

一种自适应惯性权重的粒子群优化算法

陈占伟, 李 骞

(周口师范学院 计算机科学系, 河南 周口 466001)

摘 要: 为较好平衡粒子群算法中全局搜索能力与局部搜索能力, 分析了 PSO 算法中的惯性权重与种群规模、粒子适应度以及搜索空间维度的关系, 并把粒子惯性权重定义为这三者的函数. 通过在每次迭代后更新每个粒子的惯性权重, 实现了自适应调整全局搜索能力与局部搜索能力, 并结合动态管理种群的策略提出了改进的粒子群算法. 通过在多个常用测试函数上与已有惯性权重调整算法测试比较, 证明新算法具有较强的全局寻优能力与较高的搜索效率.

关键词: 粒子群算法; 自适应惯性权重; 种群规模; 搜索空间维度; 粒子适应度; 动态管理种群

中图分类号: TP18

文献标识码: A

文章编号: 1000-7180(2011)03-0027-04

Adaptive Particle Swarm Optimization Algorithm with Dynamically Changing Inertia Weight

CHEN Zhan-wei, LI Qian

(Department of Computer, Science Zhoukou Teachers College, Zhoukou 466001, China)

Abstract: In order to get a better balance between global search ability and local search capabilities in the particle swarm algorithm, analyzed the relationship between inertia weight and the particle fitness, the population size and dimensions of the searching space, and constructed a function between them. After each iteration, updated the inertia weight of each particle as to achieved a self-adaptive adjustment of global search ability and local search capabilities. A new improved particle swarm optimization is brought up combined with population dynamic management strategy. The searching result of some standard testing functions proved that the new algorithm have a stronger global optimization capability and a higher search efficiency.

Key words: PSO; adaptive inertia weight; population size; the search space dimension; particle fitness; dynamic management of populations

1 引言

粒子群优化 (Particle Swarm Optimization, PSO) 是由 Kennedy 和 Eberhart 等人提出的一类模拟群体智能行为的优化算法. 其思想来源于对鸟群捕食行为的研究, 与遗传算法和蚁群算法相比, PSO 容易实现并且可调整参数较少, 因此被广泛应用.

文献[1-3]指出, 目前 PSO 的研究主要集中在三个方面: 一是算法的改进研究, 二是算法的性能分析, 三是算法的应用研究. 而算法的性能分析主要针

对参数不同取值组合对算法性能的影响. 惯性权值是粒子群算法最重要的可调整参数之一. 文献[4]指出较大的权值有利于提高算法的全局搜索能力, 而较小的权值会增强算法的局部搜索能力. 为了找到一种能在全局搜索和局部搜索之间取得最佳平衡的惯性权值选取方法, 研究人员进行了大量的研究工作, 先后提出了线性递减权值(LDIW)策略、模糊惯性权值(FIW)策略和随机惯性权值(RIW)策略. 而已有的搜索策略都是将粒子群看作一个整体来调整惯性权重, 没有考虑到不同适应度的粒子需要不同的惯性权重, 忽视了问题复杂度和群体规模等重要

因素. 本文分析了 PSO 算法中的惯性权重与种群规模、粒子适应度以及搜索空间维度的关系, 把粒子惯性权重定义为这三者的函数, 并结合动态管理种群的策略提出了改进的粒子群算法. 新算法在每次迭代后根据当算法搜索状态更新每个粒子的惯性权重, 实现了自适应调整全局搜索与局部搜索能力. 通过与 LDIW、FIW、RIW 等调整算法在常用多峰测试函数上的实验结果证明, 新算法具有较强的全局寻优能力与较高的搜索效率.

2 经典粒子群算法

粒子群优化(PSO)算法是一种进化计算技术, 源于对鸟群捕食的行为的模拟. 搜索空间中每个粒子代表一个可能解, 粒子在解空间中移动的过程就是搜寻最优值的过程. 所有的粒子都有一个表示当前在解空间中位置的属性 $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$, 根据粒子当前位置会产生一个粒子适应度以反映粒子位置即解的优劣. 每个粒子还有一个速度向量 $V_i = (v_{i1}, v_{i2}, \dots, v_{in})$ 决定其运动的方向和运动的快慢. 首先粒子群初始化为一群随机粒子(随机解), 然后通过迭代来寻找最优解. 在每一轮的迭代中, 粒子通过速度更新当前位置, 并通过适应值函数计算出其适应度, 然后根据式(1) 更新其当前速度.

$$V_i = \omega V_i + c_1 * \text{rand}() * (Pbest_i - x_i) + c_2 * \text{rand}() * (Gbest - x_i) \quad (1)$$

接着按照式(2) 更新粒子位置 X_i .

$$X_i = X_i + V_i \quad (2)$$

式中, $Pbest_i$ 表示粒子 i 的个体最优值, 即粒子 i 目前为止在搜索空间中到过的最佳点, $Gbest$ 表示整个粒子群的全局最优值, 即整个粒子群到目前为止在搜索空间中到过的最佳点. C_1 和 C_2 是两个正常数, 称为学习因子. $\text{rand}()$ 表示 0 到 1 之间的随机数. ω 称为惯性因子, ω 值较大, 全局寻优能力强, 收敛较慢; 反之局部寻优能力较强, 收敛较快.

3 惯性权重调整策略

惯性权重 ω 是 PSO 算法中调整全局搜索与局部搜索的最重要参数. 文献[4] 指出, 较大的惯性权重有利于全局探索, 但效率较低; 较小的惯性权重能够加速算法的收敛, 但是容易陷入局部最优. 如何设置合理的惯性权重, 是避免陷入局部最优并高效搜索的关键. 在实际问题背景下, 惯性权重如何设置, 要同时分析众多因素和当前搜索状态. 其中, 粒子适应度、种群规模以及搜索空间维度是表征当前搜索状

态的重要参数. 下面分别定性分析这三者与惯性权重的关系.

粒子适应度是反应粒子当前位置优劣的一个参数. 对于某个具有较高适应度的粒子 P_i , 在 P_i 所在局部区域可能存在能够更新全局最优的点 P_x , 即 P_x 所表示的解优于全局最优. 为使全局最优能够迅速更新, 迅速找到 P_x , 应减小粒子 P_i 惯性权重以增强其局部寻优能力; 而对于适应度较低的粒子, 当前位置较差, 所在区域存在优于全局较优解的概率较低, 为了跳出当前的区域, 应当增大惯性权重, 增强全局搜索能力.

种群规模是决定粒子对搜索空间覆盖程度关键因素. 种群规模较大时, 种群多样性较高, 粒子所在区域覆盖全局最优解的概率较大, 则应该减小惯性权重, 提高局部搜索能力, 实现快速收敛于全局较优; 种群规模较小时, 尤其对于多峰函数, 粒子通常不能有效覆盖整个搜索空间, 则应该增大惯性权重, 提高全局搜索能力, 避免陷入局部最优.

由文献[5] 可知, 当搜索空间维度较大并且问题较复杂时, PSO 常常收敛过早, 很容易陷入局部最优. 如何根据不同复杂程度的问题背景, 在搜索效率和寻优能力之间寻求较好平衡极为重要. 对于具有高维度搜索空间的复杂问题, 应该减小惯性权重以提高全局搜索能力, 避免过早收敛陷入局部最优. 相反, 当搜索空间维度较少时, 应该增大惯性权重实现快速收敛以提高搜索效率.

由以上分析可知, 粒子适应度、种群规模以及搜索空间维度与惯性权重有密切关系, 可根据这些参数的值实现自适应调整惯性权重. 式(3) 将惯性权重定义为粒子适应度、种群规模以及搜索空间维度三者的函数:

$$\omega_i = \frac{1}{aF_i / (D * \sum_{i=1}^n F_i) - \exp(-n/b) + 1} \quad (3)$$

式中, ω_i 表示第 i 个粒子惯性权重, F_i 表示第 i 个粒子适应度, D 表示搜索空间维度, n 表示粒子数目, a, b 为经验参数. 算法在每次迭代后通过式(3) 更新所有粒子的惯性权重, 从而实现了局部搜索和全局搜索的能力自适应调整.

4 动态管理种群策略

在 PSO 算法的某一次迭代中, 如果有部分粒子位置不佳, 致使其 $Pbest_i$ 连续多次没有更新, 这些粒子当前所在位置较差, 并不能为 $Gbest$ 的更新做

做贡献,为提高算法搜索效率,可以把这些粒子删除.相反,如果 Gbest 连续多次没有被更新,此时粒子群体可能陷入局部最优,需要增加粒子来增加启发信息,加快 Gbest 的更新.因此,提出动态种群管理策略,具体描述如下:

(1) 当 Gbest 连续 s 次没有改变,说明现有种群需要新的粒子来提供启发信息,则动态添加一个粒子,并用个体最优 P_{best_i} 更新最频繁的两个粒子的位置组合成初始位置,以全部粒子的平均速度作为初始速度;

(2) 当 Gbest 连续 s 次改变,说明现有种群启发信息已经有充足,为提高算法运行效率,则动态删除 P_{best_i} 更新最不频繁的粒子.

5 动态管理种群的自适应惯性权重粒子群算法描述

根据上述分析,提出动态管理种群的自适应惯性权重粒子群算法—DSAPSO,算法具体描述如下:

算法 1: DSAPSO (D , MAX, MIN, K , P_n , s)

输入: 求解空间维度 D , 粒子数目上限 MAX, 粒子数目下限 MIN, 初始粒子数目 P_n , 粒子动态管理敏感指数 s .

输出: 问题的解.

步骤:

(1) 随机生成 P_n 个粒子的初始位置及初始速度

(2) 计算粒子适应度 F_i , 更新个体最优 P_i 及全局最 P_g ; 根据式(3) 计算粒子惯性权重 ω_i

(3) 根据粒子适应度更新个体最优 P_i 及全局最 P_g ;

(4) 根据式(1) 更新粒子速度, 根据式(2) 更新粒子位置.

(5) 动态管理种群;

① 当 Gbest 连续 s 次改变, 且 $P_n > \text{MAX}$, 则动态删除 P_{best_i} 更新最不频繁的粒子.

② 当 Gbest 连续 s 次没有改变, 且 $P_n < \text{MIN}$, 则增加一个粒子, 用 P_{best_i} 更新最频繁的两个粒子的位置组合成初始位置, 以全部粒子的平均速度作为初始速度.

③ 当 Gbest 连续 s 次没有改变, 且 $P_n = \text{MAX}$, 则删除 P_{best_i} 更新最不频繁非全局最优粒子, 然后动态添加一个新的粒子, 并用 P_{best_i} 频繁被更新的两个粒子的位置组合成初始位置, 以全部粒子的平均速度作为初始速度.

(6) 若达到结束条件则结束, 否则返回(2).

算法整体采用动态管理种群策略, 并在每一次迭代中计算式(3), 分别更新每个粒子的惯性权重.

6 实验结果以及分析

6.1 实验环境以及实验参数设置

在实验中, 取粒子群规模 MAX 为 30, MIN 为 5, 其他算法粒子数目均为 30; $c_1 = c_2 = 2$. 实验选取了六个不同特点的常用测试函数, 具体参数如表 1 所示. 其中, 维数是各个函数求值的空间维度 D , 目标值是算法结束条件, 即算法搜索到的解所必须达到的值.

表 1 实验所用测试函数及其相关参数

函数名	维数	变量取值范围	求解目标值
Sphere	30	$[-100, 100]$	0.01
Rosenbrock	50	$[-30, 30]$	150
Griewank	30	$[-500, 500]$	0.01
Schaffer'f6	2	$[-100, 100]$	0.996
Rast rigrin	40	$[-10, 10]$	100

6.2 实验方案

采用本文提出的 DSAPSO 算法与下面三种惯性权重调整算法进行比较: 惯性权重线性下降的标准粒子群算法 LWPSO、随机惯性权重粒子群算法 RWPSO 以及带压缩因子的粒子群算法 CFPSO. 对于四种不同算法, 采用两种方案进行试验: 方案一是固定迭代次数为 1 000 次, 计算每种算法运行结果的平均值; 方案二是确定每个函数的优化目标值, 计算每种算法的评价迭代次数, 超过 5 000 次记为无穷大. 每种方案独立运行 10 次计算结果平均值.

6.3 实验结果

表 2 中统计了固定迭代次数为 1 000 次时, 四种算法求解的平均值和最差的一次求解结果. 表 3 中统计了四种算法搜索到表 1 中对每个函数预订的目标值时, 迭代的次数和所用的时间, 如果迭代次数超过 5 000, 则将次数和时间都计为无穷大. 图 1 中记录 DASPSO 算法在 Sphere 函数上求解时, PSO 粒子数目随迭代次数的变化.

6.4 实验结果分析

从表 2 中可以看出, 本文提出的 DASPSO 算法, 由于惯性权重选择较为恰当, 全局寻优能力较强, 在五个函数上求解普遍优于其他算法, 而且最差解与平均解相差不大, 较为稳定. RWPSO 算法采用

随机策略,增加种群多样性,在对多峰函数优化上算法取得不错的结果;但对单峰 Sphere 函数效果较差,其主要原因算法在后期仍然采用随机惯性赋值策略,没有增强局部搜索能力,很难收敛到较优解.从表 3 可以看出,DASPSO 算法迭代次数与所用时间远少于其他算法.这是由于在迭代过程中,动态删除部分无效粒子并不断补充新粒子,粒子数目一直少于其他算法,但每个粒子都非常活跃,全局最优更新非常快.图 1 中记录了在 Sphere 函数上搜索时粒子数目的变化折线图,可以看出,在搜索过程中粒子数目很少达到 30,较少的粒子减少了计算粒子适应

度以及粒子移动等时间开销,极大提高了搜索效率.




图 1 求解 Sphere 函数时例子数目
随迭代次数的变化折线图

表 2 算法运行 1 000 次搜索到的解的平均值

	Sphere		Rosenbrock		Griewank		Schaffer'f6		Rastrigrin	
	平均值	最差	平均值	最差	平均值	最差	平均值	最差	平均值	最差
DASPSO	$1.47e^{-21}$	$1.78e^{-21}$	34.71	37.98	0.007 59	0.008 34	0.992 33	0.994 51	54.39	58.47
LWPSO	$1.25e^{-6}$	$1.54e^{-5}$	329.52	351.52	0.016 38	0.018 39	0.996 55	1.043 37	89.35	91.44
CFPSO	$1.63e^{-20}$	$1.82e^{-18}$	131.47	159.33	0.031 62	0.043 19	0.995 24	0.998 47	165.73	170.88
RWPSO	59.13	73.11	67.85	76.57	0.016 44	0.017 73	0.996 11	0.998 52	84.94	87.36

表 3 四种算法达到目标值迭代次数和运行时间

	Sphere		Rosenbrock		Griewank		Schaffer'f6		Rastrigrin	
	迭代次数	时间	迭代次数	时间	迭代次数	时间	迭代次数	时间	迭代次数	时间
DASPSO	664.2	12.6	631.6	8.4	482.6	9.7	728.6	4.5	544.3	12.1
LWPSO	2 227.4	153.8	无穷大	无穷大	1 786.7	57.0	1 214.5	16.5	945.2	33.7
CFPSO	978.3	39.5	1 338.2	23.8	无穷大	无穷大	894.8	14.3	无穷大	无穷大
RWPSO	无穷大	无穷大	957.3	15.2	1 425.1	29.5	1 345.6	17.6	784.2	29.0

7 结束语

惯性权重是决定 PSO 算法全局寻优与局部寻优的重要参数.本文提出了根据搜索状态在一种每次迭代后自适应调整惯性权重,进而更好地平衡全局搜索和局部开发的改进 PSO 算法.改进的算法采用了动态管理种群策略,极大提高了搜索效率.新算法与 LDIW、FIW、RIW 等调整算法在常用多峰测试函数上的实验结果证明,新算法具有较强的全局寻优能力与较高的搜索效率.

参考文献:

- [1] Angeline P J. Using selection to improve particle swarm optimization [C]// IEEE International Conference on Evolutionary Computation. Anchorage, Alaska, USA: IEEE, 2007:84-89.
- [2] Jacques Roget, Jacob SVesterstr. A diversity guided particle swarm optimizer, the ARPSO [R]. Technical Report 2002202, 2008:65-69

- [3] Shi Y, Eberhart R. A modified particle swarm optimizer [C]// IEEE World Conf on Computational Intelligence. Piscataway: IEEE, 2005:69-73.
- [4] Zhang L P, Yu H J, Hu S X. A new approach to improve particle swarm optimization[C]// Lecture Notes in Computer Science. Chicago: Springer2Verlag, 2006:134-139.
- [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(1):154-157.
- [6] 孙向军,赵斯强,严宗睿.基于粒子群优化的反潜搜索研究[J].微电子学与计算机,2008,25(7):91-93.
- [7] Salomon R. Reevaluating genetic algorithm performance under coordinate rotation of benchmark functions[J]. BioSystems, 1996(39):263-278.

作者简介:

陈占伟 男,(1975-),硕士,讲师.研究方向为计算机网络及应用.

李 蕊 女,(1976-),硕士,讲师.研究方向为计算机应用研究.