

基于 Species 机制的多目标遗传算法

王洪峰¹, 张 迁¹, 李小将^{2,3}

(1. 东北大学 信息科学与工程学院, 辽宁 沈阳 110819; 2. 中国民航局第二研究所, 四川 成都 610041;

3. 民航机场(成都)电子工程设计所, 四川 成都 610041)

摘 要: 多目标优化算法设计正在成为当前进化算法领域的一个研究热点. 考虑将最初用于多峰优化的 Species 机制引入到多目标遗传算法中, 通过借鉴现有多目标算法的相关思想, 设计并提出了一种新的 Species 方法, 包括基于 Pareto 最优性和拥挤度思想的 Species 种子确定策略及适应性的 Species 构造策略. 一组标准多目标测试函数的仿真实验结果表明, 提出的基于 Species 机制的多目标遗传算法表现出比经典的非支配排序遗传算法 II (NSGA-II) 更好的性能.

关 键 词: 多目标优化问题; 进化多目标优化; 遗传算法; Species 机制; 多峰优化

中图分类号: TI 8

文献标志码: A

文章编号: 1005-3026(2014)04-0479-05

Species-based Genetic Algorithm for Multiobjective Optimization Problems

WANG Hong-feng¹, ZHANG Qian¹, LI Xiao-jiang^{2,3}

(1. School of Information Science & Engineering, Northeastern University, Shenyang 110819, China; 2. The Second Research Institute of CAAC, Chengdu 610041, China; 3. Civil Aviation Electronic Engineering Design Institute, Chengdu 610041, China. Corresponding author; WANG Hong-feng, E-mail: hfwang@mail.neu.edu.cn)

Abstract: Considering that evolutionary multiobjective optimization has been becoming one of research topics in evolutionary algorithm community recently, a species-based mechanism was introduced into multi-objective GA, which is initially applied into GA for multi-modal optimization problem. And then a new species-based method was designed and proposed for multiobjective optimization problem, which comprises a species seed indentifying strategy based on Pareto optimality and crowd degree and an adaptive species constructing scheme. Experimental results showed that the proposed species-based multiobjective GA outperforms nondominated sorting GA II (NSGA-II) on a set of benchmark test problems.

Key words: multiobjective optimization problem; evolutionary multiobjective optimization; genetic algorithm; species-based mechanism; multi-modal optimization

许多实际科学和工程领域中的优化问题可能具有多个目标,在这种多目标优化问题中并不存在唯一的全局最优解,而是存在一个由很多甚至无穷多个 Pareto 最优解构成的解集,显然这样的复杂特性将给求解算法带来极大的难度. 由于借鉴自然进化原理和基于种群机制的遗传算法(GA)在寻优过程中表现出的鲁棒性和自适应性,使得 GA 开始成为求解多目标优化问题的不错选择.

近年来,学者们设计和提出了各种求解多目标优化问题的遗传算法^[1-4]. 这些算法都是通过利用额外的算子使一般 GA 具备求解多目标问题的能力,这些新算子通常具有如下特征:根据非支配排序来设定个体适值;保持相同非支配边界分布的均匀性. 尽管这些早期算法在很多多目标问题上取得了不错的效果,然而研究者们后来发现精英保留策略将会进一步改善多目标 GA 的性能. 于是,一系列采用精英保留机制的多目标算法

被广泛研究^[5-7],文献[7]中提出的 NSGA-Ⅱ 是一种最为经典的多目标进化算法,本文借鉴了 NSGA-Ⅱ 的^[8-10]相关思想,并结合多峰优化中的一种 Species 机制,设计和开发一种更为高效的多目标优化算法.

1 本文所提出的算法

1.1 一般 Species 方法的算法框架

Species 方法最初应用于求解多峰优化问题的 GA 中,其基本思想就是将整个种群分成若干个小种群(Species)对解空间进行有效并行搜索,每个 Species 由一个 Species 种子及其支配(dominate)的若干个成员组成,同时 Species 种子及其半径还将用来避免不同 Species 之间互不影响.一般性 Species 方法的算法框架见图 1,其中 P 表示当前种群.

```
Procedure general Species-based method:
begin
  set the status of each individual in  $P$  as unprocessed;
  while (there are unprocessed individual in  $P$ ) do
    indentify a species seed  $s$ ;
    construct a species  $S$  dominated by  $s$ ;
    set the status of each member in  $S$  as processed;
  end while;
end;
```

图 1 一般 Species 方法的伪码图

Fig. 1 Pseudo-code for general Species-based method

由图 1 可知,在这种基于 Species 的方法中有两个关键步骤:一个是如何确定 Species 种子;另一个是如何构造一个由 Species 种子支配的 Species.

1.2 面向多目标优化的 Species 方法

在单目标优化问题中,由于目标函数是唯一的,种群中个体的优劣可以通过其适值来进行评价.在以前的工作中,个体适值往往被用做 Species 种子的确定准则,也就是说,个体的适值越大,其越优先被确定为 Species 种子.

显然,这样的策略在多目标优化问题中难以直接使用,这是因为问题本身具有多个目标函数,个体的适值无法简单地通过对目标函数的标定而获得.于是制定多目标优化环境中个体优劣的评价标准就成为 Species 种子确定策略的关键.在文献[7]中,在评价种群中不同个体优劣性时除了考虑个体对应目标值的 Pareto 最优性之外,还考虑了其目标值对整个 Pareto 解集分布性的影响程度.于是,这里将上述思想应用于 Species 种子的确定策略中,为了便于描述,给出几个定义:

$$\min F(x) = (f_1(x), f_2(x), \cdots, f_m(x))^T,$$
$$\text{s. t. } x \in \Omega.$$

式中: Ω 表示决策空间; x 表示决策变量; $F(x)$ 包含 m 个目标函数 $f_i: \Omega \rightarrow \mathbf{R}, i = 1, \cdots, m$.

定义 1 在一个种群 P 中,个体 u Pareto 优于($>$)个体 v ,当满足下列条件时:

$$f_i(u) \leq f_i(v), i = 1, 2, \cdots, m,$$
$$\text{且 } f_k(u) < f_k(v), k \in \{1, 2, \cdots, m\}.$$

定义 2 对于种群 P 中个体 u 来说,若 P 中不存在这样的个体 $v(v > u)$,则称 u 是种群 P 的 Pareto 最优个体.

定义 3 由种群 P 中所有 Pareto 个体构成的集合称之为它的 Pareto 最优个体集,而由所有 Pareto 个体目标函数值构成的集合称之为它的 Pareto 边界.

根据定义 2 和定义 3,在本文提出的算法中,每个个体将具有两个特殊属性:rank 值和 crowd 值.其中,rank 值用来表征个体在种群中 Pareto 最优性;crowd 值用来评价个体目标值对于种群 Pareto 前沿的贡献度.这里 rank 值和 crowd 值可根据图 2 和图 3 中的伪码计算获得.

```
Procedure calculate the rank value of each individual in  $P$ 
begin
   $rk=1$ ;
  while ( $P$  is not null) do
    achieve the Pareto individuals set  $PS(r)$  in  $P$ ;
    for each individual  $i$  in  $PS(r)$  do
       $rank(i)=rk$ ;
    end for;
    remove all individuals in  $PS(r)$  from  $P$ ;
     $rk=rk+1$ ;
  end while;
end;
```

图 2 个体的 rank 值

Fig. 2 Rank value of individual

```
Procedure calculate the crowd value of each individual in  $PS(r)$ 
begin
   $l=|PS(r)|$ ;
  for each individual  $i$  in  $PS(r)$  do
     $crowd(i)=0$ ;
  end for;
  for each objective function  $m$  do
    sort  $PS(r)$  according to  $f_m$  in ascending order;
     $crowd(1)=crowd(n)=\infty$ ;
    for  $i=2$  to  $l-1$  do
       $crowd(i)=crowd(i)+(f_m(i+1)-f_m(i-1))/(f_m(i)-f_m(1))$ ;
    end for;
  end for;
end;
```

图 3 个体的 crowd 值

Fig. 3 Crowd value of individual

由图 2 和图 3 可知,个体的 rank 值越小,其 Pareto 最优性能越好;个体的 crowd 值越大,则其对种群 Pareto front 的贡献性越好.于是,可以根据这两个特殊属性值来确定 Species 种子,其原则

是选择 rank 值最小的个体集中 crowd 值最大的个体作为 Species 种子。

在文献[8]中,一个 Species 是由 Species 种子以及与其 Euclidean 距离小于一个给定阈值 r 的所有个体构成。显然,这种简单直接的方法存在一个弊端,即 Species 的构造完全依赖于参数 r 。若 r 的值过大,将会造成 Species 的构造数量过少,这会影响到算法对多个 Pareto 最优解的搜索效率;若 r 的值过小,将会造成 Species 的支配个体数目过少,这会影响到算法对 Pareto 最优解的开发能力。而 r 值的设定往往是问题依赖的,很难预先确定其适当的大小。

为了解决这个问题,这里提出了一种较强鲁棒的 Species 构造策略。在本文的方法中,一个 Species 由其 Species 种子以及与其距离最近的 n 个个体构成,其中 n 是一个预先设定的参数。可见,在这种构造策略中,每个 Species 将总是包含相同数量 $(n + 1)$ 的个体,但其分布范围大小各不相同,同时还将随着算法的运行做出适应性的调整。

根据上面的讨论,本文提出一种基于 Species 的多目标遗传算法,其算法流程如图 4 所示。

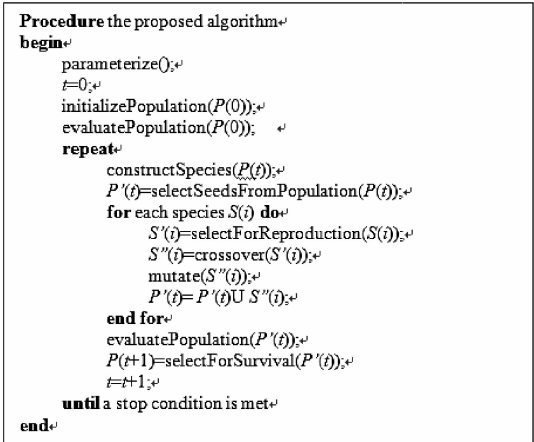


图 4 基于 Species 的多目标遗传算法伪码图
Fig. 4 Pseudo-code for multiobjective GA based on Species

2 仿真实验

2.1 实验设置

本文所选择的 8 个测试函数均来自文献,这些测试函数都是近些年来多目标优化研究中常用的 benchmark 问题。表 1 给出了这些测试函数的描述及相关性质,所有问题均是具有 2 个目标函数的无约束优化(min)问题。

表 1 仿真实验中所采用的测试函数
Table 1 Test benchmark functions of simulation

测试函数	维度	变量边界	目标函数
SCH	1	$[- 10^3 , 10^3]$	$f_1(x) = x^2$ $f_2(x) = (x - 2)^2$
FON	3	$[- 4 , 4]$	$f_1(x) = 1 - \exp\left(-\sum_{i=1}^3\left(x_i - \frac{1}{\sqrt{3}}\right)^2\right)$ $f_2(x) = 1 - \exp\left(-\sum_{i=1}^3\left(x_i + \frac{1}{\sqrt{3}}\right)^2\right)$
POL	2	$[- \pi , \pi]$	$f_1(x) = 1 + (A_1 - B_1)^2 + (A_2 - B_2)^2$ $f_2(x) = (x_1 + 3)^2 + (x_2 + 1)^2$ $A_1 = 0.5\sin 1 - 2\cos 1 + \sin 2 - 1.5\cos 2$ $A_2 = 1.5\sin 1 - \cos 1 + 2\sin 2 - 0.5\cos 2$ $B_1 = 0.5\sin x_1 - 2\cos x_1 + \sin x_2 - 1.5\cos x_2$ $B_2 = 1.5\sin x_1 - \cos x_1 + 2\sin x_2 - 0.5\cos x_2$
KUR	3	$[- 5 , 5]$	$f_1(x) = \sum_{i=1}^{n-1}(-10 \cdot \exp(-0.2\sqrt{x_i^2 + x_{i+1}^2}))$ $f_2(x) = \sum_{i=1}^n(x_i ^{0.8} + 5\sin x_i^3)$
ZDT1	30	$[0 , 1]$	$f_1(x) = x_1$ $f_2(x) = g(x)[1 - \sqrt{x_1/g(x)}]$ $g(x) = 1 + 9\left(\sum_{i=2}^n x_i\right)/(n - 1)$

续表

测试函数	维度	变量边界	目标函数
ZDT2	30	[0,1]	$f_1(x) = x_1$ $f_2(x) = g(x) [1 - (x_1/g(x))^2]$ $g(x) = 1 + 9(\sum_{i=2}^n x_i)/(n - 1)$
ZDT3	30	[0,1]	$f_1(x) = x_1$ $f_2(x) = g(x) \left[1 - \sqrt{x_1/g(x)} - \frac{x_1}{g(x)} \sin(10\pi x_1) \right]$ $g(x) = 1 + 9(\sum_{i=2}^n x_i)/(n - 1)$
ZDT6	10	[0,1]	$f_1(x) = 1 - \exp(-4x_1) \sin^6(6\pi x_1)$ $f_2(x) = g(x) [1 - (f_1(x)/g(x))^2]$ $g(x) = 1 + 9 \left[(\sum_{i=2}^n x_i)/(n - 1) \right]^{0.25}$

为了更好地验证本文所提出算法(简称为 speMOGA)的性能,在接下来的仿真实验中将其与一种经典的多目标算法(NSGA-II)进行比较.除非特殊说明,所有算法将设置如下:种群大小设为 100,采用竞标赛选择(选择参数设为 2),模拟二进制交叉(交叉率设为 0.8)及多项式变异方式(变异率设为 0.2),最大迭代次数设为 50.在 speMOGA 中,设 n 为 4,也就是说,每一代种群将组成 20 个不同的 Species.

由于在多目标优化问题中不存在唯一的最优解,故在仿真实验中将采用不同算法所获得 Pareto 最优个体集之间的覆盖率 CS 来评估它们性能的优劣.若 PS1 和 PS2 分别表示算法 alg1 和 alg2 所获得 Pareto 最优个体集,则 CS(alg1, alg2) 可以计算如下:

$$CS(alg1,alg2) = \frac{|\{\alpha1 \in PS1 | \exists \alpha2 \in PS2, \alpha1 > \alpha2\}|}{|PS2|}$$

若 $CS(alg1,alg2) \rightarrow 1$,则说明 alg1 能够获得更高质量的 Pareto 解.

2.2 实验结果与分析

在仿真实验中,首先比较 speMOGA 和 NSGA-II 在 8 个测试函数中的实验结果.两种算法均采纳 2.1 中的算法设置,并利用相同随机初始种群进行执行,每次执行都将对其获得 Pareto 最优个体集进行比较,最终的实验结果是 50 次运行所获得实验结果的平均值,如表 2 所示.其中, t 检验行表示两个性能指标 CS(speMOGA, NSGA-II) 和 CS(NSGA-II, speMOGA) 在自由度为 98,置信水平为 0.95 下的 t 检验结果;“ $s+$ ”表示前者显著大于后者;“+”表示前者不显著大于后者.

由表2知,在所有的测试函数中,sepMOGA

表 2 speMOGA 和 NSGA-II 在测试函数中的实验结果
Table 2 Experimental results of speMOGA and NSGA-II in test functions

性能指标	SCH	FON	POL	KUR
CS(speMOGA, NSGA-II)	0.028	0.154	0.042	0.437
CS(NSGA-II, speMOGA)	0.001 1	0.006 1	0.02	0.088
t 检验	$s+$	$s+$	$s+$	$s+$
性能指标	ZDT1	ZDT2	ZDT3	ZDT6
CS(speMOGA, NSGA-II)	0.830	0.857	0.706	0.360
CS(NSGA-II, speMOGA)	0.004 9	0.011	0.019	0.336
t 检验	$s+$	$s+$	$s+$	+

都能获得比 NSGA-II 更好的 Pareto 解.特别是在测试函数 ZDT1, ZDT2 和 ZDT3 中, speMOGA 获得的 Pareto 最优个体大部分都能支配 NSGA-II 获得的某个 Pareto 最优个体.

这一点同样可以通过性能指标的 t 检验结果可以证实.大部分测试函数(仅函数 ZDT6 除外)的 t 检验结果都表明了 CS(speMOGA, NSGA-II) 显著性大于 CS(NSGA-II, speMOGA).

这是由于在本文提出的算法中,能够将种群划分成若干个不同的 Species,对多个 Pareto 最优解进行并行搜索.上述实验结果表明这种 Species 机制能够有效改善 GA 在多目标优化问题中的性能.

显然,在 speMOGA 中 Species 的构造方法是一个非常关键的算子.在本文提出的 Species 构造策略中,在确定了 Species 种子后,利用解空间中与 Species 种子距离最近的 n 个个体构成 Species.在接下来的实验中,将检验这种构造策略的有效性,这里以一种 speMOGA 的变形算法(简称为 speMOGAa)作为性能比较的对象.在 speMOGAa 中,当确定了 Species 种子后,根据一个预设的半

径 r 来构造 Species,也就是说,一个 Species 是由种子以及与种子距离小于 r 的所有个体构成. 在具体的实验设置中, r 的值将分别被设为测试函数边界值的 1% ,5% 和 10% . 为了便于描述,采用上述 r 取值的算法分别用 speMOGAa1 ,speMOGAa2 和 speMOGAa3 表示. 所有算法同样也采纳 2.1 中的算法设置,并利用相同随机初始种群进行执行,每次执行对其获得 Pareto 最优个体集进行比较,实验结果如表 3 所示.

表 3 不同的 speMOGA 算法在测试函数中的实验结果
Table 3 Experimental results of different speMOGAs in test functions

性能指标	SCH	FON	POL	KUR
CS(speMOGA,speMOGAa1)	0.812	0.986	0.906	0.894
CS(speMOGAa1,speMOGA)	0	0	0	0
CS(speMOGA,speMOGAa2)	0.784	0.728	0.920	0.913
CS(speMOGAa2,speMOGA)	0	0	0	0
CS(speMOGA,speMOGAa3)	0.794	0.988	0.862	0.886
CS(speMOGAa3,speMOGA)	0	0	0	0

性能指标	ZDT1	ZDT2	ZDT3	ZDT6
CS(speMOGA,speMOGAa1)	0.812	0.740	0.936	0.940
CS(speMOGAa1,speMOGA)	0	0	0	0
CS(speMOGA,speMOGAa2)	0.812	0.728	0.920	0.913
CS(speMOGAa2,speMOGA)	0	0	0	0
CS(speMOGA,speMOGAa3)	0.808	0.746	0.942	0.924
CS(speMOGAa3,speMOGA)	0	0	0	0

由表 3 知,在所有的测试函数中 speMOGA 的表现都远远优于其他算法,speMOGA 总是能够获得最好的 Pareto 最优个体集,甚至于 3 种 speMOGAa 算法都无法获得能够支配 speMOGA 的任何 Pareto 最优个体的 Pareto 解. 在所有测试函数中,CS(speMOGAa1,speMOGA),CS(speMOGAa2,speMOGA) 和 CS(speMOGAa3,speMOGA) 均等于 0. 这是由于在 speMOGAa 中,Species 的构造很大程度上依赖于参数 r ,而 r 值的大小难以恰当的设定. 而本文所提出的策略中没有采用固定 Species 半径,而采用固定 Species 大小的构造方法,显然这种策略能够帮助 speMOGA 具有更强鲁棒性,并构造出不同分布范围的 Species. 仿真实验结果表明了这种适应性的构造策略要比采用固定半径的方法更为有效.

综上,在上述 8 个标准多目标测试函数上通过与 NSGA-II 以及一种变形算法(speMOGAa) 所获得实验结果的比较,本文所提出的基于 Species 机制的多目标遗传算法(speMOGA)是一

种求解多目标优化问题的好方法.

3 结 论

本文将一种最初用于多峰优化的 Species 机制引入到多目标遗传算法,在提出的 Species 策略中,利用 2 个能够反映多目标优化性质的个体属性(rank 值和 crowd 值)来确定种群中哪些粒子成为 Species 种子,在种子确定之后利用种群与该种子距离最近的一定数量的个体构成一个 Species. 在对 8 个标准多目标测试函数进行的仿真实验中,通过与一种经典多目标遗传算法(NSGA-II)和一种变形算法(speMOGAa)的比较和分析知,本文所提出的基于 Species 机制的多目标遗传算法(speMOGA)具有更好的有效性和适应性.

参考文献:

[1] Zhou A, Qu B, Li H, et al. Multiobjective evolutionary algorithms;a survey of the state of the art[J]. *Swarm and Evolutionary Computation*,2011,1:32-49.

[2] Fonseca C,Fleming P. Genetic algorithm for multiobjective optimization problem;formulation,discussion and generalization [C]//Proceeding of the 5th International Conference on Genetic Algorithm. Urbana,1993:416-423.

[3] Srinivas N,Deb K. Multiobjective function optimization using nondominated sorting genetic algorithm [J]. *Evolutionary Computation*,1995,2(3):221-248.

[4] Horn J,Nafploits N,Goldberg D. A niched Pareto genetic algorithm for multiobjective optimization[C]//Proceeding of the 1st IEEE Conference on Evolutionary Computation. Piscataway,1994:82-87.

[5] Zitzler E,Thiele L. Multiobjective optimization using evolutionary algorithm—a comparative case study [C]//Proceeding of Parallel Problem Solving from Nature. Amsterdam,1998:292-301.

[6] Knowles J,Corne D. The Pareto archived evolutionary strategy:a new baseline algorithm for multiobjective optimization[C]// Proceeding of the IEEE Congress on Evolutionary Computation. New York:IEEE Press,1999:98-105.

[7] Deb K,Pratap A,Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II [J]. *IEEE Transactions on Evolutionary Computation*,2002,6(2):182-197.

[8] Li J,Balazs M,Parks G, et al. A species conserving genetic algorithm for multimodal function optimization [J]. *Evolutionary Computation*,2002,10(2):207-234.

[9] Wang H,Moon I K,Yang S, et al. A memetic particle swarm optimization algorithm for multimodal optimization problems [J]. *Information Science*,2012,197:38-52.

[10] Wang H,Yang S,Ip W H, et al. A memetic particle swarm algorithm for dynamic multi-modal optimization problems [J]. *International Journal of Systems Science*,2012,43(7):1268-1283.