第36卷 第14期 计 算 机 工 程 2010年7月
Vol.36 No.14 Computer Engineering July 2010
·人工智能及识别技术· 文章编号：1000—3428(2010)14—0156—02 文献标识码：A 中图分类号：TP301.6

用于进化计算的群记忆性算法

陶俊波[1]，蔡德所[1,2]，吴彰敦[1]，段秋华[1]
(1. 广西大学土木建筑工程学院，南宁 530004；2. 三峡大学，宜昌 443002)

摘 要：在进化计算中利用群的记忆性，提出群记忆性算法(PMA)。PMA 考虑了群个体的当前多样性较优群和多样性权重 w_1。在多维优化和固定进化次数的情况下，采用 Rastrigrin 函数、Griewangk 函数和 Schwefel 函数进行测试，benchmark 表明 PMA 的性能优于混沌惯性权重的粒子群优化算法。

关键词：进化计算；群记忆性算法；多样性权重

Population Mnemonic Algorithm for Evolutionary Computation

TAO Jun-bo[1], CAI De-suo[1,2], WU Zhang-dun[1], DUAN Qiu-hua[1]
(1. College of Civil Engineering & Architecture, Guangxi University, Nanning 530004; 2. China Three Gorges University, Yichang 443002)

【Abstract】This paper utilizes population memory and proposes a Population Mnemonic Algorithm(PMA) for evolutionary computation. PMA thinks about population individual current more diverse population and the diversity weight w_1. With multi-dimensional optimization and fixed evolutionary generations, this paper tests the algorithm by using Rastrigrin function, Griewangk function, and Schwefel function. benchmark shows that PMA is better than Chaos inertance weight PSO(CPSO) algorithm.

【Key words】evolutionary computation; Population Mnemonic Algorithm(PMA); diversity weight

1 概述

进化计算(Evolutionary Computation, EC)的设计原理是由物种自然进化模型的启发得到的。

典型 EC 主要包括遗传算法[1](Genetic Algorithms, GA)和粒子群优化[2](Particle Swarm Optimization, PSO)。PSO 和 GA 都基于群体和适应度 2 个概念，并随机初始化种群，它们使用适应值来评价系统，并根据适应值进行一定随机搜索。2 个系统均不能保证找到最优解。但 PSO 没有 GA 的交叉和变异，而是根据自己的速度来决定搜索。PSO 具有记忆特点，其信息共享机制与 GA 不同。在 GA 中，染色体互相共享信息，因此，整个种群较均匀地向最优区域移动。而在 PSO 中，只有全局最优和局部最优提供信息给其他粒子，这是单向的信息流动，整个搜索更新过程是跟随最优解的过程。与 GA 相比，在多数情况下，所有粒子可能更快地收敛于最优解。为了更好地控制 PSO 的开发和探索能力，研究者将惯性权重 w 引入 PSO，形成了目前的标准 PSO[3]。

本文提出一种新的群记忆性算法(Population Mnemonic Algorithm, PMA)，该算法首次在 EC 中考虑了群体的记忆性。

2 PMA

2.1 PMA 的基本思想

PMA 随机初始化种群，使用适应值来评价系统，并根据适应值进行一定随机搜索。进化过程中考虑了群迄今最优个体和当前最优个体。智能性行为包含了 GA 的适应值评价系统和 PSO 的粒子记忆。PMA 可以考虑单群进化和多群并行进化的情况，并具有以下特点：

(1)在 EC 中考虑了群体的记忆性，迄今群同当前群相互共享信息。考虑了同一个群个体的迄今多样性最优群。对各群个体的当前多样性使用相同范围内的数值表示，使不同迭代的同一个群个体的多样性可以相互对比，从而得到同一个群个体的迄今多样性最优群。

(2)考虑了群个体的当前多样性较优群。各群智能识别群个体的当前多样性最优群，其实质是群个体的当前多样性较优群。

(3)通过 3 个参数(w_1、w_2 和 w_3)控制算法的收敛速度和收敛精度。多样性权重 w_1 是迄今群多样性的继承权值。w_2 是时间上和空间上分布的 2 个外群信息的分配权值。w_3 是外群信息对本群信息的影响权值。对复杂问题求解时，w_1、w_2 和 w_3 取值应当增大。

2008 年初，具备特点(1)和特点(2)的群记忆性算法已经完成，并和一些学者进行了交流。

2.2 PMA 的群多样性

$[X_d, X_u]$为变量区间。$f(X)$评价每一代群个体的适应值。

$$\min f(X)$$
$$\text{s.t. } X \in [X_d, X_u] \quad (1)$$

$X_{i,l,j}$ 的下标 i 表示个体，l 表示种群，j 表示当前进化次数。n 为种群规模，$l_{\max}$ 为种群个数，$j_{\max}$ 为最大进化次数。群 l 的个体适应值由好到坏排序为 $1,2,\cdots,u\text{-}1,u,u+1,\cdots,v\text{-}1,v,v+1,\cdots,n\text{-}1,n$，且 $1\le u<v\le n$，$u+1$, $u+2,\cdots$, $v\text{-}1$ 之间的个体不需要进行适应值排序，可以找出群 l 的适应值排序 $u(v)$的当前优(劣)个体 $X_{u,l,j}(X_{v,l,j})$。各群的适应值排序 $u(v)$的当前优(劣)个体相互比较适应值，得到适应值排序 $u(v)$的当前最优(劣)

基金项目：国家自然科学基金资助项目(60720106001)
作者简介：陶俊波(1982－)，男，硕士，主研方向：进化计算，工程结构可靠度计算，工程有限元方法；蔡德所，教授、博士；吴彰敦，教授；段秋华，讲师、博士
收稿日期：2010-02-16 **E-mail：**ulanala@hotmail.com

个体所在的种群 $bestu(worstv)$，适应值排序 $u(v)$的当前最优(劣)个体表示为 $X_{u,bestu,j}(X_{v,worstv,j})$。为了比较 $X_{u,l,j}(X_{v,l,j})$与 $X_{u,bestu,j}(X_{v,worstv,j})$的差异，由 $X_{u,l,j}(X_{v,l,j})$与 $X_{u,bestu,j}(X_{v,worstv,j})$差的范数得到 $b^j_l(w^j_l)$。一般取 u=1、v=n，比较群 l 的当前最优(劣)个体 $X_{1,l,j}(X_{n,l,j})$和当前最优(劣)个体 $X_{1,bestu,j}(X_{n,worstv,j})$的差异。各群的元素 $b^j_l(w^j_l)$组成向量 $\boldsymbol{B}^j(\boldsymbol{W}^j)$，向量 $\boldsymbol{B}^j(\boldsymbol{W}^j)$含有 $l_{\max}$ 个元素。max()取向量 $\boldsymbol{B}^j(\boldsymbol{W}^j)$的最大元素。min()取向量 $\boldsymbol{B}^j(\boldsymbol{W}^j)$的最小元素。将 $b^j_l(w^j_l)$标准化，在区间$(1/c^{0.5},1)$得到 $m^j_l(n^j_l)$，常数 c>1。$X_{u,l,j}(X_{v,l,j})$越接近 $X_{u,bestu,j}(X_{v,worstv,j})$，计算得到的 $m^j_l(n^j_l)$数值越大。

$$b^j_l=\left\|X_{u,l,j}-X_{u,bestu,j}\right\|$$
$$w^j_l=\left\|X_{v,l,j}-X_{v,worstv,j}\right\|$$
$$m^j_l=1/c^{0.5}+\left(1-1/c^{0.5}\right)\frac{\max\left(\boldsymbol{B}^j\right)-b^j_l}{\max\left(\boldsymbol{B}^j\right)-\min\left(\boldsymbol{B}^j\right)}$$
$$n^j_l=1/c^{0.5}+\left(1-1/c^{0.5}\right)\frac{\max\left(\boldsymbol{W}^j\right)-w^j_l}{\max\left(\boldsymbol{W}^j\right)-\min\left(\boldsymbol{W}^j\right)} \quad (2)$$

各群的元素 $m^j_l(n^j_l)$组成向量 $\boldsymbol{M}^j(\boldsymbol{N}^j)$，向量 $\boldsymbol{M}^j(\boldsymbol{N}^j)$有 $l_{\max}$ 个元素。向量 $\boldsymbol{M}^j$ 和 $\boldsymbol{N}^j$ 对应元素相互点乘组成新的 $l_{\max}$ 个元素的向量 $\boldsymbol{A}^j$，$1/c<a^j_l<1$。a^j_l 数值越大，群 l 个体的当前多样性越好。为了不使个体更新信息单调，使得群 l 个体的当前多样性优群固定在当前多样性最优群，群 l 智能识别群个体的当前多样性最优群(实质是群个体的当前多样性较优群)，智能识别体现在 A^j 点乘 $rand(1,l_{\max})$，$rand(1,l_{\max})$是(0,1)之间的均匀分布的随机向量。$find()$找出向量 $\boldsymbol{A}^{temp}$ 的最大元素对应的群 h。

$$\boldsymbol{A}^j=\boldsymbol{M}^j\times\boldsymbol{N}^j$$
$$\boldsymbol{A}^{temp}=\boldsymbol{A}^j\times rand(1,\ l_{\max})+\boldsymbol{A}^j$$
$$h=find(\boldsymbol{A}^{temp}==\max(\boldsymbol{A}^{temp})) \quad (3)$$

2.3 PMA 的群记忆性

设 k 表示群 l 个体的迄今多样性最优群对应的进化次数，A^k 的元素 a^k_l 表示群 l 个体的迄今多样性，A^j 的元素 a^j_l 表示群 l 个体的当前多样性。如果当前群的多样性优于迄今群的多样性，即 $a^k_l<a^j_l$，PMA 通过 k=j 和 $a^k_l=a^j_l$ 更新，否则通过 w_1 继续折减迄今群的多样性，k 和 a^k_l 保持不变，具体描述如下：

if $\quad a^k_l<a^j_l$
k=j
$a^k_l=a^j_l$
else $\quad a^k_l=w_1a^k_l$

设 g_s 是当前群和迄今群最大的代数间隔。连续 j-k 次进化满足 $a^k_l\geq a^j_l$，由 $a^k_l=w_1a^k_l$ 迭代得到 $a^j_l=w_1^{j-k}a^k_l$，由 $1/c\leq a^j_l\leq 1$ 得到 $1/c=w_1^{g_s}$，代数间隔 g_s 取整数，$g_s=ceil(\ln(1/c)/\ln(w_1))$，$ceil()$向正方向舍入。若固定的 w_1 取值小，则得到 g_s 数值小，否则 g_s 数值大。

2.4 PMA 的算法流程

PMA 的算法流程如下：

Sep1 k_1=1，k=1、$a^k_l=a^1_l$，随机初始化群 l 个体 i 的 d 维 $x_{d,i,l,1}$。

Step2 k_1=j，当前群 l 个体 i 的 d 维 $x_{d,i,l,j}$ 通过当前最优个体的 d 维 $x_{d,1,bestl,j}$、群 l 迄今最优个体的 d 维 $x_{d,1,l,bestj}$、群 l 个体的迄今多样性最优群的个体 i 的 d 维 $x_{d,i,l,k}$(k_1=k，即时间分布相应的 $x_{d,i,l,j}$)和群 l 识别得到的群个体的当前多样性较优群的个体 i 的 d 维 $x_{d,i,h,j}$(l=h，就是空间分布相应的 $x_{d,i,l,j}$)来实现。r_1 和 r_2 是(0,1)之间的均匀分布随机数。

$$x_{d,i,l,j+1}=x_{d,i,l,j}+r_1(x_{d,1,bestl,j}-x_{d,i,l,j})+r_2(x_{d,1,l,\text{bestj}}-x_{d,i,l,j})+w_3[w_2x_{d,i,l,k}+(1-w_2)x_{d,i,h,j}-x_{d,i,l,j}]$$

Step3 k_1=j+1，当满足条件时终止算法，否则执行 Step2。

3 benchmark

所有 benchmark 都运行在一台机器上，都采用 Matlab7 编程。应用 3 个典型的 benchmark，Dim=50。Rastrigin 函数是一个可扩展的连续多峰函数，不可分离。Rastrigin 函数是一个复杂的多模问题，具有大量的局部极值点，主要用于检验算法的群体多样性。Schwefel 函数由于其全局极值点周围的所有局部极值点远离它，因此搜索最优解过程中很容易陷入错误的收敛方向。Griewangk 函数在各维上的变量是密切相关的，互相作用，因此很难取得最优解[4]。

在 PMA 中，$l_{\max}$=10、n=15、c=10、u=1、v=n、$j_{\max}$=300、w_1=0.75, 0.98，得 $g_s=ceil(\ln(0.1)/\ln(0.75))=9$、$g_s=ceil(\ln(0.1)/\ln(0.98))=114$，初始化的 w_3 采用 0.8，随后采用 logistic 映射更新。表 1 给出了 w_1=0.75 时 PMA 的 50 次 benchmark 的最佳最优值、平均最优值和最差最优值。表 2 给出了 w_1=0.98 的 PMA 的 30 次 benchmark 的最佳最优值、平均最优值和最差最优值。Rastrigrin 函数最好的 benchmark 产生在 w_1=0.98、w_2=0.75 处。Schwefel 函数最好的 benchmark 产生在 w_1=0.75、w_2=1.00(仅考虑时间上分布的外群信息)处。Griewangk 函数最好的 benchmark 产生在 w_1=0.75、w_2=0.00(仅考虑空间上分布的外群信息)处。

表 1　w_1=0.75 时 PMA 的 benchmark

函数	最优值项	w_2=1.00	w_2=0.75	w_2=0.50	w_2=0.25	w_2=0.00
Rastrigin	最佳	31.877 5	34.832 6	42.025 4	51.738 9	59.767 9
	平均	68.973 1	67.751 8	69.756 8	87.635 7	92.890 8
	最差	106.667 2	103.504 7	100.578 5	121.394 0	143.273 8
Schwefel	最佳	-1.3625e4	-1.1473e4	-1.1926e4	-1.3379e4	-1.2500e4
	平均	-1.1426e4	-1.0161e4	-1.0016e4	-1.0291e4	-1.0465e4
	最差	-9.9329e3	-8.8081e3	-8.2972e3	-8.4913e3	-8.5311e3
Griewangk	最佳	0.062 9	0.449 2	0.379 9	0.211 4	0.006 8
	平均	0.626 1	0.902 1	0.961 4	0.804 6	0.224 2
	最差	1.010 9	1.111 6	1.528 2	1.278 5	0.723 0

表 2　w_1=0.98 时 PMA 的 benchmark

函数	最优值项	w_2=1.00	w_2=0.75	w_2=0.50	w_2=0.25	w_2=0.00
Rastrigin	最佳	36.882 4	37.353 7	31.694 1	51.748 3	60.980 8
	平均	67.207 5	59.030 5	62.184 4	72.806 9	107.375 2
	最差	105.480 9	87.146 9	92.991 7	116.104 4	213.919 4
Schwefel	最佳	-1.2981e4	-1.1293e4	-1.2590e4	-1.1666e4	-1.1730e4
	平均	-1.0685e4	-9.5837e3	-9.9796e3	-9.8667e3	-1.0240e4
	最差	-9.1893e3	-7.7374e3	-7.9609e3	-7.5976e3	-8.9062e3
Griewangk	最佳	0.878 8	0.825 7	0.912 7	0.716 7	0.014 0
	平均	1.021 3	1.105 1	1.170 2	1.128 4	0.234 5
	最差	1.190 4	1.462 8	2.691 8	1.666 3	0.990 2

PSO 是目前被广泛研究的 EC，本文将 PMA 和混沌惯性权重的 PSO(Chaos inertance weight PSO, CPSO)[5]进行比较。CPSO 的 n=150、$j_{\max}$=300，初始化的 w 为 0.8，随后采用 logistic 映射更新。表 3 给出了 CPSO 的 30 次 benchmark 的最佳最优值、平均最优值和最差最优值。Rastrigrin 和 Griewangk 函数最好的 benchmark 产生在 c_1,c_2=1.25 处。Schwefel 函数最好的 benchmark 产生在 c_1,c_2=1.75 处。benchmark 说明在多维优化且固定进化次数的情况下，PMA 优于 CPSO。

(下转第 160 页)