

# 粒子群优化方法在动态优化中的研究现状

陈杰<sup>1</sup>, 潘峰<sup>1,2</sup>, 王光辉<sup>1</sup>

(1. 北京理工大学 复杂系统智能控制与决策教育部重点实验室, 北京 100081; 2. Department of Electrical and Computer Engineering, Purdue School of Engineering and Technology, Indiana University-Purdue University Indianapolis, Indianapolis, IN 46202, USA)

**摘要:**作为一种基于群智能的并行随机优化方法, 粒子群优化算法(PSO)在优化求解问题中体现出了良好的性能。从提出至今引起了广泛的关注, 研究成果也不断涌现。从 2000 年开始, PSO 被用于动态优化问题中。这对 PSO 的研究提出了新的挑战, 对于动态问题的优化不再是在解空间中找到一个最优点, 而是要尽可能地在解空间中跟踪运动变化的最优点。对目前为止对于 PSO 在动态环境优化问题的研究内容进行了分析和总结, 介绍了针对动态环境优化问题 PSO 的改进方法、对环境变化的检测和应对策略、优化性能评价的一系列方法以及各种试验及应用案例。

**关键词:**粒子群优化方法; 动态环境优化; 检测策略; 应对策略; 性能评价

中图分类号: TP391.41 文献标识码:A 文章编号:1673-4785(2009)03-0189-10

## Review of the PSO research in dynamic environments

CHEN Jie<sup>1</sup>, PAN Feng<sup>1,2</sup>, WANG Guang-hui<sup>1</sup>

(1. Key Laboratory of Complex System Intelligent Control and Decision of Ministry of Education, Beijing Institute of Technology, Beijing 100081, China; 2. Department of Electrical and Computer Engineering, Purdue School of Engineering and Technology, Indiana University-Purdue University Indianapolis, Indianapolis, IN 46202, USA)

**Abstract:** Particle swarm optimization (PSO), a parallel random optimization method based on swarm intelligence, exhibits good performance for optimization problems. Since 2000, PSO has been applied to optimization problems in dynamic environments. The challenge with PSO is that the objective is not only to locate an optimum, but also to track that moving optimum as closely as possible. This paper presented the latest developments of PSO in dynamic environments. Various research approaches were reviewed, including improvements in PSO, dynamic change detection, response strategies, performance evaluation and experiments used in researching dynamic problems.

**Keywords:** particle swarm optimization (PSO); optimization in dynamic environment; detection strategy; response strategy; performance evaluation

生物社会学家 E. O. Wilson 认为, 对于生物种群, 个体在搜索食物的过程中可以从群体其他成员的经验和经历中获取信息, 在搜索未知的、不可预测的零星分布的食物时, 这种协作行为的优势远大于竞争压力。从这种协作模型中得到启示, Kennedy 和 Eberhart<sup>[1]</sup>于 1995 年提出了基于群体智能的并行优化算法—粒子群优化方法 (particle swarm optimizer, PSO)。并且随着十多年的研发进展, 研究成果不断

涌现<sup>[2]</sup>。然而, 在现实世界的许多系统中存在很多动态的问题。所谓动态问题, 是指问题中变量的状态常常随着时间的变化而变化, 可以是随时间离散变化, 或随时间连续变化的, 甚至有些是交替进行的, 诸如价格浮动、路径规划、目标识别、动态规划、投资分配、数据挖掘等等。动态优化问题, 就是为了获得诸如上述动态问题的最优解随时间的变化轨迹。动态优化问题对计算智能方法提出了挑战, 主要是因为动态问题中, 不再要求算法在搜索空间中寻找最优值, 而是希望它们能在解空间中尽可能的跟踪最优解的变化轨迹。同遗传算法、进化计算法、进化规划等优化方法类似, PSO 的研究也已建立了一个多

收稿日期: 2008-08-22。

基金项目: 高等学校优秀青年教师教学科研奖励计划资助项目 (20010248)。

通信作者: 潘峰。Email: andropan@gmail.com。

元化、系统化的框架。这也使得难以面面俱到地尽览 PSO 研究现状的各个方面。因此,本文将专注于 PSO 在动态环境下的优化问题的研究现状。

通过进化计算方法对动态系统进行优化的研究最早可追溯到 1966 年<sup>[3]</sup>,但是直到 20 世纪 80 年代后,才引起学者们广泛的研究兴趣。之后,对各种算法的不同改进方法层出不穷。自从 1995 年 PSO 被提出后,对 PSO 的改进方法和扩展设计相继涌现<sup>[4-5]</sup>。最初由 Carlisle 和 Dozier<sup>[6]</sup>、Eberhart 和 Shi<sup>[7]</sup>从 2000 年开始将粒子群优化算法应用于解决动态跟踪系统问题。动态 PSO 算法在随机搜索策略基础上,增加了环境检测过程,并对检测结果做出响应,调整动态 PSO 算法的搜索策略。

## 1 动态优化问题中 PSO 搜索策略

### 1.1 标准 PSO 搜索策略

标准 PSO 算法中,每个粒子代表一个可能的解,所有的粒子组成群。假设在  $D$  维搜索空间中进行问题求解,群体由  $m$  个粒子组成,  $S = \{x_1^k, x_2^k, \dots, x_m^k\}$ 。 $k$  时刻第  $i$  个粒子在搜索空间中的位置向量为  $x_i^k = (x_{i1}^k, x_{i2}^k, \dots, x_{in}^k)$ ,  $i = 1, 2, \dots, m$ , 这也是问题的一个潜在的可能解,其对应的速度向量为  $v_i^k = (v_{i1}^k, v_{i2}^k, \dots, v_{in}^k)$ 。PSO 的邻域函数在每一个迭代周期根据个体自身位置向量、速度向量、个体历史信息、群体信息和扰动来产生新的位置状态(如式(1))。各参数意义如表 1 所示。

$$\begin{aligned} v_{id}^{k+1} &= w \cdot v_{id}^k + c_1 \cdot r_{id}(p_{id}^k - x_{id}^k) + \\ &\quad c_2 \cdot r_{gd}(p_{gd}^k - x_{id}^k), \\ x_{id}^{k+1} &= x_{id}^k + \eta \cdot v_{id}^{k+1}. \end{aligned} \quad (1)$$

表 1 参数意义

Table 1 Nomenclature

参数	意义	参数	意义
$\omega$	惯量因子	$c_1, c_2$	加速因子
$\eta$	速度比例约束因子	$r_{id}, r_{gd}$	在(0,1)之间的随机数
$x_i^k$	第 $i$ 个粒子 $k$ 时刻位置向量	$m$	种群粒子数量
$v_i^k$	粒子运动速度向量	$D$	搜索空间维数
$p_i^k$	个体位置最优值	$p_g^k$	群体位置最优值

粒子在搜索空间中不断通过自身信息  $p_i^k$  和群体信息  $p_g^k$  向目标点运动。这种显式的描述使得算法中粒子运动的物理含义相对于其他计算智能的方法而言更容易理解。但作为一个由若干粒子个体组成的群体复杂系统,以及算法中存在的各种待定参数和约束条件,使得 PSO 算法在简单的物理框架下,却又体现出复杂的运动特性。因此除了采用标准的

PSO 搜索策略(式(1))以外,提出了很多改进搜索策略来提高 PSO 的性能。

### 1.2 针对动态优化问题的 PSO 改进搜索策略

#### 1.2.1 基于参数调节改进

Carlisle<sup>[6]</sup>使用的自适应 PSO (adaptive PSO, APSO) 是早期带线性递减惯量因子  $\omega$  的基本 PSO 算法,即式(1)中  $\omega$  是随迭代周期递减的线性函数;但是没有采用  $V_{\max}$  的 Lipschitz 约束,没有这个约束,粒子个体的运动很容易进入不稳定的区域。从这个角度来看有益于增加群体多样性,  $\omega$  随着迭代周期递减,使得粒子动态系统的参数稳定域变宽,从而保证了群体将最终收敛到解空间中的某一个极值区域<sup>[8]</sup>。与前者不同的是, Eberhart<sup>[7]</sup> 和 Hu<sup>[9]</sup> 采用  $\omega$  在  $[0.5 + \text{Rand}/2]$  范围内随机取值的方法。作为对 APSO 的一种改进, IAPSO<sup>[10]</sup> (improved adaptive particle swarm optimizer) 定义了一个活跃因子,以控制粒子在空间的分布与多样性。Esquivel<sup>[11]</sup> 提出的一种混合 PSO(hybrid PSO, HPSO\_dym) 方法中,采用了大变异操作。GA 的变异操作对于 PSO 而言,作用和原理都类似于 PSO 当中的扰动因子,用以保证系统的多样性。

#### 1.2.2 基于距离的改进

基于对静电场能量的类比, Blackwell<sup>[12-13]</sup> 提出了一种“带电粒子”PSO (charged PSO, CPSO)。它通过额外增加加速因子来模拟实现带电粒子对其他的带电粒子排斥效果,借此来保持系统多样性,以应对环境的动态改变问题。这种 CPSO 进一步扩展为“原子核”PSO<sup>[14]</sup> (atomic PSO, APSO), 即只让一半粒子(质子)带正电模拟额外的加速因子,而让另外一半粒子(中子)保持中性不带电。Jatmiko<sup>[15]</sup> 将 CPSO 和标准 PSO 相结合,并增加一个排斥函数,以保持系统多样性的平衡,他这种改进的方法可以应用于对气味源定位的问题上。

#### 1.2.3 基于信息的改进

与重置(reset)操作舍弃所有当前信息不同,在对动态定价问题的研究中, Mullen<sup>[16]</sup> 提出了个体最优化 PSO (p-best decay PSO, PBDPSO)。当群体监测到动态环境中任何变量的变化,并且触发响应操作的时候,每个粒子个体最优值  $p_i^k$  的适应值按照衰退比率进行衰退。和 PBDPSO 类似, 动态跟踪 PSO (tracking dynamic PSO, TDPSO) 在每次迭代中使用一个蒸发常数(evaporation constant), 用来蒸发(递减)个体最优  $p_i^k$  和群体最优  $p_g^k$  粒子的适应值。这 2 种算法在更新它们的历史信息中,为保持粒子的简单行为而不使用集中控制方法;并且二者都通过对

群体中的历史信息的衰减来减少信息传递压力,以维持群体的多样性. Pan<sup>[17]</sup> 和 Dou<sup>[18]</sup> 将模拟退火算法中的基于概率的选择机制引入到 PSO 中 (PSO with simulated annealing, PSOwSA), 来作为 PSO 算法的选择函数. 这样有条件地接受劣于当前解的点, 可以改善群体中粒子间的信息传递方式, 减轻信息传递压力, 有利于多样性的保持.

#### 1.2.4 存在的问题

在每一次环境发生动态变化时, 多样性状态直接决定了群体对动态变化的适应能力和潜在的进行进一步搜索的能力. 因此, 在对 PSO 的搜索策略改进方法中, 都注重采用各种方法以改善群体的多样性. 对于基于参数调节类的方法中, 存在的问题是如何选择待调节的参数的值. 无论是 IAPSO 中的活跃因子, 还是 HPSO\_dyn 中的变异参数, 作者都没有给出引入系统中的扰动与动态变化的关系. 这样在环境和问题没有动态变化期间, 以及无论动态变化的情况如何, 都采用一种通用型扰动策略和数值, 并不利于算法性能的提高. 对于基于距离的改进方法而言, “带电粒子”PSO、“原子核”PSO 或者排斥函数, 都面临着对距离的掌控和平衡问题. 在求解的不同阶段和针对不同的问题, 对距离的要求是不同的, 那在对问题的先验知识有限的情况下, 只能通过试凑的方法来得到参数的设置. 对于基于信息的改进方法而言, 无论是衰退比率参数, 抑或是蒸发常数, 对算法而言都是新引入的人为设定参数, 使得算法更加依赖于参数的调解<sup>[19]</sup>.

#### 1.3 基于种群的策略

多种群进化算法, 常被用来在多形态环境下进行多峰值定位, 以及增强在动态环境下的搜索能力, 正如 Branke 提出的自组织群算法<sup>[20]</sup> (self organizing scouts, SOS), Oppenacher 和 Wineberg<sup>[21]</sup> 提出的均衡迁移 GA (shifting balance GA, SBGA) 等. 这些算法通过使用一些较小的子群来搜寻并监控大量的潜在可行峰值, 而另外一些则对未知的区域进行进一步的探索. 基于多种群的概念, 多群体的方法被引入到 PSO 中, 通过多个粒子群体用来同时跟踪多个最优值.

Blackwell<sup>[22]</sup> 设计了“多带电粒子”PSO (multi-charged PSO, multi-CPSO) 和多量子群算法 (multi-quantum swarm optimizer, multi-QSO). Multi-CPSO 作为 CPSO 的多种群进化的一种改进方法, 在多模空间中, 每个局部极值附近都会分布有一个 CPSO 子群, 而中性的子群将继续搜索; 并且以一定的距离环绕在带电粒子周围以保持足够的多样性, 以跟踪系统的动态变化. 同样是在这篇论文中, 基于量子模型

而不是静电的原子模型, Blackwell 采用量子的模型与带电粒子进行类比, 提出了多量子群算法 (multi-QSO). 由于量子微粒的位置由种群吸引子的概率函数决定, 所以可以避免粒子间相互对比计算, 量子原子同时具有复杂性低、分布容易控制的优点.

Parrott 和 Li<sup>[23]</sup> 提出的基于种群的 PSO (speciation-based PSO) 基于粒子间的相似性, 在每个迭代周期, 粒子被自适应划分为不同的子群, 每个群体存在 1 个主导粒子, 并集中在 1 个“食物”周围. 算法中采用 Pmax 作为一种避免粒子过分集中, 该参数限制了每一个种群中允许的最大粒子数. 通过这些 PSO 模型改进机制的引入, 可以避免粒子过分集中收敛到某一个峰值, 提高算法对多峰值同时跟踪的能力.

Parrott<sup>[24]</sup> 继而提出了一种改进的 SPSO 模型, 引入了在子群中删除冗余重复粒子的机制, 以获得更高效的性能. 在综合考虑一些现有的多种群进化计算方法改进措施的基础上, 并以此为出发点, Li<sup>[25]</sup> 设计了基于物种群拓展 PSO 算法, 算法中采用多种改进方法: Pmax<sup>[23]</sup>、中子和量子概念<sup>[22]</sup> (保持更优多样性的 multi-QSO 模型方法)、多样性阈值方法 (触发以最差种群的逆收敛<sup>[26]</sup> 复位过程)、子群内的多样性阈值 (用以判断粒子是否进行粒子重分布操作). 通过并行种群机制和一些列的改进方法, 增加了种群收敛到多个局部最优值而非单一全局最优的能力.

Pan<sup>[17-18]</sup> 将群体分为 3 个子群 (swarm-core evolutionary PSO, SCEPSO), 以期望兼顾局部搜索和全局搜索. 其中核心群采用进化规划算法用以在最优点附近形成新的群体, 另外 2 个子群分别负责进行细化搜索和探索未知区域.

Wang<sup>[27]</sup> 设计了多种群协同 PSO (cooperative multi-swarms particle swarm optimizer, CmSPSO), 将整个群体分为一些子群, 各子群分别搜索解空间中不同的潜在可行解. 当 2 个子群的最优个体距离小于排斥半径时, 保留着 2 个群体中的最优个体, 然后同时对 2 个群体中的部分个体进行协同随机初始化. 虽然文章指出排斥半径与求解区域大小成正比, 与峰数及粒子数目成反比; 但是仍然缺乏有效的对排斥半径的定量计算, 群体协同随机初始化的比例也许要进一步确定.

无论是各种不同的优化方法 (如 GA、EA、GP、PSO), 还是针对不同的问题 (如动态优化、多目标优化、约束优化问题等), 多种群是一种广泛采用的思路, 从计算模型、算法结构和信息传递的拓扑结构等

方面都进行了有效的改进。但是需要引入额外的机制或者参数,来控制种群间的分布,以维持种群间的多样性,这无疑在算法中引入了新的待调整参数。此外在考虑多种群思路的同时,应该充分的考虑到计算的复杂性。PSO 的魅力之一就是其简单而高效的性能,如果算法过于复杂,就失去了 PSO 原本的特色。另一个原因是,算法采用的个体过多,计算过于复杂的话,对于同样的问题在同样的计算时间和消耗下,如果采用经过简单的 Monte Carlo 抽样都可以遍历很大的解空间,甚至有可能找到满意的解,那么就失去了启发式优化方法自身的优势。

## 2 环境变化检测方法

PSO 已有的研究表明,PSO 对静态环境和动态环境的最优化问题均有较好的效果。它能快速收敛到最优值,但往往也付出了多样性丢失的代价,因而算法容易提前收敛到局部最优。在优化进化过程中,个体粒子参考群体最优粒子来搜寻目标并趋向于收敛。因此,对于一个损失了多样性的群体而言,如果没有有效的策略去增加群体的多样的话,传统的 PSO 方法很难对外界环境变化做出有效的反应,并难于重新启动对新环境的探索过程。因此,目前的研究中,一类方法是在优化过程中采用某些机制来定期判断动态环境变化。

### 2.1 无环境动态检测方法

对于保持种群的多样性研究的一个出发点就是,在整个算法计算过程中采用某种机制保持群体的多样性,以便使粒子对环境改变做出自适应调整。这种思路主要的优点在于不需要对探测环境改变做特定的操作,而在算法事先的设计中引入一些机制,使群体在优化过程中始终能保持一定的多样性<sup>[12,28]</sup>。它适合于目标函数是连续的小范围变化情况。

另外一类不采用检测操作的方法,采用周期的动态环境响应和多样性激发的策略。Carlisle<sup>[6]</sup>使用的自适应 PSO (adaptive PSO, APSO) 中,在经过一定的周期后,响应动态环境的操作将被激发,这暗示着虽然这种方法对环境不进行监测;但是默认经过一定周期后,环境是有可能产生变化了,而且必须进行响应操作,以激发群体多样性。Esquivel<sup>[11]</sup>提出的 hybrid PSO 算法假设已知环境的周期性动态变化,并对这个周期进行相应的检测。在文献[9]中,检测群体最优粒子  $g_{best}$  和次优粒子的适应值在 20 个周期内是否没有改变,如果没有改变则激发响应操作。和这种方法类似的是文献[15]中的方法,它采用监测群体最优粒子  $g_{best}$  在 20 步内是否改变的方法。

### 2.2 有环境动态检测操作

有很多方法被设计用来测量描述环境的动态变化,而后算法针对该变化做出自己的调整和响应。这些方法大多数都是建立在环境变化是已知的假设上,或环境变化至少是可观和可测的,比如可以通过重新计算目标函数值来反应。一种比较普遍的描述环境变化方法是通过计算一个或一些点的适应值,然后通过同前一时刻的适应值进行比较得到。

Carlisle<sup>[6]</sup>在搜索空间中随机选择一个点作为环境变化量测点,而且当且仅当它的适应值变化超过一个设定的范围时,算法才对此做出相应调整。Carlisle<sup>[6,29-30]</sup>提出了多种形式的“岗哨” PSO (sentry PSO, SPSO)。顾名思义,“岗哨”粒子意味一种对动态环境带有监督和监控的 PSO 方法。该方法在搜索空间中选择一个或者多个特定的点,这些点可以是固定的或者遵循某一分布的随机的点,在每次迭代中将自己的适应值与历史适应值比较,从而对环境变化进行检测。在文献[31]中,Veeramachaneni 也同样采用的是这种方法,并将这种动态 PSO 方法应用于信息融合。Pan<sup>[17-18]</sup>也将固定的“岗哨”粒子作为 SCEPSO 和 PSOwSA 算法对动态环境的检测点。

与随机选择一个点的方法不同,Hu<sup>[9]</sup>通过选择群体最优粒子  $g_{best}$  来作为检测点。综合文献[6,9],Mullen<sup>[16]</sup>一方面使用  $g_{best}$  作为探测点,另一方面设定一个阈值来减小存在于动态定价问题中的噪声的影响。Blackwell<sup>[26]</sup>选择每个种群中的量子粒子作为探测点。协同进化群优化方法 CESO 中,通过重新计算第一个子群 CRDE 的最优个体的目标函数值来探测动态系统的变化<sup>[32]</sup>。Bird<sup>[33]</sup>的方法是对于冯·诺依曼邻域模型 PSO,则监测前 5 个最优粒子的  $p_{best}$ ,对于种群 PSO (species-based PSO) 则记录前 5 个最优子群中最优个体的  $p_{best}$ 。文献[25]采用的也是这个策略,Wang<sup>[27]</sup>在每个迭代周期内检测每个种群的群体最优粒子,来判断是否发生动态变化。对于基于种群类的方法,另一种检测方法<sup>[24]</sup>是在每个迭代周期里,对每一个  $p_{best}$  在它们原来的位置上重新计算每一个粒子的  $p_{best}$  适应值。IAPSO 将所有粒子都作为检测点,每个周期所有粒子都要进行一次适应度函数计算。

对于无特定环境动态检测的方法多基于一定的假设条件,进而设计动态相应策略;但这一类方法的前提是算法对环境的动态变化规律的假设接近实际的环境变化规律,或者其差别在可接受的范围之内。否则优化的进程就不能充分相应和跟踪系统的变化,而失去了动态优化的意义,因此这种方法对问题

的依赖性很强. 其优点是这种方法并不依赖于环境的变化是局部的、或者全局的, 都能对动态变化做出反应.

而对环境变化需要进行检测或者监测的方法, 额外地增加了计算函数适应值的额外负担. 这些对环境的监测方法, 尤其是基于个别粒子或者个别点的监测的方法, 都基于一定假设. 即动态变化是全局性, 或者通过个别的监测粒子可以反映环境的动态变化, 或者即使环境的动态变化是局部性的变化, 群体也能通过检测点得到触发信息. 但如果环境只是在局部产生动态变化(如第5节中局部适应值峰值变化), 尤其是现实生活中的实际问题, 就需要进一步研究对动态环境进行监测的方法.

### 3 动态响应策略

与其他计算智能的方法(如 EA、EP、GA 等)类似, PSO 算法的性能很大程度上要依赖于种群在探索已知与开拓未知能力上二者间的平衡, 群体的多样性对这种平衡的影响至关重要. 特别是动态系统中跟踪群体的行为, 如果失去了多样性, 则变得毫无希望了. 一般来说, 动态系统中多样性问题多通过 2 种机制来解决: 主动式和响应式<sup>[34]</sup>. 当然, 也有一些算法同时使用这 2 种机制, 比如一些基于种群的 PSO. 因此, 本文主要通过 3 个方面来分析为解决动态变化的各种调整策略: 主动式、响应式以及混合策略.

#### 3.1 主动式策略

预处理策略在文中定义为一种不基于对动态变化进行探测的应对机制, 用以实现防止群体收敛过快和保持群体多样性. 它可以通过减小选择压力, 降低历史记忆信息的影响, 周期性增加系统多样性或采用多种群结构等实现. 基于主动式策略的 PSO 算法能够具有较好的动态寻优效果, 尤其是针对动态环境变化小或者缓慢的情况; 但是从另一方面来考虑, 为了保持多样性, 群体不能较快地收敛, 而且不能充分接近动态的最优值.

当系统动态变化时, 群体的历史信息就变成了相对陈旧的过时信息, 在新环境下它有可能就是错误的, 这将会导致对其他个体的误导. “重置”(reset)是处理过时信息和保持种群多样性最常用的机制之一, 它动态地用一些粒子位置向量或者重新计算得到的适应值来替代另外一些粒子的位置向量或适应值. 例如每间隔一定迭代周期, 就用粒子个体当前的位置向量代替它们最优个体  $p_{best}$  的位置向量  $p_i^k$ , 来减少种群对历史信息的依赖<sup>[6, 24, 25, 33, 35]</sup>. Jatmiko<sup>[15]</sup> 采用重新设定  $g_{best}$  的适应值为初始值

( $g_{best} = 0$ ), 来让所有机器人能够跟踪到环境的动态变化进行气味源定位. 该文中将“带电粒子”CP-SO<sup>[12]</sup> 和标准 PSO 相结合, 并增加了一个排斥函数来维持群体多样性平衡. CPSO 以及排斥函数的使用也有助于对机器人个体自身体积的考虑, 避免发生碰撞. 但是对于“重置”操作而言, 简单的替换操作也意味着丢失搜索过程中收集的已有信息.

文献[6, 9] 中采用周期性地对整个或部分种群或最优  $g_{best}$  粒子进行重新随机分布, 来增加群体多样性, 抛弃部分目前已知的信息. 重新随机分布(re-randomization)是另一种典型的途径, 但是同“重置”操作一样, 容易过多地失去过去迭代过程中或许有用的信息. 而且重新随机分布对信息的丢失更加彻底, 这也是许多文献中对该方法持怀疑态度的主要原因. 但是其实总体上来说, 这种方法依赖于需要解决的动态问题类型. 在很大一部分的动态环境变化问题中, 环境的变化是基于上一时刻或空间的环境状态的, 而不是完全的全空间内随机变化, 过多丢失过去信息对算法不利; 但是如果粒子状态是随机的、变化很大或者当前最优状态相关性很小, 则这种重新随机操作可以将群体从过期的信息束缚中解放出来. 因此在文献[9, 35] 中设计的重新随机化的粒子是以一定的比例进行的, 而这个比例的大小, 直接关系到算法的优化性能, 动态环境的变化特性是影响其取值大小的原因之一.

多群体设计的基本思想就是将整个群体分为一些子群. 每个子群分别关注解空间中不同的潜在可行解. 这种设计本身就是保证群体整体多样性的一个有效的方法. 当环境发生改变时, 由于群体中所有粒子都还没有收敛到一个狭小的区域, 从某种意义上说群体依然能保持着搜索能力. 因此第 1 节中 PSO 基于种群的搜索策略, 在动态响应策略意义上, 多群方法其实也是一种主动式策略. 基于种群的 PSO<sup>[23]</sup> 没有专门地用以应对动态变化的操作, 它通过重新随机初始化种群中多余的粒子来动态地调整种群结构和多样性参数.“多带电粒子”PSO<sup>[22]</sup> 的群体中, 在一个制定半径范围内的最差群体将被重新随机化处理, 使粒子相互之间散开一定的距离. 多量子群算法(multi-QSO)中用量子群体代替了带电粒子群体以增加多样性, 量子群体的位置只依赖于以群体吸引子为中心的一个概率函数.

为了保持多样性, 除了采用多种群的群体结构设计外, 多群体 PSO 中融合了其他的一些改进方法. 这些方法中常用的一些基于环境变化检测的反应式改进操作. 这一类的改进方法可以看作是主

动式和反应式相结合的混合式操作策略,这将在本节的第3部分予以阐述。

### 3.2 反应式策略

反应式策略定义为探知环境的动态变化后,针对这种变化做出响应调整的方法。当没有检测到环境有新的变化发生时,粒子群集中搜索当前的最优值。当有环境发生了变化的警示信息时,群体就对此做出反应,采用相应的反应式策略来增加群体多样性,同时减少群体过期信息的影响。这一类方法的主要问题是,需要额外增加环境检测的计算,这势必导致对适应度函数进行额外计算的负担。

“重置”依旧是广泛采用的反应式机制。文献[16]中通过设置一个阈值变量,优化过程中如果最优值的位置移动超过了这个阈值,所有粒子重新设置它们的个体最优位置 $p_i^*$ 为当前的位置向量 $x_i^*$ 。相对于简单的重新设置所有粒子的位置,一种改进的“重置”操作对重新计算 $p_{best}$ 的适应值,只有当前位置的适应值比个体最优适应值更佳的粒子才被重置<sup>[29, 31]</sup>。Eberhart指出<sup>[7]</sup>,并不能完全否定个体的最有历史信息,每个个体最优适应值都在环境变化过程中得到了更新,它们的位置会得到保留。

Hu<sup>[9]</sup>把对整个或部分群体中的粒子,或群体最优粒子进行随机化,作为一种对环境变化的应对机制。比例太大则过多失去有用的历史信息和搜索经验;相反,比例太小不能保证有效的激发多样性增长。试验经验表明,在多数情况下,群体10%的比例进行重新随机化就可以了。文献[35]中也采用了这种方法,对各种PSO的改进方法在动态环境下搜索性能进行了比较。但如何根据问题的特性选择随机化比例是一个亟待解决的问题。

### 3.3 混合式策略

混合式策略指的是综合利用了反应式和主动式应对策略的那些PSO改进方法。一般说来,两者都具有各自的优势和不足,比如,主动式策略一般收敛的速度相对较慢,而且不能充分收敛到动态的最优值;而反应式方法导致额外增加计算量是不得不考虑的问题。动态环境下,如何改进算法来实现在环境动态变化前的快速搜索同时保持群体的多样性,是至关重要的环节。

最近,Lung<sup>[32]</sup>提出了分级子群PSO模型,又称为协同进化群优化方法(collaborative evolutionary-swarm optimization, CESO)。CESO由2个规模相同的群体PSO的粒子群和拥挤差分进化群(crowding differential evolution, CRDE)构成混合式响应策略。一个群体采用进化算法的保持多样性机制,负责群

体多样性保持,以避免早熟收敛,另外一个群体跟踪全局最优值。当环境发生变化或者子群CRDE的最优值 $c_{best}$ 和PSO的群体最优值 $g_{best}$ 距离过近时,就通过CRDE中的个体来重置SWARM,以提高SWARM的多样性。

文献[26]在多群体设计中引入了3个多样性算子进行综合:量子微粒(quantum particles, 文献[22]中采用的多样性保持方法)、排斥因子(exclusion, 排斥即将发生碰撞的临近群体间的相互作用,用来避免各不同群体停留在同一个峰值上)、逆收敛因子(1个新的算子,使群体间共享信息,以便探测新的峰值)。如果探测到环境变化,对所有粒子的个体最优粒子 $p_{best}$ 的适应值进行重新计算,所有的操作都根据群体情况来进行。群体中集中了3种操作机制都是用来控制群体多样性。当子群相互之间过分靠近时,进行排斥操作,重新初始化最差的种群。通过反收敛操作把最差的种群抛弃,在搜索空间上重新初始化,这样可以保证至少有1个子群在空间中进行新的搜索。但这种综合性的改进方法,在算法中引入了复杂的在各重操作机制之间进行判断和切换的过程,并且引入了更多的待调节的参数。即使降低了该方法试验的可重复性,这也是一个显著的附加问题。因此,同所有基于群体的方法一样,该算法需要进一步降低计算复杂性。

## 4 性能评价

动态优化对计算智能方法提出了一个独特的挑战。算法的总体性能对算法的改进、修正和设计新的方法是非常重要的,因此非常有必要通过一些评价方法来对算法的性能进行一个衡量。虽然对PSO在动态环境优化的研究都是基于适应值曲面的,但是目前为止没有一个统一的评价标准来对函数的优化性能进行评判。因而目前在优化实验中采用了多种评价函数,主要可以分为2个方面:优化过程中适应度函数性能评价和基于大量试验的统计分析评价。

### 4.1 适应度性能评价

一些传统的进化计算性能评价方法依然被采用,比如离线性能、在线性能、收敛时间及当前最优值曲线等。此外,为了对动态函数的优化评价,一些传统性能评价方法有了改进,以及设计了一些新的评价方法。

当前最优值(Best-so-far)曲线用来记录并描绘迄今为止的最优值,这些最优值信息反映了每个迭代周期后,优化结果与最优值的距离。一些学者认为在动态环境中采用这个评价方法不合时宜<sup>[36-37]</sup>;因

对于每次的环境改变后,先前的最佳适应值很可能已经改变了,原来的性能在新的环境下就不一样了。不过,只要考虑到新的最优值,并且重新计算粒子们的适应值,这样的扩展 Best-so-far 评价曲线依然是简单有效的常见评价方法。例如,在小球追踪问题中<sup>[6]</sup>,最优粒子与运动小球实时的距离差距。实际上同每次迭代过程中的群体最优个体位置与变化的目标最优位置的距离误差是类似的<sup>[7, 12, 27, 29, 31, 38]</sup>。扩展 Best-so-far 评价曲线在动态环境优化问题中一般是锯齿状的,它具有简单、清楚而且容易理解优点,但是缺少总体性能比较的定量描述。

离线误差(offline error)描述基本上是算法总体性能比较的最普遍,也是最有效的方法,它通过计算一定周期内的群体最优性能的平均值来进行性能评价。Branke 和 Schmeck<sup>[20, 22, 38-40]</sup>引入离线误差来作为动态优化问题的性能评价,例如,用于对 species-PSO<sup>[25]</sup>, mCPSO, mQSO<sup>[26]</sup>解决移动峰值标准问题(moving peak benchmark problem)时性能的评价。动态定价问题中的累计平均收益<sup>[16]</sup>(cumulative mean revenue)是基于离线误差的一定时间长度内总收益的平均值。文献[23]对于每一个优化过程采用了每次迭代的标准最小误差和平均最小误差。而且在文献[24]中也使用了全局最优离线误差(global best offline error),该文章通过计算2个离线误差来进行性能评价。一个是全局最优离线误差,通过计算自上一次环境改变以来粒子距离全局最优点的离线误差来得到,另一个是平均局部离线误差(average local offline error),指在考虑到上一次环境改变以来所有最优目标值已知的情况下,计算的局部最优误差的平均值<sup>[27]</sup>。在静态函数的优化评价中,离线误差提供了一个单调递增的指标来评价算法寻优的快速性。但是在动态优化中,一方面在每一次适应值曲面进行了动态变化以后,前一时刻的最优值相对当前而言就失去了意义;另一方面,由于动态变化的程度的不同,对于 PSO 而言,群体最优的适应值变化也都不同,这就减弱了各个动态变化后的适应值的可对比性。

然而,离线误差的评价方法缺少足够的对算法开拓特性和细化开发特性的评估。离线误差可分为正交的2部分<sup>[33]</sup>:一是已知最优峰值误差(best known peak error, BKPE),用以评价收敛速度,另一个是峰值范围(peak cover),常用来描述最优值或峰值的数量,以及群体多样性和开拓搜索状态。这种评价方法提供了一种新的视角,可以更加深入地分析

算法的收敛速度和多样性。

#### 4.2 统计性能分析

大部分论文中,每个试验都需要重复几十次,以便于进行统计特性的分析,从而减小结果的变化性。通过统计和分析得到的实验数据来评价算法优劣,比如追踪动态最优值所需要的平均迭代周期数,或者在一定时间内成功完成搜索任务的比率。对于所有基于随机的优化算法,对结果的统计特性分析都十分重要。文献[6]中,3个指标被用于分析:在找到解的前提下的计算可靠性、在每次找到解的平均周期前提下的计算效率与每次计算的平均迭代次数。这些指标可以很快地给出解的分布情况,对最优值不同的运动速度和群体拓扑结构可以进行对比。

一些比较简单的方法就是对几十次实验的结果求平均,得到一个性能的平均指标。例如,可以对每种改进的 PSO 算法运行 50 次,每次迭代 1 000 个周期,然后对扩展 Best-so-far 性能进行求平均<sup>[35]</sup>。也可以通过 50 次运算后得到的平均离线误差来评估不同参数设置对算法的影响<sup>[25, 32]</sup>。累计平均收益均值用于对几种改进的 PSO 在不同检测和应对策略下的算法性能进行对比。文献[23]中,在每次实验计算中,全局最优离线误差、最小或最大误差和标准偏差都一一被记录下来,然后得到 50 次的平均值。

文献[9]中,主要考虑了 2 种统计性能:第 1 个是 PSO 搜索到最优解所需要的平均迭代次数;第 2 个是 PSO 算法跟踪动态变化所需要的平均迭代次数。然后分别考虑了使用不同的探测方法、变化剧烈程度、应对策略(不同比例的群体随机化)情况对算法性能的影响。文献[15]中也使用了第 2 种方法。

有很多广泛应用于 EA 算法的评价方法,在 PSO 算法中并不常用,比如 Morrison<sup>[36]</sup>提出的共同均值适应度评价(collective means fitness metrics)。它主要使用了 2 个平均操作,一是足够多代最优个体均值,另一个是多次运行的平均。这种方法最大的好处就是,通过多次运行得到算法稳定的性能,可以作为多个算法的参考比较标准。但是目前还没有看到任何将该方法应用于 PSO 的研究文章。

目前在 PSO 的动态优化问题中采用的评价方法还局限于以上分析的几种,但是这一类方法普遍将迭代周期作为衡量的依据。它是建立一个算法间每个迭代周期的计算代价是近似相等的。但是显然一些计算复杂性高的改进算法,其每个周期的算法计算时间与适应值函数计算次数都远高于一般性的 PSO 算法,因此这样的衡量是不全面的。

其他的一些 EA 算法常用的评价方法包括:跟

踪误差均值 (mean tracking error)、在线性能 (on-line performance)、绝对性能 (absolute performance) 等。这些方法为不同的研究问题和分析需求提供性能分析的选择,然而无论选择其中的任何评价函数,或者设计改进性能评价方法,都需要具备:

1) 直观性. 要求既可以反映每次优化的过程,又可以对整个优化性能进行评价;

2) 在统计意义上能提供直接结果,与其他的方法之间,或者在不同的动态变化条件下,都具有可比性;

3) 尽可能充分全面地反映动态变化,以避免局部动态特性变化造成的误导.

## 5 结 论

近些年来,随着进化计算方法在动态环境优化问题应用中引起了普遍关注,PSO 在该领域的应用也越来越多. 国际上从研究成果到发表的论文数量都越来越多,目前国内相关的研究文献相对还比较少,这也将成为下一步 PSO 和动态优化方面的研究重点. 目前的研究现状表明,不但是对于 PSO 而言,包括 EA、GA 等计算智能的方法,在动态优化的研究中,主要关注的是算法改进(当然这也涉及到对环境变化的应对策略)、检测方法、性能评价和应用等方面的研究. 而需要进一步细化研究的是,针对不同的 PSO 改进方法在解决不同的动态特性的研究.

1) 在动态优化中 PSO 特性的理论研究. 尽管对于 PSO 在静态函数和问题的优化中的理论分析还远没有成熟,但仍需进一步对 PSO 在动态环境下的运动特性、算法特性以及寻优特点及原理展开理论研究.

2) 动态优化中 PSO 多样性的度量和保持策略. 无论是目前的多种群的方法,或是采用随机化部分粒子的最近操作,从多样性的角度来看,都试图通过一定的算法设计来保持群体的多样性. 目前多数对静态优化问题中对群体多样性的定量计算的思路是基于粒子位置向量或者速度向量的空间距离来进行计算,如群体的位置方差等. 但是在动态环境下还没有见到相关的研究报道. 尤其是,将群体多样性的定量计算与环境动态变化的检测概率相结合的研究.

3) 对环境变化的监测方法研究. 这完全取决于问题本身,如果问题本身是连续变化,或者在每个周期,解空间都会产生随机变化的话,那么每个周期对环境进行监测和频繁的对一些特定点的检测是必须,即使要付出很多的计算代价. 对于检测点的选择也取决于空间的变化特性,如果每次变化都在全空间中都会有体现,那么选择面就很宽,重要的是怎样

选择能减小额外的计算开销. 如果空间的变化只是局部的,那就需要根据对动态变化的了解,来设计检测的策略.

4) 性能测量. 对于优化方法的性能的评价由很多评价方法,还没有一个统一的方法来进行评价描述,尤其是在动态环境中. 在设计实验和考虑性能评价方法的过程中,需要综合考虑各方面的因素,例如可以使用扩展 Best-so-far 来对优化过程中的性能指标的动态变化作出直观的表示,离线误差来对算法的整体性能进行评价,通过统计特性来得到相对稳定可靠的性能评价. 此外,应该考虑到算法的计算复杂性和性能间的关系,而不能仅仅从迭代周期上来评价;因为具有不同时间复杂性和计算复杂性的算法在每个迭代周期所消耗的计算代价是不同的.

5) 应用研究. 移动峰值标准函数和 DF1 函数为进化计算方法在动态优化提供了一个标准的测试函数,这为 PSO 在这方面研究提供了很大帮助. 并且可以产生多种随时间变化的不同动态特性的动态问题. 在这 2 个标准函数被应用于 PSO 的动态环境寻优的试验之前,也有一些类似的动态函数被采用,那些函数都可以看作是这 2 个标准函数的一种特例. 同时,在对标注函数研究的基础上,进一步开展对现实世界中动态问题研究,将使这个领域的研究变得更加具有实用意义. 无论是对于一个标准测试函数而言,还是对于现实问题的数学模型提炼,在对于试验函数的设计中需要注意:a) 适应值曲面具有很好的可修改性,可以反映问题的复杂程度;b) 可以方便直接的通过参数调节来反映适应函数的变化,包括峰值的重新分布、形状的改变、运动的步长改变、运动的周期,以及运动的形式等;c) 以高效、简洁的方式反应待研究问题和系统的动态特性,具有合理的计算复杂性.

## 参考文献:

- [1] KENNEDY J, EBERHART R C. Particle swarm optimization [C]//Proc IEEE International Conference on Neural Networks. Perth, Australia, 1995: 1942-1948.
- [2] 姚耀中, 徐玉如. 粒子群优化算法分析 [J]. 哈尔滨工程大学学报, 2007, 28(11): 1242-1246.  
YAO Yaohong, XU Yuru. Parameter analysis of particle swarm optimization algorithm [J]. Journal of Harbin Engineering University, 2007, 28(11): 1242-1246.
- [3] FOGEL L J, OWENS A J, WALSH M J. Artificial intelligence through simulated evolution [M]. New York: John Wiley & Sons, Inc., 1966.
- [4] 蒋建国, 吴琼, 夏娜. 自应用粒子群算法求解 Agent

- 联盟[J]. 智能系统学报, 2007, 2(2): 69-73.
- JIANG Jianguo, WU Qiong, XIA Na. Solving for Agent co-alton using adaptive particle swarm optimization algorithm [J]. CAAI Transactions on Intelligent Systems, 2007, 2(2): 69-73.
- [5] 王冰, 刁鸣, 高洪元. 一种改进的粒子群算法求解背包问题[J]. 应用科技, 2008, 35(3): 16-19.
- WANG Bing, DIAO Ming, GAO Hongyuan. An improved particle swarm optimization algorithm for knapsack problems [J]. Applied Science and Technology, 2008, 35(3): 16-19.
- [6] CARLISLE A, DOZIER G. Adapting particle swarm optimization to dynamic environments [C]//Proceedings of International Conference on Artificial Intelligence. Las Vegas, USA, 2000: 429-434.
- [7] EBERHART R C, SHI Y H. Tracking and optimizing dynamic systems with particle swarms [C]// Proceedings of the 2001 Congress on Evolutionary Computation. Piscataway, USA, 2001: 94-100.
- [8] 潘峰, 陈杰, 甘明刚, 等. 粒子群优化算法模型分析[J]. 自动化学报, 2006, 32(3): 368-377.
- PAN Feng, CHEN Jie, GAN Minggang, et al. Model analysis of particle swarm optimizer[J]. Acta Automatica Sinica, 2006, 32(3): 368-377.
- [9] HU X, EBERHART R C. Adaptive particle swarm optimization: detection and response to dynamic systems [C]// Proceedings of the IEEE Congress on Evolutionary Computation (CEC'02). Honolulu, USA, 2002: 1666-1670.
- [10] 单世民, 邓贵仕. 动态环境下一种改进的自适应微粒群算法[J]. 系统工程理论与实践, 2006(3): 39-44.
- SHAN Shimin, DENG Guishi. Improved adaptive particle swarm optimizer in dynamic environment[J]. Systems Engineering—Theory & Practice, 2006(3): 39-44.
- [11] ESQUIVEL S C, COELLO COELLO C A. Particle swarm optimization in non-stationary environments [J]. Lecture Notes in Computer Science, 2004, 3315: 757-766.
- [12] BLACKWELL T M, PETER J B. Dynamic search with charged swarms[C]//Proceedings of the Genetic and Evolutionary Computation Conference. San Francisco, USA: Morgan Kaufmann Publishers Inc, 2002: 19-26.
- [13] BLACKWELL T M, BENTLEY P. Don't push me! collision-avoiding swarms[C]//Proceedings of the IEEE Congress on Evolutionary Computation (CEC 2002). Honolulu, USA, 2002: 1691-1696.
- [14] BLACKWELL T. Particle swarm optimization in dynamic environments[M]//YANG S X, ONG Y S, JIN Y C. Evolutionary computation in dynamic and uncertain environments. Heidelberg: Springer, 2007, 51: 29-49.
- [15] JATMIKO W, SEKIYAMA K, FUKUDA T. A PSO-based mobile sensor network for odor source localization in dynamic environment: theory, simulation and measurement [C]// Proceedings of the IEEE Congress on Evolutionary Computation (CEC 2006). Vancouver, Canada, 2006: 1036-1043.
- [16] MULLEN P B, MONSON C K, SEPPI K D, et al. Particle swarm optimization in dynamic pricing [C]//IEEE Congress on Evolutionary Computation (CEC 2006). Vancouver, Canada, 2006: 1232-1239.
- [17] PAN Guanyu, DOU Quansheng, LIU Xiaohua. Performance of two improved particle swarm optimization in dynamic optimization environments [C]//Proceedings of the Sixth International Conference on Intelligent Systems Design and Applications (ISDA'06). Washington DC, USA: IEEE Computer Society, 2006, 2: 1024-1028.
- [18] 窦全胜, 周春光, 徐中宇, 等. 动态优化环境下的群核进化粒子群优化方法[J]. 计算机研究与发展, 2006, 43(1): 89-95.
- DOU Quansheng, ZHOU Chunguang, XU Zhongyu, et al. Swarm-core evolutionary particle swarm optimization in dynamic optimization environments [J]. Journal of Computer Research and Development, 2006, 43(1): 89-95.
- [19] 林川, 冯全源. 利用有效信息的粒子群优化算法[J]. 哈尔滨工程大学学报, 2008, 29(11): 1227-1231.
- LIN Chuan, FENG Quanyuan. An effectively informed particle swarm optimization algorithm [J]. Journal of Harbin Engineering University, 2008, 29(11): 1227-1231.
- [20] BRANKE J, KAUBLER T, SCHMIDT C, et al. A multi-population approach to dynamic optimization problems [M]//Adaptive Computing in Design and Manufacture. Berlin: Springer, 2000: 299-308.
- [21] OPPACHER F, WINEBERG M. The shifting balance genetic algorithm: improving the GA in a dynamic environment [C]//Proc of Genetic and Evolutionary Computation Conf. Orlando, USA, 1999: 504-510.
- [22] BLACKWELL T, BRANKE J. Multi-swarm optimization in dynamic environments[J]. Lecture Notes in Computer Science, 2004, 3005: 489-500.
- [23] PARROTT D, LI Xiaodong. A particle swarm model for tracking multiple peaks in a dynamic environment using speciation[C]//Proceedings of the 2004 Congress on Evolutionary Computation (CEC 2004). Piscataway, USA, 2004, 1: 98-103.
- [24] PARROTT D, LI Xiaodong. Locating and tracking multiple dynamic optima by a particle swarm model using speciation [J]. IEEE Transactions on Evolutionary Computation, 2006, 10(4): 440-458.
- [25] LI Xiaodong, BRANKE J, BLACKWELL T. Particle

- swarm with speciation and adaptation in a dynamic environment[C]//Proceedings of the 8th Annual Conference on Genetic and Evolutionary Computation. New York, USA: ACM Press,2006: 51-58. ]
- [26] BLACKWELL T,BRANKE J.Multiswarms,exclusion, and anti-convergence in dynamic environments[J]. IEEE Transactions on Evolutionary Computation,200610(4) : 459-472.
- [27] 王光辉,陈杰,潘峰.多种群协同粒子群优化算法求解动态环境优化问题[C]//第27届中国控制会议.昆明,2008,5: 43-48.  
WANG Guanghui,CHEN Jie,PAN Feng,Collaborated multi-swarms particle swarm optimizer for dynamic environment optimization [ C ]//Proceedings of the 27th Chinese Control Conference. Kunming,2008,5: 43-48.
- [28] CUI X,HARDIN CT,RAGADE R K,et al. Tracking non-stationary optimal solution by particle swarm optimizer [ C ]//Proceedings of the Sixth International Conference on Software Engineering,Artificial Intelligence,Networking ; and Parallel/Distributed Computing and First ACIS International Workshop on Self-Assembling Wireless Networks (SNPD/SAWN 2005) . Washington DC,USA: : IEEE Computer Society,2005: 133-138..
- [29] CARLISLE A,DOZLER G. Tracking changing extrema with adaptive particle swarm optimizer[C]//Proceedings ; of the 5th Biannual World Automation Congress. Orlando, USA,2002: 265-270.
- [30] CARLISLE A J. Applying the particle swarm optimizer to non-stationary environments[D] . Auburn,AL,USA: : Auburn University,2002.
- [31] VEERAMACHANENI K,OSADCIW L. Dynamic particle swarm optimizer for information fusion in non stationary sensor networks[C]//Proceedings of IE Swarm Intelligence Symposium. Indianapolis,USA,2006.
- [32] LUNG R I,DUMITRESCU D.A new collaborative evolutionary-warm optimization technique[ C ]//Proceedings of the 2007 GECCO Conference Companion on Genetic and Evolutionary Computation. New York,USA: : ACM Press, 2007: , 2817-2820.
- [33] BIED S,LI Xiaodong. Informative performance metrics for dynamic optimisation problems[C] J// Proceedings of the 9th Annual Conference on Genetic and Evolutionary Computation. New York,USA: : ACM Press,2007: : 18-25.
- [34] ZAHARIE D,ZAMFIRACHE F. Diversity enhancing mechanisms for evolutionary optimization in Static and dynamic environments[C]//Proc of 3rd Romanian-Hungarian Joint Symposium on Applied Computational Intelligence. Timisoara,Romania,2006: 5460471..
- [35] LI Xiaodong,DAM K H. Comparing particle swarms for tracking extrema in dynamic environments[ C ] / /The 2003 Congress on Evolutionary Computation(CEC'03). Canberra,Australia,2003,3: 1772-1779.
- [36] MORRISON R W. Performance measurement in dynamic environments[ C ]//BRANKE J.GECCO Workshop on Evolutionary Algorithms for Dynamic Optimization Problems(EvoDOP 2003) . Chicago,USA,2003: : 5-8.
- [37] MORRISON R W. Designing evolutionary algorithms for dynamic environments[M] . [ S. 1. ] : Springer-Verlag, 2004 .
- [38] BLACKWELL T M,PETER J B. Dynamic search with charged swarm[C] //Proceedings of the Genetic and Evolutionary Computation Conference. San Francisco,USA: Morgan Kaufmann Publishers Inc,2002: , 19-26.
- [39] MOSER I. Review all currently known publications on approaches which solve the moving peaks problem[ R ]. Melbourne: Swinburne University of Technology,2007.
- [40] BRANKE J,SCHMECK H. Designing evolutionary algorithms for dynamic optimizations problems[M]//TSUTSUI T , S,GHOSH A.Advances in evolutionary computing: theory and applications. New York,USA: : Springer-Verlag, , 2003: , 239-262.

#### 作者简介:



陈杰,男,1965年生,教授、博士生导师。博士,中国自动化学会控制理论专业委员会委员。主要研究方向为复杂系统、多目标优化与决策、智能控制、非线性控制和优化方法等。2005年获全国优秀科技工作者"荣誉称号,2001年获教育部

"全国高校青年教师奖"。获部级科技进步奖12项,北京市优秀教学成果二等奖2项。完成并通过鉴定的科研项目20余项。发表学术论文100余篇,出版教材1部,译著1部。



潘峰,男,讲师,博士。主要研究方向为智能控制、计算智能、人工智能、伺服系统和机器人等。已获部级科技进步奖1项,发表学术论文20余篇。



王光辉,男,1987年生,博士研究生。主要研究方向为智能算法、计算智能、优化设计。