

控制与决策

Control and Decision

基于自适应差分进化的常压塔轻质油产量多目标优化

丁进良, 陈佳鑫, 马欣然

引用本文:

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[J]. *控制与决策*, 2020, 35(3): 604–612.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2018.0794>

您可能感兴趣的其他文章

Articles you may be interested in

精英导向型差分变异多目标烟花算法及其在模拟集成电路设计中的应用

Elitist guided multi-objective fireworks algorithm with difference variation and its application in analog integrated circuits

控制与决策. 2020, 35(1): 55–64 <https://doi.org/10.13195/j.kzyjc.2018.0516>

基于自适应配对控制的多目标演化算法

Adaptive mating control based multiobjective evolutionary algorithm

控制与决策. 2018, 33(3): 392–402 <https://doi.org/10.13195/j.kzyjc.2017.0055>

自适应的非支配排序遗传算法

Adaptive non-dominated sorting genetic algorithm

控制与决策. 2018, 33(12): 2191–2196 <https://doi.org/10.13195/j.kzyjc.2017.1032>

一种基于进化知识融合的多目标人工蜂群算法

A multi-objective artificial bee colony based on evolutionary knowledge integrated

控制与决策. 2017, 32(12): 2176–2182 <https://doi.org/10.13195/j.kzyjc.2016.1322>

基于环境Pareto支配选择策略的有约束多目标差分进化算法

Differential evolution algorithm based on environment Pareto dominated selection strategy in constrained multi-objective optimization problem

控制与决策. 2016, 31(1): 45–51 <https://doi.org/10.13195/j.kzyjc.2014.1885>

基于动态学习策略的群集蜘蛛优化算法

Social spider optimization with dynamic learning strategy

控制与决策. 2015(9): 1575–1582 <https://doi.org/10.13195/j.kzyjc.2014.0853>

自适应局部图嵌入加权罚支持向量机

Adaptive local graph embedding weighted-penalty SVM

控制与决策. 2015(2): 203–214 <https://doi.org/10.13195/j.kzyjc.2014.0017>

多目标自适应混沌粒子群优化算法

Multi-objective adaptive chaotic particle swarm optimization algorithm

控制与决策. 2015, 30(12): 2168–2174 <https://doi.org/10.13195/j.kzyjc.2014.1869>

基于自适应差分进化的常压塔轻质油产量多目标优化

丁进良[†], 陈佳鑫, 马欣然

(东北大学 流程工业综合自动化国家重点实验室, 沈阳 110004)

摘要: 常压塔轻质油产量最大化是提高企业效益的重要途径之一. 为了适应市场需求和价格变化, 生产高需求与高价值的轻质油产品, 提出一种基于自适应差分进化的常压塔轻质油产量多目标优化算法. 该算法采用惩罚边界交叉法的分解方法, 在种群变异阶段引入择优学习算子来改进传统变异算子随机选取个体或者单纯选取最好个体的随机性和盲目性, 利用自适应策略逐渐改变交叉变异算子. 将改进算法应用于 3 种测试函数和实际炼油厂常压塔轻质油产量优化, 结果表明所提出的算法在测试函数上具有明显优势, 并能有效提高常压塔轻质油产量, 验证了所提算法的有效性.

关键词: 常压塔; 轻质油产量; 自适应差分进化; 惩罚边界交叉; 择优学习; 多目标优化

中图分类号: TE624

文献标志码: A

Multi-objective optimization of light oil production in atmospheric distillation column based on self-adaptive differential evolution

DING Jin-liang[†], CHEN Jia-xin, MA Xin-ran

(State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110004, China)

Abstract: Maximizing the production of light oil in atmospheric distillation column is one of the important ways to improve the benefit of enterprises. In order to adapt to the change of market demand and price, and to produce high-demand and high-value light oil, a multi-objective optimization algorithm for light oil production of atmospheric distillation column based on self-adaptive differential evolution is proposed. The algorithm adopts the decomposition method of the penalty boundary intersection method, and introduces the preferred learning operator in the stage of population mutation to decrease the randomness and blindness brought about by the random selection or the simple selection of the best individual by the traditional operator. The self-adaptive strategy is used to gradually change the crossover mutation operator. The improved algorithm is applied to three kinds of test functions and the actual refinery atmospheric distillation column light oil production optimization. The results show that the proposed algorithm has obvious advantages in testing functions and can effectively improve the atmospheric distillation column light oil production, which verifies the effectiveness of the proposed algorithm.

Keywords: atmospheric distillation column; light oil production; self-adaptive differential evolution; penalty boundary intersection; preferred learning; multi-objective optimization

0 引 言

常减压蒸馏是原油加工的第一道工序, 通过对原油进行加热、分馏、冷却等操作, 得到不同沸点范围的组分, 也被称为一次加工装置. 常压塔是常减压蒸馏中的核心装置, 主要作用是切割原油 350 °C 以前的馏分. 常压塔产品大体分为两种: 一种是从其顶部及侧线分离的轻质油品, 如汽油、柴油等; 另一种是从底部分离出的重质油品. 这些产品广泛应用于国防、工农业、航天、交通等领域.

根据市场对石油产品需求的不同, 对应的产品价格会上浮浮动. 一般而言, 汽油、柴油等轻质油比重质油具有更大的社会需求量, 且产品价格更高. 为了最大化轻质油产品产量, 炼油企业采用轻质油收率作为评价指标. 轻质油收率即轻质油产量(汽油、煤油、柴油、芳烃和化工轻油等)占原油和外购原料油加工量的百分比^[1]. 在原油进料加工量一定的情况下, 增加轻质油产量是迫切需要解决的问题, 也是提升企业

收稿日期: 2018-06-10; 修回日期: 2018-10-20.

基金项目: 国家自然科学基金项目(61590922, 61525302, 61621004).

责任编辑: 林崇.

[†]通讯作者. E-mail: jlding@mail.neu.edu.cn.

效益的重要手段之一。常减压蒸馏装置比二次装置加工比例大,而常压塔是常减压蒸馏中的产品分离装置,因此常压塔的轻质油产量对全厂轻质油收率影响很大。当前常压塔获得的轻质油产量较低,不能满足社会的需求,因此常压塔轻质油产量最大化的操作优化显得尤为重要。

关于常压塔操作优化及建模方面,国内外学者做了许多研究,其中文献[2]利用专家系统解决单目标优化问题,根据市场价格波动调整石油产品产量;文献[3]建立了常压塔的近似稳态模型,采用非支配排序遗传算法(NSGA-II)将产品质量、产品总馏出率、装置能耗等多个生产指标两两组合进行优化;文献[4]建立了专家系统,采用遗传算法根据产品价格优化产品产量;文献[5]采用支持向量回归方法建立模型,以最大化常压塔收益与总侧线收益为目标建立了两个优化模型;文献[6]建立常压塔混合模型,实现了高价值产品最大化和能耗最小化;文献[7]利用 aspen plus 流程模拟软件建立常压塔装置模型,利用序列二次规划(SQP)最大化产品利润,并最小化原料和能量消耗;文献[8]利用小波神经网络建立了初馏塔和常压塔模型,通过排队竞赛算法优化经济效益问题;文献[9]利用神经网络建立常减压装置模型,并采用 SQP 方法优化有效能效率。

现有常压塔装置操作优化研究大多对能量和利润建立单目标优化,而常压塔轻质油产量是一个多种类型轻质油产量的多目标优化问题,现有的方法难以解决,因此本文采用多目标优化方法对常压塔轻质油产量进行优化。多目标优化是一项具有挑战性的问题,其目标之间相互冲突,难以同时得到所有目标问题的最优解。而在实际炼油厂中,工艺指标难以在线测量,操作变量间具有强非线性、强耦合的特点,因此要求多目标算法具有较高的求解效率和多样性。目前,常减压装置操作优化中常用 NSGA-II 算法和 SQP 等方法,其中 NSGA-II 在二维和三维问题中效果良好,但是在高维问题中会因种群中个体互不支配而导致搜索性能呈指数级衰减^[10];而 SQP 因为需求解拉格朗日函数的二阶偏导数导致计算量大且复杂。因此这些算法不能有效求解常压塔复杂多目标优化问题。文献[11]提出一种基于分解技术的多目标进化算法(MOEA/D),研究表明该算法能够有效处理大规模高维多目标问题以及连续决策变量和复杂 Pareto 集问题。文献[12]基于 MOEA/D 的基本框架,提出了一种基于差分进化(DE)的 MOEA/D 算法(MOEA/D-

DE),实验结果表明 MOEA/D-DE 算法的性能在一定程度上优于 MOEA/D 和 NSGA-II。

基于以上问题,本文采用最大信息系数算法(MIC)^[13]选取操作变量,利用径向基函数(RBF)建立常压塔轻质油产量模型,并提出一种改进的自适应差分多目标优化算法。该方法采用基于惩罚的边界交叉法(PBI)进行分解操作,在种群变异更新阶段,在保留原有鲁棒性较强的 DE/rand/1 算子的同时引入择优学习策略,采用自适应策略根据进化情况逐渐改变变异算子,将算法用于3种标准测试函数集与实际常压塔中,实验结果表明该算法具有良好的收敛性和分布性。

1 常压塔工艺过程及模型建立

1.1 常压蒸馏过程描述

常减压蒸馏是石油的最初加工工序,而常压塔是常减压装置中最重要、操作最复杂、要求最精准的蒸馏塔。

如图1所示,常压塔的工艺流程描述如下:原油在常压炉中加热到 $360^{\circ}\text{C}\sim 370^{\circ}\text{C}$ 后通入常压塔底部。塔顶至塔底温度逐渐升高,塔内蒸汽从塔底逐板上升,液体由塔顶逐板下降,气液两相在塔板处相互接触,接触后液体部分汽化,气体部分冷凝。常压塔一共设有3个中段回流和3条侧线,分别为常顶循、常一中及常二中和常一线、常二线及常三线。中段回流用于回收塔内多余热量,均匀塔内负荷,其温度及流量直接影响塔顶和侧线产品的质量和产量。塔顶和侧线用于生产产品,分别为汽油、煤油、柴油及常压瓦斯油。常压塔塔底生产的重油经减压炉加热后进入减压塔进行减压蒸馏。

1.2 常压塔轻质油产量模型

常压塔是一个复合塔,按建模方式不同可分为机理模型、混合模型和数据模型。机理模型建立涉及4大平衡方程,需同时求解成千上万组线性和非线性方程组,目前的大部分机理模型不能精确描述实际生产过程对象。实际的生产过程中存在噪声干扰,低阶的神经网络能够缓解由噪声带来的过拟合问题,因此本文采用实际生产过程的数据,利用神经网络建立常压塔轻质油产量模型。这里需要说明的是,本文着重考虑轻质油中汽油、煤油和柴油的产量。

由于 RBF 具有良好的性能,可以映射任意复杂的非线性函数^[14],本文采取 RBF 建立常压塔产量模型。在决策变量选取方面,不同的决策变量建立的模

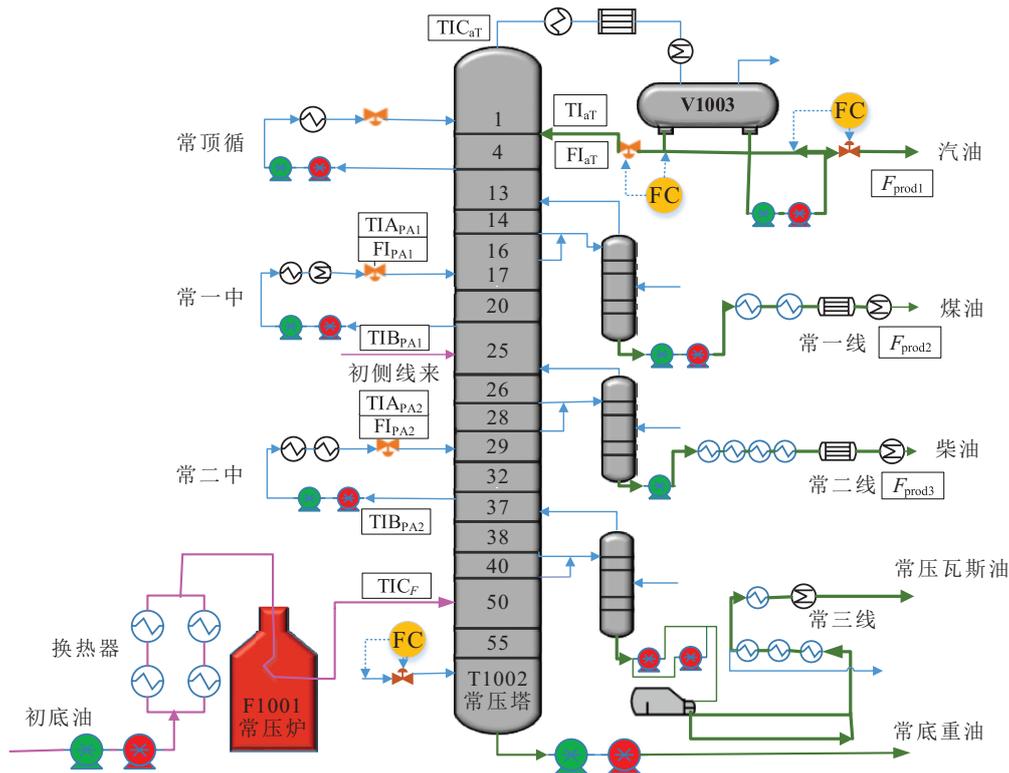


图1 常压蒸馏装置工艺流程

型其内含物理特性以及泛化能力不同,因此要选取合适的决策变量. 现有大多研究采用灵敏度分析或主元分析法,为了尽可能挖掘常压塔变量间的有用信息,充分揭示其内在联系,本文采用MIC法选择对目标产品产量影响较大的操作变量作为模型的决策变量. MIC法的优点在于能够充分地衡量不同函数类型变量之间的关系. 各决策变量对应的MIC值如表1所示.

表1 决策变量间MIC值

输入变量	相关系数MIC
常压炉出口温度 (TIC _F)	0.5652
常顶回流流量 (FI _{aT})	0.1562
常顶油抽出温度 (TIC _{aT})	0.4456
常顶油返回温度 (TI _{aT})	0.5906
常一中回流流量 (FI _{PA1})	0.2711
常一中返回温度 (TIA _{PA1})	0.2592
常一中抽出温度 (TIB _{PA1})	0.2499
常二中回流流量 (FI _{PA2})	0.2916
常二中返回温度 (TIA _{PA2})	0.2774
常二中抽出温度 (TIB _{PA2})	0.2123

实验采用某炼油厂500组实际生产数据,用处理后的前400组数据作为训练数据集,后100组数据作为检测数据集,采用均方根误差(RMSE)作为模型评价的性能指标,运行20次的RMSE平均值如表2所示,结果满足产量模型对精度的要求.

表2 常压塔不同产品产量模型的RSME值

产量类型	测试集均方根误差
常顶汽油产量 (F _{prod1})	0.02707
常一线煤油产量 (F _{prod2})	0.03001
常二线柴油产量 (F _{prod3})	0.04911

2 基于PBI的自适应差分多目标优化算法

2.1 惩罚边界交叉法(PBI)原理

文献[12]提出了一种基于差分进化的分解多目标MOEA/D-DE优化算法,其主要思想是采用分解方法将多目标优化问题分解成多个子问题,通过优化每一个子问题得到原问题的最优解. MOEA/D-DE算法中更新范围及新个体产生公式如下:

$$P = \begin{cases} B(i), & \text{rand} < \delta; \\ \{1, \dots, N\}, & \text{otherwise.} \end{cases} \quad (1)$$

变异产生新个体

$$\bar{y}_k = \begin{cases} x_k^{r1} + F(x_k^{r2} - x_k^{r3}), & \text{probability} = \text{CR}; \\ x_k^{r1}, & \text{probability} = 1 - \text{CR}. \end{cases} \quad (2)$$

$$y_k = \begin{cases} \bar{y}_k + \sigma_k(b_k - a_k), & \text{probability} = p_m; \\ \bar{y}_k, & \text{probability} = 1 - p_m. \end{cases} \quad (3)$$

$$\sigma_k = \begin{cases} (2 \times \text{rand})^{\frac{1}{\eta+1}} - 1; \\ 1 - [2(1 - \text{rand})]^{\frac{1}{\eta+1}}. \end{cases} \quad (4)$$

式(1)中,对每一个 $i = 1, \dots, N$, 设 $B(i) = \{i_1, \dots, i_T\}$, 其中 $\lambda^{i_1}, \dots, \lambda^{i_T}$ 为离 λ^i 最近的 T 个权重向量; δ 为父代解从邻居解中选取的概率; N 为子问题的个数. 式(2)中, F 为步长缩放因子; CR 为交叉变异率; 令 $r_1 = i$, 随机从 P 中选取两个指数 r_2 和 r_3 , 用 DE 算子产生个体 \bar{y} , \bar{y}_k 是 $\bar{y} = (\bar{y}_1, \dots, \bar{y}_n)$ 中第 k 个元素; x^{r_1} 、 x^{r_2} 和 x^{r_3} 是随机选择的3个父代个体, x_k^i 为 $x^i = (x_1^i, \dots, x_n^i)$ 中的元素. 式(3)和(4)为多项式变异, p_m 为变异率; σ_k 为扰动因子; η 为分配参数, 是一个用户自定义的任意非负实数; b_k 和 a_k 为决策变量中第 k 个元素的上限和下限范围.

MOEA/D-DE算法通过聚合方法得到函数值来评价新个体的好坏,因此针对不同多目标问题要选择合适的聚合方法. 常用的聚合方法有3种: 权重求和法(WS)、切比雪夫法(TCH)以及边界交叉法(BI). 其中: WS 不适用非凸的 Pareto 最优向量; TCH 针对连续多目标问题求解出的 Pareto 前沿面(PF)不够平滑; BI 能够处理非凸问题, 但因其需要求解等式约束, 增加了计算的复杂度. 在 BI 的基础上引入惩罚项的方法称为 PBI, 当权重向量规模不大的时候, PBI 获得的 PF 较 TCH 更为均匀. 因此, 针对常压塔这类复杂实际工业问题, 采取 PBI 分解方法能更好地逼近 PF. PBI 的具体表达如下:

$$\begin{aligned} \min g^{pbi}(x|\lambda, z^*) &= d_1 + \theta d_2; \\ d_1 &= \frac{\|z^* - F(x)^T \lambda\|}{\|\lambda\|}, \\ d_2 &= \|F(x) - (z^* - d_1 \lambda)\|. \end{aligned} \quad (5)$$

其中: g^{pbi} 是通过 PBI 聚合方法所得的函数值; z^* 是更新过程中的参考点; $F(x)$ 是目标函数值; d_1 是 z^* 与 y 之间的距离, 代表收敛性信息; d_2 是 $F(x)$ 与 L 之间的距离, 代表分布性信息; θ 是预先设置的惩罚参数, $\theta > 0$; λ 是权重向量. PBI 的说明如图2所示, 其中直线 L 为一条沿着权重向量 λ 方向并经过参考点 z^* 的直线, y 为 $F(x)$ 在直线 L 上的映射.

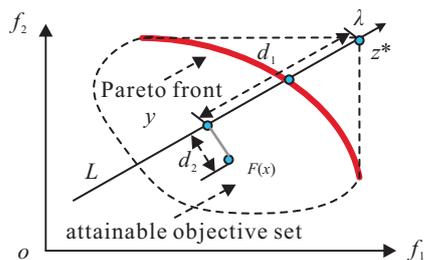


图2 惩罚交叉边界法

2.2 择优学习策略

在 MOEA/D-DE 算法的差分变异过程中, 只采用了鲁棒性较强的 $DE/rand/1$ 算子^[15]. 然而, 不同算子具有不同特性, 适应于不同问题. 而实际常压塔操作变量可行域广, 目标空间范围大. 若只采用随机个体信息, 可能很难在求解过程中得到良好的前沿面, 且无法得到最优解, 并使收敛速度变慢. 为解决上述问题, 在差分变异阶段引入择优学习策略.

基于择优学习的差分变异算子并不是随机选取个体或者单纯选取最好的个体, 而是选择比当前个体性能好的个体 X_{better} 进行学习. 这种方法能在一定程度上避免进化的随机性和盲目性. 将这种差分变异算子应用到 MOEA/D-DE 框架中, 在 MOEA/D-DE 邻居解更新阶段, 每一个邻居个体都将得到一个由分解策略产生的近似函数值, 对邻居解得到的函数值进行降序排列, 随机选择性能比当前个体优异的个体进行学习. 设性能最差的个体为个体 1, 性能最优的为个体 N . 对于个体 1 而言, 它可以向 $2 \sim N$ 的个体进行学习; 对于个体 2 而言, 它的学习范围是 $3 \sim N$. 以此类推, 个体 i 的学习范围为 $i + 1 \sim N$, 可以学习个体的数量为 $N - i$. 通过这种方法指引种群进化的方向, 能够增加种群的多样性. 下式给出了择优学习的差分算子:

$$V_{i,g} = X_{i,g} + F(X_{better} - X_{i,g}). \quad (6)$$

其中: X_{better} 为较好个体, $X_{i,g}$ 为当前个体, F 为步长缩放因子.

2.3 自适应策略

差分进化变异过程中, 不同的变异策略适合不同特性的优化问题, 而传统的差分进化只有单一的向量产生策略, 没有根据优化问题按需分配变异策略. 针对实际常压塔产量优化问题, 引入一种自适应策略. 自适应策略的优点是可以根据种群进化的情况自动选择差分变异算子, 提升种群的多样性. 本文采用 $DE/rand/1$ 算子和择优学习算子. 其中, $DE/rand/1$ 在处理多峰问题时具有较强的鲁棒性, 而择优学习算子在一定程度上能保证进化个体的质量, 融入这两种算子的自适应策略能够在一定程度上保持种群的多样性和收敛性.

$DE/rand/1$ 的具体表达式为

$$V_{i,g} = X_{r_1} + F(X_{r_2} - X_{r_3}). \quad (7)$$

其中: X_{r_1} 、 X_{r_2} 和 X_{r_3} 为3个随机选择的父代个体, F

为步长缩放因子.

更新产生的新个体为

$$V_{i,g} = \begin{cases} X_{i,g} + F(X_{\text{better}} - X_{i,g}), & \text{rand} < p; \\ X_{r_1} + F(X_{r_2} - X_{r_3}), & \text{otherwise.} \end{cases} \quad (8)$$

其中:rand是[0,1]之间的均匀随机数,变异算子 $V_{i,g}$ 的选择由

$$p = \frac{\text{sn}_1(\text{sn}_2 + \text{fn}_2)}{\text{sn}_2(\text{sn}_1 + \text{fn}_1) + \text{sn}_1(\text{sn}_2 + \text{fn}_2)} \quad (9)$$

计算出的参数 p 进行控制.

p 值通过学习过程确定,初始值设为0.5,在评估邻居解后,由式(6)或(7)产生并成功进入下一代的后代数量分别记为 sn_1 和 sn_2 ,被下一代淘汰的数量分别记为 fn_1 和 fn_2 .这两组数据通过50代的进化逐渐产生,这50代称为学习阶段^[16].每一个学习阶段的 p 更新后, sn_1 、 sn_2 、 fn_1 和 fn_2 的值会被重置.在式(8)中, sn_1 的大小影响 p 值的大小,而 p 值影响变异算子选择,通过 p 值变化自适应选择变异算子.当由式(6)产生并成功进入下一代的数量 sn_1 变大时, p 值随之增大,因此交叉变异选择式(6)算子的概率也随之增加,反之亦然.

2.4 MOEA/D-SADE算法流程

将基于PBI分解方法的自适应差分进化多目标优化算法称为MOEA/D-SADE,相应的算法流程如下.

step 1: 种群初始化. 设置初始化参数,种群大小 N ,每个权重向量邻居向量数 T ,父代个体选择邻居个体的可能性 δ ,被子代取代的最大数量 n_r .

step 1.1: 通过欧氏距离确定每个权重向量的 T 个邻居向量, $i = 1, \dots, N, B(i) = \{i_1, \dots, i_T\}$.

step 1.2: 在决策空间内随机产生规模为 N 的初始种群 P . 设 $FV^i = F(x^i)$, FV^i 是 x^i 的函数值. 初始化参考点 $z, z = (z_1, \dots, z_m), z_j = \min_{1 \leq i \leq N} f_j(x^i)$.

step 2: 种群更新过程, $i = 1, \dots, N$.

step 2.1: 根据式(1)选择种群更新范围.

step 2.2: 设 $r_1 = i$,在 P 中随机选取两个数 r_2 、 r_3 . 如果 $i = 1$,则令 $p = 1$;否则转入step 2.3.

step 2.3: 将每个子问题的 T 个邻居个体按照 g^{pbi} 进行降序排序,并随机选出对于每个个体的较优个体 X_{better} . 根据式(9)经参数 p 控制,通过式(8)的自适应差分进化产生变异个体. 按照式(2)~(4)的多项式变异经参数 p_m 控制产生子代 y .

step 2.4: 对子代 y 进行修正并更新参考点 z . 如果 y 值超出了 Ω , y 值会在可行范围内随机重置. 若

$z_j > f_j(y)$,则 $z_j = f_j(y), j = 1, \dots, m, m$ 为目标数.

step 2.5: 更新邻居个体,设 $c = 0$:

1) 如果 $c = n_r$ 或者 P 为空集,则转入step 3;否则,从 P 中随机选取指数 j .

2) 判断是否满足 $g^{\text{pbi}}(y|\lambda^j, z) \leq g^{\text{pbi}}(x^j|\lambda^j, z)$. 若满足,则 $x_j = y$ 且 $FV^j = F(x^j), c = c + 1$;否则,不替换.

3) 从 P 中去除 j ,转入step 1.

step 3: 判断是否满足算法终止条件. 若满足,则停止;否则,转入step 2.

MOEA/D-SADE算法的流程如图3所示.

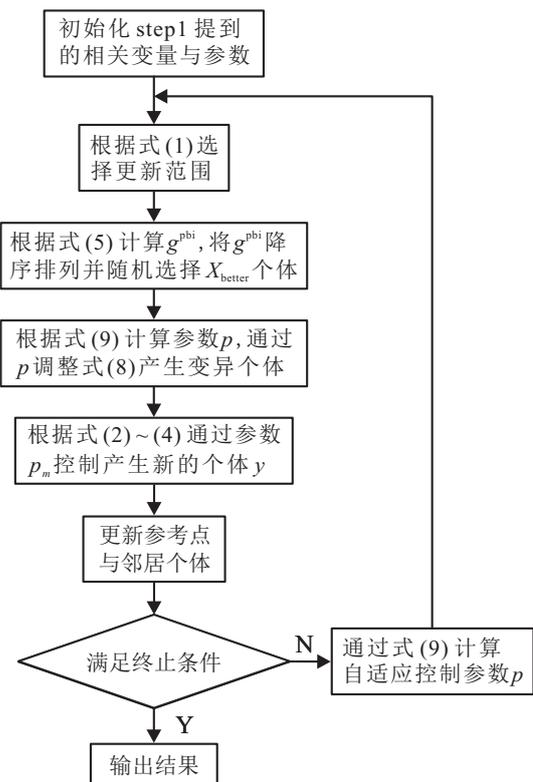


图3 MOEA/D-SADE的算法流程

2.5 标准测试函数测试

本文主要针对目标数为2和3的多目标问题进行测试,根据所求解问题的特性选取3组不同性质的标准测试函数. 第1组为DTLZ^[17]系列函数,用于测试优化后的Pareto前沿面的性能;第2组为两目标测试函数ZDT^[18];第3组为Pareto解集相对规整的一套测试函数F1~F9^[12].

为了验证改进算法MOEA/D-SADE的有效性,将改进算法与MOEA/D-DE进行对比. 两种算法的参数设置如下:交叉变异率CR为0.5,步长缩放因子 F 为0.5,多项式变异分配系数 η 为20,多项式变异率 p_m 为 $1/n$ (n 为决策变量个数),每个向量的邻居个体个数 T 为 $0.1N$ (N 为种群规模),父代选择邻居个体的

可能性 δ 为0.9,子代替代的最大数量 n_r 为2,控制参数 p 初值为0.5. DTLZ系列函数两种算法均取种群规模 N 为300,目标数 M 为3,决策变量数 n 为10,最高评价次数FEAS为75 000; ZDT系列函数两种算法种群规模均取 N 为100,目标数 M 为2,最高评价次数FEAS为25 000,其中ZDT1至ZDT3的 n 为30,ZDT4和ZDT6的 n 为10;F系列函数的种群规模 N 为300,决策变量数 n 为10,最高评价次数FEAS为150 000,除了F6的目标数 M 为3之外,其余函数的 M 为2.

采用IGD^[19]来评价算法的逼近、分布及延展性能. IGD值越小,算法获得的近似Pareto前沿面的收敛性和多样性越好. IGD计算如下:

$$IGD(P^*, P) = \frac{\sum_{\nu \in P^*} d(\nu, P)}{|P^*|}. \quad (10)$$

表3列出了两种算法在DTLZ、ZDT以及F标准测试集函数的IGD评价指标的平均值(mean)、最小值(min)以及标准差(std). 由表3可得,在18个MOP测试函数上,MOEA/D-SADE在12个测试函数上获得了更好的IGD平均值,在12个测试函数上获得了更好的IGD最小值. 以几个函数为例进行说明,改进算法在三目标凹形多模态DTLZ3函数上与MOEA/D-DE的均值和最小值相比相差1.20e-02,明显优于MOEA/D-DE对比算法,而DTLZ3算法能够测试算法收敛到全局Pareto最优边界的能力,表明改进算法具有较好的收敛性能. 在DTLZ4函数中,改进算法的最小值明显优于对比算法,而DTLZ4能够测试算法保持解的分布能力,表明改进算法具有较好的分布性. 在两目标多模态ZDT4函数上,改进算法虽然在均值上略次于对比算法MOEA/D-DE,但其最小值和标准差均明显优于对比算法,表明改进算法能够较好处理多峰问题. 在F系列函数中,两目标F1、F2、F3、F5等函数均明显优于MOEA/D-DE. 以F5函数为例进行说明,F5函数是一个两目标,具有凸形PF形状的测试函数,改进算法所得的最小值相比于MOEA/D-DE相差0.57e-03,表明改进算法有更好的收敛性、分布性和鲁棒性. 从F系列函数整体来看,改进算法效果优于MOEA/D-DE. 然而,改进算法在少数测试函数效果较不理想,原因可能是算法在初期时容易陷入局部最优. 综上所述,MOEA/D-SADE算法在3种测试函数集中均获得了较好的结果,具有良好的收敛性和分布性,并且在大部分函数上较MOEA/D-DE有较为明显的优势,表明改进策略的有效性.

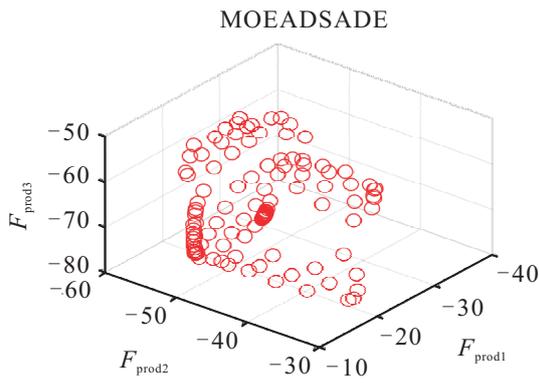
表3 对比算法在ZDT、DTLZ、F测试函数20次运行结果IGD值

MOP	MOEA/D-SADE			MOEA/D-DE		
	mean	min	std	mean	min	std
DTLZ1	1.59e-02	1.12e-02	1.71e-02	1.50e-02	1.50e-02	0
DTLZ2	3.78e-02	3.78e-02	0	3.79e-02	3.79e-02	0
DTLZ3	4.40e-02	4.40e-02	0	5.60e-02	5.60e-02	0
DTLZ4	4.30e-02	2.41e-02	2.54e-02	4.30e-02	3.96e-02	3.61e-03
ZDT1	3.73e-02	1.56e-02	1.05e-02	3.43e-02	1.38e-02	2.26e-02
ZDT2	1.27e-01	1.99e-02	1.70e-01	2.01e-01	2.38e-01	1.53e-02
ZDT3	4.17e-02	2.02e-02	1.56e-02	7.80e-02	1.81e-02	8.32e-02
ZDT4	5.30e-01	1.46e-01	1.99e-01	4.69e-01	1.83e-01	2.48e-01
ZDT6	3.12e-03	3.10e-03	0	4.82e-03	3.10e-03	6.70e-03
F1	1.54e-03	1.52e-03	0	1.54e-03	1.53e-03	0
F2	2.36e-03	2.00e-03	2.67e-04	2.37e-03	2.00e-03	6.62e-04
F3	2.18e-03	1.74e-03	4.52e-04	2.40e-03	1.78e-03	1.01e-03
F4	7.49e-03	1.78e-03	1.16e-02	6.27e-03	1.75e-03	1.20e-02
F5	6.46e-03	3.04e-03	2.38e-03	6.51e-03	3.61e-03	2.94e-03
F6	6.13e-02	4.52e-02	1.29e-02	6.65e-02	4.26e-02	1.31e-02
F7	4.24e-02	1.63e-03	3.17e-02	1.82e-03	1.64e-03	1.02e-04
F8	8.39e-02	2.00e-03	7.95e-02	5.71e-02	2.05e-03	7.49e-02
F9	2.85e-03	2.22e-03	4.52e-04	2.96e-03	2.15e-03	7.91e-04

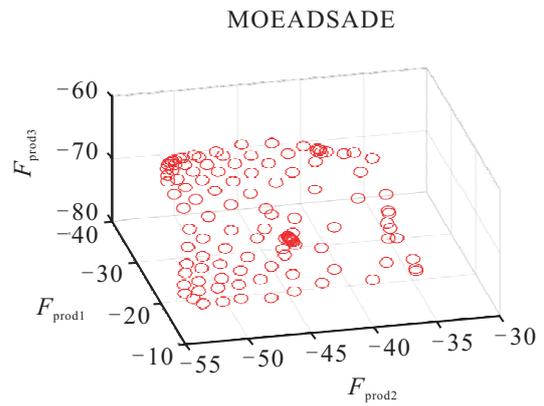
3 常压塔轻质油产量多目标运行优化

为了更好地适应市场需求和价格波动,应制定合理的常压塔轻质油生产方案实现轻质油产量最大化. 以我国某大型石化厂为例,选取该厂常压塔实际生产过程中的数据建立常压塔产量模型,利用MIC法选取与常压塔产量有较强相关性的常压炉出口温度、常顶回流流量等10个变量作为输入变量,具体输入变量如表1所示. 应用改进算法和SMPSO、MOEA/D、NSGA-II算法来优化常顶汽油产量、常一线煤油产量及常二线柴油产量,并进行对比.

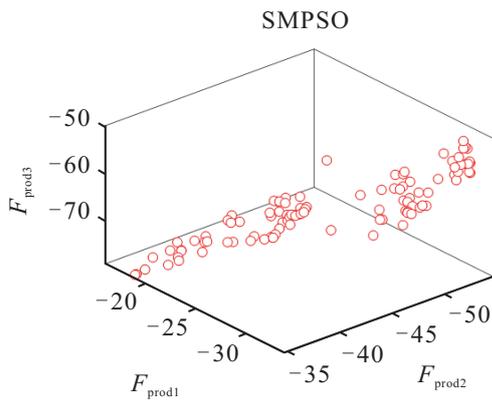
实验参数设置如下:循环代数分别为500和800,交叉变异率为0.5,步长缩放因子为0.5,多项式变异分配系数为20,父代选取邻居解的可能性为0.9,子代替代的最大数量为2. 4种算法的PF如图4所示. 在相同条件下,当种群进化到500代时,MOEA/D-SADE算法、SMPSO算法和MOEA/D算法的优化结果在PF上分布范围广,表明这3种算法所得结果分布性较好. 当种群进化至800代时,4种算法的优化效果都有提升,而MOEA/D-SADE的PF分布效果的优化更加明显,说明MOEA/D-SADE算法的搜索能力强.



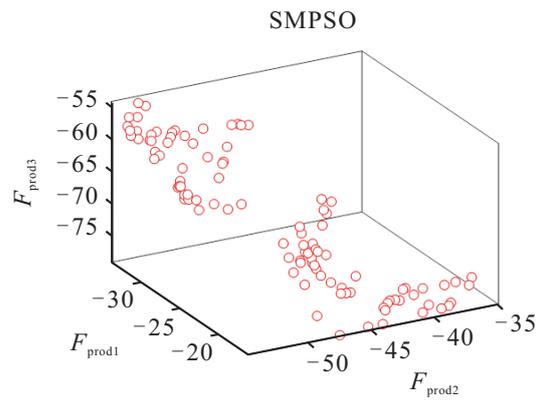
(a) 500代MOEADSADE算法的PF



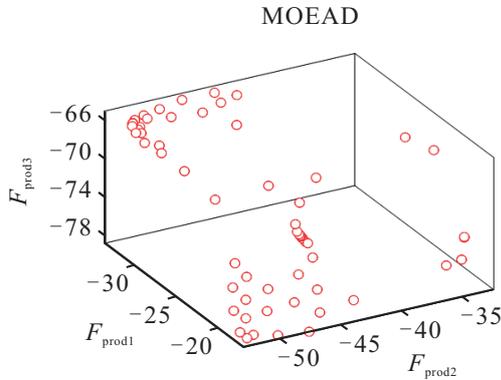
(b) 800代MOEADSADE算法的PF



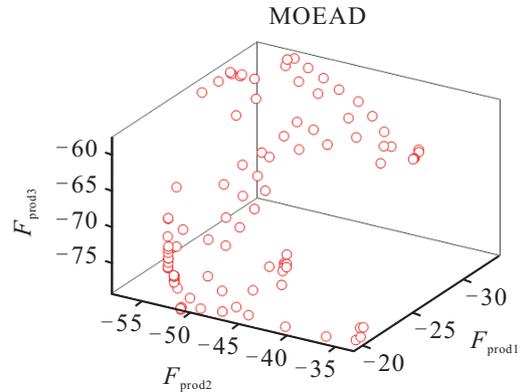
(c) 500代SMPSO算法的PF



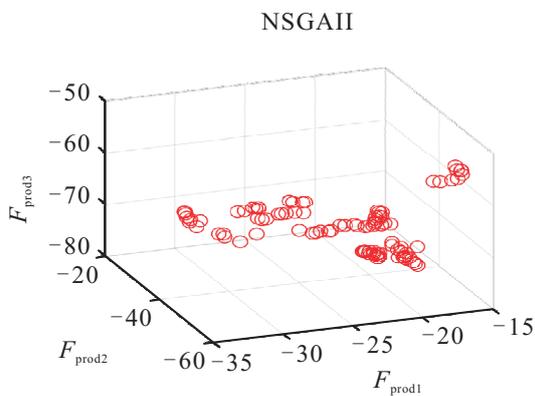
(d) 800代SMPSO算法的PF



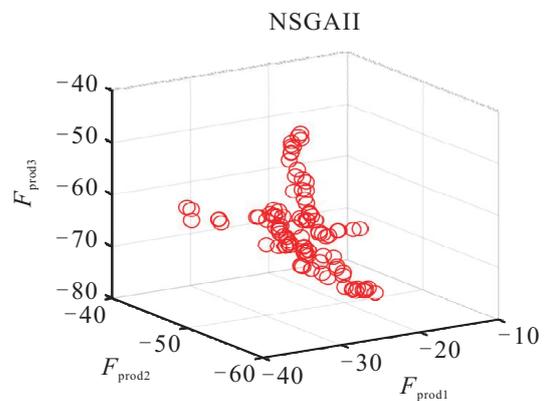
(e) 500代MOEAD算法的PF



(f) 800代MOEAD算法的PF



(g) 500代NSGAI算法的PF



(h) 800代NSGAI算法的PF

图4 4种算法对应的常压塔轻质油产量的PF

常压蒸馏过程产量优化问题无法获得其真实的PF,因此采用超体积指标(HV)^[20]来评价常压塔优化的多样性及收敛性. HV的计算公式如下:

$$HV(P) = \{ \bigcup \text{vol}(\nu) | \nu \in P \}. \quad (11)$$

表4给出了MOEA/D-SADE、SMP SO、MOEA/D和NSGA-II这4种算法的常压塔模型HV计算结果.从表4可以得出,HV指标由大到小分别为MOEA/D-SADE、SMP SO、MOEA/D、NSGA-II,而HV值越大,代表算法具有更好的收敛性和分布性.由此可得,MOEA/D-SADE算法性能较好.

表4 4种算法对应的常压塔轻质油产量HV值

算法	MOEA/D-SADE	SMP SO	MOEA/D	NSGA-II
HV	0.56	0.51	0.48	0.39

表5给出了4种算法MOEA/D-SADE、SMP SO、MOEA/D和NSGA-II操作变量的优化结果.这里需要指出的是,为了方便实际生产中阀门操作,常顶油抽出温度与常顶油返塔温度换算为常顶循温度差,常一中抽出温度与常一中返塔温度换算为常一中温度差,常二中抽出温度与常二中返塔温度换算为常二中温度差.以常压炉总出口温度为例,经MOEA/D-SADE优化后常压炉总出口温度调整范围的最

小值为350℃,最大值为367.5880℃,调整范围为17.5880℃;而经SMP SO、MOEA/D和NSGA-II优化的常压炉总出口温度调整范围分别为9.0261℃、17.2570℃和14.5098℃.MOEA/D-SADE的操作变量优化范围明显增大,表明算法能够搜索到更大空间.4种算法优化产生的常顶最大产量分别为33.8848 t/h、30.9298 t/h、28.0468 t/h和33.8187 t/h.MOEA/D-SADE算法求解所得的常顶最大产量明显优于其他3种算法.MOEA/D-SADE算法优化产生的常二线最大产量为79.2089 t/h,相比于其他算法,常顶和常二线能达到的最大产量明显变大.常一线最大产量虽略低于SMP SO算法优化后的产量,但是明显好于MOEA/D和NSGA-II算法优化所得的产量.由此可得,MOEA/D-SADE优化决策变量范围明显变大,决策者有更大的范围可以调整决策变量,可以得到更高的常顶、常一线和常二线的轻质油产量.例如,当前常顶、常一及常二线产量为30 t、55 t和70 t,经改进算法优化后产量可达到31 t、56 t和71 t.

综上所述,本文提出的MOEA/D-SADE可以用于实际优化问题,增大操作变量调整范围并提高轻质油产品的最大产量.改进算法MOEA/D-SADE的性能优异,具有良好的多样性和收敛性.

表5 4种算法操作变量优化结果及轻质油产量

变量和目标值	MOEA/D-SADE		SMP SO		MOEA/D		NSGA-II	
	min	max	min	max	min	max	min	max
常压炉总出口温度/℃	350.0000	367.5880	350.0000	359.0261	350.0000	367.2570	350.0000	364.5098
常顶回流流量/(t/h)	144.7802	200.4242	144.7802	200.4242	144.7802	195.8616	144.7802	170.2894
常一中回流流量/(t/h)	86.5956	179.5484	86.5956	179.5484	86.5956	179.5484	109.7596	179.5484
常二中回流流量/(t/h)	10.0000	36.6591	10.0000	30.6410	10.00	24.9429	10.0000	29.4516
常顶循温度差/℃	20.8196	37.9605	20.8196	34.2193	20.8196	30.0589	20.8196	37.9605
常一中温度差/℃	49.8412	86.0971	62.8427	86.0971	49.8412	86.0971	49.8412	64.6634
常二中温度差/℃	3.0508	22.0669	3.0508	22.0669	3.0508	21.3911	3.0508	22.0669
常顶产量/(t/h)	17.4307	33.8848	17.5500	30.9298	17.8232	28.0468	16.7037	33.8187
常一线产量/(t/h)	32.7804	57.6639	33.0982	57.9634	32.7789	53.4990	35.9588	54.3427
常二线产量/(t/h)	58.7392	79.2089	54.2316	79.1102	64.9441	78.9603	56.7125	79.2023

4 结论

本文利用最大信息系数法选取操作变量,选择鲁棒性较强的径向基神经网络建立了常压塔产量的优化模型,并提出了一种能够有效提高算法收敛性和多样性的基于分解的自适应差分进化多目标优化算法.采用PBI的分解方法,在种群交叉变异阶段,引入择优学习算子,根据种群更新进化情况自适应选择变

异交叉算子.与MOEA/D-DE算法在DTLZ、ZDT和F系列测试问题上进行仿真对比,并用于实际常压塔产量模型与几种常用算法进行对比,实验结果表明MOEA/D-SADE具有良好的多样性和收敛性,能够很好地解决实际常压塔优化决策问题,有效地提高常压塔轻质油产品产量,增大操作变量的调整空间,为复杂工业操作优化提供了一种新的优化方法.

进一步可能的研究方向包括: 1) 基于数据和机理混合方法建立产量模型; 2) 研究适用于生产过程动态变化的动态优化算法。

参考文献(References)

- [1] 曹春燕. 优化原油加工轻质油收率的探索[D]. 天津: 天津大学化工学院, 2012.
(Cao C Y. Exploration in the optimizing of crude oil processing and improving the yield of light oil[D]. Tianjin: School of Chemical Engineering and Technology, Tianjin University, 2012.)
- [2] Liao C K, Yang C K, Tsai M T. Expert system of a crude oil distillation unit for process optimization using neural networks[J]. *Expert Systems with Applications*, 2004, 26(2): 247-255.
- [3] Inamdar S V, Gupta S K, Saraf D N. Multi-objective optimization of an industrial crude distillation unit Using the elitist non-dominated sorting genetic algorithm[J]. *Chemical Engineering Research & Design*, 2004, 82(5): 611-623.
- [4] Motlaghi S, Jalali F, Ahmadabadi M N. An expert system design for a crude oil distillation column with the neural networks model and the process optimization using genetic algorithm framework[J]. *Expert Systems with Applications*, 2008, 35(4): 1540-1545.
- [5] Yao H, Chu J. Operational optimization of a simulated atmospheric distillation column using support vector regression models and information analysis[J]. *Chemical Engineering Research and Design*, 2012, 90(12): 2247-2261.
- [6] Mahalec V, Sanchez Y. Inferential monitoring and optimization of crude separation units via hybrid models[J]. *Computers & Chemical Engineering*, 2012, 45: 15-26.
- [7] More R K, Bulasara V K, Uppaluri R, et al. Optimization of crude distillation system using aspen plus: Effect of binary feed selection on grass-root design[J]. *Chemical Engineering Research and Design*, 2010, 88(2): 121-134.
- [8] Wu W, Hsieh C L, Shi B, et al. Plantwide control for optimal operation of industrial-scale crude distillation unit processes[J]. *Chemical Engineering Communications*, 2018, 205(5): 581-595.
- [9] Osuolale F N, Zhang J. Thermodynamic optimization of atmospheric distillation unit[J]. *Computers & Chemical Engineering*, 2017, 103: 201-209.
- [10] Jaskiewicz A. On the performance of multiple-objective genetic local search on the 0/1 knapsack problem-a comparative experiment[J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(4): 402-412.
- [11] Zhang Q, Li H. MOEA/D: A multiobjective evolutionary algorithm based on decomposition[J]. *IEEE Transactions on Evolutionary Computation*, 2007, 11(6): 712-731.
- [12] Li H, Zhang Q. Multiobjective optimization problems with complicated Pareto sets, MOEA/D and NSGA-II[J]. *IEEE Transactions on Evolutionary Computation*, 2009, 13(2): 284-302.
- [13] Reshef D N, Reshef Y A, Finucane H K. Detecting novel associations in large data sets[J]. *Science*, 2011, 334(6062): 1518-1524.
- [14] Jin R, Chen W, Simpson T W. Comparative studies of metamodelling techniques under multiple modelling criteria[J]. *Structural & Multidisciplinary Optimization*, 2015, 23(1): 1-13.
- [15] Tang L, Dong Y, Liu J. Differential evolution with an individual-dependent mechanism[J]. *IEEE Transactions on Evolutionary Computation*, 2015, 19(4): 560-574.
- [16] Yang Z, Tang K, Yao X. Self-adaptive differential evolution with neighborhood search[C]. *Evolutionary Computation*. Hong Kong: IEEE, 2010: 1110-1116.
- [17] Deb K, Thiele L, Laumanns M, et al. Scalable multi-objective optimization test problems[C]. *Proceedings of the 2002 Congress on Evolutionary Computation*. Honolulu: IEEE, 2002: 825-830.
- [18] Zitzler E, Deb K, Thiele L. Comparison of multiobjective evolutionary algorithms: Empirical results[J]. *Evolutionary Computation*, 2000, 8(2): 173-195.
- [19] Zitzler E, Thiele L, Laumanns M, et al, Fonseca VGD. Performance assessment of multiobjective optimizers: An analysis and review[J]. *IEEE Transactions on Evolutionary Computation*, 2003, 7(2): 117-132.
- [20] Bader J, Zitzler E. HypE: An algorithm for fast hypervolume-based many-objective optimization[J]. *Evolutionary Computation*, 2014, 19(1): 45-76.

作者简介

丁进良(1976—), 男, 教授, 博士生导师, 从事复杂工业过程智能建模与优化控制等研究, E-mail: jlding@mail.neu.edu.cn;

陈佳鑫(1994—), 女, 硕士生, 从事复杂工业过程建模与优化的研究, E-mail: chenjiaxin1934@qq.com;

马欣然(1992—), 女, 硕士生, 从事复杂工业过程建模与优化的研究, E-mail: 844101263@qq.com.

(责任编辑: 齐 霖)