

## 基于动态层次分析的自适应多目标粒子群优化算法及其应用

夏立荣<sup>1</sup>, 李润学<sup>1</sup>, 刘启玉<sup>1,2</sup>, 耿志强<sup>1</sup>

(1. 北京化工大学 信息科学与技术学院, 北京 100029; 2. 浙江大学 宁波理工学院, 浙江 宁波 315110)

**摘要:** 提出一种基于动态层次分析的自适应多目标粒子群优化算法, 利用模糊一致矩阵层次分析法选取全局最优粒子, 保证进化方向的合理性和客观性. 在进化过程中对种群状态进行客观度量, 自适应更新种群的权重和学习因子等重要参数, 使种群进化具有自我调节能力. 将提出的算法分别应用于标准多目标测试函数、PID控制器参数优化和甲醇转化烃类物质的工业过程模型辨识中, 通过与其他算法的对比说明了所提出算法的有效性和可行性.

**关键词:** 多目标粒子群; 模糊决策; 模糊一致矩阵; 层次分析; PID控制

中图分类号: TP18

文献标志码: A

## An adaptive multi-objective particle swarm optimization algorithm based on dynamic AHP and its application

XIA Li-rong<sup>1</sup>, LI Run-xue<sup>1</sup>, LIU Qi-yu<sup>1,2</sup>, GENG Zhi-qiang<sup>1</sup>

(1. College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China; 2. Ningbo Institute of Technology, Zhejiang University, Nibong 315110, China. Correspondent: GENG Zhi-qiang, E-mail: gengzhiqiang@mail.buct.edu.cn)

**Abstract:** An adaptive multi-objective particle swarm optimization (APSO) algorithm based on dynamic analytic hierarchy process (AHP) is proposed. The fuzzy consistent matrix is used to select the global best particle, which ensures the right direction of particle evolution, and the evolution state is measured to adjust the weight and learn coefficients adaptively. Well-known benchmark functions are used to test the performance of the proposed algorithm, and its diversity and convergence are compared with other algorithms. The results show that the proposed algorithm has better performance in global search, and the diversity and convergence are better as well. At the same time, by applying the proposed method to the challenging PID controller tuning and process model identification of the conversion of methanol to hydrocarbons, the comparison with other algorithms verify the effectiveness and feasibility of the proposed algorithm.

**Keywords:** multi-objective particle swarm optimization; fuzzy decision; fuzzy consistent matrix; analytic hierarchy process; PID control

### 0 引言

现实生活中优化问题通常由多个目标组成, 并且目标之间是互相矛盾的, 难以同时达到最优, 因此不同的决策者在对同一问题进行决策时, 往往根据自身对不同目标的偏好程度进行目标之间的权衡, 从而导致不同决策者确定的最终解不同, 这就需要在求解多目标优化问题时, 根据需要获得一组最优解, 以满足不同决策者的要求.

粒子群算法<sup>[1]</sup>是一种智能优化算法, 其最初只是作为一种单目标优化算法被提出, 由于单目标算法无

法满足多目标优化的需要, 因此需要拓展为多目标优化算法. 基于生物进化的智能算法, 由于其隐含的并行性, 在一次进化中可以得到多组解, 非常适合于求解多目标优化问题, 已被广泛用于电力、能源、工业控制等领域<sup>[2-4]</sup>.

Sierra等<sup>[5]</sup>全面总结并提出, 将粒子群算法由单目标发展为多目标时需要解决以下3个问题: 1) 如何构建非支配解; 2) 进化过程中如何选取最优粒子; 3) 如何保持 Pareto 前沿上解的多样性和分布性.

在基于微粒群的多目标进化算法研究中, Hu

收稿日期: 2013-10-09; 修回日期: 2014-01-14.

基金项目: 国家自然科学基金项目(61374166); 教育部博士点基金项目(20120010110010); 宁波市自然科学基金项目(2012A610001).

作者简介: 夏立荣(1980-), 女, 博士生, 从事过程建模与优化的研究; 耿志强(1973-), 男, 教授, 博士生导师, 从事过程建模与优化等研究.

等<sup>[6]</sup>通过计算微群间的距离进行个体最优粒子的选取,并对各个目标进行逐次优化,但其对目标函数的优化顺序较为敏感.王辉等<sup>[7]</sup>从非支配解中随机选取一组解作为最优粒子,陈民铀等<sup>[8]</sup>采用动态加权的方法进行多目标最优粒子的选取,但他们对全局最优粒子的选取都具有随机性,缺乏客观性.

为了进一步提高微粒群在多目标进化过程中最优粒子选取的客观性,本文提出一种基于动态层次分析的自适应多目标粒子群进化算法.该算法根据当前进化解进行实时动态客观决策来确定最优粒子,以保证最优粒子对全局寻优的引导的客观性和有效性;并在进化过程中通过粒子进化状态进行权重等重要参数的自适应调节,保证目标解集的分布性和多样性.最后,将改进的算法用于多目标测试函数、PID控制器参数的优化和甲醇转化为烃类物质的工业过程模型辨识,通过与其他算法对比,验证了所提出算法的有效性.

## 1 基于模糊一致判断矩阵的层次分析方法

层次分析法是一种相当成熟的综合指标评价方法,其核心在于建立实用的一致判断矩阵.9标度方法是一种常用的建立判断矩阵的方法,但应用往往受到主客观条件的限制:1)利用9标度表示的方案重要性常会出现不一致的现象;2)决策者在进行优选方案决策时往往受很多因素干扰,这些因素又由不同的类别和层次构成,其结构相当复杂,导致综合后的判断矩阵出现不一致的现象,并且单独求解在综合中的工作量较大;3)对不具有满意一致性的判断矩阵求解主特征根较浪费时间<sup>[9-10]</sup>.针对以上问题,文献[9]采用3标度进行一致判断矩阵的构造,较好地保证了得到的一致判断阵的一致性和可综合性.待评价方案描述如下:

$$C = \begin{matrix} c_1 \\ c_2 \\ \vdots \\ c_m \end{matrix} \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{bmatrix}. \quad (1)$$

方案集为  $C = (c_1, c_2, \dots, c_m)$ ,  $m$  表示待评价方案的个数,  $n$  表示方案中属性个数.对方案集中方案的各个属性分别进行重要性对比,其中  $f_{i,j}^l$  表示重要性指标,其取值如下:

$$f_{i,j}^l = \begin{cases} 0, & x_{jl} \text{ 比 } x_{il} \text{ 重要;} \\ 0.5, & x_{jl} \text{ 与 } x_{il} \text{ 同样重要;} \\ 1, & x_{il} \text{ 比 } x_{jl} \text{ 重要.} \end{cases} \quad (2)$$

其中:  $i, j \in \{1, 2, \dots, m\}$ ;  $l \in \{1, 2, \dots, n\}$ , 令  $E_i^l = \sum_{i=1}^m f_{i,j}^l$ .由式(2)获得一致判断矩阵的各个元素

$$A^l = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n1} & \cdots & a_{nn} \end{bmatrix}. \quad (3)$$

其中

$$a_{i,j} = \frac{E_i^l - E_j^l}{2\alpha n} + 1, \quad (4)$$

$\alpha$  表示敏感因子,其取值为 0, 1, 2, 3, 具体取值可根据实际情况而定.结合一致判断矩阵的特点,利用乘积方根法计算每组权重,即

$$w_i^l = \left( \prod_{j=1}^n a_{i,j}^l \right)^{1/n}. \quad (5)$$

对其进行归一化,获得参数  $x_{i,j}^l$  的效用为

$$w_i^l = w_i^l / \sum_{l=1}^m w_i^l. \quad (6)$$

对于第  $i$  个待评价方案的综合评价函数为

$$y_i = \sum_{j=1}^n w_j^l x_{i,j}^l. \quad (7)$$

## 2 多目标优化问题的描述

一般地,含有  $D$  维变量的  $n$  个目标的多目标优化问题可以描述为

$$\begin{aligned} \min y &= (f_1(x), f_2(x), \dots, f_n(x)), \\ \text{s.t. } g(x) &\leq 0. \end{aligned}$$

其中:  $x = (x_1, x_2, \dots, x_D)$  为决策向量,  $y$  为目标向量,  $g(x)$  为约束条件.

若目标函数矢量  $f(x)$  为非支配的,则当且仅当对于另外一个矢量有  $f(y) \geq f(x)$  且至少存在一个目标向量使得  $f_i(y) > f_i(x)$  成立,否则为支配的.

## 3 基于层次分析的自适应多目标粒子群算法

### 3.1 基本粒子群算法

粒子群优化算法中每一个粒子代表一个可能解,每一个粒子具有位置和速度两个特性参数,通常将位置坐标对应的函数值作为粒子的自适应值,进行当前粒子位置优劣的评价.算法首先在寻优范围内随机初始化一群粒子,然后根据跟踪粒子个体最优位置和整个种群全局最优位置来更新位置和速度,直至寻到满意解或达到最大寻优次数,才停止并输出搜寻的最终结果.其速度和位置的更新公式如下<sup>[1-2]</sup>:

$$\begin{aligned} V_i &= wV_i + C_1 \text{rand}()(\text{pbest}_i - x_i) + \\ &C_2 \text{rand}()(\text{gbest} - x_i), \end{aligned} \quad (8)$$

$$X_i = X_i + V_i. \quad (9)$$

其中:  $V_i = [V_i^1, V_i^2, \dots, V_i^D]$  为粒子  $i$  的速度,代表下一步粒子前进的方向和步长;  $X_i = [X_i^1, X_i^2, \dots,$

$X_i^p$ ] 为粒子  $i$  的位置;  $pbest_i$ ,  $gbest$  分别代表当前粒子寻到的最优位置和整个种群寻到的最优位置;  $w$  称为权重, 主要用于全局和局部寻优能力的权衡;  $C_1$  和  $C_2$  称为学习因子, 分别代表向局部和全局趋近的速率变化大小;  $rand()$  为  $[0,1]$  之间的随机数.

### 3.2 权重和学习因子的自适应调整

在粒子群进化过程中, 权重的大小代表了进行全局和局部寻优能力的大小, 当权重较大时, 粒子更易于进行全局遍历, 而当权重较小时, 粒子局部寻优能力较强; 学习因子代表了当前粒子自我认知和进行社会学习的能力, 当个体学习因子较大时, 粒子有较好的局部寻优能力, 但易使整个种群陷入局部极优, 而全局学习因子较大时则相反. 因此根据粒子进化状态进行自适应地调整权重和学习因子可以使粒子更好地收敛到全局最优点. 本文采用进化因子进行种群进化状态的度量, 进化因子的计算步骤如下:

1) 计算每个粒子与其他粒子的欧氏距离的平均值, 即

$$d_i = \frac{1}{N-1} \sum_{j=1, j \neq i}^N \sqrt{\sum_{k=1}^D (x_i^k - x_j^k)^2}. \quad (10)$$

2) 当定义全局最优粒子的距离为  $d_g$  时, 进化因子的定义如下<sup>[11]</sup>:

$$f = \frac{d_g - d_{\min}}{d_{\max} - d_{\min}}. \quad (11)$$

在获得了进化因子后, 可以很好地对粒子的进化状态进行评估, 自适应调节粒子进化的权重和学习因子. 本文采用权重系数在  $[0.4, 0.9]$ 、学习因子在  $[0.5, 2.5]$  范围内随进化因子动态变化的方式进行参数调整, 其调节公式为

$$w = \frac{1}{1 + 1.5e^{-2.6f}}, \quad (12)$$

$$C_1 = \frac{1}{0.2 + 0.2e^{2.2f}}, \quad (13)$$

$$C_2 = \frac{1}{0.1 + 0.2e^{-1.85f}}. \quad (14)$$

当  $C_1$  与  $C_2$  的和大于 4 时, 需要对其值进行标准化, 即

$$C_i = 4C_i / \sum_{i=1}^2 C_i. \quad (15)$$

### 3.3 最优粒子的选取

粒子群算法进行多目标优化时, 其最优粒子的选取对寻优结果有较大的影响, 本文基于解的支配关系和随机方式进行个体最优的选取, 即当粒子进化后的解支配个体最优粒子时, 选取进化后的解作为当前粒子的个体最优粒子; 当进化后的解与当前个体最优粒子互不支配时, 随机进行个体最优粒子的更新, 否则保持个体最优粒子不变, 从而保证解的非支配性和分布性.

多目标粒子群寻优是一个逐步迭代逼近真实 Pareto 前沿的过程. 对整个种群而言, 其获得的非支配解构成的 Pareto 解集中的解对于当前和过去所有种群都是非支配的, 层次分析法能够较好地进行多个非支配目标的客观评判. 对于全局最优粒子, 充分利用进化过程已获得的进化信息, 选用综合效用较低的作为全局最优粒子, 从而保证全局最优粒子选取的客观性和有效性.

### 3.4 外部归档集的更新和维护策略

合理的外部归档集更新和维护策略可以很好地保证种群在进化过程中得到的 Pareto 前沿具有较好的分布性和多样性, 保证了算法的可行性和有效性.

本文基于拥挤度的排序策略进行外部归档集维护和更新操作, 其定义为计算点所在不包含其他点的最大立方体中的不同目标函数相邻点边长之和. 由定义可以看出, 其定义代表了解的分布情况, 拥挤度越大则代表解的分布性越好, 否则代表分布性较差. 因此在进行外部归档集更新和维护时, 可以对拥挤度大的予以保留, 而拥挤度相对较小的予以删除, 从而保证了解的分布性和多样性. 拥挤度的计算步骤如下:

1) 初始化当前外部归档集中解的拥挤度为 0, 解集的大小为  $L$ , 目标数为  $M$ , 设置当前目标数为  $i = 1$ .

2) 对第  $j = 1$  个目标降序排列, 设置第 1 个和最后 1 个粒子的拥挤度为无穷大.

3) 从第 2 个粒子开始按照下式计算拥挤度距离:

$$\text{Dis}[i] = \text{Dis}[i] + \frac{f_{i+1}^m - f_{i-1}^m}{\max(f^m) - \min(f^m)}. \quad (16)$$

4) 判断当前计算粒子是否大于  $L - 1$ , 若是, 则跳到 5), 否则返回到 3).

5) 令  $j = j + 1$ , 判断当前目标数是否大于  $M$ , 若是, 则停止, 否则返回到 2).

6) 令  $i = i + 1$ , 判断当前粒子是否大于  $L$ , 若是, 则停止, 否则返回到 2).

### 3.5 层次分析的自适应多目标粒子群算法流程

层次分析的自适应多目标粒子群算法流程如下:

1) 初始化种群大小、迭代进化次数等参数, 随机初始化种群的位置和速度, 以及初始个体最优粒子.

2) 计算初始粒子的目标函数值.

3) 根据模糊一致判断矩阵选取全局最优粒子, 进行种群进化方向的引导.

4) 计算种群的进化因子, 判断种群进化状态, 自适应调节种群进化所需权重和学习因子等重要参数.

5) 按照式 (8) 和 (9) 进行速度和位置更新.

6) 按照个体最优粒子的更新策略, 进行个体最优

粒子的更新.

7) 判断当前粒子是否为最后一个粒子, 若否, 则返回到 5).

8) 判断是否满足结束条件, 若是, 则输出结果并结束, 否则返回到 4).

## 4 性能验证

### 4.1 验证函数及性能指标

为验证本文所提出算法的有效性, 采用 Pareto 前沿已知的标准多目标性能测试函数 ZDT1、ZDT2、ZDT3 和 ZDT4<sup>[12]</sup>进行仿真研究. 为了验证得到 Pareto 前沿的真实性及解的多样性和分布性, 本文采用文献 [8] 提出的收敛度和多样性两个指标进行算法性能的度量.

收敛度的定义为

$$\gamma = \frac{1}{N} \sum_{y \in Y'} \min\{|y - y'|, y' \in Y'\}.$$

其中:  $y$  为算法获得的非劣解集  $P$ ,  $N$  为非劣解集的大小,  $y'$  为真实的非劣解集  $P^*$ . 首先从真实的 Pareto 前沿均匀地选取 500 个解构成  $P^*$ ; 然后计算 Pareto 解集  $P$  中的每个解与  $P^*$  最近解之间的欧式距离的平均值. 收敛度大小代表了获得的解集与真实 Pareto 前沿的逼近程度, 其值越小说明其逼近程度越好.

多样性的计算公式如下:

$$\Delta = \frac{d_f + d_l + \sum_{i=1}^{N-1} |d_i - \bar{d}|}{d_f + d_l + (N-1)\bar{d}}.$$

其中:  $d_i$  为算法得到的解集中相邻解间的距离,  $\bar{d}$  为  $d_i$  的平均,  $d_f$  和  $d_l$  为算法获得解集的边界解与真实最极端解之间的距离, 其代表了获得的解集在 Pareto 前沿的分布情况, 其值越小说明其前沿的分布越均匀.

### 4.2 对比算法及其参数设置

为了验证算法的优越性, 将本文算法 APSO 与 NSGA-II<sup>[12]</sup>、MOPSO<sup>[13]</sup>、PESA-II<sup>[14]</sup>、NSPSO<sup>[15]</sup>、PSO-IMOCA<sup>[16]</sup>、AEPSo<sup>[8]</sup>、TV-MOPSO 和 RE-MEDA<sup>[17]</sup> 进行对比.

设置待比较算法的参数. NSGA-II、RE-MEDA、PESA-II、NSPSO、MOPSO 和 AEPSo 按照文献 [8] 设置, PSO-IMOCA、TV-MOPSO 按照文献 [15] 设置, 其参数详细设置如下: NSGA-II、NSPSO、PESA-II、RM-MEDA、RE-MED 和 AEPSo 的种群大小为 100, 迭代次数为 250; MOPSO 的种群规模为 50, 迭代次数为 500; TV-MOPSO 的种群规模为 50, 迭代次数为 500. 权重采用由 0.9~0.4 的线性下降. RM-MEDA 中聚类数为 5, NSPSO 中  $C_1 = 1, C_2 = 2$ ,  $w$  为 1.0~0.4 线性下降; AEPSo 中  $w$  取为 1~0.35 线性下降; PSO-

IMOCA 的种群规模为 50, 信念空间规模为 20, 归档集为 100, 迭代次数为 500; 本文提出的自适应多目标粒子群 (APSO) 种群规模为 50, 迭代次数为 500. 由上可以看出所有算法的函数评价次数为 25 000, 其具有可比性.

### 4.3 结果及讨论

通过对各个测试函数及算法独立运行 30 次后进行分析比较. 表 1 和表 2 分别给出了运行后算法的收敛度和多样度的结果对比. 其中  $M$  为均值,  $V$  为方差. NSGA-II, PESA-II, NSPSO, RE-MEDA, MOPSO, AEPSo 的实验结果来自文献 [8]; PSO-IMOCA, TV-MOPSO 的实验结果来自文献 [15], 其中“-”表示具体数值文献未给出.

表 1 收敛度  $\gamma$  对比

算法	指标	ZDT1	ZDT2	ZDT3	ZDT4
NSGA-II	$M$	0.033 482	0.072 391	0.114 5	0.513 05
	$V$	0.004 75	0.031 689	0.007 94	0.118 46
PESA-II	$M$	0.001 05	7.4e-4	0.007 89	9.982 54
	$V$	0	0	1.1e-4	20.134
NSPSO	$M$	0.006 42	9.51e-3	4.91e-3	4.957 75
	$V$	0	0	0	7.436 01
MOPSO	$M$	0.001 33	8.9e-4	4.18e-4	7.374 29
	$V$	0	0	0	5.482 86
AEPSo	$M$	0.001	7.8e-4	0.004 62	0.498
	$V$	0	0	0	1.936 06
TV-MOPSO	$M$	0.001 2	8.30e-04	0.006 7	—
	$V$	5.25e-08	1.31e-08	9.53e-08	—
PSO-IMOCA	$M$	0.001 1	7.95e-04	0.001 3	—
	$V$	4.03e-08	5.59e-08	1.30e-07	—
RE-MEDA	$M$	0.021 21	2.92e-02	4.42e-02	5.37e+01
	$V$	2.00e-05	1.70e-04	1.40e-04	5.38e+00
APSO	$M$	0.000 4	0.000 4	0.000 45	0.000 4
	$V$	1.764 3e-10	1.02e-10	2.37e-10	1.86e-10

表 2 多样性  $\Delta$  对比

算法	指标	ZDT1	ZDT2	ZDT3	ZDT4
NSGA-II	$M$	0.390 31	0.430 77	0.738 54	0.702 61
	$V$	0.001 87	0.004 72	0.019 71	0.064 65
PESA-II	$M$	0.848 16	0.892 92	1.227 31	1.011 36
	$V$	2.87e-03	5.74e-02	2.93e-02	7.20e-04
NSPSO	$M$	9.07e-01	9.22e-01	6.21e-02	9.65e-01
	$V$	0.00e+00	1.20e-04	6.90e-04	1.56e-03
MOPSO	$M$	6.81e-01	6.39e-01	8.32e-01	9.62e-01
	$V$	1.34e-02	1.14e-03	8.92e-03	1.14e-03
AEPSo	$M$	5.57e-01	5.19e-01	5.52e-01	8.04e-01
	$V$	1.42e-03	9.50e-04	8.70e-04	7.08e-02
TV-MOPSO	$M$	2.10e-02	2.10e-02	1.54e-02	—
	$V$	3.923 3e-5	6.76e-05	1.39e-05	—
PSO-IMOCA	$M$	2.35e-02	2.33e-02	1.60e-02	—
	$V$	1.31e-05	8.69e-06	5.98e-06	—
RE-MEDA	$M$	0.385 9	0.365 56	0.811 03	7.64e-01
	$V$	5.70e-04	5.31e-03	4.04e-03	4.15e-03
APSO	$M$	0.477	0.349	0.716	0.195
	$V$	0.002	0.000 9	0.000 2	0.000 4

由表 1 和表 2 可看出, 对于所有函数本文算法的收敛度明显优于其他算法, 其最优解集更接近于真实

的 Pareto 前沿, 具有较好的收敛性. 就分布度而言, 对于大部分测试函数本文算法的收敛度都优于其他算法, 具有较好的分布性, 并且对于实际优化问题, 其按照模糊一致矩阵进行最优粒子的选取, 采用全局最优粒子选取方式选取的最优个体具有一致性和综合性.

为了进一步比较多目标优化算法的效果, 采用文献[8]提出的将多次优化结果重复叠加显示的方式,

将其多样性和分布性进行对比. 由图1可以看出, 本文算法的收敛性和分布性明显优于其他方法, 而且其他算法最优解的选取都具有随机性, 按照获取全局最优粒子的方式进行最终优化解的选取, 其解并不能代表真实的权衡最优解. 本文根据模糊一致矩阵所进行的最优粒子的选取方式, 完全可以用于最终权衡解的选取, 其选取的解具有一定的合理性和综合性.

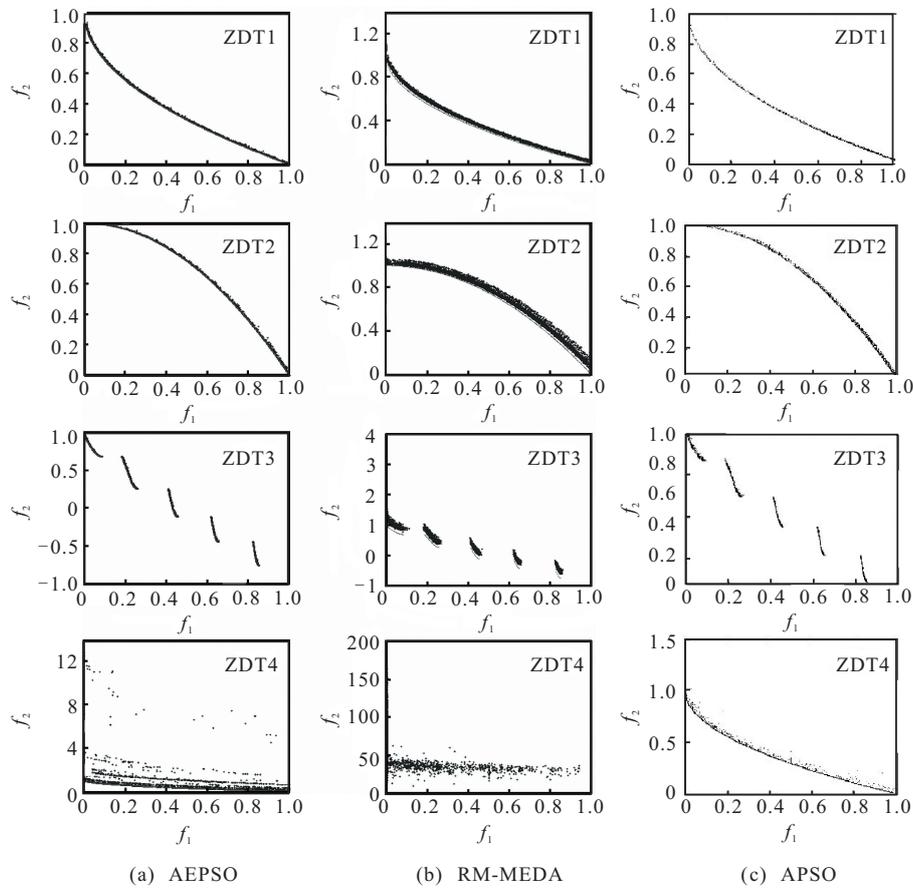


图1 优化对比图

### 5 工业应用

**例1** 使用PID整定模型作为优化目标, 将提出的多目标优化算法用于工业PID的控制器整定, 其原理如图2所示.

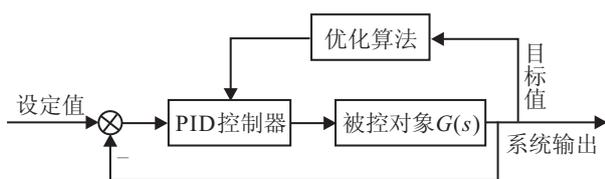


图2 PID控制器优化整定原理

1) 优化目标. 为了使优化后的系统同时达到快速性、稳定性和鲁棒性的要求, 选用系统输出的超调量、上升时间和调节时间作为优化目标, 同时以频域指标为约束进行优化, 其优化模型如下:

$$\min f(k_p, k_i, k_d) = (\delta, t_r, t_s),$$

$$\text{s.t. } G_m \geq g_m, P_m \geq p_m.$$

其中:  $\delta$  为超调量,  $t_r$  为上升时间,  $t_s$  为调整时间,  $G_m$  和  $P_m$  分别为相位裕度和幅值裕度.

2) 优化范围. 为了减小搜索的范围, 以ZN法获得的控制器参数值为中心进行延拓, 形成优化参数的寻优范围, 其拓展结构为

$$[(1-x)K_{ZN}, (1+x)K_{ZN}].$$

其中:  $K_{ZN}$  为ZN整定的结果,  $x$  取值范围为  $[0,1]$ .

3) 过程对象. 对于一般的工业过程可用二阶系统加纯滞后来模拟, 本文采用二阶加纯滞后模型进行仿真, 其传递函数形式为

$$G(s) = \frac{1}{(s+1)^2} e^{-0.5s}.$$

控制器采用标准的PID控制器, 其控制器结构为

$$G_c(s) = k_p + \frac{k_i}{s} + k_d s.$$

设置约束的下限  $g_m = 2, p_m = 60$ .

4) 优化结果. 表 3 给出了不同优化算法设计结果的对比, 其中 ZN 法、ITAE 法<sup>[18]</sup>、SGA<sup>[19]</sup>、PSO<sup>[20]</sup>和改进的遗传算法(IGA)<sup>[21]</sup>的优化结果来自于文献[22], APSO 的优化结果是在采用本文提出的算法进行多目标优化的基础上, 按照层次分析的方法从最优解集中选取的一个最佳权衡解. 图 3 给出了各种算法获得的系统单位阶跃响应曲线. 由图 3 可以看出, 虽然各种不同的控制器参数矫正方法均能使系统保持稳定, 但采用本文算法整定后的系统具有超调量小、上升时间和稳定时间短且稳定裕度大、综合性能较优的特点, 并且与文献[21-22]中按照个人经验进行最终解的方式相比, 采用本文算法进行 PID 控制器参数整定获得最终权衡解的过程完全由算法实现, 无需人为操作, 避免了最优解选取的主观性.

表 3 不同设计方法比较

算法	$K_p$	$K_i$	$K_d$	$\delta/\%$	$t_r/s$	$t_s/s$	$g_m$	$p_m$
ZN	2.8234	1.7193	1.1524	43.00	0.63	5.10	2.36	39.92
ITAE	2.2566	1.0990	1.3432	3.84	0.73	3.46	2.55	63.56
SGA	2.5736	1.4420	1.4977	14.50	0.62	2.27	2.29	55.66
PSO	2.1984	1.3364	1.2548	9.20	0.74	3.06	2.72	57.17
IGA	2.1600	1.0824	1.3831	0.76	0.72	1.39	2.56	66.52
APSO	2.1089	1.0013	1.2649	0.2	0.83	1.51	2.71	66.60

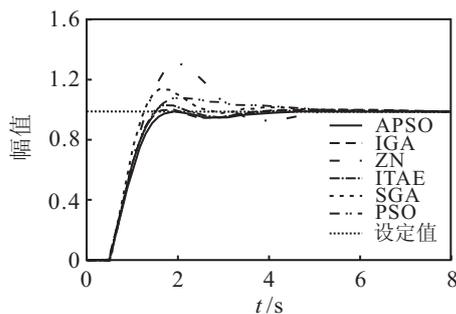


图 3 不同设计方法的单位阶跃响应曲线

例 2 将本文算法应用于甲醇转化为烃类物质的工业过程模型辨识, 其反应模型<sup>[23]</sup>

$$\begin{cases} \frac{dy_1}{dt} = -\left[2\theta_1 - \frac{\theta_1 y_2}{(\theta_2 + \theta_5)y_1 + y_2} + \theta_3 + \theta_4\right]y_1, \\ \frac{dy_2}{dt} = \frac{\theta_1 y_1 (\theta_2 y_1 - y_2)}{(\theta_2 + \theta_5)y_1 + y_2} + \theta_3 y_1, \\ \frac{dy_3}{dt} = \frac{\theta_1 y_1 (y_2 + \theta_5 y_1)}{(\theta_2 + \theta_5)y_1 + y_2} - \theta_4 y_1. \end{cases}$$

初始条件为  $y = [1 \ 0 \ 0]$ , 边界条件为  $0 \leq y_i \leq 1, \theta \geq 0$ . 其中:  $\theta = \{\theta_1, \theta_2, \theta_3, \theta_4, \theta_5\}$  为待辨识的模型参数, 系统输出  $y = \{y_1, y_2, y_3\}$  分别代表氧化剂、烃类物质和芳香族的浓度. 为了保证优化后的模型能够很好地反应真实输出, 选用目标函数

$$f_i = \min \sum_{t=0} |y_i(t) - C_{i,t}|^2, \quad i = 1, 2, 3.$$

采用龙格库塔法进行微分方程的求解, 采用本文算法进行模型参数的辨识, 与文献[23]将氧化物浓度  $y_1$  的最小拟合差值作为最终目标函数选取标准相比, 其优化结果具有一致性. 图 4 给出了优化前后模型的预测值与实际值间的拟合结果对比曲线, 表 4 给出了不同方法所获得的模型参数和优化目标函数的对比结果, 其中前 4 种的优化结果均来自文献[23]. 由表 4 可看出, 本文的结果优于其他文献的方法, 进一步说明了本文算法的有效性和可行性.

表 4 实验结果对比

求解方法	$\theta$	目标值
Jiang	(1.775 0, 2.168 0, 1.858 0, 1.802 0, 0.000 0)	(0.008 6, 0.018 1, 0.085 6)
Maria	(2.690 0, 0.500 0, 3.020 0, 0.500 0, 0.500 0)	(0.006 4, 0.003 5, 0.004 9)
NSGA-II	(2.500 0, 0.530 0, 2.960 0, 0.510 0, 0.560 0)	(0.003 6, 0.004 5, 0.003 0)
PNSGA	(2.565 0, 0.495 0, 2.931 0, 0.000 0, 2.090 0)	(0.002 4, 0.005 1, 0.003 3)
APSO	(2.600 9, 0.757 0, 2.671 2, 0.000 0, 3.218 8)	(0.002 0, 0.008 2, 0.003 4)

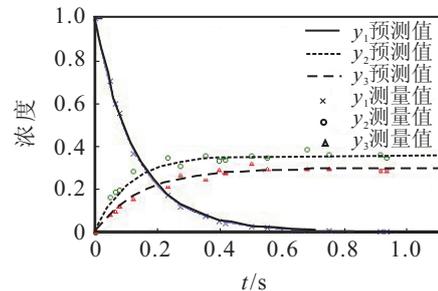


图 4 预测值与观察值的对比曲线

## 6 结 论

本文提出了一种基于动态层次分析的自适应多目标粒子群算法, 在寻优过程中充分利用已获得的非支配解进行模糊一致决策, 选取全局最优粒子用于指导种群的全局寻优, 并在寻优过程中进行种群进化状态的实时度量, 自适应地进行种群进化的权重和学习因子等参数的自适应调整, 使种群的进化具有自我调节能力. 将本文算法用标准的多目标测试函数进行实验, 并与其他多目标算法进行对比, 结果表明本文的自适应多目标粒子群算法具有更好的全局寻优能力, 获得的非支配解集的分布性和收敛性均较好. 将改进的算法用于 PID 控制器参数整定和甲醇转化为烃类物质的工业过程模型辨识, 优化对比结果表明, 本文算法是有效的, 基于层次分析的全局最优粒子选取具有一致性.

## 参考文献(References)

- [1] Kennedy J, Eberhart R C. Particle swarm optimization[C]. Proc of IEEE Int Conf on Neural Networks. Piscataway, 1995: 1942-1948.
- [2] 巩敦卫, 张勇, 张建化, 等. 新型粒子群优化算法[J]. 控制理论与应用, 2008, 25(1): 111-114.

- (Gong D W, Zhang Y, Zhang J H, et al. Novel particle swarm optimization algorithm[J]. *Control Theory & Applications*, 2008, 25(1): 111-114.)
- [3] 方正, 佟国峰, 徐心和. 基于粒子群优化的粒子滤波定位方法[J]. *控制理论与应用*, 2008, 25(3): 533-537.  
(Fang Z, Tong G H, Xu X H. A local method for particle-filter based on the optimization of particle swarm[J]. *Control Theory & Applications*, 2008, 25(3): 533-537.)
- [4] 马清亮, 胡昌华. 多目标进化算法及其在控制领域中的应用综述[J]. *控制与决策*, 2006, 21(5): 481-486.  
(Ma Q L, Hu C H. Survey of multi-objective Evolutionary algorithm and its applications in the field of automatic control[J]. *Control and Decision*, 2006, 21(5): 481-486.)
- [5] Sierra M R, Coello C A C. Multi-objective particle swarm optimizers: A survey of the state of the art[J]. *Int J of Computational Intelligence Research*, 2006, 2(3): 287-308.
- [6] Hu X, Eberhart R. Multiobjective optimization using dynamic neighborhood particle swarm optimization[C]. *Proc of IEEE Int Conf on Evolutionary Computation*. Honolulu, 2002, 2: 1677-1681.
- [7] 王辉, 钱锋. 基于拥挤度与变异的动态微粒群多目标优化算法[J]. *控制与决策*, 2008, 23(11): 1238-1248.  
(Wang H, Qian F. Improved PSO-based multi-objective optimization by crowding with mutation and particle swarm optimization dynamic changing[J]. *Control and Decision*, 2008, 23(11): 1238-1248.)
- [8] 陈民铀, 张聪誉, 罗辞勇. 自适应进化多目标粒子群优化算法[J]. *控制与决策*, 2009, 24(12): 1851-1855.  
(Chen M Y, Zhang C Y, Luo C Y. Adaptive evolutionary multi-objective particle swarm optimization algorithm[J]. *Control and Decision*, 2009, 24(12): 1851-1855.)
- [9] 孙才志, 林学钰. 基于层次分析的模糊一致性判断矩阵及其应用[J]. *模糊系统与数学*, 2002, 16(3): 59-63.  
(Sun C Z, Lin X Y. Fuzzy consistent matrix based on AHP and its application[J]. *Fuzzy Systems and Mathematics*, 2002, 16(3): 59-63.)
- [10] 顾祥柏, 朱群雄, 宣达婧. 基于层次分析的全信息生成算法及其应用[J]. *计算机工程*, 2006, 32(5): 32-35.  
(Gu X B, Zhu Q X, Xuan D J. Complete information generated algorithm based on AHP and its application[J]. *Computer Engineering*, 2006, 32(5): 32-35.)
- [11] Zhan Z H, Zhang J, Li Y, et al. Adaptive particle swarm optimization[J]. *IEEE Trans on System, Man, Cybernetic B*, 2009, 39(6): 1362-1381.
- [12] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multi-objective genetic algorithms: NSGA-II[J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(2): 182-197.
- [13] Coello C A C, Pulido G T, Lechuga M S. Handling multiple objectives with particle swarm optimization[J]. *IEEE Trans on Evolutionary Computation*, 2004, 8(3): 256-279.
- [14] Corne D, Jerram N R, Knowles J, et al. PESA-II: Region-based selection in evolutionary multi-objective optimization[C]. *Proc of the Genetic and Evolutionary Computation Conf(GECCO-2001)*. San Francisco, 2001: 283-290.
- [15] Li X. A non-dominated sorting particle swarm optimizer for multi-objective optimization[C]. *Genetic and Evolutionary Computation*. Berlin: Springer Heidelberg, 2003: 37-48.
- [16] 吴亚丽, 徐丽青. 一种基于粒子群算法的改进多目标文化算法[J]. *控制与决策*, 2012, 27(8): 1127-1132.  
(Wu Y L, Xu L Q. A improved multi-objective cultural algorithm based on particle swarm optimization[J]. *Control and Decision*, 2012, 27(8): 1127-1132.)
- [17] Zhang Q, Zhou A, Jin Y. RM-MEDA: A regularity model-based multi-objective estimation of distribution algorithm[J]. *IEEE Trans on Evolutionary Computation*, 2008, 12(1): 41-63.
- [18] Yuwana M, Seborg D E. A new method for on-line controller tuning[J]. *J of AIChE*, 1982, 28(3): 434-440.
- [19] Wang J, Jing Y, Zhang C. Genetic optimization algorithm on PID decoupling controller for variable flow heating system[C]. *Proc of ICIEA'08*. Singapore: IEEE Press, 2008: 510-515.
- [20] 张兴华, 周刘喜. PID控制器的粒子群多目标优化设计[J]. *应用科学学报*, 2007, 25(4): 392-396.  
(Zhang X H, Zhou L X. Multi-objective optimization design of PID controllers based on particle swarm algorithms[J]. *J of Applied Sciences*, 2007, 25(4): 392-396.)
- [21] 秦福高, 毛莺池, 石玉. 改进遗传算法在PID优化中的应用[J]. *计算机工程*, 2011, 37(17): 149-151.  
(Qin F G, Mao Y C, Shi Y. Application of improved genetic algorithm in PID optimization[J]. *Computer Engineering*, 2011, 37(17): 149-151.)
- [22] 刘楠楠, 石玉, 范胜辉. 基于Pareto最优的PID多目标优化设计[J]. *信息与控制*, 2010, 39(4): 385-390.  
(Liu N N, Shi Y, Fan S H. PID multi-objective optimization design based on pareto optimality[J]. *Information and Control*, 2010, 39(4): 385-390.)
- [23] 商秀芹, 卢建刚, 孙优贤, 等. 一种基于偏好的多目标遗传算法在动态模型参数辨识中的应用[J]. *化工学报*, 2008, 59(7): 1620-1624.  
(Shang X Q, Lu J G, Sun Y X, et al. A preference-based non-dominated sorting genetic algorithm for dynamic model parameters identification[J]. *J of Chemical Industry and Engineering*, 2008, 59(7): 1620-1624.)