

基于参考点的高维多目标粒子群算法

韩敏[†], 何泳, 郑丹晨

(大连理工大学 电子信息与电气工程学部, 辽宁 大连 116023)

摘要: 高维多目标优化问题一般指目标个数为4个或以上时的多目标优化问题. 由于种群中非支配解数量随着目标数量的增加而急剧增多, 导致进化算法的进化压力严重降低, 求解效率低. 针对该问题, 提出一种基于粒子群的高维多目标问题求解方法, 在目标空间中引入一系列的参考点, 根据参考点筛选出能兼顾多样性和收敛性的非支配解作为粒子的全局最优, 以增大选择压力. 同时, 提出了基于参考点的外部档案维护策略, 以保持最后所得解集的多样性. 在标准测试函数 DTLZ2 上的仿真结果表明, 所提方法在求解高维多目标问题时能够得到收敛性和分布性都较好的解集.

关键词: 高维多目标优化; 参考点; 粒子群优化

中图分类号: TP18

文献标志码: A

Reference-point-based particle swarm optimization algorithm for many-objective optimization

HAN Min[†], HE Yong, ZHENG Dan-chen

(Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116023, China)

Abstract: Many-objective optimization problems generally refer to problems with four or more objectives. Because the number of nondominated solutions increases quickly with the increase of the number of objectives, the evolutionary pressure and efficiency of multi-objective evolutionary algorithms decrease heavily. To solve this problem, this paper proposes a reference-point-based particle swarm optimization algorithm for many-objective optimization. A structured set of reference points is generated in the objective space, and then the solutions which have both good convergence and diversity are selected as the global best to increase the selection pressure. Meanwhile, a truncation method for the external archive based on the reference points is proposed to maintain the diversity of the solution set. The results of simulations on the DTLZ2 test problem show that the proposed algorithm can obtain a solution set which has both good convergence and diversity for many-objective optimization problems.

Keywords: many-objective optimization; reference point; particle swarm optimization

0 引言

多目标优化问题是工程实践与科学研究问题的主要形式之一, 各目标之间往往存在相互冲突, 最优解为一组互不占优的 Pareto 最优解集. 一般当目标个数为4个或以上时, 称为高维多目标问题. 由于高维多目标问题的冲突目标数量增多, 非支配解的数量急剧增加, 导致计算复杂度和搜索难度增大, 是国内外智能优化领域最难解决的问题之一^[1].

目前, 研究者们已经提出了多种改进以应对高维多目标问题, 其中大多为进化算法, 主要可以归纳为以下几类: 1) 改进支配关系, 扩大支配区域, 使一些质

量相对较差的个体被支配, 从而增大选择压力, 例如 ϵ 支配^[2]、 K 支配^[3-4]、格支配^[5]等; 2) 基于多样性的方法, 减少多样性维护策略所带来收敛性降低的负面影响, 如 Li 等^[6]提出的 SDE 的多样性策略, 在选择个体时兼顾了其收敛性和多样性; 3) 基于聚合的方法, 设计一组权重系数将高维多目标问题转化为单目标优化问题, 如 Zhang 等^[7]提出的基于分解的进化算法 (MOEA/D), 毕晓君等^[8]提出的高维多目标多方向协同进化算法 (HMMCA) 等; 4) 基于评价指标的方法, 通过给个体赋予适应度指标值来直接引导个体收敛到 Pareto 前沿, 如 Zitzler 等^[9]将指标值引入个体

收稿日期: 2016-04-01; 修回日期: 2016-06-24.

基金项目: 国家自然科学基金项目 (61374154, 61272375).

作者简介: 韩敏 (1959—), 女, 教授, 博士生导师, 从事复杂工业系统建模与控制、智能技术及优化算法等研究; 何泳 (1991—), 男, 硕士生, 从事复杂系统建模和智能优化算法的研究.

[†]通讯作者. E-mail: minhan@dlut.edu.cn

适应度函数中提出的IBEA算法;Bader等^[10]提出的基于Hypervolume的进化算法(HypE);5)基于参考点的方法,通过一系列的参考点来评价解的质量,从而辅助控制种群在目标空间中的分布,如Deb等^[11]提出的基于参考点的非支配排序遗传算法(NSGA-III);6)基于目标数量缩减的方法,通过降低目标维度来提升传统算法对高维目标的优化能力^[12].

粒子群算法(PSO)^[13]是一种基于群体迭代搜索的智能优化算法,可并行处理所有目标函数,具有操作简单,收敛速度快等优点,将其应用到求解多目标问题中的方法受到了学术界的广泛关注^[14].然而,目前大部分多目标粒子群主要针对2或3个目标的优化问题,如何使粒子群有效求解高维多目标问题还是一个亟待解决的问题.目前已有部分学者提出一些改进算法,例如Wickramasinghe等^[15]提出一种基于距离测度的高维多目标粒子群算法,不再使用Pareto支配关系,避免了Pareto支配带来的问题;Britto^[16]等提出改进外部档案维护策略以增大粒子群在解决高维多目标问题时的选择压力;章恩泽等^[17]提出一种改进的 r 支配高维多目标粒子群优化算法,粒子之间进行 r 支配比较,并优化了非 r 支配阈值的取值策略,在高维DTLZ2测试函数上表现出较好的优化效果.

本文提出一种基于参考点的高维多目标粒子群算法,为粒子群求解高维多目标优化问题提供一种新的思路.由于在高维目标空间中,维数的增多使得种群持续收敛和解集多样性维护方面出现较大的困难,如何筛选出能兼顾收敛性和多样性的个体成为一个关键问题.对此,将进化算法中基于参考点的策略引入到多目标粒子群算法中,并结合粒子群自身的特点,提出新的全局最优选择策略和外部档案维护策略,在充分发挥粒子群快速收敛的优势的同时保持解集的多样性分布.与其他典型的高维多目标算法进行仿真比较,结果表明所提算法在解决高维多目标问题时能够保持较好的收敛性和解集分布性.

1 高维多目标问题和粒子群算法

为了方便介绍所提算法,对高维多目标问题和粒子群算法的一些相关概念进行简要介绍.

1.1 高维多目标问题

假设最小化形式的多目标问题具有 n 个决策变量、 M 个优化目标,可表示为如下形式^[14]:

$$\begin{aligned} \min \quad & F(x) = (f_1(x), f_2(x), \dots, f_m(x))^T. \\ \text{s.t.} \quad & g_i(x) \geq 0, \quad i = 1, 2, \dots, p; \\ & h_j(x) = 0, \quad j = 1, 2, \dots, q. \end{aligned} \quad (1)$$

其中: $x = (x_1, x_2, \dots, x_n) \in \Omega \subset R^n$ 为 n 维决策向量, Ω 为决策空间; $F: R^n \rightarrow R^m$ 包含了 m 个目标函数; $g_i(x) \geq 0$ 为不等式约束条件; $h_j(x) = 0$ 为等式约

束条件.当 $M \geq 4$ 时,一般称为高维多目标问题.以下是多目标优化问题引出的几个相关定义.

定义1(Pareto支配)^[14] 称决策向量 $x_v = (v_1, v_2, \dots, v_n)$ 对 $x_u = (u_1, u_2, \dots, u_n)$ 是Pareto支配的,记为 $x_v \prec x_u$,当且仅当 $\forall i = 1, 2, \dots, m, f_i(x_v) \leq f_i(x_u)$,且 $\exists j = 1, 2, \dots, m, f_j(x_v) < f_j(x_u)$.

定义2(Pareto支配最优解集)^[14] 如果 $P^* = \{x \in R^n | \neg \exists x' \in R^n, x' \prec x\}$,则称 P^* 为Pareto最优解集.

定义3(Pareto前沿, PF^*)^[14] Pareto解集在目标函数上的映射,即 $PF^* = \{F(x) | x \in P^*\}$,映射之后的集合称为Pareto前沿.

1.2 粒子群算法

粒子群算法是由Kennedy等^[13]提出的一种基于种群搜索的进化计算技术.在第 k 次迭代时,种群中粒子 i 的速度和位置分别根据下式更新:

$$v_{i,d}^{(k+1)} = \omega v_{i,d}^{(k)} + c_1 r_1 (p_{i,d} - x_{i,d}^{(k)}) + c_2 r_2 (p_{g,d} - x_{i,d}^{(k)}), \quad (2)$$

$$x_{i,d}^{(k+1)} = x_{i,d}^{(k)} + v_{i,d}^{(k+1)}. \quad (3)$$

其中: ω 为惯性权重, $v_{i,d}^{(k)}$ 和 $x_{i,d}^{(k)}$ 分别为第 k 次迭代时粒子 i 的第 d 维变量的速度和位置, p_i 和 p_g 分别为粒子 i 的历史最优和全局向导的位置, c_1 和 c_2 为学习因子, r_1 和 r_2 为 $[0, 1]$ 区间上均匀分布的随机值.

2 基于参考点的高维多目标粒子群算法

针对高维多目标优化问题,本文提出一种基于参考点的高维多目标粒子群算法(RPMOPSO).首先在外部档案解集的目标空间中生成一系列均匀分布的参考点,然后根据非支配解与参考点的相对位置选择兼顾收敛性和多样性较好的个体作为粒子的全局向导,从而指引粒子向真实Pareto前沿收敛的同时均匀分布.

2.1 参考点生成和转换档案解集目标值

Das等^[18]提出的标准边界交叉(NBI)方法被广泛应用于目标空间中产生参考点,通过设定每维的步长和节点个数,循环迭代获取一组均匀分布的参考点.本文采用该方法在档案解集的目标空间中生成均匀分布的参考点.图1是在三维目标空间中产生参考点的示意图,其中: r_1 、 r_2 和 r_3 分别是目标的维数,每维都均匀分割成5个区间.




图1 参考点生成示意图

假设将每维目标分割成 p 个相等的区间,则参考点的个数为

$$H = C_{M+p-1}^p, \quad (4)$$

其中 M 是目标个数.当 M 取值为8或以上时,为防止参考点数量过多,将参考点分成外层和内层两层^[11],设 p_1 和 p_2 分别为外层和内层分割的区间数,则总的参考点数量为

$$H = C_{M+p_1-1}^{p_1} + C_{M+p_2-1}^{p_2}. \quad (5)$$

由于非支配解在各个目标的值范围可能不同,有必要对其目标值 $f_i(s)$ 进行相应转换如下^[11]:

$$\bar{f}_i(s) = (f_i(s) - z_i^{\min}) / (z_i^{\text{nad}} - z_i^{\min}). \quad (6)$$

其中: $z_i^{\min} = \min_{s \in A} f_i(s)$ 是外部档案 A 中的所有个体在目标 i 上的最小值, z_i^{nad} 是真实Pareto解集在目标 i 上的最大值.采用文献[19]中的方法对 z_i^{nad} 值进行估计.首先,找出 A 中在目标 i ($i = 1, 2, \dots, M$)上的极端解

$$s^i = \arg \min_{s \in A} \text{ASF}(s, \mathbf{w}); \quad (7)$$

$$\text{ASF}(s, \mathbf{w}) = \max_{j=1,2,\dots,M} \left\{ \frac{1}{w_{j,i}} \left| \frac{f_j(s) - z_j^{\min}}{z_j^{\text{nad}} - z_j^{\min}} \right| \right\}; \quad (8)$$

$$w_{j,i} = \begin{cases} 10^{-6}, & j \neq i; \\ 1, & j = i. \end{cases} \quad (9)$$

其中: $i = 1, 2, \dots, M$, M 是目标个数; z_i^{nad} 是上一次迭代时所估计的 z_i^{nad} 值.将 $\{s^1, s^2, \dots, s^M\}$ 构成 M 维的线性超平面,其在 $(1, z_2^{\min}, \dots, z_M^{\min})$, $(z_1^{\min}, 1, \dots, z_M^{\min})$, $(z_1^{\min}, \dots, z_{M-1}^{\min}, 1)$ 上的截距 a_1, a_2, \dots, a_M 通过下式计算得到:

$$\begin{bmatrix} (a_1 - z_1^{\min})^{-1} \\ \vdots \\ (a_M - z_M^{\min})^{-1} \end{bmatrix} = \mathbf{E}^{-1} \mathbf{u}. \quad (10)$$

其中: $\mathbf{E} = (\mathbf{f}(s^1) - \mathbf{Z}^{\min}, \dots, \mathbf{f}(s^M) - \mathbf{Z}^{\min})^T$, $\mathbf{Z} = (z_1^{\min}, z_2^{\min}, \dots, z_M^{\min})$, $\mathbf{u} = (1, 1, \dots, 1)^T$.如果 \mathbf{E} 非满秩,则令 $a_i = \max_{s \in A} f_i(s)$.求出截距 a_i 之后,令 $z_i^{\text{nad}} = a_i$.

根据以上步骤生成参考点和转换档案解集目标值之后,将原点和参考点连接成一系列的参考线,将档案内的非支配解关联到与其垂直距离最近的参考线中^[12].

值得注意的是,本文所提算法和参考文献[11]均采用了参考点的方法.但文献[11]中为多目标遗传算法,需要从种群中选择优秀个体遗传到下一代,因此参考点作用于种群.而在本文的粒子群算法中,需要从档案中选择全局最优来引导种群收敛,因此参考点作用于档案解集.另外,本文所提算法需要重新设计全局最优选择策略和外部档案维护策略,以下进行详细描述.

2.2 全局最优选择策略

粒子群优化算法中的全局最优个体影响整个粒子群的飞行和更新,因此也是改善整个算法性能的关键.通常,全局最优个体引导种群向真实Pareto前沿推进,或者沿Pareto前沿进行多样性分布.如果全局最优的收敛性不足则可能导致选择压力过小而不能有效推进收敛过程,而如果多样性差则容易造成种群早熟收敛而丢失多样性.因此,在全局最优选择策略上,应尽可能兼顾其收敛性和分布性,从而有效推进进化过程.

本文提出基于参考点的全局最优选择策略.由于同一参考线可能关联多个个体,数量越多,表明该参考线附近个体密度越大.因此,根据参考线所关联的个体数量作为多样性度量指标,记为参考线的拥挤度 ρ_j ($j = 1, 2, \dots, H$ 为参考线索引). ρ_j 值越大,说明个体在参考线 j 附近分布越密集,多样性越差.当两个非支配解被同一条参考线所关联,则视为具有相同的多样性.为了进一步评估非支配解的收敛性,定义非支配解 s 到参考点的距离作为收敛性度量指标,计算如下:

$$\sigma_s = \begin{cases} \sqrt{\sum_{i=1}^M (f_i^n(s) - z_i)^2}, & \sum_{i=1}^M f_i^n(s) \geq 1; \\ -\sqrt{\sum_{i=1}^M (f_i^n(s) - z_i)^2}, & \sum_{i=1}^M f_i^n(s) < 1. \end{cases} \quad (11)$$

其中: $z = (z_1, z_2, \dots, z_M)$ 为非支配解 s 所对应的参考点向量. $\sum_{i=1}^M f_i^n(x) \geq 1$ 表示非支配解位于参考点所在平面上方,反之表示在下方. σ 值越小,代表非支配解的收敛性越好.因此,在多样性相同的非支配解中,选择 σ 值最小的解作为全局向导.具体步骤如下:

Step 1: 随机选择两条参考线,取拥挤度 ρ 值较小的参考线 j 的非支配解集 J ,如果拥挤度值相同,则随机选择某一条参考线的非支配解集 J ;

Step 2: 在所取的非支配解集 J 中,选择 σ 值最小的解 $s = \arg \min_{s \in A} \sigma_s$ 作为粒子的全局向导.

图2为二维目标空间中全局最优选择策略示意图,从左到右4条参考线的拥挤度分别为 $\rho_1 = 2, \rho_2 = 2, \rho_3 = 1, \rho_4 = 2$.参考线3比其他参考线的拥挤度值更小,所以被选中的概率更大.假设被锦标赛选中的参考线为1和2,因为具有同样的 ρ 值,所以随机取其中一条参考线(假设选中参考线2)所关联的解集 J .比较 J 中非支配解的收敛性指标 σ 值,可以看出 $\sigma_d < \sigma_c$,所以收敛性更好的非支配解 d 将被选为粒子的全局向导.可见,本文算法首先选择了分布较稀疏的解,使粒子飞向稀疏的近似Pareto解集区域,并

采用锦标赛选择保持搜索行为的随机性,以避免早熟收敛;其次,在分布稀疏的解集中选择收敛性最好的解,以推进种群收敛。




图2 全局最优选择策略示意图

2.3 外部档案维护策略

外部档案用于保存种群进化过程中所发现的高质量的非支配解,当算法所得到的非支配解数量超过档案限定最大容量时,需要删除超出其最大容量的非支配解数量.在此过程中需要注意解集的多样性,以避免最终解集的多样性损失.因此,外部档案的更新和维护策略也是多目标粒子群的关键技术之一.为了维持解集的多样性,本文提出基于参考点的多样性维护策略.首先选择拥挤度最高的参考线,然后将其所关联的收敛性最差的非支配解删除.具体步骤如下:

Step 1: 取拥挤度为最高值的参考线集合 $J_{\max} = \{j : \arg \max_j \rho_j\}$, 随机选择其中一条参考线 j ;

Step 2: 将参考线 j 所关联的解集 J 中 σ 值最大的非支配解 $s = \arg \max_{s \in J} \sigma_s$ 删除.

根据该多样性维护策略,每次维护将外部档案分布性最差区域中收敛性最差的非支配删除,保持了解集的多样性和收敛性.

2.4 算法流程

RPMOPSO 算法的总体流程如下.

Step 1: 初始化. 设置种群 $P^{(0)}$, 种群数量 N 和最大迭代次数 G_{\max} ; 初始化粒子的个体最优为当前位置 x_i ; 设定档案 $A^{(0)} = \emptyset$, 以及最大容量 \bar{A} ; 令迭代次数 $k = 0$.

Step 2: 将 $P^{(0)}$ 中的非支配解加入 $A^{(0)}$, 形成 $A^{(1)}$.

Step 3: 令 $k := k + 1$.

Step 4: 按式(2)和(3)更新粒子的位置,并计算目标函数值.

Step 5: 将种群中的粒子与 $A^{(k)}$ 中的解 Pareto 支配比较,如果粒子支配 $A^{(k)}$ 中的旧解,或两者互不支配,则将粒子加入到 $A^{(k)}$ 中,并删除 $A^{(k)}$ 中被支配的旧解.

Step 6: 根据 $A^{(k)}$ 中的非支配解集生成参考点,对所有非支配解的目标值进行转换,并关联到相应的参考点.

Step 7: 判断 $A^{(k)}$ 中解的数量是否大于 \bar{A} , 如果是,则根据所提的外部档案维护策略删除多余的解,并更新所删除解所属的参考线 ρ 值.

Step 8: 若未达到算法终止条件,则回到 Step 3; 否则终止算法,最后输出 $A^{(k)}$ 中的非支配解.

2.5 计算复杂度分析

假设所求问题有 M 个目标数, H 个参考点, N 个粒子, 外部档案最大容量为 \bar{A} , 则根据所提算法流程, 每次迭代过程中的主要操作及最坏情况下的计算复杂度为: 找出理想点为 $O(MN)$, 找出极端解为 $O(M^2N)$, 计算截距 a_i 为 $O(M^3)$, 种群和档案中的解进行非支配比较为 $O(MN\bar{A})$, 档案中所有解关联到相应参考线为 $O(MNH)$, 式(11)中计算 σ_s 为 $O(M(\bar{A} + N))$, 找出所关联解的数量最少的参考线集合为 $O(H)$, 进行全局向导选择为 $O(N\bar{A})$. 在 RPMOPSO 算法中 $H = N = \bar{A}$, 故计算复杂度为 $O(MN^2)$.

3 仿真实验及结果分析

将所提算法与3种目前具有代表性的多目标进化算法(分别为 NSGA-III^[11], OMOPSO^[20] 和 IBEA^[9] 算法)对比. 采用 DTLZ2^[21] 问题进行仿真实验, 其变量维数设置为 $M + k - 1$. 其中: M 为目标个数, 本次仿真中 k 取 10. DTLZ2 问题的表达式如下:

$$\begin{aligned} \min f_1(x) &= (1 + g(x_M)) \prod_{i=1}^{M-1} \cos \frac{x_i \pi}{2}, \\ \min f_{m=2:M-1}(x) &= \\ & (1 + g(x_M)) \cdot \sin \frac{x_{M-m+1} \pi}{2} \cdot \prod_{i=1}^{M-m} \cos \frac{x_i \pi}{2}, \\ \min f_M(x) &= (1 + g(x_M)) \sin \frac{x_M \pi}{2}; \\ \text{s.t. } g(x_M) &= \sum_{x_i \in x_M} (x_i - 0.5)^2. \end{aligned} \quad (12)$$

采用反转世代距离(IGD)^[11] 作为性能评价指标. 其值越小, 说明算法所得解集的收敛性和多样性越好. 在参数设置方面, 参考点数量和种群规模大小设置如表 1 所示, RPMOPSO 中惯性权重 ω 为 0.729, 学习因子 c_1 和 c_2 均设置为 1.494, RPMOPSO 和 OMOPSO 的外部档案最大容量等于种群规模, 其他控制参数均按相应原文献设置. 表 2 为各算法独立运算 30 次时最终解集的 IGD 最小值、中位值和最大值, 最好结果用加粗字体表示, NSGA-III 的实验结果来自文献[11].

表 1 目标个数不同时参考点数量和种群规模

目标个数	p	参考点数量	NSGA-III 种群规模	粒子群和 IBEA 算法的种群规模
3	$p = 12$	91	92	91
5	$p = 6$	210	212	210
8	$p_1 = 3, p_2 = 2$	156	156	156
10	$p_1 = 3, p_2 = 2$	275	276	275

表2 对比算法在DTLZ2测试问题上的IGD指标对比结果

测试问题	目标个数	最大迭代次数	RPMOPSO(本文)	NSGA-III ^[11]	OMOPSO ^[20]	IBEA ^[9]
DTLZ2	3	250	8.021×10^{-4}	1.262×10^{-3}	1.093×10^{-3}	1.335×10^{-3}
			8.217×10^{-4}	1.357×10^{-3}	1.155×10^{-3}	1.409×10^{-3}
			8.178×10^{-4}	2.114×10^{-3}	1.251×10^{-3}	1.474×10^{-3}
	5	350	2.617×10^{-3}	4.254×10^{-3}	2.736×10^{-2}	1.542×10^{-2}
			2.521×10^{-3}	4.982×10^{-3}	3.152×10^{-2}	1.557×10^{-2}
			2.883×10^{-3}	5.862×10^{-3}	3.446×10^{-2}	1.574×10^{-2}
	8	500	9.571×10^{-3}	1.371×10^{-2}	7.956×10^{-2}	1.624×10^{-2}
			1.143×10^{-2}	1.571×10^{-2}	9.969×10^{-2}	2.051×10^{-2}
			1.641×10^{-2}	1.811×10^{-2}	1.348×10^{-1}	7.915×10^{-2}
	10	750	7.122×10^{-3}	1.350×10^{-2}	1.348×10^{-1}	1.349×10^{-2}
			8.817×10^{-3}	1.528×10^{-2}	1.071×10^{-1}	2.503×10^{-2}
			1.235×10^{-2}	1.697×10^{-2}	1.163×10^{-1}	4.287×10^{-2}

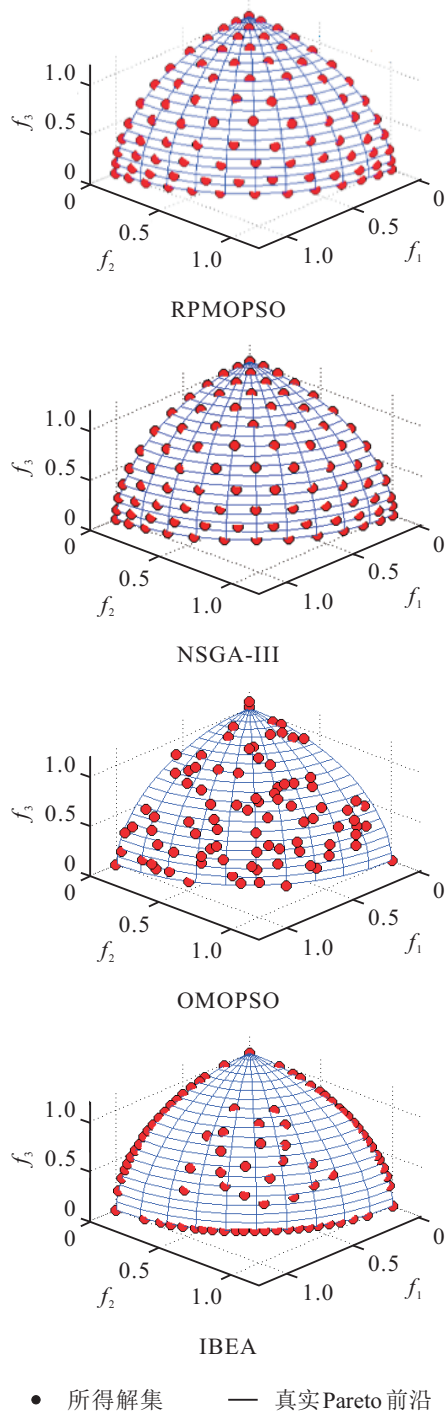


图3 4种对比算法在3目标DTLZ2上的Pareto近似前沿

DTLZ2问题用于测试算法在增加目标个数时的运算能力. 从表2可以看出,随着目标函数个数的增多,各算法所得解集的IGD值呈下降趋势,说明随着目标个数的增加,优化难度也逐渐增大. 图3展示了4种算法优化3目标DTLZ2所得的Pareto近似前沿. 综合来看,所提算法RPMOPSO在解决高维多目标问题具有一定的优势,具体分析如下.

1) 与OMOPSO算法相比,OMOPSO在目标数较少时收敛性表现较好,仅次于RPMOPSO(IGD值比NSGA-III和IBEA更小,但比RPMOPSO大),表明了粒子群具有收敛速度快的优势,在同样迭代次数下能达到更好的收敛性. 但由于不是针对高维多目标问题的算法,因此在目标个数较多的情况下,IGD值比其他3种算法更差,无法体现收敛速度的优势. 相比之下,RPMOPSO不仅在低维时具有较快的收敛速度,同时在高维目标情况下保持了较好的收敛性,IGD值均小于OMOPSO所得的IGD值.

2) 与同为解决高维多目标问题的NSGA-III、IBEA相比,RPMOPSO也具有收敛性和多样性的优势,IGD的值比NSGA-III、IBEA更小. 在图3中,IBEA在保持收敛的同时无法有效维持解集的多样性,出现较多的稀疏区域. 而RPMOPSO和NSGA-III取得的解集不仅具有较好的收敛性,同时在真实Pareto前沿也分布比较均匀,保持了较好的多样性. 而从表2的IGD值比较来看,所提算法比同为基于参考点方法的NSGA-III算法取得了更精确的解集(IGD值更小). 说明本文算法所设计基于参考点的全局最优选择策略和外部档案维护策略能够有效引导种群收敛,并且增加解集的分布性,在求解高维多目标问题时能够保持良好的收敛性和解集分布性.

4 结 论

针对高维多目标优化问题,本文提出一种基于参考点的高维多目标粒子群算法RPMOPSO. 在目标空

间中引入的参考点能够有效筛选出多样性和收敛性好的非支配解,作为粒子的全局向导,增大了选择压力,使得算法的搜索能力不受目标个数增加的影响;同时,所提出的基于参考点的档案维护策略也有效避免了最终档案中解集多样性的丢失,维护了最终解集的多样性.对多个目标的DTLZ2问题进行仿真实验,并与NSGA-III、OMOPSO和IBEA算法进行了比较,结果表明所提算法在求解高维多目标问题时具有收敛性和多样性的优势.

参考文献(References)

- [1] 孔维健,丁进良,柴天佑.高维多目标进化算法研究综述[J].控制与决策,2010,25(3):321-326.
(Kong W J, Ding J L, Chai T Y. Survey on large-dimensional multi-objective evolutionary algorithms[J]. Control and Decision, 2010, 25(3): 321-326.)
- [2] Laumanns M, Thiele L, Deb K, et al. Combining convergence and diversity in evolutionary multiobjective optimization[J]. Evolutionary Computation, 2002, 10(3): 263-282.
- [3] Farina M, Amato P. A fuzzy definition of "optimality" for many-criteria optimization problems[J]. IEEE Trans on Systems, Man, Cybernetics, Part A: Systems and Humans, 2004, 34(3): 315-326.
- [4] 肖婧,王科俊,毕晓君.基于改进 K 支配排序的高维多目标进化算法[J].控制与决策,2014,29(12):2165-2170.
(Xiao J, Wang K J, Bi X J. Multi-objective evolutionary algorithm based on improved K -dominated sorting[J]. Control and Decision, 2014, 29(12): 2165-2170.)
- [5] Yang S, Li M, Liu X, et al. A grid-based evolutionary algorithm for many-objective optimization[J]. IEEE Trans on Evolutionary Computation, 2013, 17(5): 721-736.
- [6] Li M, Yang S, Liu X. Shift-based density estimation for Pareto-based algorithms in many-objective optimization[J]. IEEE Trans on Evolutionary Computation, 2014, 18(3): 348-365.
- [7] Qing F Z, Hui L. Multiobjective optimization problems with complicated pareto sets, MOEA/D and NSGA-II[J]. IEEE Trans on Evolutionary Computation, 2009, 13(2): 284-302.
- [8] 毕晓君,张永建,沈继红.高维多目标多方向协同进化算法[J].控制与决策,2014,29(10):1737-1743.
(Bi X J, Zhang Y J, Shen J H. High-dimensional multi-objective multi-directional co-evolutionary algorithm[J]. Control and Decision, 2014, 29(10): 1737-1743.)
- [9] Zitzler E, Künzli S. Indicator-based selection in multiobjective search[C]. Proc of Parallel Problem Solving from Nature. Berlin: Heidelberg Springer, 2004: 832-842.
- [10] Bader J, Zitzler E. Hyp E: An algorithm for fast hypervolume-based many-objective optimization[J]. Evolutionary Computation, 2011, 19(1): 45-76.
- [11] Deb K, Jain H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, Part I: Solving problems with box constraints[J]. IEEE Trans on Evolutionary Computation, 2014, 18(4): 577-601.
- [12] Saxena D K, Duro J A, Tiwari A, et al. Objective reduction in many-objective optimization: Linear and nonlinear algorithms[J]. IEEE Trans on Evolutionary Computation, 2013, 17(1): 77-99.
- [13] Kennedy J, Eberhart R C. Particle swarm optimization[C]. Proc of IEEE Int Conf on Neural Networks. Piscataway, 1995: 1942-1948.
- [14] Reyes-Sierra M, Coello C C. Multi-objective particle swarm optimizers: A survey of the state-of-the-art[J]. Int J of Computational Intelligence Research, 2012, 2(3): 287-308.
- [15] Wickramasinghe U K, Carrese R, Li X. Designing airfoils using a reference point based evolutionary many-objective particle swarm optimization algorithm[C]. Proc of IEEE Congress on Evolutionary Computation. Melbourne: IEEE, 2010: 1-8.
- [16] Britto A, Pozo A. Using archiving methods to control convergence and diversity for many-objective problems in particle swarm optimization[C]. Proc of IEEE Congress on Evolutionary Computation. IEEE, 2012: 1-8.
- [17] 章恩泽,陈庆伟.改进的 r 支配高维多目标粒子群优化算法[J].控制理论与应用,2015,32(5):623-630.
(Zhang E Z, Chen Q W. Improved r -dominance-based particle swarm optimization for multi-objective optimization[J]. Control Theory & Applications, 2015, 32(5): 623-630.)
- [18] Das I, Dennis J E. Normal-boundary intersection: A new method for generating the Pareto surface in nonlinear multicriteria optimization problems[J]. SIAM J on Optimization, 1998, 8(3): 631-657.
- [19] Yuan Y, Xu H, Wang B, et al. A new dominance relation based evolutionary algorithm for many-objective optimization[J]. IEEE Trans on Evolutionary Computation, 2015, 20(1): 16-37.
- [20] Sierra M R, Coello C A C. Improving PSO-based multi-objective optimization using crowding, mutation and epsilon-dominance[C]. Proc of Evolutionary Multi-Criterion Optimization. Mexico: Springer Berlin Heidelberg, 2005: 505-519.
- [21] Deb K, Thiele L, Laumanns M, et al. Scalable test problems for evolutionary multiobjective optimization[C]. Proc of IEEE Congress on Evolutionary Computation. Piscataway, 2002: 26-33.

(责任编辑:齐霖)