

基于自适应进化学习的约束多目标粒子群优化算法

王建林, 吴佳欢, 张超然, 赵利强, 于涛

(北京化工大学 信息科学与技术学院, 北京 100029)

摘要: 针对约束边界粒子在边界区域搜索能力不足的问题, 提出一种基于自适应进化学习的约束多目标粒子群优化算法. 该算法根据不符合约束条件粒子的约束违反程度, 修正优化算法的进化学习公式, 提高算法在约束边界区域的搜索能力; 通过引入一种基于拥挤距离的 Pareto 最优解分布性动态维护策略, 在不增加算法复杂度的前提下改进 Pareto 前沿的分布性. 实验结果表明, 所提出的算法可以获得具有更好收敛性、分布性和多样性的 Pareto 前沿.

关键词: 多目标粒子群优化; 自适应进化学习; 拥挤距离

中图分类号: TP273

文献标志码: A

Constrained multi-objective particle swarm optimization algorithm based on self-adaptive evolutionary learning

WANG Jian-lin, WU Jia-huan, ZHANG Chao-ran, ZHAO Li-qiang, YU Tao

(College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China. Correspondent: WANG Jian-lin, E-mail: wangjl@mail.buct.edu.cn)

Abstract: Considering the problem of the inadequate search ability for constraint boundary particles in the boundary region, a constrained multi-objective particle swarm optimization algorithm based on self-adaptive evolutionary learning is presented. The evolutionary learning formulas of multi-objective particle swarm optimization algorithm are modified according to the constraint violation level of infeasible particles, so that the algorithm's search ability is enhanced greatly in the constraint boundary region. Furthermore, a dynamic distribution maintenance strategy for Pareto front based on the crowding distance is adopted to improve the distribution of Pareto front without any increase in the algorithm's complexity. The experimental results show that the Pareto front obtained by the proposed algorithm has better convergence, distribution and diversity.

Key words: multi-objective particle swarm optimization; self-adaptive evolutionary learning; crowding distance

0 引言

实际工程中的优化问题通常是带有约束条件的多目标优化问题. 在多目标优化问题求解中, 多目标优化算法的研究已取得了一些进展, 但其研究成果大都集中在获得多目标优化问题的 Pareto 前沿的最优分布上, 缺少对多目标优化问题约束条件的处理方法的研究; 相比无约束优化问题, 约束优化问题的求解更加复杂^[1]. 因此, 简单、高效地求解带约束多目标优化问题的多目标优化算法日益受到重视^[2-3].

针对带有约束的多目标优化问题, 罚函数^[4]是最常用的约束处理方法之一, 但在该方法中, 罚因子的选取问题一直未能得到有效地解决^[5]. 为了避免对罚因子的选取, 文献[6]提出了基于评价准则的约束处理方法, 并与进化算法相结合实现了带约束多目标优

化问题的求解. 文献[7]提出的粒子群优化算法(PSO)因具有收敛速度快、易于实施等优点, 作为一种性能优异的进化算法在求解约束多目标优化问题中得到应用^[8]. 文献[9]将基于评价准则的约束处理方法引入 PSO 算法并验证了其可行性. 文献[10-12]采用基于评价准则的约束多目标粒子群处理方法求解带约束多目标优化问题, 均取得了较好的优化结果. 然而, 采用这种处理技术的多目标粒子群优化算法求解时, 由于约束边界附近不可行粒子对可行域内全局最优位置的过度追随, 导致算法在约束边界区域搜索能力不足, 难以获得完整的 Pareto 最优前沿.

本文提出一种基于自适应进化学习的约束多目标粒子群优化算法. 该算法根据不符合约束条件粒子的约束违反程度修正多目标粒子群优化算法

收稿日期: 2013-06-05; 修回日期: 2013-09-23.

基金项目: 国家自然科学基金项目(61240047).

作者简介: 王建林(1965-), 男, 教授, 博士生导师, 从事复杂工业过程智能检测与优化控制等研究; 吴佳欢(1984-), 男, 博士生, 从事复杂工业过程智能检测与控制、多目标优化算法的研究.

的进化学习公式,并通过引入一种基于拥挤距离的 Pareto 最优解分布性动态维护策略,得到具有更好收敛性、分布性和多样性的 Pareto 前沿.

1 约束多目标优化问题及约束处理

考虑一般性,约束多目标优化问题可表示为

$$\begin{aligned} \min F(x) &= (f_1(x), f_2(x), \dots, f_m(x)). \\ \text{s.t. } g_j(x) &\leq 0, j = 1, 2, \dots, k; \\ h_j(x) &= 0, j = 1, 2, \dots, l; \\ x &= (x_1, x_2, \dots, x_D); \\ x_i^{\min} &\leq x_i \leq x_i^{\max}, i = 1, 2, \dots, D. \end{aligned} \quad (1)$$

其中: x 为 D 维决策向量, $f_i(x) (i = 1, 2, \dots, m)$ 为 m 个目标函数, x_i^{\min} 和 x_i^{\max} 为第 i 维决策变量的上下限, $g_j(x) (j = 1, 2, \dots, k)$ 为 k 个不等式约束条件, $h_j(x) (j = 1, 2, \dots, l)$ 为 l 个等式约束.

基于评价准则的约束多目标粒子群处理方法,根据式 (1) 中的约束条件计算各粒子的约束违反程度

$$Q(x) = \sum_{i=1}^k \max(0, g_i(x)) + \sum_{i=1}^l \max(0, |h_i(x)|). \quad (2)$$

其中 $Q(x)$ 代表粒子 x 的约束违反程度,用于定量地描述粒子与可行域的接近程度,对于可行粒子,有 $Q(x) = 0$. 结合粒子的多个目标函数值信息和约束违反程度信息,评价准则给出了两个粒子间的择优方法:

1) 若两个粒子中一个可行另一个不可行,则选择可行粒子为优;

2) 若两个粒子均不可行,则选择约束违反程度小的粒子为优;

3) 若两个粒子均可行,则基于 Pareto 支配关系选择非支配粒子为优.

2 基于自适应进化学习的约束多目标粒子群优化算法

2.1 标准粒子群优化算法

对于 D 维决策变量, PSO 算法中粒子 x 的位置记为 $x = [x_1, x_2, \dots, x_D]^T$, 速度记为 $v = [v_1, v_2, \dots, v_D]^T$. 假设在第 $k+1$ 次迭代中, 粒子 x 的个体最优位置为 p_b , 种群获得的全局最优位置为 g_b , 则粒子 x 的速度与位置学习进化公式为

$$\begin{aligned} v^{(k+1)} &= \\ wv^{(k)} &+ c_1r_1(p_b^{(k)} - x^{(k)}) + c_2r_2(g_b^{(k)} - x^{(k)}), \quad (3) \\ x^{(k+1)} &= x^{(k)} + v^{(k+1)}. \quad (4) \end{aligned}$$

其中: w 为惯性因子, c_1 和 c_2 分别为个体学习因子和社会学习因子, r_1 和 r_2 为 $[0,1]$ 内均匀分布的随机数. 标准 PSO 算法只能求解无约束单目标优化问题. 对于

带有约束多目标优化问题的求解,需考虑约束处理方法以及 Pareto 前沿最优.

2.2 自适应进化学习公式

分析标准粒子群进化公式,当种群中某个粒子飞入可行域后,处在约束边界附近的不可行粒子由于可行域内全局最优解的吸引作用快速脱离边界位置,忽略了对约束边界附近有利信息的挖掘. 为了避免约束边界附近不可行粒子对可行域内全局最优解的过度追随,本文提出通过自适应进化学习方式减缓约束边界不可行粒子的飞行速度.

根据约束违反程度将粒子分为可行和不可行两类. 对于可行粒子仍按照标准粒子群算法的学习进化公式 (3) 和 (4) 更新粒子的速度与位置信息,完成可行域内 Pareto 前沿的搜索任务. 对于不可行粒子,将其约束违反程度进行归一化处理,得到归一化的约束违反程度为

$$Q_{\text{vio}}(x) = \frac{Q(x) - \min_x(Q(x))}{\max_x(Q(x)) - \min_x(Q(x))}. \quad (5)$$

利用不可行粒子的归一化约束违反程度 $Q_{\text{vio}}(x)$ 影响其社会学习因子,修正其速度和位置. 自适应进化学习公式为

$$\begin{aligned} v^{(k+1)} &= wv^{(k)} + c_1r_1(p_b^{(k)} - x^{(k)}) + \\ & c_2Q_{\text{vio}}(x)r_2(g_b^{(k)} - x^{(k)}), \quad (6) \\ x^{(k+1)} &= x^{(k)} + v^{(k+1)}. \quad (7) \end{aligned}$$

通过分析修正后的进化学习公式可知,不可行粒子可以根据自身的约束违反程度自适应地完成不同的进化学习任务: 对于约束边界附近的粒子,因其 $Q_{\text{vio}}(x_i)$ 接近为 0, 所以 $c_2Q_{\text{vio}}(x_i)$ 为极小值,表现为全局最优解对该粒子的吸引力减弱,粒子以小步长向全局最优解靠近,完成可行域边缘有利信息的挖掘任务; 对于约束违反程度较大的粒子,有 $c_2Q_{\text{vio}}(x_i) \approx c_2$, 此时,粒子保持了对全局最优解较强的追随能力,粒子脱离当前位置完成未知可行域的探索任务. 与标准粒子群优化算法相比,采用修正后的进化学习公式不仅可以提高约束边界的搜索能力,而且能够充分利用具有不同约束违反程度的粒子完成全局搜索,保证粒子快速收敛到真实 Pareto 前沿.

2.3 基于拥挤距离的 Pareto 最优解分布性动态维护

对于 Pareto 最优解集尺寸较大的优化问题,保留所有 Pareto 最优解将会增加算法的复杂度,且无实际意义. Pareto 前沿分布均匀能为决策者提供具有较好多样性的候选解. 拥挤距离是常用的度量个体聚集密度的指标,可用于 Pareto 前沿分布性的维护,其计算公式为

$$I_i = \sum_{k=1}^m (|f_{i+1,k} - f_{i-1,k}|). \quad (8)$$

其中: $f_{i,k}$ 为在第 k 个目标维度上从小到大排序后的第 i 个个体目标函数值, m 为目标函数的总个数, I_i 为第 i 个最优解的拥挤距离。

传统的基于拥挤距离的 Pareto 前沿分布性维护方法很可能因一次性裁剪过多密集区域内的粒子, 导致遗漏 Pareto 最优解。为此, 本文提出一种基于拥挤距离 Pareto 最优解分布性的动态维护方法, 避免误删 Pareto 最优解。

所有最优解分别按照各目标函数值从小到大进行排序, 将第 k 个目标维度上最优解 x 的排序号记为在该维度上的位置信息, 表示为 $P(x, k)$, 与该最优解对应的目标函数值则表示为 $f_{P(x,k)}$ 。由拥挤距离计算公式可知, 若第 k 个目标维度上位置信息为 $P(x, k)$ 的最优解 x 被删除, 则在第 k 个目标维度上只会影响位置信息为 $P(x, k) + 1$ 和 $P(x, k) - 1$ 的两个最优解的拥挤距离分量, 此时需要重新计算这两个受影响的最优解在第 k 个目标维度上的拥挤距离分量, 即

$$\begin{aligned} I_{P(x,k)-1} &= |f_{P(x,k)+1} - f_{P(x,k)-2}|, \\ I_{P(x,k)+1} &= |f_{P(x,k)+2} - f_{P(x,k)-1}|, \end{aligned} \quad (9)$$

其中 $I_{P(x,k)}$ 为在第 k 个目标维度上位置信息为 $P(x, k)$ 的最优解的拥挤距离分量。

在分布性动态维护过程中, 每次只删除拥挤距离最小的一个最优解, 由被删除最优解的位置信息找出在各目标维度上拥挤距离分量受影响的最优解; 按式 (9) 重新计算受影响的最优解的拥挤距离分量, 更新其拥挤距离, 进而基于新的拥挤距离对 Pareto 最优集进行维护, 不断循环直至 Pareto 最优解规模达到给定值。

2.4 算法实现

基于自适应进化学习的约束多目标粒子群优化 (MOPSO) 算法的实现步骤如下。

Step 1: 设置进化参数 (w, c_1, c_2), 种群规模 N , Pareto 最优解规模 L 和最大迭代次数 $\max DT$ 。

Step 2: 在给定搜索域内初始化种群位置 x 和速度 v 。

Step 3: 计算种群中各粒子的目标函数值及约束违反程度。

Step 4: 选取所有可行解, 基于 Pareto 支配关系构造当前的 Pareto 最优集。若当前 Pareto 最优集规模大于给定值 L , 则采用动态分布性维护策略将 Pareto 最优集规模维持在给定值。

Step 5: 若当前 Pareto 最优集为空, 则选取约束

违反程度最小的粒子作为全局最优位置 g_b ; 否则, 从 Pareto 最优集中以大概率选择拥挤距离大的解作为全局最优位置 g_b 。

Step 6: 采用基于评价准则的约束处理方法更新各粒子的个体最优位置 p_b 。

Step 7: 按照自适应学习进化方式更新所有粒子的位置 x 与速度 v 。

Step 8: 判断是否达到最大迭代次数 $\max DT$, 若未达到则返回 Step 3, 否则, 结束循环并输出 Pareto 最优集。

3 算法复杂度分析

考虑一般性, 假设约束多目标优化问题的目标函数个数为 M , 种群规模为 N , Pareto 最优解规模为 L 。

分析 Pareto 最优解的构造过程。将种群中的所有可行解与当前的 Pareto 最优解合并, 若种群中的 N 个粒子均为可行解, 则合并后新种群规模为 $N + L$ 。新种群中判断一个粒子是否为非支配解需进行 $M(N + L)$ 次比较。若各粒子互不支配, 则构造一个新的 Pareto 最优解共需 $M(N + L)^2$ 次比较。因此, 该部分的算法复杂度为 $O(M(N + L)^2)$ 。

分析 Pareto 最优解的维护过程, 其计算量主要集中在粒子位置信息获取和拥挤距离分量重新计算两部分。位置信息获取过程即为首次 Pareto 最优解拥挤距离的计算过程, 其算法复杂度为 $O(M(N + L) \log(N + L))$ 。在动态维护过程中, 每次删减一个最优解后拥挤距离受影响的最优解个数最多为 $2M$ 。在最坏情况下, 该 $2M$ 个最优解的拥挤距离分量重新计算过程的算法复杂度为 $O(M(N + L))$, 该过程循环 N 次直至 Pareto 最优解规模减为 L , 则时间复杂度为 $O(NM(N + L))$ 。因此, Pareto 最优解维护过程的算法复杂度为 $O(M(N + L) \log(N + L) + NM(N + L))$ 。

由上述分析可知, 本文算法的总体时间复杂度为 $O(M(N + L)^2 + M(N + L) \log(N + L) + NM(N + L))$ 。由于 N 和 L 均为正整数, 且 $N + L > \log(N + L)$, 算法的总体时间复杂度可简化为 $O(M(N + L)^2)$, 即整个算法的计算量主要集中在 Pareto 最优解的构造。因此, 本文所提出的 Pareto 最优解分布性动态维护方法并不增加算法的整体计算复杂度。

4 实验与分析

4.1 测试函数及参数选择

将本文算法与其他 3 种算法进行对比分析, 如表 1 所示。算法 1 采用基于自适应罚函数的约束处理方法, 算法 2 采用基于评价准则的约束处理方法, 且两者均采用标准进化方式及一次裁剪分布性维护方法。算法 3 与算法 2 的约束处理方法及 Pareto 最优

解集维护方法一致,但采用修正学习进化方式.本文算法与算法3的约束处理方法及学习进化方式一致,但采用基于拥挤距离的动态分布性维护策略.实验选择8个标准约束多目标测试函数CONSTR、SRN、BNH、TNK、OSY、CTP2、CTP5和CTP8^[6,13-14]对各算法进行测试分析.

表1 4种对比算法

算法	约束处理方法	学习进化方式	Pareto最优解维护方法
1	自适应罚函数	标准进化	一次裁剪拥挤距离
2	评价准则	标准进化	一次裁剪拥挤距离
3	评价准则	修正进化	一次裁剪拥挤距离
本文算法	评价准则	修正进化	动态拥挤距离

设置SRN、BNH、CONSTR函数寻优实验中算法最大迭代次数 $\max DT = 100$, Pareto最优解规模 $L = 200$;设置TNK函数寻优实验中算法最大迭代次数 $\max DT = 300$, Pareto最优解规模 $L = 150$;设置OSY函数寻优实验中算法最大迭代次数 $\max DT = 2500$, Pareto最优解规模 $L = 150$;设置CTP系列函数寻优实验中算法最大迭代次数 $\max DT = 300$, Pareto最优解规模 $L = 200$. OSY函数寻优实验中种群规模 $N = 200$,其余实验均取 $N = 150$.算法中各进化参数设置如下:学习因子 $c_1 = c_2 = 1$;采用线性递减惯性权值 w ,且 $w_{\max} = 0.95$, $w_{\min} = 0.4$.

4.2 性能指标

采用世代距离指标GD^[11]计算获得的Pareto前沿与真实Pareto前沿的接近程度

$$GD = \sqrt{\frac{\sum_{i=1}^n d_i^2}{n}}. \quad (10)$$

其中: n 为Pareto最优解个数, d_i 为目标空间中第 i 个Pareto最优解距Pareto前沿最近个体的距离.

采用指标SP^[11]评价算法求得Pareto前沿分布

$$SP = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (\bar{d} - d_i)^2}. \quad (11)$$

其中: n 为Pareto最优解个数, d_i 为目标空间中第 i 个Pareto最优解距其他个体的距离, \bar{d} 为 d_i 的平均值.

4.3 结果与讨论

在相同硬件条件下,8个测试函数分别采用4种优化算法独立运行30次.4种算法的收敛性指标GD统计结果见表2,分布性指标SP统计结果见表3.收敛性指标GD和分布性指标SP的最大值与最小值如表4和表5所示.

8个测试函数中SRN和BNH的约束Pareto前沿为无约束Pareto前沿的一部分.CONSTR的约束Pareto前沿由无约束Pareto前沿和约束边界两部分组成;TNK的约束Pareto前沿为3段不连续的非线性约束边界;OSY的约束Pareto前沿为5段线性的约束边界;CTP系列函数的约束Pareto前沿为多段不连续的非线性约束边界.其中,OSY函数和CTP系列函数Pareto前沿获取难度最大^[10].

首先,对比分析算法1、算法2和算法3的收敛性指标.由表2可知,算法2可以获得明显优于算法1的收敛性指标,说明基于评价准则的约束处理方法相对于基于自适应罚函数的约束处理方法具有明显优势.此外,算法3获得的各收敛性指标均优于算法2,说明本文提出的自适应学习进化方式在保证算法全局搜

表2 GD指标统计结果对比

测试函数	算法1		算法2		算法3		本文算法	
	均值	方差	均值	方差	均值	方差	均值	方差
SRN	0.0310	1.06e-4	0.0150	1.97e-5	0.0129	7.73e-6	0.0086	6.93e-6
BNH	0.0045	2.39e-7	0.0045	4.50e-7	0.0039	2.68e-7	0.0024	2.29e-7
CONSTR	4.33e-4	2.50e-9	3.66e-4	2.09e-9	3.28e-4	2.14e-9	2.10e-4	1.95e-9
TNK	6.62e-4	9.82e-9	1.73e-4	4.45e-10	1.41e-4	2.07e-10	1.30e-4	3.44e-10
OSY	0.7294	0.1592	0.1225	0.0554	0.0633	0.0037	0.0570	0.0055
CTP2	0.0580	0.0057	0.0078	1.36e-4	0.0028	4.16e-5	0.0017	1.01e-5
CTP5	0.0319	0.0035	0.0024	6.95e-5	0.0017	3.73e-5	0.0015	3.29e-5
CTP8	0.1131	0.0118	0.0073	2.26e-4	0.0059	1.87e-4	0.0040	1.47e-4

表3 SP指标统计结果对比

测试函数	算法1		算法2		算法3		本文算法	
	均值	方差	均值	方差	均值	方差	均值	方差
SRN	0.4697	0.0104	0.5394	0.0027	0.5388	0.0021	0.2878	0.0026
BNH	0.2772	1.57e-4	0.2536	2.79e-4	0.2565	1.61e-4	0.1426	8.15e-5
CONSTR	0.0112	8.6e-9	0.0124	8.68e-7	0.0128	5.28e-7	0.0078	1.66e-7
TNK	0.0057	1.07e-6	0.0027	1.85e-7	0.0024	1.17e-7	0.0022	1.16e-7
OSY	3.8571	2.4207	0.4993	0.0407	0.4710	0.0307	0.4084	0.0351
CTP2	0.0670	0.0087	0.0370	5.18e-5	0.0033	4.36e-5	0.0022	2.28e-5
CTP5	0.0450	0.0022	0.0140	2.62e-5	0.0157	3.03e-5	0.0151	1.96e-5
CTP8	0.3199	0.0509	0.1427	0.0183	0.1514	0.0159	0.1124	6.66e-4

表 4 收敛性指标 GD 的最大值与最小值

测试函数	算法 1		算法 2		算法 3		本文算法	
	最大值	最小值	最大值	最小值	最大值	最小值	最大值	最小值
SRN	0.0599	0.0146	0.0286	0.0101	0.0184	0.0082	0.0167	0.0056
BNH	0.0056	0.0035	0.0061	0.0033	0.0052	0.0026	0.0036	0.0015
CONSTR	5.93e-4	2.96e-4	4.48e-4	2.66e-4	4.11e-4	2.37e-4	2.91e-4	1.26e-4
TNK	8.67e-4	4.62e-4	2.15e-4	1.27e-4	1.75e-4	1.10e-4	1.71e-4	1.06e-4
OSY	1.5652	0.1743	0.9672	0.0138	0.4530	0.0193	0.4133	0.0123
CTP2	0.1264	0.0084	0.0344	0.0017	0.0243	0.0001	0.0167	8.21e-5
CTP5	0.1023	0.0032	0.0333	0.0002	0.0325	0.0002	0.0316	9.03e-5
CTP8	0.3981	0.0014	0.0401	8.32e-6	0.0400	7.22e-6	0.0388	1.56e-6

表 5 分布性指标 SP 的最大值与最小值

测试函数	算法 1		算法 2		算法 3		本文算法	
	最大值	最小值	最大值	最小值	最大值	最小值	最大值	最小值
SRN	0.7225	0.2336	0.6693	0.4260	0.6896	0.4526	0.5188	0.2447
BNH	0.2983	0.2501	0.2928	0.2154	0.2844	0.2271	0.1621	0.1229
CONSTR	0.0214	0.0097	0.0151	0.0108	0.0142	0.0112	0.0087	0.0068
TNK	0.0080	0.0371	0.0035	0.0021	0.0036	0.0018	0.0032	0.0007
OSY	7.7411	0.3741	1.2460	0.3025	1.2451	0.2780	1.2147	0.2493
CTP2	0.4531	0.0125	0.0391	1.10e-5	0.0335	6.50e-5	0.0274	1.56e-5
CTP5	0.2021	9.60e-3	0.0180	5.27e-5	0.0365	3.81e-5	0.0251	3.26e-5
CTP8	0.3485	0.1592	0.5352	0.0040	0.5571	0.0731	0.1370	4.10e-4

索能力的同时增强算法在约束边界附近的搜索能力, 可帮助算法更好地获得各类约束优化问题的 Pareto 前沿, 提高了算法的收敛性。

对比分析前 3 个算法与本文算法的收敛性指标及分布性指标. 由于本文算法在算法 3 的基础上采用基于拥挤距离的动态分布性维护策略, 改进了 Pareto 前沿的分布性, 避免了搜索陷入局部最优问题. 因此, 针对 8 种不同难度的测试函数, 本文算法均可获得最优的收敛性指标均值及分布性指标均值. 虽然在处理部分函数时本文算法获得的分布性指标方差并不是最小, 但考虑方差数量级极小, 可忽略其表达的 Pareto 前沿收敛性、分布性差异。

图 1~图 3 为算法 1、算法 2、算法 3 与本文算法分别求解 OSY 函数和两个 CTP 系列函数得到的 Pareto 前沿对比 (f_1 和 f_2 为目标函数值). 图 2 和图 3 中实线为无约束时所获得的 Pareto 前沿. 由图 1~图 3 可看出, 在处理 OSY 函数时, 算法 1、算法 2 和算法 3 只能获得部分 Pareto 前沿, 而本文算法则可以得到完整 Pareto 前沿. 在处理 CTP2 与 CTP5 函数时, 虽然算法 1、算法 2 和算法 3 都可以获得完整的 Pareto 前沿, 但本文算法所获得的 Pareto 前沿具有更好的分布性和多样性. 所选取的 OSY、CTP 系列测试函数的 Pareto 前沿为约束边界, 所提出算法获得了更好的 Pareto 最优解, 说明算法在约束边界的搜索能力更好。

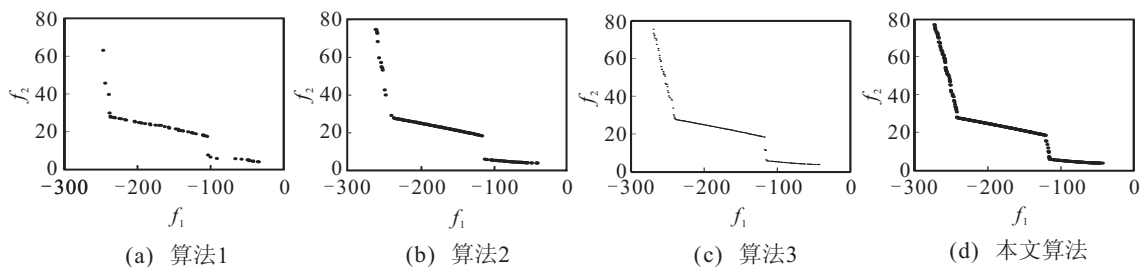


图 1 函数 OSY 的 Pareto 前沿对比

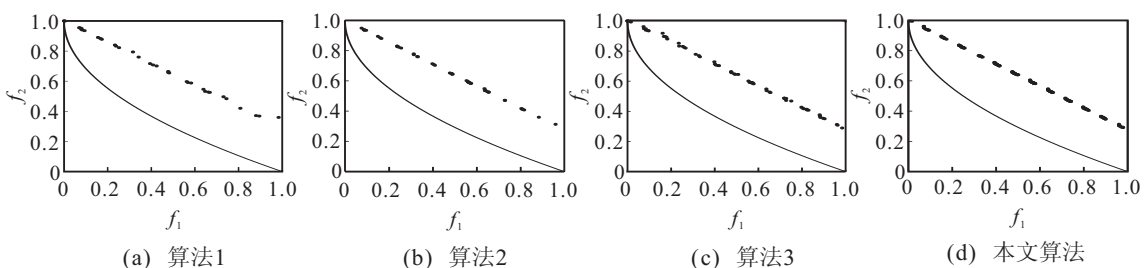


图 2 函数 CTP2 的 Pareto 前沿对比

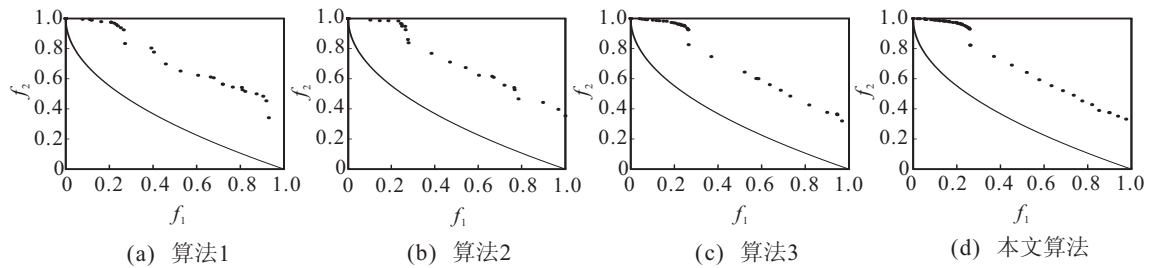


图3 函数CTP5的Pareto前沿对比

5 结 论

本文提出了一种基于自适应进化学习的约束多目标粒子群优化算法. 该算法根据不符合约束条件粒子的约束违反程度修正多目标粒子群优化算法的进化学习公式, 有效地提高了算法在约束边界区域的搜索能力; 引入了一种基于拥挤距离的Pareto最优解分布性动态维护策略, 在不增加算法复杂度的前提下, 改进了Pareto前沿的分布性. 实验结果表明, 在处理带约束多目标优化问题时, 基于自适应进化学习的约束多目标粒子群优化算法可以获得具有更好收敛性、分布性和多样性的Pareto前沿.

参考文献(References)

- [1] Li X, Du G. BSTBGA: A hybrid genetic algorithm for constrained multi-objective optimization problems[J]. *Computers & Operations Research*, 2013, 40(1): 282-302.
- [2] Singh H K, Ray T, Smith W. C-PSA: Constrained Pareto simulated annealing for constrained multi-objective optimization[J]. *Information Sciences*, 2010, 180(13): 2499-2513.
- [3] 郭俊, 桂卫华, 陈晓方. 基于粗糙集理论与差分进化的混合多目标优化算法[J]. *控制与决策*, 2013, 28(5): 736-740.
(Guo J, Gui W H, Chen X F. A hybrid algorithm based on rough set theory and differential evolution for multi-objective optimization[J]. *Control and Decision*, 2013, 28(5): 736-740.)
- [4] Homaifar A, Qi C X, Lai S H. Constrained optimization via genetic algorithms[J]. *Simulation*, 1994, 62(4): 242-253.
- [5] Li L D, Li X D, Yu X H. Power generation loading optimization using a multi-objective constraint-handling method via PSO algorithm[C]. *The IEEE Int Conf on Industry Informatics*. Korea, 2008: 1632-1637.
- [6] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(2): 182-197.
- [7] Kennedy J, Eberhart R. Particle swarm optimization[C]. *IEEE Int Conf on Neural Networks*. Australia, 1995, 4: 1942-1948.
- [8] 张勇, 巩敦卫, 任永强, 等. 用于约束优化的简洁多目标微粒群优化算法[J]. *电子学报*, 2011, 39(6): 1436-1440.
(Zhang Y, Gong D W, Ren Y Q, et al. Barebones multi-objective particle swarm optimizer for constrained optimization problems[J]. *Acta Electronica Sinica*, 2011, 39(6): 1436-1440.)
- [9] He Q, Wang L. A hybrid particle swarm optimization with a feasibility-based rule for constrained optimization[J]. *Applied Mathematics and Computation*, 2007, 186(2): 1407-1422.
- [10] Li L D, Yu X H, Li X D, et al. A modified PSO algorithm for constrained multi-objective optimization[C]. *The 3rd Int Conf on Network and System Security*. Australia, 2009: 462-467.
- [11] 王小刚, 李明杰, 王福利, 等. 一种新的多目标粒子群算法的研究与应用[J]. *东北大学学报: 自然科学版*, 2008, 29(10): 1377-1380.
(Wang X G, Li M J, Wang F L, et al. Study on a new MOPSO and its applications[J]. *J of Northeastern University: Natural Science*, 2008, 29(10): 1377-1380.)
- [12] 贾树晋, 杜斌, 岳恒. 基于局部搜索与混合多样性策略的多目标粒子群算法[J]. *控制与决策*, 2012, 27(6): 813-818.
(Jia S J, Du B, Yue H. Local search and hybrid diversity strategy based multi-objective particle swarm optimization algorithm[J]. *Control and Decision*, 2012, 27(6): 813-818.)
- [13] Qu B Y. Constrained multi-objective optimization algorithm with diversity enhanced differential evolution[C]. *2010 IEEE Congress on Evolutionary Computation*. Spain, 2010: 1-5.
- [14] Wong E Y C, Yeung H S C, Lau H Y K. Immunity-based hybrid evolutionary algorithm for multi-objective optimization in global container repositioning[J]. *Engineering Applications of Artificial Intelligence*, 2009, 22(6): 842-854.

(责任编辑: 孙艺红)