

基于动态加速因子的粒子群优化算法研究

滕志军¹, 吕金玲¹, 郭力文¹, 王志新², 许 恒², 袁丽红²

(1 东北电力大学 信息工程学院, 吉林 吉林 132012;

2 国网吉林供电公司信息通信分公司, 吉林 吉林 132011)

摘 要: 针对固定加速因子导致粒子群算法中函数优化精度差、易于陷入局部最优、后期收敛速率较缓慢等问题, 提出一种基于动态加速因子的改进粒子群优化算法(PSO-DAC). 采用递减的惯性权重系数, 提高权衡局部搜索和全局搜索的能力, 引入动态的加速因子, 有利于全局搜索以改善粒子群算法的收敛速度及精度. 借助四个常用的测试函数与标准粒子群算法进行仿真测验对比, 结果显示, 改进之后的算法的最优解精度明显提高同时比标准粒子群算法迭代次数降低 51.28% 以上, 能够更快搜索到最优解, 特别是在多峰函数中表现更加明显.

关键词: 粒子群算法; 惯性权重; 加速因子; 收敛速度; 全局搜索

中图分类号: TP18

文献标识码: A

文章编号: 1000-7180(2017)12-0125-05

Research on Particle Swarm Optimization Based on Dynamic Acceleration Coefficients

TENG Zhi-jun¹, LV Jin-ling¹, GUO Li-wen¹, WANG Zhi-xin²,
XU Heng², YUAN Li-hong²

(1 Department of Information Engineering, Northeast Dianli University, Jilin 132012, China;

2 State Grid Jilin Power Supply Company Communication Branch, Jilin 132011, China)

Abstract: For fixed acceleration factors in the particle swarm optimization cause the function optimization accuracy poorly, easy to fall into local optimal solution and slow late convergence, this paper presents an improved particle swarm optimization base on dynamic acceleration coefficients (PSO-DAC). Adopting decreasing inertia weight coefficients improve the ability of weigh local search and global search capability. At the same time, introducing dynamic acceleration coefficients raise the convergence speed and accuracy of the particle swarm algorithm. By four commonly used benchmark functions, the improved particle swarm algorithm contrasts with the standard particle swarm optimization through simulation experiments. The experimental results show, the improved algorithm comparing with the standard particle swarm optimization has higher accuracy and reduce the number of iterations over 51.28%. The optimal solution can be found more quickly, especially in multimodal function.

Key words: particle swarm optimization; inertia weight; acceleration coefficients; convergence speed; global searching

1 引言

粒子群算法(Particle Swarm Optimization, PSO)的发展开始于 1995 年 Eberhart 和 Kennedy 所给出的模仿鸟类种群空中飞行寻食的动作, 利用鸟类当中的整体合作能力使得群体能够达到最

优^[1]. 由于粒子群算法概念简单、具有很强的发现较好解的能力、调整参数较少、易于实现等优势, 所以自从提出后引起众多研究人员关注. 如今, 粒子群算法在求解组合优化问题、图像融合、模糊系统控制等一些传统优化问题方面得到更加普遍的运用^[2-5]. 但是, 标准的粒子群算法有很多不足的地方, 例如比较

易于陷入局部最优、后期时其收敛速率比较缓慢、寻优精度相对较差等。

为了能够提升粒子群算法的功能,研究人员从各个不同的方面进行探索.在文献[6]中提出一种惯性系数随全局最佳值变化的方法,改善收敛速度和全局收敛性;在文献[7]中提出在不同时期采用不同的惯性权重系数及引入混沌变异,提高收敛精度、速度和稳定性;在文献[8]中提出更改速率更新方程式的新粒子群算法,来进一步增强全局搜索能力;在文献[9]中推出了一种采用动态的惯性权重系数以及更改适应度函数的方法,来加快算法的收敛功能.但大多数论文忽略了加速因子对粒子群算法的影响,把加速因子设置为固定值,导致粒子易陷入局部最优.因此,本文将固定的加速因子改进为动态的加速因子,并且采用递减的惯性权重系数,即基于动态加速因子的粒子群算法(Particle Swarm Optimization Based on Dynamic Acceleration Coefficients, PSO-DAC),进而能够增加粒子收敛速率以及提高算法优化精度。

2 粒子群算法

标准粒子群优化算法^[10](Standard Particle Swarm Optimization, SPSO)是指鸟类个体依据自身达到的最佳位置以及剩余个体达到的最佳位置来更改自身的位置和速度,从而能够找到种群最佳位置.首先,初始化种群中粒子初始值,利用个体和种群的经验来更改粒子原来的位置以及速率;然后,利用适应度函数方程式来计算每一个粒子的适应度值,依据该适应度值来判断当前粒子位置的优劣,从而能够找到粒子自身所搜寻到的最佳位置以及种群所搜寻到的最佳位置。

假定该算法所在空间是 D 维,那么第 i 个粒子的位置可以表示成: $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$,速度可以表示为: $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$,粒子搜索到最佳位值为: $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$,粒子群搜索到最佳位置为: $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$, i 表示粒子的个数即 $i = \{1, 2, \dots, m\}$,速率以及位置的更新方程式表示为

$$v_{id} = \omega v_{id} + c_1 r_1 (p_{id} - x_{id}) + c_2 r_2 (p_{gd} - x_{gd}) \quad (1)$$

$$x_{i(d+1)} = x_{id} + v_{id} \quad (2)$$

在式(1)中, c_1, c_2 是加速因子,通常取 $c_1 = c_2 = 2$; r_1, r_2 是随机数,一般取值在 $[0, 1]$ 之间; ω 是惯性权重系数,通过实验可以证明^[11],惯性权重系数 ω 的数值较大时能够增强粒子进行整体搜索能力,惯性系数 ω 数值较小时能够增强粒子进行局部搜索能力。

3 改进的粒子群算法

本文所提出的 PSO-DAC 算法是对粒子群算法进行一些改良.首先,采用动态递减的惯性权重系数,以至于能够增强权衡局部搜索以及全局搜索的能力;其次,采用动态的加速因子即 c_1 逐渐递减以及 c_2 逐渐递增的方法,来增加粒子群算法的收敛速率。

3.1 惯性权重

一个优化算法的功能好坏的关键在于能否权衡全局以及局部搜索,因此粒子群算法利用惯性权重系数来权衡全局以及局部搜索.通常取值比较大的惯性系数会改善算法的整体搜索能力,而对于取值比较小的惯性权重系数则能够改善局部搜索能力.因此,一个惯性权重系数的大小对于该算法有重要的作用。

本文采用线性递减惯性权重系数,其能够有效地权衡局部以及整体搜索的能力.表达式为

$$\omega(k) = \omega_{ini}(\omega_{ini} - \omega_{fin})(T_{max} - k)/T_{max} \quad (3)$$

式中, ω_{ini} 是指开始时的惯性权重; ω_{fin} 是指迭代数目达到最大值时的惯性系数; T_{max} 是指迭代次数最大值; k 是指当前的迭代次数.通过实验可知,当 $\omega_{ini} = 0.9, \omega_{fin} = 0.4$ 时,PSO算法的性能最好.本文所采用的式(3)在寻优过程中,惯性权重系数呈现递减的状态,这样能够在寻优初期增强全局搜索能力,在寻优后期能够增强局部搜索能力。

3.2 加速因子

在粒子群算法中,加速因子 c_1, c_2 是代表粒子自己以及剩余粒子对于粒子运动路线所产生的作用,同时也体现了粒子们之间的信息交换.不同的参数下,产生不同的粒子轨迹,也就是粒子的搜索能力不同.如果 c_1 值太大,则会造成过多的粒子在局部附近停留;如果 c_2 值太大,则会造成粒子提前达到局部最佳值并收敛于此值.本文设置在早期阶段选择较大的 c_1 值和较小 c_2 的值,使粒子能够增强“自我认知”能力,减弱“社会认知”能力,有利于增强全局搜索能力;在搜索后期减小 c_1 值同时增大 c_2 值,这样能够使得较多的粒子向“整体最优”学习,而较少的粒子向“局部最优”学习,以至能够较好地强化粒子的全局搜索能力。

因此,本文提出加速因子变化公式如下:

$$c_1(k) = c_{1ini} - (c_{1ini} - c_{1fin}) \times (k/T_{max}) \quad (4)$$

$$c_2(k) = c_{2ini} + (c_{2fin} - c_{2ini}) \times (k/T_{max}) \quad (5)$$

式中, c_{1ini}, c_{1fin} 表示加速因子 c_1 的开始值和最终值; c_{2ini}, c_{2fin} 表示加速因子 c_2 的开始值和最终值, k 表示当前迭代数目, T_{max} 表示最大迭代数目。

把式(3)~(5)代入式(1),从而能够得到新的粒子速度更新方程式:

$$v_{id} = w(k)v_{id} + c_1(k)r_1(p_{id} - x_{id}) + c_2(k)r_2(p_{gd} - x_{id})$$

(6)

在(6)式中,第一部分则表示为粒子之前的速率;第二部分则表示为粒子本身对于当前速率的作用;第三部分则表示其他剩余粒子对当前速率的作用。

3.3 改进后的粒子群优化算法步骤

改进之后的粒子群算法的具体环节如下(流程图见图1)。

Step1:初始化参数,并随机产生 N 个粒子位置以及速率的最初值。

Step2:计算出每一个粒子的适应值,并且对适应值进行从大到小排序,接着更新每一个粒子最佳适应值以及种群最佳适应值。

Step3:按照式子(3)、(4)、(5)来计算出加速因子以及惯性权重系数,并及时更新每一个粒子的速率及其位置。

Step4:重新计算出每个粒子的适应值并和原来的适应值比较,从而能够更新每个粒子最佳的适应值以及种群最佳的适应值。

Step5:检查迭代数目是否达到最初设定的最大值,如果达到最初设定的最大值,则跳出程序。反之则回到 Step3 继续往下依次执行,一直到迭代数目达到最初设定的最大值时跳出程序。




图1 PSO-DAC 算法流程图

4 仿真分析

为了能够检测本文所给出 PSO-DAC 算法的性能优劣,选择四个常用的测试函数来仿真比较 PSO-

DAC 算法算法的性能^[12]。

(1) Sphere Model 函数

$$f_1 = \sum_{i=1}^{30} x_i^2$$

(7)

搜索范围: $-100 \leq x_i \leq 100$

全局最优值: $\min(f_1) = f_1(0, \dots, 0) = 0$

该函数为非线性的对称单峰函数。

(2) Generalized Griewank 函数

$$f_2 = \frac{1}{4\,000} \sum_{i=1}^{30} x_i^2 - \prod_{i=1}^{30} \left(\frac{x_i}{\sqrt{i}} \right) + 1$$

(8)

搜索范围: $-600 \leq x_i \leq 600$

全局最优值: $\min(f_2) = f_2(0, \dots, 0) = 0$

若增长该函数的维数,则其部分最佳的范畴将减小,从而更加易于搜刮到整体最优解。

(3) Generalized Rastrigin 函数

$$f_3 = \sum_{i=1}^{30} [x_i^2 - 10\cos(2\pi x_i) + 10]$$

(9)

搜索范围: $-5.12 \leq x_i \leq 5.12$

全局最优值: $\min(f_3) = f_3(0, \dots, 0) = 0$

该函数为拥有许多部分最佳值点的多峰函数,因而难以搜刮到整体最佳解。

(4) Step 函数

$$f_4 = \sum_{i=1}^{30} (|x_i + 0.5|)^2$$

(10)

搜索范围: $-100 \leq x_i \leq 100$

全局最优值: $\min(f_4) = f_4(0, \dots, 0) = 0$

该函数只有一个最小值,且不连续。

本文把改进之后的 PSO-DAC 算法与 PSO 算法实行 Matlab 仿真测验,在该测验中具体的参数设定为种群大小 $Size = 40$,最大维数 $Dimension = 30$,迭代数目最大值为 $T_{\max} = 500$,在标准粒子群算法中设定加速因子 $c_1 = c_2 = 2$,惯性权重 $w = 0.7$;在改进之后的粒子群算法中设定加速因子 $c_{1\text{ini}} = 2$, $c_{1\text{fin}} = 0.5$, $c_{2\text{ini}} = 0.5$, $c_{2\text{fin}} = 2$,惯性权重 $w_{\text{ini}} = 0.9$, $w_{\text{fin}} = 0.4$ 。

对四个测试函数依次进行仿真测验,其数值测试结果见表1,其收敛迭代次数见表2。

表1 数值测试结果

	Sphere	Girewank	Rastrigin	Step
SPSO	0.417 1	33.895 8	0.398 9	0.238 5
PSO-DAC	0.290 8	16.244 1	0.195 0	0.124 2
精度提高百分比/%	30.28	52.07	51.11	47.92

表 2 平均收敛迭代次数

	Sphere	Girewank	Rastrigin	Step
SPSO	97.3	102.78	107.8	111.4
PSO-DAC	47.4	36.7	48.1	51.3
迭代次数降低百分比/%	51.28	64.29	55.38	53.95

Sphere Model 函数、Generalized Griewank 函数、Generalized Rastrigin 函数、Step 函数具体的优化曲线如图 2~5 所示。




图 2 Sphere Model 函数仿真结果




图 3 Generalized Griewank 函数仿真结果

由表 1 中四个测试函数的精度数值对比可得出,改进之后的算法的精度比标准的粒子群优化算法的精度至少提高 30.28%,特别是在 Generalized Griewank 测试函数中,PSO-DAC 算法精度比 SPSO 算法精度提高了 52.07%。如表 2 中四个测试函数的迭代次数对比能够得出,改进之后的算法的迭代数目比标准粒子群算法的降低了 51.28%以上,




图 4 Generalized Rastrigin 函数仿真结果




图 5 Step 函数仿真结果

因此 PSO-DAC 算法具有较快的收敛速度。通过图 2~5 四个测试函数具体的优化仿真曲线对比图能够得出,PSO-DAC 算法在单峰函数中以及在多峰函数中求最优过程的搜索能力、其收敛性都优于 SPSO 算法;同时也反映了 PSO-DAC 算法经过多次计算之后依然具有较高的粒子活性,使粒子能够跳出局部最优搜索,从而能够得到很快的收敛速度,以至可以加强粒子全局搜索最优值的能力。

5 结束语

本文给出基于动态加速因子的粒子群算法,进一步深入对粒子群算法的研究,采用递减的惯性权重系数,并将固定的加速因子改为动态的加速因子,增强粒子自身经验和其余粒子经验对收敛速度的影响,以增强改进后算法的收敛速度以及其精度。仿真

实验表明,PSO-DAC 算法的精度比标准的粒子群算法精度至少提高了 30.28%,迭代次数至少降低了 51.28%。因此,本文所给出的 PSO-DA 算法比标准粒子群算法的收敛速度以及精度均有较大幅度的提升,并且更加稳定。下一阶段将围绕在 PSO-DA 算法中引入 Tent 混沌序列以提高初始粒子群的多样性开展相关研究。

参考文献:

[1] Kennedy J , Eberhat R C. Particle swarm optimization [C]//IEEE International Conference on Neural Networks, Perth, Australia, 1995:1942-1948.

[2] Yildiz A R, Solanki K N. Multi-objective optimization of vehicle crashworthiness using a new particle swarm based approach [J]. Int. J. Advanced Manufacturing Technology ,2012,59:367-376.

[3] 阳同光,桂卫华. 基于粒子群优化自适应反推光伏并网逆变器控制研究[J]. 中国电机工程学报,2016,36(11):3030-3044.

[4] 孟庆宽,张漫,杨耿煌,等. 自然光照下基于粒子群算法的农业机械导航路径识别[J]. 农业机械学报,2016,47(6):11-20.

[5] 李菁华,张峥,方达,等. 基于混合差分蜂群算法的城市电动汽车充电站布局规划[J]. 东北电力大学学报,2016,36(4):84-90.

[6] 延丽平,曾建潮. 具有自适应随机惯性权重的 PSO 算法[J]. 计算机工程与设计,2016,27(24):4677-4679.

[7] 王洪涛,任燕. 基于改进惯性权重的粒子群优化算法[J]. 计算机应用与软件,2011,28(10):271-274.

[8] Borowska B. PAPSO algorithm for optimization of the coil arrangement[J]. Przegląd Elektrotechniczny(Electrical Review),2013,89:272-274.

[9] 龙文,梁昔明,董淑华,等. 动态调整惯性权重的粒子群优化算法[J]. 计算机应用,2009,29(8):2240-2242.

[10] 潘峰,周倩,李位星,等. 标准粒子群优化算法的马尔科夫链分析[J]. 自动化学报,2013,39(4):381-389.

[11] 刘志雄,梁华. 粒子群算法中随机数参数的设置与实验分析[J]. 控制理论与应用,2010,27(11):1489-1496.

[12] 王迪,吴鑫强,王振浩. 基于改进遗传算法的含分布式电源配电网故障定位[J]. 东北电力大学学报,2016,36(1):1-7.

作者简介:

滕志军 男,(1973-),博士,教授. 研究方向为无线通信技术. E-mail:tengzhijun@163.com.

吕金玲 女,(1993-),硕士研究生. 研究方向为无线通信技术.

郭立文 男,(1991-),硕士研究生. 研究方向为无线通信技术.

王志新 男,(1969-),助理工程师. 研究方向为电力通信技术.

许恒 男,(1973-),高级工程师. 研究方向为电力通信技术.

袁丽红 女,(1970-),工程师. 研究方向为电力通信技术.

(上接第 124 页)

[3] 陶洋,白璐. 基于节点传输性能的机会网络自适应转发策略[J]. 计算机应用研究,2014,31(7):2156-2158.

[4] 熊伟丽,刘欣,陈敏芳,等. 基于差分蜂群算法的无线传感器网络节点分布优化[J]. 控制工程,2014,21(6):1036-1040.

[5] 董晓丹,丁力. 一种混沌萤火虫算法的 WSN 节点分布优化研究[J]. 电光与控制,2017,24(3):73-76.

[6] 廖洁,张磊,马飒飒. 一种低能耗的 WSN 覆盖控制优化策略[J]. 计算机工程,2016,42(11):109-113.

[7] 封岸松,王宏,张彦武. 无线 HART 网络节点变速率资源调度算法实现[J]. 电子技术应用,2016,42(3):95-97.

[8] 刘向东,刘奎,王聪. 基于离散粒子群的节点可重用虚拟网络映射算法[J]. 计算机工程与科学,2015,37(2):276-280.

[9] 徐昌彪,吕顺. ICN 中基于节点权重的缓存大小分配方案研究[J]. 计算机应用研究,2017,34(1):214-216.

[10] 张传锦,李璐璐. 基于模糊 C 均值聚类的无线传感器网络节点定位算法[J]. 电子设计工程,2016,24(8):58-60.

作者简介:

傅望 女,(1976-),硕士研究生,讲师. 研究方向为司法信息技术、信息安全. E-mail:fuwang@zjzy.com.cn.