

基于蚁群系统的参数自适应粒子群算法及其应用

杨帆¹, 胡春平², 颜学峰¹

(1. 华东理工大学 化工过程先进控制和优化技术教育部重点实验室, 上海 200237; 2. 上海核工程研究设计院, 上海 200233)

摘要: 为了解决粒子群算法惯性权重自适应问题, 提出一种基于蚁群系统的惯性权重自适应粒子群算法(AS-PSO)。AS-PSO 首先将惯性权重取值区间离散化, 各个惯性权重子区间在初期赋予相同的信息素; 然后, 粒子群算法中的各个粒子, 根据各个惯性权重子区间中的信息素浓度和粒子在搜索空间中分布的先验知识, 确定各个惯性权重子区间的选择概率, 并进而实现粒子的空间搜索; 最后, 基于粒子的进化信息, 实现惯性权重子区间信息素浓度的更新。仿真研究表明, AS-PSO 算法在种群进化寻优的同时, 能根据种群的进化信息, 通过蚁群算法实现惯性权重参数的自适应调整和进化, 且不增加测试函数的调用次数; 算法寻优性能优于传统的自适应粒子群算法和根据速度信息自适应调整参数的粒子群算法。同时, 算法实际应用于复杂系统模型参数的优化估计, 获得满意结果。

关键词: 粒子群算法; 蚁群算法; 参数自适应; 进化计算

中图分类号: TP273

文献标识码: A

Particle swarm optimization algorithm of self-adaptive parameter based on ant system and its application

YANG Fan¹, HU Chun-ping², YAN Xue-feng¹

(1. Key Laboratory of Advanced Control and Optimization for Chemical Processes of Ministry of Education, East China University of Science and Technology, Shanghai 200237, China

2. Shanghai Nuclear Engineering Research and Design Institute, Shanghai 200233, China)

Abstract: To adjust the inertia weight in particle swarm optimization(PSO), we propose a novel self-adaptive particle swarm optimization algorithm based on ant system(AS-PSO). First, the inertia weight space is divided into several regions; each of them is given the same initial intensity of pheromone trails. The probability for selecting a parameter region for each particle is determined by the intensity of the region pheromone trails and the particle's a priori knowledge of the search space. The evolution search is then performed in spaces of solutions. Finally the trail of the regions is updated according to the information of evolution. Experiments indicate that the promising AS-PSO algorithm realizes the evolution and the self-adaptation of the inertia weight by ant colony algorithm without increasing the function calls in evaluation. Results show that AS-PSO obviously outperforms the original self-adaptive PSO and the APSO-VI, in which the parameter is adjusted according to the velocity information. Furthermore, satisfactory results have been obtained when AS-SPO algorithm is applied to estimate the parameter of complex system models.

Key words: particle swarm optimization algorithm ; ant colony algorithm; parameter self-adaption; evolutionary computation

1 引言(Introduction)

源于对鸟群捕食行为的研究, J.Kennedy与Eberhart提出了粒子群算法(particle swarm optimization, PSO)^[1]。算法简单而且参数容易调整, 已广泛应用于函数优化、神经网络训练、模糊系统控制以及其他遗传算法的应用领域。标准PSO算法采用固定的惯性权重, 在优化复杂函数时, 易陷入局部极值点或早熟收敛。目前大多数研究集中在算法如何自适

应调整惯性权重, 如惯性权重线性递减策略^[2]、非线性递减策略^[3], 但这些算法在求解复杂问题时容易发生早熟收敛; 另外有一些算法考虑粒子轨迹对算法收敛性的影响^[4], 以及速度收敛对算法收敛性的影响, 分别提出了动态参数自适应调整粒子群优化(DPATPSO)算法^[5]和速度信息自适应调整参数的粒子群优化(APSO-VI)算法^[6], 在一定程度上解决了早熟问题。这些自适应算法中惯性权重都是参照一

收稿日期: 2009-02-18; 收修稿日期: 2010-01-15。

基金项目: 国家自然科学基金资助项目(20776042); 国家“863”计划资助项目(2007AA04Z164); 上海市重点学科建设资助项目(B504); 教育部博士点基金资助项目(20090074110005); 上海市曙光计划资助项目(09SG29); 教育部新世纪优秀人才资助项目(NCET-09-0346)。

种预先设定轨迹变化,实现算法的参数自适应性.由于优化问题复杂程度的不同,预先设定的自适应变化轨迹难以满足不同特性优化问题的需求,最终难免早熟收敛,陷入局部极值点.同时,这些自适应算法未综合考虑粒子演化、以及粒子空间分布等信息.

为此,本文提出一种基于蚁群系统的参数自适应粒子群算法(self-adaptive particle swarm optimization algorithm based on ant system, AS-PSO),通过对惯性权重取值区间的离散化,将各个惯性权重子区间作为蚁群算法的一条路径;根据各条路径上的信息素浓度与粒子的空间分布信息,选择路径(即惯性权重),实现粒子进化搜索;同时,根据粒子进化信息,实现各条路径信息素浓度的更新. AS-PSO能根据优化问题搜索进展,通过蚁群算法实现惯性权重的自适应进化.仿真研究与实际应用表明,算法具有很好的自适应性能,搜索效率高.

AS与PSO结合的算法中,文献[7]采用蚁群机制对粒子群算法的局部最优解进行领域搜索,通过概率选择确定合适的进化方向,加大了粒子间的多样性差异,提高了算法避开局部最优解的能力.文献[8]通过粒子群和蚁群算法优化车辆调度问题中的不同变量,这样的蚁群粒子群混合模型提高了车辆载货率及运输资源使用效率.文献[9]提出一种蚁群与粒子群的混合算法,为了避免了原先的粒子群最优解始终向着自身的方向进化而陷入局部最优,通过蚁群算法为每个粒子选择合适的进化方向,提高了算法跳出局部最优和处理非线性优化问题的能力.文献[10]用蚁群算法来对建立的模型进行优化,而其中的粒子群算法的作用是确定蚁群算法参数的自适应取值,并应用于深海开采的线路设计中.本文算法的蚁群与粒子群的结合主要是用蚁群机制来挑选粒子群算法的惯性权重,最为重要的是粒子群算法的每个粒子的惯性权重都由蚁群算法决定并随算法的进行不断地进行优化选择.

2 粒子群算法(Particle swarm optimization algorithm)

2.1 基本的粒子群算法(Basic particle swarm optimization algorithm)

假设搜索空间是 n 维,粒子群中第 i 个粒子的位置用 $\mathbf{x}_i(x_{i1}, x_{i2}, \dots, x_{in})$ 表示,第 i 个粒子的速度表示为 $\mathbf{v}_i(v_{i1}, v_{i2}, \dots, v_{in})$,第 i 个粒子迄今为止搜索的最好位置记为 $\mathbf{pbest}_i(p_{i1}, p_{i2}, \dots, p_{in})$,整个粒子迄今为止搜索到的最好位置记为 $\mathbf{gbest}(g_1, g_2, \dots, g_n)$,则下一代粒子的位置和速度根据式(1)(2)更新

$$\begin{aligned} \mathbf{v}_i^{G+1} = & \mathbf{v}_i^G \cdot \omega + c_1 \cdot \text{Rand}_1 \cdot (\mathbf{pbest}_i - \mathbf{x}_i^G) + \\ & c_2 \cdot \text{Rand}_2 \cdot (\mathbf{gbest} - \mathbf{x}_i^G), \end{aligned} \quad (1)$$

$$\mathbf{x}_i^{G+1} = \mathbf{x}_i^G + \mathbf{v}_i^{G+1}. \quad (2)$$

其中:加速常数 c_1, c_2 是两个非负值, $\text{Rand}_1, \text{Rand}_2$ 为均匀分布于 $[0, 1]$ 之间的随机数.为使粒子速度不致过大,可设定速度上限 $v_{\max}$,即当式(1)的 $|v_{id}| > v_{\max}$ 时,取 $|v_{id}| = v_{\max}$. ω 为惯性权重,它决定了粒子先前速度对当前速度的影响程度,从而起到平衡算法全局搜索和局部搜索能力的作用.较大的惯性权重使算法有较好的全局搜索能力,收敛速度快,但是精度不高;较小的惯性权重虽然使算法有较高的搜索精度,但是收敛过慢.因此,变化的惯性权重能改善PSO算法的性能.

2.2 各种改进的自适应粒子群算法(Various kinds of improved self-adaptive PSO)

为了进一步提高算法的性能,文献[2]提出自适应调整的策略,即

$$\omega(G) = (\omega_{\max} - \omega_{\min})(G_{\max} - G)/G_{\max} + \omega_{\min}. \quad (3)$$

其中: G 为当前进化迭代次数, $G_{\max}$ 为最大进化迭代次数, $\omega_{\max}$ 为初始惯性权重, $\omega_{\min}$ 为进化至最大代数时的惯性权重.随着迭代的进行,可以线性减少 ω 的值,这使得算法在迭代初期探索能力较强,可以不断搜索新的区域,然后收敛能力逐渐增强,而在算法的后期使粒子在可能的最优解周围精细搜索.这是目前使用最广泛的SPSO算法形式.文献[11]根据粒子适应度的不同将群体分为3个子群,分别采用不同的自适应操作,使得群体始终保持惯性权重的多样性.文献[5]中针对基本粒子群优化算法搜索成功或失败与粒子群平均速度之间的关系提出了一种改进算法,即动态参数自适应调整粒子群优化(DPATPSO)算法.文献[6]提出了根据速度信息自适应调整参数的粒子群优化(APSO-VI)算法,以解决基本PSO算法在求解高维、多峰等复杂非线性优化问题时搜索失败的问题.这些算法都只考虑了粒子进化中的部分信息(如平均速度,位置等),去参照一种预先设定的轨迹,实现算法的参数自适应调整,未能考虑粒子进化过程中其他因素的影响,粒子一旦按照原先设定的轨迹进化未能取得理想的效果,只能按照设定的轨迹继续进行优化,无法再做相应的调整,在处理不同特性的高维复杂问题时难以满足要求.

3 基于蚁群系统的参数自适应粒子群算法(Self-adaptive particle swarm optimization algorithm based on ant system)

为了使惯性权重的自适应选取能针对不同的高维, 复杂非线性问题, 并综合考虑粒子在进化过程中的各方面信息, 本文提出一种基于蚁群系统的参数自适应粒子群算法. 首先将粒子群算法的惯性权重 ω 取值离散化, 划分成若干子区间并赋予相同的信息素作为蚁群算法的一条路径. 根据不同路径上信息素的分布, 以及粒子的空间分布, 按概率选择惯性权重, 生成新粒子. 同时根据新粒子的信息更新各条路径的信息素. 由此可以看出, 引入AS算法之后, AS-PSO算法把惯性权重的选择也看成一种进化的过程, 同粒子一起遵循着一定的机制进化, 将惯性权重也看成一个被优化的种群, 并且始终将寻找最优目标作为选择惯性权重的依据, 而非按照预先设定的轨迹进行自适应调整, 同时在进化过程中考虑了粒子的空间分布因素, 以适应不同特性的高维复杂问题.

3.1 蚁群算法基本原理(Basic principles of ant colony optimization)

受蚂蚁觅食时的通信机制的启发, 20世纪90年代Dorigo提出了蚁群算法^[12]. 在蚁群算法中, 蚂蚁通过行走在不同的地点(状态)之间转移, t 时刻蚂蚁 k 在点 i 向点 j 的转移概率 $P_{ij}^k(t)$ 为:

$$P_{ij}^k(t) = \begin{cases} \frac{\tau_{ij}^\alpha(t)\eta_{ij}^\beta(t)}{\sum_{s \in \text{allowed}_k} \tau_{is}^\alpha(t)\eta_{is}^\beta(t)}, & j \in \text{allowed}_k, \\ 0, & \text{其他}. \end{cases} \quad (4)$$

式中: η_{ij} 为边 (i, j) 的能见度, 反映由点 i 转移到点 j 的启发程度; τ_{ij} 为边 (i, j) 上的信息素轨迹强度; $P_{ij}^k(t)$ 为蚂蚁 k 的转移概率, j 是尚未访问的点; allowed_k 为蚂蚁 k 下一步允许选择的点; s 为蚂蚁可以到达的位置. 由式(4)可知, 转移概率 $P_{ij}^k(t)$ 与 η_{ij} , τ_{ij} 成正比. α 和 β 为两个参数, 分别反映了蚂蚁在运动过程中所积累的信息和启发信息在蚂蚁选择路径中的相对重要性. 蚂蚁完成一次循环以后, 各路径上信息素量根据下式调整:

$$\begin{cases} \tau_{ij}(t+1) = \\ (1-\rho)\tau_{ij}(t) + \Delta\tau_{ij}(t, t+1), \quad \rho \in [0, 1], \\ \Delta\tau_{ij}(t, t+1) = \sum_{k=1}^m \Delta\tau_{ij}^k(t, t+1). \end{cases} \quad (5)$$

式中: $\Delta\tau_{ij}^k(t, t+1)$ 为第 k 只蚂蚁在时刻 $(t, t+1)$ 留在路径 (i, j) 上的信息素量, 其值大小由蚂蚁表现的

优劣而定. 路径越短信息素释放就越多; $\Delta\tau_{ij}(t, t+1)$ 为本次循环中路径 (i, j) 的信息素的增量; ρ 为信息素挥发系数, 通常设置 $\rho < 1$ 来避免路径上轨迹量的无限累加.

3.2 惯性权重参数区间离散化(Discretization of inertia weight space)

在AS-PSO算法中, 将惯性权重 ω 的取值范围划分成若干子区间. 惯性权重分别以正态分布概率在各自区间取值, 描述如下:

$$\begin{aligned} \omega_j &\sim N(0.4 + k, \frac{0.5}{w+1}), \\ \omega_j &\in (k - \frac{0.25}{w+1}, k + \frac{0.25}{w+1}), \\ k &= \frac{0.5}{w+1}, \frac{0.5 \times 2}{w+1}, \dots, \frac{0.5w}{w+1}. \end{aligned}$$

其中 w 是区间的个数. 这样就以 k 对惯性权重进行了编码, k 值确定, 对应的惯性权重 ω 也就确定, 不同的 k 就是一条不同的路径. 由此, 每个粒子需要从 w 种 k 中选取其一作为其生成惯性权重的方法. 在实际操作中, 对第 j 条路径 $j=1, 2, \dots, w$, $k=0.5\frac{j}{w+1}$, $\omega_j \sim N(0.4 + k, \frac{0.5}{w+1})$.

3.3 算法流程(Process of AS-PSO)

具体的AS-PSO算法流程如下:

1) 初始化操作在解空间 S_0 随机生成初始化种群 $x_i^0, i=1, 2, \dots, \text{NP}$. 确定惯性权重 ω 子区间个数 w , 蚁群算法控制参数 ρ, α, β 和 Q (Q 为信息素增加强度系数), 以及最大进化代数 G_m . 对粒子群算法惯性权重 ω 进行编码, 形成 w 条路径. 并对每个惯性权重子区间赋予相同含量的信息素. 令当前进化代数为 $G=0$.

2) 对每个粒子 $x_i^G, i=1, 2, \dots, \text{NP}$ 实施3)4)步的操作, 生成下一代种群.

3) 生成备选粒子以 w 种 ω 生成 w 个可能的惯性权重取值. 对每个粒子 $x_i^G, i=1, 2, \dots, \text{NP}$, 以 w 个 ω 分别实行操作, 生成 w 个备选粒子. 对于第 i 个粒子 x_i^G 采用第 j 条路径生成的第 j 个备选粒子 $\bar{x}_{ij}^{G+1}$:

$$\begin{aligned} \omega_j &\sim N(0.4 + 0.5\frac{j}{w+1}, \frac{0.5}{w+1}), \\ \bar{v}_{ij}^{G+1} &= \bar{v}_i^G \omega_j + c_1 \text{Rand}_1(p\text{best} - x_i^G) + \\ &\quad c_2 \text{Rand}_2(g\text{best} - x_i^G), \end{aligned} \quad (6)$$

$$\bar{x}_{ij}^{G+1} = x_i^G + \bar{v}_{ij}^{G+1}. \quad (7)$$

如果 $\bar{v}_{ij}^{G+1}$ 超过了所给定的范围, 那么算法将在给定范围内重新随机生成 $\bar{v}_{ij}^{G+1}$. 同样的, 当 $\bar{x}_{ij}^{G+1}$ 超出了

边界时,算法将重新生成 $\bar{x}_{ij}^{G+1}$.

4) 备选粒子的选择每个粒子需要从 w 个备选粒子中选择一个作为其新粒子. 对于第 i 个粒子,选择第 j 个备选粒子的概率 $P_{ij}(G)$ 定义如下:

$$P_{ij}(G) = \frac{\tau_j^\alpha(G) \cdot \eta_{ij}^\beta}{\sum_{k=1}^{w \times w} (\tau_k^\alpha(G) \cdot \eta_{ik}^\beta)}. \quad (8)$$

其中: $\tau_j(G)$ 表示第 j 条路径当前信息素余量, η_{ij} ($i = 1, 2, \dots, NP; j = 1, 2, \dots, w$)表示备选粒子 $\bar{x}_{ij}^{G+1}$ 的期望值, α 和 β 是控制信息素和期望值之间相对重要性的参数. 期望值 η_{ij} 定义如下:

$$\eta_{ij} = [\sum_{t=1}^n (\frac{\bar{x}_{ijt}^{G+1} - x_{bt}^G}{\bar{x}_{ijt}^{G+1}})^2]^{\frac{1}{2}}. \quad (9)$$

其中: $\bar{x}_{ijt}^{G+1}$ 为第 j 个备选粒子的第 t 个基因, x_{bt}^G 为第 G 代最优粒子的第 t 个基因. 因此,选择概率综合考虑了期望值,即粒子空间分布(越靠近当前最优粒子的备选粒子被选中的概率越小,这样能防止PSO因收敛过快而陷入局部最优值)和信息素浓度(意味着越能提升粒子适应度值的参数被选中的概率越大),实现了空间分布先验知识,以及寻优过程历史积累知识的综合利用,并进而指导寻优进程.

5) 信息素更新设第 i 个粒子选择 $\bar{x}_{ij}^{G+1}$ 作为新粒子 x_i^{G+1} ,如果满足 $f(\bar{x}_{ij}^{G+1}) < f(x_i^G)$,则对第 j 条路径的信息素强度由式(10)进行更新:

$$\tau_j(G+1) = \rho \tau_j(G) + \Delta \tau_j. \quad (10)$$

$(1-\rho)$ 表示第 G 代和第 $G+1$ 代之间信息素的挥发程度,

$$\Delta \tau_j = \sum_{i=1}^{NP} \Delta \tau_j^i. \quad (11)$$

$\Delta \tau_j^i$ 为第 i 个粒子在第 G 代和第 $G+1$ 代之间赋予第 j 条路径上的信息素量. 可由下式进行计算

$$\Delta \tau_j^i = \begin{cases} \frac{Q}{L_i}, & f(\bar{x}_{ij}^{G+1}) < f(x_i^G), \\ 0, & \text{其他}. \end{cases} \quad (12)$$

式中: Q 为常数, L_i 表示为

$$L_i = \left| \frac{f(x_i^{G+1})}{f(x_i^{G+1}) - f(x_i^G)} \right|. \quad (13)$$

系数 ρ 必须设为一个小于1的数,以避免信息素无限制的积累.

6) 根据式(14)(15)更新粒子群算法的粒子最优值 $pbest$ 和全局最优值 $gbest$,

$$pbest = \begin{cases} x_i^{G+1}, & f(x_i^{G+1}) \leq f(pbest), \\ pbest, & \text{其他}. \end{cases} \quad (14)$$

$$gbest = \begin{cases} pbest_{\min}, & f(pbest_{\min}) \leq f(gbest), \\ gbest, & \text{其他}. \end{cases} \quad (15)$$

其中 $pbest_{\min} = \arg \min f(pbest)$.

7) 重复2)~6)操作,直到进化代数超过最大进化代数 G_m 或最优值在若干代中不再更新.

4 仿真研究(Simulation and research)

4.1 蚁群算法参数设置(Preferences of ant colony optimization)

众多的研究学者对蚁群算法参数设置进行研究^[13],这些研究成果无疑对AS-PSO算法中蚁群系统参数设置提供借鉴. 启发因子 α 反映蚂蚁在运动过程中所积累的信息素在指导蚁群搜索中的相对重要程度,其值越大,蚂蚁选择以前走过路径的可能性就越大,搜索的随机性减弱,导致过早的收敛;而当启发因子 α 值过小时,易使蚁群的搜索速度慢. 启发因子 β 反映了启发式信息在指导蚁群搜索过程中的相对重要程度,其大小反映了蚁群寻优过程中先验性、确定性因素的作用强度. β 越大,能防止算法过早的收敛,但使得算法在最优粒子附近进行局部搜索的能力变弱. 信息素挥发因子 ρ 对算法的影响具有双重性^[14],当 ρ 较小时,未被选中路径上的信息量将迅速衰减,这使搜索空间减小,算法陷入局部最优的可能性加大而算法的收敛性提高;另一方面,被选路径上的信息量增量减小,这使搜索空间增大,算法陷入局部最优的可能性减小,而算法的收敛性降低. 信息素强度 Q 为蚂蚁循环一周时释放在所经路径上的信息素总量. 作为反馈量, Q 越大算法的收敛性越高,但同时由于反馈加强使搜索空间减小,算法陷入局部最优的可能性会增大. 同时,对AS-PSO算法参数设置的仿真试验也获得相同的定性结论,具体地,当 $\alpha \in [1.0, 2.0]$, $\beta \in [4.0, 6.0]$, $\rho \in [0.5, 0.8]$ 算法具有较好的寻优性能,且收敛性和收敛速度较好. 当 $Q \geq 700$ 时,算法的寻优性能很不稳定.

4.2 性能比较(Performance comparison)

为了体现提出算法的优越性,分别采用AS-PSO, DPATPSO^[5], APSO-VI^[6], 对下面4个典型的基准函数(如表1所示)求解最小值. 实验参数设置如下:

DPATPSO 和APSO-VI算法的 $c_1 = c_2 = 1.49$, $\omega_{\max} = 0.9$, $\omega_{\min} = 0.3$, $\Delta \omega = 0.05$, $T_{\text{end}} = 1800$; 在AS-PSO算法中,参数设置为 $w = 9$, $\alpha = 1$, $\beta = 6$, $\rho = 0.6$ 和 $Q = 100$, $c_1 = c_2 = 1.4$. 粒子群的种群规模 $N = 40$,迭代次数为 $G = 2000$. 针对每个测试函数不同维度,运行 $T = 30$ 次,求平均值. 仿真结果与统计数据见表2.

表 1 用于测试的基准函数及其参数

Table 1 Benchmark functions used to test and their parameters

函数名称	公式	维数	$[x_{\min}, x_{\max}]$	最优值
2^n -minima	$f(x) = \sum_{i=1}^n (x_i^4 - 16x_i^2 - 5x_i)$	30 100	$[-5, 5]$	$-78n$
Rastringrin	$f(x) = \sum_{i=1}^n \{x_i^2 - 10 \cos(2\pi x_i) + 10\}$	30 100	$[-5, 5]$	0
Griewank	$f(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 + \prod_{i=1}^n \cos \frac{x_i}{\sqrt{i}} + 1$	30 100	$[-50, 50]$	0
Rosenbrock	$f(x) = \sum_{i=1}^{n-1} \{100(x_n^2 - x_{n-1})^2 + (1 - x_n)^2\}$	30 100	$[-5, 5]$	0

表 2 4种基准函数的优化结果比较

Table 2 Comparison of optimization results of four Benchmark functions

函数名称	维数	最优值	DPATPSO算法的适应值			APSO-VI算法的适应值			AS-PSO算法的适应值		
			平均值	最好值	最差值	平均值	最好值	最差值	平均值	最好值	最差值
2^n -minima	30	-2350	-2067	-2180	-1982	-2198	-2280	-1996	-2263	-2350	-2060
	100	-7883	-6166	-6497	-5771	-6509	-6767	-6264	-6601	-6869	-6417
Rastringrin	30	0	62	29	107	48	18	78	33	17	56
	100	0	547	343	816	445	307	657	101	72	120
Griewank	30	0	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
	100	0	0.486	0.293	0.691	0.331	0.153	0.413	0.008	0.000	0.189
Rosenbrock	30	0	58	21	176	47	7	93	48	0	81
	100	0	3711	1113	7864	2224	932	4138	96	82	108

从表2可以看出, AS-PSO算法在维数 $D = 30$ 的情况下, 除Rosenbrock函数之外, 其余3个测试函数的平均值均优于DPATPSO和APSO-VI算法. 而在维数 $D = 100$ 的情况下, AS-PSO算法对于4个基本测试函数的测试结果都优于其余2个算法. 这说明AS-PSO算法具有更好的稳定性以及寻优效果. 另外, AS-PSO与SPSO^[2]算法进行比较:

PSO算法中惯性权重线性下降, ω 从0.9到0.4随进化而线性减小, $c_1 = c_2 = 2.0$;

在AS-PSO算法中, 参数设置为:

$$w = 9, \alpha = 1, \beta = 6, \rho = 0.6,$$

$$Q = 100, c_1 = c_2 = 1.4.$$

粒子群的种群规模 $N = 40$, 迭代次数为 $G = 2000$.

分别采用表1中4个测试函数在维数 $D = 100$ 的情况下, 求出平均每代全局最优值曲线与SPSO算法进行比较, 结果如图1~4, 图中横坐标为进化代数, 纵坐标为平均每代全局最优值.

由图1~4可见, AS-PSO比SPSO算法更快的收敛到最优值附近进行局部搜索, 而最终的寻优结果也好于SPSO算法.




图 1 AS-PSO, SPSO对 2^n -minima寻优性能比较

Fig. 1 Performance Comparison of 2^n -minima




图 2 AS-PSO, SPSO对Rastrigrin寻优性能比较

Fig. 2 Performance Comparison of Rastrigrin




图3 AS-PSO, SPSO对Griewank寻优性能比较

Fig. 3 Performance Comparison of Griewank




图4 AS-PSO, SPSO对Rosenbrock寻优性能比较

Fig. 4 Performance Comparison of Rosenbrock

4.3 AS-PSO参数自适应分析(Parameter self-adaption analysis of AS-PSO)

以维数 $D=100$, 种群大小 $n=40$, 进化代数 $G=2000$ 的AS-PSO算法运行 $T=30$ 次来对Rastrigrin函数进行寻优的过程为例, 对本文算法的参数自适应过程进行分析. 定义惯性权重均值 $\bar{\omega}(G)$ 以及路径平均选择概率 $\bar{P}_j(G)$, 如下式表示:

$$\bar{\omega}(G) = \frac{\sum_{t=1}^T \sum_{i=1}^N \sum_{j=1}^w P_{tij}(G) \times \omega(G)_{tij}}{T \cdot N},$$

$$\bar{P}_j(G) = \frac{\sum_{t=1}^T \sum_{i=1}^N P_{tij}(G)}{T \cdot N}.$$

其中 $P_{tij}(G)$ 表示在第 t 次运算过程中, 第 G 代第 i 个粒子选择第 j 条路径的概率; $\omega(G)_{tij}$ 表示在第 t 次运算过程中, 第 G 代第 i 个粒子选择第 j 条路径时惯性权重的取值. $\bar{\omega}(G)$ 反应了在 T 次运算过程中, 种群进化时算法自适应选取的惯性权重的整体平均值; $\bar{P}_j(G)$ 反映了在 T 次运算过程中, 种群进化时第 j 条路径被选中的概率均值. 图5为惯性权重均值 $\bar{\omega}(G)$ 随进化代数的变化曲线图. 图6~14为不同路径平均选择概率与进化代数的变化图.




图5 AS-PSO算法惯性权重均值

Fig. 5 Mean inertia weight of AS-PSO




图6 路径1平均选择概率

Fig. 6 Mean selecting probability of path1




图7 路径2平均选择概率

Fig. 7 Mean selecting probability of path2




图8 路径3平均选择概率

Fig. 8 Mean selecting probability of path3




图 9 路径4平均选择概率

Fig. 9 Mean selecting probability of path4




图 10 路径5平均选择概率

Fig. 10 Mean selecting probability of path5




图 11 路径6平均选择概率

Fig. 11 Mean selecting probability of path6




图 12 路径7平均选择概率

Fig. 12 Mean selecting probability of path7




图 13 路径8平均选择概率

Fig. 13 Mean selecting probability of path8




图 14 路径9平均选择概率

Fig. 14 Mean selecting probability of path9






由图6~14可以看出,在算法的初期(100代以内),惯性权重各条路径上的选择概率是基本是相等的,都维持在平均值 $1/9$ 左右.说明在此期间内,算法基本可以通过等概率的不同惯性权重取值确定不同的步长,从而使算法的搜索覆盖到整个空间,能较快的寻优到最优值附近.相比于其他的采用一特定参考轨迹的自适应算法,通常初期采用较大的惯性权重容易使得算法的搜索主要集中在搜索空间的边界附近.而Rastrigin函数的最优解为 $\{x_1, x_2, \dots, x_n\} = \{0, 0, \dots, 0\}$,所以如果在初期规定采用较大的惯性权重在空间的边界搜索显然会降低寻优的速度.算法在400代左右找到最优解,观察200~400代内的惯性权重自适应情况,各条路径的选择概率开始偏离概率均值 $1/9$,因为算法在200代左右时寻优已接近最优值,所以在这一期间内,算法进入局部搜索阶段,故理论上应采用较小的惯性权重.由图6~14看出那些较大的惯性权重显然不符合局部搜索的要求,所以它们的选择概率逐渐减小,而惯性权重相对较小的路径,选择概率逐渐增大.在400代以后,算法仍然在进行局部搜索,所以取值小的惯性权重的选择概率继续增加,而那些经过算法前期搜索验证不利

于产生更优解的路径选择概率继续减小,但是同样可以发现,一些惯性权重取值较大的路径同样存在被选中的可能(如图13),这样保证了算法跳出局部最优的能力.由图2的寻优过程可以看出,AS-PSO由于前期采用多样的惯性权重策略在整个空间搜索,在算法的初期就能很快的找到测试函数的最优值,并使得算法在很长的时间内在其附近进行局部搜索,而并非如惯性权重线性下降的SPSO算法规定了初期采用较大的惯性权重进行全局搜索,而到了算法后期才进行局部搜索.这样大大地提高了算法寻优的速度,效率和精确度.由图5可以看出,AS-PSO算法采用参数自适应方法使得惯性权重平均值在进化的初期取较大值,经过中期振荡下降的过程,到算法的末期会选取较小的惯性权重,这符合粒子群算法初期注重全局搜索而在末期主要进行最优值附近局部搜索的策略;而且,这一过程是根据粒子进化寻优进展情况,通过蚁群算法自适应形成的.从图6可以看出,对于惯性权重取值较小的路径,被算法选中的概率从初期的概率平均值1/9处,随着种群不断的进化而逐渐增加,到一定程度以后在一个较大的值0.6附近波动,并最终收敛到这个值,这说明较小的惯性权重值有利算法在后期产生更优秀的粒子;而图13,14反映了对于惯性权重取值较大的路径,在算法初期被选择的概率一度高于概率平均值1/9,但之后快速的下降并减小为0,说明采用较大的惯性权重值在初期的全局搜索时尚能发现更优秀的粒子,但随着粒子不断的进化,较大的惯性权重不利于产生更好的粒子,随之该路径就被算法所抛弃.另外,一些惯性权重取值在中间大小的子区间,同样存在着一些规律:如图7~9、图12,在这些路径上,选取的概率经过前期的振荡之后收敛到平均概率1/9附近,说明在算法后期,选取这些路径也能生成较好的粒子,但是生成较好粒子的概率不如选择较小的惯性权重来的高;在剩余的子区间上,如图12,13,经过进化前期信息素积累到一定程度之后,这些路径也被算法抛弃,被选择概率接近为0.从全局看,在路径的选择上,算法并没有使较小惯性权重路径的选择概率得到无限的增长,而是在增大到一定值之后稳定在该值,使得算法也能够选择其他的路径产生优秀的粒子,这使得算法在一定程度上保证了惯性权重的多样性,并有一定的能力跳出局部极值.经过上述的分析,可以看出,利用蚁群算法来优化粒子群算法中惯

性权重的取值,综合了粒子在进化过程中的各方面因素,充分发挥了蚁群算法在路径选择上的优势,使得算法具有很好的性能.

5 AS-PSO估计废气水银氧化动力学模型参数(AS-PSO Applied to preferences estimation of Hg oxidation kinetics model)

水银是人们熟知的剧毒环境污染物,煤燃烧以后产生的水银及其化合物对包括大气、水体以及土壤在内的生态环境产生严重污染,而燃煤电站烟气中水银的形态(如:元素汞 Hg^0 ,氧化汞 Hg^{2+} 和颗粒态汞 Hg^P)对水银的去除有很大的影响.科学理论证明,通过提高 Hg^0 被氧化成 Hg^{2+} 的比例,能有效的减少 Hg 的污染排放量.为了研究烟气中水银的反应机理,建立能够预测水银氧化进程的动力学模型就显得非常有意义. Agarwal等对水银氧化机理作了详尽的分析,并提出了一个有5个反应的系统框架,5个反应里包含2个可逆反应和3个不可逆反应.反应式的化学方程式如下:



其中: Hg : 元素汞; Cl_2 : 氯气; HgCl_2 : 氯化汞; H_2O : 水; HCl : 盐酸; O_2 : 氧气; H_2 : 氢气; SO_2 : 二氧化硫; SCL_2 : 二氯化硫; NO : 一氧化氮; NOCl : 氯化亚硝酸; (g)表示气态; (s,g)表示物质可能是固态(s)也可能是气态(g)或固气共存.

反应动力学方程如下:

$$r_1 = A_1 \cdot \exp\left(\frac{-E_1}{R \cdot T}\right) \cdot ([\text{H}_2\text{O}] \cdot [\text{Cl}_2] - \frac{[\text{HCl}]^2 \cdot [\text{O}_2]^{1/2}}{\exp(13.707 - \frac{4769.2}{T})}), \quad (16)$$

$$r_2 = A_2 \cdot \exp\left(\frac{-E_2}{R \cdot T}\right) \cdot ([\text{Hg}] \cdot [\text{Cl}_2] - \frac{[\text{HgCl}_2]}{\exp(-17.833 - \frac{17133.1}{T})}), \quad (17)$$

$$r_3 = A_3 \cdot \exp\left(\frac{-E_3}{R \cdot T}\right) \cdot [\text{NO}] \cdot [\text{Cl}_2], \quad (18)$$

$$r_4 = A_4 \cdot \exp\left(\frac{-E_4}{R \cdot T}\right) \cdot [\text{HgCl}_2] \cdot [\text{SO}_2], \quad (19)$$

$$r_5 = A_5 \cdot \exp\left(\frac{-E_5}{R \cdot T}\right) \cdot [\text{Hg}] \cdot [\text{HCl}]. \quad (20)$$

其中: $[Hg]$: 元素汞的浓度; $[Cl_2]$: 氯气的浓度; $[HgCl_2]$: 氯化汞的浓度; $[H_2O]$: 水的浓度; $[HCl]$: 盐酸的浓度; $[O_2]$: 氧气的浓度; $[SO_2]$: 二氧化硫的浓度; $[NO]$: 一氧化氮的浓度; r_i : 反应速率, $i = 1, 2, 3, 4, 5$; A_i : 前项因子, $i = 1, 2, 3, 4, 5$; E_i : 活化能, $i = 1, 2, 3, 4, 5$; R : 气体常数; T : 绝对温度. 其中 A_i 和 E_i ($i = 1, 2, 3, 4, 5$) 是 10 个待定的动力学参数, 优化这些待定参数的目标是使由式(16)~(20)计算得到的氧化汞的转化率与测量值的差值最小. 则目标函数可表示为

$$\min EQS = \frac{1}{m} \sum_{i=1}^m (\bar{c}_i - c_i)^2, \quad (21)$$

表 3 AS-PSO 算法与报导文献中参数与优化目标函数值的比较

Table 3 Optimal parameters and objective function values corresponding to reported data^[16] and AS-PSO

	A_1	A_2	A_3	A_4	A_5	E_1	E_2	E_3	E_4	E_5	EQS
Agarwal et al.	62.271	0.37688	98.682	138.85	36.113	8.8668	0.089337	23.509	17.638	15.108	88.134
AS-PSO	3.7943	0.51374	70.551	7.6191	33.426	3.8570	0.4516	17.383	12.861	15.204	77.66

6 结论(Conclusion)

基于蚁群系统的惯性权重自适应粒子群算法(AS-PSO), 通过蚁群算法综合粒子进化搜优进展信息与粒子空间分布情况, 实现在粒子进化寻优的同时, 算法关键参数——惯性权重的自适应进化. 4 个典型测试函数的仿真研究表明, AS-PSO 算法的惯性权重能随着算法搜索进展, 自适应进化调整, 保证算法的全局寻优性能与局部搜索能力, 提高算法的收敛速度, 以及解的精度; AS-PSO 算法的寻优速度, 以及求得最优解的精度均优于 APSO-VI, SPSO 两个典型的自适应粒子群算法. 最后, 将 AS-PSO 算法应用于求解废气水银氧化动力学模型参数, 模型的拟合精度明显低于文献报道值.

参考文献(References):

- [1] KENNEDY J, EBERHART R C. Particle swarm optimization[C] // *Proceedings of IEEE International Conference on Neural Networks*. Perth, Australia: IEEE, 1995: 1942 – 1948.
- [2] EBERHART R C, SHI Y H. Comparing Inertia Weights and Constriction Factors in Particle Swarm Optimization[C] // *Proceedings of the 2000 Congress on Evolutionary Computation*. San Diego, USA: IEEE, 2000: 84 – 88.
- [3] 陈贵敏, 贾建援, 韩琪. 粒子群优化算法的惯性权重递减策略研究[J]. 西安交通大学学报, 2006, 40(1): 53 – 56.
(CHEN Guimin, JIA Jianyuan, HAN Qi. Study on the strategy of decreasing inertia weight in particle swarm optimization algorithm[J]. *Journal of Xi'an Jiaotong University*, 2006, 40(1): 53 – 56.)
- [4] CLERC M, KENNEDY J. The particle swami explosion, stability, and convergence in a multidimensional complex space[J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(1): 58 – 73.
- [5] NOBUHIRO Iwasaki, KEIICHIRO Yasuda. Dynamic parameter tuning of particle swarm optimization[J]. *IEEE Transactions on Electrical and Electronic Engineering*, 2006, 1(4): 353 – 363.
- [6] 徐刚, 瞿金平, 杨智韬. 一种改进的自适应粒子群优化算法[J]. 华南理工大学学报(自然科学版), 2008, 9(36): 6 – 10.
(XU Gang, QU Jinping, YANG Zhitao. An improved adaptive particle swarm optimization algorithm[J]. *Journal of South China University of Technology(Natural Science Edition)*, 2008, 9(36): 6 – 10.)
- [7] 段玉宏, 高岳林. 基于蚁群信息机制的粒子群算法[J]. 计算机工程与应用, 2008, 44(31): 81 – 83.
(DUAN Yuhong, GAO Yuelin. Particle swarm optimization algorithm based on information of ant colony[J]. *Computer Engineering and Applications*, 2008, 44(31): 81 – 83.)
- [8] 王素欣, 高利, 崔小光, 等. 多需求点车辆调度模型及其群体智能混合求解[J]. 自动化学报, 2008, 34(1): 102 – 104.
(WANG Suxin, GAO Li, CUI Xiaoguang, et al. Study on multi-requirement points vehicle scheduling model and its swarm mix algorithm[J]. *Acta Automatica Sinica*, 2008, 34(1): 102 – 104.)
- [9] MOZAFARI B. A hybrid of particle swarm and ant colony optimization algorithms for reactive power market simulation[J]. *Journal of Intelligent and Fuzzy Systems*, 2006, 17(6): 1064 – 1246.
- [10] SHI C X, BU Y Y, LI Z G. Path planning for deep sea mining robot based on ACO-PSO hybrid algorithm, intelligent computation technology and automation(ICICTA)[C] // *2008 International Conference*. Washington DC: IEEE Computer Society, 2008, 1: 125 – 129.
- [11] 韩江洪, 李正荣, 魏振春. 一种自适应粒子群优化算法及其仿真研究[J]. 系统仿真学报, 2006, 18(10): 2969 – 2971.
(HAN Jianghong, LI Zhengrong, WEI Zhenchun. Adaptive particle swarm optimization algorithm and simulation[J]. *Journal of System Simulation*, 2006, 18(10): 2969 – 2971.)
- [12] COLORNI A, DORIGO M, MANIEZZO V. Distributed optimization by ant colonies[C] // *Proceedings of the First European Conference on Artificial Life*. Amsterdam: Elsevier Publishing, 1991: 134 – 142.
- [13] 蒋玲艳, 张军, 钟树鸿. 蚁群算法的参数分析[J]. 计算机工程与应用, 2007, 43(18): 31 – 36.
(JIANG Lingyan, ZHANG Jun, ZHONG Shuhong. Analysis of pa-

其中: $\bar{c}_i$: 通过动力学方程拟合得到的 Hg 转化率; c_i : 实验测量得到的 Hg 转化率; EQS: Hg 转化率拟合的误差平方和; m : 实验点个数.

采用 AS-PSO 算法并以式(21)为目标, 估算式(16)~(20)中的反应动力学参数, 有关的样本实验数据取自文献[15,16]. AS-PSO 算法操作参数设置为: $G_m = 400$, $\alpha = 0.8$, $\beta = 0.5$, $\rho = 0.3$, $c_1 = c_2 = 2.0$, $\omega \in [0.4, 0.9]$. 表 3 给出了 AS-PSO 算法求得的参数值和文献报道值的比较. 从表中可以看出, 由 AS-PSO 求得的最优值为 77.66, 而文献报道值 EQS = 88.134. 下降幅度十分显著.

rameters in ant colony system[J]. *Computer Engineering and Applications*, 2007, 43(18): 31 – 36.)

- [14] 王颖, 谢剑英. 一种自适应蚁群算法及其仿真研究[J]. 系统仿真学报, 2002, 14(1): 31 – 33.

(WANG Ying, XIE Jianying. An adaptive ant colony optimization algorithm and simulation[J]. *Journal of System Simulation*, 2002, 14(1): 31 – 33.)

- [15] AGARWAL H, STENGER H G, WU S, et al. Effects of H_2O , SO_2 and NO on homogeneous Hg oxidation by Cl_2 [J]. *Energy Fuels*, 2006, 20(3): 1068 – 1075.

- [16] AGARWAL H, ROMERO C E, STENGER H G. Comparing and interpreting laboratory results of Hg oxidation by a chlorine species[J].

Fuel Processing Technology, 2007, 88(7): 723 – 730.

作者简介:

杨帆 (1985—), 男, 主要研究方向为智能优化算法与工业装置优化, E-mail: fanyang2008@hotmail.com;

胡春平 (1982—), 男, 主要研究方向为智能优化算法与工业装置建模与优化;

颜学峰 (1972—), 男, 教授, 博士生导师, 研究方向为复杂系统建模与优化和智能信息处理, E-mail: xfyang@ecust.edu.cn.

两部人工智能新著出版

蔡自兴等教授编著的《人工智能及其应用》第4版和《人工智能基础》第2版新著, 最近分别由清华大学出版社和高等教育出版社出版发行。

由蔡自兴和徐光祐执笔编著的《人工智能及其应用》一书, 是国内率先出版的具有自主知识产权的人工智能著作, 不仅为我国人工智能课程提供了一部好教材, 而且促进了人工智能课程在国内高校的普遍开设和建设, 对人工智能在中国的传播和发展起到重大推动作用。该书得到国内同行肯定和赞许, 曾获1999年度国家教育部科技进步一等奖等奖励, 已先后印刷30多次, 发行近30万册, 处于国内同类著作和教材领先地位, 不仅成为蔡自兴教授主持的2003年首批国家精品课程《人工智能》的配套教材在全国全面推广使用, 而且为人工智能课程建设和创新型人才培养做出贡献。该教材还与蔡自兴、蒙祖强教授编著的《人工智能基础》一起, 作为国家级《智能科学基础系列课程教学团队》(2008)人工智能课程的配套教材使用。

两书主要内容相似, 但其深度、篇幅和使用对象有异。以《人工智能及其应用》第4版为例, 该书共10章。第1章叙述人工智能的定义、起源与发展, 归纳了人工智能的研究目标、研究内容和研究方法, 简介人工智能不同学派的认知观, 列举出人工智能的研究与应用领域。第2章和第3章主要研究传统人工智能的知识表示方法和搜索推理技术。第4章探讨不确定性推理方法, 涉及概率推理、主观贝叶斯方法、可信度方法和证据理论等。第5章阐述计算智能的基本知识, 包含神经计算、模糊计算、进化计算、人工生命、粒子群优化和蚁群计算诸内容。第6章至第10章详细地逐一讨论了人工智能的主要应用领域, 包括专家系统、机器学习、自动规划、分布式人工智能和自然语言理解等。与第3版本科生用书相比, 许多内容都是第一次出现的, 例如, 知识表示和推理部分的本体论和非经典推理, 计算智能部分的粒子群优化和蚁群计算, 机器学习部分的决策树学习和增强学习, 自然语言理解部分的词法分析、语义分析和语料库语言学, 以及路径规划和基于Web的专家系统等。其它章节也在第3版的基础上作了相应修改、精简或补充。

两书具有系统全面、理论联系实际、及时反映人工智能研究与应用的最新进展及可读性好等特色。其中, 《人工智能及其应用》主要面向研究生和重点高校本科生, 而《人工智能基础》则是面向一般院校本科生。此外, 两书也可供从事人工智能研究与应用的科技工作者学习参考。

(任中南, 向蔚蓝)