

# 基于淘汰机制的双种群遗传算法

方必和, 于蕾蕾

(合肥工业大学, 安徽 合肥 230009)

**摘要:**传统的遗传算法虽然经过了多方改进,但是早熟的困扰仍然存在。针对这一缺陷,提出一种基于淘汰机制的遗传算法,模仿自然和社会的进化过程,在双种群遗传算法的基础上,将“战争”模式引入到种群的进化过程中去,建立一种新的淘汰机制来保持种群的多样性,避免算法提前收敛。用测试函数对算法进行测试,并将结果与自适应遗传算法进行对比和分析。实验证明,基于淘汰机制的遗传算法是可行且有效的。

**关键词:**淘汰机制;双种群遗传算法;多样性;测试函数

中图分类号:TP301.6

文献标识码:A

文章编号:1673-629X(2009)09-0101-03

## Dual Population Genetic Algorithm Based on Out Mechanism

FANG Bi-he, YU Lei-lei

(Hefei University of Technology, Hefei 230009, China)

**Abstract:** While traditional genetic algorithm has been improved much, but the trouble of “premature convergence” remains. In response to this defect, proposes genetic algorithm based on the out mechanism, to imitate the natural and social evolution, introduces the “war” model into the dual population genetic algorithm, the purpose is to establish a new out mechanism to maintain the diversity of population, avoiding premature convergence. Finally, test this algorithm with test function, contrast and analysis the result with the result of adaptive genetic algorithm. The experiments proved that dual population genetic algorithm based on out mechanism is feasible and effective.

**Key words:** out mechanism; dual population genetic algorithm; diversity; test function

### 0 引言

遗传算法(GA)是近年来大家关注比较多的一种智能算法,其简单通用、鲁棒性强、使用并行处理的优点使其在各个领域都得到了广泛的应用<sup>[1]</sup>。经过近几十年的发展,专家们提出了众多的改进方案,切实有效地提高了遗传算法的性能<sup>[2,3]</sup>,但是仍受到“过早收敛”的困扰<sup>[4]</sup>。防止过早收敛,关键在于保持种群的多样性。文中尝试性地将一些社会性的元素加入到算法中去,建立一种类似于战争模式的淘汰机制,通过这种竞争的方法来引导两个种群间的共同进化,并争取能在较大程度上保持种群的多样性。

### 1 加入淘汰模式的双种群遗传算法

并行遗传算法是一种近年来比较活跃的一个改进分支,其中提到了多种群的概念,各个种群独立进化,并相互交流。独立进化保证了种群的多样性,种群间的交流保证了可行解收敛的速度。但是种群多则意味

着耗费的时间增大,在某些问题上,像一些实时系统,人们对解的精度要求不是特别高,但是对时间的要求却是特别苛刻,怎样在比较短的时间内得到比较理想的目标解,于是有些人提出了双种群遗传算法。如Martikanien等提出了分层次的双种群遗传算法,杨小芹等提出一种基于熵的双群体遗传算法,李军华等提出了一种改进的双种群遗传算法<sup>[5]</sup>。

文中即是在双种群基础上进行的改进,建立一种淘汰机制力图使进化摆脱早熟的困扰。

#### 1.1 基本思想

遗传算法中的基本单位是染色体,也就是一串包含问题解的符号串。但是一般在解释遗传算法机理的时候,习惯把它当成个体,若干个体组成一个种群<sup>[6,7]</sup>。在蚁群遗传算法中,可以把个体和种群解释为蚂蚁和蚂蚁群<sup>[8]</sup>;蜂群遗传算法中,也可被理解为蜂和蜂群<sup>[9]</sup>;鉴于此,做出类似的假设:把个体当成是人。而人群会自然而然地组成各自为政的种族,种族会各自进化,但是又并不是完全孤立的,不同种族之间会有“竞争”。纵观中国古代历史,“战争”是最常见的一种竞争方式。文中就试图模拟这一社会进程,尝试通过

收稿日期:2009-01-07;修回日期:2009-03-18

作者简介:方必和(1964-),男,安徽巢湖人,副教授,硕士研究生导师,研究方向为管理系统工程。

引入“战争”模式来完成种族的共同进化进程<sup>[10]</sup>。

现在假设有两个种族,战争来临时,种族之间选出各自的战士出征,按照“循环赛制”,双方的每个战士都交战一次,然后记录每个战士的失败和胜利的情况。为了记录相关数据,引入这样一个名词:生命点,用来对战士进行淘汰性选择。

生命点是与战士的胜负次数密切相关的。生命点小于0时,可视为此战士死亡,即被淘汰。给每个战士一个初始的生命点,当他战胜一次时,生命点加1;失败一次,生命点减1。战斗结束后,扫描双方战士生命点,清除死亡的个体,剩余的战士则各自回到自己种族中,随后种族会重新补充人口,开始新一轮的遗传进化操作。

这样经过战争的洗礼后,两个种群的成员都发生了变化,一方面淘汰了相对弱势的个体,另一方面又给种族增加了新鲜的血液。

文中模拟这一过程,对双种群遗传算法进行改进,加入“战争”这一模式。

### 1.2 概念

上述是基于淘汰机制的 DGA(dual population genetic algorithm)的基本思想,为此需定义一些基本概念,假设有两个种群 A 和 B。

1)生命点:记录每个战士战斗输赢的情况,经过试验对比表明,将初始生命点设为战士人数的 20% ~ 40%时,算法效率最高。

2)战争:适应度高的个体作为战士,进行战斗。A、B 各取出其适应度位于前 N 名的个体作为待比较种群 AA 和 BB,然后让 AA 中的所有个体依次与 BB 中的所有个体进行适应度的比较,适应度高的个体获胜,生命点加1,适应度低的个体生命点减1。经过 N<sup>2</sup> 次比较后,战斗结束。A 和 B 扫描各自战士的生命点,将生命点小于0的个体丢弃。经试验表明,将 N 设为种群规模的 40% ~ 60% 较为合适。

### 1.3 算法描述

为了尽可能增大两个种群之间的差异,采取了一种特殊的方式来对种群进行初始化操作。将其中一个种群的染色体的基因位取反,就得到另一个种群的染色体,如图 1 所示。

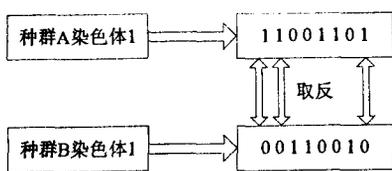


图 1 初始化染色体示例

算法步骤可描述如下:

Step1:初始化。产生两个同等规模的种群,初始化其染色体和生命点;设定循环次数变量  $t = 0$ 。设定最大循环代数  $T$ 。

Step2:计算适应度。两个种群分别取个体的染色体进行适应度的计算。

Step3:保存最优解。两个种群分别保存自己的最优解。

Step4:检测是否  $t < T$ 。若满足,则比较两个种群的最优值,最接近于理想值的即为所求值;若不满足,继续。

Step5:分别进行遗传操作。包括选择、交叉和变异三个算子。

Step6:战争。两个种群分别重新计算适应度,选择战士,进行战争。

Step7:补充人口。战争结束后,两个种群分别扫描各自的战士生命点,并随机生成新的个体代替死去的战士; $t++$ 。

算法流程图如图 2 所示。

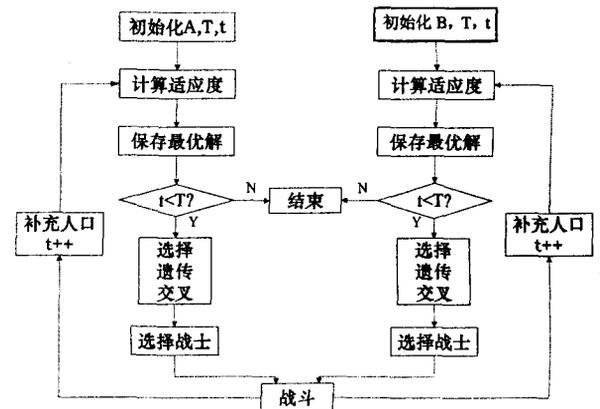


图 2 基于淘汰机制的 DGA 流程图

### 1.4 分析

在这种算法中,按照适应值与理想值接近的程度将个体分为了三个部分:强个体——适应值最接近于理想值的个体,对应于战争中幸存下来的战士;弱个体——适应值离理想值较远的个体,对应于未被选中为战士的个体;其余部分则为中等个体,对应于在战争中被淘汰的个体。

强个体和中等个体作为战士进入淘汰选择。在战斗中,强个体因为适应值较高,获胜的几率就高,随着战斗的进行,生命点会不断增大,则此类个体更不易被淘汰,从而确保了强个体也就是优秀染色体在整个种群进化过程中的主导地位。

中等个体的染色体跟强个体的比较接近,它们的存在不易使算法跳出局部最优的困扰。因此,及时将这些个体淘汰并重生新的个体,有助于增大种群的多

样性。

在模式定理中,遗传进化的本质被定义于优秀模式的保存和改进,一般认为,一条染色体之所以适应值很高,是因为它包含了优秀的模式。而弱个体的染色体虽然整体不强,但是其基因片段中却可能存在着大量优秀的模式。因此,选择将弱个体进行部分保留,在一定程度上保证了优秀模式的存活率。

## 2 仿真实验

因为数学函数优化问题具有普遍意义,且能较好地反应算法本身的实际效能,所以常常被用来作为遗传算法的测试对象。为了检测基于淘汰机制的 DGA 的有效性,引入了若干经典的测试函数<sup>[11]</sup>。

$$F1: f(x_1, x_2) = \min((4.0 - 2.1x_1^2 - x_1^4)x_1^2 + x_1x_2 + (4.0x_2^2 - 4.0)x_2^2)$$

$$x_1 \in [-3, 3], x_2 \in [-2, 2]$$

$$F2: f(x_1, x_2) = \min\left(\frac{(\sin\sqrt{x_1^2 + x_2^2})^2 - 0.5}{[1.0 + 0.01(x_1^2 + x_2^2)]^2} - 0.5\right)$$

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

此函数为 Schaffer 函数,最小值为 -1。

$$F3: f(x_1, x_2) = \min(100 * (x_2 - x_1^2)^2 + (1 - x_1)^2)$$

$$x_1 \in [-3, 3], x_2 \in [-3, 3]$$

此函数为 Banana 函数,此函数极难优化,只有一个全局最小点,最小值为 0。

为了进行比较,引入了自适应 GA,其主要思想是,遗传操作过程中,交叉和变异概率随着种群多样性的不同进行自适应调整。其方法简单,改进效率高,是人们比较常用的一种改进算法<sup>[12]</sup>。

为了排除随机数的干扰,对每个算法都进行了 100 次。种群规模设为 100,染色体长度为 30,交叉概率为 0.9,选择概率为 0.1。运行结果统计如表 1 至表 3 所示,这里的最优值代表 100 次实验结果中最优的一个数据;最劣值则代表了其中最差的一个数据;平均值即是这 100 个结果的算术平均值。

表 1 F1 函数的试验结果

F1	最优值	搜到最优值的次数	最劣值	平均值
自适应 GA	-1.031628	17	-0.999807	-1.02746839
基于淘汰机制的 DGA	-1.031628	83	-1.031566	-1.03162139

在表 1 中可以看到,对于 F1 函数,自适应 GA 和基于淘汰机制的 DGA 都能搜索到理想值。但是前者搜索到理想值的概率是 17%,而后者搜索到理想值的概率提高到了 83%,是前者的 4.9 倍。

表 2 F2 函数的试验结果

F2	最优值	搜到最优值的次数	最劣值	平均值
自适应 GA	-0.999981	14	-0.727233	-0.96392025
基于淘汰机制的 DGA	-0.999981	33	-0.962776	-0.99234714

表 2 中,基于淘汰机制的 DGA 有 33 次得到最优值,是自适应 GA 搜索到最优值次数的 2.6 倍;而且可以明显看出,后者得到的最优值的平均值远远优于前者。

表 3 F3 函数的试验结果

F3	最优值	搜到最优值的次数	最劣值	平均值
自适应 GA	0.000387	1	0.772653	0.11961803
基于淘汰机制的 DGA	0.000000	1	0.077462	0.00912362

表 3 中,自适应 GA 只能接近却无法求得理想值,基于淘汰机制的 DGA 虽然只有一次搜索到了理想值,但是从平均值上可以看出,基于淘汰机制的 DGA 与自适应 GA 得出的结果相比,具有非常大的优越性。

通过以上的对比和分析,可以认为,相比于自适应 GA 来说,基于淘汰机制的 DGA 无论是在搜索次数还是在平均值上都能够得到明显提高,进而说明了文中所提出来的改进方法是可行且有效的。

## 3 结束语

模仿自然生物进化是人们常用的一种改进遗传算法的方式<sup>[13]</sup>。文中在双种群遗传算法的基础上,除去模仿自然进化以外,又加入了社会性的元素——战争,将其作为一种保持种群多样性的方式。初步实验证明,这种方法是有效的,但是改进效率仍需进一步提高,战士人数等一些重要参数需要更多的试验来进行分析和调整。这将是下一步的研究方向。

### 参考文献:

- [1] 王小平,曹立明. 遗传算法——理论、应用与软件实现[M]. 西安:西安交通大学出版社,2002.
- [2] Slotnick S A, Morton T E. Order acceptance with weighted tardiness[J]. Computers and Operations Research, 2008, 36: 1758-1767.
- [3] Berghman L, Goossens D, Leuss R. Efficient solutions for Mastermind using genetic algorithms[J]. Computers and Operations Research, 2008, 36: 1880-1885.
- [4] 玄光南,程润伟. 遗传算法与工程优化[M]. 北京:清华大学出版社,2004.
- [5] 李军华,黎明,袁丽华. 一种改进的双种群遗传算法[J]. 小型微型计算机系统, 2008, 29(11): 2099-2102.

真环境为 Matlab7.1。实验采用分辨率为  $256 \times 256$  和  $512 \times 512$  的脑部 MR 图像,分类数为 4,对应聚类类别数,初始学习率取定为 0.5,实验训练次数均采用 1000 次。分别采用基本 SOFM 和 MWSOFM 两种算法对两种不同分辨率的 MRI 图像做分割。

实验表明,在分辨率为  $256 \times 256$  时,MWSOFM 算法所用时间比基本的 SOFM 算法稍微多点,因为 MWSOFM 算法的复杂度较高(对图像先处理后聚类),而基本 SOFM 算法则是直接对图像进行聚类分析。在分辨率为  $512 \times 512$  时,基本 SOFM 算法的所需分割时间明显增加,但 MWSOFM 分割速度明显加快,这是因为多小波分析可以将高分辨率的图像分解为几个低分辨率图像,从而减少了 SOFM 聚类算法处理的维数,因此在高分辨率下,明显地提高了分割的速度。在不同的分辨率下两种算法时间的对比见表 1。

表 1 两种算法的时间对比表

算法	分辨率	时间(s)
SOFM	$256 \times 256$	19.6213
	$512 \times 512$	102.2225
MWSOFM	$256 \times 256$	21.7705
	$512 \times 512$	34.2454

多小波可以把光滑性、紧支性、对称性等完美结合在一起,而这些特性恰是在图像处理过程中是十分重要的。通过实验可以发现,利用 MWSOFM 算法分割后的图像,无论是在平滑性、细节处理还是在边缘分割方面,都比 SOFM 算法的结果要好,分割的质量和精度都得到了很好的改善。如图 3 至图 5 为实验结果。

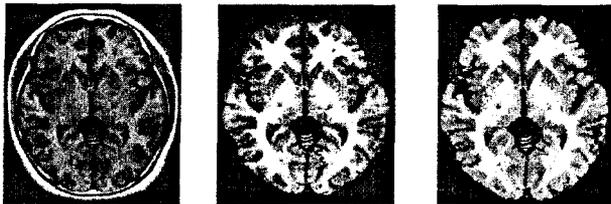


图 3 原始图像 图 4 MWSOFM 分割结果图 图 5 SOFM 分割结果

## 5 结束语

MR 脑图像分割是脑神经科学研究的重要环节,目前还没有彻底解决。由于使用单一的分割方法往往存在这样或那样的不足,因此目前的研究热点趋于将多种方法结合起来。

文中提出了一种基于多小波分析与 SOFM 相结合的 MWSOFM 算法,相对于基本的 SOFM 算法,MWSOFM 算法不但提高了图像的分割精度,而且提高了分割的速度。但是由于 MR 图像的复杂性,图像的特征提取对分割的准确率有很大的影响,因此如何提取更有效的图像特征还需进一步研究。

### 参考文献:

- [1] 田捷,包尚联,周明全.医学影像处理与分析[M].北京:电子工业出版社,2003.
- [2] Li Yan, Chi Zheru. MR Brain Image Segmentation Based on Self-Organizing Map Network[J]. International Journal of Information Technology, 2005, 11(8): 45-53.
- [3] 杨占华,杨燕. SOM 神经网络算法的研究与进展[J]. 计算机工程, 2006, 32(16): 201-228.
- [4] Gafiychuk V V, Datsko B Y, Izmaylova J. Analysis of data clusters obtained by self-organizing methods[J]. Physica A - statistical Mechanics and It's Applications, 2004, 341(10): 547-552.
- [5] Vesanto J, Alhoniemi E. Clustering of the Self-Organizing Map[J]. IEEE Transactions on Neural Networks, 2000, 11(3): 586-600.
- [6] 王斌. 基于 SOFM 神经网络的数字模式识别方法[J]. 微机发展(现更名:计算机技术与发展), 2003, 13(8): 6-7.
- [7] 黄明辉,朱维彰. 基于多小波基维纳滤波图像去噪[J]. 微机发展(现更名:计算机技术与发展), 2004, 14(2): 8-10.
- [8] Strela V, Strang G. The application of multi-wavelet filter banks to image processing[J]. IEEE Trans. Image processing, 1999, 18(4): 548-563.
- [9] Goodman T N T, Lee S L. Wavelets of multiplicity[J]. Trans on Amer Math Soc, 1994, 342: 307-324.

(上接第 103 页)

- [6] 路景,周春燕. 基于遗传算法的混合优化策略研究[J]. 计算机技术与发展, 2007, 17(3): 144-145.
- [7] 刘红,韦穗. 基于遗传算法的布局问题求解[J]. 计算机技术与发展, 2007, 17(1): 74-75.
- [8] 王良俊. 蚁群算法理论、应用及其与其它算法的混合[D]. 南京:南京邮电学院, 2005.
- [9] 吴迪. 蜂群遗传算法的研究[D]. 延吉:延边大学, 2006.
- [10] 熊敏,刘玉树. 基于协同进化遗传算法的地域选取方法

[J]. 计算机技术与发展, 2006, 16(6): 174-176.

- [11] 王凌. 智能优化算法及其应用[M]. 北京:清华大学出版社, 2001.
- [12] 葛继科,邱玉辉,吴春明,等. 遗传算法研究综述[J]. 计算机应用研究, 2008, 25(10): 2911-2915.
- [13] Borisovsky P, Dolgui A, Ereemeev A. Genetic algorithms for a supply management problem: MIP-recombination vs greedy decoder[J]. Science Direct, 2007, 195: 770-779.