

# 用适应值激励机制提高遗传算法的效率\*

林 丹 李敏强 寇纪淞  
(天津大学系统工程研究所 300072)

**摘 要** 分析了传统遗传算法作为函数优化器在宏观进化机制上的局限性,讨论了群体的可进化性在函数优化中的作用。在此基础上提出在遗传算法中引入适应值激励机制,用它来动态地提高群体的可进化性。数值实验表明,带有适应值激励机制的改进遗传算法的搜索效率得到很大提高。

**关键词** 遗传算法,可进化性,适应值激励机制

**分类号** TP 18

## Improving the Efficiency of Genetic Algorithms by Using Fitness Stimulating Mechanism

Lin Dan, Li Minqiang, Kou Jisong  
(Tianjin University)

**Abstract** The limitations of GAs as function optimizers are analyzed and the important role of evolvability during the evolutionary process is discussed. Then the fitness stimulating mechanism is introduced into GAs to dynamically improve the evolvability of the population under the general genetic operators. Experimental results show that GAs with fitness stimulating mechanism greatly improve the efficiency compared with conventional GAs.

**Key words** genetic algorithm, evolvability, fitness stimulating mechanism

## 1 引 言

用遗传算法作为函数优化器来求解具有连续变量的目标函数的全局优化问题

$\max f(x), x \in S \subseteq R^n$  ( $S$  为搜索区域) (1) 是遗传算法研究和应用领域中倍受关注的课题之一。与传统的基于梯度的优化方法不同,遗传算法不要求  $f(x)$  是可微的,并且能以较大的概率找到全局最优解,因此得到了广泛的应用。

当用遗传算法作为函数优化器时,存在搜索效率低下的严重缺陷。亦即遗传算法搜索到最优解或满意解的速度太慢,同时经常伴有早熟收敛现象。因此,提高遗传算法的优化效率具有重要的理论和实际意义。

## 2 提高遗传算法效率的途径

提高遗传算法效率的途径之一是将所优化问题的特定性质(如梯度)与遗传算法本身结合起来,用这些性质帮助遗传算法加快搜索的进程<sup>[1]</sup>。但是这种途径往往不具备一般性。

具有一般性的改进工作包括<sup>[2]</sup>: 1) 改变编码方式,直接采用实数(浮点)编码表示; 2) 改变选择方法,采用如竞争选择方法等来代替比例选择方法; 3) 采用动态改变的遗传操作参数。这些改进工作都取得了一定的效果。

遗传算法不是为了解决任何特定问题而设计的。当面临不确定性时,优化一个序贯的决策过程是对传统遗传算法最好的行为描述,它所强调的是群体的平均适应值的改进<sup>[3]</sup>。而函数优化器的目标是使用合理的计算资源找到最优解或满意解,对其效

\* 国家自然科学基金项目(69974026)

率的评价标准是在给定的计算资源内, 所找到最优解的质量和搜索到满意解所消耗的计算资源的数量。对于用作函数优化器的遗传算法而言, 应更多地强调其群体中最优个体的进化能力和速度。传统遗传算法的进化机制所要达到的目标与作为函数优化器的目标是不一致的, 这种宏观进化机制与进化目标之间的一致性, 是造成遗传算法效率低下的一个重要原因, 因此, 要提高遗传算法作为函数优化器的效率, 必须对遗传算法本身的机制进行改造, 而这一点在目前已有的工作中尚未涉及。

### 3 群体的可进化性和适应值激励机制

群体的可进化性 (evolvability)<sup>[4]</sup> 是一个进化生物学概念, 指的是一个生物群体产生比群体中所有现存个体更好的子个体的能力。显然, 可进化性对于生物进化的适应过程是必需的, 这种适应性依赖于子代好于父代的频度, 也依赖于子代比父代好的程度。类比到遗传算法中, 可进化性意味着一个群体在一定的表示模式下, 通过交叉和变异算子的作用产生比其父代更好的子代的能力。可进化性强调的是群体中好的个体产生更好个体的能力, 而不是群体的平均适应值。例如当早熟收敛现象发生时, 如果只考虑交叉算子, 则群体的可进化性将完全丧失, 而此时群体的平均适应值却比较好。

从函数优化器的角度看, 可以将可进化性作为用遗传算法求解优化问题(1)时表现的某种度量。函数优化器所强调的群体中单个最优个体的进化能力可由群体的可进化性来保证。遗传算法就是依靠保持群体的可进化性使得群体向着最优解进化, 群体的可进化性越强, 进化到最优解的可能性就越大, 速度也越快。因此, 通过提高群体的可进化性, 有助于使遗传算法的进化机制, 从传统的强调群体平均适应值转变到强调群体中单个最优个体的进化能力上, 从而使改造后的遗传算法作为函数优化器的效率得以提高。

由于遗传算法中的选择方式是定向的, 即偏好于比平均值更高的个体, 所以这种更多父个体产生更好子个体的可进化性, 应仅对那些高于平均值的个体有所要求, 而对低于平均值的较差个体则不做考虑。

鉴于可进化性的重要性, 我们在遗传算法中引入适应值调整策略, 以提高群体在交叉和变异算子

作用下的可进化性。其具体实施过程如下:

对任一进化代  $gen$ , 在交叉或变异算子操作后产生的群体  $P(gen)$  和  $P(gen)$  中, 首先考虑其中适应值在群体平均适应值以上的新生成的子个体。假如子个体  $p$  是由两个父个体  $p_1, p_2$  通过交叉产生的,  $p$  的原适应值为  $f(p)$ , 则采用适应值激励机制后,  $p$  的激励后适应值计算如下

$$stim(p) = \max(\min(f(p) - f(p_1), f(p) - f(p_2)), 0) \quad (2)$$

$$f(p) = f(p) + s(gen)stim(p) \quad (3)$$

同理, 当子个体  $p$  是由父个体  $p$  通过变异而产生时, 则  $p$  的激励后适应值  $f(p)$  计算如下

$$stim(p) = \max(f(p) - f(p), 0) \quad (4)$$

$$f(p) = f(p) + s(gen)stim(p) \quad (5)$$

式(3)和(5)中的  $s(gen)$  表示随着进化代数  $gen$  而改变的激励因子。

对于  $P(gen)$  中适应值低于群体平均值的新一代个体和所有直接复制(不是由交叉产生)的个体, 规定

$$f(p) = f(p) \quad (6)$$

对于  $P(gen)$  中适应值低于群体平均值的新一代个体和直接复制(不是由变异产生)的  $P(gen)$  中原有个体, 其激励后适应值也按式(6)计算。对于适应值高于群体平均值的所有直接复制的  $P(gen)$  中原有个体, 其激励后适应值仍为其作为  $P(gen)$  成员时根据式(3)或(6)计算所得值。

适应值调整策略是通过动态地提高那些具有可进化性的较好(在群体平均适应值之上)个体的适应值, 以增加它们在下一代群体中的生存机会, 从而达到激励提高群体可进化性的目的, 因此称这种适应值调整策略为适应值激励机制。从以上公式可以看出, 这种激励机制能提高群体的可进化性, 并能在一定程度上防止早熟收敛。

引入适应值激励机制后的遗传算法, 求解优化问题(1)的步骤可描述如下:

- 1) 确定要采用的各种遗传算子及参数值, 包括确定激励因子;
- 2) 代数  $gen = 0$ , 随机生成初始化群体  $P(0)$ , 计算每个个体  $p$  的适应值  $f(p)$ , 并且令  $f(p) = f(p)$ ;
- 3)  $gen = gen + 1$ ;
- 4) 根据个体的激励后适应值  $f(p)$ , 从  $P(gen - 1)$  中选出群体  $P(gen)$ ;
- 5) 对  $P(gen)$  中的个体进行交叉操作产生

$P(\text{gen})$ , 计算生成的子个体的适应值以及  $P(\text{gen})$  的群体平均适应值, 并计算  $P(\text{gen})$  中每个个体的激励后适应值;

6) 对  $P(\text{gen})$  中的个体进行变异操作产生下一代群体  $P(\text{gen})$ , 计算生成的子个体的适应值以及  $P(\text{gen})$  的群体平均适应值, 并计算  $P(\text{gen})$  中每个个体的激励后适应值;

7) 如果终止条件不满足, 则返回 3)。

引入适应值激励机制后的遗传算法, 需要分别计算  $P(\text{gen})$  和  $P(\text{gen})$  中个体的适应值, 但由于对  $P(\text{gen})$  中直接由  $P(\text{gen})$  复制下来的个体不需要再次计算适应值, 因此在变异概率较小时, 与传统遗传算法相比所增加的计算量是不多的。

### 4 数值实验

选择球函数  $f_1$  和 Ackley 函数  $f_2$  作为测试函数, 其具体定义为

$$f_1: f_1(x) = \prod_{i=1}^n x_i^2$$

其中  $x = (x_1, \dots, x_n) \quad [-100, 100]^n$ 。

$$f_2: f_2(x) = 20 + e - 20 \exp \left[ -0.2 \left( \frac{1}{n} \sum_{i=1}^n x_i^2 \right) \right] - \exp \left[ \frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i) \right]$$

其中  $x = (x_1, \dots, x_n) \quad [-30, 30]^n$ 。

这两个函数都在  $x = (0, 0)$  处取得全局最小值 0, 其中  $f_1$  是单峰函数,  $f_2$  是具有大量局部最优点的多峰函数。在下面的实验中, 对每个函数都取维数  $n = 30$ 。

采用基于浮点编码的遗传算法求解以上问题, 群体大小设为 200, 使用 BLX-0.5 交叉算子 ( $p_c$  为 0.35), arithmetic 和 heuristic 交叉算子 ( $p_c$  均为 0.08), uniform, boundary 和 multinonuniform 变异算子 ( $p_m$  均为 0.08)<sup>[5]</sup>, 激励因子设置为  $s(t) = \lg(t + 10)$ 。采用竞争规模为 5 的竞争选择方法, 并采用单个个体的精英保留策略。对每一个函数, 分别用带有适应值激励机制的遗传算法 (GA1) 和普通遗传算法 (GA2) 进行 20 次实验, 在每次实验中, 当已进行了 10 万次适应值函数计算时则终止。另外, 定义满意解为适应值小于  $10^{-4}$  的解。

图 1 和图 2 分别给出了用 GA1 和 GA2 优化函数  $f_1$  和  $f_2$  时, 适应值函数计算次数与完成该数目的

适应值计算所找到的最优 (最小) 适应值的关系。其中虚线为 GA1 方法, 实线为 GA2 方法。所有计算结果都是 20 次实验的平均值。




图 1 用两种遗传算法求解  $f_1$




图 2 用两种遗传算法求解  $f_2$

$f_1$  是一个单峰函数, 从某种意义上说, 求解该问题能反映出算法的局部搜索能力。从图 1 可以看出, 在给定的 10 万次适应值函数计算内, 用 GA1 找到的最优解的质量明显好于 GA2, 并且搜索到满意解的速度有了很大的提高 (计算次数约少 4.8 万次)。这反映出采用适应值激励机制能够提高算法的局部搜索能力。

对于多峰函数  $f_2$ , 实验结果与  $f_1$  类似。在给定的适应值函数计算次数内, GA1 找到最优解的质量明显好于 GA2, 找到满意解的速度也有了大幅度的提高。值得注意的是, 用 GA2 求解  $f_2$  时, 在 20 次实验中有 11 次未找到满意解, 其中 5 次发生早熟收敛; 而采用 GA1 求解时, 20 次实验全部找到满意解。这说明采用适应值激励机制能在一定程度上防止早熟收敛现象。

### 5 结 语

本文通过引入适应值激励机制来提高群体的可进化性, 以此对传统遗传算法进行改造, 使之更适合于作为函数优化器。数值实验表明, 采用适应值激励机制可以大大提高遗传算法的优化效率。

(下转第 768 页)

水平也必须随之变化,这样才能适应新的要求。评价决策模型也应具有动态可变性,否则做出的评价就失去了其辅助决策的意义。小波神经网络的动态可变性恰好适应于这种需要。

2) 小波神经网络能包含位于不同类型变量空间中的变量。当两类不同性质的属性进行比较时,往往很难判断它们之间的相对重要性,更难于定量表达;对于同一属性的不同属性值,可以通过比较得出其隶属度或根据归纳的隶属度函数计算出其隶属度。网络通过实例的学习来获取知识,由于抽象性,使得小波神经网络成为一个模拟人脑思维的“黑箱”。

3) 小波神经元及整个结构的确定有可靠的理论依据,可避免BP网络等结构设计的盲目性。由于小波神经元的低相关性,使得小波网络有更快的收敛速度。

## 参考文献

- 1 Zhang Q, Benvenise A. Wavelet network. IEEE Trans on Neural Network, 1992, 3(6): 889 ~ 898
- 2 Delyon B, Juditsky A, Benveniste A. Accuracy analysis for wavelet approximations. IEEE Trans on Neural Network, 1995, 6(2): 332 ~ 348
- 3 丁宇新,沈雪勤. 基于能量密度的小波神经网络. 计算机学报, 1997, 20(9): 832 ~ 838
- 4 陈湛匀. 现代决策分析概论. 上海: 上海科学技术出版社, 1991
- 5 王应明. 运用无限方案多目标决策方法进行有限方案多目标决策. 控制与决策, 1993, 8(1): 25 ~ 29
- 6 樊治平. 多属性决策的一种新方法. 系统工程, 1994, 12(1): 15 ~ 17

## 作者简介

宋如顺 男, 1957年生。南京师范大学计算机系副教授。主要学术方向为决策支持系统和计算机网络安全控制与决策。

(上接第761页)

## 参考文献

- 1 赵明旺. 连续可微函数全局优化的混合遗传算法. 控制与决策, 1997, 12(5): 589 ~ 592
- 2 李敏强, 张志强, 寇纪淞. 关于杂合遗传算法的研究. 管理科学学报, 1998, 1(1): 64 ~ 68
- 3 De Jong K. Are genetic algorithms function optimizers. In: Parallel Problem Solving from Nature 2. Amsterdam: Elsevier, 1992. 3 ~ 13
- 4 Michalewicz Z. Genetic algorithms + Data structures = Evolution programs. 3rd Edition. New York: Springer, 1996
- 5 Altenberg L. The evolution of evolvability in genetic programming. In: Genetic Programming. Cambridge:

The MIT Press, 1994. 47 ~ 74

## 作者简介

林丹 男, 1968年生。1995年于南开大学获硕士学位, 现为天津大学数学系讲师, 在职博士生。研究方向为进化计算。

李敏强 男, 1965年生。天津大学系统工程研究所教授。研究方向为系统工程与信息系, 机器学习与人工智能, 数据库与知识发现。

寇纪淞 男, 1947年生。天津大学副校长, 教授, 博士生导师。研究方向为管理科学, 系统决策, 计算机工程, 人工智能。

(上接第764页)

- 5 A L Fradkov, A Yu Pogromsky. Introduction to control of oscillations and chaos. Singapore: World Scientific, 1999
- 6 Thomas L Vincent. Control using chaos. IEEE Control Systems, 1997, 65 ~ 76
- 7 F J Romeiras, C Grebogi, E Ott *et al.* Controlling chaotic dynamical systems. Physica D, 1992, 58: 165 ~ 192

## 作者简介

卢俊国 男, 1975年生。南京理工大学自控系博士生。研究方向为非线性控制理论与应用, 神经网络, 混沌控制等。

汪小帆 男, 1967年生。南京理工大学自控系副教授。研究方向为非线性控制理论与应用, 混沌控制等。

王执铨 男, 1939年生。1962年毕业于哈尔滨军事工程学院, 现为南京理工大学自控系教授, 博士生导师。目前研究方向为高精度数字伺服系统, 智能控制, 容错控制等。