特性, 实现 MSWI 过程优化运行具有以下难点:

1) 难以建立评价 MSWI 过程运行性能的指标模型。MSWI 过程是一个典型的非线性过程, 如何在线评价其运行性能存在一定困难。

2) 难以设计高效的优化算法。MSWI 过程中涉及多个优化目标与操作变量, 需设计高效优化算法寻找多个操作变量的设定组合。

3) 难以确定最佳操作变量设定值。为实现 MSWI 过程高效运行, 需选取一组最优操作变量设定值, 以实现多个目标的协同提升。

为解决上述问题, 本文通过建立运行指标模型、设计高效优化算法、选取最优操作变量设定值, 以实现 MSWI 过程的优化运行。

2 基于多目标粒子群算法的 MSWI 过程智能操作优化

本文提出了一种基于多目标粒子群算法的 MSWI 过程智能操作优化方法, 对炉排速度、一次风入口

流量/出口压力、二次风入口流量四个操作变量进行优化设定, 以实现 MSWI 过程中燃烧效率与脱硝效率的协同提升, 具体流程如图 1 所示. 首先, 结合误差补偿算法与改进二阶学习算法设计了一种自组织径向基函数 (Self-organizing radial basis function, SORBF) 神经网络, 并建立了基于 SORBF 神经网络的运行指标模型; 然后, 将运行指标模型作为评价函数, 引入区域拥挤度指标改进多目标粒子群算法, 获取操作变量的 Pareto 解集; 最后, 利用熵权法确定操作变量的最优设定值.

2.1 基于 SORBF 神经网络的运行指标模型构建

2.1.1 RBF 神经网络

径向基函数 (Radial basis function, RBF) 神经网络因具有良好的非线性映射能力, 已被广泛用于复杂工业过程建模中^[27-30].

图 2 为 RBF 神经网络的结构, 由输入层、隐藏层、输出层构成, 网络输出可以描述为:

$$\hat{y} = \sum_{j=1}^J w_j \Phi_j(\mathbf{x}) \quad (3)$$

式中, \hat{y} 为 RBF 神经网络的输出, \mathbf{x} 表示模型的输入向量, w_j 为第 j 个隐藏层神经元的连接权值, Φ_j 为第 j 个隐藏层神经元的激活函数, 表达式如下所示:

$$\Phi_j(\mathbf{x}) = e^{-\frac{|\mathbf{x}-\mathbf{c}_j|^2}{\sigma_j^2}} \quad (4)$$

式中, \mathbf{c}_j 为第 j 个隐节点的中心向量, σ_j 为第 j 个隐藏层神经元的宽度值.

网络结构与参数是影响 RBF 神经网络性能的主要因素. 为此, 本文设计了一种 SORBF 神经网络, 通过新增隐藏层神经元补偿学习过程中最大误差以提高网络学习精度. 然后, 采用改进二阶算法对网络参数进行调整, 能够在保证学习精度的同时加快收敛速度. 所设计的 SORBF 神经网络具有精简的结构、良好的泛化性能, 采用 SORBF 神经网络建立运行指标模型, 可以实现 MSWI 过程运行性能在线评价, 为后续操作变量优化设定提供精准指导. SORBF 神经网络构建过程具体如下:

2.1.2 网络结构设计

初始时刻, 隐藏层中神经元个数为 0. 当所有训练样本进入网络后, 寻找期望输出绝对值最大的训练样本 k_1 .

$$k_1 = \arg \max \left\{ |y_1|, |y_2|, \dots, |y_p|, \dots, |y_P| \right\} \quad (5)$$

式中, P 代表训练样本的个数, y_p 表示第 p 个样本的期望输出.

然后, 基于训练样本 k_1 新增第一个神经元, 初

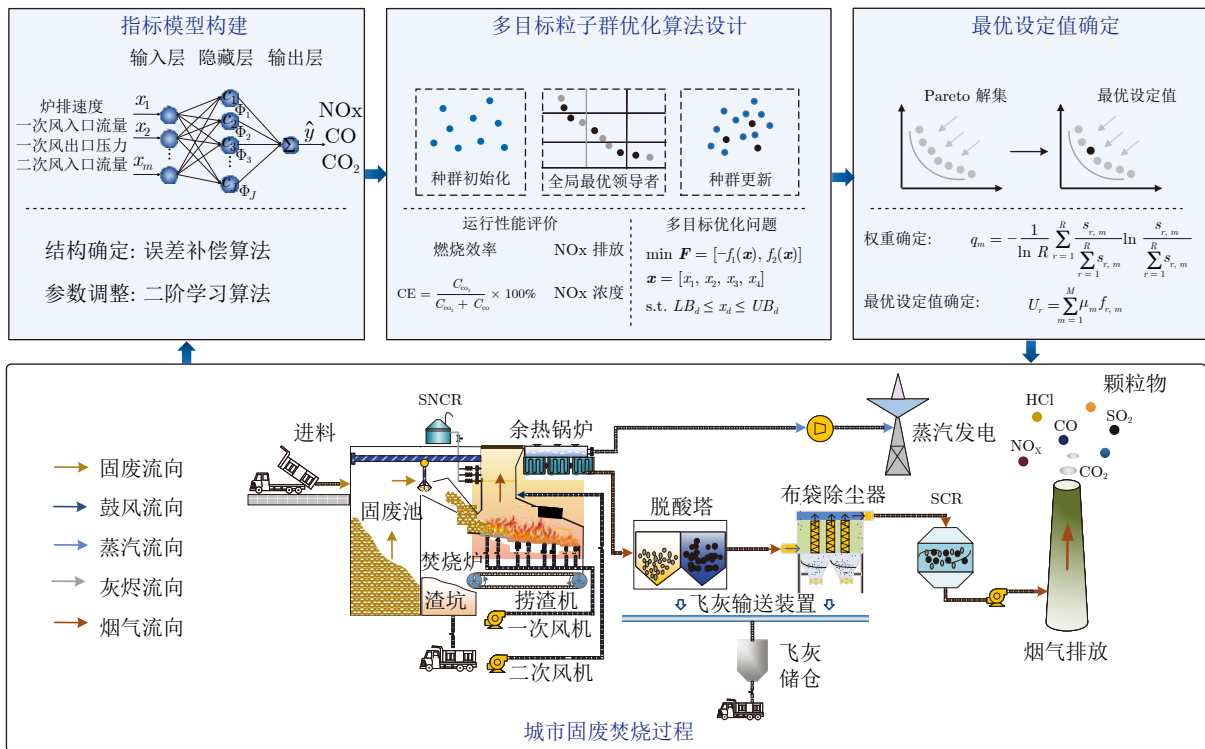


图 1 城市固废焚烧过程智能操作优化方法框架

Fig.1 The framework for intelligent operational optimization method of municipal solid waste incineration process




图 2 RBF 神经网络结构

Fig.2 RBF neural network structure

始参数设置如下:

$$\mathbf{c}_1 = \mathbf{x}_{k_1} \quad (6)$$

$$w_1 = y_{k_1} \quad (7)$$

$$\sigma_1 = 1 \quad (8)$$

式中, \mathbf{c}_1 , w_1 和 σ_1 分别为第一个隐藏层神经元的中心向量、权值以及宽度, \mathbf{x}_{k_1} 和 y_{k_1} 分别为样本 k_1 的输入向量和期望输出。

t 时刻, 对于所有的训练样本, 计算当前误差向量:

$$\mathbf{e}(t) = [e_1(t), e_2(t), \dots, e_p(t), \dots, e_P(t)]^T \quad (9)$$

式中, P 是训练样本个数. 第 p 个样本的误差 $e_p(t)$ 为第 p 个样本的期望输出 y_p 与 t 时刻实际输出 $\hat{y}_p(t)$ 的差值。

$$e_p(t) = y_p - \hat{y}_p(t) \quad (10)$$

寻找当前误差向量峰值点:

$$l = \operatorname{argmax} \|\mathbf{e}(t)\| \quad (11)$$

第 l 个样本绝对误差最大, 表示当前所建网络对该样本学习能力不足. 因此, 需要新增一个隐藏层神经元对该样本进行学习, 以提高网络学习能力, 新增神经元的初始中心、连接权值设置如下:

$$\mathbf{c}_t = \mathbf{x}_l \quad (12)$$

$$w_t = y_l \quad (13)$$

式中, \mathbf{x}_l 和 y_l 分别为样本 l 的输入向量和期望输出。

RBF 神经元的宽度参数表示其径向作用范围. 若宽度过小, 则作用范围较小; 宽度过大, 相邻神经元会产生相同作用, 导致网络结构冗余. 因此, 宽度的设置至关重要. 新增神经元后, 寻找与当前神经元距离最近的神经元, 采用欧氏距离进行计算:

$$\mathbf{c}_{\min} = \operatorname{argmin} \{dist(\mathbf{c}_t, \mathbf{c}_{j \neq t})\} \quad (14)$$

式中, $dist$ 表示计算 \mathbf{c}_t 与 $\mathbf{c}_{j \neq t}$ 之间的欧氏距离。

然后, 基于 \mathbf{c}_{\min} 对新增神经元的初始宽度进行设置:

$$\sigma_t = \alpha \|\mathbf{c}_t - \mathbf{c}_{\min}\| \quad (15)$$

在实验过程中, 通过调节 α 可以保证神经元的作用范围并避免结构上的冗余。

2.1.3 网络参数更新

每新增一个神经元并完成初始参数设置后, 使用二阶算法对网络参数进行调整, 调整规则如下:

$$\Psi(\eta + 1) = \Psi(\eta) - (\mathbf{H}(\eta) + \lambda \mathbf{I}(\eta))^{-1} \Omega(\eta) \quad (16)$$

式中, η 为参数调整的迭代步数, \mathbf{H} 为类海森矩阵, λ 为学习率, \mathbf{I} 表示单位矩阵, Ω 为梯度向量, Ψ 指代所有需要调整的网络参数:

$$\Psi(\eta) = [c_j(\eta), \sigma_j(\eta), w_j(\eta)] \quad (17)$$

式中, c_j , σ_j , w_j 分别表示第 j 个隐藏层神经元在第 η 次迭代时的中心向量、宽度及连接权值。

为了降低计算复杂度, 将类海森矩阵 \mathbf{H} 转化为 p 个类海森子矩阵 \mathbf{h} 的和, 将梯度向量 Ω 转换为 p 个梯度子向量 \mathbf{g} 的和, 如下所示:

$$\mathbf{H}(\eta) = \sum_{p=1}^P \mathbf{h}_p(\eta) \quad (18)$$

$$\Omega(\eta) = \sum_{p=1}^P \mathbf{g}_p(\eta) \quad (19)$$

在对网络参数进行第 η 次调整时, 第 p 个类海森子矩阵 \mathbf{h} 和梯度子向量 \mathbf{g} 计算如下:

$$\mathbf{h}_p(\eta) = \mathbf{j}_p^T(\eta) \mathbf{j}_p(\eta) \quad (20)$$

$$\mathbf{g}_p(\eta) = \mathbf{j}_p^T(\eta) e_p(\eta) \quad (21)$$

式中, $e_p(\eta)$ 为第 p 个样本在第 η 次调整时的期望输出 y_p 与网络输出 $\hat{y}_p(\eta)$ 的差值, $\mathbf{j}_p(\eta)$ 为雅可比向量, 计算如下:

$$e_p(\eta) = y_p - \hat{y}_p(\eta) \quad (22)$$

$$\mathbf{j}_p(\eta) = \left[\frac{\partial e_p(\eta)}{\partial c_j(\eta)}, \dots, \frac{\partial e_p(\eta)}{\partial \sigma_j(\eta)}, \dots, \frac{\partial e_p(\eta)}{\partial w_j(\eta)}, \dots \right] \quad (23)$$

当达到预设最大结构或期望学习精度时, SO-RBF 神经网络构建完成. 采用均方误差 (Mean square error, MSE) 评价网络学习精度, 计算如下:

$$\text{MSE} = \frac{1}{P} \sum_{p=1}^P (y_p - \hat{y}_p)^2 \quad (24)$$

2.2 基于 MOPSO-RC 算法的操作优化设定

2.2.1 多目标粒子群优化算法

在单目标优化问题中, 最优解只有一个, 通常可以用较为简单的优化方法求出. 然而在多目标优化问题中, 各个目标之间相互制约, 一个目标性能的提升往往以损失其他目标性能为代价, 不存在使所有目标性能都达到最优的解. 因此, 解决多目标优化问题的本质是寻找一组非劣解的集合——Pareto 解集.

多目标粒子群优化 (Multi-objective particle swarm optimization, MOPSO) 算法通过模拟粒子在搜索空间中的移动和相互影响不断调整粒子的速度和位置, 使它们在搜索空间中广泛探索, 寻找 Pareto 最优. 搜索过程中, 粒子有两个“领导者”, 一个是种群搜索到的全局最优解 $g_{i,d}(it)$, 一个是粒子个体的历史最优解 $p_{i,d}(it)$, 更新策略如下:

$$\begin{cases} v_{i,d}(it+1) = \omega v_{i,d}(it) + c_1 r_1 (p_{i,d}(it) - z_{i,d}(it)) + c_2 r_2 (g_{i,d}(it) - z_{i,d}(it)) \\ z_{i,d}(it+1) = z_{i,d}(it) + v_{i,d}(it+1) \end{cases} \quad (25)$$

式中, $v_{i,d}(it)$ 和 $v_{i,d}(it+1)$ 分别是粒子 i 在第 it 次和第 $it+1$ 次迭代时的速度; r_1, r_2 是 $0 \sim 1$ 之间的随机数; ω 表示惯性权重; c_1, c_2 为学习因子; $z_{i,d}(it)$ 和 $z_{i,d}(it+1)$ 表示粒子 i 在第 it 次和第 $it+1$ 次迭代时的位置.

传统的 MOPSO 存在易陷入局部最优的缺陷. 为实现 MSWI 过程优化运行, 本文设计了一种基于区域拥挤度的多目标粒子群优化算法 (Multi-objective particle swarm optimization algorithm based on regional congestion degree, MOPSO-RC), 以获取操作变量的 Pareto 解集. 算法流程如图 3 所示. MOPSO-RC 算法设计如第 2.2.2 节.

2.2.2 初始化种群策略

一般情况下, 群智能优化算法以随机方式产生初始化种群, 但这种方式可能导致种群内个体分布不均匀, 影响演化算法寻找全局最优的进程, 进而降低最终解的准确度. 为此, 本文采用拉丁超立方体抽样方法产生初始化种群, 保证粒子在全空间填充, 使种群个体分布均匀. 然后, 基于上述指标模型评估粒子适应度值, 并建立外部档案库保存非支配解.

2.2.3 全局最优粒子选择

传统 MOPSO 算法中种群在每次更新过程中, 全局最优领导者只有一个. 为充分使用种群中粒子的信息, 提高种群在搜索过程中的多样性, MOPSO-RC 在每次更新后依据非支配解在目标空间的分布

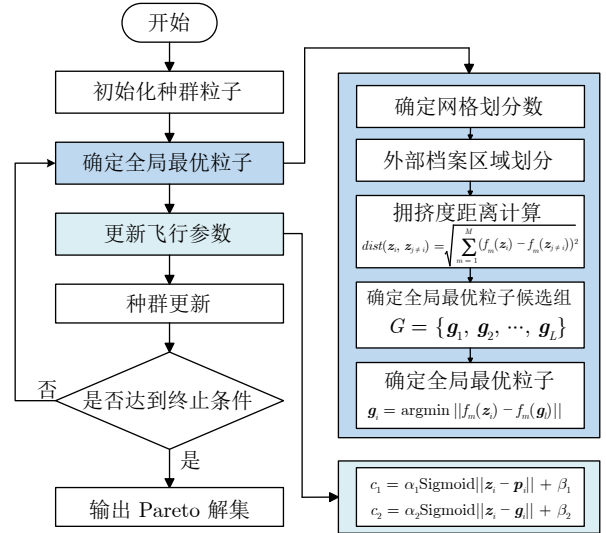


图 3 MOPSO-RC 算法流程图

Fig. 3 The flowchart of MOPSO-RC algorithm

区域与拥挤度距离构建全局最优粒子候选组, 以供种群中的粒子在更新过程中进行选择. 全局最优粒子候选组的构建方法如下:

首先, 对外部档案进行区域划分. 考虑到非支配粒子的分布区域不同, 为了能在后续更新过程中较为均衡地分配搜索资源, 对外部档案库在目标空间上进行 $N_{it} \times N_{it}$ 划分, 并赋予各个子区域相应索引. 同时, 为加快收敛速度, 区域划分数 N_{it} 随着迭代次数 it 的增加逐渐减小.

$$N_{it} = n - \varepsilon \cdot \left[\frac{\eta \cdot it}{it_{\max}} \right] \quad (26)$$

式中, n 为单维空间上的初始划分数, it_{\max} 表示最大迭代次数, ε 与 η 为调节系数, $[\cdot]$ 表示取整运算.

然后, 在外部档案中, 计算非支配粒子 i 与其余非支配粒子间的距离:

$$dist(z_i, z_{j \neq i}) = \sqrt{\sum_{m=1}^M (f_m(z_i) - f_m(z_{j \neq i}))^2} \quad (27)$$

式中, $f_m(z_i)$ 表示非支配粒子 i 的第 m 个优化目标值, M 为优化目标个数. 对其进行排序后, 选出距离该粒子最近的 Q 个粒子, 并计算距离均值作为该非支配粒子的拥挤度距离 CD_i :

$$CD_i = \frac{1}{Q} \sum_{q=1}^Q dist(z_i, z_q) \quad (28)$$

最后, 在每个子区域中选出拥挤度距离最大的非支配粒子, 将其构成全局最优粒子候选组:

$$G = \{g_1, g_2, \dots, g_L\} \quad (29)$$

式中, L 表示外部档案中包括非支配粒子的子区

域数.

全局最优候选组的构建为粒子后续进化提供了更多信息, 可以促使解集分布相对均匀, 以避免陷入局部最优的情况.

为了加快搜索进程, 促使种群向全局最优解收敛, 在更新过程中为粒子挑选距离其最近的全局最优粒子候选者, 作为该粒子的全局最优领导者 g_i :

$$g_i = \arg \min_l \left(\sqrt{\sum_{m=1}^M (f_m(z_i) - f_m(g_l))^2} \right),$$

$$l = 1, 2, \dots, L \quad (30)$$

确定最优粒子领导者的具体流程如图 4 所示.

2.2.4 飞行参数自适应调整

飞行参数是影响种群搜索的另外一个重要因素. 式 (25) 中的 c_1, c_2 可以看作粒子在搜索过程中向领导者靠近的加速度系数. 当粒子距离领导者较远时, 应采用较大的加速度系数加速靠近, 然而过大的加速度系数又会导致粒子在搜索过程中越过最优解; 相反, 当粒子距离领导者较近时, 应减小加速度系数, 以免造成过早收敛, 然而过小的加速度系数又会影响搜索进程. 因此, 本文对 c_1, c_2 的调整方式设计如下:

$$c_1 = \alpha_1 \text{Sigmoid} \|z_i - p_i\| + \beta_1 \quad (31)$$

$$c_2 = \alpha_2 \text{Sigmoid} \|z_i - g_i\| + \beta_2 \quad (32)$$

式中, z_i 为粒子 i 所在位置, p_i 为当前迭代时刻粒子 i 的历史最优解, g_i 为粒子 i 的全局最优领导者, α, β 为可调系数. Sigmoid 函数是具有单调递增且有界的平滑曲线, 既能避免参数的意外突变, 又可以反映种群更新的动态特性^[31].

惯性权重系数 ω 采用线性衰减的方式动态调整:

$$\omega = \omega_1 \theta^{it-1} \quad (33)$$

式中, ω_1 为初始权重; θ 为线性衰减率, 并设为 0.99.

2.3 基于熵权法的操作变量设定值确定

基于 MOPSO-RC 可以获取操作变量的最优解集合, 即 Pareto 解集. 而实际工程通常需要一个确定的解决方案, 因此, 如何从获取的 Pareto 解集中选择出最适合的解决方案有待进一步研究.

为确定最优操作变量设定值, 本文设计了 U_r 指标对 Pareto 解集进行评价:

$$U_r = \sum_{m=1}^M \mu_m f_{r, m}, \quad r = 1, 2, \dots, R \quad (34)$$

式中, μ_m 表示第 m 个优化目标的权重, $f_{r, m}$ 表示

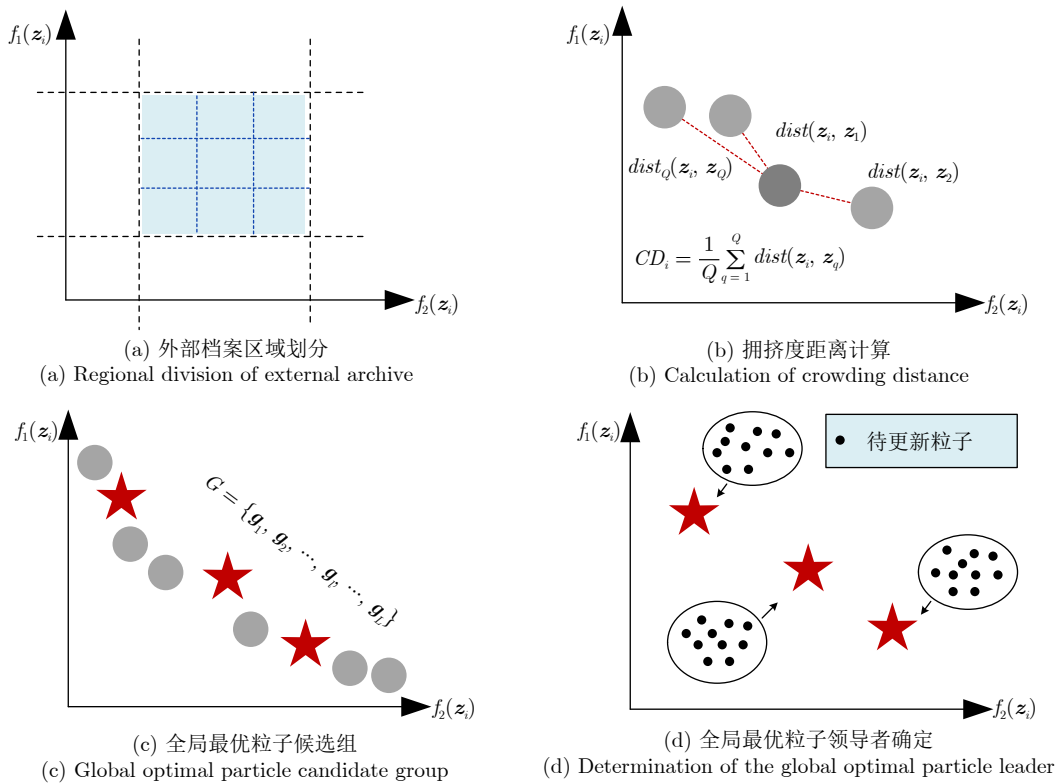


图 4 确定全局最优领导者示意图

Fig. 4 The diagram of determining the global optimal leader

Pareto 解集中第 r 个解的第 m 个优化目标值, R 为 Pareto 解集的个数, M 为优化目标个数.

一般情况下, 会依据决策偏好主观确定权重 μ_m . 然而, 这种人为赋权的方式往往会造成顾此失彼的情况. 熵权法作为一种客观赋权的方法, 可以根据信息熵计算各目标的熵权. 熵权越大, 表示该目标在决策评价中所起的作用越大. 基于熵权法的优化目标权重确定方法如下:

1) 计算每个目标的信息熵. 信息熵作为衡量数据有序化程度的指标, 可以充分体现 Pareto 解集内各解的差异性. 第 m 个目标的信息熵 q_m 计算公式为:

$$q_m = -\frac{1}{\ln R} \sum_{r=1}^R \frac{s_{r,m}}{\sum_{r=1}^R s_{r,m}} \ln \frac{s_{r,m}}{\sum_{r=1}^R s_{r,m}} \quad (35)$$

式中, $s_{r,m}$ 为 $f_{r,m}$ 经过归一化处理的优化目标值.

2) 基于信息熵 q_m 确定第 m 个目标的权重 μ_m :

$$\mu_m = \frac{1 - q_m}{\sum_{m=1}^M (1 - q_m)} \quad (36)$$

最终, 为选取最优操作变量设定值, 将计算所得 μ_m 代入式 (34), 使得评价指标 U_r 最小的解即为最终操作变量设定值.

3 仿真实验结果

3.1 数据集描述

所用实验数据采集自北京市某固废焚烧厂在稳定运行状态下的真实数据, 设置采样间隔为 30 s, 优化周期为 4 min. 为了排除传感器故障及其余干扰因素的影响, 采用 3σ 法剔除数据异常值. 最终实验数据包括炉排速度、一次风入口流量、一次风出口压力、二次风入口流量、NO_x 浓度、CO 浓度及 CO₂ 浓度 7 个变量, 共 1 000 组数据, 其中前 700 组数据作为训练集, 后 300 组数据作为测试集. 数据基本信息如表 1 所示. 为消除数量级差异, 对数据进行归一化处理, 以提高模型精度, 具体如下:

$$x'_d = \frac{x_d - x_{\min}}{x_{\max} - x_{\min}} \quad (37)$$

3.2 运行指标模型结果

首先, 利用所设计的 SORBF 神经网络分别建立 NO_x/CO/CO₂ 指标模型. NO_x/CO/CO₂ 指标模型的输出变量分别为 t 时刻的 NO_x/CO/CO₂ 浓度, 输入变量包括 t 时刻的炉排速度、一次风入口流量、一次风出口压力、二次风入口流量四个操作

表 1 实验数据基本信息
Table 1 Basic information of experimental data

变量名称	取值范围	单位
炉排速度	30.05 ~ 30.08	%
一次风入口流量	47 698.32 ~ 63 444.03	m ³ /h
一次风出口压力	1 988.02 ~ 3 189.73	Pa
二次风入口流量	4 924.86 ~ 5 124.70	m ³ /h
NO _x 排放浓度	79.21 ~ 231.27	mg/m ³
CO 排放浓度	0.39 ~ 7.38	mg/m ³
CO ₂ 排放浓度	4.80 ~ 6.55	mg/m ³

变量以及 $t-1$ 时刻的 NO_x/CO/CO₂ 浓度. 实验过程中设置学习率为 0.01, 所建立 NO_x/CO/CO₂ 指标模型的隐藏层神经元个数分别为 13、10、10. 图 5 ~ 7 为基于 SORBF 神经网络所建立的不同指标模型结果. 由此得出, 基于 SORBF 神经网络所建立的运行指标模型可以准确表征 NO_x 排放和燃烧效率, 实现 MSWI 过程运行性能的在线评价.




图 5 NO_x 指标模型结果
Fig. 5 The results of NO_x index model





图 6 CO 指标模型结果
Fig. 6 The results of CO index model

此外, 为验证所设计 SORBF 神经网络的优良性, 将其与最小二乘支持向量回归 (Least squares support vector regression, LSSVR)^[32] 和 Kriging 模型^[33] 以及 RBF 三种不同方法进行比较. 利用均方根误差 (Root mean square error, RMSE)

图 7 CO₂ 指标模型结果Fig. 7 The results of CO₂ index model

和平均百分比误差 (Mean absolute percentage error, MAPE) 评价模型精度, 计算如下:

$$\text{RMSE} = \sqrt{\frac{1}{K} \sum_{k=1}^K (\hat{y}_k - y_k)^2} \quad (38)$$

$$\text{MAPE} = \frac{100\%}{K} \sum_{k=1}^K \left| \frac{\hat{y}_k - y_k}{y_k} \right| \quad (39)$$

式中, \hat{y}_k 和 y_k 分别为第 k 个样本的网络输出和期望输出, K 为测试样本个数.

不同指标模型的 RMSE 与 MAPE 计算结果如表 2 所示. 分析实验结果可以得出, 相比其他方法, 基于 SORBF 神经网络构建的指标模型精度更高, 可以精准表征操作变量与运行指标间的映射关系, 为后续求解多目标优化问题奠定了基础.

3.3 操作优化结果

然后, 将上述所建运行指标模型作为评价函数, 经 MOPSO-RC 算法求解获取 Pareto 解集后, 利用熵权法确定操作变量最优设定值. 实验过程中, 设置种群规模为 50, 迭代次数为 30, 第 2.2 节中所提参数 $Q = 2$, $\alpha_1 = \alpha_2 = 1.5$, $\beta_1 = \beta_2 = 1.5$; 惯性权重初始值 ω_1 为 0.5.

图 8 ~ 9 为 NO_x 排放与燃烧效率的优化结果. 结果表明, 所提算法在提高燃烧效率的同时有效降低了 NO_x 排放. 与实际运行相比, 优化后燃烧效率

平均提高 7.73%, NO_x 浓度平均降低 15.34%. 实验过程中, 单次优化所用计算时间少于 30 s, 可以满足实际生产需求.

图 10 ~ 13 为优化前后的操作变量设定值, 结果显示, 在所选实验数据时段内, 与实际设定相比, 除优化后的一次风入口流量设定增加外, 优化后的炉排速度、一次风出口压力与二次风入口流量都基本降低, 且总体变化波动相较实际设定减少, 在一定程度上可以减少因频繁操作所带来的机器损耗. 炉排速度的减慢与一次风入口流量的增加可以延长固废停留时间与提供氧气供应, 为炉膛内的充分燃烧提供了条件; 一次风出口压力和二次风入口流量的减少可以降低炉内氮气与氧气的接触与反应, 一定程度上减少了 NO_x 的生成.

此外, 为验证 MOPSO-RC 算法在 MSWI 过程中的优良性, 将其与 NSGA-II、MOPSO 及基于拥挤距离的 MOPSO (MOPSO based on crowding distance, MOPSO-CD) 算法进行比较. 图 14 ~ 15 为利用不同算法对 MSWI 过程中燃烧效率与 NO_x 排放的优化结果. 表 3 为图中不同方法优化后燃烧效率均值与 NO_x 排放均值结果. 由此可以看出, MOPSO-RC 算法在 NO_x 排放和燃烧效率上都明显优于 NSGA-II 与 MOPSO 算法. 与 MOPSO-CD 算法相比时, 虽在燃烧效率优化方面优势较小, 但在降低 NO_x 排放方面具有明显优势. 综上所述, 虽然其他三种优化算法都能实现 MSWI 过程运行优化, 但本文提出的 MOPSO-RC 算法更具优势, 可以在提高城市固废燃烧效率的同时降低 NO_x 排放.

4 结束语

本文提出了一种基于 MOPSO 算法的 MSWI 过程智能操作优化方法, 实现了脱硝效率与燃烧效率的协同提升. 该方法主要包括建立运行指标模型、设计多目标优化算法以及选取操作变量最优设定值三部分. 通过北京某固废焚烧厂实际运行数据对上述方法进行验证, 可以得出以下结论:

1) 在运行指标模型方面, 结合误差补偿与改进

表 2 不同指标模型精度

Table 2 Accuracy of different index models

方法	NO _x 指标模型		CO 指标模型		CO ₂ 指标模型	
	RMSE	MAPE (%)	RMSE	MAPE (%)	RMSE	MAPE (%)
LSSVR	11.2729	7.0716	0.6281	17.8164	0.1970	2.6587
Kriging	10.3483	6.1612	0.5376	15.5635	0.1967	2.5834
RBF	11.6462	7.3384	0.5595	16.5597	0.1908	2.4366
SORBF	9.3939	5.5603	0.5368	15.4444	0.1866	2.2523




图 8 NOx 排放的优化结果

Fig. 8 Optimization results of NOx emissions




图 9 燃烧效率的优化结果

Fig. 9 Optimization results of CE




图 10 炉排速度设定

Fig. 10 The settings of grate speed

二阶学习算法设计的 SORBF 神经网络可以准确表征 MSWI 过程中燃烧效率与 NOx 排放, 实现了 MSWI 过程运行性能在线评价。

2) 在多目标优化方面, 引入区域拥挤度指标所设计的改进多目标粒子群算法在 MSWI 过程优化运行中具有一定优越性。

3) 在操作变量设定值选取方面, 利用熵权法确定了操作变量的最优设定值, 燃烧效率平均提升 7.73%, NOx 排放平均降低 15.34%。

尽管本文所提方法实现了燃烧效率和 NOx 排




图 11 一次风入口流量设定

Fig. 11 The settings of the inlet flow of primary air




图 12 一次风出口压力设定

Fig. 12 The settings of the outlet pressure of primary air

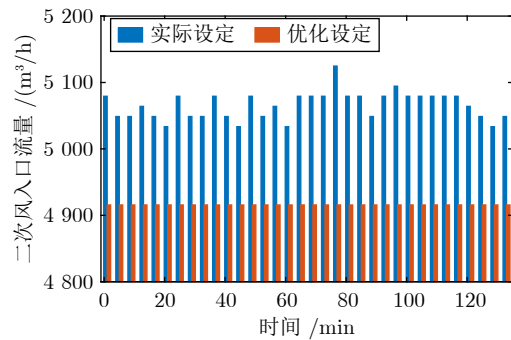


图 13 二次风入口流量设定

Fig. 13 The settings of the inlet flow of secondary air




图 14 不同算法对 NOx 排放的优化结果

Fig. 14 Optimization results of NOx emissions using different algorithms

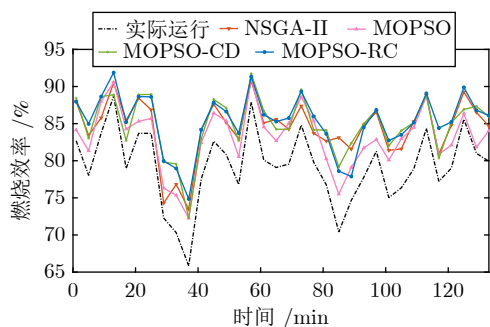


图 15 不同算法对 CE 的优化结果

Fig. 15 Optimization results of CE using different algorithms

表 3 不同算法优化结果均值比较

Table 3 Comparison of mean optimization results using different algorithms

不同优化算法	NOx 排放 (mg/m ³)	燃烧效率 (%)
实际运行	133.840 2	79.274 0
NSGA-II	123.567 4	84.460 1
MOPSO	121.792 7	83.122 0
MOPSO-CD	119.997 0	84.890 7
MOPSO-RC	113.462 5	85.299 0

放的优化, 但尚未考虑能源转化利用率、经济效益等其他指标. 此外, 如何确保所提出的方法在复杂工况下的可靠应用也是未来研究的主要内容.

References

- Maalouf A, Mavropoulos A, El-Fadel M. Global municipal solid waste infrastructure: Delivery and forecast of uncontrolled disposal. *Waste Management & Research*, 2020, **38**(9): 1028–1036
- Tang Jian, Xia Heng, Yu Wen, Qiao Jun-Fei. Research status and prospects of intelligent optimization control for municipal solid waste incineration process. *Acta Automatica Sinica*, 2023, **49**(10): 2019–2059
(汤健, 夏恒, 余文, 乔俊飞. 城市固废焚烧过程智能优化控制研究现状与展望. *自动化学报*, 2023, **49**(10): 2019–2059)
- Frey H H, Peters B, Hunsinger H, Vehlow J. Characterization of municipal solid waste combustion in a grate furnace. *Waste Management*, 2003, **23**(8): 689–701
- Shin D, Choi S. The combustion of simulated waste particles in a fixed bed. *Combustion and Flame*, 2000, **121**(1–2): 167–180
- Yang Y B, Goh Y R, Zakaria R, Nasserzadeh V, Swithenbank J. Mathematical modelling of MSW incineration on a travelling bed. *Waste Management*, 2002, **22**(4): 369–380
- Liang Z, Ma X. Mathematical modeling of MSW combustion and SNCR in a full-scale municipal incinerator and effects of grate speed and oxygen-enriched atmospheres on operating conditions. *Waste Management*, 2010, **30**(12): 2520–2529
- Xia Z, Li J, Wu T, Chen C, Zhang X. CFD simulation of MSW combustion and SNCR in a commercial incinerator. *Waste Management*, 2014, **34**(9): 1609–1618
- Hu Z, Jiang E, Ma X. Numerical simulation on operating parameters of SNCR process in a municipal solid waste incinerator. *Fuel*, 2019, **245**: 160–173
- Yang X, Liao Y, Ma X, Zhou J. Effects of air supply optimization on NOx reduction in a structurally modified municipal solid waste incinerator. *Applied Thermal Engineering*, 2022, **201**: Article No. 117706
- Huai X L, Xu W L, Qu Z Y, Li Z G, Zhang F P, Xiang G M, et al. Numerical simulation of municipal solid waste combustion in a novel two-stage reciprocating incinerator. *Waste Management*, 2008, **28**(1): 15–29
- Han H, Liu Y, Hou Y, Qiao J. Multi-modal multi-objective particle swarm optimization with self-adjusting strategy. *Information Sciences*, 2023, **629**: 580–598
- Zhou P, Wang X, Chai T. Multiobjective operation optimization of wastewater treatment process based on reinforcement self-learning and knowledge guidance. *IEEE Transactions on Cybernetics*, 2023, **53**(11): 6896–6909
- Ding Jin-Liang, Chen Jia-Xin, Ma Xin-Ran. Multi-objective optimization of light oil production in atmospheric distillation column based on self-adaptive differential evolution. *Control and Decision*, 2020, **35**(3): 604–612
(丁进良, 陈佳鑫, 马欣然. 基于自适应差分进化的常压塔轻质油产量多目标优化. *控制与决策*, 2020, **35**(3): 604–612)
- Yang Chun-Hua, Sun Bei, Li Yong-Gang, Huang Ke-Ke, Gui Wei-Hua. Cooperative optimization and intelligent control of complex production processes. *Acta Automatica Sinica*, 2023, **49**(3): 528–539
(阳春华, 孙备, 李勇刚, 黄科科, 桂卫华. 复杂生产流程协同优化与智能控制. *自动化学报*, 2023, **49**(3): 528–539)
- Huang W, Mohammad M. Development, exergoeconomic assessment and optimization of a novel municipal solid waste-incineration and solar thermal energy based integrated power plant: An effort to improve the performance of the power plant. *Process Safety and Environmental Protection*, 2023, **172**: 562–578
- Costa M, Indrizzi V, Massarotti N, Mauro A. Modeling and optimization of an incinerator plant for the reduction of the environmental impact. *International Journal of Numerical Methods for Heat & Fluid Flow*, 2015, **25**(6): 1463–1487
- Pan M, Chen X, Li X. Multi-objective analysis and optimization of cascade supercritical CO₂ cycle and organic Rankine cycle systems for waste-to-energy power plant. *Applied Thermal Engineering*, 2022, **214**: Article No. 118882
- Özahi E, Tozlu A, Abuşoğlu A. Thermoeconomic multi-objective optimization of an organic Rankine cycle (ORC) adapted to an existing solid waste power plant. *Energy Conversion and Management*, 2018, **168**: 308–319
- Mayanti B, Songok J, Helo P. Multi-objective optimization to improve energy, economic and, environmental life cycle assessment in waste-to-energy plant. *Waste Management*, 2021, **127**: 147–157
- Tang Z, Zhang Z. The multi-objective optimization of combustion system operations based on deep data-driven models. *Energy*, 2019, **182**: 37–47
- Chai T, Zhang J, Yang T. Demand forecasting of the fused magnesia smelting process with system identification and deep learning. *IEEE Transactions on Industrial Informatics*, 2021, **17**(12): 8387–8396
- Anderson S R, Kadirkamanathan V, Chipperfield A, Sharifi V, Swithenbank J. Multi-objective optimization of operational variables in a waste incineration plant. *Computers & Chemical Engineering*, 2005, **29**(5): 1121–1130
- Cui Ying-Ying, Meng Xi, Qiao Jun-Fei. The intelligent optimization setting method of air flow for municipal solid wastes incineration process. *Control and Decision*, 2023, **38**(2): 318–326
(崔莺莺, 蒙西, 乔俊飞. 城市固废焚烧过程风量智能优化设定方法. *控制与决策*, 2023, **38**(2): 318–326)
- Sun J, Meng X, Qiao J. Data-driven optimal control for municipal solid waste incineration process. *IEEE Transactions on Industrial Informatics*, 2023, **19**(12): 11444–11454
- Sun Jian, Meng Xi, Qiao Jun-Fei. Adaptive predictive control of oxygen content in flue gas for municipal solid waste incineration process. *Acta Automatica Sinica*, 2023, **49**(11): 2338–2349
(孙剑, 蒙西, 乔俊飞. 城市固废焚烧过程烟气含氧量自适应预测控制. *自动化学报*, 2023, **49**(11): 2338–2349)
- Bai Liang-Cheng. *Engineering Technology for Incineration Treatment of Municipal Solid Waste*. Beijing: China Architectural & Building Press, 2011

ture & Building Press, 2021.
(白良成. 生活垃圾焚烧处理工程技术. 北京: 中国建筑工业出版社. 2021)

- 27 Meng X, Rozycki P, Qiao J, Wilamowski B. Nonlinear system modeling using RBF networks for industrial application. *IEEE Transactions on Industrial Informatics*, 2017, **14**(3): 931–940
- 28 Qiao J, Zhou J, Meng X. A multitask learning model for the prediction of NO_x emissions in municipal solid waste incineration processes. *IEEE Transactions on Instrumentation and Measurement*, 2022, **72**: 1–14
- 29 Zhou W, Li X, Yi J, He H. A novel UKF-RBF method based on adaptive noise factor for fault diagnosis in pumping unit. *IEEE Transactions on Industrial Informatics*, 2018, **15**(3): 1415–1424
- 30 Yao F, Zhao J, Li X, Mao L, Qu K. RBF neural network based virtual synchronous generator control with improved frequency stability. *IEEE Transactions on Industrial Informatics*, 2020, **17**(6): 4014–4024
- 31 Liu W, Wang Z, Yuan Y, Zeng N, Hone K, Liu X. A novel sigmoid-function-based adaptive weighted particle swarm optimizer. *IEEE Transactions on Cybernetics*, 2019, **51**(2): 1085–1093
- 32 Smola A, Schölkopf B. A tutorial on support vector regression. *Statistics and Computing*, 2004, **14**(3): 199–222
- 33 Sacks J, Welch W J, Mitchell T J, Wynn H P. Design and analysis of computer experiments. *Statistical Science*, 1989, **4**(4): 409–423



蒙 西 北京工业大学信息学部副教授. 主要研究方向为神经网络结构分析与设计, 城市固废焚烧过程智能优化控制. 本文通信作者.

E-mail: mengxi@bjut.edu.cn

(MENG Xi Associate professor at the Faculty of Information Technology, Beijing University of Technology. Her research

interest covers analysis and design of artificial neural network structure and intelligent optimization control of municipal solid waste incineration process. Corresponding author of this paper.)



侯启正 北京工业大学信息学部硕士研究生. 主要研究方向为城市固废焚烧过程智能操作优化.

E-mail: houqizheng@emails.bjut.edu.cn

(HOU Qi-Zheng Master student at the Faculty of Information Technology, Beijing University of Technology. Her research

interest covers intelligent operational optimization of municipal solid waste incineration process.)



乔俊飞 北京工业大学信息学部教授. 主要研究方向为计算智能与智能优化控制, 环保自动化.

E-mail: adqiao@bjut.edu.cn

(QIAO Jun-Fei Professor at the Faculty of Information Technology, Beijing University of Technology. His research

interest covers computational intelligence and intelligent optimization control, environmental protection automation.)