

基于可进化性的自适应遗传算法

林明玉, 黎 明, 周琳霞

(南昌航空大学无损检测教育部重点实验室, 南昌 330063)

摘 要: 针对传统遗传算法容易陷入局部最优解的问题, 提出一个基于可进化性的自适应遗传算法。将个体可进化性作为适应度函数的参数加入到随进化代数动态调整的非线性适应度函数中, 动态调整整个种群的交叉与变异概率以逸出局部最优。实验结果表明, 该算法可改善适应度不高但具有较好进化能力个体的生存概率, 且提高了种群多样性与搜索效率。

关键词: 个体可进化性; 自适应遗传算法; 种群多样性

Self-adaptive Genetic Algorithm Based on Evolvability

LIN Ming-yu, LI Ming, ZHOU Lin-xia

(Key Laboratory of Nondestructive Test, Ministry of Education, Nanchang Hangkong University, Nanchang 330063, China)

【Abstract】 Aiming at the problem of traditional genetic algorithm is easy to involve in local optima, this paper presents a self-adaptive genetic algorithm based on evolvability. The individual evolvability as a parameter is put into the nonlinear fitness function which dynamically adjustment with the evolution algebra, and it adjusts dynamically the crossover and mutation probability to runaway the local optima. Experimental results show that this algorithm can improve the survival probability of the individuals with better evolvability but worse fitness, and enhances population diversity and search efficiency.

【Key words】 individual evolvability, self-adaptive Genetic Algorithm(GA); population diversity

1 概述

遗传算法(Genetic Algorithm, GA)存在早熟收敛, 很难逸出局部最优, 导致全局搜索能力不强, 从而产生欺骗问题。如何克服这种欺骗问题, 提高遗传算法的进化能力是目前研究的重要问题之一。许多学者作了大量研究, 提出很多改进思想和方法。文献[1]针对自然选择的不足提出基于可进化性而不是适应度的选择准则。文献[2]针对欺骗问题提出自适应遗传算法。Goldberg D E 和 Richardson J 利用共享函数提出共享策略。Grefenstette J J 提出在每一代种群中部分个体被随机产生的个体所替代的随机移民遗传算法以及 Branke J 提出多种种群策略。自然界的生物群体能否逐步进化到优良个体源于种群的进化能力, 而个体的可进化性是群体进化性的原动力。生物进化的速度取决于种群中个体的可进化性的强弱, 因此如何充分发挥和引导这些可进化性强的个体, 加快算法的收敛速度和收敛精度, 从而增强算法的进化能力就是本文需要解决的问题。本文基于自适应算法思想, 引入个体可进化性^[1]的 2 个定义, 充分重视个体的可进化性, 并对可进化性强的个体的适应度加以引导, 提出一种基于可进化性的自适应遗传算法。

2 基于可进化性的自适应遗传算法

2.1 个体可进化性

在生物学领域, 认为个体可进化性是可选择的特征^[2-3]; 在计算机科学, 认为个体可进化性是一个体产生适应变种的能力, 即个体产生较群体中其他个体更优的个体的能力, 这体现了个体改进自身适应度的能力^[4-5]。个体的可进化性是在进化历史中体现的属性, 下文给出个体可进化性的 2 个定义的数学公式:

$$e1(i) = \max(HD(i, m)/l, HD(i, b)/l) \quad (1)$$

$$e2(i) = \max((f(i) - f(m))/f(m), (f(i) - f(b))/f(b)) \quad (2)$$

其中, i 代表当前种群个体; m 、 b 分别为前代种群 i 对应的父代; l 为个体基因型的串长; $HD(i, m)$ 为个体 i 和 m 的海明距离; $f(i)$ 为个体 i 的适应度值; $e1(i)$ 、 $e2(i)$ 分别为个体 i 基于基因改变、适应度改变的个体可进化性。

2.2 基于可进化性的适应度函数

适应度函数的选取是至关重要的, 直接影响遗传算法的收敛速度以及能否找到最优解。一般, 适应度函数仅与目标函数有关而不涉及其他相关信息, 如历史的适应度值、进化代数、个体可进化性等。本文认为个体的适应度值不是唯一只与它的目标函数值有关, 也与种群中个体的可进化性大小有关, 当前种群个体的适应度值由原适应度值的基础上加上个体的可进化性的大小决定。因此, 本文设计的适应度函数^[6]是在一种非线性动态适应度函数的基础上引入个体进化性, 其具体函数表示如下:

$$f' = (f + p \times e1 + (1 - p) \times e2) \times \sqrt[M]{gen} \quad (3)$$

其中, p 为在 0~1 之间的参数; f 为目标函数; $e1$ 、 $e2$ 分别为基于基因改变、适应度改变的 2 类个体可进化性; gen 为当前的进化代数; $M = \ln(N) + 1$, N 为算法最大的进化代数。

2.3 自适应的交叉概率与变异概率

本文基于文献[2]的自适应思想, 依据适应度平均值、最

基金项目: 国家自然科学基金资助项目“动态环境下的元胞遗传算法”(60963002); 航空科学基金资助项目“基于图像处理与模式识别技术的疲劳断裂测试与分析”(2008ZD56003)

作者简介: 林明玉(1983 -), 女, 硕士研究生, 主研方向: 图像处理, 模式识别; 黎 明, 教授、博士、博士生导师; 周琳霞, 副教授

收稿日期: 2010-04-23 **E-mail:** linmingyu2007@163.com

大值和最小值 3 个变量衡量种群适应度的集中程度，定义交叉、变异概率：

$$P_c = \begin{cases} pc \times \frac{favg}{fm - fn} & \frac{fm - favg}{fm - fn} > a \text{ 并且 } \frac{fn}{fm} > b \\ pc & \text{其他情况} \end{cases} \quad (4)$$

$$P_m = \begin{cases} pm \times \frac{favg}{fm - fn} & \frac{fm - favg}{fm - fn} > a \text{ 并且 } \frac{fn}{fm} > b \\ pm & \text{其他情况} \end{cases} \quad (5)$$

其中， pc 、 pm 为给定的交叉、变异概率； P_c 、 P_m 为自适应交叉、变异概率； fm 、 $favg$ 、 fn 为适应度的最大值、平均值和最小值； a 、 b 为参数， a 在 0.5~1.0 之间、 b 在 0~1 之间； P_c 、 P_m 在 0~1 之间。

2.4 算法基本步骤

本文在改进适应度函数、交叉概率和变异概率的同时应用最优保留策略，其具体步骤如下：

Step1 产生初始种群，进行一次遗传操作；

Step2 依式(1)和式(2)计算种群个体的可进化性；

Step3 依式(3)计算种群适应度，保留最佳个体；

Step4 依式(4)、式(5)计算自适应交叉、变异概率，并依其值做遗传操作；

Step5 计算目标函数值，找到当前最佳个体和最劣个体；

Step6 若当前群体最佳个体的目标函数值比总的迄今为止的最好个体的目标函数值还高，则当前群体中的最佳个体为新的迄今为止的最好个体；

Step7 用迄今为止的最好个体替换当前群体中的最差个体；

Step8 判断是否满足算法终止条件，若满足，则输出搜索结果；否则 $gen=gen+1$ ，返回 Step2。

3 实验仿真

3.1 问题描述

数学函数优化问题是遗传算法测试性能的常用方法，具有一定的实际效能，能直观地体现算法的优化特性，本文选取以下 2 个实验函数，其具体表示如下：

(1)Shubert 函数 $F1$

Shubert 函数 $F1$ 是一个多峰值函数，在定义域内总共有 760 个局部最小点，其中，18 个点为全局最小点，理论最小值为 $f(-1.425\ 13, -0.800\ 32) = -186.731$ ，局部最小值为 -186.34，其具体形式为：

$$\begin{cases} F1: f(x_1, x_2) = \sum_{i=1}^5 i \cos[(i+1)x_1 + i] \times \sum_{i=1}^5 i \cos[(i+1)x_2 + i] \\ -10 \quad x_i \quad 10(i=1, 2) \end{cases}$$

(2)De Jong 函数 $F2$

De Jong 函数 $F2$ 是病态的二维函数，难以进行全局极小化，具有一个全局极小点 $f(1,1) = 0$ ，其具体形式为：

$$\begin{cases} F2: f(x_1, x_2) = 100 \times (x_1^2 - x_2)^2 + (1 - x_1)^2 \\ -2.048 \quad x_i \quad 2.048(i=1, 2) \end{cases}$$

3.2 实验结果与分析

本文通过对 2 个典型函数进行 100 次寻优计算，在全局收敛率、平均最佳值、最佳最优值等方面对本文算法与基本遗传算法(Simple Genetic Algorithm, SGA)、MGA 算法^[7]、AGA 算法^[8]以及随机移民算法(Random Immigrant Genetic Algorithm, RIGA)的寻优性能进行比较。对每一个目标函数设置一个阈值作为其收敛准则，当种群存在个体目标值大于该

阈值时，认为该算法达到全局收敛，此次寻优结束。全局收敛率是指算法达到全局收敛的次数相对于重复做优化实验的次数(100 次)的比值。平均最优值是在达到全局收敛条件时最优值的平均值。最佳最优值是达到全局收敛条件的最好的最佳值。在 4 种算法中使用二进制编码和轮盘赌选择法，单点交叉率为 0.7、种群大小为 50、最大遗传代数 300、变量二进制位数为 25。4 种算法的实验仿真结果见表 1。

表 1 4 种算法的试验仿真结果

测试函数	算法	收敛阈值	全局收敛率/(%)	平均最佳值	最佳最优值
F1	SGA	-186.6	2	-186.653	-186.694 1
	MGA	-186.6	6	-186.679	-186.730 4
	AGA	-186.6	6	-186.669	-186.730 3
	RIGA	-186.6	17	-186.699	-186.728 6
	本文算法	-186.6	24	-186.685	-186.730 7
F2	SGA	0.001	-	-	-
	MGA	0.001	11	5.968 4e-4	1.041 4e-5
	AGA	0.001	12	5.969 8e-4	2.285 4e-5
	RIGA	0.001	19	5.235 4e-4	6.767 1e-5
	本文算法	0.001	21	5.107 1e-4	8.856 4e-6

从表 1 可以看出，在相同实验条件下，本文算法收敛率是最高的，且最佳最优值是最好的。可见，本文算法收敛到最优解的效果最好，改善了遗传算法的性能。

种群的多样性是有效搜索整个可行空间的必要条件，本文所用的种群多样性是用基因内部多样性来度量的，它表明种群在该基因位的收敛程度，代表了遗传漂移的程度，是衡量算法进化能力强弱的重要尺度。其范围在 0~0.25 之间，值越大，表示当前代种群的多样性越好，具有越强的进化能力。 $F1$ 函数的最佳最优值比较如图 1、图 2 所示。




图 1 $F1$ 函数的最佳最优值比较 1




图 2 $F1$ 函数的最佳最优值比较 2

从图 1、图 2 可看出，在 $F1$ 函数运行中本文算法的有效性和可行性，其最佳最优值好于其他 4 种算法。对 $F2$ 函数最佳最优值的比较，用图形说明不能直观看出本文算法优于其

他算法,在此选用在进化过程中各算法最佳最优值精度改变时进化代数值的的具体数据说明。在SGA算法中,第8代的最优值为0.027,到第15代改变为0.021至进化结束,陷入局部最优解。在MGA算法中,第13代为0.014,第143代改变为0.011,第161代为0.008,至第190代为0.000473。在AGA算法中,第9代达到0.025,此后发生很小范围的递减,但是不明显,最终达到0.019。在MIGA算法中,第47代达到0.015,此后变化就不明显,陷于局部最优。在本文算法中,在第23代达到0.0108,第36代为0.00478。虽然MGA算法的收敛精度以及达到的数量级与本文算法相差不多,但是MGA的收敛速度比本文算法差。MIGA算法与本文算法相差不是很大,但在平均值、最佳值性能方面劣于本文算法。通过以上分析说明本文算法的有效性和可行性。

为使算法的种群多样性对比更明显,本文将SGA、MGA、AGA和RIGA分别与本文算法进行比较,见图3~图6。




图3 F1多样性比较1




图4 F1多样性比较2




图5 F1多样性比较3




图6 F1多样性比较4

从图3~图6可以看出,在F1函数运行中,本文算法相比其他4种算法,具有更优的多样性。同样运行F2函数可以得到相同的结论,限于篇幅,在此不一一列出具体的图形。通过图3~图6可以看出,本文算法在整个进化过程处于一种很小的波动范围,基本维持在0.24~0.25之间,即具有很强的进化能力。其原因是本文算法在种群中个体过于集中时加大了算法的交叉率和变异率,降低了适应度不高但具有较好进化能力的个体的生存压力,从而提高种群的多样性与搜索能力。

4 结束语

本文引入个体可进化性的2个定义,将其运用到算法中,从个体历史属性的角度,改善个体适应度不高但具有较好进化能力的个体的生存压力,使种群多样性在整个进化过程中保持稳定。今后要进一步研究如何利用个体可进化性提高种群的进化能力。

参考文献

- [1] Wang Yao, Wineberg M. The Estimation of Evolvability Genetic Algorithm[J]. IEEE Trans. on Evolutionary Computation, 2004, 5(2): 2302-2309.
- [2] Srinivas M, Patnaik L M. Adaptive Probabilities of Crossover and Mutation in Genetic Algorithms[J]. IEEE Trans. on Systems, Man and Cybernetics, 1994, 24(4): 175-181.
- [3] Earl D J, Deem M W. Evolvability Is a Selectable Trait[J]. Proceedings of the National Academy of Sciences, 2004, 101(32): 111531-111536.
- [4] 何大阔, 王福利. 基于可进化性的快速遗传算法[J]. 东北大学学报: 自然科学版, 2002, 23(7): 628-631.
- [5] Turney P D. Increasing Evolvability Considered as a Large-scale Trend in Evolution[C]//Proc. of 1999 Genetic and Evolutionary Computation Conference on Evolvability. Orlando, Florida, USA: [s. n.], 1999.
- [6] 李 婷, 崔杜成. 基于规则归纳的遗传算法选择和参数设置[J]. 计算机工程, 2010, 36(3): 218-221.
- [7] 张思才, 张方晓. 一种遗传算法适应度函数的改进方法[J]. 计算机应用与软件, 2006, 23(2): 108-110.
- [8] 王 蕾, 沈庭芝, 招 扬. 一种改进的自适应遗传算法[J]. 系统工程与电子技术, 2002, 24(5): 75-78.

编辑 陆燕菲