

文章编号: 1001-0920(2011)06-0816-05

粒子群优化算法的概率特性分析及算法改进

申元霞^{1,2,3}, 王国胤^{1,2}

(1. 西南交通大学 信息科学与技术学院, 成都 610031; 2. 重庆邮电大学 计算机科学与技术研究所, 重庆 400065; 3. 重庆文理学院 计算机学院, 重庆 402160)

摘要: 群体多样性的丧失是导致粒子群优化(PSO)出现早期收敛的重要原因, 鉴于此, 对 PSO 运动方程进行概率特性分析, 指出了方程中学习参数的概率分布及参数间的相依性与群体多样性丧失之间的关系, 并提出了一种自适应学习的 PSO 算法. 该算法通过调整学习参数的概率特性来保持种群多样性, 同时设计了随进化状态自适应变化的学习参数来协调粒子的全局与局部搜索能力. 实验结果表明, 自适应学习的 PSO 算法提高了收敛的精度, 有效避免了早期收敛.

关键词: 粒子群优化算法; 早期收敛; 概率特性; 群体多样性

中图分类号: TP273

文献标识码: A

Probabilistic characteristics analysis of particle swarm optimization and its improved algorithm

SHEN Yuan-xia^{1,2,3}, WANG Guo-yin^{1,2}

(1. School of Information Science and Technology, Southwest Jiaotong University, Chengdu 600031, China; 2. Institute of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China; 3. School of Computer Science, Chongqing University of Arts and Sciences, Chongqing 402160, China. Correspondent: SHEN Yuan-xia, E-mail: yuanxiashen@163.com)

Abstract: The loss of population diversity is an important reason to cause the premature convergence in particle swarm optimization(PSO). Therefore, this paper makes the probabilistic characteristics analysis of learning parameters of PSO and proposes the relationship between the loss of population diversity and the probabilistic distribution and dependence of learning parameters. Then an adaptive learning particle swarm optimization(ALPSO) is proposed, where the modified probabilistic distribution of learning parameters is used to maintain population diversity. Meanwhile, the adaptive learning parameter with changing of evolutionary state is designed to balance the global and local search abilities of particles. Experimental results show that ALPSO improves the convergence precision and effectively avoids the premature convergence.

Key words: particle swarm optimization; premature convergence; probabilistic characteristic; population diversity

1 引言

在智能自动化研究领域, 具有群体智能特征的算法研究正受到越来越多的关注. 粒子群优化(PSO)算法是一种典型的群体智能优化算法, 用来解决大量非线性、不可微和多峰值的复杂问题的优化, 并已广泛应用于电力系统控制、多目标问题的决策优化、资源分配等科学和工程领域^[1]. 但是, 随着求解问题复杂性的增加, 现有 PSO 模型面临着早熟、全局收敛性能

差等问题. 为了避免早熟收敛, 研究者提出了通过控制种群多样性来提高算法性能的方法: 一方面通过引入突变算子^[2]、随机扰动^[3]、混沌算子^[4-5]等操作使粒子逃离局部极值区域; 另一方面通过制约粒子间共享信息的流动速度、增加环境的检测和控制等策略来维持群体的多样性. 文献[6]提出粒子自身认知的加速系数随迭代次数递减、群体认知的加速系数随迭代次数递增的策略来制约粒子间学习前期的信息交流以

收稿日期: 2010-03-14; 修回日期: 2010-05-31.

基金项目: 国家自然科学基金项目(60773113); 重庆市自然科学基金重点项目(2008BA2017); 重庆市杰出青年科学基金项目(2008BA2041); 重庆市重点实验室开放基金项目(CY-CNCL-2009-03).

作者简介: 申元霞(1979-), 女, 博士生, 从事计算智能、智能信息处理的研究; 王国胤(1970-), 男, 教授, 博士生导师, 从事粗糙集、粒计算等研究.

保持群体的多样性. [7-8] 分别通过种群多样性和进化状态来监控环境的变化, 并依据环境的响应来调整惯性系数和加速系数. [9] 提出全信息 PSO 算法, 通过向邻域粒子学习来降低共享信息的流速. 上述方法通过调整加速系数、惯性系数和学习对象来维持或提高群体多样性, 但由于缺乏对标准 PSO 信息加工机制的分析, 使得改进 PSO 算法仍无法避免陷入早期收敛, 收敛精度较差.

本文从理论上对 PSO 算法的运动方程做了概率统计特性分析, 并研究了学习参数的概率分布及参数间的相依性与群体多样性丧失之间的关系. 在此基础上, 提出自适应学习的 PSO 算法 (ALPSO), 该算法通过调整学习参数的概率特性来保持种群多样性, 同时设计了学习参数随进化状态自适应调整的策略, 使得学习参数的自适应性能能够协调粒子的全局与局部搜索能力. 对复杂的多峰测试函数仿真实验结果表明, 本文提出的算法明显提高了收敛精度, 有效避免了算法陷入早熟收敛.

2 标准 PSO 模型的概率特性分析

2.1 简介标准 PSO 模型

PSO 算法在对动物集群活动行为进行观察的基础上, 利用群体中的个体对信息的共享使得整个群体的运动在问题求解空间中产生从无序到有序的演化过程, 其运动方程可由如下差分方程来描述^[10]:

$$V_{id}(t+1) = wV_{id}(t) + c_1r_1(t)(P_{bd}(t) - X_{id}) + c_2r_2(t)(P_{gd}(t) - X_{id}), \quad (1)$$

$$X_{id}(t+1) = X_{id}(t) + V_{id}(t+1). \quad (2)$$

其中: X_{id} 和 V_{id} 分别代表第 i 个粒子第 d 维的位置与速度分量, $|V_{id}| \leq V_{\max}$; P_{bd} 为第 i 个粒子个体所经历的历史最佳位置分量, P_{gd} 为群体所经历的历史最佳位置分量; w 为惯性权重; r_1 和 r_2 为 $[0,1]$ 之间独立均匀分布的随机数, 称为随机因子; c_1 和 c_2 为加速系数 (通常 $c_1 = c_2$). 式 (1) 中第 1 项为动量项, 表示粒子以先前速度所进行的惯性运动; 第 2 项为自身认知项, 表示粒子本身的思考; 第 3 项为群体认知项, 反映粒子间的协同合作和知识的共享.

目前, 标准 PSO 模型多样性迅速丧失的原因在于, 模型以全体最优解为中心, 该结构使得群体中的信息交流速度快且方向单一, 粒子快速地聚集在一个较小的搜索区域内, 进而使群体多样性降低, 导致出现早熟收敛现象^[11]. 此外, 本文将从个体认知和社会认知的信息加工原理进一步分析多样性丧失的原因.

2.2 PSO 运动方程的概率特性分析

为了便于研究, 将 PSO 模型简化为一维 PSO 模型. 不失一般性, 研究 PSO 中某一个粒子 i 某一维 d 的

运动方程. 将式 (1) 代入 (2) 可得

$$X(t+1) = X(t) + c_1r_1(P_b(t) - X(t)) + c_2r_2(P_g(t) - X(t)) + wV(t). \quad (3)$$

当式 (3) 中的随机因子 r_1, r_2 的取值遍历 $[0,1]$ 时, 粒子的自身认知和群体认知之和对应着一个搜索空间, 称为一步搜索空间. 粒子在 $t+1$ 时刻的位置可以看成由两个运动构成: 首先是粒子飞行到一步搜索空间的某个位置; 再以原来的速度继续向前做惯性运动. 下面通过对一步搜索空间的概率特性分析来研究粒子的运动行为和信加工. 由式 (3) 可得

$$X(t+1) = X(t) + wV(t) + c_1r_1(P_b(t) - X(t)) + c_2r_2(P_g(t) - X(t)) = X(t) + wV(t) + (c_1 + c_2) \left[\frac{c_1r_1}{c_1 + c_2} + \frac{c_2r_2}{c_1 + c_2} \right] \times \left[\frac{c_1r_1P_b(t)}{c_1r_1 + c_2r_2} + \frac{c_2r_2P_g(t)}{c_1r_1 + c_2r_2} - X(t) \right]. \quad (4)$$

令 $k = c_1/(c_1 + c_2)$, 可得

$$X(t+1) = X(t) + wV(t) + (c_1 + c_2)[kr_1 + (1-k)r_2] \times \left[\frac{kr_1P_b(t)}{kr_1 + (1-k)r_2} + \frac{(1-k)r_2P_g(t)}{kr_1 + (1-k)r_2} \right]. \quad (5)$$

令 $Y = kr_1 + (1-k)r_2$, $Z = kr_1/(kr_1 + (1-k)r_2)$, 有

$$X(t+1) = X(t) + (c_1 + c_2)Y[ZP_b(t) + (1-Z)P_g(t) - X(t)] + wV(t), \quad (6)$$

其中 Y, Z 为随机因子 r_1, r_2 和待定参数 k ($0 \leq k \leq 1$) 的函数, 且 $0 \leq Y, Z \leq 1$. 因此, Y 和 Z 为 $[0,1]$ 上的随机数, 且 Y 和 Z 的相关性是显然的. 式 (6) 中第 2 部分为粒子个体认知和群体认知的合成项. 首先给出合成项的几何描述: 由于 $0 \leq Z \leq 1$, 对于给定的任意 Z , $ZP_b(t) + (1-Z)P_g(t) - X(t)$ 表示以 $X(t)$ 为端点、 $P_b(t)$ 与 $P_g(t)$ 之间任一点为终点的有向线段, 称为基础线段; 由于 $0 \leq Y \leq 1$, 对于给定的任意 Y , $Y[ZP_b(t) + (1-Z)P_g(t) - X(t)]$ 表示以 $X(t)$ 为端点、基础线段中任一点为终点的线段, 称为继承线段. 合成项是以基础线段的方向为方向对继承线段扩大 $(c_1 + c_2)$ 倍的有向线段. 当 Z, Y 的取值遍历 $[0,1]$ 时, 合成项形成了一步搜索空间, 而空间内点的分布则依赖于 Z 和 Y 两个重要参数.

从信息加工的角度而言, Z 是对于 $P_b(t)$ 与 $P_g(t)$ 两个信息合成的加权系数, 其值的大小可以体现粒子对极值信息 $P_b(t)$ 和 $P_g(t)$ 学习的差异. 当 $Z > 0.5$ 时, 粒子偏向对 $P_b(t)$ 学习; 当 $Z < 0.5$ 时, 粒子偏向对 $P_g(t)$ 学习; 当 $Z = 0.5$ 时, 粒子对于极值信息 $P_b(t)$ 和 $P_g(t)$ 的学习程度相当. 因此, Z 称为学习因子, Y 是粒

子对于 $P_b(t)$ 和 $P_g(t)$ 的合成信息继承的态度, 称为继承因子. 学习因子和继承因子的特性不但可以反映一步搜索空间的分布特征, 而且反映了 $P_b(t)$ 与 $P_g(t)$ 信息加工的机理. 学习因子和继承因子为 r_1, r_2 和待参数 $k(0 \leq k \leq 1)$ 的函数, 通常情况下 $c_1 = c_2$, 即 $k = 0.5$. r_1 和 r_2 为独立的均匀随机变量, 学习因子 Z 的概率密度 $f_Z(z)$ 和学习因子与继承因子的联合密度函数 $f(y, z)$ 分别为

$$f_Z(z) = \begin{cases} 1/(2(1-z)^2), & 0 \leq z \leq 0.5; \\ 1/(2z^2), & 0.5 \leq z \leq 1; \\ 0, & \text{otherwise.} \end{cases} \quad (7)$$

$$f(y, z) = \begin{cases} 4y, & 0 \leq y \leq 1, U \leq z \leq V; \\ 0, & \text{otherwise.} \end{cases} \quad (8)$$

其中: $U = \max(0, 1 - 1/2y)$, $V = \min(1, 1/2y)$. 由式(7)和(8)可计算在给定 $Z = z$ 的条件下, Y 的条件概率密度为

$$f_{Y|Z}(y|z) = \begin{cases} 8y(1-z)^2, & 0 \leq z < \frac{1}{2}, 0 \leq y \leq \frac{1}{2(1-z)}; \\ 8yz^2, & \frac{1}{2} \leq z < 1, 0 \leq y \leq \frac{1}{2z}. \end{cases} \quad (9)$$

由式(7)可知, 学习因子的概率密度函数 $f_Z(z)$ 是关于 $z = 0.5$ 对称的单峰函数, 如图1所示. 由于 $f_Z(z)$ 在 $z = 0.5$ 处取得最大值2, 在 $z = 0.5$ 的邻近可以取得较大的概率 $P(0.5 - a \leq z \leq 0.5 + a)$. 当 $a = 0.05$ 时, $P(0.5 - a \leq z \leq 0.5 + a) = 0.182$.




图1 学习因子的概率密度

由式(9)可知, 在给定 $Z = z$ 的条件下, Y 的取值范围依赖于 Z 的取值 z . 条件概率密度 $f_{Y|Z}(y|z)$ 关于 $z = 0.5$ 对称, 当 $z = 0.5$ 时, 继承因子 Y 的取值范围 $[0, 1]$ 最大, 随着 z 的增加或减小, Y 的取值范围均不断减小, 当 $z = 0$ 或 1 时, Y 的取值范围 $[0, 0.5]$ 达到最小. 在给定 $Z = z$ 的条件下, Y 的条件概率密度是单增函数, 如图2所示, 这说明粒子对合成信息采用急进的继承态度.

通过计算和分析学习因子和继承因子的概率特性, 从3个方面论述 PSO 易陷入早熟的原因: 1) 当 $z = 0.5$ 时, 继承因子 Y 的取值范围 $[0, 1]$ 最大, 即一步最大搜索空间为 $[0, 2(P_b(t) + P_g(t) - 2X(t))]$. 由于 $z = 0.5$




图2 给定 $Z = z$ 的条件下 Y 的条件概率密度

的邻近取值概率 $P(0.5 - a \leq z \leq 0.5 + a) = 0.182$, 粒子的一步搜索空间取不到最大空间的概率是 0.818, 从而约束了粒子的开拓能力. 2) 在每步学习中, 粒子选择偏向 $P_g(t)$ ($Z < 0.5$) 的概率约等于 0.4, 且粒子一步搜索空间的范围随 Z 的减小而不断减小, 这会导致粒子在 $P_g(t)$ 附近聚集. 3) 粒子对合成信息采用急进的继承态度, 这使得粒子在一步搜索空间不能均匀取值, 且导致粒子在一步搜索空间内出现聚集的情况, 减小了粒子位置的多样性. 下面举例说明, 假设 $P_b(t) - X(t) > P_g(t) - X(t)$, 考虑两种极端情况: 若粒子只学习 $P_g(t)$ ($z = 0$), 则粒子落在 $2(P_g(t) - X(t))$ 邻近的可能性较大; 若只学习 $P_b(t)$ ($z = 1$), 则落在 $2(P_b(t) - X(t))$ 邻近的可能性较大. 当 $0 \leq Z \leq 1$ 时, 粒子落在区间 $[2(P_g(t) - X(t)), 2(P_b(t) - X(t))]$ 的概率较大, 而一步最大搜索空间为 $[0, 2(P_b(t) + P_g(t) - 2X(t))]$, 因此出现了粒子聚集的情况. 通过上面的分析可知, 学习因子和继承因子的概率特性对粒子的搜索行为和群体的多样性有着重要的影响.

3 自适应学习的粒子群优化算法

3.1 算法原理

学习因子体现粒子对极值信息 $P_b(t)$, $P_g(t)$ 学习的差异, 是平衡粒子全局与局部搜索能力的主要参数. 因为标准 PSO 学习因子偏向 $P_g(t)$ ($Z < 0.5$) 和偏向 $P_b(t)$ ($Z > 0.5$) 的概率均为 0.407, 该随机性既不利于粒子在进化前期进行开拓学习, 也不利于进化后期对已获知最优解的发掘. 所以, 对学习因子实施有效的控制有利于提高粒子的寻优能力. 本文提出一种时变的学习因子策略, 在进化初期粒子只学习 $P_b(t)$, 随着学习步的增加缓慢地偏向 $P_g(t)$ 学习, 有效平衡了粒子的全局与局部搜索能力.

在标准 PSO 中, 粒子的一步搜索空间只有在学习因子为 0.5 时才能达到最大搜索空间, 同时粒子对合成信息采用急进的继承态度, 这两方面均不利于保持种群多样性. 本文提出解除学习因子与继承因子相依的策略, 使继承因子对所有学习因子采用一致的信息继承态度, 因此 ALPSO 的速度更新公式为

$$V_{id}(t+1) = wV_{id}(t) + (c_1 + c_2)Y[ZP_{ba}(t) + (1-Z)P_{ga}(t) - X_{id}(t)],$$

$$Z = Z_{\max} - (Z_{\max} - Z_{\min})t/\text{itermax},$$

$$f_Y(y) = 1, Y \in [0, 1]. \quad (10)$$

其中: 学习因子 Z 和继承因子 Y 是独立的; $Z_{\max} = 1$, $Z_{\min} = 0$; itermax 为最大迭代步长. 学习因子时变的递减策略使粒子在学习前期增强全局搜索能力, 而在学习后期增强局部搜索能力. 学习因子和继承因子解相关, 且继承因子服从 $[0,1]$ 均匀分布, 这使得粒子一步最大搜索空间的大小不依赖于学习因子的取值. 在整个进化过程中, 粒子的一步搜索空间均可达到最大搜索空间, 且粒子以等概率落在一步搜索空间的任一位置, 有利于维持群体的多样性.

3.2 算法的收敛性能分析

定义 1 将 ALPSO 的平均行为按其期望值进行观察, 当 $0 < (c_1+c_2) < 4(w+1)$ 时, $\lim_{t \rightarrow \infty} X(t) = ZP_b + (1-Z)P_g, 0 \leq Z \leq 1$.

证明 对于任意粒子 i , 将运动方程 (10) 的时间项向前推进一步代入 (2), 可得

$$X(t+1) = (1+w - (c_1+c_2)Y)X(t) - wX(t-1) + (c_1+c_2)Y[ZP_b(t) + (1-Z)P_g(t)]. \quad (11)$$

若将位置变化看作一个连续过程, 则式 (11) 可对应得到一个二阶微分方程, 其对应的一般解的形式为

$$X(t) = K_1 + K_2\lambda_1^2 + K_3\lambda_2^2. \quad (12)$$

其中: λ_1, λ_2 是方程的特征根, 有

$$\lambda_{1,2} = (1+w - (c_1+c_2)Y) \pm \sqrt{((1+w - (c_1+c_2)Y)^2 - 4w)/2}; \quad (13)$$

K_1, K_2, K_3 是由系统的初始条件决定的常数, 有

$$K_1 = ZP_b + (1-Z)P_g, \quad (14)$$

$$K_2 = \frac{\lambda_2(X(0) - X(1)) - X(1) + X(2)}{(\lambda_1 - 1)(\lambda_1 - \lambda_2)}, \quad (15)$$

$$K_3 = \frac{\lambda_1(X(1) - X(0)) - X(1) + X(2)}{(\lambda_2 - 1)(\lambda_1 - \lambda_2)}. \quad (16)$$

粒子第 0, 1, 2 步的位置分别为 $X(0), X(1)$ 和 $X(2)$.

当 $\max(\|\lambda_1\|, \|\lambda_2\|) < 1$ 时, 极限 $\lim_{t \rightarrow \infty} X(t)$ 存在. 不等式解得 $0 < (c_1+c_2)Y < 2(w+1)$. 由于 Y 是 $[0,1]$ 均匀分布随机变量, $E((c_1+c_2)Y) = (c_1+c_2)/2$. 将 ALPSO 的平均行为按其期望值进行观察, 当 $0 < (c_1+c_2) < 4(w+1)$ 时, 有 $\lim_{t \rightarrow \infty} X(t) = ZP_b + (1-Z)P_g$. \square

4 仿真实验

下面采用 3 个复杂多模测试函数来评价 ALPSO 的性能, 并与标准粒子群算法 (SPSO)^[10], 时变加速系数粒子群算法 (PSO-TVAC)^[6], 自适应粒子群算法 (APSO)^[8], 全信息粒子群算法 (FIPS)^[9] 和混沌粒子群算法 (CPSO)^[5] 的测试结果进行比较.

函数 f_1 (Rastrigin 函数) 为

$$f_1(x) = \sum_{i=1}^D (x_i^2 - 10 \cos(2\pi x_i) + 10),$$

$$x_i \in [-5.12, 5.12].$$

函数 f_2 (非连续 Rastrigin 函数) 为

$$f_2(x) = \sum_{i=1}^D (y_i^2 - 10 \cos(2\pi y_i) + 10).$$

$$y_i = \begin{cases} x_i, & |x_i| < 0.5; \\ \text{round}(2x_i)/2, & |x_i| \geq 0.5, x_i \in [-5.12, 5.12]. \end{cases}$$

函数 f_3 (Schaffer's f_7 函数) 为

$$f_3(x) = \sum_{i=1}^{D-1} (x_i^2 + x_{i+1}^2)^{0.25} [\sin(50(x_i^2 + x_{i+1}^2))^{0.1} + 1],$$

$$x_i \in [-100, 100].$$

$f_1 \sim f_3$ 均为典型的非线性多模态函数, 它们具有广泛的搜索空间、大量的局部极小点和高大的障碍物, 通常被认为是目前很难处理的复杂多模态问题. 3 个函数均在 $x_i = 0$ 处取得全局最小值 0. 为了方便比较各个算法的性能, 令算法的种群规模均为 $S = 20$, 问题解的维数分别为 30 和 50, 最大进化代数 $\text{itermax} = 100\,000$. 惯性系数均设置为从 0.9 到 0.3 递减的策略. 对于加速系数, SPSO 和 CPSO 设置为 $c_1 = c_2 = 2$; PSO-TVAC, APSO 和 FIPS 的设置见文献 [6, 8-9]; ALPSO 设置为 $c_1 + c_2 = 4$. 在相同迭代次数的条件下, 各算法对于每个函数的测试均运行 20 次, 算法寻优结果的比较如表 1 所示. 为了直观地观察 6 种算法的优化过程, 图 3~图 5 给出了维数为 30 时各算法对应的寻优曲线.

由表 1 可知, 对于 3 个复杂多模的函数, CPSO 和 APSO 的优化性能比 SPSO 和 PSO-TVAC 优越. 从寻优曲线可以看出, SPSO 和 PSO-TVAC 在进化前期具




图 3 函数 f_1 的进化曲线





图 4 函数 f_2 的进化曲线

表1 6种算法的优化结果比较

函数	维数	算法	平均值	标准差
f_1	30	SPSO	2.818e+1	5.281e+1
		PSO-TVAC	2.037e+1	1.469e+2
		FIPS	5.011e+1	7.382
		APSO	9.949e-1	5.854e-1
		CPSO	1.195e+1	9.586
		ALPSO	3.162e-6	8.631e-7
	50	SPSO	5.362e+1	1.281e+1
		PSO-TVAC	5.196e+1	1.194e+1
		FIPS	2.104e+2	1.754e+1
		APSO	1.213e+1	1.142e+1
f_2	30	SPSO	1.634e+1	9.562
		PSO-TVAC	1.591e+1	2.672e+1
		FIPS	4.391e+1	1.239e+1
		APSO	1.058	5.226e-1
		CPSO	1.100e+1	4.211
		ALPSO	2.343e-11	5.214e-11
	50	SPSO	9.251e+1	2.639e+1
		PSO-TVAC	6.694e+1	2.142e+1
		FIPS	2.248e+2	1.317e+1
		APSO	1.566e+1	7.341
f_3	30	SPSO	3.549	2.501
		PSO-TVAC	1.332	1.194
		FIPS	2.302e+1	5.502
		APSO	1.642	1.329e-1
		CPSO	3.408e-1	8.528e-2
		ALPSO	9.314e-2	3.951e-2
	50	SPSO	1.509e+1	1.311e+1
		PSO-TVAC	6.518	4.613
		FIPS	4.143e+1	9.493
		APSO	9.857	1.568
CPSO	4.037	8.229e-1		
ALPSO	1.750	7.996e-1		

图5 函数 f_3 的进化曲线

有较好的寻优速度和精度,但很快便陷入早期收敛;FIPS算法的优化结果很不理想,不能找到最优值,且偏差较大,虽然没有陷入早期收敛,仍有寻优能力,但寻优速度过慢无法在给定的代数内找到理想的值;ALPSO算法与其他算法相比,取得了最佳的优化结果,由进化曲线可以看出,ALPSO算法在进化前期寻优速度缓慢,主要用于对解空间进行全局探索,在进化后期通过对最优解的开掘利用提高了寻优速度和寻优精度.实验结果体现了ALPSO算法的设计意图,并验证了ALPSO算法的有效性.当问题维数增至

50时,ALPSO算法仍具有良好的收敛精度和较小的标准差,体现了该算法具有较强的稳定性.

SPSO和PSO-TVAC在解决复杂多模问题时,均易陷入局部极值点,即使PSO-TVAC采用了时变的加速系数策略,也只是加强了进化前期粒子对解空间的全局探索和进化后期对已获得的最优解的利用,并没有使粒子避免陷入早期收敛.这主要是因为PSO-TVAC采用了SPSO的信息加工模式,正如在前文所分析,该加工模式不利于保持群体的多样性.FIPS采用局部的拓扑结构,而没有陷入早期收敛,但动态的学习榜样致使收敛速度过于缓慢.CPSO和APSO表现良好,主要由于其分别引入混沌优化和种群状态监控机制来使算法延缓或避免早期收敛.ALPSO算法具有优良的寻优能力,因为该算法调整了学习因子和继承因子的概率特性,使其有利于保持群体的多样性,且时变的学习因子既增强了算法的全局搜索性能又保证了局部搜索能力.

5 结论

本文针对PSO易陷入早期收敛的问题,对PSO中运动方程作了概率特性分析.从信息加工和概率统计特征的角度,指出了运动方程中学习参数的概率分布及参数间的相依性与群体多样性丧失之间的关系,为PSO的运动机理和早期收敛问题的研究提供了新的分析工具.文中还提出了自适应学习的PSO算法,并给出了该算法的收敛条件.自适应学习的PSO算法保持了标准PSO算法操作简捷的特性,通过学习参数概率特性的调整和时变的学习因子策略来增强粒子的全局搜索能力.实验结果验证了自适应学习的PSO算法的有效性.

参考文献(References)

- [1] Valle Y D, Venayagamoorthy G K, Mohagheghi S, et al. Particle swarm optimization: Basic concepts, variants and applications in power systems[J]. IEEE Trans on Evolutionary Computation, 2008, 12(2): 171-195.
- [2] Niu Q, Jiao B, Gu X S. Particle swarm optimization combined with genetic operators for job shop scheduling problem with fuzzy processing time[J]. Applied Mathematics and Computation, 2008, 205(1): 148-158.
- [3] Zhao X C. A perturbed particle swarm algorithm for numerical optimization[J]. Applied Soft Computing, 2010, 10(1): 119-124.
- [4] Coelho L D S, Lee C S. Solving economic load dispatch problems in power systems using chaotic and Gaussian particle swarm optimization approaches[J]. Electrical Power and Energy Systems, 2008, 30(5): 297-307.

(下转第825页)