

# 基于自适应粒子群算法的重油热解模型参数估计\*

龙文, 张文专

(贵州财经大学 贵州省经济系统仿真重点实验室, 贵阳 550004)

**摘要:**通过构造一个合适的目标函数,将化工模型参数估计问题转化为一个多维数值优化问题,然后提出一种参数自适应调整和维变异的改进粒子群优化算法来求解该问题。该算法首先利用佳点集方法初始化种群以保证粒子的多样性。惯性权重和学习因子随进化过程自适应调整,从而协调算法的全局和局部搜索能力。为了避免算法陷入局部最优,对收敛度最小的维进行变异。几个标准测试问题的实验结果表明该算法具有较强的全局寻优能力。最后将改进粒子群算法应用到重油热解模型参数估计中,并与基本遗传算法(SGA)和粒子群优化算法(PSO)进行比较。研究结果表明:本文得到的平均相对误差为5.62%,比SGA和PSO分别低1.08%和0.50%。

**关键词:**粒子群优化算法;自适应;重油热解模型;参数估计

**中图分类号:**TP301

**文献标志码:**A

**文章编号:**1672-6693(2013)06-0128-06

现代化工生产要求采用具有较高精度的数学模型来描述它的过程,为了保证理论上的可行性和合理性,这些数学模型通常采用一般的非线性结构。同时,在研究过程中又希望这些数学模型尽可能与实际生产情况相吻合,因此,通常需要用实际生产过程数据来估计模型的参数。不失一般性,非线性模型的形式为

$$y = g(x, \theta) + e; e \sim N(0, \delta) \quad (1)$$

式中, $y$ 为因变量, $x$ 为自变量, $\theta$ 为参数。假设已知实际测量数据对 $(x_i, y_i) (i=1, 2, \dots, n)$ ,非线性模型(1)参数的估计问题就是求解一组参数 $\theta$ ,使得偏差平方和

$$q(\theta) = \sum_{i=1}^n (y_i - g(x_i, \theta))^2 \quad (2)$$

最小。

传统的优化方法如梯度下降法、拟牛顿法、直接搜索法等都可对问题(2)进行求解。但是这些确定性优化方法往往只对某些特定的问题有效,对模型的要求较高,且求得的解多为局部最优解<sup>[1]</sup>。

粒子群优化(Particle swarm optimization, PSO)算法是由 Kennedy 等提出的一种模拟鸟群觅食行为的随机搜索优化算法<sup>[2]</sup>。由于 PSO 算法具有概念简单、易于实现、参数设置少和能够有效地解决复杂优化问题等特点,因此,在函数优化、传感器网络覆盖、神经网络训练等诸多领域中得到了广泛应用<sup>[3-6]</sup>。然而,PSO 算法性能的好坏在很大程度上依赖于参数的选择。惯性权重是 PSO 算法最重要的参数之一,对算法性能具有较大影响。文献[2]认为,较大的惯性权重可增强算法的全局搜索能力,较小的惯性权重可加速算法的收敛速度。因此,如何设置合适的惯性权重已成为 PSO 研究人员的热点方向之一。

除了惯性权重以外,学习因子也是 PSO 算法的重要参数之一。文献[7]指出,在不同的进化阶段,要求算法具有不同的搜索能力,比如在进化初期阶段,希望算法具有较强的全局搜索能力,而在进化后期阶段,希望算法具有较强的局部搜索能力和较快的收敛速度,因此提出了一种时变学习因子策略。

针对粒子群算法参数设置问题,本文提出一种惯性权重和学习因子自适应调整的 PSO 算法。该算法首先利用佳点集方法产生初始种群,以保证粒子在解空间中均匀分布。在进化过程中,惯性权重和学习因子随着进化代数的增加自适应调整大小,以平衡算法的全局和局部搜索能力。另外,为了避免算法陷入局部最优,在算法后期,对收敛度最小的维进行变异。4个标准测试函数的数值实验结果表明,新算法能有效地处理复杂全局优化问题。最后将改进粒子群算法应用到重油热解模型参数估计问题中,获得了满意的结果。

\* 收稿日期:2012-12-03 修回日照:2013-04-28 网络出版时间:2013-11-20 14:46

资助项目:贵州省科学技术基金(黔科合J字[2013]2061号,黔科合J字[2009]2061(号);贵州省高校优秀科技创新人才支持计划(黔教合KY字[2013]140);贵州省教育厅自然科学研究项目(No. 2008040)

作者简介:龙文,男,副教授,博士,研究方向为进化计算、优化方法及应用,E-mail: dragon638@126.com

网络出版地址: [http://www.cnki.net/kcms/detail/50.1165.N.20131120.1446.201306.133\\_053.html](http://www.cnki.net/kcms/detail/50.1165.N.20131120.1446.201306.133_053.html)

## 1 基本粒子群优化(PSO)算法

PSO 算法是一种模拟鸟群飞行觅食行为的随机搜索技术,它通过粒子间的合作来寻求问题的全局最优解。假设问题的搜索空间为  $D$  维,种群规模为  $N$ ,  $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$  表示第  $i$  个粒子的空间位置,粒子  $i$  的空间飞行速度为  $V_i = (v_{i1}, v_{i2}, \dots, v_{id})$ ,  $P_i = (p_{i1}, p_{i2}, \dots, p_{id})$  表示第  $i$  个粒子的最好位置,  $P_g = (p_{g1}, p_{g2}, \dots, p_{gd})$  表示整个群体中的最后位置,其中  $1 \leq d \leq D, 1 \leq i \leq N$ 。在  $k+1$  时刻,粒子  $i$  的位置和速度按(3)式进行更新。

$$\begin{aligned} v_{id}^{k+1} &= \omega v_{id}^k + c_1 \text{rand}() (p_{id}^k - x_{id}^k) + c_2 \text{rand}() (p_{gd}^k - x_{id}^k) \\ x_{id}^{k+1} &= x_{id}^k + v_{id}^{k+1} \end{aligned} \quad (3)$$

其中,  $k$  为当前进化代数,  $\omega$  为惯性权重,  $c_1$  称为自我学习因子,  $c_2$  称为社会学习因子,  $\text{rand}()$  为分布于  $(0, 1)$  间的随机数。

基本 PSO 算法的步骤如下:1)设置算法的参数,初始化粒子的位置和速度;2)计算每个粒子的适应度值,将粒子  $i$  的当前位置设置为  $p_i$ ,将群体中的最佳粒子的位置设置为  $p_g$ ;3)判断算法是否满足结束条件,若满足,则算法结束,输出最优解;否则,执行 4)根据(3)式对每个粒子的速度和位置进行更新,返回 2)。

## 2 自适应粒子群优化(MPSO)算法

基本 PSO 算法存在的主要缺陷为:在整个搜索过程中,算法参数均为固定值,不考虑进化过程,进而影响了算法的搜索效率。另外,为了增强算法全局搜索能力奠定基础,采用佳点集方法产生初始粒子。最后,在算法后期避免算法陷入局部最优,对收敛度最小的维进行变异。本文从种群初始化、惯性权重、学习因子和维变异等 4 个方面对 PSO 算法进行改进。

### 2.1 种群初始化

种群中粒子多样性的优劣对算法的搜索效率产生较大的影响,一般来说,期望种群中粒子具有较好的多样性。另外,在求解问题前无法预知全局最优解所在区域的情况下,初始粒子必须充分代表解空间中的解,这样才能使算法以较快的方式快速逼近全局最优解。

佳点集是一种有效的均匀取点的方法,在相同取点个数的条件下,佳点集方法要比随机方法选取的点更均匀<sup>[8]</sup>。因此,本文采用佳点集方法来产生初始种群粒子。图 1 是采用佳点集方法产生的规模为 80 的初始粒子分布。从图 1 可以看出,佳点集方法产生的初始粒子分布均匀,具有较好的多样性。

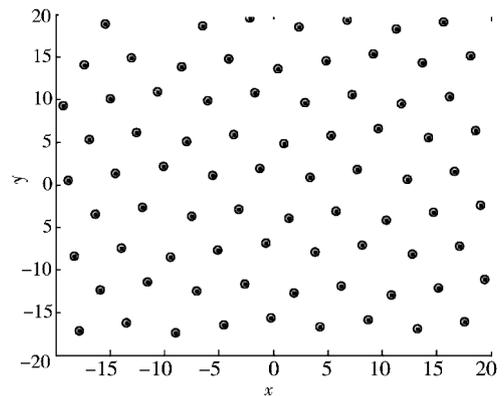


图 1 佳点集方法产生的 80 个初始粒子分布

### 2.2 惯性权重调整策略

在 PSO 算法的参数中,惯性权重  $\omega$  是影响算法性能最大的参数。因此,近年来对惯性权重  $\omega$  的研究是 PSO 算法研究人员的重点研究方向之一<sup>[2-6]</sup>。研究表明:较大的惯性权重可增强算法的全局搜索能力;较小的惯性权重可增强算法的局部搜索能力和加快算法的收敛速度。一般来说,在进化初期,要求算法在解空间中进行大范围的搜索,即要求算法具有较强的全局搜索能力;在进化后期,要求算法在局部区域进行精确搜索,即要求算法具有较强的局部搜索能力。为了平衡算法的全局和局部搜索能力,在进化初期惯性权重应取较大值,在进化后期应取较小值。基于上述思想,文献<sup>[2]</sup>提出了惯性权重线性递减策略,即

$$\omega(k) = \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{k_{\max}} \times k \quad (4)$$

式中,  $\omega_{\max}$  和  $\omega_{\min}$  分别为最大和最小惯性权重,通常取  $\omega_{\max} = 0.9, \omega_{\min} = 0.4, k$  为当前迭代次数,  $k_{\max}$  为最大迭代次数。线性权重递减策略使算法在进化初期具有较强的全局搜索能力,在进化后期具有较强的局部搜索能力,但易陷入局部最优<sup>[6]</sup>。然而,PSO 算法在搜索过程中却是非线性变化的,惯性权重线性递减策略不能体现出实际的优化搜索过程<sup>[9]</sup>。因此,为了协调算法的全局和局部搜索能力,本文提出一种自适应调整惯性权重  $\omega$  策略<sup>[9]</sup>

$$\omega = \begin{cases} \omega_{\min} - \frac{(\omega_{\max} - \omega_{\min}) * (f - f_{\min})}{f_{\text{avg}} - f_{\min}}, & f \leq f_{\text{avg}} \\ \omega_{\max}, & f > f_{\text{avg}} \end{cases} \quad (5)$$

式中,  $w_{\max}$  和  $w_{\min}$  分别为惯性权重  $w$  的最大值和最小值,  $f$  为粒子当前的目标函数值,  $f_{\min}$  和  $f_{\text{avg}}$  分别为当前所有粒子的最小目标函数值和平均目标函数值。

(5)式表明,当群体中各粒子的目标函数值趋于一致或趋于局部最优时惯性权重  $w$  增加,而当各粒子的目标函数值比较分散时惯性权重  $w$  减少,从而体现出惯性权重随种群中粒子的不同状态而自适应调整。另外,对于目标函数值优于评价目标函数值的粒子,它对应的惯性权重  $w$  较小,从而保护了该粒子;对于目标函数值劣于平均目标函数值的粒子的惯性权重  $w$  较大,使得该粒子向较好的搜索区域飞去。

### 2.3 学习因子调整策略

在 PSO 算法中,  $c_1$  和  $c_2$  被称为自我学习因子和社会学习因子,一般都取值为 2。在现有文献中,对学习因子相对研究得较少。然而,学习因子  $c_1$  和  $c_2$  对算法性能具有较大的影响,它决定了粒子自身的经验和群体中其它粒子的经验对算法寻优性能的影响,反映了粒子间的信息交换。较大的  $c_1$  值则增强算法的局部搜索能力;较大的  $c_2$  值会使粒子收敛于局部最优。

为了平衡算法的全局和局部搜索能力,在算法搜索初期,要求粒子具有较大的自我学习能力和较小的社会学习能力,也就是说,  $c_1$  取值较大而  $c_2$  取值较小,这样使粒子可以在整个搜索空间飞行。而在算法搜索后期,则要求粒子具有较小的自我学习能力和较大的社会学习能力,即  $c_1$  取值较小而  $c_2$  取值较大,使粒子飞向全局最优解。因此,本文采用动态自适应调整  $c_1$  和  $c_2$  策略

$$\begin{cases} c_1 = c_{1s} + \frac{c_{1e} - c_{1s}}{k_{\max}} \times k \\ c_2 = c_{2s} + \frac{c_{2e} - c_{2s}}{k_{\max}} \times k \end{cases} \quad (6)$$

式中,  $k$  为当前迭代次数,  $k_{\max}$  为最大迭代次数,  $c_{1s}$ 、 $c_{2s}$  分别为  $c_1$ 、 $c_2$  的初始值,  $c_{1e}$ 、 $c_{2e}$  分别为  $c_1$ 、 $c_2$  的最终值,一般取  $c_{1s}=2.5$ ,  $c_{1e}=0.5$ ,  $c_{2s}=0.5$ ,  $c_{2e}=2.5$  时算法效果较好<sup>[5]</sup>。

### 2.4 维变异算子

在进化后期,所有粒子都向最优解方向飞去,导致种群多样性损失,算法收敛速度明显变慢,进而陷入局部最优解<sup>[10]</sup>。这是基于群体搜索的智能优化算法的固有缺点。为了避免算法陷入局部最优,当粒子群收敛到一定程度时就要进行变异。很多参数都可以表示粒子群的收敛程度,用来确定是否变异的依据。假设参数  $l_{\text{const}}(d)$ ,  $d \in [1, D]$  来表示粒子群当前位置的质心到各个粒子当前位置的距离之和,它的值越大,粒子群的收敛度越小。本文采用维变异算子<sup>[11]</sup>来进行变异,具体变异方法详见文献<sup>[11]</sup>。

### 2.5 MPSO 算法步骤

1)设置算法参数,利用佳点集方法产生初始粒子的速度和位置,令  $k=1$ ; 2)计算种群中各粒子的适应度值,设置当前粒子的  $p_i$  和群体中最好位置  $p_g$ ; 3)判断算法是否满足结束条件,若满足,则算法结束,输出最优解; 4)按(5)式和(6)式自适应调整惯性权重和学习因子,再按(3)式更新群体中各粒子的速度和位置; 5)按第 2.4 节的方法进行变异操作,令  $k=k+1$ ,返回 2)。

## 3 数值实验及分析

为了测试 MPSO 算法的性能,选取 4 个标准测试函数: 1) Sphere 函数:  $f_1(x) = \sum_{i=1}^D x_i^2, x_i \in [-100, 100]$ ; 2) Rosenbrock 函数:  $f_2(x) = \sum_{i=1}^{D-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2], x_i \in [-30, 30]$ ; 3) Griewank 函数:  $f_3(x) = \frac{1}{4000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos(\frac{x_i}{i}) + 1, x_i \in [-100, 100]$ ; 4) Rastrigin 函数:  $f_4(x) = \sum_{i=1}^D (x_i^2 - 10\cos(2\pi x_i) + 10), x_i \in [-10, 10]$ 。

在 4 个测试函数中, Sphere 函数是一个简单的单峰值函数,其它 3 个函数均为复杂的多峰值函数,4 个函数的全局最优值均为 0。

将 MPSO 算法与标准粒子群优化(BPSO)算法、惯性权重线性递减粒子群优化(LWPSO)算法、惯性权重自适应粒子群优化(SAPSO)算法和自适应学习因子粒子群优化(CPSO)算法得到的结果进行比较。在比较实验中,4 个函数的维数  $D=30$ ,5 种算法的种群规模均为  $N=50$ ,4 个函数最大迭代次数设置为 1000,收敛精度设置为  $1e-06$ 。在 MPSO 算法中,  $w_{\max}=0.9$ ,  $w_{\min}=0.4$ ; 在 BPSO 算法中,  $c_1=c_2=2$ ,  $w=0.5$ ; 在 LWPSO 算法中,  $w_{\max}=0.9$ ,  $w_{\min}=0.4$ ,  $c_1=c_2=2$ ; 在 SAPSO 算法中,  $w_{\max}=0.9$ ,  $w_{\min}=0.6$ ,  $c_1=c_2=2$ ; 在 CPSO 算法中,  $c_{1s}=2.5$ ,  $c_{1e}=0.5$ ,  $c_{2s}=0.5$ ,  $c_{2e}=2.5$ ,  $w=0.9$ 。每个测试问题在相同条件下独立运行 20 次实验,记录它的最优值和平均

最优值,表 1 给出了在上述参数设置下,5 种算法对 4 个函数的寻优结果比较。

表 1 5 种算法对 4 个函数的寻优结果比较

函数	全局最优值	BPSO		LWPSO		SAPSO		CPSO		MPSO	
		最优值	平均值	最优值	平均值	最优值	平均值	最优值	平均值	最优值	平均值
$f_1(x)$	0	4.637 232	6.385 296	1.28E-05	4.12E-04	6.98E-07	7.68E-06	6.15E-09	1.24E-08	2.43E-26	5.21E-25
$f_2(x)$	0	304.688 0	354.339 1	113.499 2	122.830 3	79.605 3	97.000 7	76.858 1	88.699 2	7.0529 6	9.450 78
$f_3(x)$	0	5.013 32	7.528 96	5.37E-03	2.42E-02	4.05E-03	1.45E-02	5.32E-04	4.66E-03	4.93E-10	2.42E-08
$f_4(x)$	0	189.794 2	202.391 1	60.498 0	75.392 2	45.826 4	57.314 8	33.899 6	45.838	1.773 726	2.879 995

从表 1 可知,对 4 个高维测试函数,MPSO 算法对 Sphere 函数和 Griewank 函数在 20 次实验中一致地找到了全局最优解。对于 Rosenbrock 函数和 Rastrigin 函数,找到的解也非常接近于全局最优解。BPSO 算法对 4 个高维测试函数,都没有找到全局最优解,说明 BPSO 算法的面对高维函数寻优能力有限。LWPSO 算法、SAPSO 算法和 CPSO 算法只对简单的高维单峰 Sphere 函数有效。与 BPSO 算法、LWPSO 算法、SAPSO 算法和 CPSO 算法相比,MPSO 算法无论在全局最优值和平均最优值上都占优。

图 2~5 给出了 MPSO 算法与 BPSO 算法、LWPSO 算法、SAPSO 算法和 CPSO 算法对 4 个测试问题的寻优收敛曲线,从图 2~5 可以清晰地看出,MPSO 算法能快速地收敛到问题的全局最优解。基于以上比较和分析,MPSO 算法要优于其它 4 种算法。

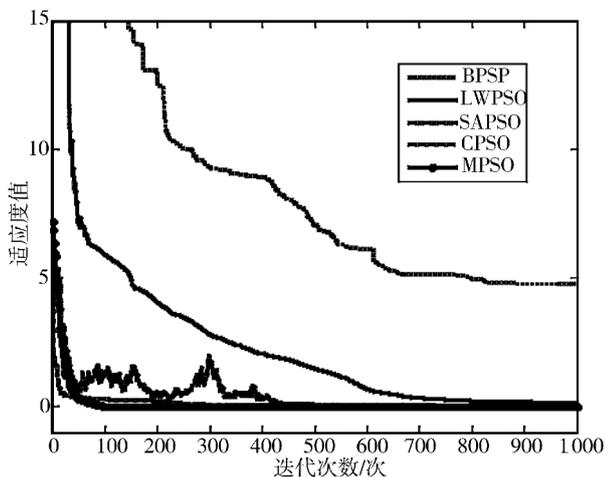


图 2 Sphere 函数的寻优收敛曲线

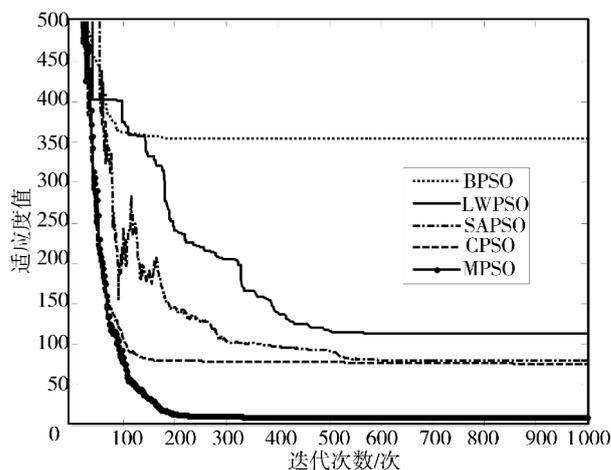


图 3 Rosenbrock 函数的寻优收敛曲线

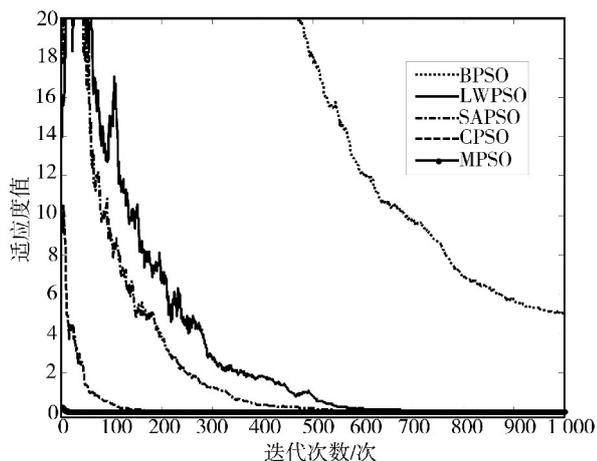


图 4 Griewank 函数的寻优收敛曲线

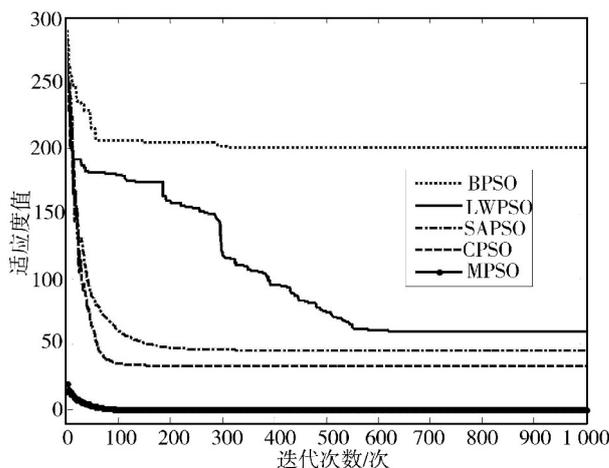


图 5 Rastrigin 函数的寻优收敛曲线

#### 4 基于 MPSO 的重油热解模型参数估计

对重油的热解采用集总反应模型可以简化组分繁多的反应体系,即将反应系统中众多的单一化合物,按动力学特性相似的原则,归并为若干个虚拟组分,以建立简化的集总反应的动力学模型<sup>[1]</sup>。图 6 表示重油热解的

三集总反应过程,设  $x$  为重油  $H$  作为原料生成小于  $510^{\circ}\text{C}$  诸馏分、热解气及甲苯不溶物的产率之总和,  $x_w$  为  $390\sim 510^{\circ}\text{C}$  的重质中间馏分产率,  $x_L$  为热解气、 $210\sim 390^{\circ}\text{C}$  轻质馏分及缩合产物产率之和。

假定:1) 热解反应原料  $H$  为渣油中大于  $510^{\circ}\text{C}$  的甲苯可溶物,反应后生成的中间重质馏分  $W$  可同时再进一步转化成裂解气、轻质馏分及缩合物  $L$ ;2) 由  $W$  转化成集总物  $L(W\rightarrow L)$  的二次反应为一级反应。那么,在等温条件下,总反应级数为 1 时,根据反应机理可推导出反应产率方程式为

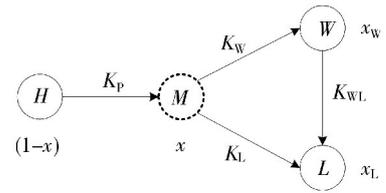


图 6 重油热解的三集总反应过程示意图

$$x_L = \frac{C_L}{n_L} [1 - (1-x)^{n_L}] + \frac{C_W C_{WL}}{n_W - C_{WL}} \left\{ \frac{1}{C_{WL}} (1 - (1-x)C_{WL}) + \frac{1}{n_W} [(1-x)^{n_W} - 1] \right\} \quad (7)$$

考虑到温度的影响,引入 Arrhenius 方程

$$K = K_0 e^{-E/RT} \quad (8)$$

因此有

$K_p = K_{p0} e^{-E_p/RT}, K_L = K_{L0} e^{-E_L/RT}, K_W = K_{W0} e^{-E_W/RT}, K_{WL} = K_{WL0} e^{-E_{WL}/RT}$ , 从而得到

$$x_L = \frac{K_{LP0} e^{-E_{LP}/T}}{n_L} [1 - (1-x)^{n_L}] + \frac{K_{WP0} K_{WLP0} e^{-(E_{WP} + E_{WLP})/T}}{n_W - K_{WLP0} e^{-E_{WLP}/T}} \times \left\{ \frac{1}{K_{WLP0} e^{-E_{WLP}/T}} \left( 1 - (1-x)^{K_{WLP0} e^{-E_{WLP}/T}} \right) + \frac{1}{n_W} [(1-x)^{n_W} - 1] \right\} \quad (9)$$

其中  $x$  和  $T$  (反应温度) 为自变量,  $x_L$  为因变量。(9) 式中需要估计的参数有 8 个, 即  $K_{LP0}, E_{LP}, K_{WP0}, E_{WP}, K_{WLP0}, E_{WLP}, n_W$  和  $n_L$ 。其中  $K_{LP0} = K_{L0}/K_{P0}, K_{WP0} = K_{W0}/K_{P0}, K_{WLP0} = K_{WL0}/K_{P0}, E_{LP} = (E_L - E_P)/R, E_{WP} = (E_W - E_P)/R, E_{WLP} = (E_{WL} - E_P)/R$ 。

文献[1]给出了通过实验采集到的实际观测数据 56 个, 本文以这 56 组实验数据作为样本数据, 利用 MPSO 算法对重油热解模型的 8 个参数进行估计, MPSO 算法的参数设置与前面相同。表 2 给出了 MPSO 算法与标准遗传算法(SGA)、基于优选策略的遗传算法(EGA)<sup>[1]</sup>、基本粒子群优化(PSO)算法<sup>[11]</sup>、复合粒子群优化(CPSO)算法<sup>[11]</sup>和自适应粒子群优化(APS0)算法<sup>[11]</sup>得到的结果比较。从表 2 可以清楚地看出, MPSO 算法得到的平均相对误差仅为 6.18, 优于或相似于比较中的方法, 这表明 MPSO 算法能有效地估计重油热解三集总非线性模型的参数。

表 2 3 种算法对重油热解三集总模型参数估计结果比较

算法	$K_{LP0}$	$K_{WP0}$	$K_{WLP0}$	$E_{LP}$	$E_{WP}$	$E_{WLP}$	$n_L$	$n_W$	平均相对误差/%
SGA <sup>[1]</sup>	4.680	5.155	4.197	1257	1850	3776	1.191	1.488	7.70
EGA <sup>[1]</sup>	4.032	5.058	4.228	1166	3676	2382	1.357	1.570	6.28
SPSO <sup>[11]</sup>	0.112	1.176	3.659	-743	295	-817	1.202	2.915	6.13
CPSO <sup>[11]</sup>	0.151	4.032	4.303	-1013	1770	-400	1.605	2.970	5.85
APS0 <sup>[11]</sup>	5.303	2.9616	1.2086	2388.3	493.88	-240.34	8.8673	5.5449	5.69
MPSO	6.049	3.857	1.360	2560.2	501.62	-286.91	8.9206	5.872	5.62

## 5 结论

本文提出一种参数自适应和维变异的改进粒子群优化算法。为了保证粒子的多样性,为算法全局搜索奠定基础,利用佳点集方法产生初始种群粒子。惯性权重与学习因子随算法进化过程动态自适应调整以协调算法的全局搜索与局部搜索能力。为了避免算法陷入局部最优,对粒子采用维变异操作。4 个标准测试问题和应用实例的实验结果表明,该算法具有较强的全局寻优性能。

### 参考文献:

[1] 宋晓峰, 陈德钊, 胡上序, 等. 基于优选策略的遗传算法对重油热解模型参数的估计[J]. 高校化学工程学报, 2003, 17(4): 411-417.  
 Song X F, Chen D Z, Hu S X, et al. Eugenic evolution strategy genetic algorithms for estimating parameters of heavy oil thermal cracking model[J]. Journal of Chemical Engineering of Chinese Universities, 2003, 17(4): 411-417.

[2] Kennedy J, Eberhart R C. Particle swarm optimization [C]//Proceedings of IEEE International Conference on Neural Networks. Piscataway: IEEE Press, 1995: 1942-1948.

- [3] 王克华, 牛慧, 张亚南, 等. 一种参数自适应调整和边界约束的粒子群算法[J]. 电子设计工程, 2011, 19(21): 46-49.  
Wang K H, Niu H, Zhang Y N, et al. Particle swarm optimization with adaptive parameters and boundary constraints[J]. Electronic Design Engineering, 2011, 19(21): 46-49.
- [4] Liang J J, Qin A K, Suganthan P N, et al. Comprehensive learning particle swarm optimization for global optimization of multi-modal functions[J]. IEEE Transactions on Evolutionary Computation, 2006, 10(3): 281-295.
- [5] Chaturvedi K T, Pandit M, Srivastava L. Particle swarm optimization with time-varying acceleration coefficients for non-convex economic power dispatch[J]. International Journal of Electrical Power & Energy Systems, 2009, 31(6): 249-257.
- [6] 张星会, 白富生. 一种求解混合离散优化问题的禁忌微粒群算法[J]. 重庆师范大学学报: 自然科学版, 2011, 28(2): 5-10.  
Zhang X H, Bai F S. A hybrid tabu search and particle swarm optimization algorithm for mixed discrete optimization problems[J]. Journal of Chongqing Normal University: Natural Science, 2011, 28(2): 5-10.
- [7] Ratnaweera A, Halgamuge S K, Watson H C. Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3): 240-255.
- [8] 张铃, 张钊. 佳点集遗传算法[J]. 计算机学报, 2011, 24(9): 917-924.  
Zhang L, Zhang B. Good point set based genetic algorithm[J]. Chinese Journal of Computer, 2011, 24(9): 917-924.
- [9] 杜继永, 张凤鸣, 李建文, 等. 一种具有初始化功能的自适应惯性权重粒子群算法[J]. 信息与控制, 2012, 41(2): 165-169.  
Du J Y, Zhang F M, Li J W, et al. A particle swarm optimization algorithm with initialized adaptive inertia weights[J]. Information and Control, 2012, 41(2): 165-169.
- [10] 龙文, 梁昔明, 董淑华, 等. 动态调整惯性权重的粒子群优化算法[J]. 计算机应用, 2009, 29(8): 2240-2242.  
Long W, Liang X M, Dong S H, et al. Particle swarm optimization with dynamic change of inertia weights[J]. Journal of Computer Applications, 2009, 29(8): 2240-2242.
- [11] 董跃华, 桑志祥, 李绍军. 改进的 AEA 算法及其在重油热解模型参数估计中的仿真研究[J]. 高校化学工程学报, 2012, 26(2): 332-337.  
Dong Y H, Sang Z X, Li S J. Improved AEA and its simulation on parameter estimation of heavy oil thermal cracking three lumps model[J]. Journal of Chemical Engineering of Chinese Universities, 2012, 26(2): 332-337.

## Parameter Estimation for Heavy Oil Thermal Cracking Model Based on Particle Swarm Optimization Algorithm

LONG Wen, ZHANG Wen-zhuan

(Guizhou Key Laboratory of Economics System Simulation,

Guizhou University of Finance and Economics, Guiyang 550004, China)

**Abstract:** Through establishing an appropriate objective function, the parameter estimation problem for chemical engineering model was formulated as a multi-dimensional numerical optimization problem, which can be solved by modifying particle swarm optimization (MPSO) algorithm with adaptive parameters and dimensional mutation. In this approach, good point set method is used to construct the initialization population which strengthens the diversity of global searching. In the evolution process, in order to balance the global and local search abilities of the algorithm, adaptive inertia weights and acceleration coefficients strategies are introduced respectively. Furthermore, dimensional mutation operator is utilized to avoid the premature convergence. Several benchmark functions are tested; the experimental results show that the MPSO algorithm is an effective way for global optimization problems. The MPSO is successfully applied to the parameter estimation of the thermal cracking model for heavy oil. The results indicate that the mean relative error of the proposed method is only 5.62%, which is less than those of standard genetic algorithm and standard particle swarm optimization by 1.08% and 0.51%, respectively.

**Key words:** particle swarm optimization algorithm; adaptive; heavy oil thermal cracking model; parameter estimation

(责任编辑 游中胜)