

城市生活垃圾焚烧炉温控制的多目标优化设定方法

严爱军^{1,2,3†}, 胡开成^{1,2}

(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)

摘要: 为实现城市生活垃圾焚烧(MSWI)过程的炉温稳定并避免炉排温度过高的控制目标, 本文提出一种通过炉排温度和一次风温间接控制炉温的多目标优化设定方法. 通过融合分解与竞争策略, 将WS变换、双向学习、随机交叉、动态高斯变异引入到多目标海鸥优化算法(MOSOA)中, 得到一种改进的MOSOA(IMOSOA), 根据炉温的设定值、误差等信息对炉排温度和一次风温的设定值进行寻优. 实验结果表明IMOSOA的寻优能力显著增强, 在干扰影响下, 基于IMOSOA的多目标优化设定方法可实现MSWI过程炉温的控制目标, 能有效促进垃圾焚烧过程的平稳运行.

关键词: 城市生活垃圾; 炉温; 多目标优化; 海鸥优化算法; 优化设定

引用格式: 严爱军, 胡开成. 城市生活垃圾焚烧炉温控制的多目标优化设定方法. 控制理论与应用, 2023, 40(4): 693 – 701

DOI: 10.7641/CTA.2022.11119

Multi-objective optimization setting method for temperature control of municipal solid waste incinerator

YAN Ai-jun^{1,2,3†}, HU Kai-cheng^{1,2}

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China;

2. Engineering Research Center of Digital Community, Ministry of Education, Beijing 100124, China;

3. Beijing Laboratory for Urban Mass Transit, Beijing 100124, China)

Abstract: To achieve the stability of the furnace temperature in the municipal solid waste incineration (MSWI) process and avoid excessively high grate temperature, a multi-objective optimization setting method is proposed in this paper, which indirectly controls the furnace temperature through the grate temperature and the primary air temperature. By introducing the weight shift (WS) transformation, bidirectional learning, random crossover and dynamic Gaussian mutation into the multi-objective seagull optimization algorithm (MOSOA), an improved MOSOA (IMOSOA) is obtained with integrating decomposition and competition strategies. The set value of grate temperature and the primary air temperature are optimized according to the set value of furnace temperature, the error and other information by IMOSOA. Experimental results show that the optimization capability of IMOSOA is significantly enhanced. Under the influence of disturbance, the furnace temperature control target of the MSWI process can be achieved through multi-objective optimization setting method based on the IMOSOA, and the smooth operation of the waste incineration process is also effectively promoted.

Key words: municipal solid waste; furnace temperature; multi-objective optimization; seagull optimization algorithm; optimal setting

Citation: YAN Aijun, HU Kaicheng. Multi-objective optimization setting method for temperature control of municipal solid waste incinerator. *Control Theory & Applications*, 2023, 40(4): 693 – 701

1 引言

城市生活垃圾焚烧(municipal solid waste incineration, MSWI)具有无害化、减量化、资源化等优点, 已逐渐成为处理城市生活垃圾的主要方式^[1]. 焚烧过程控制的核心在于炉温(通常指一燃室烟气温度均值)控制, 若能稳定控制在工艺要求的最低温度以上, 可使

炉内垃圾充分燃烧并减少二次污染物排放. 由于影响炉温的因素众多, 干扰频繁, 表现出强耦合、非线性等复杂特性, 常规的定值控制方法难以保证炉温的稳定控制要求, 容易导致炉排温度过高等故障的发生以及二次污染物排放超标. 因此, 对影响炉温控制效果的关键参数进行优化设定的方法研究具有现实意义.

收稿日期: 2021–11–16; 录用日期: 2022–04–28.

†通讯作者. E-mail: yanaijun@bjut.edu.cn; Tel.: +86 10-67396376.

本文责任编辑: 吴敏.

国家自然科学基金项目(61873009, 62073006), 北京市自然科学基金项目(4212032)资助.

Supported by the National Natural Science Foundation of China (61873009, 62073006) and the Beijing Natural Science Foundation of China (4212032).

目前,炉温控制系统的设计与实现侧重于多变量控制方式,所选择的操作变量主要有垃圾给料量、风量、风温等,在实践中往往是采用PID控制方法对这些操作变量分开控制,但这种方法难以适应MSWI过程多目标、变量耦合、约束条件众多等情况.为此,文献[2]提供了一种模型预测控制方法,改善了控制性能,但控制精度仍有待提高.在这种情况下,智能控制方法得到了足够重视,例如:Carrasco等人^[3]提出了一种基于知识的燃烧控制系统,通过焚烧炉的动态模型来分析变量之间的关系,并获得垃圾给料量、风量和风温的设定规则去控制炉温;文献[4]则采用模糊控制方法调整给料量和风量大小,其中的模糊规则是相对固定的,有可能适应不了焚烧环境的变化,而采用一种可以随时调整模糊规则的自适应方法可以改善控制性能^[5];基于神经网络的智能控制方法研究也有报道,文献[6]开发了一种离散时间神经控制方案来调节风量大小,以实现焚烧炉的CO和NO_x排放目标,并使炉温处于工艺要求范围之内.后来也出现了一些仿人智能控制策略用于炉温的控制^[7-8].以上所述的各种控制方案经过实践检验或者模拟仿真证明可以改善垃圾焚烧过程的运行状况.然而,由于垃圾热值不易检测^[9],而且操作变量(包括垃圾给料量、风量、风温)与被控变量(炉温)之间的大时滞特性等,使得上述通过直接调节操作变量进而控制炉温的效果并不理想.因而,如何在复杂因素影响下优化操作变量的设定值,以达到稳定控制炉温、保证焚烧过程平稳运行的目标仍须进一步研究.

根据上述分析,针对垃圾热值不易检测和炉温控制过程的大时滞特性,本文从多目标优化的角度出发,主要围绕新的炉温优化控制结构和设定值算法两方面内容开展研究,兼顾炉温的稳定控制与炉排温度过高的工艺要求,具体方案是:将炉排温度和一次风温作为中间控制变量,按照炉温与中间变量形成串级控制的思想设计了多目标优化设定控制结构;然后,通过权值变换(weight shift, WS)、双向学习、随机交叉、动态高斯变异4种策略的引入得到了一种新的改进多目标海鸥优化算法(improved multiple objective seagull optimization algorithm, IMOSOA),利用该算法可得到炉排温度和一次风温的优化设定值;最后,通过实验测试了多目标优化设定策略的优越性.

本文余下部分的组织结构安排是:第2节介绍MSWI过程及问题分析;第3节介绍改进的多目标海鸥优化算法及多目标优化设定步骤;第4节是实验及结果分析;最后总结全文.

2 MSWI过程及问题分析

以某垃圾焚烧厂的炉排炉为例,MSWI工艺流程如图1所示:首先,经过堆放发酵的生活垃圾通过进料

器推送到炉排上,炉排交错往复运动,一次风从炉排下方吹入,穿过垃圾料层.垃圾经过干燥炉排时,吸收来自炉膛下部的高温一次风和焚烧炉内侧壁辐射的热量,蒸发水分,达到着火点.干燥后的垃圾依次通过燃烧炉排1与燃烧炉排2,二次风从炉排上方由上而下吹入,促进炉内挥发性气体和炉排上的垃圾燃烧.最后,燃烬炉排接收从燃烧炉排送来的固定碳以及炉渣中未燃烬的部分,使之充分燃烧并冷却炉渣.垃圾焚烧所产生的高温烟气经余热回收、尾气处理后排入大气.

从MSWI的工艺流程中可以看出,炉温是衡量垃圾燃烧是否充分、焚烧过程是否稳定的重要指标.由于MSWI过程干扰众多,常规的定值控制方法难以适应复杂多变的焚烧工况.此外,我国的生活垃圾热值较低,通过直接调节垃圾给料量与一次风量来控制炉温,容易造成炉温的反向调节.由垃圾焚烧机理可知,垃圾热值高低会显著影响炉温,但其目前还没有可靠的检测手段^[9],所以目前已有的控制方案中没有考虑这一不确定性干扰.值得注意的是,炉排与垃圾直接接触,其温度高低在一定程度上可以反应垃圾热值的变化;从降低故障发生的角度分析,炉排温度如果过高会导致卡涩等现象发生.另外,一次风温对垃圾的干燥和充分燃烧具有重要作用.因此,本文将炉排温度和一次风温作为炉温控制的中间变量,炉排温度、一次风温与炉温呈现如下式所示的非线性关系:

$$T = f(x_1, x_2, x_3, x_4, x_5), \quad (1)$$

其中: T 表示炉温; $x_1 \sim x_4$ 分别表示图1中的干燥炉排、燃烧炉排1、燃烧炉排2、燃烬炉排的温度; x_5 是一次风温.

式(1)所示的准确机理模型难以获得,在这种情况下,采用基于机理模型的控制方案难以保证炉温的稳定控制.为适应炉温控制的大时滞特性,实现稳定控制炉温和避免炉排温度过高的控制目标,本文制定了炉温控制的多目标优化方案,在满足约束条件的前提下: 1) 炉温偏差最小; 2) 炉排温度不超过工艺规定的高值; 3) 一次风温尽可能高.可用下式进行描述:

$$\min(e = |T^* - T|), \max x_i, \quad (2)$$

$$\text{s.t. } x_{i,\min} \leq x_i \leq x_{i,\max},$$

$$T \geq T_{\min},$$

其中: T^* 为炉温设定值; e 为炉温设定值与炉温检测值的偏差; $T_{\min}$ 为工艺要求的炉温最小值; x_i ($i = 1, 2, \dots, 5$)的意义参见式(1); $x_{i,\min}$ 和 $x_{i,\max}$ 分别为 x_i 的最小值和最大值.

基于上述,多目标优化控制的关键就是通过优化算法获得炉排温度和一次风温的优化设定值,这是实现炉温稳定控制并避免炉排温度过高的关键.




图1 MSWI工艺流程

Fig. 1 MSWI process flow

3 IMOSOA设定方法

由于式(2)属于多目标优化问题, 单一的最优解难以获得, 只能寻求一组帕累托(Pareto)解, 而多目标优化算法在处理这类问题时具有无需求导和一次运行可得到多个Pareto解的优势^[10]。其中, 海鸥优化算法(seagull optimization algorithm, SOA)具有易于实现、参数简单等特点, 在工业优化过程中得到成功应用^[11-13]。虽然动态存档与自适应网格可以改善多目标海鸥优化算法(multiple objective SOA, MOSOA)的收敛性与解集分布性^[14], 但外部存档的引入使算法的计算开销较大, 这给MOSOA的在线应用带来了挑战。另外, 对于具有复杂帕累托前沿(pareto front, PF)的多目标优化问题, 自适应网格难以保证MOSOA解集的分布性。因此, 本节首先对MOSOA进行改进得到IMOSOA, 然后利用它对炉排温度和一次风温的设定值进行寻优。

3.1 IMOSOA

对于多目标优化问题而言, 基于分解的多目标优化算法通过对邻域内的子问题进行协同求解(邻域范围由参考向量个数决定)^[15], 相比于支配排序、指标的多目标优化算法, 在解集分布性上具有优势^[16]。此外, 在同代种群中随机挑选成对个体进行比较, 输者向赢者学习的竞争策略, 由于不需要精英外部存档, 使算法的计算成本较低, 在求解精度上也有较好的表现^[17]。因此, 本文将分解与竞争策略相融合, 通过WS变换、双向学习、随机交叉、动态高斯变异4种策略的加入, 进一步提升MOSOA在求解多目标优化问题时的收敛性与解集分布性。

SOA主要模拟了海鸥的迁徙与攻击两种自然行

为^[12], 海鸥的迁徙过程需要满足3个条件, 即避免碰撞、确定移动方向和靠近最佳位置, 从而以当前最佳海鸥的位置来指导其它海鸥进行位置更新, 具体描述如下:

1) 避免碰撞: 通过附加变量产生不同的位置, 避免海鸥在迁徙过程中相互发生碰撞, 计算公式如下:

$$C = A \cdot X(t), \quad (3)$$

其中: C 表示海鸥个体与其它海鸥不发生碰撞时应处的位置; $X(t)$ 表示海鸥个体当前位置; t 表示当前迭代次数; A 表示附加变量, 用于描述海鸥群体在搜索空间的移动行为, 由下式进行计算:

$$A = f_c \cdot \left(1 - \frac{t}{t_{\max}}\right), \quad (4)$$

其中: f_c 用来控制附加变量 A 的变化范围, f_c 一般取2; $t_{\max}$ 表示最大迭代次数。

2) 确定移动方向: 在避免碰撞的前提下, 海鸥个体会根据当前最佳海鸥的位置来确定自己的移动方向, 表达式如下:

$$M = B \cdot (X_{bs}(t) - X(t)), \quad (5)$$

其中: M 表示海鸥个体与当前最佳海鸥的相对位置; $X_{bs}(t)$ 表示当前最佳海鸥的位置; B 是协调全局与局部搜索的收敛因子, 由下式进行计算:

$$B = 2 \cdot A^2 \cdot rd, \quad (6)$$

其中 rd 表示[0, 1]之间的随机数。

3) 靠近最佳位置: 海鸥个体在确定了避免碰撞位置和移动方向后, 向当前最佳海鸥的方向移动, 表达式如下:

$$D = |C + M|, \quad (7)$$

其中 $\mathbf{D}$ 表示海鸥个体与当前最佳海鸥的距离。

海鸥攻击猎物的行为可以用 x, y, z 平面上的螺旋运动表示, 具体描述如下:

$$r = u \cdot e^{kv}, \quad x' = r \cdot \cos k, \quad y' = r \cdot \sin k, \quad z' = r \cdot k, \quad (8)$$

其中: r 表示海鸥的飞行半径; u, v 是控制螺旋形状的系数, u, v 一般均取1; e 是自然对数的底; k 表示 $[0, 2\pi]$ 范围内的随机攻击角度; 攻击猎物后的新位置由下式计算:

$$\mathbf{X}(t+1) = (\mathbf{D} \cdot x' \cdot y' \cdot z') + \mathbf{X}_{bs}(t). \quad (9)$$

由于加权切比雪夫分解能够较好的平衡算法的收敛性与解集分布性且易于实施^[15-16], 在基于分解的多目标优化算法中应用较为广泛, 其数学表达如下:

$$\min_{\mathbf{x} \in \Omega} (g(\mathbf{x} | \lambda, \mathbf{z}^*)) = \max_{1 \leq i \leq m} (\lambda_i |f_i(\mathbf{x}) - \mathbf{z}_i^*|), \quad (10)$$

$$\text{s.t.} \quad \sum_{i=1}^m \lambda_i = 1, \quad \lambda_i \geq 0,$$

其中: $\mathbf{x}$ 表示决策变量(即本文中的炉排温度和一次风温); Ω 表示决策空间; $\mathbf{z}^*$ 表示理想参考点; $i = 1, 2, \dots, m$; m 表示子问题数量; λ 表示子问题权值。

由式(10)可知, 确定子问题权值是加权切比雪夫分解的前提。由于决策空间与目标空间之间为非线性映射关系^[18], 使得权值向量与解向量的分布不具有 consistency, 通过文献[15]的方法在决策空间生成的均匀分布权值无法保证目标空间的解集也服从均匀分布。因此, 本文采用文献[18]提出的权值初始化方法, 通过WS变换得到在目标空间均匀分布的权值 λ' , 以提高算法所求解集的分布性。WS变换的数学表达如下所示:

$$\lambda' = \text{WS}(\lambda) = \frac{1/\lambda_1}{\sum_{i=1}^m 1/\lambda_i}, \frac{2/\lambda_2}{\sum_{i=1}^m 1/\lambda_i}, \dots, \frac{m/\lambda_m}{\sum_{i=1}^m 1/\lambda_i}. \quad (11)$$

在多目标优化算法中, 通常使用支配关系进行个体间的比较。支配的定义为(以最小化为例)^[19]: 给定一个多目标优化问题 $\mathbf{F}(\mathbf{x}) = [f_1(\mathbf{x}) \ f_2(\mathbf{x}) \ \dots \ f_m(\mathbf{x})]$, 设 p 与 q 是进化群体中任意2个不同的个体, 若满足式(12)的条件, 则称 p 支配 q , 记为 $p \succ q$ 。

$$\begin{cases} \forall f_i(p) \leq f_i(q), \quad i \in [1, m], \\ \exists f_j(p) < f_j(q), \quad j \in [1, m]. \end{cases} \quad (12)$$

下面以双目标最小化问题为例, 通过求解过程中可能出现的2种情形(如图2所示)说明双向学习与随机交叉的实现过程。

假设第 t 代海鸥位置为 $\mathbf{X}(t)$, 第 $t+1$ 代海鸥位置为 $\mathbf{X}(t+1)$, 邻域内相互比较的海鸥个体1与2所处位置分别为 $\mathbf{X}_1(t)$ 与 $\mathbf{X}_2(t)$ 。以 $\mathbf{X}_1(t)$ 支配 $\mathbf{X}_2(t)$ 为例, 当

海鸥个体1与2处于图2中的情形(1)时, 根据文献[17]的竞争思想, 由于 $\mathbf{X}_1(t)$ 支配 $\mathbf{X}_2(t)$, 所以海鸥2向海鸥1学习, 从 $\mathbf{X}_2(t)$ 移动到新位置 $\mathbf{X}_2(t+1)$ 。对于海鸥1而言, 若朝着海鸥2的方向从 $\mathbf{X}_1(t)$ 移动到新位置 $\mathbf{X}_1(t+1)$, 由于 $\mathbf{X}_1(t)$ 支配 $\mathbf{X}_1(t+1)$ 导致算法的收敛性降低; 若海鸥1朝着海鸥2的反方向, 从 $\mathbf{X}_1(t)$ 移动至新位置 $\mathbf{X}'_1(t+1)$, 而 $\mathbf{X}'_1(t+1)$ 支配 $\mathbf{X}_1(t)$, 此时, 海鸥1与海鸥2通过双向学习, 使得自身的位置 $\mathbf{X}_1(t)$ 与 $\mathbf{X}_2(t)$ 同时逼近PF, 这有利于提升算法的求解精度。海鸥1与海鸥2双向学习的表达式如下:

$$M = \begin{cases} B \cdot (\mathbf{X}_1(t) - \mathbf{X}_2(t)), & \mathbf{X}_1(t) \succ \mathbf{X}_2(t), \\ B \cdot (\mathbf{X}_2(t) - \mathbf{X}_1(t)), & \mathbf{X}_1(t) \prec \mathbf{X}_2(t). \end{cases} \quad (13)$$

它们的新位置由下式计算:

$$\begin{cases} \mathbf{X}_1(t+1) = (\mathbf{D}_1 \cdot x' \cdot y' \cdot z') + \mathbf{X}_1(t), \\ \mathbf{X}_2(t+1) = (\mathbf{D}_2 \cdot x' \cdot y' \cdot z') + \mathbf{X}_2(t). \end{cases} \quad (14)$$




图2 双目标最小化示意图

Fig. 2 Schematic diagram of dual objective minimization

若相互比较的海鸥个体处于图2中的情形(2), 此时 $\mathbf{X}_1(t)$ 与 $\mathbf{X}_2(t)$ 互不支配, 双向学习策略不再适用。借鉴遗传算法中的交叉思想^[20], 采用随机交叉使海鸥个体间进行信息交流, 从而产生优秀的子代, 使其进一步逼近PF。随机交叉的数学表达如下所示:

$$\begin{cases} \mathbf{X}_1^h(t+1) = \begin{cases} r_1 \cdot \mathbf{X}_1^h(t) + (1-r_1) \cdot \mathbf{X}_2^h(t), & P_c < 0.5, \\ \mathbf{X}_1^h(t), & P_c \geq 0.5, \end{cases} \\ \mathbf{X}_2^h(t+1) = \begin{cases} r_2 \cdot \mathbf{X}_1^h(t) + (1-r_2) \cdot \mathbf{X}_2^h(t), & P_c < 0.5, \\ \mathbf{X}_2^h(t), & P_c \geq 0.5, \end{cases} \end{cases} \quad (15)$$

其中: $h = 1, 2, \dots, H$; H 表示搜索维度; $\mathbf{X}_1^h(t)$ 与 $\mathbf{X}_2^h(t)$ 分别表示 $\mathbf{X}_1(t)$ 与 $\mathbf{X}_2(t)$ 在第 h 维上的分量; r_1, r_2 表示 $[0, 1]$ 之间的随机数; P_c 表示交叉概率。

由于优化算法在求解的过程中会不可避免的陷入局部最优, 而基本的SOA中没有涉及使算法跳出局部最优的措施, 限制了其寻优性能的提升。因此, 本文提出一种动态高斯变异策略, 通过产生具有正态分布的随机数来替换海鸥个体的原有位置值, 以提高海鸥种群的多样性, 避免算法陷入局部最优。与传统的高斯

变异^[21]相比, 动态高斯变异的方差不再是固定不变的常数, 而是通过海鸥群体所处的位置与搜索区间进行动态调整, 具有自适应性. 动态高斯变异的数学表达如下所示:

$$\begin{cases} \mathbf{X}_n^h(t+1) = \text{Gaussian}(\mu, \sigma^2), P_m < 1/H, \\ \mu = \mathbf{X}_n^h(t), \\ \sigma^2 = \varepsilon + \frac{a_h(t) - b_h(t)}{ub(h) - lb(h)}. \end{cases} \quad (16)$$

其中: $n = 1, 2, \dots, N$; N 表示种群规模; μ 与 σ^2 表示高斯变异的均值与方差; P_m 表示变异概率; $\mathbf{X}_n^h(t)$ 表示第 n 只海鸥的位置在第 h 维上的分量; $a_h(t)$ 与 $b_h(t)$ 分别表示 $\mathbf{X}(t)$ 在第 h 维上的最大值与最小值; $ub(h)$ 与 $lb(h)$ 分别表示搜索区间在第 h 维的上界与下界; ε 表示一个正实数, 本文取0.1.

综上所述, 通过WS变换改善算法所求解集的分布性, 双向学习与随机交叉提高算法收敛性, 动态高斯变异避免算法陷入局部最优, 从而获得IMOSOA, 算法伪代码如表1所示.

表1 IMOSOA伪代码

Table 1 Pseudocode of IMOSOA

输入:	种群规模 N , 最大迭代次数 $t_{\max}$, 搜索维度 H , 搜索区间 $[lb, ub]$, 子问题数量 m , 参考向量个数.
输出:	IMOSOA求解的Pareto解集.
1	根据式(11)初始化子问题权值;
2	在搜索空间上随机生成 N 只海鸥的初始位置, 并根据式(10)计算海鸥个体的切比雪夫值;
3	while $t \leq t_{\max}$ do
4	for $n = 1 : N$ do
5	根据式(12)对相互比较的海鸥个体进行支配判断;
6	if 存在支配关系;
7	根据式(13)–(14)进行双向学习;
8	else
9	根据式(15)进行随机交叉;
10	end if
11	根据式(16)进行动态高斯变异;
12	根据式(10)重新计算相互比较海鸥个体的切比雪夫值, 并更新邻域解.
13	end for
14	end while
15	输出IMOSOA求解的Pareto解集.

3.2 IMOSOA设定步骤

使用IMOSOA对炉排温度和一次风温的设定值进行寻优的具体步骤如下所示:

步骤1 初始化炉温设定值 T^* , IMOSOA的种群规模 N , 最大迭代次数 $t_{\max}$ 等参数;

步骤2 计算当前炉温偏差 e ;

步骤3 根据第3.1节的算法1迭代求解式(2);

步骤4 若达到最大迭代次数 $t_{\max}$, 则将 $e_{\min}$ 对应的炉排温度与一次风温的优化设定值输送至控制回路(详细解释参见第4.3节), 否则返回步骤3.

4 仿真实验及结果分析

为使入炉垃圾充分燃烧, 实现炉温稳定控制的同时, 避免炉排高温卡涩等故障发生, 本文提出了一种基于IMOSOA的炉温控制多目标优化设定方法, 下面通过2部分实验来验证该方法的有效性. 一是不同炉温模型的对比实验; 二是在文献[22]设计的半实物仿真平台上验证炉温控制多目标优化设定方法的效果.

4.1 实验设计

采用如图3所示的串级控制结构进行实验, 通过设定回路中的IMOSOA优化设定模型, 在线调整控制回路中炉排温度和一次风温的优化设定值. 图中各符号的含义是: T^* 表示炉温设定值; B 表示约束条件; $T_s = T_1 \sim T_5$ 分别表示干燥炉排、燃烧炉排1、燃烧炉排2、燃烬炉排及一次风温度的优化设定值; T_D 表示 T_s 对应的检测值; T 表示炉温检测值; d_1 表示影响炉排温度与一次风温的干扰因素(一次风压等); d_2 表示影响炉温的干扰因素(垃圾热值等). 执行设备主要包括炉排液压驱动器、一次风机、一次风阀门等, 它们的输出量是炉排速度、一次风量以及一次风空气预热器入口旁路的冷风掺入量. 炉排温度及一次风温过程模型采用在工业建模与控制中广泛应用的最小二乘支持向量回归(least square support vector regression, LSSVR)^[23]建立(由多个LSSVR子模型集成), 根据执行设备的输出量对炉排温度和一次风温进行计算. 另外, 同样采用LSSVR来建立式(1)所描述的炉温模型.

4.2 炉温模型对比

本小节首先给出使用LSSVR建立炉温模型的具体步骤, 然后进行炉温模型对比实验, 旨在说明LSSVR对于MSWI过程建模具有一定的优势, 炉排温度与一次风温模型同样采用上述步骤获得.

使用LSSVR建立炉温模型的基本思想是: 输入训练集后, 利用LSSVR拟合式(1)中的非线性函数 $f(\cdot)$, 具体步骤如下:

步骤1 输入训练数据集. 由式(1)可知, 炉温模型的训练数据集可表示为

$$\{(\mathbf{x}_i, T_i) | i = 1, 2, \dots, L\}, \quad (17)$$

其中 L 表示训练数据集的数量.

步骤2 构建炉温数学模型. 式(1)中的非线性函数 $f(\cdot)$ 可表示为

$$f(\mathbf{x}) = \sum_{i=1}^L \mathbf{w}^T \varphi(\mathbf{x}_i) + b, \quad (18)$$

其中: $\mathbf{w}$ 表示权值向量; b 表示偏置; $\varphi(\cdot)$ 表示非线性映射函数; 对于单维回归估计问题, LSSVR通过最小

化目标函数 J , 以获得 $\mathbf{w}$ 与 b , 即

$$\begin{aligned} \min J &= \frac{1}{2} \|\mathbf{w}\|^2 + \frac{C}{2} \sum_{i=1}^L e_i^2, \\ \text{s.t. } T_i &= \mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i, \end{aligned} \quad (19)$$

其中: C 表示惩罚系数; e_i 表示容忍误差. 通过引入拉格朗日乘子 α , 将式(19)转为无约束优化问题

$$\begin{aligned} \min J &= \frac{1}{2} \|\mathbf{w}\|^2 + \frac{C}{2} \sum_{i=1}^L e_i^2 - \\ &\sum_{i=1}^L \alpha_i (\mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i - T_i), \end{aligned} \quad (20)$$

再根据KKT最优条件对上式进行转化, 参照文献[24]

可得如下所示的线性方程组:

$$\begin{bmatrix} K + \frac{1}{C} I_L & 1_L \\ 1_L^T & 0 \end{bmatrix} \cdot \begin{bmatrix} \alpha \\ b \end{bmatrix} = \begin{bmatrix} T \\ 0 \end{bmatrix}, \quad (21)$$

其中: $1_L^T \in \mathbb{R}^{1 \times L}$ 表示元素为1的行矩阵; $T = [T_1 \ T_2 \ \dots \ T_L]^T$; I_L 表示 L 维单位矩阵; $K_{ij} = \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_j)$ 表示满足Mercer条件的核函数.

步骤3 求解模型参数. 通过求解式(21)得到 α 与 b , 式(1)中 $f(\cdot)$ 的估计可表示为

$$\hat{f}(\mathbf{x}) = \sum_{i=1}^L \alpha_i K(\mathbf{x}, \mathbf{x}_i) + b. \quad (22)$$




图3 炉温控制结构

Fig. 3 Furnace temperature control structure

炉温模型对比实验参数设置如下: LSSVR采用高斯核函数, 通过网格搜索法得到核函数参数为5.65, 惩罚因子为11.31. 误差反传(back propagation, BP)网络与径向基函数(radial basis function, RBF)网络分别采用MATLAB工具箱的newff与newrbe函数实现, BP网络的训练次数为100, 学习率为0.01, 隐含层节点数为12, RBF网络的传播系数为0.3.

相比于BP网络, LSSVR通过核函数将数据映射到高维空间, 对非线性数据具有较强的学习能力. 与RBF网络相比, LSSVR以最小化结构风险为基本原则, 提高了模型的泛化能力与鲁棒性, 避免了过拟合. 从图4中可以看出, LSSVR炉温模型能够较真实的反应炉温的波动情况.

4.3 炉温控制实验

为了考察IMOSOA优化设定方法的炉温控制效果, 本小节设计了2组炉温控制对比实验, 一是将IMOSOA与非支配排序遗传算法-II(non-dominated sorting genetic algorithms-II)^[25], (multiobjective evolutionary algorithm based on decomposition, MOEA/D)^[15], 多目标粒子群算法(multiple objective particle swarm optimization, MOPSO)^[26], MOSOA^[14]等优化算法进行对比, 以验证IMOSOA对炉温控制设定

值(即炉排温度与一次风温设定值)的寻优能力; 二是将IMOSOA多目标优化设定控制方法与单回路定值PID控制方法进行对比, 从总体上验证本文控制方法对干扰的抑制能力. 两组实验均采用最大绝对误差(maximum absolute error, MAE)、积分绝对误差(integral absolute error, IAE)、均方跟误差(root mean square error, RMSE)对实验结果进行评价. 仿真平台主要使用RockWell系列软件包、Visual studio以及MATLAB等软件进行开发^[22].

炉温控制实验参数设置如下: IMOSOA的种群数量为20, 最大迭代次数为50, 参考向量个数为5, 对比算法(NSGA-II, MOEA/D, MOPSO, MOSOA)的种群数量、最大迭代次数以及参考向量均与IMOSOA保持一致, 其余参数设置与原文献保持一致. 炉温设定值为930°C, 采样周期为1 min. 采用区间为[2, 4]的随机值来模拟一次风压扰动(单位: kpa). 由于垃圾热值无法在线测量, 因此在炉温测量值上叠加区间为[-10, 10]的随机值, 从而模拟垃圾热值对炉温的影响. 根据垃圾焚烧的工艺要求, $T_{\min}$ 一般设为850°C. 需要指出的是, 本文所研究的炉温多目标优化设定控制是在式(2)中的 $\mathbf{x}_i (i = 1, 2, \dots, 5)$ 满足式(23)的约束下, 利用优化算法对炉排温度与一次风温的设定值进行寻

优,从而使炉温尽可能的靠近设定值.由于式(23)的约束,炉排温度与一次风温的优化设定值均在合理范围内,为保证炉温控制的稳定性,选择式(2)中 $e_{\min}$ 对应的炉排温度与一次风温设定值运行,即

$$\begin{cases} 103^{\circ}\text{C} \leq x_1 \leq 225^{\circ}\text{C}, \\ 114^{\circ}\text{C} \leq x_2 \leq 298^{\circ}\text{C}, \\ 155^{\circ}\text{C} \leq x_3 \leq 245^{\circ}\text{C}, \\ 129^{\circ}\text{C} \leq x_4 \leq 166^{\circ}\text{C}, \\ 142^{\circ}\text{C} \leq x_5 \leq 156^{\circ}\text{C}. \end{cases} \quad (23)$$

对比表2所列数据(表中加粗字体表示最优值),由于WS变换使子问题的权值向量能在目标空间均匀分布,双向学习与随机交叉,使相互比较的海鸥个体可以快速逼近PF,动态高斯变异使IMOSOA在求解的过程中不易陷入局部最优,所以在炉温控制设定值的寻优对比实验中,IMOSOA相对于其它4种算法而言,在MAE,IAE及RMSE评价指标上表现相对较好,这表明IMOSOA多目标优化设定方法对于MSWI过程的炉温

控制设定值寻优具有优势.




图4 炉温模型结果对比

Fig. 4 Comparison of furnace temperature model results

表2 炉温控制设定值寻优结果对比

Table 2 Comparison of optimization results of furnace temperature control setting value

评价指标与 对比算法	一次风压干扰 MAE \ IAE \ RMSE	垃圾热值干扰 MAE \ IAE \ RMSE	两种干扰同时存在 MAE \ IAE \ RMSE
NSGA-II	21.6 \ 823.5 \ 8.6	22.3 \ 834.7 \ 8.8	24.6 \ 869.6 \ 9.1
MOEA/D	23.8 \ 692.1 \ 7.6	24.1 \ 829.5 \ 8.5	25.1 \ 891.9 \ 9.2
MOPSO	22.9 \ 894.4 \ 9.2	22.0 \ 828.8 \ 8.7	23.6 \ 858.8 \ 9.4
MOSOA	22.5 \ 729.8 \ 7.8	20.0 \ 801.6 \ 8.2	22.8 \ 916.2 \ 9.4
IMOSOA	18.2 \ 644.3 \ 6.6	19.8 \ 776.2 \ 7.8	20.3 \ 797.3 \ 8.2

在MSWI过程中,考虑一次风机的功率、效率等参数恒定的情况下,当一次风压增大时一次风量会减小,这容易导致助燃空气不足,造成入炉垃圾不能充分燃烧,进而导致炉温偏低.从图5-6可以看出,在一次风压扰动下,由于多目标优化设定控制采用的是串级控制方案,它能够迅速的克服进入副回路的一次风压干扰,所以相对于单回路定值PID控制而言,炉温低于设定值的时间较短.




图5 一次风压干扰-单回路定值PID控制

Fig. 5 Primary wind pressure disturbance-single-loop fixed-value PID control

由于垃圾热值会显著影响炉温的变化且难以在线测量,多目标优化设定控制基于炉排温度在一定程度

上可以反应垃圾热值变化这一事实,将炉排温度与一次风温作为中间控制变量,并利用多目标优化设定模型对炉排温度和一次风温的设定值进行寻优,使得垃圾热值扰动对炉温的影响相对较小,从图7-8可以看出,在在垃圾热值扰动下,多目标优化设定控制的炉温波动范围较小,而常规的单回路定值PID控制难以克服垃圾热值的影响,炉温波动幅度较大.




图6 一次风压干扰-IMOSOA多目标优化设定控制

Fig. 6 Primary wind pressure disturbance-IMOSOA multi-objective optimization setting control

从图9-10可以看出,在一次风压与垃圾热值同时扰动下,直接通过垃圾给料量与一次风量控制炉温的单回路控制方案,难以克服焚烧过程中存在的一次风

压与垃圾热值干扰,炉温波动幅度较大.而通过炉排温度和一次风温间接控制炉温的串级控制方案,能够较好适应焚烧过程中的干扰,炉温的波动幅度相对较小.




图7 垃圾热值干扰-单回路定值PID控制

Fig. 7 Waste heat value disturbance-single-loop fixed-value PID control




图8 垃圾热值干扰-IMOSOA多目标优化设定控制

Fig. 8 Waste heat value disturbance-IMOSOA multi-objective optimization setting control




图9 两种干扰-单回路定值PID控制

Fig. 9 Two disturbance-single-loop fixed-value PID control




图10 两种干扰-IMOSOA多目标优化设定控制

Fig. 10 Two disturbance-IMOSOA multi-objective optimization setting control

5 结论

为实现MSWI过程炉温的稳定控制,本文提出一种通过控制炉排温度和一次风温间接控制炉温的多目标优化设定方法,通过半实物仿真平台验证了该方法的优越性.本文的主要贡献总结如下:

第一,从多目标优化的角度建立炉温优化设定控制方案,在实现炉温稳定控制的同时,避免炉排温度过高,从而促进垃圾焚烧过程的平稳运行.

第二,将分解与竞争策略相融合,通过加入WS变换、双向学习、随机交叉与动态高斯变异4种策略,得到算法IMOSOA,从而提升了MOSOA在多目标优化问题上的寻优能力.

第三,通过IMOSOA优化设定模型在线调整炉排温度和一次风温的优化设定值,以适应复杂多变的焚烧工况,从而兼顾炉温的稳定控制与炉排温度过高的工艺要求.

实验结果表明,本文提出的炉温控制多目标优化设定方法能够将炉温控制在工艺要求的范围内,炉温波动幅度较小,且在一定程度可以避免炉排高温卡涩故障的发生.因此,该方法对于MSWI过程的炉温稳定控制具有借鉴意义.

参考文献:

- [1] LI Y, ZHAO X G, LI Y B, et al. Waste incineration industry and development policies in China. *Waste Management*, 2015, 46(8): 234 – 241.
- [2] LESKENS M, KESSEI L B M V, BOSGRA O H. Model predictive control as a tool for improving the process operation of MSW combustion plants. *Waste Management*, 2005, 25(8): 788 – 798.
- [3] CARRASCO F, LLAURÓX, POCH M. A methodological approach to knowledge-based control and its application to a municipal solid waste incineration plant. *Combustion Science and Technology*, 2006, 178(4): 685 – 705.
- [4] SHEN Kai, LU Jidong, LIU Gang, et al. Combustion control system of waste incinerator based on fuzzy method. *Journal of Engineering for Thermal Energy and Power*, 2004, 19(5): 491 – 494. (沈凯, 陆继东, 刘刚, 等. 基于模糊方法的垃圾焚烧炉燃烧控制系统. 热能动力工程, 2004, 19(5): 491 – 494.)
- [5] SHEN K, LU J D, LI Z H, et al. An adaptive fuzzy approach for the incineration temperature control process. *Fuel*, 2005, 84(9): 1144 – 1150.
- [6] CARRASCO R, SANCHEZ E N, RUIZ-CRUZ R, et al. Neural control for a solid waste incinerator. *Proceedings of the International Joint Conference on Neural Networks*. Beijing: IEEE, 2014, 9: 3289 – 3294.
- [7] LIU Y C, LIU Y B. Human-simulated intelligent control technique for incineration treatment of municipal solid waste. *Information Technology Journal*, 2013, 12(23): 7758 – 7761.
- [8] WU Q, XU H. Intelligent control strategy of incineration process pollution in municipal solid waste. *Advances in Intelligent Systems and Computing*, 2016, 433(6): 311 – 319.
- [9] WANG D, TANG Y T, HE J, et al. Generalized models to predict the lower heating value (LHV) of municipal solid waste (MSW). *Energy*, 2021, 216(4): 119279.
- [10] DHIMAN G, KUMAR V. Multi-objective spotted hyena optimizer: A multi-objective optimization algorithm for engineering problems. *Knowledge-Based Systems*, 2018, 150(6): 175 – 197.
- [11] JIA H M, XING Z K, SONG W L. Three dimensional pulse coupled neural network based on hybrid optimization algorithm for oil pollution image segmentation. *Remote Sensing*, 2019, 11(9): 1046 – 1069.
- [12] DHIMAN G, KUMAR V. Seagull optimization algorithm: Theory and its applications for large-scale industrial engineering problems. *Knowledge-Based Systems*, 2019, 165(2): 169 – 196.
- [13] LEI G, SONG H Q, RODRIGUEZ D. Power generation cost minimization of the grid-connected hybrid renewable energy system through optimal sizing using the modified seagull optimization technique. *Energy Reports*, 2020, 6(11): 3365 – 3376.
- [14] DHIMAN G, SINGH K K, SONI M, et al. MOSOA: A new multi-objective seagull optimization algorithm. *Expert Systems with Applications*, 2021, 167(4): 114150.

- [15] ZHANG Q F, LI H. MOEA/D: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on Evolutionary Computation*, 2007, 11(6): 712 – 731.
- [16] DAI C, WANG Y P. A new decomposition based evolutionary algorithm with uniform designs for many-objective optimization. *Applied Soft Computing*, 2015, 30(5): 238 – 248.
- [17] ZHANG X Y, ZHENG X T, CHENG R, et al. A competitive mechanism based multi-objective particle swarm optimizer with fast convergence. *Information Sciences*, 2018, 427(2): 63 – 76.
- [18] QI Y T, MA X L, LIU F, et al. MOEA/D with adaptive weight adjustment. *Evolutionary Computation*, 2014, 22(2): 231 – 264.
- [19] ZITZLER E, THIELE L. Multiobjective evolutionary algorithms: A comparative case study and the strength pareto approach. *IEEE Transactions on Evolutionary Computation*, 1999, 3(4): 257 – 271.
- [20] HOLLAND J H. *Adaptation in Natural and Artificial Systems*. Cambridge: MIT Press, 1975: 211 – 247.
- [21] FENG Y H, WANG G G, DONG J Y, et al. Opposition-based learning monarch butterfly optimization with gaussian perturbation for large-scale 0-1 knapsack problem. *Computers and Electrical Engineering*, 2018, 67(4): 454 – 468.
- [22] YAN Aijun, XIA Heng, LIU Xizhi. Development of semi-physical simulation platform for monitoring municipal solid waste incineration process. *Journal of System Simulation*, 2021, 33(6): 1427 – 1435. (严爱军, 夏恒, 刘溪芷. 城市生活垃圾焚烧过程监控半实物仿真平台研发. *系统仿真学报*, 2021, 33(6): 1427 – 1435.)
- [23] ZHOU P, GUO D W, CHAI T Y. Data-driven predictive control of molten iron quality in blast furnace ironmaking using multi-output LS-SVR based inverse system identification. *Neurocomputing*, 2018, 308(9): 101 – 110.
- [24] ZHANG Shuning, WANG Fuli, HE Dakuo, et al. Modeling method of online robust least-squares-support-vector regression. *Control Theory & Applications*, 2011, 28(11): 1601 – 1606. (张淑宁, 王福利, 何大阔, 等. 在线鲁棒最小二乘支持向量机回归建模. *控制理论与应用*, 2011, 28(11): 1601 – 1606.)
- [25] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multi-objective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 2002, 6(2): 182 – 197.
- [26] COELLO C A C, PULIDO G T, LECHUGA M S. Handling multiple objectives with particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, 2004, 8(3): 256 – 279.

作者简介:

严爱军 教授, 博士生导师, 目前研究方向为过程建模与控制、人工智能, E-mail: yanaijun@bjut.edu.cn;

胡开成 硕士研究生, 目前研究方向为工业过程建模、控制与优化, E-mail: HuKaicheng@emails.bjut.edu.cn.