

文章编号: 1001-0920(2006)11-1234-05

一种混合自适应多目标Memetic算法

郭秀萍, 杨根科, 吴智铭

(上海交通大学自动化系, 上海 200240)

摘要: Memetic 算法是求解多目标优化问题最有效的方法之一, 融合了局部搜索和进化计算, 具有较高的全局搜索能力. 混合自适应多目标Memetic 算法(HAMA)用基于模拟退火的加权法进行局部搜索, 采用 Pareto 法实现交叉和变异, 通过扰动增强算法的 exploration 能力, 且进化过程可根据改善率自适应调整, 以提高搜索效率并改善算法的鲁棒性. 算例测试说明 HAMA 能产生更接近 Pareto 前沿且多样性更好的近似集.

关键词: 混合; 自适应; 多目标优化; Memetic 算法; 多目标 0/1 背包问题

中图分类号: TP301 **文献标识码:** A

A Hybrid Adaptive Multi-objective Memetic Algorithm

GUO Xiu-ping, YANG Gen-ke, WU Zhi-ming

(Department of Automation, Shanghai Jiaotong University, Shanghai 200240, China Correspondent: GUO Xiu-ping, Email: gxp@sjtu.edu.cn)

Abstract: Memetic algorithm is one of the most efficient methods for multi-objective optimization problems, incorporating local search into evolutionary computation and having high global search ability. Hybrid adaptive memetic algorithm (HAMA) uses a simulated annealing-based weighted-sum method to perform local search, uses Pareto-based approach to implement crossover and mutation, and employs perturbation to enhance the exploration capability of the algorithm. The evolution is made self-adjusted according to optimization ratio for better efficiency and robustness of the algorithm. A testing example shows that HAMA can generate near-Pareto optimal and well-extended approximation set.

Key words: Hybrid; Adaptive; Multiobjective optimization; Memetic algorithm; Multiobjective 0/1 knapsack problem

1 引言

多目标组合优化是实际中广泛存在的NP难问题. 近年来, 有关多目标优化方法的研究越来越多, 很多基于局部搜索的单目标优化方法如禁忌搜索和模拟退火通过对多个目标进行加权和实现多目标优化. 一些加权法将加权函数作为工具, 通过变化权值来改变搜索方向以维护解的多样性. 另一类多目标优化方法是基于 Pareto 主导概念的 Pareto 法, 这类多目标进化算法(MOEA s)引起了不同领域研究者的重视, 数量也在不断增加, 如文献 [1~5]. 其中,

多目标Memetic 算法^[2,3,6,7](或称混合遗传算法)是一种新型的进化方法, 通过混合局部搜索和进化算子能成功地解决多目标优化问题.

为了更有效地产生 Pareto 前沿的近似, 本文提出一种混合自适应多目标Memetic 算法(HAMA), 将基于加权函数的局部搜索和基于 Pareto 主导关系的交叉、变异和网格微扰动算子相结合实现全局优化, 并通过在线改善率调整搜索以改善算法的优化进度. 通过求解多目标 0/1 背包问题算例, 与算法 MOGLS^[3], NSGA-II^[4], SPEA^[1]和 SPEA2^[5]的比

收稿日期: 2005-09-26; 修回日期: 2006-01-25

基金项目: 国家自然科学基金项目(60174009).

作者简介: 郭秀萍(1977—), 女, 内蒙古武川人, 博士生, 从事CMS生产环境下的生产计划与调度研究; 杨根科(1964—), 男, 山西原平人, 教授, 博士生导师, 从事CMS生产环境下的生产计划与调度、混和动态系统等研究.

较结果表明, HAMA 能得到 Pareto 前沿更好的近似

2 多目标问题描述

一般, 多目标优化问题可描述如下:

$$\begin{aligned} \text{Max } y = f(x) &= (f_1(x), f_2(x), \dots, f_n(x)), \\ \text{s.t. } g_c(x) &= 0, \quad c = 1, 2, \dots, r, \\ x &= (x_1, x_2, \dots, x_m) \in X. \end{aligned} \quad (1)$$

式中: x 是具有 m 个决策变量的矢量, X 表示可行解空间, 点 y 是 x 的目标矢量, $g_c(x)$ 是问题约束

对于任意两个解 $a, b \in X$, 称 a 主导 b (记为 $a \succ b$) 当且仅当

$$\begin{aligned} \forall i &= \{1, 2, \dots, n\}; f_i(a) \leq f_i(b) \\ \exists i &= \{1, 2, \dots, n\}; f_i(a) < f_i(b). \end{aligned} \quad (2)$$

如果 $a \succ b$, 则 $f(a) \succ f(b)$. 解 $x \in X$ 是 Pareto 最优当且仅当没有其他解 $x' \in X$ 主导 x . 所有 Pareto 最优解组成的集合称为 Pareto 最优集. Pareto 最优集在目标空间的像称为 Pareto 前沿

在加权法中, 解的适应值由加权函数表示为

$$s(f(x), \lambda) = \sum_{i=1}^n \lambda f_i(x). \quad (3)$$

权矢量 $\lambda = (\lambda_1, \dots, \lambda_n)$ 满足 $\forall i: \lambda_i \geq 0, \sum_{i=1}^n \lambda_i = 1$.

用 Pareto 法进行多目标优化时, 适应值由目标矢量表示, 其生存概率依赖于 Pareto 主导关系

3 混合自适应 Memetic 算法 (HAMA)

HAMA 每代包含局部搜索和进化重组两个阶段, 分别用内部档案 IA 和外部档案 EA 存放局部搜索得到的非劣解和进化过程产生的所有非劣解, 算法的执行过程如下:

Step 1: 随机生成规模为 pop size 的初始种群 Pop, 计算个体的目标值, 将 Pop 中的非劣解放入 EA; 设置 SA 的初始温度 T_0 , 终止温度 T_{end} 和冷却度 χ

Step 2: 设置代数 $g = 1$.

Step 3: 计算第 g 代参数 $iter_g(ir)$ 和 $np_g(ir)$.

Step 4: 局部搜索: 对每个个体 $x \in \text{Pop}$ 执行:

1) 随机生成权矢量 λ , 设置 IA 为空集, 将 x 放入 IA, 并计算 x 的适应值 $s(f(x), \lambda)$;

2) 设置温度 $T = T_0$, 迭代次数 $k = 0$;

3) 构造 x 的可行邻域解 x_1 ;

4) 如果 $\Delta s = \sum_{i=1}^n \lambda (f_i(x) - f_i(x_1)) \leq 0$, 则接收 x_1 并用 x_1 更新 IA; 否则, 如果 $\exp(-\Delta s/T) > \text{random}[0, 1)$, 则接收 x_1 ;

5) $k++$, 如果 $k < iter_g(ir)$, 转到 3); 否则 $T = \chi T$;

6) 如果 $T > T_{end}$, 则转到 3); 否则, SA 结束, 返

回 x , 并用 IA 更新 EA.

Step 5: 进化重组:

1) 从种群 EA Pop 中随机选择若干个体对其进行交叉变异, 将产生的非劣解存入集合 recPop, 同时更新外部档案 EA;

2) 用基于网格密度的锦标赛方法从种群 EA Pop 选择扰动种群 pPop, 对每个个体 $y \in \text{pPop}$ 施加 $np_g(ir)$ 次扰动, 将产生的非劣解存入 pedPop, 同时更新 EA;

3) 用基于网格密度的锦标赛方法从种群 recPop \cup pedPop 选择个体形成新一代 Pop.

Step 6: $g++$, 如果 $g = \text{gen}$ (最大代数), 则转到 Step 3; 否则, 算法结束

以上执行中更新档案指如果一个解没有被这个档案中的任何解主导时, 则将其存入档案并去掉档案中被此解主导的个体; \cup 表示两个集合的并集, 即去掉被主导的个体. 为了找到目标空间各区域的非劣解, 算法在局部搜索阶段 (Step 4) 采用动态权矢量, 并由模拟退火 (SA) 对种群的每个个体进行局部优化; 为了强化局部搜索, HAMA 采用了基于 Pareto 主导关系的交叉变异操作 (Step 5), 并结合网格微扰动算子扩展算法的 exploration 能力.

网格微扰动算子的工作原理如图 1 所示. 首先将外部档案 EA 中种群占据的 n 维目标空间划分成 $G_1 \times G_2 \times \dots \times G_n$ 个网格区域 (G_k 表示第 k 维目标空间的网格数, $k = 1, 2, \dots, n$), 并采用文献 [8] 的方法确定 EA 中每个个体在网格中的位置, 每个网格的密度定义为其包含的个体数. 为了增强 HAMA 的




图 1 网格微扰动算子原理

局部搜索能力,采用基于网格密度的锦标赛方法从 EA 中选择若干个体进行扰动,如图 1 所示 网格密度小的个体比网格密度大的个体被选择的几率大,并且对每个选择的个体用“扩展变异”实现扰动,即对同一个体进行若干次变异产生多个邻域解

假定问题的解编码为 m 位的染色体 $x = (x_s, s = 1, 2, \dots, m)$, s 是编码号, $s = 1$ 表示染色体中最有影响的基因, $s = m$ 表示影响最小的基因 为了增加邻域内而不是邻域外的扰动概率,网格微扰动算子用 S 形函数^[9]确定染色体 x 中基因 x_s 的扰动概率为

$$P_s = \begin{cases} b[2(\frac{s-1}{m-1})^2 + a], & 1 \leq s \leq \beta; \\ b[1 - 2(\frac{s-m}{m-1})^2 + a], & \beta < s \leq m; \end{cases} \quad (4)$$

$\forall s = \{1, 2, \dots, m\}; m > 1$

根据式(4),基因的影响越大,即 s 越小,其被扰动的概率就越小 P_s 的下界和上界分别是 ab 和 $ab + b$ 本文取 $0 < b < 0.8, 0 < ab < 0.03, \beta$ 取 $\lfloor m/2 \rfloor$

由 Step3 可见, HAMA 每代进化局部搜索 SA 在每温度下的迭代次数和网格微扰动算子对每个选择个体的局部扰动次数分别是改善率(ir)的函数,即 $iter_g(ir)$ 和 $np_g(ir)$. 虽然 $iter$ 和 np 越大,局部搜索能力越强,收敛越快,但时间开销越大 为了解决这个问题, HAMA 利用在线改善率自适应地调整 $iter$ 和 np 以提高搜索效率 第 g 代的 ir 定义为

$$ir(g) = \frac{| \{ a \cdot nd(g); \exists b \cdot nd(g-1); a > b \} |}{|nd(g)|} \quad (5)$$

式中: $| \cdot |$ 表示集合的元素个数, $nd(g)$ 和 $nd(g-1)$ 分别表示第 g 和 $(g-1)$ 代 EA 中非劣解的集合 改善率随进化代数的增加逐渐减小,即近似集越接近 Pareto 前沿 ir 越小, ir 接近零时认为算法收敛 一般,解在计算初期(ir 较大时)较易改善,而进化停滞常发生在计算后期 因此,使 $iter$ 和 np 以与 ir 相反的趋势变化,即随 ir 的减小而增大,以改善特别是进化后期的优化进度,产生更多有“竞争力”的非劣解如图 2 所示 图中“Good ir”和“Bad ir”分别表示 ir 较高和较低的状态 第 g 代的 $iter$ 确定为

$$iter_g(ir) = \begin{cases} ub, & 0 < ir < \alpha; \\ ub - 2(ub - lb) \left(\frac{ir - \alpha}{g} \right)^2, & \alpha < ir < \alpha; \\ lb + 2(ub - lb) \left(\frac{ir + 1 - \alpha - g}{g} \right)^2, & \\ \alpha < ir < \alpha; \\ lb, & \alpha < ir < 1. \end{cases} \quad (6)$$

式中 ir 是第 g 代的改善率, α 和 α 是不同状态的模




图 2 参数 $iter$ 和 np 随改善率变化的趋势

糊边界,本文分别取 0.001 和 0.9 . α 是对 ir 的满意度,取 0.4 简单起见, $np_g(ir)$ 也由式(6)确定 计算 $iter_g(ir)$ 时, ub 和 lb 分别是 $iter$ 的上界和下界;计算 $np_g(ir)$ 时, ub 和 lb 分别是 np 的上界和下界

4 实例仿真与性能比较

4.1 测试问题

本文采用 9 个多目标 0/1 背包问题(MOKP)算例^[1]测试算法性能,包括 2, 3 和 4 个背包及 250, 500 和 750 个物品,记为 2-250, 2-500, 2-750 等 给定 n 个背包和 m 个物品的 MOKP 描述如下^[1]:

$$\begin{aligned} \text{Max } f(x) &= (f_1(x), f_2(x), \dots, f_n(x)), \\ \text{s.t. } & \sum_{j=1}^m w_{i,j} \cdot x_j \leq c_i, \quad i = 1, 2, \dots, n. \end{aligned} \quad (7)$$

式中: $f_i(x) = \sum_{j=1}^m p_{i,j} \cdot x_j, i = 1, 2, \dots, n$; c_i 是背包 i 的容量; $p_{i,j}$ 是物品 j 相对背包 i 的价值; $w_{i,j}$ 是物品 j 相对背包 i 的重量; 解编码为 m 位的二进制染色体 $x = (x_1, x_2, \dots, x_m) \in \{0, 1\}^m, x_j = 1$ 表示物品 j 被选中.

HAMA 在局部搜索阶段根据加权价值/重量比^[3]修改不可行解,变异率取 $4/L$ (L 为染色体长度);在重组阶段,按照平均值/重量比的升序逐步去掉物品,直到满足所有背包的重量约束 物品 j 相对所有背包的平均价值/重量比 \bar{q}_j 的定义如下:

$$\bar{q}_j = \frac{1}{n} \sum_{i=1}^n \left\{ \frac{p_{i,j}}{w_{i,j}} \right\}, j = 1, 2, \dots, m.$$

编码时物品按 \bar{q}_j 的降序排列,网格微扰动算子的变异率取 $1/L$,由 S 形函数确定染色体基因的扰动概率,使得 \bar{q}_j 越大的基因被扰动的概率越小

本文算法与 MOGLS, SPEA, SPEA 2 和 NSGA-II 进行了比较 算例以及 SPEA, SPEA 2 和 NSGA-II 产生的近似集从 web^[10] 上获得, SPEA 2 和 NSGA-II 只有物品数为 750 的 3 个算例的结果 MOGLS 求解 9 个相同算例的结果在 web^[11] 上获得

4.2 性能指标

多目标优化的一个目的是收敛到 Pareto 前沿, Fieldsend 等^[12]提出用 \tilde{C} 比较两个集合的收敛速度 假设 A, B 是两个近似集, \tilde{C} 的定义如下:

$$\tilde{C}(A, B) = \frac{| \{ f(b) \mid B; \exists f(a) \mid A: f(a) \geq f(b) \} |}{|B|} \quad (8)$$

当 B 中任何点都被 A 中某些点主导时, $\tilde{C}(A, B) = 1$; 当 B 中所有点都不被 A 中的点主导时, $\tilde{C}(A, B) = 0$ 一般, $\tilde{C}(A, B) \neq \tilde{C}(B, A)$, 所以要分别考虑

本文采用的第二个性能指标是用边沿范围 (FS)^[13] 测量近似集覆盖目标空间的大小 FS 越大, 解的多样性越好. 对于 n 目标问题, 假设近似集 A 是非劣解集合 S 的像, A 的 FS 为

$$FS(A) = \sqrt{\max_{i=1, \dots, n} \max_{(x^0, x^1) \in S \times S} \{ (f_i(x^0) - f_i(x^1))^2 \}} \quad (9)$$

式中 $f_i(x^0)$ 和 $f_i(x^1)$ 分别是解 x^0 和 x^1 的目标函数

4.3 结果比较


HAMA 由 C++ builder 编程实现, 所有实验在 CPU 为 2.40GHz, 内存为 512M 的笔记本上进行. HAMA 对每个实例的参数设置如表 1 所示, 包括种群大小 (Pop size)、SA 中 iter 的上下界 (ub 和 lb)、第 i 维目标空间的网格数 G_i . 对每个实例, np 的上下界分别设为 20 和 5, SA 的其他参数取为: $T_0 = 0.0001, T_{end} = 0.000001, Y = 0.95$.

表 1 HAMA 对每个 MOKP 实例的参数设置


实例	Pop size	lb	ub	G_1	G_2	G_3	G_4
2-250	10	800	1 000	8	8	—	—
2-500	10	1 000	1 200	8	8	—	—
2-750	10	1 100	1 300	8	8	—	—
3-250	15	1 000	1 200	16	16	16	—
3-500	15	1 000	1 200	16	16	16	—
3-750	20	1 000	1 200	16	16	16	—
4-250	15	1 000	1 200	32	32	32	32
4-500	15	1 000	1 200	32	32	32	32
4-750	20	1 000	1 200	32	32	32	32

基于性能指标 \tilde{C} 的比较如图 3 所示, 用简单的数据统计图 box plots^[13] 对结果进行可视化描述. 其中图 3(a) 中每个矩形图左面 3 个 box plots 对应 2 背包问题 (从左到右为 2-250, 2-500, 2-750); 中间 3 个 box plots 对应 3 背包问题; 右面 3 个 box plots 对应 4 背包问题. 图 3(b) 和图 3(c) 的每个矩形图 3 个 box plots 对应实例 2-750, 3-750 和 4-750 (从左到右). 由图 3(a) 可见, 与 MOGLS 相比, HAMA 能产生更接近 Pareto 前沿的非劣面. 对每个实例, HAMA 的近似集主导 MOGLS 结果的大部分, 而 MOGLS 的近似集只主导 HAMA 非劣面的很小一


部分. 由图 3(b) 和图 3(c) 可知, 基于 \tilde{C} 值, HAMA 在求解算例时明显优于 SPEA 2 和 NSGA-II, 特别是对于 3 目标和 4 目标问题, HAMA 产生的所有点都比 NSGA-II 的结果更接近 Pareto 前沿.



(a) 与 MOGLS 比较



(b) 与 SPEA 2 比较



(c) 与 NSGA-II 比较


图 3 基于 \tilde{C} 的比较

图 4(a) 和图 4(b) 给出不同算法求解 2-500 和 2-750 得到的近似集. 显然, 与 SPEA, MOGLS 和 SPEA 2 比较, HAMA 能得到更好的近似集.


表 2 比较了不同算法运行 30 次所得近似集边沿范围 (FS) 的平均值. 由表 2 可知, 与 MOGLS 相比, 对所有实例 (除 2-250 外), HAMA 能得到范围更广的近似集. 而与 SPEA 2 和 NSGA-II 相比, HAMA 明显改善了解的多样性.

表 2 HAMA 与 MOGLS, SPEA 2 和 NSGA-II 的比较: FS

实例	HAMA	MOGLS	SPEA 2	NSGA-II
2-250	3 374	3 465	—	—
2-500	5 491	5 346	—	—
2-750	9 432	8 935	4 085	3 416
3-250	4 532	4 437	—	—
3-500	8 653	7 763	—	—
3-750	12 541	11 260	6 220	6 582
4-250	5 044	4 857	—	—
4-500	9 542	8 282	—	—
4-750	14 653	13 498	8 269	11 285



(a) 求解2-500



(b) 求解2-750

图4 不同算法得到的近似集比较

5 结 语

本文提出一种混合自适应多目标Memetic算法(HAMA)。为了实现全局搜索,算法混合使用了基于模拟退火的加权法和基于Pareto主导关系的进化算子,并采用网格微扰动算子增强局部搜索能力。同时,算法可随改善率进行自适应调整以改善特别是计算后期的优化进度。实例计算表明HAMA能有效地解决多目标优化问题,具有良好的应用前景。

参考文献(References)

- [1] Zitzler E, Thiele L. Multiobjective Evolutionary Algorithms: A Comparative Case Study and the Strength Pareto Approach [J]. *IEEE Trans on Evolutionary Computation*, 1999, 3(4): 257-271.
- [2] Knowles J, Corne D. M-PAES: a Memetic Algorithm for Multiobjective Optimization [A]. *Proceedings of the 2000 Congress on Evolutionary Computation* [C]. La Jolla, 2000: 325-332.
- [3] Jaszkiewicz A. Brief Papers on the Performance of Multiple-objective Genetic Local Search on the 0/1 Knapsack Problem—a Comparative Experiment [J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(4): 402-412.
- [4] Deb K, Pratap A, Agarwal S, et al. A Fast and Elitist Multi-objective Genetic Algorithm: NSGA-II [J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(2): 182-197.
- [5] Zitzler E, Laumanns M, Thiele L. Spea2: Improving the Strength Pareto Evolutionary Algorithm [R]. Zurich, 2001.
- [6] Jaszkiewicz A. Genetic Local Search for Multiple Objective Combinatorial Optimization [J]. *European J of Operational Research*, 2002, 137(1): 50-71.
- [7] Ishibuchi H, Yoshida T, Murata T. Balance Between Genetic Search and Local Search in Memetic Algorithms for Multiobjective Permutation Flow shop Scheduling [J]. *IEEE Trans on Evolutionary Computation*, 2003, 7(2): 204-223.
- [8] Yen G, Haining L. Dynamic Multiobjective Evolutionary Algorithm: A Adaptive Cell-based Rank and Density Estimation [J]. *IEEE Trans on Evolutionary Computation*, 2003, 7(3): 253-274.
- [9] Tan K, Lee T, Khor E. Evolutionary Algorithms with Dynamic Population Size and Local Exploration for Multiobjective Optimization [J]. *IEEE Trans on Evolutionary Computation*, 2001, 7(3): 565-588.
- [10] Zitzler E. SPEA [EB/OL]. <http://www.tik.ee.ethz.ch/zitzler/testdata.html>, 2005-09-01.
- [11] Jaszkiewicz A. MOGLS [EB/OL]. <http://www-idssc.put.poznan.pl/jaszkiewicz/mokp>, 2005-09-01.
- [12] Fieldsend J, Everson R, Singh S. Using Unconstrained Elite Archives for Multiobjective Optimization [J]. *IEEE Trans on Evolutionary Computation*, 2003, 7(3): 305-323.
- [13] Bosman P, D Thierens. The Balance Between Proximity and Diversity in Multiobjective Evolutionary Algorithms [J]. *IEEE Trans on Evolutionary Computation*, 2003, 7(2): 174-188.
- [8] Wu D J, Kleindorfer P R. Competitive Option, Supply Contracting, and Electronic Markets [J]. *Management Science*, 2005, 51(3): 462-466.
- [9] Wu D J, Kleindorfer P R, Zhang Jin E. Optimal Bidding and Contracting Strategies for Capital-intensive Goods [J]. *European J of Operational Research*, 2002, 137(3): 657-676.
- [10] Kandel E. The Right to Return [J]. *J of Law and Economics*, 1996, 39(1): 329-356.
- [11] 范龙振, 胡畏. 金融工程学 [M]. 上海: 上海人民出版社, 2003: 2-3.
(Fan L Z, Hu W. *Financial Engineering* [M]. Shanghai: Shanghai People Press, 2003: 2-3.)
- [12] Varian H. *Microeconomic Analysis* [M]. 3rd ed. New York: W W Norton and Company, 1993: 465-480.

(上接第1233页)