

# 一种基于进化过程学习的粒子群优化算法

胡 旺 张 鑫

(电子科技大学计算机学院 成都 611731)

**摘 要** 随机优化的 PSO 只利用了进化过程中的上一时刻  $t$  的速度  $v(t)$  和位置  $x(t)$  信息, 以及个体最优值  $P_i$  和群体最优值  $P_g$ , 缺乏对待优化目标函数特征的充分认识, 导致了后期进化过程的长期停滞现象。PSO 在长期进化过程中, 尤其是在经历了大量函数评估次数的进化后期, 待优化的目标函数的性态特征可以从进化迭代过程信息中得到了解。通过采集学习 PSO 进化过程中的目标函数的解分布特征信息, 使 PSO 可以利用这些特征信息来控制部分粒子的重新初始化过程和交叉选择过程, 以及在参数选择中平衡探索模式和开采模式。实验结果表明, 利用了进化过程信息的 PSO 可以增加种群的多样性, 从而获得更高的优化精度和更少的期望迭代次数, 虽然其轻微地增加了进化过程特征采集的时间和空间复杂性。

**关键词** 粒子群优化, 进化过程学习, 分布特征, 智能粒子

**中图分类号** TP183 **文献标识码** A

## Improved PSO Based on Evolutionary Process Learning

HU Wang ZHANG Xin

(School of Computer Science and Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

**Abstract** Particle swarm optimization(PSO) easily falls into the stagnation at the late evolutionary period because it does not know about the characteristics of the objective function completely. In the classic PSO, the finite information, such as the velocity  $v(t)$ , the location  $x(t)$ , the individual extremum  $P_i$  of the particle and the global extremum  $P_g$  of the swarm at the prior time  $t$ , is employed to drive the evolutionary process. But in the evolutionary of PSO, the distribution characteristics of solutions of the objective function are hidden in the many and many function evaluations while the evolutionary is iterating. The novel PSO based on evolutionary learning(L-PSO) balances the exploration and the exploitation process and controls the re-initialization and crossover selection of particles through the distribution characteristics of solutions extracted statically from the historical evaluations. The experimental results show that the L-PSO can improve the precise of solution and reduce the expected iterations although the time and space complexity is increased lightly.

**Keywords** Particle swarm optimization, Evolutionary process learning, Distribution characteristics, Intelligent particle

## 1 引言

PSO 算法由于形式简单、参数少、易于实现, 并且具有较强的全局优化能力, 因此迅速成为处理困难问题的最有力全局随机优化工具之一<sup>[1]</sup>。尽管 PSO 的研究与应用已经取得了一些成果, 但它在基础理论、模型改进、实际应用、硬件实现以及智能融合方面都还存在着问题。粒子位置和速度的构造与边界控制<sup>[2]</sup>、算法收敛性和稳定性分析<sup>[3]</sup>、参数的设计理论<sup>[4]</sup>尚处于经验水平阶段。

标准 PSO 及其大部分变体, 只利用了进化过程中的上一时刻  $t$  的速度  $v(t)$  和位置  $x(t)$  信息, 以及个体最优值  $P_i$  和群体最优值  $P_g$ , 完全依靠 PSO 方程来控制进化过程方向, 缺乏对待优化目标函数特征的充分认识, 导致了后期进化过程的长期停滞现象<sup>[5]</sup>。因此标准 PSO 算法存在后期收敛速度慢、收敛精度不高等缺点, 同时还依赖于初始解在定义域上的分

布。很多 PSO 的变体都致力于改进这些问题, 主要从参数优化、与其他方法混合等角度出发。文献[6]借鉴蚁群算法引入信息素共享机制提高了群体的信息共享能力。文献[7]提出了综合学习的改进方法, 该方法能在不同维度上选择不同学习对象的学习策略。文献[8,9]从信息交流的程度进行了改进。文献[10]建立了粒子对自身经验信息和群体共享信息认知的内在联系模型, 提高了信息的利用程度。

为了降低 PSO 的函数评估次数, 一些研究人员在 PSO 参数选择、群体拓扑结构、智能优化方法融合等方面做了大量卓有成效的工作。但这些 PSO 改进算法与标准 PSO 一样, 都没有利用待优化目标函数的特征信息, 而是采用纯随机优化的进化方法。本文从 PSO 优化过程中采集目标函数的解分布特征信息, 使 PSO 可以利用这些特征信息控制部分粒子的重新初始化过程和新解交叉选择过程, 以及在参数选择中平衡开采模式和开发模式, 提高 PSO 算法的收敛速度和优化

到稿日期: 2011-06-02 返修日期: 2011-08-11

胡 旺(1974-), 男, 博士, 主要研究方向为计算智能、商业智能, E-mail: scuhuwang@126.com; 张 鑫(1986-), 男, 硕士生, 主要研究方向为计算智能、软件工程。

精度。

## 2 研究动机

PSO(与其他随机优化算法一样)通过粒子数为  $N$  的种群在大量的迭代次数( $G$ )下,对目标函数  $F$  进行  $N * G$  次适应值评估来获得待优化问题的近似最优解及其近似最优值。但 PSO 不像牛顿法等确定性算法需要了解待优化函数  $F$  的性态特征(如函数导数等),而是根据仿生粒子的人工进化方式来引导优化过程。

在  $D$  维目标搜索空间中,由粒子数为  $N$  组成的种群中第  $i$  个粒子在第  $d$  维的位置为  $x_{id}$ ,其飞行速度为  $v_{id}$ 。 $r_1$  和  $r_2$  是服从  $U(0,1)$  分布的随机数;学习因子  $c_1$  和  $c_2$  为非负常数。在进化过程中,PSO 首先初始化一群随机粒子,然后通过迭代找到最优解。在每一次迭代中,粒子通过跟踪两个“极值”来更新自己的速度与位置:个体粒子最优解  $P_{id}$  和群体的全局最优解  $P_{gd}$ 。PSO 通过如下两个带有随机因子的进化式(1)和式(2)在解空间中进行迭代遍历。

$$v_{id}(t+1) = \omega v_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gd} - x_{id}(t)) \quad (1)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (2)$$

从式(1)、式(2)可以看出,PSO 在进化过程中只利用了个体粒子第  $d$  维在上一时刻  $t$  的速度  $v_{id}(t)$  和位置  $x(t)$  信息,以及粒子的个体最优解  $P_{id}$  和群体的全局最优解  $P_{gd}$ 。这导致了 PSO 缺乏对待优化目标函数内在本质特征的理解,从而依靠众多的迭代评估次数来“试探”最优解的分布位置。PSO 及其类似方法(如 GA、ACO 等)依靠增加目标函数评估次数的“以多取胜”策略来实现优化计算,这显著增加了优化过程的时间,也导致了优化精度具有随机性,不过获得了逃逸出局部极值的优势。确定性优化计算方法(如牛顿法、最速下降方向)充分利用了目标函数的特征(如导数)来指导进化方向而加快了优化过程,但这种确定性方法存在需要求导数,以及容易陷入局部极值等缺点而限制了其应用范围。

如果 PSO 算法能够充分利用  $N * G$  次函数迭代过程中产生的可行解,间接地获得一些待优化目标函数的解分布特征,即使这些特征不是精确描述的,也可以为优化过程提供进化的方向,从而加速进化过程,提高进化精度和减少期望迭代次数。

为了提高粒子的“智能”水平,本文从 PSO 迭代过程中已经产生的  $N * G$  个解的样本信息中提炼解的分布特征,并利用这个特征控制粒子的重新初始化过程、交叉选择过程以及平衡探索(Exploration)与开采(Exploitation)过程,以便更有效地控制进化过程。

本文第 3 节介绍 PSO 的解分布特征提取与学习过程;第 4 节介绍改进算法 L-PSO 利用解分布特征控制重新初始化和交叉选择产生新解的过程,以及利用解的分布熵控制参数选择以平衡探索与开采模式,同时总结了 L-PSO 的算法过程;第 5 节介绍实验过程及结果分析;最后总结 L-PSO 算法的思想与特征。

## 3 特征采集与学习

通常,随机优化方法不直接“理解”目标函数本身的特征(如函数导数等)。但随机优化过程是一个从“盲目”到“精化”

的过程,并且大多数随机优化方法可以从理论上保证全局收敛(但可能需要趋近无穷多的迭代次数)。正因为 PSO 随机优化算法经历了大量的迭代次数,并产生了许多反映目标函数特性的统计信息,所以我们可以构建基于概率的统计模型描述目标函数的解分布特征。

一般情况下,被优化的目标函数  $F$  在解空间  $\Omega_D$  中是连续的,对于解的分布特征描述需要用到密度函数。为了方便度量,将某一维度  $d(d \in D)$  在取值范围  $\Omega_{D-d}$  内等分成  $K$  个区间。解  $x$  在  $d$  维上的分量  $x_d$  被映射到某一区间,其编号可以通过式(3)计算得到:

$$Seq_{x_d} = \left\lceil \frac{x_d - L_d^a}{L_d^b - L_d^a} \right\rceil \times K \quad (3)$$

式中, $L_d^a$  和  $L_d^b$  分别表示  $d$  维度上取值范围的最小值和最大值; $Seq_{x_d}$  是一个整数,表示  $x_d$  在  $\Omega_{D-d}$  中的区间编号; $\lceil \cdot \rceil$  表示向上取整符号。

通过以上变换,PSO 的所有迭代解都可以被映射到一组区间序号上。函数  $F$  的所有迭代解  $x$  在维度  $d$  上被映射到区间  $Seq_d^k$  上的频率可以表示为:

$$Q_d^k = \frac{\text{Card}(Seq_d^k)}{\sum_{k=1}^K \text{Card}(Seq_d^k)} \times 100\% \quad (4)$$

式中,Card()表示计算集合的成员个数函数。

$Q_d^k$  是一个的解分布特征变量,它表示在维度  $d$  上,PSO 遍历过的解落在第  $k$  个区间的频率。 $Q_d^k$  的值越大,表示粒子“光顾”该区域的次数越多,该区域的“吸引力”越大,最优值落在该区域的可能性也越大。因此,智能粒子需要抓住有利机会,重点开采该区域,以便提高优化精度;同时智能粒子还需要防止粒子被迭代式(1)“飞越”该区域而错失机会。 $Q_d^k$  的值越小或趋向于 0,意味着该区域是“无人区”,应该派遣智能粒子来探索(Exploration)该区域,以防止“无人问津”最优值区域而陷入局部极小值当中。因此,解分布特征量  $Q_d^k$  可以为粒子的进化提供智能决策。

为了从整体上刻画出解的分布特征,本文引入解分布熵  $H(\Gamma)$  来描述 PSO 方程的解序列  $\Gamma = \{x(1), x(2), \dots, x(t), \dots, x(N)\}$  在解空间  $\Omega$  的分布定义为:

$$H(\Gamma) = \sum_{d=1}^D \sum_{k=1}^K Q_d^k(\Gamma) * \log\left(\frac{1}{Q_d^k(\Gamma)}\right) \quad (5)$$

解分布熵  $H(\Gamma)$  反映了群体在  $\Omega_D$  上的遍历分布情况,其值越大,则探测的范围越广,种群的多样性越好,反映了群体在进行广度探索;其值越小,表明粒子越集中,反映了群体在进行深度开采,或者长期处于停滞状态。因此, $H(\Gamma)$  可以作为探索与开采模式的控制标志量。

由于  $Q_d^k$  是一个累积量,因此 PSO 可以在迭代进化的同时,计算并存储每个区间  $Seq_d^k$  上的频次,以减少  $Q_d^k$  和  $H(\Gamma)$  的计算量。

## 4 基于进化过程学习的 PSO 算法

在上一节中,对 PSO 进化过程中解分布的区间微观特征  $Q_d^k$  和整个群体的宏观特征  $H(\Gamma)$  进行了采集和学习。本节将利用这两个特征量来提高粒子在优化过程中的智能性,使粒子在进行迭代之前思考自己的进化策略。本文将基于进化过程学习的 PSO 改进算法简称为 L-PSO,以便与经典 PSO (C-PSO)相区别。

### 4.1 探索模式与开发模式的切换策略

根据 PSO 进化方程可知,群体粒子最终将停止在由粒子

个体极值  $P_{id}$  和群体全局极值  $P_{gd}$  确定的一个点上。而解分布熵  $H(\Gamma)$  反映了群体在  $\Omega_b$  上的遍历分布情况,如果群体处于停止状态,则粒子将密集分布在某个区域上,解分布熵  $H(\Gamma)$  将不断变小。这样,根据  $H(\Gamma)$  的变化趋势可以控制群体粒子采取广度探索模式还是深度开采模式。

由于不同的待优化问题可能导致粒子遍历的区间个数不一样,从而导致  $H(\Gamma)$  的绝对数值不同。可以通过  $H(\Gamma)$  的变化趋势来评估目前的优化进展态势。当  $H(\Gamma)$  连续  $T_1$  次都减少,且当前粒子的个体极值  $P_{id}$  和群体全局极值  $P_{gd}$  均连续  $T_2$  次处于停滞时,当前粒子进入探索模式,否则当前粒子处于开采模式,其他情况下粒子继续根据迭代式(1)和式(2)处于正常迭代进化过程。

$T_1$  与  $T_2$  的取值在一定程度上会影响改进算法的效率,根据大量实验观察结果, $T_1$  与  $T_2$  取值在 8~15 之间可以取得比较好的效果。

#### 4.2 重新初始化策略

当智能粒子处于探索模式时,重新初始化可以增加种群的多样性,使得处于停滞的粒子有机会继续参与进化过程。另外,当粒子位置  $x$  超出边界时,一种处理方式就是重新初始化粒子。有了解分布特征  $Q_d$ ,智能粒子就可以选择在“无人问津”的区域内初始化,以便有更多的机会发现最优解而逃逸出局部极小值。

因此,当粒子需要重新初始化时,可以在  $Q_d \leq q$  ( $q$  接近于 0) 时的区域内随机选择位置初始值。

#### 4.3 交叉选择产生新解策略

当智能粒子处于开采模式时,PSO 希望在精华解附近再提高优化精度(发现更优解)。因此,如何尽可能找到潜在的精华解是一个重要的问题。

当  $Q_d$  较大时,意味着该区间被 PSO 进化方程引导大量粒子访问过,局部极值和全局极值在这些区间的概率较大。在每一维  $d$  上按照  $Q_d$  的解分布特征,依据概率选择区间  $k$  作为  $x_d$  的精华解。因此第  $d$  维区间  $k$  的选中概率模型为:

$$P(\text{Seq}_d^k | K) = Q_d^k \quad (6)$$

将所有  $D$  个维度都按照式(6)进行区间选择后构成潜在的精华解  $x'(t+1)$ ,实际上是由众多的精华解按照解分布特征进行杂交而成的。 $x'(t+1)$  按照式(1)和式(2)进化形成  $x(t+1)$ 。

式(6)确保了较好的解以较高的概率进入到精华解  $x'(t+1)$  中,从而提高了优化精度和优化效率。

#### 4.4 算法描述及复杂性分析

L-PSO 改进算法在 C-PSO 的基础上增加了解的分布特征计算和进化模式切换两个关键步骤,并增加了探索模式进化策略和开采模式进化策略。根据第 3 节和第 4.1—4.3 节的介绍,L-PSO 算法可以总结如下:

- 第 1 步 随机初始化种群中的所有粒子的位置和速度;
- 第 2 步 评估种群中粒子的适应值;
- 第 3 步 计算解分布特征  $Q_d$  和  $H(\Gamma)$ ;
- 第 4 步 根据  $H(\Gamma)$  切换粒子的进化模式;
- 第 5 步 按照进化模式实施常规模式进化、探索模式进化和开采模式进化策略;
- 第 6 步 计算粒子的新的适应值;
- 第 7 步 终止条件判断,如果达到迭代次数或优化精度,则迭代终止;否则转入第 3 步。

L-PSO 增加了解分布特征的计算,自然也增加了改进算法的时间复杂度和空间复杂度。为了存储中间计算变量,L-PSO 比 C-PSO 平均需要增加  $K * D$  个存储空间(其中  $D$  为待优化问题的维度数, $K$  为平均每个维度等分的区间数)。在 L-PSO 迭代过程中,需要增加  $N * G * D$  次  $Q_d$  计算,以及  $N * G * D * K$  次计算量而获得  $H(\Gamma)$ ,并且还需要增加  $N * G$  次模式切换比较运算(其中  $N$  为种群粒子数, $G$  为迭代次数)。

L-PSO 以牺牲空间复杂度和时间复杂度来换取收敛精度的提高和收敛速度的提升。从某种角度上来看,收敛速度的提升,尤其是前期进化速度的提高,可以减少迭代次数  $G$ ,以降低算法的复杂度。

## 5 实验及其结果分析

由于 L-PSO 算法可以叠加于 PSO 及其改进算法,甚至是基于群体的进化算法,因此,只对 C-PSO 算法进行相同参数的对比实验,以说明其在典型测试函数上的性能改进效果。

本文选择以下 F1-F3 作为测试函数,如表 1 所列。

表 1 用于测试改进算法的基准函数

Code & Name	Formula	Dim $n$	Range $[x_{\min}, x_{\max}]$	Optimal $f$	Goal $f(\text{Log}10)$
F1: Griewank	$f_2(x) = \frac{1}{4000} \sum_{i=1}^n (x_i)^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	10	$[600, 600]^{10}$	0	-1
F2: Rosenbrock	$f_3(x) = \sum_{i=1}^{n-1} (100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2)$	10	$[100, 100]^{10}$	0	0
F3: Rastrigin	$f_4(x) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10)$	10	$[100, 100]^{10}$	0	0

L-PSO 与 C-PSO 算法的共同实验参数设置如下:种群粒子数为 20;最大迭代次数为 300;目标函数的维度数为 10;加速度常数  $c_1$  和  $c_2$  分别为 1.429;惯性系数  $\omega$  为 0.729。L-PSO 算法的专门参数设置如下: $T_1$  和  $T_2$  分别取值为 10。为了控制进化曲线的显示范围,将目标函数的适应值取 10 为底的对数。同时,为了降低随机因子对实验结果的波动影响,本实验重复运行 20 次,实验结果取 20 次运行的平均值。L-PSO 和 C-PSO 算法在函数 F1-F3 上的平均适应值的进化曲线如图 1 所示。

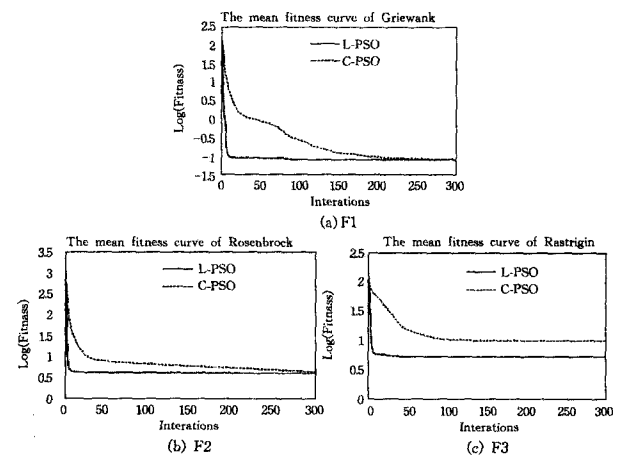


图 1 测试函数 F1-F3 的平均适应值进化曲线

有比较好的处理效果,一直能够平稳跟踪。




图6 多干扰情况下一位抱小孩妇女的跟踪效果结束语

对于复杂场景下的目标跟踪,要求跟踪算法对场景有很强的适应能力。本文在设计跟踪算法时,通过在线调整控制粒子滤波算法中似然观测模型的高斯方差来实现特征的自适应融合,从而提高了算法对各种场景的适应能力;粒子滤波的重采样过程中采用了聚类核函数平滑采样的方法,不仅提高了粒子预测的准确性,也解决了粒子退化问题。两组视频跟踪实验结果表明,优化后的算法对于目标存在遮挡、背景干扰以及光照变化影响下的跟踪均具有良好的效果。

### 参考文献

[1] 高世伟,郭雷,杨宁,等.一种新的粒子滤波目标跟踪算法[J].上海交通大学学报,2009,43(3):485-489

[2] Deguchi K, Kawanaka O, Okatani T. Object tracking by the mean-shift of regional color distribution combined with the par-

title-filter algorithms[C]//Proc of IEEE Int Conf on Pattern Recognition. Cambridge,2004,3:506-509

[3] 王鑫,唐振民.基于特征融合的粒子滤波在红外小目标跟踪中的应用[J].中国图象图形学报,2010,15(1):91-97

[4] 张辉,赵保军,唐林波,等.基于自适应多特征整合的红外目标跟踪[J].光学学报,2010,30(5):1291-1296

[5] Brasnett P, Mihaylova L, Bull D, et al. Sequential Monte Carlo Tracking by Fusing Multiple Cues in Video Sequences [J]. Image and Vision Computing,2007,25(8):127-1227

[6] Sabbi A S. Object tracking in a stereo system using particle filter [Z]. University of Texas at Arlington,2005

[7] 胡士强,敬忠良.粒子滤波原理及其应用[M].北京:科学出版社,2010

[8] 陈爱斌,蔡自兴,董德毅.一种基于目标和背景加权的跟踪方法[J].控制与决策,2010,25(8)

[9] Borden B H, Mumford M L. A statistical glint/radar cross section target model [J]. IEEE Trans on AES,1983,19:781-785

[10] 陆可,肖建. IMM算法实现非线性状态估计的研究与仿真[J].计算机仿真,2008,25(5):77-80

[11] Nummiaro K, Meier E K, van Gool L. An adaptive color-based particle filter [J]. Image and Vision Computing,2003,21:99-110

(上接第195页)

从图1可以得出以下结论:(1)L-PSO获得了比C-PSO更高精度的平均最优适应值。L-PSO在F1-F3函数上获得的平均最优值分别为-1.0906,0.6195和0.7245;而C-PSO在F1-F3函数上获得的平均最优值分别为-1.0653,0.6637和0.9989。这表明,改进的算法充分利用了开采过程,提高了收敛精度。(2)L-PSO算法在进化前期获得了很高的收敛速度。F1-F3分别在前50次迭代(或者前1000次函数评估)内就基本上搜索到了较好的最优值。这对于实时在线优化问题和目标函数本身大计算量的问题(如图像处理)具有较好的实用性。

图2是F1函数在优化过程中解x在第1维上的振荡曲线。由图2可以看出,C-PSO在经过一定迭代次数之后便“静止”下来了;而L-PSO中的粒子始终具有较好的“活性”,这得益于探索模式的切换,使得种群具有较高的多样性,从而增加了逃逸出局部极小值的概率。




图2 粒子位置在进化过程中的振荡曲线

以上实验结果表明,充分利用PSO进化过程信息而得到的目标函数的解分布特征可以有效地引导群体进化过程。同时这种思想可以叠加到其他的基于种群的优化计算之中。

**结束语** 本文通过PSO进化过程中产生的解分布特征信息的采集与学习,并充分利用这些信息来改进PSO的进化策略,使得PSO具有额外的进化方向指导,增强了粒子的智能性。实验结果表明,这种方法提高了PSO种群的多样性和

优化精度,以及进化前期的收敛速度。尽管这种方法增加了进化过程的时间复杂性和空间复杂性,但对实时优化问题和复杂优化问题具有很好的应用价值。

### 参考文献

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

[2] 迟玉红,孙富春,王维军,等.基于空间缩放和吸引子的粒子群优化算法[J].计算机学报,2011,34(1):116-130

[3] van den Bergh F. An analysis of particle swarm optimizers [D]. South Africa:University of Pretoria,2002

[4] Trelea IC. The particle swarm optimization algorithm: convergence analysis and parameter selection[J]. Information Processing Letters,2003,85(6):317-325

[5] Clerc M. Stagnation analysis in particle swarm optimization or what happens when nothing happens [OL]. [http://clerc.maurice.free.fr/ps0/stagnation analysis](http://clerc.maurice.free.fr/ps0/stagnation%20analysis)

[6] 吕强,刘士荣,邱雪娜.基于信息素机制的粒子群优化算法的设计与实现[J].自动化学报,2009,35(11):1410-1419

[7] Liang J, Qin A, Suganthan P, et al. Comprehensive learning particle swarm optimizer for global optimization of multimodal functions[J]. IEEE Transactions on Evolutionary Computation,2006,10(3):281-295

[8] Kennedy J, Mendes R. Neighborhood topologies in fully informed and best-of-neighborhood particle swarms [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part C: Application and Reviews,2006,36(4):515-519

[9] Mendes R, Kennedy J, Neves J. The fully informed particle swarm: simpler, maybe better[J]. IEEE Transactions on Evolutionary Computation,2004,8(3):204-210

[10] 申元霞,王国胤,曾传华.相关性粒子群优化模型[J].软件学报,2011,22(4):695-708