

一种带差分局部搜索的改进型 NSGA2 算法

谢承旺¹ 李 凯¹ 廖国勇²

(华东交通大学软件学院 南昌 330013)¹ (华东交通大学基础科学学院 南昌 330013)²

摘 要 NSGA2 算法以其 Pareto 支配的选择模式并辅以解个体密度估计算子选择胜出解的策略而成为了现代多目标进化算法的典范,但是该算法通过计算解个体的聚集距离来保持群体的分布性的机制存在一定的缺陷。鉴于此,提出了一种带差分局部搜索的改进型 NSGA2 算法。新算法利用差分进化中变异算子的定向引导作用,抽取其中的差分向量,并与 NSGA2 算法结合以改善解群的分布性。仿真实验表明:新算法较 NSGA2 算法在解群分布的均匀性和广度上有明显的改善。此外,新算法在时间复杂性方面与经典的 NSGA2 算法相当。

关键词 差分进化,局部搜索,NSGA2,分布性
中图分类号 TP301 **文献标识码** A

Improved NSGA2 Algorithm with Differential Evolution Local Search

XIE Cheng-wang¹ LI Kai¹ LIAO Guo-yong²

(School of Software, East China Jiaotong University, Nanchang 330013, China)¹

(School of Basic Science, East China Jiaotong University, Nanchang 330013, China)²

Abstract NSGA2 algorithm with its selection mode of Pareto dominate method and the strategy of using individual density estimation operator of solution to select winning solution becomes the model of modern multi-objective evolutionary algorithm, but the algorithm by computing the solution of individual crowding distance to keep the population distribution mechanisms has certain defects. In view of this, this paper proposed a kind of improved algorithm which takes differential local search with NSGA2 algorithm. The new algorithm uses the differential evolution mutation operator in directional guiding ideology, takes the difference vector, and combines the NSGA2 algorithm to improve the solution population distribution. Simulation results show that the new algorithm compared with the NSGA2 algorithm in the solution of cluster distribution uniformity and depth is improved obviously. In addition, the new algorithm in the time complexity is same as the classic NSGA2 algorithm.

Keywords Differential evolution, Local search, NSGA2, Diversity

1 引言

现实中的许多优化问题都是多属性的,通常需要对多个目标同时优化。一般说来,多目标优化问题(Multi-objective Optimization Problem, MOP)中各目标之间通过决策变量相互制约,对其中一个目标优化必须以其它目标作为代价,因而总体目标没有单个最优解。这就使得一次能够得到一组最优解的算法比那些一次只能得到一个最优解的算法更具优势。基于群体搜索的进化算法可并行搜索多个目标,因此非常适合求解多目标优化问题。

第一个真正意义上的多目标进化算法(Multi-Objective Evolutionary Algorithms, 简称 MOEAs)当属 Schaffer 于 1985 年提出的向量评估遗传算法(VEGA)^[1]。此后研究者们针对不同的实际问题,提出了各种不同的 MOEAs,比较有代表性的有:Zitzler 和 Thiele 提出的 SPEA(Strength Pareto Evolutionary Algorithm)^[2], Kim 等人在其基础上提出了改进的

SPEA2^[3], Srinivas 和 Deb 提出了 NSGA(Non-dominated Sorting Genetic Algorithm)^[4], Deb 等在此基础上提出了改进的 NSGA2^[5], 以及 Corne 等提出的 PESA(Pareto Envelope-based Selection Algorithm)^[6]等。

多目标进化算法的目标主要是使种群快速收敛,并且使解个体能够广泛而均匀地分布在问题的 Pareto 最优前沿上^[7], 因此,均匀分布和快速收敛是 MOEAs 的两大目标。

目前,基于 Pareto 支配的多目标进化算法最为活跃,而在这些多目标进化算法中又以 NSGA2 算法最具代表性。NSGA2 算法以其 Pareto 支配的选择模式并辅以解个体密度估计算子选择胜出解的机制而成为现代多目标进化算法的典范。NSGA2 算法通过计算解个体的聚集距离来度量解的密度以保持种群的分布性。需要指出的是,解个体的聚集距离值与其解密度之间会存在不一致性,这种不一致性可能导致一些分布性好的个体被淘汰而分布性差的个体得到保留,容易造成个体分布不均匀,甚至在 Pareto 最优前沿的某些区域

到稿日期:2012-12-24 返修日期:2013-03-12 本文受国家自然科学基金(61165004),江西省自然科学基金(20114BAB201025),江西省教育厅科技项目(GJJ12307)资助。

谢承旺(1974-),男,博士,副教授,硕士生导师,主要研究方向为智能计算、智能信息系统, E-mail:chengwangxie@163.com;李 凯(1987-),男,硕士生,主要研究方向为智能计算;廖国勇(1975-),男,硕士,讲师,主要研究方向为信号处理、图像处理。

没有个体分布的现象。

差分进化算法(Differential Evolution, DE)^[8]具有子代产生简单、收敛迅速、实现简便、易于与其它算法相结合构造出性能更优的算法等特点。与传统进化算法相比,DE采用了特殊的变异算子对解个体的进化方向进行干预扰动,具有局部寻优的优势。

本文针对经典 NSGA2 算法中解群分布性保持机制的不足进行改进,利用差分进化中的定向变异机制改善解个体的分布性,提出一种带差分局部搜索的改进型 NSGA2 算法(Differential Evolution Local Search-based Non-dominated Sorting Genetic Algorithm 2, DELS_NS GA2)。新算法较 NSGA2 算法在解群的分布性能上有较大改善,而且保持了良好的收敛性,时间复杂性方面则与 NSGA2 算法处于同一数量级。

2 多目标优化问题及相关概念

为不失一般性,考虑下面 n 个自变量和 k 个目标函数的多目标函数最小化问题(MOP):

$$\begin{aligned} \text{Min: } y=f(x) &= (f_1(x), f_2(x), \dots, f_k(x)) \\ \text{S. T. } e(x) &= (e_1(x), e_2(x), \dots, e_m(x)) \leq 0 \end{aligned} \quad (1)$$

式中, $x=(x_1, x_2, \dots, x_n) \in X \subset R^n$, $y=(y_1, y_2, \dots, y_k) \in Y \subset R^k$, x 表示决策向量, y 表示目标向量, X 表示决策向量 x 形成的决策空间, Y 表示目标向量 y 形成的目标空间,约束条件 $e(x) \leq 0$ 确定决策变量 x 的可行取值范围。本文仅讨论无约束 MOP 问题。

为方便本文讨论,首先给出 MOP 问题可行解集的概念。

定义 1(可行解集) 可行解集 X_f 为满足式(1)中约束条件 $e(x)$ 的决策向量 x 的集合,即 $X_f = \{x \in X | e(x) \leq 0\}$ 。

对 MOP 问题而言,一般 X_f 不可以全部排序,而只能针对某个指标进行排序,即部分排序,其情形比单目标优化问题复杂。为此需要在决策空间和目标空间上分别定义向量之间的偏序关系。

定义 2(决策空间中的支配关系) 对于决策向量 $a, b \in X_f$, $a < b$ (a 支配 b); 当且仅当 $\forall i \in (1:k); f_i(a) \leq f_i(b) \wedge \exists j \in (1:k); f_j(a) < f_j(b)$ 。

定义 3(目标空间中的支配关系) 设 $u=(u_1, u_2, \dots, u_k)$ 和 $v=(v_1, v_2, \dots, v_k)$ 是目标空间中的两个向量,称 u 支配 v , 记为 $u < v$, 当且仅当 $u_i \leq v_i (i=1:k) \wedge \exists j \in (1:k); u_j < v_j$ 。

定义 4(Pareto 最优解) 给定一个多目标优化问题 $\min f(x)$, 若 $x^* \in X_f$, 且不存在其它的 $x^* \in X_f$ 使得 $f_i(x^*) \leq f_i(x^*) (i=1:k)$ 成立, 且其中至少有一个是严格不等式, 则称 x^* 是 $\min f(x)$ 的 Pareto 最优解。其中, X_f 为定义 1 中的可行解集。

定义 5(Pareto 最优解集) 给定一个多目标优化问题 $\min f(x)$, 它的最优解集 P^* 或 P_{true} 定义为: $P^* = \{x^*\} = \{x \in X_f | \neg x' \in X_f; f_j(x') \leq f_j(x), j=1:k\}$, 其中 X_f 的意义同定义 1。

定义 6(进化群体的非劣解集) 设 pop 为 MOEAs 进化过程中的某一代群体, 解个体 $x^* \in pop$ 为群体的当前最优解个体或非劣解, 当且仅当 $\neg \exists x \in pop; x < x^*$; pop 中所有非劣解个体的集合称为当前进化群体的非劣解集。

定义 7(Pareto 最优前沿) 给定一个多目标优化问题

$\min f(x)$ 和它的最优解集 $\{x^*\}$, 它的 Pareto 最优前沿 PF^* 或 PF_{true} 定义为 $PF^* = \{f(x) = (f_1(x), f_2(x), \dots, f_k(x)) | x \in \{x^*\}\}$ 。

3 带差分局部搜索的改进型 NSGA2 算法

3.1 NSGA2 中聚集距离的计算

Deb 等在文献[5]中给出了 NSGA2 算法中保持解群的分布性和多样性的策略。该算法依据种群中个体所处的层级以及它们的聚集距离定义一个偏序集(partial order set), 构造新一代种群时依次在偏序集中选择个体。其中个体聚集距离的计算如算法 1 所示。

算法 1 个体聚集距离的计算

```
crowding-distance-assignment(P)
{
  N=|P|; //N 为群体大小
  for each i, P[i].distance=0;
  //初始化每个个体的聚集距离
  for each objective m
    //针对每个子目标进行如下操作
    {
      P=sort(P, m);
      //对子目标 m 的函数值进行排序
      for i=2 to (N-1) //针对边界点之外的解
        P[i].distance = P[i].distance + (P[i+1].m - P[i-1].m)
    } end for objective m
  P[0].distance = P[N].distance = ∞;
  //给边界点一个最大值确保每次它们均能入选下一代
}
```

产生新群体时,通常那些层级靠前并且聚集距离较大的个体将保留并参与下一代的繁殖。该方法存在一个缺陷:个体的聚集距离与其密度度量之间会存在不一致,也就是说,聚集距离大的个体其解密度不一定小,下面通过图 1 说明存在的问题。




图 1 种群内个体分布实例图

图 1 中,个体 B 和个体 C 的聚集距离都较大,而且它们的聚集距离值非常接近,如果按照 NSGA2 中的分布性保持机制,这两个点可能会同时保留下来,但是,理想的种群分布应该是均匀的,因此 B、C 这两个点应该只保留其中一个。个体 E 的附近也存在非常接近的点,在进化初期,由于其处于最高层级集合(即当代种群的非劣解集)中,因此 E 很可能被保留下来,这种情形不利于种群分布的多样性,容易造成局部收敛。

3.2 差分局部搜索

差分算法是基于种群的进化寻优机制,其采用特殊的变异算子对个体进化方向进行干预扰动。对于种群 P , 父代个体 $p_i \in P$, 其临时子代 p_i' 由以下变异算子产生, 如式(2)所示:

$$p_i' = \gamma \cdot p_{best} + (1-\gamma)p_i + F \cdot \sum_{k=1}^K (p_{a_k}^i - p_{b_k}^i) \quad (2)$$

式中, $\gamma \in [0, 1]$ 代表最佳个体对变异方向的影响程度权重, p_{best} 是父代最佳个体, F 是扰动向量权重。DE 的变异算子由两部分构成, 一般将 $\gamma \cdot p_{best} + (1-\gamma)p_i$ 称为差分向量, 其一部分称为扰动向量。差分向量利用种群最佳个体信息, 引导其它个体向最佳个体进化; 扰动向量产生随机变异, 为 DE 提供了自适应特性, γ, K, F 与算法的性能相关^[9,10]。

为改善 NSGA2 算法中种群分布性, 本文引入差分进化的思想, 利用式(2)中的差分向量, 将同一层级集合中相邻的两个个体分别作为 p_{best} 与 p_i , 并且将 γ 设为 0.5, 作为局部搜索算子, 即

$$\gamma \cdot p_a + (1-\gamma)p_b \quad (3)$$

由式(3)可知: 同一层级集合中相邻个体利用局部搜索算子产生的新个体与原始个体 p_a 和 p_b 之间互为非支配关系, 并且大量数据实验表明, 新个体空间位置一般位于 p_a 和 p_b 的中间区域。

本文的差分局部搜索方法首先需要找出当前代种群最高的层级集合 $F(1)$ (即当前代的非支配个体集), 确定距离阈值, 选择需要进行局部搜索的相邻个体, 并根据式(3)产生出新个体, 检查新个体与原始个体间是否满足相互非支配的条件。如果不满足相互非支配的条件则舍弃新产生的个体, 否则将新个体并入 $F(1)$ 中, 形成新的个体集合 $F(1)'$, 然后根据算法 1, 计算 $F(1)'$ 中所有个体的聚集距离, 根据各个个体聚集距离值保留 $|F(1)|$ 个个体。这里的搜索方法涉及到两个重要的算子: (1) 确定距离阈值; (2) 选择相邻个体。

(1) 确定距离阈值的方法: 首先找出当前种群的非支配解集合 $F(1)$ 在子目标 $i (i=1:k)$ 下的两个极值端点, 并求得它们的目标值差, 记为 $distance_{0,n}^i$, 然后按下列公式求得子目标 i 下的距离阈值 δ^i :

$$\delta^i = distance_{0,n}^i \times 2 / (|F(1)| - 1) \quad (4)$$

式中, $|F(1)|$ 是当代种群中的非支配个体的数目, δ^i 在进化过程中将随着当代种群非支配集合 $|F(1)|$ 的规模变化而动态调整, 从而保证了当代非支配前沿的均匀分布。

如图 2 所示, 距离阈值分别为两边界个体 0 和 n 在子目标下的距离与当代非支配集个体数 $|F(1)|$ 减去 1 后比值的两倍。




图 2 种群内个体分布实例图

(2) 选择相邻的个体: 对非支配集 $F(1)$ 按子目标 i 进行排序, 将相邻个体 A 和 B 距离与子目标 i 的距离阈值 δ^i 进行比较, 如果大于或等于距离阈值 δ^i , 且个体 A 和 B 在其它子目标 $j (j=1:k, j \neq i)$ 下的目标值至少有一对不相等, 即 $\exists j \in I (j \neq i), I = \{1, 2, \dots, k\}$, 使 $f_A^j \neq f_B^j$, 则相邻个体对 (A, B) 需要执行差分局部搜索。

根据上述方法可以判定图 2 中有两组相邻个体满足局部搜索条件, 分别为 (A, B) 和 (C, D) , 通过差分局部搜索, 产生

两个新个体 F, G , 最后判断 F 与 (A, B) 以及 G 与 (C, D) 是否满足互相非支配要求。显然, F, G 均满足要求, 并且它们空间位置大约位于 A 与 B 以及 C 与 D 的中点处。

继续执行差分局部搜索将移除个体 B 和 E , 新产生的个体 F 和 G 将与更新后的非支配解集合合并形成下一代种群, 其改善的分布性效果如图 3 所示。




图 3 种群内个体分布实例图

在进化初期, 这种差分局部搜索有助于种群分布的广泛性和均匀性, 增强了种群的多样性, 防止过早收敛。在进化后期, 它对于种群最终非支配解集的分布性具有明显的改进。

3.3 DELS_NSGA2 算法

在 3.1 节和 3.2 节的基础上给出 DELS_NSGA2 算法的流程如下:

(1) 初始化: 产生一个初始群体 P_0 , 设定算法执行所需的参数, 并置 $t=0$;

(2) 杂交选择: 使用二元锦标赛选择 P_t 中的个体进入杂交池, 设定其规模等于 N ;

(3) 遗传操作: 对杂交池中个体执行交叉和变异操作, 产生的新个体进入 Q_t 。

(4) 适应值计算: 计算 P_t 和 Q_t 中个体的适应度值。

(5) 环境选择: 将 P_t 和 Q_t 中的所有非支配个体拷贝到非支配集 Nds 中。如果 Nds 的规模超过 N , 则使用算法 1 计算个体的密度, 选择密度低的个体优先进入 P_{t+1} , 直到规模等于 N ; 如果 Nds 规模小于或者等于 N , 则拷贝 Nds 中的个体进入 P_{t+1} , 规模不足 N 的部分, 选择适应度值较高的支配个体进入 P_{t+1} , 直到其规模等于 N 。

(6) 判定差分局部搜索: 利用 3.2 节描述的差分局部搜索方法, 对当前种群 P_{t+1} 的非劣解集执行差分局部搜索。

(7) 终止: 如果 $t < T, t=t+1$, 转至步骤(2), 否则将 P_{t+1} 中的非支配个体作为最终结果输出。

DELS_NSGA2 算法中差分局部搜索算子的时间复杂度为 $O(MN \log N)$, 其中 M 表示优化的目标数目, N 表示种群的规模, 而算法用到的非支配排序算子的时间复杂度为 $O(MN^2)$, 因此整个算法的时间复杂度为 $O(MN^2)$, 其与 NSGA2 算法的时间复杂性相当。

4 实验与分析

4.1 测试函数与实验环境

选择了 5 个不同的 MOP 测试函数来验证算法的性能, 程序运行在 2.3GHz CPU、4G 内存、Windows 7、32 位环境下。测试函数的描述如表 1 所列。

为了更直观地显示出分布性差异, 算法的执行参数设置为种群规模 $popsize=50$, 运行代数 $gen=500$, 解个体采用实数编码, 交叉概率 $p_c=0.9$, 变异的概率 $p_m=0.1$ 。

表1 测试函数

测试问题	目标函数	约束条件及特征
ZDT1	$f_1(x_1) = x_1$	$m=30; 0 \leq x_i \leq 1$ 真实 Pareto 凸
	$f_2(x) = g(1 - \sqrt{f_1/g})$	
	$g(x) = 1 + 9 \sum_{i=2}^m x_i / (m-1)$	
ZDT2	$f_1(x_1) = x_1$	$m=30; 0 \leq x_i \leq 1$ 真实 Pareto 凹
	$f_2(x) = g(1 - (f_1/g)^2)$	
	$g(x) = 1 + 9 \sum_{i=2}^m x_i / (m-1)$	
ZDT3	$f_1(x_1) = x_1$	$m=30; 0 \leq x_i \leq 1$ 真实 Pareto 凸且非连续
	$f_2(x) = g(1 - \sqrt{f_1/g}) - (f_1/g) \sin(10\pi f_1)$	
	$g(x) = 1 + 9 \sum_{i=2}^m x_i / (m-1)$	
ZDT4	$f_1(x_1) = x_1$	$m=10; 0 \leq x_i \leq 1,$ $-5 \leq x_i \leq 5$ 真实 Pareto 凸
	$f_2(x) = g(1 - \sqrt{f_1/g})$	
	$g(x) = 1 + 10(m-1) + \sum_{i=2}^m (x_i^2 - 10 \cos(4\pi x_i))$	
ZDT6	$f_1(x_1) = 1 - \exp(-4x_1) \sin^6(6\pi x_1)$	$m=10; 0 \leq x_i \leq 1$ 真实 Pareto 凹
	$f_2(x) = g(1 - (f_1/g)^2)$	
	$g(x) = 1 + 9(\sum_{i=2}^m x_i / (m-1))^{0.25}$	

4.2 评价方法

多目标进化算法研究的目的是使种群快速收敛并均匀分布于问题的 Pareto 最优前沿。为了评估多目标进化算法的分布性,本文采用 Schott 提出的空间评价方法^[12],其定义如下:

$$SP = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (\bar{d} - d_i)^2} \quad (5)$$

式中, $d_i = \min_j (|f_1^j(x) - f_1^i(x)| + |f_2^j(x) - f_2^i(x)|)$, $i, j = 1, \dots, n$, n 是解集中个体的数目, \bar{d} 是所有 d_i 的平均值。SP 值越小,说明解集分布越均匀。

4.3 实验与数据分析

利用 DELS_NSGA2 和 NSGA2 算法在前述的环境下对表 1 中的测试函数求解,得到 Pareto 前沿,如图 4—图 8 所示。




图 4 两种算法在 ZDT1 上的最终边界




图 5 两种算法在 ZDT2 上的最终边界




图 6 两种算法在 ZDT3 上的最终边界




图 7 两种算法在 ZDT4 上的最终边界




图 8 两种算法在 ZDT6 上的最终边界

不仅如此,本文还将 DELS_NSGA2 与 NSGA2 求解同一 MOP 问题所获得的近似 Pareto 解集与 MOP 问题真正的 Pareto 前沿做比较,图 9—图 13 就是它们在求解 ZDT1—ZDT4 以及 ZDT6 等 5 个测试例中所获得结果的直观显示。




图 9 两种算法在 ZDT1 上最终边界与真实 Pareto 前沿的比较




图 10 两种算法在 ZDT2 上最终边界与真实 Pareto 前沿的比较




图 11 两种算法在 ZDT3 上最终边界与真实 Pareto 前沿的比较




图 12 两种算法在 ZDT4 上最终边界与真实 Pareto 前沿的比较




图 13 两种算法在 ZDT6 上最终边界与真实 Pareto 前沿的对比

从图 4—图 8 可以看出,NSGA2 算法获得的个体分布不均匀,容易造成某些区域个体分布过于集中,而某些地方的个体稀疏,甚至没有个体;改进后的 DELS_NSGA2 在分布的广度和均匀性方面均优于 NSGA2,特别在 ZDT2、ZDT3 和

(下转第 273 页)

- [3] 李乐, 章毓晋. 基于线性投影结构的非负矩阵分解[J]. 自动化学报, 2010, 36(1): 23-39
- [4] 林庆, 李佳, 雍建平, 等. 一种改进的基于 NMF 的人脸识别方法[J]. 计算机科学, 2012, 39(5): 243-245
- [5] Yuan Zhi-jian, Oja E. Projective nonnegative matrix factorization for image compression and feature extraction[C]//Proceedings of the fourteenth Scandinavian Conference on Image Analysis. 2005: 333-342
- [6] Lee D D, Seung H S. Algorithms for non-negative matrix factorization[J]. Advances in Neural Information Processing Systems, 2001, 13: 556-562
- [7] Yoo J, Choi S. Orthogonal non-negative matrix tri-factorization for co-clustering: multiplicative updates on stiefel manifolds[J]. Information Processing & Management, 2010, 46(5): 559-570

- [8] Li S Z, Hou Xin-wen, Zhang Hong-jiang, et al. Learning spatially localized, parts-based representation[C]// Proceedings of the IEEE conference on Computer Vision and Pattern Recognition. 2001: 1-6
- [9] Li Zhao, Wu Xin-dong, Peng Hong. Non-negative matrix factorization on orthogonal subspace[J]. Pattern Recognition Letters, 2010, 31(9): 905-911
- [10] Buciu I, Naformita I. Non-negative matrix factorization methods for face recognition under extreme lighting variations[C]// Proceedings of the International Symposium on Signals, Circuits and Systems. 2009: 125-128
- [11] Yang Zhi-rong, Yuan Zhi-jian, Laaksonen J. Projective nonnegative matrix factorization with applications to facial image processing[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2007, 21(8): 1353-1362

(上接第 238 页)

ZDT4 上表现尤为突出。另外从图 9—图 13 可以看出, DELS_NSGA2 的收敛性与 NSGA2 相当, 均能有效收敛到真实的 Pareto 前沿。

表 2 给出了两种算法在不同测试函数上的分布性度量 (SP) 结果。其中的数据为算法运行 10 次统计得到的 SP 平均值 SP(AVG) 和方差 SP(σ), 表中加粗的数据为最好值。

表 2 算法的分布性平均 SP 及其方差 σ 的比较

	DELS_NSGA2		NSGA2	
	SP(Avg)	SP(σ)	SP(Avg)	SP(σ)
ZDT1	0.011507	0.002289	0.015961	0.001972
ZDT2	0.011773	0.002668	0.016862	0.002284
ZDT3	0.012203	0.001893	0.016023	0.003657
ZDT4	0.013037	0.0021705	0.017641	0.00094
ZDT6	0.011923	0.004101	0.015522	0.001173

从表 2 可以看出, DELS_NSGA2 算法的 SP 均值在 ZDT 系列的 5 个测试例中的表现都要明显好于 NSGA2, 说明 DELS_NSGA2 算法能够有效地改善解群分布性。

结束语 本文提出了一种带差分局部搜索的改进型 NSGA2 算法, 算法利用差分进化中变异算子的定向引导思想, 抽取其中的差分向量, 并与经典的 NSGA2 算法相结合以改善解群的分布性。

利用 5 个 ZDT 测试例作为基准测试函数, 比较了 DELS_NSGA2 算法和 NSGA2 算法的分布性, 实验结果表明 DELS_NSGA2 算法获得的解群在分布的均匀性和广度上要明显优于 NSGA2 算法。不仅如此, DELS_NSGA2 算法的差分局部搜索过程的时间复杂度为 $O(MN \log N)$, 其中的非支配排序算子的时间复杂度为 $O(MN^2)$, 整个算法的时间复杂度为 $O(MN^2)$, 与 NSGA2 算法的时间复杂性相当。因此, DELS_NSGA2 算法是一种有前途的算法。

未来将把 DELS_NSGA2 算法应用在更多的工程设计与科学计算问题中, 以进一步测试其在各种环境中的表现, 不断改善其性能。

参考文献

- [1] Schaffer J D. Multiple objective optimization, with vector evalua-

- ted genetic algorithms[C]// Proceedings of International Conference on Genetic Algorithms and Their Applications. Pittsburgh, PA, 1985: 93-100
- [2] Zitzler E, Thiele L. Multi-objective evolutionary algorithms: A comparative case study and the strength pareto approach[J]. IEEE Transactions on Evolutionary Computation, 1999, 3(4): 257-271
- [3] Zitzler E, Laumanns M, Thiele L. SPEA2: Improving the strength Pareto evolutionary algorithm[R]. TIK2Report 103. 2001
- [4] Srinivas N, Deb K. Multi-objective optimization using non-dominated sorting in genetic algorithms[J]. Evolutionary Computation, 1994, 2(3): 221-248
- [5] Deb K, Agrawal S, Pratab A, et al. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGAII[R]. KanGAL Report 200001. Indian Institute of Technology, Kanpur, India, 2000
- [6] Corne D W, Knowles J D, Oates M J. The Pareto envelope-based selection algorithm for multiobjective optimization[C]// Schoenauer M, Deb K, Rudolph G, et al. Proceedings of the Parallel Problem Solving from Nature VI Conference. New York: Springer, 2000: 839-848
- [7] Deb K, Mohan M, Mishra S. A fast multi-objective evolutionary algorithm for finding well-spread Pareto-optimal solutions[R]. KanGAL Report No 2003002. 2003
- [8] Storn R, Price K. Differential Evolution—A Simple and Efficient Heuristic for global Optimization over Continuous Spaces[J]. Journal of Global Optimization, 1997, 11(4): 341-359
- [9] Noman N, Iba H. Accelerating differential evolution using an adaptive local search[J]. IEEE Trans, Evolut. Comput., 2008, 12: 107-125
- [10] 刘波, 王凌, 金以慧. 差分进化算法研究发展[J]. 控制与决策, 2007, 34(3): 1-5
- [11] 郑金华. 多目标进化算法及应用[M]. 北京: 科学出版社, 2007: 23-24
- [12] Schott J R. Fault tolerant design using single and multicriteria genetic algorithm optimization[D]. Department of Aeronautics and Astronautics, Massachusetts Institute of Technology, Cambridge, Massachusetts, 1995