

文章编号: 1001-0920(2004)11-1290-04

一类带筛选策略的改进遗传算法及其性能分析

王 凌, 黄 璇, 郑大钟
(清华大学 自动化系, 北京 100084)

摘 要: 为避免遗传算法的早熟收敛, 增强算法的全局搜索和局部趋化能力, 在传统保优 GA 中引入筛选策略, 即基于种群性能和种群地域差别删去一些性能相对差的冗余个体, 进而维持种群的多样性. 基于典型复杂函数的数值仿真结果表明, 所提算法的全局收敛速度和命中全局最优的几率相对传统方法大大提高, 并对参数具有较好的鲁棒性.

关键词: 遗传算法; 筛选策略; 性能分析

中图分类号: TP18 **文献标识码:** A

A class of improved genetic algorithm with sifting strategy and its performance analysis

WANG Ling, HUANG Xuan, ZHENG Da-zhong

(Department of Automation, Tsinghua University, Beijing 100084, China Correspondent: WANG Ling, E-mail: wangling@tsinghua.edu.cn)

Abstract To avoid premature convergence of genetic algorithm (GA) and to enhance the exploration and exploitation abilities, the sifting strategy is incorporated into classic elitist GA to maintain the population diversity. That is, some bad redundant individuals are deleted from the population according to the difference of population performance and location. Numerical simulation results based on benchmark complex functions show that the convergence rate and hitting probability on global optima of the proposed algorithm are greatly better than that of the classic method, and the improved algorithm is robust on its parameters as well.

Key words: genetic algorithm; sifting strategy; performance analysis

1 引 言

遗传算法是一类基于“优胜劣汰”思想的群体并行搜索算法, 目前已在诸多领域得到广泛应用^[1,2]. 但经研究表明, 若算法结构、操作和参数设计不合理, 则易产生早熟收敛. 因此, GA 研究的重点在于如何避免早熟收敛及均衡 GA 的全局搜索和局部趋化能力^[1-5]. 迄今已提出许多改进策略, 譬如参数自适应、混合或并行 GA 算法^[4-7]. GA 早熟收敛的原因本质上可归结为遗失种群多样性, 因此本文引入筛选策略以维持种群多样性, 即基于种群性能差别

和种群地域差别删去一些性能相对差的冗余个体. 基于典型函数的仿真表明, 本文算法的全局收敛速度和命中全局最优解的几率均好于传统方法, 且对参数具有较好的鲁棒性.

2 筛选策略

为衡量种群的多样性, 给出如下定义:

定义 1 定义种群性能分散度为 $D(f(X_1), \dots, f(X_N))$, 即种群 $P = \{X_1, X_2, \dots, X_N\}$ 中各个体性能的方差

定义 2 定义种群地域分散度为 $E(X_1, \dots, X_N)$

收稿日期: 2004-01-11; 修回日期: 2004-03-12

基金项目: 国家自然科学基金资助项目(60204008, 60374060); 973 计划资助项目(2002CB312200).

作者简介: 王凌(1972—), 男, 江苏武进人, 副教授, 博士, 从事优化理论与方法的研究; 黄璇(1982—), 女, 江西临川人, 硕士生, 从事优化方法、供应链问题的研究

$G, \dots, X_N - G$), 其中: $G = E(X_1, \dots, X_N)$ 为种群的重心, 定义欧氏距离

基于二维 Rosenbrock 函数

$$f(x_1, x_2) = 100(x_2 - x_1^2)^2 + (1 - x_1)^2$$

对标准保优遗传算法(SGA)^[1,2]的研究表明, SGA 进化过程中性能分散度和地域分散度急剧下降(限于篇幅略去相关曲线), 种群过早缺乏多样性, 即为早熟现象. 由此, 本文引出如下基于分散度的筛选策略:

首先设置最小种群性能差别 ϵ , 即种群中任意两个个体适配值差值允许的下限, 设置最小种群地域差别 σ , 即种群中任意两个个体地域差值允许的下限. 所谓基于性能差别的筛选策略, 即将所有个体按性能由好到坏依次以最小种群性能差别 ϵ 为阈值删除性能上邻近的不良个体. 基于地域差别的筛选策略, 就是将所有个体按性能由好到坏依次以最小种群地域差别 σ 为阈值删除地域上邻近的不良个体. 显然通过上述筛选策略, 种群中一些性能和地域上存在一定冗余性的不良个体将被淘汰, 而用随机新个体进行补充, 如此既可保持种群的最优性能, 又可增强种群的多样性, 有利于进一步进化搜索.

3 带筛选策略的改进 GA

3.1 算法描述

相比 SGA^[1,2], 带筛选策略的改进 GA (记作 IGA) 在遗传操作后依次进行基于 ϵ 和 σ 的筛选, 再采用随机产生的新个体补充所删除的不良冗余个体. 其步骤如下:

Step 1: 随机产生初始种群 $P = \{X_1, X_2, \dots, X_N\}$, 计算各个体 $X_i = [x_{i,1}, \dots, x_{i,n}]$ 的适配值;

Step 2: 根据适配值大小按轮盘赌方式执行比例复制;

Step 3: 按交叉概率 p_c 和变异概率 p_m 分别对所得个体执行如下算术交叉操作和高斯变异操作:

$$x_{i,j} = \alpha_j x_{i,j} + (1 - \alpha_j) x_{k,j}, \alpha_j \in (0, 1); \quad (1)$$

$$x_{i,j} = x_{i,j} + Q \cdot 2\xi_{i,j}, \xi_{i,j} \sim N(0, 1). \quad (2)$$

进而得到后代 $O = \{X_{N+1}, \dots, X_{2N}\}$.

Step 4: 对种群 $P \cup O$ 进行基于性能差别的筛选, 即按个体性能好坏顺序依次删掉不满足 $|f(X_i) - f(X_j)| \geq \epsilon$ 的个体, 并随时按尺度放大动态调整 ϵ (见后文), 记剩余个体构成的种群为

$$P = \{X \mid X \in P \cup O, \text{ and } \forall i, j, |f(X_i) - f(X_j)| < \epsilon\}.$$

Step 5: 对 P 进行基于地域差别的筛选, 即按个

体性能好坏顺序依次删掉不满足 $|X_i - X_j| \geq \sigma$ (在此令 $|X_i - X_j| = \max\{|x_{i,k} - x_{j,k}|\}$) 的个体, 并随时按尺度放大动态调整 σ (见后文), 得到种群

$$P = \{X \mid X \in P \cup O, \forall i, j, |f(X_i) - f(X_j)| < \epsilon, |X_i - X_j| < \sigma\}.$$

Step 6: 若种群 P 包含多于 N 个个体, 则取其中 N 个最好个体为下一代种群 P ; 否则, 对 P 随机补充一定数量的新个体, 使其成为包含 N 个个体的下一代种群 P .

Step 7: 若算法满足终止准则, 则输出结果; 否则, 按尺度收缩调整 ϵ 和 σ (见后文) 并转 Step 2.

可见, 改进算法增加了筛选环节和新个体增添环节, 尽管相对 SGA 增加了部分计算量, 但克服了因遗失种群分散性所造成的早熟收敛的缺点. 根据文献[8]的讨论, 若遗传操作可实现最优解的可达性且带保优环节, 则改进的 GA 理论上仍具有全局收敛性.

3.2 参数尺度收缩和尺度放大

增加筛选策略的目的主要是增强种群多样性. 由模拟退火算法^[2]知, 初温越大越有利于状态的全局大范围迁移, 也有利于避免算法陷入局部极小. ϵ 和 σ 越大, 算法对种群个体的分散度要求越高, 则更多的冗余个体将被淘汰. 但增加种群多样性必然降低算法的趋化能力. 在进化过程的前期主要目的是增加种群多样性, 此时 ϵ 和 σ 可大些, 而到进化过程的后期 ϵ 和 σ 应适当变小以增加趋化性搜索能力. 因此, 类似于 SA 算法的降温过程^[2], 在进化过程中对 ϵ 和 σ 进行如下的“尺度收缩”:

$$\epsilon_{k+1} = \lambda_1 \epsilon_k, 0 < \lambda_1 < 1; \quad (3)$$

$$\sigma_{k+1} = \lambda_2 \sigma_k, 0 < \lambda_2 < 1. \quad (4)$$

其中: λ_1 和 λ_2 分别为 ϵ 和 σ 的收缩因子, ϵ_k 和 σ_k 分别为算法第 k 代进化中允许的最小种群性能差别和最小种群地域差别.

每一代的筛选过程是按个体性能由好到坏依次根据性能差别或地域差别淘汰个体的, 如果筛选时的差别阈值自适应增大, 将使淘汰性能差的个体的可能大于淘汰性能相对优良的个体, 则较差个体保留的比例相对较少, 有利于种群整体向更优进化. 因此, 在每一代的筛选过程中设计如下参数的“尺度放大”:

$$\begin{cases} \epsilon_k(1) = \epsilon_k, \\ \epsilon_k(i+1) = \mu_1 \epsilon_k(i), i = 1, 2, \dots; \mu_1 > 1. \end{cases} \quad (5)$$

$$\begin{cases} \sigma_k(1) = \sigma_k, \\ \sigma_k(i+1) = \mu_2 \sigma_k(i), i = 1, 2, \dots; \mu_2 > 1. \end{cases} \quad (6)$$

其中: μ_1 和 μ_2 分别为 ϵ_k 和 σ_k 对应的放大因子, $\epsilon_k(i)$ 和 $\sigma_k(i)$ 分别为算法第 k 代进化中第 i 次删除个体时的性能差别阈值和地域差别阈值

4 数值仿真和比较

选取如下 3 个典型复杂函数^[1,2,9] 对本文算法进行数值仿真和算法比较:

$$\max f_1 = [\sin(2x) + \cos(5x)]^3, \quad x \in [0, 9]; \quad (7)$$

$$\min f_2 = \frac{\sin^2 \sqrt{x_1^2 + x_2^2} - 0.5}{[1 + 0.001(x_1^2 + x_2^2)]^2} - 0.5, \quad x_i \in [-4, 4]; \quad (8)$$

$$\min f_3 = \sum_{i=1}^5 i \cos((i+1)x_1 + i) \times \sum_{i=1}^5 i \cos((i+1)x_2 + i), \quad x_i \in [-10, 10] \quad (9)$$

设置 SGA 和 IGA 的种群大小为 30, 交叉概率为 0.9, 变异概率为 0.1, 最大进化代数为 100, 对各函数 IGA 的其他参数取值如表 1 所示, 其中参数 θ 用于定义满意解, 即对于最优解 X^* 若 $|f(X) - f(X^*)| < \theta$ 则认为 X 为满意解

表 1 IGA 参数取值

函数	ϵ_0	σ_0	λ_1	λ_2	μ_1	μ_2	θ
f_1	0.2	3	0.8	0.8	1.5	1.5	0.02
f_2	0.01	2	0.8	0.8	1.5	1.5	0.001
f_3	5	1	0.8	0.8	1.5	1.5	0.4

图 1 和图 2 分别给出了改进算法和 SGA 优化 f_3 时种群分散度和地域分散度的变化曲线(实线表

示改进算法, 虚线表示 SGA)。可见, 改进算法无论在性能分散度上, 还是在地域分散度上, 都保持了较大值, 即维持了种群的多样性, 有利于全局搜索。表 2 给出了 IGA 和 SGA 在上述参数下分别对各函数随机仿真 300 次的统计结果

实验结果表明, 改进算法明显以更大的概率跳出局部最优, 命中最优解。尤其对于强振荡函数, SGA 很难收敛到最优解, 大部分只能搜索到它附近的局部最优, 而 IGA 则大几率收敛到全局最优。图 3 显示了两种算法求解 f_3 时最优性能的变化(实线表示改进算法, 虚线表示 SGA)。可见, IGA 比 SGA 具有更快的收敛能力和更好的最终收敛效果, 即 IGA 比 SGA 收敛快且好。

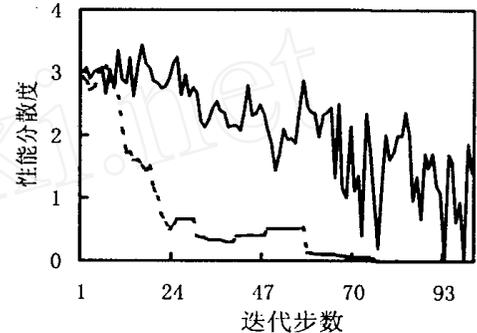


图 1 求解 f_3 时种群性能分散度比较

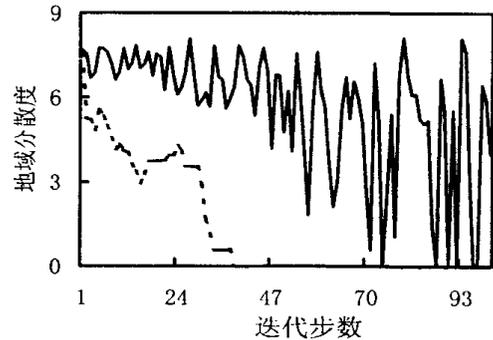


图 2 求解 f_3 时种群地域分散度比较

表 2 仿真结果统计

函数	算法	最佳优化值	平均优化值	最差优化值	优化值方差	满意解次数*
f_1	GA	7.5029	7.3049	4.376	0.5798	279
	IGA	7.5029	7.5029	7.5029	0.0000	300
f_2	GA	-0.9999	-0.9909	-0.9903	0.000004	21
	IGA	-1.0000	-0.9986	-0.99028	0.000011	255
f_3	GA	-186.7309	-182.6537	-46.1058	147.0383	94
	IGA	-186.7309	-186.7308	-186.7278	0.0000	300

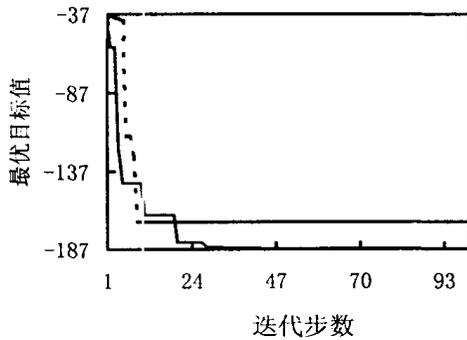


图 3 优化 f_3 时两种算法最佳性能的变化曲线

5 参数灵敏度分析

下面考察初始值 ϵ_0 和 σ_0 、尺度收缩因子 λ_1 和 λ_2 、尺度放大因子 μ_1 和 μ_2 对算法性能的影响

1) ϵ_0 的影响: 设置基准参数 $\lambda_1 = 0.8, \lambda_2 = 0.8, \mu_1 = 1.5, \mu_2 = 1.5$, 令 $\sigma_0(f_1) = 3, \sigma_0(f_2) = 2, \sigma_0(f_3) = 1$, 令基准性能幅度 $A(f_1) = 16, A(f_2) = 1, A(f_3) = 400$ 分别对各函数在不同 ϵ_0/A 比例下进行 300 次随机实验, 算法获得满意解的次数如表 3 所示。可见, 改进算法对 ϵ_0 具有很强的鲁棒性, 不同取值情况下均能够较大几率得到满意解

表 3 不同 ϵ_0/A 比例下算法获得满意解次数统计 %

ϵ_0/A	1	5	10	25	50	100	150	200
f_1	300	300	300	300	300	300	300	300
f_2	242	255	261	257	261	272	266	274
f_3	300	300	300	300	299	300	300	300

2) σ_0 的影响: 设置基准参数 $\lambda_1 = 0.8, \lambda_2 = 0.8, \mu_1 = 1.5, \mu_2 = 2.0$, 令 $\epsilon_0(f_1) = 16, \epsilon_0(f_2) = 1, \epsilon_0(f_3) = 400$, 令基准地域幅度 $B(f_1) = 9, B(f_2) = 8, B(f_3) = 20$ 分别对各函数在不同 σ_0/B 比例下进行 300 次随机实验, 获得满意解次数如表 4 所示。可见, 改进算法对 σ_0 具有很强的鲁棒性

表 4 不同 σ_0/B 比例下算法获得满意解次数统计 %

σ_0/B	1	5	10	25	50	100	150	200
f_1	300	300	300	300	300	300	300	300
f_2	273	259	267	268	268	260	270	270
f_3	300	300	300	300	300	299	300	300

3) λ_1 的影响: 设置基准参数 $\lambda_2 = 0.8, \mu_1 = 1.5, \mu_2 = 1.5$, 令 $\epsilon_0(f_1) = 16, \sigma_0(f_1) = 9; \epsilon_0(f_2) = 1, \sigma_0(f_2) = 8; \epsilon_0(f_3) = 400, \sigma_0(f_3) = 20$ 分别对各函数在不同 λ_1 进行 300 次随机实验, 算法获得满意解的次数如表 5 所示。整体而言, 改进算法在 λ_1 取 $0.8 \sim 0.9$ 时具有很好的优化性能

4) μ_1 的影响: 设置基准参数 $\lambda_1 = 0.85, \lambda_2 =$

$0.8, \mu_2 = 1.5$, 其他参数同上。分别对各函数在不同 μ_1 进行 300 次随机实验, 算法获得满意解的次数如表 6 所示。整体而言, 改进算法在 μ_1 取 $1.5 \sim 5.0$ 时具有很好的优化性能

限于篇幅, 略去对 λ_2 和 μ_2 的研究结果, 整体而言, 在 λ_2 取 $0.4 \sim 0.9, \mu_2$ 取任意值时, IGA 均具有很好的优化性能

因此, 尽管 IGA 相对 SGA 增加了部分参数, 但 IGA 对这些参数具有较高的鲁棒性, 应用时不必过分精心选取。但需要指出的是, 性能筛选和地域筛选的同时使用很重要

表 5 不同 λ_1 下算法获得满意解次数统计

λ_1	0.95	0.9	0.8	0.7	0.6	0.5	0.4
f_1	300	300	300	300	300	300	300
f_2	255	276	269	228	201	195	198
f_3	171	295	300	296	286	287	285

表 6 不同 μ_1 下算法获得满意解次数统计

μ_1	1.2	1.5	1.8	2.0	2.5	5.0	10
f_1	300	300	300	300	300	300	300
f_2	234	283	286	284	286	280	278
f_3	299	300	300	299	294	282	261

6 结 语

本文首先提出了衡量种群多样性的分散度概念, 进而提出了种群性能差别和基于种群地域差别的筛选策略, 用于排斥种群中的近亲个体, 增强种群多样性和避免早熟收敛。仿真结果验证了本文算法的有效性和高效性以及参数的鲁棒性。组合优化问题相关的筛选策略是需要进一步探讨的问题

参考文献(References):

- [1] Goldberg D E. *Genetic Algorithms in Search, Optimization, and Machine Learning* [M]. MA: Addison-Wesley, 1989.
- [2] 王凌. 智能优化算法及其应用[M]. 北京: 清华大学出版社, 2001.
- [3] Gong D, Sun X, Guo X. Novel survival of the fittest genetic algorithm [J]. *Control and Decision*, 2002, 17(6): 908-911.
- [4] Eiben A E, Hinterding R, Michalewicz Z. Parameter control in evolutionary algorithms [J]. *IEEE Transactions on Evolutionary Computation*, 1999, 3(2): 124-141.
- [5] Srinivas M, Patnaik L M. Adaptive probabilities of crossover and mutation in genetic algorithms [J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1994, 24(4): 656-667.

(下转第 1297 页)

$$B_1 = \begin{bmatrix} 0 & 182 & 0 \\ 0 & 0 & 301 \\ 0 & 0 & 187 \end{bmatrix}, F = \begin{bmatrix} 0 \\ 0 & 150 & 4 \\ 0 & 056 & 2 \end{bmatrix},$$

$$C = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 2 & 0 & 1 \end{bmatrix}.$$

根据上述设计方法,并考虑到非最小相位系统导致的开环响应应具有反向响应特性,确定出预测时域的可选范围为 $P = [10 \ 13]^T$, 给定值为 $Y^s = [1 \ -1]^T$. 最后选择 3 组预测时域得到仿真曲线如图 1 所示

6 结 论

本文对工业生产过程中常见的多重滞后复杂过程控制系统的预测控制进行了研究,利用状态反馈预测控制,引入对未来状态和未来可测干扰变化轨迹的假设,给出了适用于具有多重状态滞后、多重控制滞后的状态反馈预测控制算法,避免了使用预测值再次递推新的预测.该算法结构简单,减少了保存历史数据的维数,从而节省计算机内存,减小了在线计算量,计算速度成倍提高,非常有利于实际工程应用与实施

参考文献(References):

- [1] Mihai Huzmezan, William A Gough, Guy A Dumont, et al Time delay integrating systems: A challenge for process control industries [J]. *A Practical Solution, Control Engineering Practice*, 2002, 10 (11): 1153-1161.
- [2] Kharitonov V L, Zhabko A P, Lyapunov-Krasovskii approach to the robust stability analysis of time-delay systems [J]. *Automatica*, 2003, 39(1): 15-20
- [3] Darko Vrecko, Damir Vrancic, Dani Huricic, et al A new modified Smith predictor: The concept, design and tuning [J]. *ISA Trans*, 2001, 40(2): 111-121.

- [4] Ibrahim Kaya Improving performance using cascade control and a Smith predictor [J]. *ISA Trans*, 2001, 40 (2): 223-234
- [5] Shu Huailin, Pi Youguo. PD neural networks for time-delay systems [J]. *Computers and Chemical Engineering*, 2000, 24(8): 859-862
- [6] 李阳春, 张卫东, 许晓鸣, 等. 时滞不确定系统 DMC 约束控制的鲁棒性条件 [J]. *控制理论与应用*, 2001, 18 (1): 109-112
- (LI Y C, ZHANG W D, XU X M, et al Robust stability conditions for DMC algorithm of constrained delay uncertain systems [J]. *Control Theory and Applications*, 2001, 18(1): 109-112)
- [7] Wen Tana, Horacio J Marquez, Tongwen Chen. MC design for unstable processes with time delays [J]. *J of Process Control*, 2003, 13(3): 203-213
- [8] 胡品慧, 袁璞. 状态反馈预测控制干扰解耦的研究 [J]. *控制与决策*, 2003, 18(2): 194-198
- (Hu P H, Yuan P. Study on disturbance decoupling of state feedback model predictive control [J]. *Control and Decision*, 2003, 18(2): 194-198)
- [9] 胡品慧, 杜殿林, 左信, 等. 状态反馈预测控制在催化裂化柴油产品质量先进控制中的应用 [J]. *石油炼制与化工*, 2003, 34(5): 57-59
- (Hu P H, Du D L, Zuo X, et al Advanced process control and plant implementation for FCC LCO quality based on state feedback model predictive control [J]. *Petroleum Processing and Petrochemicals*, 2003, 34 (5): 57-59)
- [10] 孙玉华, 石卫红, 刘万丰, 等. 具有纯滞后系统的预测控制算法 [J]. *大庆石油学院学报*, 1997, 21(4): 40-44
- (Sun Y H, Shi W H, Liu W F, et al Predictive control algorithm of time delay systems [J]. *J of Daqing Petroleum Institute*, 1997, 21(4): 40-44)

(上接第 1293 页)

- [6] Wang L, Zheng D Z. An effective hybrid optimization strategy for job-shop scheduling problems [J]. *Computers and Operations Research*, 2001, 28(6): 585-596
- [7] Guo G Q, Yu S Y. Evolutionary parallel local search for function optimization [J]. *IEEE Trans on Systems, Man, and Cybernetics*, 2003, 33 (6): 864-876
- [8] He J, Kang L S. On the convergence rate of genetic al-

- gorithm s [J]. *Theoretical Computer Science*, 1999, 229 (1): 23-39
- [9] Xu Y G, Li G R, Wu Z P. A novel hybrid genetic algorithm using local optimizer based on heuristic pattern move [J]. *Applied Artificial Intelligence*, 2001, 15 (7): 601-631.