

一种动态改变惯性权的自适应粒子群算法

张选平, 杜玉平, 秦国强, 覃 征

(西安交通大学计算机科学与技术系, 710049, 西安)

摘要: 针对惯性权值线性递减粒子群算法(LDW)不能适应复杂的非线性优化搜索过程的问题,提出了一种动态改变惯性权的自适应粒子群算法(DCW).在该算法中引入了参数粒子群进化速度因子和聚集度因子,并根据这 2 个参数对粒子群算法搜索能力的影响,将惯性因子表示为粒子群进化速度因子和聚集度因子的函数.在每次迭代时算法可根据当前粒子群进化速度因子和聚集度因子动态地改变惯性权值,从而使算法具有动态自适应性.对几种典型函数的测试结果表明,DCW 算法的收敛速度明显优于 LDW 算法,收敛精度也有所提高.

关键词: 粒子群; 惯性权; 自适应

中图分类号: TP18 **文献标识码:** A **文章编号:** 0253 987X(2005)10 1039 04

Adaptive Particle Swarm Algorithm with Dynamically Changing Inertia Weight

Zhang Xuanping, Du Yuping, Qin Guoqiang, Qin Zheng

(Department of Computer Science and Technology, Xi an Jiaotong University, Xi an 710049, China)

Abstract: A new particle swarm algorithm with dynamically changing inertia weight (DCW) is presented to solve the problem that the linearly decreasing weight (LDW) of the particle swarm algorithm cannot adapt to the complex and nonlinear optimization process. The evolution speed factor and aggregation degree factor of the swarm are introduced in this new algorithm and the weight is formulated as a function of these two factors according to their impact on the search performance of the swarm. In each iteration process, the weight is changed dynamically based on the current evolution speed factor and aggregation degree factor, which provides the algorithm with effective dynamic adaptability. The algorithms of LDW-PSO and DCW-PSO are tested with three well-known benchmark functions. The experiments show that the convergence speed of DCW-PSO is significantly superior to DCW-PSO, and the convergence accuracy is also increased.

Keywords: *particle swarm; inertia weight; adaptability*

粒子群优化 (Particle Swarm Optimization, PSO) 算法是由 Eberhart 和 Kennedy 于 1995 年提出的一类基于群智能的随机优化算法^[1],适用于求解大量非线性、不可微和多峰值的复杂优化问题.由于 PSO 算法的程序实现起来异常简洁,需要调整的参数也少,因而已应用于多个科学和工程领域^[2].与遗传算法等其他全局优化算法一样,粒子群算法同样存在早熟收敛现象和后期振荡现象.针对这些问

题,国内外的研究者做了大量的工作,并提出了各种改进的算法^[3-6],如 Berhart 和 Shi 的惯性权值线性递减 (Linearly Decreasing Weight, LDW) PSO 算法^[6],即在优化方程的性能上有明显的效果.但是,PSO 在实际搜索过程中是非线性的且是高度复杂的,致使惯性权重 w 线性递减的策略不能反映实际的优化搜索过程.

本文提出了一种动态改变惯性因子的粒子群算

法.在该算法中,惯性因子的变化受算法运行态势的影响,是由粒子群的进化速度和粒子的聚集度综合决定.

1 粒子群的进化速度和粒子的聚集度

粒子群优化算法首先初始化一群随机粒子,然后通过迭代找到最优解.在每一次迭代中,粒子通过跟踪当前自身找到的个体最优值 p_{best} 和整个种群找到的全局最优值 g_{best} ,并根据

$$V_k = wV_{k-1} + c_1 r(\cdot)(p_{\text{best}} - p_{\text{present}}) + c_2 r(\cdot)(g_{\text{best}} - p_{\text{present}}) \quad (1)$$

$$p_{\text{present}_k} = p_{\text{present}_{k-1}} + V_k \quad (2)$$

来更新自己的速度和位置.其中: V 是粒子的速度; p_{present} 是粒子的当前位置; $r(\cdot)$ 是(0,1)之间的随机数; c_1 和 c_2 被称作学习因子,通常 $c_1 = c_2 = 2$; w 为惯性因子,取值范围在0.1~0.9之间.

在本文中,假定适应度函数在搜索空间内的值恒大于0,如果适应度值不满足这个条件,可以通过在原适应度值的基础上加上一个正数来满足这个要求.

全局最优值取决于个体最优值的变化,同时也反映了粒子群的所有粒子的运动效果.在迭代过程中,当前迭代的全局最优值总是要优于或至少等于上一次迭代的全局最优值.具体地说,如果优化目标是寻找极大值, $F(g_{\text{best}_T}) > F(g_{\text{best}_{T-1}})$, 则定义 $h = F(g_{\text{best}_{T-1}}) / F(g_{\text{best}_T})$; 如果优化目标是寻找极小值, $F(g_{\text{best}_T}) < F(g_{\text{best}_{T-1}})$, 则定义 $h = F(g_{\text{best}_T}) / F(g_{\text{best}_{T-1}})$. 综合这2种情况, h 可以表示为

$$h = \frac{\min(F(g_{\text{best}_{T-1}}), F(g_{\text{best}_T}))}{\max(F(g_{\text{best}_{T-1}}), F(g_{\text{best}_T}))} \quad (3)$$

并将 h 称之为进化速度因子.根据上面的假设和定义, $0 < h < 1$. 该参数考虑了算法运行的历史,也反映了粒子群进化速度,即 h 值越小,进化速度越快.当经过了一定的迭代次数之后, h 值保持为1,则断定算法停滞或者找到了最优解.

影响算法性能的另一个因素是粒子的聚集度.在算法中,全局最优值总是优于所有个体的当前的适应度值.如果 \bar{f}_T 为所有粒子当前适应度值的平均值,则 $\bar{f}_T = \frac{1}{N} \sum_{i=1}^N F(X_T[i])$, 其中 $X_T[i]$ 是粒子 i 在当前迭代次数为 T 时的位置, N 是粒子群的规模数.

同样,在极小值的寻优过程中, $F(g_{\text{best}_T}) < \bar{f}_T$, 则定义 $s = F(g_{\text{best}_T}) / \bar{f}_T$; 在极大值的寻优过程中,

$F(g_{\text{best}_T}) > \bar{f}_T$, 则定义 $s = \bar{f}_T / F(g_{\text{best}_T})$. 综合以上2种情况, s 可以表示为

$$s = \frac{\min(F(g_{\text{best}_T}), \bar{f}_T)}{\max(F(g_{\text{best}_T}), \bar{f}_T)} \quad (4)$$

并将 s 称之为粒子聚集度因子.显然, $0 < s < 1$, 它反映了所有粒子当前的聚集程度,同时也在一定程度上也反映出粒子的多样性. s 值越大,粒子群聚集程度也越大,粒子多样性越小.当 $s = 1$ 时,粒子群中的所有粒子具有同一性,如果此时算法陷入局部最优,则结果不容易跳出该局部极点.

2 自适应动量因子粒子群算法

Shi 和 Eberhart 研究发现^[6], w 较大时算法具有较强的全局搜索能力, w 较小则算法倾向于局部搜索. LDW 算法将惯性因子线性地减少,其变化公式为

$$w = w_{\text{max}} - \frac{R(w_{\text{max}} - w_{\text{min}})}{R_{\text{max}}} \quad (5)$$

式中: R 为当前迭代次数; R_{max} 为最大迭代次数.通常取 w_{max} 为0.9, w_{min} 为0.4.

实验证明: LDW 算法在优化方程性能上有明显效果,但是 LDW 算法中的 w 变化只与迭代次数线性相关,不能适应算法运行中的复杂、非线性变化特性.

事实上, w 的大小应该随着粒子群进化速度和粒子的逐渐聚集程度而改变,即 w 可表示为 h 和 s 的函数,即

$$w = f(h, s) \quad (6)$$

如果粒子群进化速度较快,算法可以在较大的搜索空间内持续搜索,粒子就可以保持大范围的寻优.当粒子群进化速度减慢时,可以减小 w 的值,使得粒子群在小空间内搜索,以便更快地找到最优解.

若粒子较分散,粒子群就不易陷入局部最优解.随着粒子群的聚集程度的提高,算法容易陷入局部最优,此时应增大粒子群的搜索空间,提高粒子群的全局寻优能力.

综上所述, w 应该随着粒子的聚集度的增大而增大,随着进化速度的降低而减小,它可以表示为

$$w = w_{\text{ini}} - hw_h + sw_s \quad (7)$$

式中: w_{ini} 为 w 的初始值,一般 $w_{\text{ini}} = 1$. 由于 $0 < h < 1$, $0 < s < 1$, 所以 $w_{\text{ini}} - hw_h < w < w_{\text{ini}} + w_s$.

基于上述讨论,本文提出了一种动态改变惯性因子(Dynamically Changing Weight, DCW)的粒子群算法,简称 DCW 算法.该算法在运行过程中根据

h 和 s 的值来动态调整 w , 从而改进算法的性能. 初始状态下, 置 $h = 0, s = 0$, 则 DCW 算法步骤如下.

步骤 1: 初始化粒子的位置向量、速度向量, 计算粒子的适应度.

步骤 2: 初始化粒子的全局最优值和个体最优值.

步骤 3: 如果算法收敛准则满足或达到最大迭代次数, 执行步骤 7, 否则执行步骤 4.

步骤 4: 对粒子群中的所有粒子相继执行更新粒子速度和位置, 计算粒子的适应度, 更新粒子的全局最优值和个体最优值.

步骤 5: 根据式 (3)、式 (4) 和式 (7), 分别计算 h, s 和 w .

步骤 6: 将迭代次数加 1, 并执行步骤 3.

步骤 7: 输出 g_{best} , 算法结束.

3 模拟实验和结果分析

3.1 进化速度因子和聚集度因子的确定

DCW 算法可以根据不同的适应度值动态地决定 w_h, w_s , 它们对算法的性能有较大的影响. 实验表明: 较大的 w_s 容易使算法陷入振荡状态, 而较大的 w_h 容易使算法陷入局部最优. 若 w_h 的取值在 0.4 ~ 0.6 之间, w_s 的取值在 0.05 ~ 0.20 之间, DCW 算法的性能较好. 表 1 和表 2 是在 w_h, w_s 不同取值下对 Schaffers f6 函数的两组测试结果. 实验中, DCW 算法随机运行 20 次, 粒子数为 30, 要求精度为 10^{-5} , 最大迭代次数为 500.

表 1 $w_s = 0.1$ 时取不同 w_h 的性能比较

	失效次数	最少迭代次数	平均迭代次数	后期振荡次数
$w_h = 0.2$	3	304	365.30	11
$w_h = 0.4$	5	84	193.60	1
$w_h = 0.5$	5	67	157.00	0
$w_h = 0.6$	7	63	186.46	0
$w_h = 0.8$	13	35	130.28	0

表 2 $w_h = 0.5$ 时取不同 w_s 的性能比较

	失效次数	最少迭代次数	平均迭代次数	后期振荡次数
$w_s = 0.05$	7	48	127.69	0
$w_s = 0.10$	5	47	197.00	0
$w_s = 0.20$	6	82	229.77	1
$w_s = 0.40$	6	92	222.80	2

3.2 模拟实验和结果分析

下面考虑 Rosenbrock 函数、Rastrigrin 函数和 Schaffers f6 函数的优化问题. 由于这 3 个函数用遗传算法优化难度均比较大, 因而常被用来比较算法的性能.

Rosenbrock 函数, 即

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

$x_i \quad [-100, 100]$

Rastrigrin 函数, 即

$$F(x) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10)$$

$x_i \quad [-10, 10]$

Schaffers f6 函数, 即

$$F(x) = 0.5 - \frac{\sin^2((x_1^2 + x_2^2)^{1/2}) - 0.5}{(1 + 0.001 \times (x_1^2 + x_2^2))^2}$$

$x_1, x_2 \quad [-100, 100]$

Rosenbrock 函数和 Rastrigrin 函数都有一个全局极小点, 其函数值为 0. 在函数优化中, 将 $F(x) + 0.1$ 作为适应度函数, 粒子维数为 10, 最大迭代次数为 2 000. Schaffers f6 有一个全局极大解 $F(x_1, x_2) = 1$, 在函数优化中, 粒子维数为 2, 最大迭代次数为 500.

在实验中, 取 $w_h = 0.5, w_s = 0.05$, 并将 DCW 算法与 LDW 算法进行比较, 结果如图 1 ~ 图 3 所示.

从图 1 和图 2 可以看出, 对于 Resenbrock 函数和 Rastrigrin 函数, DCW 算法在早期的收敛速度明显优于 LDW 算法, 在运行后期这 2 种算法的性能接近, 并且 DCW 算法的收敛精度优于 LDW 算法. 对于 Schaffers f6 函数的全局最优点, 由于被一圈局部最优点包围, 算法极易陷入局部最优点, 所以 DCW、LDW 算法都出现了失效状态, 也就是说二者均无法找到全局最优点. 算法的失效情况如表 3 所

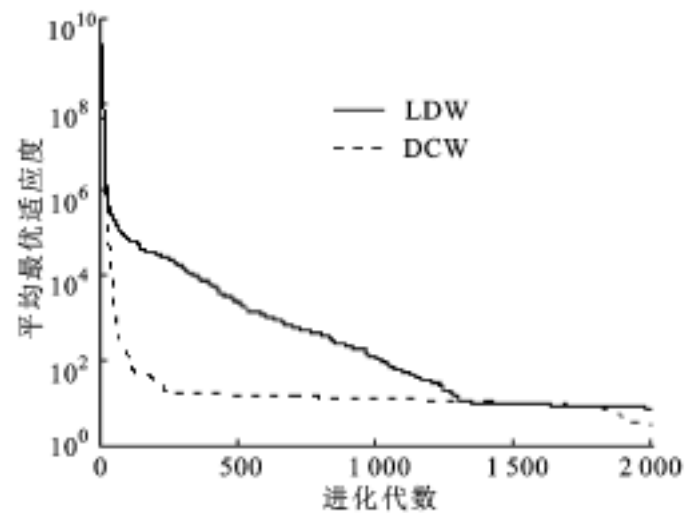


图 1 Rosenbrock 函数平均最优适应度进化曲线

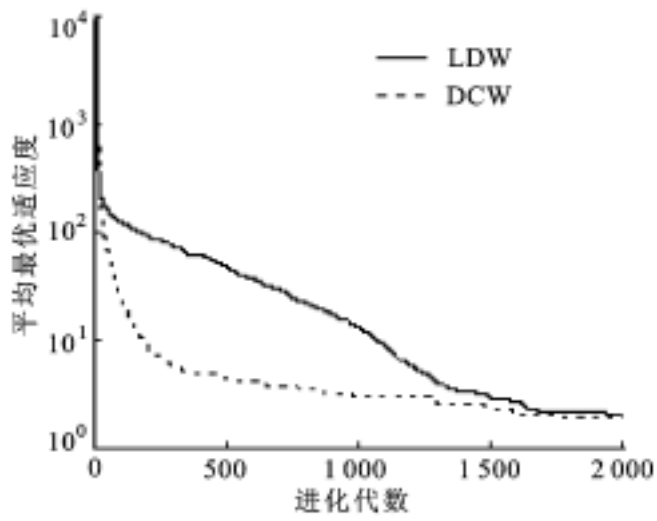


图2 Rastrigrin函数平均最优适应度进化曲线




图3 Schaffers f6函数平均最优适应度进化曲线

示,从表中可以看出,DCW算法可以较快的找到全局最优解,但在跳出局部搜索的能力上略次于LDW算法。

表3 LDW、DCW两种算法的性能比较

算法	失效次数	最少迭代次数	平均迭代次数
LDW	4	148	268
DCW	5	47	197

4 结论

w 的变化会影响算法的搜索能力.根据Shi和

Eberhart的研究,利用线性减少 w 的方法能有效改进算法的性能,提高函数的收敛精度和收敛速度.但是, w 的改变独立于算法的运行状况,据此本文引入了 h 来衡量算法的进化速度,引入 s 来衡量算法的粒子聚集度,并将其作为函数 w 的变量.这样一来, w 与算法的运行状态相关,可以根据实际情况调整 w ,从而改进算法的性能.与LDW算法相比,改进的算法平均迭代次数至少平均降低25%,收敛速度明显提高,这在算法早期运行时效果尤其明显.在收敛精度方面,改进的算法也体现出了较好的性能。

参考文献:

- [1] Eberhart R C, Kennedy J. A new optimizer using particle swarm theory [A]. Proceedings of the Sixth International Symposium on Micro Machine and Human Science [C]. Piscataway, USA: IEEE Service Center, 1995. 39-43.
- [2] Eberhart R C, Shi Y H. Particle swarm optimization: developments, applications and resources [A]. Proceedings of the IEEE Congress on Evolutionary Computation [C]. Piscataway, USA: IEEE Service Center, 2001. 81-86.
- [3] Shi Y H, Eberhart R C. Fuzzy adaptive particle swarm optimization [A]. Proceedings of the IEEE Congress on Evolutionary Computation [C]. Piscataway, USA: IEEE Service Center, 2001. 101-106.
- [4] 吕振肃, 侯志荣. 自适应变异的粒子群优化算法 [J]. 电子学报, 2004, 32(3): 416-420.
- [5] 高 鹰, 谢胜利. 免疫粒子群优化算法 [J]. 计算机工程与应用, 2004, 41(6): 4-6.
- [6] Shi Y H, Eberhart R C. A modified particle swarm optimizer [A]. Proceedings of the IEEE Congress on Evolutionary Computation [C]. Piscataway, USA: IEEE Service Center, 1998. 69-73.

(编辑 苗 凌)