

一种改进的自适应进化粒子群优化算法

范会联, 陶维安

(长江师范学院 数学与计算机学院, 重庆 408100)

摘 要: 针对粒子群优化算法容易陷入局部极值点以及进化后期收敛慢和优化精度较差等缺点, 提出一种改进的自适应进化算法. 该算法引入信息扩散函数, 根据不同粒子的位置及对应适应值与当前群体最佳位置和最佳适应值的关系, 控制粒子变尺度向群体当前最佳位置移动; 基于多样性反馈机制动态调节惯性权值和控制粒子群的微变异. 通过复杂基准函数的仿真优化结果表明, 改进算法具有抑制早熟、收敛速度快、求解精度高的特点.

关键词: 粒子群优化; 信息扩散; 多样性反馈; 变异; 早熟收敛

中图分类号: TP18

文献标识码: A

文章编号: 1000-7180(2011)05-0011-04

Improved Adaptive Evolutionary Particle Swarm Optimization Algorithm

FAN Hui-lian, TAO Wei-an

(School of Mathematics and Computer Science, Yangtze Normal University, Chongqing 408100, China)

Abstract: In allusion to particle swarm optimization algorithm (PSO) many defects such as being easy to trap into local optima, slow convergence in the end of evolution stage and low computational precision, proposes an improved adaptive evolutionary PSO algorithm. A pheromone diffusion function, which can control the degree of convergence of particles move to the best position, is designed by both taking into account these particles distribution and their fitness value. Adjusting inertial weight adaptively with diversity feedback control is built into the improved PSO, and makes use of mutation to greatly contribute to breaking away from local optima. Experiments on optimization of high-dimension benchmark functions show that the improved algorithm can find better optima with converges faster, and prevent more effectively the premature convergence.

Key words: Particle Swarm Optimization; pheromone diffusion; diversity feedback; mutation; premature convergence

1 引言

基本粒子群算法(PSO)假设在一个 D 维的目标搜索空间中, 有 N 个粒子组成一个群落, 其中第 i 个粒子的位置表示为一个 D 维的向量 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{id})$; 第 i 个粒子的历史最优位置为 $pBest_i = (p_{i1}, p_{i2}, \dots, p_{id})$; 整个粒子群迄今为止搜索到的最好位置记为 $gBest = (p_{g1}, p_{g2}, \dots, p_{gd})$; 第 i 个粒子的“飞翔”速度也是一个 D 维向量 $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{id})$, 决定粒子在搜索空间单位迭代次数的位移, 粒

子将按式(1)和式(2)来调整自己的位置^[1]:

$$\mathbf{V}_i(t+1) = w \cdot \mathbf{V}_i(t) + c_1 \cdot r_1 \cdot (pBest_i(t) - \mathbf{X}_i(t)) + c_2 \cdot r_2 \cdot (pBest(t) - \mathbf{X}_i(t)) \quad (1)$$

$$\mathbf{X}_i(t+1) = \mathbf{X}_i(t) + \mathbf{V}_i(t+1) \quad (2)$$

式中, w 是惯性权值, 取值通常在 $0.4 \sim 0.95$, $\mathbf{X}_i(t)$ 和 $\mathbf{V}_i(t)$ 分别表示第 i 个粒子在 t 时刻的位置和速度, c_1 和 c_2 为加速因子, r_1 和 r_2 是在 $[0, 1]$ 范围内的两个随机数, $pBest_i(t)$ 是第 i 个粒子到 t 时刻为止所找到的最佳适应值对应的位置, $gBest(t)$ 是粒子群到 t 时刻为止所找到的最佳适应值对应的位置.

收稿日期: 2010-07-13; 修回日期: 2010-10-12

基金项目: 重庆市教委科学技术研究项目(KJ091309)

式(1)中的第1部分为粒子的当前飞行速度,表示粒子当前自身运动状态对下一时刻的影响;第2部分称为个体认知部分,鼓励粒子飞向自身曾经发现的最佳位置;第3部分称为群体认知部分,表示粒子间的信息共享和相互合作,引导粒子飞向目前群体发现的最佳位置.这3个部分之间的相互平衡和制约体现了粒子之间的合作与竞争关系,从而决定算法的主要性能^[2].

2 PSO 算法的不足及改进

基本 PSO 算法存在诸如早熟收敛、维数灾难、易于陷入局部极值等问题.针对这些问题,产生了很多有效的改进方法,主要分为3类:第1类是通过调整 PSO 的参数来平衡算法的全局和局部搜索能力,如 PSO_w^[3]等算法;第2类是致力于设计不同类型的拓扑来提高算法性能,如 PSO_cf_local^[4]等算法;第3类是将 PSO 和其他搜索技术相结合,形成混合 PSO 提高算法性能,如文献[5]提出的基于单纯形法的量子粒子群优化算法等.文中根据生物群体中信息扩散的特点并引入多样性反馈机制,提出一种改进的自适应粒子群优化算法(Improved Adaptive Evolutionary PSO, IAEPSO),可较好地解决多峰、高维函数的全局优化问题.

2.1 早熟收敛以及维数灾难的原因分析

标准 PSO 算法在复杂多峰高维函数的全局优化时存在早熟收敛和维数灾难问题,分析其原因,认为主要受以下三个因素的影响:

首先,从式(1)的第1部份中可以看出,粒子在整个迭代过程中,惯性权值 w 保持不变,因而在设置 w 的初始值时存在两难的局面,如果太小,则粒子下一时刻的速度受当前群体最优值的影响就大,容易陷入局部最优解;如果太大,则在迭代后期粒子接近最优值时,因为受粒子自身运动状态的影响大而飞过最优值,造成精度不高的缺陷.尽管有算法提出惯性权值线性递减^[6]或者非线性调节惯性权值^[7]的办法解决这些问题,但是,仅仅依靠惯性权值的调节,很难平衡对多峰高维函数的全局搜索与局部搜索能力之间的矛盾.

其次,从式(1)的第3部份可以看出,在标准 PSO 迭代中,所有粒子从群体最佳位置 $gBest$ 获得一样的“群体认知”能力,即不论距离 $gBest$ 位置远近,每个粒子均从 $gBest$ 学习到相同的信息,因而,所有粒子快速地受其吸引,造成群体多样性迅速降低.事实上,对于在拥有大量局部极值的多峰高维函

数的搜索环境中, $gBest$ 很可能仅仅是一个局部最优解.

最后,由于式(1)对群体当前最佳位置 $gBest$ 不会产生任何影响,粒子在搜索过程中, $gBest$ 只受上一代的最优值和当代群体找到的最优值的影响.这种情况下,在拥有大量局部极值的复杂环境中, $gBest$ 作为当前重要的记忆单元,一旦陷入局部极值,由于没有提供逃离机制,则很难摆脱^[8].

2.2 信息扩散函数

自然界生命系统的实际活动过程中,个体间的信息扩散和传递范围受信息强度和距离远近的影响,受此启发,式(1)中群体当前最佳位置 $gBest$ 对每个粒子的引导程度(即传递给每个粒子的信息多少)受以下两个因素的影响:粒子当前位置与 $gBest$ 的距离远近和 $gBest$ 位置对应的适应值较粒子当前位置适应值的改善程度.离当前最佳位置 $gBest$ 越近、 $gBest$ 对应的适应值与粒子当前位置适应值相比越好,则粒子能够根据 $gBest$ 的引导迅速地改变自身飞行方向和速度扑向它,相反,粒子则比较缓慢地向其移动,甚至脱离 $gBest$ 的控制.

这样的改进能带来两个方面的好处:首先,远离当前群体最佳位置 $gBest$ 的粒子不会迅速收敛到这个位置,从而增强了全局搜索能力,降低陷入局部最优风险;其次,靠近 $gBest$ 的粒子因为适应值的改善程度不高,因而也不致于快速收敛,从而增强了局部搜索能力,尽可能的提高解的精度.

所以,我们为式(1)的第3部份引入信息扩展函数 H ,定义如下:

$$H_i = k \times \left(1 - \frac{d_i + \delta}{\max_{1 \leq j \leq m} d_j + \delta}\right) \quad (3)$$

其中, k 的值由式(4)决定:

$$k = \begin{cases} \frac{s_i + \delta}{\max_{1 \leq j \leq m} s_j + \delta} & \text{如果 } \frac{s_i + \delta}{\max_{1 \leq j \leq m} s_j + \delta} > 0.6 \\ 0.6 & \text{else} \end{cases} \quad (4)$$

H_i 表示当前群体最佳位置 $gBest$ 对第 i 个粒子的引导程度,该信息扩散函数由2部分组成:

第1部份是通过式(3)中 k 值(即式(4)),将粒子向群体当前最佳位置 $gBest$ 的移动尺度跟 $gBest$ 对应的适应值较粒子当前适应值的改善程度联系起来.式(4)中, s_i 是第 i 个粒子当前位置对应的适应值与 $gBest$ 对应的适应值的差, m 是粒子群中包含的粒子数量, s_j 是当前群体中每个粒子与 $gBest$ 对应的适应值的差的最大值.经反复测试, k 的取值最小不低于 0.6 为好.

式(3)中的第2部份将粒子的移动尺度与该粒子与 $gBest$ 的距离远近联系起来. d_i 表示第 i 个粒子与 $gBest$ 的欧氏距离, d_j 是当前群体中所有粒子与 $gBest$ 的欧氏距离的最大值.

式(3)、(4)中加一个小的正数 δ 是为了避免分子、分母为0(测试中我们取的是0.0001),同时又不会导致对分式的结果产生较大影响.

2.3 多样性反馈机制

PSO算法易陷入局部极值的根本原因是种群多样性的快速降低以及一旦陷入局部极值后没有逃离机制.因此,文中引入多样性反馈机制,一是通过动态自适应调节惯性权值抑制群体多样性的过早降低,二是如果多样性降低到规定阈值时,引入类似遗传算法的变异机制以增大群体多样性.

群体多样性用采用文献[9]提出的式(5)进行测量:

$$\text{diversity}(t) = \frac{1}{m \times |L|} \times \sum_{i=1}^m \sqrt{\sum_{d=1}^D (x_{id} - \bar{x}_d)^2} \quad (5)$$

式中, m 表示粒子群规模; x_{id} 表示第 i 个粒子 t 时刻的第 d 维分量; $\bar{x}_d$ 是 t 时刻所有粒子第 d 维分量的平均值; D 是问题的维数, $|L|$ 为搜索域的最长对角线长度.

惯性权值按式(6)进行动态调节:

$$\omega(t) = \omega_{\text{final}} + e^{-\text{diversity}(t)} \left(1 - \frac{\text{Iter}}{\text{Iter}_{\text{max}}}\right) (\omega_{\text{initial}} - \omega_{\text{final}}) \quad (6)$$

式中, Iter_{max} 和 Iter 分别表示最大迭代次数和当前迭代次数, ω_{initial} 表示初始权值, ω_{final} 表示最终权值,测试中我们取 $\omega_{\text{initial}} = 0.95$, $\omega_{\text{final}} = 0.4$.

式(6)将惯性权值跟群体多样性和迭代次数联系起来,可以看出,在迭代初期,由于种群具有较大多样性,因此,由于迭代次数和多样性的共同作用,惯性权值会维持在一个较高的值,有利于保持粒子的全局搜索能力.随着迭代次数的增加,同时多样性也逐渐降低,在其共同影响下,所以惯性权值不至于下降太快,使种群在获得局部开发能力的同时,全局搜索能力不会迅速降低,从而降低早熟收敛的风险.

算法针对式(1)的第2和第3两部份,引入变异系数 R ,定义如下:

$$R = \begin{cases} -1 & \text{diversity}(t) < 0.2 \ \& \ P_i \leq 0.1 \\ 1 & \text{else} \end{cases} \quad (7)$$

算法实时监测多样性变化情况,当多样性降低到阈值时(我们取的0.2),算法按随机概率使部份

粒子产生变异(测试中我们让不超过种群数量10%的粒子变异).

3 自适应进化的粒子群优化算法

文中提出的基于信息扩散和多样性反馈机制的PSO算法综合考虑了当前最佳位置 $gBest$ 、惯性权值 ω 、当前进化代数 Iter 以及群体多样性等多个因素对粒子搜索的影响.文中改进的粒子速度更新方法如式(8)所示,位置更新方法按式(2)不变.

$$V_i(t+1) = \omega(t) \cdot V_i(t) + R \cdot [c_1 \cdot r_1 \cdot (pBest_i(t) - X_i(t)) + H_i \cdot c_2 \cdot r_2 \cdot (gBest(t) - X_i(t))] \quad (8)$$

式中, $\omega(t)$ 由式(6)决定, H_i 由式(3)决定, R 的值由式(7)决定,其意义是:当多样性降低的阈值时,粒子按一定概率向远离当前最优解的方向移动,从而增大多样性,进一步降低早熟收敛的风险.

实现该算法的计算流程如下^[10]:

- (1) 随机初始化粒子群中粒子的位置与速度;
- (2) 计算每个粒子的适应值,设置每个粒子的初始当前最优解 $pBest_i$ 和群体当前最优解 $gBest$;
- (3) 根据式(5)计算种群的多样性;
- (4) 根据式(8)、(2)更新粒子的速度与位置;
- (5) 进行速度、位置限制.当 $V_i > V_{\text{max}}$ 或 $V_i < V_{\text{min}}$ 时,令 $V_i = V_{\text{max}}$ 或 $V_i = V_{\text{min}}$;当 $X_i > X_{\text{max}}$ 或 $X_i < X_{\text{min}}$ 时,则令 $X_i = X_{\text{max}}$ 或 $X_i = X_{\text{min}}$;
- (6) 计算每个粒子在新位置上的适应值;
- (7) 如果粒子的适应值优于 $pBest$ 的适应值,则 $pBest$ 更新为新位置,反之 $pBest$ 保持不变;如果粒子的适应值优于 $gBest$ 的适应值,则 $gBest$ 更新为新位置,反之 $gBest$ 保持不变.
- (8) 判断算法收敛准则是否满足,如果不满足则转(3);
- (9) 输出全局最优粒子 $gBest$ 的位置和对应的最优适应值,结束.

4 实验与分析

为了评价文中算法对函数优化时的收敛速度、群体多样性及全局优化能力等求解性能,选取2个广泛采用的复杂非线性函数作为基准函数在高维情况进行算法测试:

Rosenbrock 函数:

$$f_1 = \sum_{i=1}^D [100 \times (x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$$

Rastrigin 函数:

$$f_2 = \sum_{i=1}^D [x_i^2 - 10\cos(2\pi x_i) + 10]$$

这 2 个函数具有不同的特点, 函数 f_1 (Rosenbrock) 是一个经典的复杂优化问题, 取值区间内走势平坦, 要收敛到全局最优机会微乎其微, 用于测试算法收敛速度. 函数 f_2 是复杂的非线性多峰函数, 存在大量局部极值, 可有效检验算法的群体多样性、全局搜索性能、逃离局部极值并避免早熟收敛能力.

为了更好地比较文中算法 (IAEPSO) 与其他 PSO 算法的全局优化能力, 文中与基本粒子群算法、文献[11]提出的改进 QPSO 算法 (IQPSO) 进行比较, 在实验中, 把函数值设置为适应度值, 种群大小分别设置为 30, 变量维数恒定 30, 迭代次数 2 000, 函数 f_1 的搜索空间为 $[-10, 10]$, 函数 f_2 的搜索空间是 $[-100, 100]$, $w=0.95\sim 0.4$, 加速因子 $c_1=c_2=2$, IQPSO 算法的参数设置与文献[11]一致.

图 1、图 2 分别描绘了文中算法 (IAEPSO) 与基本粒子群算法 (SPSO)、文献[11]的改进 QPSO 算法 (IQPSO) 分别对 Rosenbrock 函数和 Rastrigin 函数在 2000 次迭代寻优过程中的适应值变化过程.




图 1 Rosenbrock 函数寻优过程中适应值变化比较

由于在文中算法的速度更新公式中, 信息扩散函数根据粒子的分布和对应适应值的情况控制着所有粒子向当前最佳位置 gBest 移动的速度分量, 加上算法中采用了基于多样性反馈的变异机制, 因此, 我们从图 1、图 2 可看出, 文中算法与基本 PSO 算法和改进 QPSO 算法相比, 具有收敛速度快、跳出局部极值能力强特点, 并且具有更高的求解精度.

5 结束语

文中基于生物群体中信息扩散的特点, 提出根据不同粒子的位置及对应函数值与当前群体最佳位




图 2 Rastrigin 函数寻优过程中适应值变化比较

置和适应值的关系来改善 PSO 算法收敛性的思想, 同时引入群体多样性反馈机制动态调整惯性权重和适时进行粒子变异以平衡算法的全局搜索和局部搜索能力, 最后通过对 2 个典型的复杂非线性测试函数在 30 维情况下的仿真结果表明, 该算法具有较强的寻优能力. 进一步的工作方向主要有: 扩大算法的测试范围, 探索控制粒子变异的新机制以及进一步改进算法性能, 并将其应用到大规模的组合优化问题中.

参考文献:

- [1] 韦杏琼, 周永权. 基于粒子群算法的数值积分方法研究[J]. 微电子学与计算机, 2009, 26(7): 117-119.
- [2] 赫然, 王永吉, 王青, 等. 一种改进的自适应逃逸微粒群算法及实验分析[J]. 软件学报, 2005, 16(12): 2036-2043.
- [3] Shi Y, Eberhart R. A modified particle swarm optimizer [C]//Proceedings of IEEE Conference on the CEC'98, Alaska: IEEE Press, 1998: 69-73.
- [4] Kennedy J, Mendes R. Population structure and particle swarm performance [C]//Proceedings of IEEE Conference on the CEC 2002. Honolulu: IEEE Press, 2002: 1671-1676.
- [5] 任小康, 郝瑞芝, 孙正兴, 等. 基于单纯形法的量子粒子群优化算法[J]. 微电子学与计算机, 2010, 27(1): 154-156.
- [6] Shi Y, Eberhart R. A modified particle swarm optimizer [C]//Proceedings of the IEEE Conference on Evolutionary Computation. Singapore: IEEE Press, 1998: 69-73.
- [7] Chatterjee A, Siarry P. Nonlinear inertia weight variation for dynamic adaptation in particle swarm optimization [J]. Computers & Operations Research (S0305-0548), 2006, 33(3): 859-871.

(下转第 17 页)

实验结果进行评价,即首先由领域专家主观判断某概念在本体中最相似的前 N 个概念,然后由算法计算出与该概念最相似的 N 个概念,看是否与领域专家的评判一致,计算准确率。




图1 “数学学科”本体结构图

实验结果显示, $P@1$ 平均准确率达 61.5%, $P@3$ 平均准确率达 76.9%, $P@5$ 平均准确率达 86.2%。从而该算法是有效的。

5 结束语

文中给出了基于超图正则化模型的本体概念相对相似度计算算法。本算的优点在于:(1)由于算法将每个顶点映射成了实数,因此不需要类似传统算法的成对计算相似度,降低了计算量;(2)算法充分利用了本体自身的结构,将图映射为实直线,更加直观地表现了各概念间的近似程度;(3)与传统本体相似度计算方法相比,本算法需要领域专家确定的参数大大减少。

参考文献:

- [1] Zhou D, Huang J, Schölkopf B. Beyond pairwise classification and clustering using hypergraphs[P]. Canada: University of Waterloo, 2005.
- [2] Zhou Dengyong, Huang Jiayuan, Bernhard Schölkopf. Learning with Hypergraphs: Clustering, Classification, and Embedding[C]// Proceedings of 20th Annual Conference on Neural Information Processing Systems, 2006, Vancouver / Whistler, Canada; IEEE, 2006:1601—1608.
- [3] Liang Sun, Shuiwang Ji, Jieping Ye. Hypergraph spectral learning for multi-label classification[C]// Proceeding of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining. Las Vegas, Nevada, USA; ACM, 2008:668—676.
- [4] Chen Gang, Zhang Jianwen, Wang Fei, et al. Efficient multi-label classification with hypergraph regularization[C]// 2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami, FL, USA; IEEE, 2009 (9):1658—1665.
- [5] Sameer Agarwal, Kristin Branson, Serge Belongie. Higher order learning with graphs[C]// Proceedings of the 23rd International conference on Machine Learning, Pittsburgh, PA; ICML, 2006: 17—24.
- [6] Zhou Dengyong, Huang Jiayuan, Bernhard Schölkopf. Learning from Labeled and Unlabeled Data on a Directed Graph[C]// Proceedings of the 22nd International Conference on Machine Learning, Bonn, Germany; ICML, 2005:1041—1048.
- [7] Isaac Pesenson. Variational Splines and Paley-wiener Spaces on Combinatorial Graphs[J]. Constr Approx, 2009(29):1—21.
- [8] Craswell N, Hawking D. Overview of the TREC 2003 web track[C]// Text Retrieval Conference (TREC). 2003 Proceedings. [s. l.]:TREC, 2003.
- [9] Riget J, Vesterstroem J S. A Diversity-Guided Particle Swarm Optimizer—the ARPSO[EB/OL]. (2009)[2010-07-13]. <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.19.2929>.
- [10] 焦巍, 刘光斌. 基于多样性反馈的粒子群优化算法[J]. 计算机工程, 2009, 35(22):202—204.
- [11] 徐文龙, 孙俊, 须文波. 基于干扰因子的 QPSO 算法改进[J]. 微电子学与计算机, 2008, 25(4):128—130.

作者简介:

高伟 男, (1981—), 博士, 讲师. 研究方向为统计学习理论及图论。

梁立 男, (1965—), 硕士, 教授. 研究方向为智能决策支持系统、信息检索。

作者简介:

范会联 男, (1971—), 硕士, 副教授, CCF 会员 (E20-0013523M). 研究方向为软件工程、智能信息处理。

陶维安 男, (1958—), 副教授. 研究方向为智能信息处理。

(上接第 14 页)