

基于微分演化的 PSO 参数选择策略

窦全胜¹ 周春光² 张忠波³ 刘小华²

(山东工商学院电子与信息学院 烟台 264005)¹ (吉林大学计算机科学与技术学院 长春 130012)²
(吉林大学数学学院 长春 130012)³

摘要 粒子群优化方法(Particle Swarm Optimization, PSO)是由 Kennedy 和 Eberhart 于 1995 年提出的一种基于群体智能(Swarm Intelligence)的演化计算技术,用于求解各类优化问题。PSO 方法通过各种参数控制粒子的运行轨迹,并对参数设置有很强的敏感性。因此,如何为 PSO 方法选择最优的参数是 PSO 方法的关键。本文提出了一种不依赖个人经验的参数选则策略,针对特定问题,将 PSO 方法的性能表示成参数的函数,从而将参数选择问题转变成函数优化问题。采用微分演化(Differential Evolution, DE)方法对该函数进行优化,来确定 PSO 的最佳参数,收到了较好的效果。

关键词 粒子群方法,微分演化

The Strategy of Parameters-selection for PSO Based on Differential Evolutions

DOU Quan-Sheng^{1, 2} ZHOU Chun-Guang² ZHANG Zhong-Bo^{2, 3} LIU Xiao-Hua²

(School of Information and Electronics Engineering, Shandong Institute of Business and Technology, Yantai 264005)¹

(College of Computer Science and Technology, Jilin University, Changchun 130012)² (Mathematics School, Jilin University, Changchun 130012)³

Abstract The Particle Swarm Optimization (PSO) method was originally designed by Kennedy and Eberhart in 1995 and has been applied successfully in various optimization problems. The PSO idea is inspired by natural concepts such as fish schooling, bird flocking and human social relations. The track of each particle is controlled by some parameters and highly sensitive to different parameters setting. So how to choice the optimum parameters is key for PSO. The strategy of parameter-selection is proposed, which dose not depend on expert experience, the performance of PSO is be regarded as a function decided by parameters of PSO in this strategy, So, the problem of parameters-selection is be transform to optimization problem, at the same time, differential evolution (DE) is be used for solving this optimization problem.

Keywords Particle swarm optimization, Differential evolution

1 引言

粒子群优化方法是由 Kennedy 和 Eberhart 于 1995 年提出的一种基于群体智能(Swarm Intelligence)的进化计算技术^[1,2],其基本思想源于对鸟群捕食等群体行为的研究。PSO 方法简单、赋有效率并且容易实现,当前有很多该方法的研究^[3~13]。在 PSO 方法中,每个问题的潜在解定义为搜索空间中的一个“粒子”。每个粒子可以用三元组 (x_i, v_i, p_i) 表示,其中, x_i 表示粒子的当前位置, v_i 表示粒子的当前速度, p_i 表示粒子本身搜索过的最好的位置(个体经验)。粒子根据下式进行自身的修正:

$$\begin{aligned} v_i &= v_i + c_1 \varphi_1 (p_i - x_i) + c_2 \varphi_2 (p_g - x_i) \\ x_i &= x_i + v_i \end{aligned} \quad (1)$$

在(1)式中, p_g 表示的是群体中所有粒子经过的最好位置(群体经验); c_1 、 c_2 为正常数, r_1 、 r_2 为 $[0, 1]$ 区间的随机数; ω 为惯性参数。

PSO 方法通常用来解决无约束优化问题。其中,惯性参数及感知系数 c_1 、 c_2 决定了 PSO 方法的性能,同时, PSO 方法对参数有很强的敏感性,因此如何确定合适的参数是 PSO 方法的关键。有一些理论研究用以指导 PSO 方法的参数设置,但是,这些研究多基于一种理想状态,与实际计算存在一定的

差异; PSO 的所有理论分析都是基于式(1),而在实际计算中,粒子往往在一定的空间(如 N 维空间内的超立方体)内进行搜索,若粒子在某一维上,超出了搜索范围,则把粒子在该维度上的值设置成搜索区间的上界或下界。这种情况在 PSO 的执行过程中经常会发生,而且是随机的,无法进行判断和估计。这就造成了在实际计算中粒子运行轨迹与理论分析中结论的差异。因此,用这些理论来指导参数设置是不完全可靠的。通过大量的实际计算和实验,为 PSO 方法的参数设置积累了一定经验,这些经验是非常有意义的。但是,由于问题的复杂性,对于一个复杂的新问题,这些经验是否有效依然是一个值得研究的问题。调整参数直至运行结果满意固然是一种方法,但这种作法效率非常低,并且需要凭借应用者的直觉和经验。这给 PSO 方法的应用带来难度。

由以上阐述可知,如何选择合适的参数是 PSO 难点。本文从另一个角度讨论了如何为 PSO 选择合适的参数。对于某类实际问题,用一个实数 p 来反映 PSO 方法的性能,显然, p 由参数 ω 、 c_1 、 c_2 所确定,即:

$$p = f - p_{so}(\omega, c_1, c_2) \quad (2)$$

寻找最优的参数设置,即是求解函数 $p = f - p_{so}(\omega, c_1, c_2)$ 的最优解,从而将参数选择问题转化成函数优化问题。同时,采用微分演化方法(Differential Evolution, DE)对 $p = f -$

$pso(\omega, c_1, c_2)$ 进行优化,取得了较理想的效果。

2 微分演化方法(DE)

微分演化(Differential Evolution, DE)方法由 Storn 和 Price 在 1995 年提出^[14],它与 PSO 方法几乎产生于同一时间。这种方法不仅简单,参数敏感性弱,而且在对各种测试问题的实验中表现优异。首先,在搜索空间内,随机产生初始群体。通过将群体中两个成员间的差向量增加到第三个成员的方法来生成新的个体。如果新个体的适应度值更好,那么新产生的个体将代替原个体。有三种运算贯穿着整个算法的执行过程:

(1)变异(Mutation):

对每个目标向量 $\bar{X}_i(t)$,根据公式

$$\bar{V}_i(t+1) = \bar{X}_{r_3}(t) + F(\bar{X}_{r_1}(t) - \bar{X}_{r_2}(t))$$

生成变异向量。其中, $\bar{X}_{r_1}(t)$, $\bar{X}_{r_2}(t)$, $\bar{X}_{r_3}(t)$ 为群体中随机选择的三个个体, i 和 r_1, r_2, r_3 之间必须是不同的, F 称为缩放因子(Scaling Factor),介于 $[0, 2]$ 之间,用于控制差向量 $(\bar{X}_{r_1}(t) - \bar{X}_{r_2}(t))$ 的影响大小。父个体 $\bar{X}_{r_1}(t)$, $\bar{X}_{r_2}(t)$ 之间的差向量越小,扰动也就越小,这意味着如果群体靠近优化值,步长会自动减小。图(1)描述了个体的修正策略。

(2)交叉(Crossover):

目标向量与变异向量相结合,生成新的向量:

$$u_i(t+1) = (u_{i1}(t+1), u_{i2}(t+1), \dots, u_{iD}(t+1))$$

其中, D 为问题空间的维度,

$$u_{ij}(t+1) = \begin{cases} u_{ij}(t+1) & \text{if } \text{random}(0,1) < CR \text{ or } j = j_{\text{rand}} \\ x_{ij}(t) & \text{if } \text{random}(0,1) > CR \text{ and } j \neq j_{\text{rand}} \end{cases}$$

$i=1, \dots, \text{population-size}, j=1, \dots, D$




图1 新向量的生成




图2 DE 信息交换示意图

这里, CR 是交叉常数,在 $[0, 1]$ 间, CR 值越大,发生交叉的可能就越大。 $CR=0$ 表示没有交叉。 j_{rand} 是 $[1, D]$ 随机选择的整数,它保证 $u_i(t+1)$ 至少要从 $u_i(t+1)$ 中获得一个元素,否则就不会有新的向量生成,群体也不会变化。

(3)选择(Selection):

在标准 DE 方法中,使用的是一种“贪婪”选择模式:当且仅当新个体的评价函数值更好时,才被保留到下一代群体中,否则,父个体仍然保留在群体中,再一次作为下一代的父向量。

关于 DE 方法的详细阐述参见文^[14~18]。

3 实验步骤描述

设需要求解的实际问题,由下式表示:

$$\min_{x \in S} f(x)$$

其中 S 是解域, f 是被优化函数。实验过程如下:

step1 在合适的区间内,随机产生由参数向量构成的群体 $POP = \{P_1, P_2, \dots, P_k\}$, 其中, $P_i = (\omega_i, c_{1i}, c_{2i})$, $i=1, 2, \dots, k$; 对于每个 P_i , 用下式来评价 PSO 方法的执行性能:

$$P_i = fbs - pso(P_i) = \frac{1}{N} \sum_{m=1}^N \text{optimum}(P_i, f(x)) \quad (3)$$

其中, $\text{optimum}(P_i, f(x))$ 表示当参数设置为 P_i 时,用 PSO 方法求得的 $f(x)$ 的最优解;

step2 对 $\forall P_i \in POP$, 按 DE 方法的修正策略对其进行修正,生成一个新的向量 P'_i , 使群体中个体的数量增加一倍;

step3 按式(3)对 POP 中的所有参数向量进行评价,按某种策略选择出 k 个优秀个体重新组成下一代群体;

step4 重复执行步骤 step2、step3 直至满足终止条件。

4 计算实例

采用简单的 Benchmark 问题 $f_1(x) = \sum_{i=1}^n x_i^2$ 来说明上述过程,这个函数为单峰函数,只有一个全局最优解。

首先,要确定搜索的范围,考察当 (ω, c_1, c_2) 中的权值分量为固定值时,感知系数 c_1, c_2 对 PSO 方法的影响,图 3~4 分别是函数 $p = \frac{1}{10} \sum_{m=1}^{10} \text{optimum}(1, c_1, c_2), f_1)$ 和 $p = \frac{1}{10} \sum_{m=1}^{10} \text{optimum}((0.7, c_1, c_2), f_1)$ 的曲面。事实上,这两个曲面的全局最优值就是当 $w=1$ 和 0.7 时,PSO 方法的最优参数,这里的目的只是初步确定感知系数 c_1, c_2 的范围,因此,这对两个曲面的精度要求并不高,若要得到高精度的参数曲面,计算量相当庞大。从这两个曲面上分析,确定 c_1, c_2 的值在区间 $[1, 2.5]$ 上。

用同样的方法,固定 $c_1, c_2 = 1.4$, 考察 w 对 PSO 的影响,下图 5 为函数 $P = \frac{1}{10} \sum_{m=1}^{10} \text{optimum}(w, 1.4, 1.4), f_1)$ 的曲线,根据该曲线确定 $w \in [0.6, 1.15]$ 。

由此可知,DE 方法中个体 $P_i = (\omega_i, c_{1i}, c_{2i})$, $i=1, 2, \dots, k$; 的搜索空间为 $S = [0.6, 1.15] \times [1, 2.5] \times [1, 2.5]$, 为 DE 方法设置合理的参数,按照本文第 3 节所述过程进行实验,得到 PSO 方法关于上述问题的最优参数。

结论 上述结果与经验值接近但并不一致,这种差异是正常的。同时,不同优化问题所采用的参数也不应该相同。上述算例只是为了说明问题,并没有很强的实际意义。本文中方法的真正意义在于:当我们遇到一个复杂优化问题,经验的参数设置未必可靠,则可以应用上述的策略,为 PSO 方法选择针对该问题的合理参数。可以看出,本文提出的策略是不依赖个人经验的,并且在求得最优参数的同时,优化问题的最优解也同时被给出。




图3 $w=1$,感知系数 c_1, c_2 与 PSO 性能曲面




图4 $w=0.7$,感知系数 c_1, c_2 与 PSO 性能曲面




图5 感知系数 c_1, c_2 一定, w 与 PSO 性能曲线

参考文献

- Eberhart R C, Kennedy J. A new optimizer using particle swarm theory. In: Proceedings of the sixth International Symposium on Micro Machine and Human Science. Nagoya Japan, 1995. 39~43
- Kennedy J, Eberhart R C. Particle Swarm Optimization. In: Proc. IEEE International Conference on Neural Networks. IEEE Service Center, Piscataway, NJ, IV, 1995. 1942~1948
- Clerc M. TRIBES-Aparameter Free Particle Swarm Optimizer. <http://clerc.maurice.free.fr/PSO/2002-08-10/2003-10-08>
- Salman A. Discrete Particle Swarm Optimization for Heterogeneous Task Assignment Problem. In: Proceedings of World Multi-conference on Systemics, Cybernetics and Informatics (SCI 2001). Orlando, USA, 2001
- Clerc M. Discrete Particle Swarm Optimization: A Fuzzy Combinatorial Black Box. <http://clerc.maurice.free.fr/PSO/Fuzzy-Discrete-PSO/Fuzzy-DPSO.htm>. 2000-04-01/2003-10-08
- Krink T, Vesterstrom J S, Riget J. Particle Swarm Optimization with Spatial Particle Extension. In: Proceeding of the IEEE Congress on Evolutionary Computation, Honolulu, Hawaii, USA, 2002
- Hirota, Yoshida, Kenichi. A particle Swarm Optimization for Reactive Power and Voltage Control Considering Voltage Stability. IEEE International Conference on Intelligent System Applications to Power Systems, Rio de Janeiro, 1999
- Voss M S, Feng Xin. Arma Model Selection Using Particle Swarm Optimization and Aic Criteria. In: 15th Triennial World Congress, Barcelona Spain, 2002
- Parsopoulos K E, Vrahatis M N. Particle Swarm Optimization Method in Multiobjective Problems. In: Proc. 2002 ACM Symp. Applied. Computing (SAC 2002), Madrid, Spain, 2002. 603~607
- Van den Bergh, Engelbrecht A P F. Cooperative Learning in Neural Networks using Particle Swarm Optimizers. South African Computer Journal, 2000, 26: 84~90
- Carlisle A, Dozier G. Tracking Changing Extrema with Adaptive Particle Swarm Optimizer. [Technical Report CSSE01-08]. Auburn University, 2001b
- 龚全胜, 周春光, 马铭, 刘全. 群进化粒子群优化方法. 计算机科学, 2005, 32(8): 134~137
- 龚全胜, 周春光, 马铭. 粒子群优化的两种改进策略. 计算机研究与发展, 2005, 42(5): 897~904
- Storn R, Price K. Differential evolution - a simple and efficient adaptive scheme for global optimization over continuous space: [Technical report]. International Computer Science Institute, Berkley, 1995
- Vesterstrom J, Thomsen R. A Comparative Study of Differential Evolution, Particle Swarm Optimization, and Evolutionary Algorithms on Numerical Benchmark Problems. In: Proceedings of Congress on Evolutionary Computation (CEC2004), Poland, 2004
- Abbass H, Sarker R, Newton C. A Pareto frontier differential evolution approach for multiobjective optimization problems. In: Proceedings of the Congress on Evolutionary Computation, IEEE Service Centre, 2001, 2: 971~978
- Krink T, Filipic B, Fogel G B. Noisy optimization problems - a particular challenge for differential evolution. In: Proceedings of Congress on Evolutionary Computation (CEC2004), Poland, 2004
- Landa R, Becerra D, Carlos A. A Cultural Algorithm with differential Evolution to Solve Constrained Optimization Problems. Springer-Verlag, Lecture Notes in Artificial Intelligence Puebla, México, November 2004, 3315: 881~890
- Olaru C, Wehenkel L. Data mining. Computer Applications in Power, IEEE, 1999, 12(3)
- Zeeman E C. Catastrophe theory, Selected papers (1972~1977). Reading, Massachusetts: Addison-Wesley, 1977
- Goharian N, Grossman D, Raju N. Extending the undergraduate computer science curriculum to include data mining. In: Information Technology: Coding and Computing, 2004. Proceedings. ITCC 2004. International Conference on, Volume: 1, 5-7 April
- 周颖, 杨炳儒. 基于语言场理论的连续属性离散化方法及实现. 计算机学报, 2003, 30(5)
- 杨炳儒. 基于内在机理的知识发现理论及其应用. 北京: 电子工业出版社, 2004
- 周颖. 对规则取舍问题研究. 计算机学报, 2003, 30(5): 126~128
- 杨炳儒, 蔡艳霞. KDD 中因果关联规则的评价方法. 软件学报, 2002, 13(6): 1142~1147
- Yang Bingru, Zhou Ying. The Inner Mechanism of Knowledge Discovery System and its influence to KDD mainstream development. In: ICAI'2002, (USA), 2002. 826~832

(上接第 195 页)

- Yang Bingru. Knowledge Discovery Based on Inner Mechanism: Construction, Realization and Application. Elliott & Fitzpatrick Inc, USA, 2004
- Yang Bingru, Shen Jiangtao, Song Wei. KDK Based Double-Basis Fusion Mechanism and Its Structural Model. International Journal of Artificial Intelligence Tools (IJAIT), 2005, 14(3)
- Yang Bingru, Li Xin, Song Wei. Research on Inner Mechanism and KDTIM Theory of Knowledge Discovery. Engineering Science, 2004, 2(1): 46~51
- Quest D, Ali H. Ontology specific data mining based on dynamic grammars. In: Computational Systems Bioinformatics Conference, 2004. CSB 2004. Proceedings. 2004 IEEE, Aug. 2004. 16~19
- Piatetsky-Shapiro G. The data-mining industry coming of age. Intelligent Systems, IEEE [see also IEEE Expert], 1999, 14(6)
- Ramakrishnan N, Grama A Y. Data mining: from serendipity to science. Computer, 1999, 32(8)