

王沛东, 祝园园, 孙希霞. 基于混合引导策略的偏好多目标进化算法[J]. 智能计算机与应用, 2025, 15(3): 125–132. DOI: 10.20169/j.issn.2095-2163.250318

基于混合引导策略的偏好多目标进化算法

王沛东, 祝园园, 孙希霞

(南京邮电大学 物联网学院, 南京 210003)

摘要: 针对传统偏好多目标进化算法存在的算法性能受偏好点位置影响, 不易于控制偏好解集大小以及收敛速度较慢等问题, 提出了一种基于角度和距离混合引导策略的偏好多目标进化算法。首先, 设计了一种基于偏好向量的距离支配(reference vector based distance dominance, rd-dominance)规则, 解决了传统 r 支配(reference solution based dominance, r-dominance)受偏好点位置影响的问题。同时, 设计了一种自适应的算法阈值更新机制, 使得算法在进化前期可以充分搜索靠近 Pareto 前沿面的个体, 保证了种群的多样性。然后, 设计了一种基于偏好角度的偏好区域划分方法并将其与所提 rd 支配规则融合, 提出了一种基于角度和距离混合引导策略。在进化中后期, 利用所提偏好区域划分方法对偏好区域进行划分, 仅对偏好区域内的个体进行 rd 支配排序, 从而快速引导种群向着决策者感兴趣的区域进化, 提高了算法的优化效率。在标准测试函数上的实验结果表明, 与几种典型的偏好多目标进化算法相比, 所提算法给出的优化结果具有更好的收敛性和稳定性, 且不受偏好点位置的影响。同时, 所提算法与传统基于 r 支配的算法相比具有更快的收敛速度。

关键词: 多目标优化; 混合引导; 偏好信息; 支配排序

中图分类号: TP180

文献标志码: A

文章编号: 2095-2163(2025)03-0125-08

Preference multi-objective evolutionary algorithm based on hybrid guidance strategy

WANG Peidong, ZHU Yuanyuan, SUN Xixia

(College of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: Considering the problems of algorithm performance being affected by the locations of preference points, having difficulty in controlling the size of the preference solution set, and slow convergence speed of traditional preference multi-objective evolutionary algorithms, a preferred multi-objective evolutionary algorithm based on a hybrid angle and distance guidance strategy is proposed. Firstly, a reference vector based distance dominance(rd-dominance) rule based on preference vector is designed to solve the problem that traditional reference solution based dominance(r-dominance) is affected by the position of the preference point. At the same time, an adaptive algorithm threshold update mechanism is designed so that the algorithm can fully search for individuals close to the Pareto front in the early stage of evolution, ensuring the diversity of the population. Then, a preference area division method based on preference angle is designed and integrated with the proposed rd-dominance rule, and a hybrid guidance strategy based on angle and distance is proposed. In the middle and late stages of evolution, the proposed preference area division method is used to divide the preference area, and only the individuals in the preference area are ranked by rd-dominance, thereby quickly guiding the population to evolve toward the area that the decision maker is interested in, and improving the optimization efficiency of the algorithm. Experimental results on standard test functions show that compared with several typical preference multi-objective evolutionary algorithms, the optimization results given by the proposed algorithm have better convergence and stability and are not affected by the position of the preference point. At the same time, the proposed algorithm has faster convergence speed than the traditional algorithm based on r-dominance.

Key words: multi-objective optimization; hybrid guidance; preference information; dominance ranking

0 引言

在科学研究和实际应用中, 经常面临着多个目

标同时优化的问题, 这类问题被称为多目标优化问题(Multi-Objective Optimization Problems, MOPs)^[1]。MOPs 的多个目标通常彼此冲突, 因此

作者简介: 王沛东(1997—), 男, 硕士研究生, 主要研究方向: 进化算法; 祝园园(1999—), 女, 硕士研究生, 主要研究方向: 优化算法, 模糊集。

通信作者: 孙希霞(1988—), 女, 博士, 讲师, 主要研究方向: 进化算法, 机器学习。Email: sxx1017@njupt.edu.cn。

收稿日期: 2023-12-26

哈尔滨工业大学主办 ◆ 专题设计与应用

MOPs 的解是一组由 Pareto 最优解^[2]组成的集合。多目标粒子群 (Multi - Objective Particle Swarm Optimization, MOPSO) 算法^[3]及带精英策略的快速非支配排序遗传算法^[2] (Nondominated Sorting Genetic Algorithm-II, NSGA-II) 等多目标进化算法 (Multi - Objective Evolutionary Algorithms, MOEAs) 因具有良好的并行性等优点,成为解决 MOPs 的重要方法。

在实际应用中,决策者^[4] (Decision Maker, DM) 往往基于个人的偏好或者特定的生产要求,仅对 Pareto 最优解集中的某些特定解感兴趣,而非整个解集。因此,将 DM 偏好信息引入 MOEAs 以引导搜索过程,寻找符合偏好的解集,已经成为多目标优化领域的一个重点研究方向。偏好 MOPs 广泛存在于经济活动规划、过程控制与操作优化、交通与物流系统优化等领域^[5-11]。

DM 通常以偏好点的形式给出偏好信息^[12-13]。根据偏好信息引入 MOEAs 的方式,可以将基于偏好点的偏好 MOEAs 分为基于偏好区域、基于距离和基于角度关系的偏好 MOEAs 等类型。文献[14]提出了一种结合 g 支配 (Reference Point Based Dominance for Multi - objective Metaheuristics, g - dominance) 的 NSGA-II 算法。该方法以 DM 指定的偏好点为基础,依据偏好点对搜索空间进行划分,并确定一个优先偏好区域。通过调整 Pareto 占优规则,该算法可以重点对偏好点附近的区域进行搜索。但当偏好点设置在前沿面附近时,该算法可能不收敛。文献[15]提出了一种 P-NSGA-II 算法。该算法根据权重向量及偏好半径构建偏好区域,从而将整个目标空间划分为偏好和非偏好区域两部分,在一定程度上解决了偏好 MOEAs 算法随目标维数增加时整体性能急剧下降的问题。然而,该算法的计算复杂度较高。文献[16]结合 Pareto 支配策略,定义了一种结合 r 支配 (Reference Solution Based Dominance, r-dominance) 的 r-NSGA-II 算法。该算法通过比较种群中个体之间的欧氏距离,保留距离偏好点最近的个体,具有计算简便、适用性广泛等优点。然而,当偏好点设置在可行域内且距离前沿面较远时,其收敛性较差。文献[17]融合了个体间偏好角度的思想,提出了一种新的基于角度的 AD-NSGA-II 算法。该算法利用角度信息保留距离偏好点最近的个体,解决了偏好点在前沿面内外时算法性能不一致的问题。但是,当偏好点设置在贴近坐标轴时,算法的性能可能会急剧下降。上述研究通常采用

单一方式引入偏好信息,导致算法在迭代过程中未能全面利用偏好信息,从而使得算法给出的偏好解集的收敛性和稳定性等受到偏好点位置影响。

为了解决上述问题,本文提出了一种基于角度和距离混合引导策略的 MOEAs。首先,提出了一种基于偏好向量的距离支配 (Reference Vector Based Distance Dominance, rd-dominance) 规则。为进一步提高算法的优化效率,设计了一种基于偏好角度划分偏好区域的方法,并将其与 rd 支配结合,提出了一种混合引导策略。实验结果表明,与现有算法相比,本文所提基于角度和距离混合引导策略的 MOEAs 不受偏好点位置影响,能够迅速引导种群向着 DM 感兴趣的区域^[18] (Region Of Interest, ROI) 进化,最终获得一个具有更好收敛性且更符合决策者期望的偏好解集。

1 相关概念

1.1 多目标优化问题

MOPs 通常可以表示成如下最小化问题:

$$\min F(x) = \min \{f_1(x), f_2(x), \dots, f_m(x)\}, x \in R^n$$

$$\text{s. t. } \begin{cases} g_i(x) \leq 0, & i = 1, \dots, p \\ h_j(x) = 0, & j = 1, \dots, q \end{cases} \quad (1)$$

其中, m 表示优化问题的目标个数; $g_i(x) \leq 0 (i = 1, \dots, p)$ 对应此类优化问题的 p 个线性不等式约束条件; $h_j(x) = 0 (j = 1, \dots, q)$ 对应优化问题的 q 个线性等式约束条件。

1.2 支配关系

1.2.1 Pareto 支配

种群中任意 2 个体 $x_a = (x_{a1}, x_{a2}, \dots, x_{an}), x_b = (x_{b1}, x_{b2}, \dots, x_{bn})$, 当且仅当满足如下 2 个条件时,定义 x_a Pareto 支配 x_b :

- (1) $f_i(x_a) \leq f_i(x_b), \forall i \in \{1, 2, \dots, m\}$;
- (2) $\exists j \in \{1, 2, \dots, m\}, f_j(x_a) < f_j(x_b)$ 。

1.2.2 r 支配

若 $g(f_1, f_2, \dots, f_m)$ 为决策者偏好点,种群中任意两个个体 $x_a = (x_{a1}, x_{a2}, \dots, x_{an}), x_b = (x_{b1}, x_{b2}, \dots, x_{bn})$ 满足如下 2 个条件中任意一个,则称 x_a r 支配 x_b :

- (1) x_a Pareto 支配 x_b ;
- (2) x_a 和 x_b 之间互不 Pareto 支配,并且 $D(x_a, x_b, g) < -\delta$, 则判定 x_a r 支配 x_b , 其中 $\delta \in [0, 1]$ 。

推得的公式如下:

$$D(x_a, x_b, g) = \frac{Dist(x_a, g) - Dist(x_b, g)}{Dist_{\max} - Dist_{\min}} \quad (2)$$

其中, $Dist_{\max} = \max_{z \in P} Dist(z, g)$, $Dist_{\min} = \min_{z \in P} Dist(z, g)$; z 表示种群 P 中任意一个个体; $Dist(x, y)$ 表示个体 x 、 y 间的欧式距离。


2 基于角度和距离混合引导策略的偏好多目标进化算法

2.1 基于角度和距离的混合偏好引导策略


2.1.1 基于偏好向量的距离支配规则

传统 r 支配规则存在当偏好点设置在可行域内时,算法收敛性变差的问题。 r 支配引导示意如图 1(a)所示, x_a 和 x_b 是种群中互不支配的 2 个个体, d_a 和 d_b 表示这两者与偏好点之间的距离。由图 1(a)可以看出, x_a 与前沿面更接近,但是在 r 支配的引导下, x_a 的排序会低于 x_b , 所以距离前沿面较远的 x_b 会被保留下来。为此基于 r 支配的 MOEAs 最终得到的偏好解集偏离真实前沿面,导致算法收敛性变差。

针对上述偏好点在可行域内外时基于 r 支配的 MOEAs 性能不一致的问题,本文提出了一种 rd 支配规则。在该规则中,偏好向量由偏好最近点^[18]与偏好点相连所得。其中,偏好最近点是种群中距离偏好点最近的个体,通常记作 x_{near} 。由图 1(b)可以看出,当偏好点设置在与图 1(a)中相同的位置时, x_a 会被赋予更高的排序,即利用基于偏好向量的个体偏好距离对种群进行排序可以使得种群同时向着前沿面和偏好区域进化,最终使得算法既具有良好的收敛性,又满足了 DM 的偏好。



(a) r 支配引导示意图



(b) 基于偏好向量的个体偏好距离示意图

图 1 引导示意图


Fig. 1 Guidance diagram

在基于距离的支配规则中,DM 通常通过设定阈值 δ ($0 < \delta \leq 1$) 来定义 ROI 的大小。阈值线性下降示意如图 2(a)所示。传统 r 支配的 δ 随进化代数的增加线性下降,但下降速度偏快会导致种群的探索能力急剧下降。为了更好地平衡种群的探索能力和开发能力,本文提出了一种自适应的阈值更新机制:


$$\delta_t = \begin{cases} 1 + (\delta_{\min} - 1) \times \left(\frac{t}{t_{\max}}\right)^{\frac{1}{c}}, & t \leq \frac{t_{\max}}{2} \\ \delta_{\min} + (\delta_{\frac{t_{\max}}{2}} - \delta_{\min}) \times \left(\frac{2(t_{\max} - t)}{t_{\max}}\right), & t > \frac{t_{\max}}{2} \end{cases} \quad (3)$$

其中, $t_{\max}$ 和 t 分别表示最大迭代次数和当前迭代次数; c 表示常数; $\delta_{\min}$ 表示阈值 δ 的最小值,由 DM 在算法开始前指定; δ_t 表示当前代的阈值; $\delta_{\frac{t_{\max}}{2}}$ 表示在 $t_{\max}/2$ 代时 δ 的取值。

图 2(b)中,所提阈值更新机制中的 δ 在进化初期下降较慢,算法选择压力较小,增强了算法早期的探索能力,保证了群体的多样性。而在进化后期, δ 快速下降,算法选择压力增大,从而达到快速引导种群向着 ROI 进化的效果。



(a) 阈值线性下降



(b) 阈值非线性下降

图 2 阈值随进化代数的增加而下降示意图

Fig. 2 Schematic diagram of threshold decreasing with increasing evolutionary algebra

综上,本文提出的 rd 支配规则为:如果以下任意一点成立,则可以称个体 x_a rd 支配个体 x_b :

(1) 个体 x_a Pareto 支配个体 x_b ;

(2) 个体 x_a 和个体 x_b 互不 Pareto 支配,并且满足 $D(x_a, x_b, l) < -\delta_i$ 。这里, $D(x_a, x_b, l)$ 表示为:

$$D(x_a, x_b, l) = \frac{Dist(x_a, l) - Dist(x_b, l)}{Dist_{\max}} \quad (4)$$

其中, $Dist(x_a, l)$ 和 $Dist(x_b, l)$ 分别表示个体 x_a 和 x_b 到偏好向量 l 的距离; $Dist_{\max}$ 表示种群中所有个体偏好距离的最大值; δ_i 表示阈值,见式(3)。

2.1.2 基于偏好角度的偏好区域划分方法

基于 r 支配的 MOEAs 和所提基于 rd 支配的 MOEAs 在非支配排序阶段的时间复杂度为 $O(m \times N^2)$, 其中 m 是目标维数, N 是种群数量,即种群中每个个体都要与剩余所有个体进行支配排序。因此,基于 r 支配的 MOEAs 和所提基于 rd 支配的 MOEAs 在种群规模较大时,算法运行时间较长。针对此问题,本文提出一种新的基于偏好角度划分偏好区域的方法,并将其与所提 rd 支配结合,达到快速引导种群向着 ROI 进化的效果,从而提高算法的优化效率。偏好区域划分示意如图 3 所示,所提基于偏好角度的偏好区域划分方法的步骤如下:




图 3 偏好区域划分示意图

Fig. 3 Schematic diagram of preference area division

(1) 将原点与偏好点的连线作为偏好向量,将原点与个体的连线作为个体向量;

(2) 计算个体向量 x_i 与偏好向量之间的夹角 θ_{x_i} , 并将 θ_{x_i} 作为个体 x_i 的偏好角度;

(3) 根据个体偏好角度,对目标空间进行偏好区域划分,规则如下:

$$flag_{rd}(x_i) = \begin{cases} 1, & \cos(\theta_{x_i}) > \cos(\alpha) \\ 0, & \cos(\theta_{x_i}) \leq \cos(\alpha) \end{cases} \quad (5)$$

其中, α 表示 DM 预设的偏好角度; θ_{x_i} 表示个体 x_i 的偏好角度; $flag_{rd}(x_i)$ 用来标识个体 x_i 是否处于偏好区域。若 $flag_{rd}(x_i)$ 为 1,则表示个体 x_i 处

于偏好区域,否则表示 x_i 处于非偏好区域。

2.1.3 混合引导策略

为更好地平衡全局搜索和局部搜索,将所提偏好区域划分方法和 rd 支配规则结合,提出了一种混合引导策略。为在进化前期提高种群的多样性和探索能力,在所提混合引导策略的进化前期仅运用 rd 支配规则对种群进行排序。而在算法迭代后期,同时运用偏好区域划分方法和 rd 支配规则对种群进行排序,即仅保留种群中位于偏好区域内的个体并且仅对这些个体进行 rd 支配排序,从而达到快速引导种群向着 ROI 进化的效果,提高算法的优化效率。所提混合引导策略可归纳为:

(1) 若 $t \leq t_{\max}/2$, 种群个体之间进行 rd 支配排序;

(2) 若 $t > t_{\max}/2$, $flag_{rd}$ 值为 1 的个体之间进行 rd 支配排序,并随机选取种群中 $flag_{rd}$ 值为 1 的个体将 $flag_{rd}$ 值为 0 的个体替换,仅保留种群中位于偏好区域内的个体并且仅对这些个体进行 rd 支配排序。

2.2 基于角度和距离混合引导策略的偏好多目标进化算法流程

本文所提混合引导策略可与 NSGA-II 及 MOPSO 算法等任意 MOEAs 结合。ADE-NSGA-II 算法流程如图 4 所示。本文所提基于角度和距离混合引导策略的偏好 NSGA-II 算法 (NSGA-II based on a mixed guidance strategy of angle and distance, ADE-NSGA-II) 的具体流程为:

(1) 种群初始化。初始化参数,随机生成 N 个个体;

(2) 更新阈值。根据阈值取值式(3)更新阈值;

(3) 生成新种群。通过交叉、变异操作生成子代。将子代和父代合并作为新种群;

(4) 运用混合引导策略对种群进行支配排序;

① 若 $t \leq t_{\max}/2$, 对种群个体之间进行 rd 支配排序;

② 若 $t > t_{\max}/2$, 先判断种群中的个体是否位于偏好区域,再对位于偏好区域内的个体之间进行 rd 支配排序;

(5) 维护种群规模。根据支配关系排序等级和拥挤度距离,通过精英策略将种群规模维护为 N ;

(6) 如果达到最大迭代次数,则算法结束,否则转步骤(2)。




图 4 ADE-NSGA-II 算法流程图

Fig. 4 Flowchart of ADE-NSGA-II algorithm

3 实验分析

本文实验的运行环境为 Windows 10 操作系统, CPU 为 Intel (R) Core (TM) i5 - 10200H CPU @ 2.40 GHz, 内存 16.0 G RAM, 软件环境为 Matlab R2020b。

将所提算法和基于距离引导的 r-NSGA-II^[16] 算法、基于偏好区域引导的 g-NSGA-II^[14] 进行实验对比。选取多目标算法性能标准测试函数 (Zitzler-Deb-Thiele, ZDT)^[19] 系列的 ZDT1~3, 6 作为测试函数, 测试 3 种算法针对前沿面为凸、非凸和不连续 MOPs 时的优化能力。其中, 每个算法在测试函数上各独立运行 20 次。

在所有实验中, 为了利于比较, 3 种算法的共有参数值均相同, 且均采用模拟二进制交叉和多项式变异算子。综合考虑优化时间与优化精度并参照文献^[14-16], 经过反复试验, 3 种算法的共有参数值具体设置如下: 种群规模为 500, 变量维数为 5, 交叉和变异概率分别为 0.99 和 0.10。与具体算法相关的参数设置如下: r-NSGA-II 算法的非支配阈值 δ 设置为 0.2。ADE-NSGA-II 算法的非支配阈值 $\delta_{\min}$ 设置为 0.2, DM 预设的偏好角度为 30° , 式(3)中的

常数 c 为 0.3。

本文主要从以下 2 个方面来比较算法的性能:

(1) 解的质量。主要体现在解的分布性和收敛性两个方面。

(2) 算法的运行时间。

本文采用世代距离 (Generational Distance, GD)^[20] 作为算法的收敛性指标。 GD 指标可表示为:

$$GD = \frac{\sqrt{\sum_{i=1}^N (dis_{x_i}^2)}}{N} \quad (6)$$

其中, dis_{x_i} 表示种群中个体 x_i 到真实前沿面的最小欧式距离, N 表示种群规模。 GD 指标可以反映进化算法最后得到的解集与真实前沿面的接近程度, 其值越小, 表明进化算法得到的解集总体距离真实前沿面越近, 代表着算法的收敛性能越好。

偏好点设置在可行域内外时, 3 种算法得到的偏好解集在 GD 指标上的统计结果, 分别见表 1、表 2。由表 1、表 2 可以看出, r-NSGA-II 算法的收敛性优于 g-NSGA-II 算法。这是由于当个体的 Pareto 支配排序等级相同时, r 支配根据个体与偏好点之间距离的大小对具有同一 Pareto 排序等级的个体进行进一步分级, 使得 r 支配相较于 Pareto 支配具有更强的选择能力。而 g 支配运用偏好点对目标空间进行分区, 在 $flag_g = 1$ 的区域内仅对种群进行 Pareto 支配排序, 因此, r-NSGA-II 算法相较于 g-NSGA-II 算法具有更好的收敛性。但是, r 支配的收敛性能与偏好点的位置有关, 当偏好点在可行域内时, r 支配的收敛性能较差。这是因为当偏好点在可行域内时, r 支配引导个体向远离前沿面的方向进化, 与 Pareto 支配冲突。当偏好点在可行域内、外时本文提出的 ADE-NSGA-II 算法都展现出了良好的收敛性和稳定性。这是由于所提 rd 支配在 r 支配的基础上, 引入了偏好向量, 将点与点之间的距离转换为点与偏好向量之间的距离。所提 rd 支配在保留 r 支配增强 Pareto 支配选择能力的基础上又规避了偏好点设置在可行域内时带来的算法收敛性下降的问题, 将偏好引导的方向从 Pareto 支配引导的水平方向转变为垂直方向, 不会发生冲突引导的问题。此外, 本文设计的自适应阈值更新机制使得算法可以在前期尽量搜索贴近前沿面的个体, 提高了 ADE-NSGA-II 算法的收敛性。

表 1 GD 计算结果(偏好点在可行域外)

Table 1 GD calculation results (preference points outside the feasible region)


函数	指标	迭代次数	r-NSGA-II	g-NSGA-II	ADE-NSGA-II
ZDT1(0.50,0.2)	均值	10 000	1.74E-04	1.02E-03	6.85E-05
ZDT2(0.50,0.5)	均值	10 000	1.73E-04	2.65E-03	2.55E-04
ZDT3(0.15,0.4)	均值	10 000	2.12E-04	5.42E-03	7.54E-05
ZDT6(0.50,0.5)	均值	20 000	2.14E-06	4.74E-03	1.45E-06

表 2 GD 计算结果(偏好点在可行域内)


Table 2 GD calculation results (preference points in the feasible region)

函数	指标	迭代次数	r-NSGA-II	g-NSGA-II	ADE-NSGA-II
ZDT1(0.7,0.6)	均值	10 000	2.57E-04	4.28E-03	7.78E-05
ZDT2(0.8,0.8)	均值	10 000	4.39E-04	3.15E-03	2.36E-04
ZDT3(0.3,0.6)	均值	10 000	2.52E-04	6.31E-04	5.62E-05
ZDT6(0.8,0.7)	均值	20 000	2.54E-06	2.74E-03	1.81E-06

在分布性方面,ADE-NSGA-II 算法在 4 个测试函数上的结果优于另外 2 个算法。由于篇幅限制,本文仅以 ZDT2 测试函数上的结果为例。3 个算法在偏好点是(0.8,0.8)时,在 ZDT2 测试函数上的实验结果如图 5 所示。由图 5 可以看出,3 个算法均可实现偏好引导。然而,g-NSGA-II 给出的偏好解集偏大,这是因为 g 支配得到的偏好区域往往受偏好点位置影响。当偏好点远离前沿面时,偏好区域较大,不利于决策者选择。而 r-NSGA-II 和 ADE-NSGA-II 均可通过阈值控制偏好解集的范围。然而,r-NSGA-II 算法给出的偏好解集范围波动较大,稳定性较差。这是因为 r 支配在计算个体距离时采用了欧氏距离,这种方法依赖于个体的绝对位置,而个体的绝对位置具有随机性,从而导致了解集的不稳定性。相比之下,所提出的 rd 支配使用基于偏好向量的个体距离计算方式,这种计算方式仅依赖于个体在偏好向量方向上的投影,受个体绝对位置的影响较小。因此,ADE-NSGA-II 得到的解集更稳定,也更符合预设的偏好区域。



(b) ADE-NSGA-II 收敛结果图




(c) r-NSGA-II 收敛结果图

图 5 3 种算法在 ZDT2 偏好点(0.8,0.8)的实验结果图

Fig. 5 Experimental results of three algorithms at ZDT2 preference points (0.8, 0.8)

为进一步验证所提算法的进化结果更符合 DM 的偏好要求,将 3 种算法在 4 种测试函数上的 20 次实验结果集合分别做与偏好点距离的归一化分布处理。由于篇幅限制,本文仅以偏好点是(0.8,0.8)时在 ZDT2 测试函数上的结果为例。归一化分布如图 6 所示。由图 6 可以看出,ADE-NSGA-II 有 40% 的解落到了离偏好点距离前 10% 的区间内,60% 的



(a) g-NSGA-II 收敛结果图

解落到了离偏好点距离前 20% 的区间内。而 r -NSGA-II 在这 2 项指标上的统计结果只有 20%, 55%。 g -NSGA-II 由于缺乏距离的引导机制, 所以解集围绕偏好点分布相对均匀, 没有体现出明显的趋向性。因此, ADE-NSGA-II 得到的结果更符合 DM 的偏好期望。




图 6 3 种算法在 ZDT2 偏好点 (0.8, 0.8) 的解集归一化分布图

Fig. 6 Normalized distribution maps of solution sets for three algorithms at ZDT2 preference points (0.8, 0.8)

由于 g -NSGA-II 算法仅针对偏好区域内的个体进行 Pareto 支配, 其算法结构相对简单, 从而实现了较快的运行速度。然而, 在解决偏好 MOPs 时 g -NSGA-II 的性能表现差, 这导致 g -NSGA-II 算法运行速度优势在解决此类问题中的意义较为有限。因此, 本文仅对 r -NSGA-II 和 ADE-NSGA-II 算法进行运行时间对比和分析。 r -NSGA-II 和 ADE-NSGA-II 算法在 4 个典型测试函数上的运行时间见表 3。由表 3 可以看出, ADE-NSGA-II 算法的优化效率整体优于 r -NSGA-II。这是由于 ADE-NSGA-II 算法和 r -NSGA-II 算法在支配排序阶段的时间复杂度都为 $O(m \times N^2)$, 但 ADE-NSGA-II 的混合引导策略运用偏好角度划分偏好区域, 只对偏好区域内的个体进行 rd 支配排序, 提高了算法的运行效率。此外, 当目标维数增加或者种群规模增加时, ADE-NSGA-II 算法的混合引导策略所具有的优化效率高的优势将更加明显。

表 3 算法运行时间结果

Table 3 Runtime results of algorithms

函数	指标	r -NSGA-II	ADE-NSGA-II
ZDT1	均值	1.32	1.08
ZDT2	均值	1.85	1.37
ZDT3	均值	1.12	1.25
ZDT6	均值	2.31	1.68

4 结束语

本文提出了一种基于角度和距离混合引导的偏好多目标进化算法。该算法采用混合引导策略对种群的进化进行引导。首先, 提出了一种基于偏好向量的距离支配规则, 解决了传统偏好 MOEAs 算法收敛性受偏好点位置影响的问题。然后, 提出了一种基于偏好角度划分偏好区域的方法, 解决了种群规模较大时, 算法运行时间较长的问题。在 ZDT 测试函数上的实验结果表明, 与 r -NSGA-II 和 g -NSGA-II 相比, 本文所提算法具有更好的收敛性、稳定性, 且其优化结果不受偏好点位置影响。

本文所提算法在二维 MOPs 的情况下已经经过充分验证。但为了更好地适应实际应用场景, 未来的研究需要进一步探索该算法在高维 MOPs 的应用和验证。此外, 基于偏好角度划分偏好区域的方法中 DM 预设的偏好角度是固定的, 如何设计出更合理的、随具体问题灵活变化的预设偏好角度自适应调整机制, 也值得进一步研究。

参考文献

[1] GUO Kai, ZHANG Limao. Multi-objective optimization for improved project management: Current status and future directions [J]. Automation in Construction, 2022, 139: 104256.

[2] 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.

[3] 李倩, 宫俊, 唐加福. 多目标粒子群算法在交叉培训规划中的应用[J]. 控制理论与应用, 2013, 30(1): 17-22.

[4] 王丽萍, 丰美玲, 邱启仓, 等. 偏好多目标进化算法研究综述[J]. 计算机学报, 2019, 42(6): 1289-1315.

[5] WANG Guangchen, LI Xinyu, GAO Liang, et al. Energy-efficient distributed heterogeneous welding flow shop scheduling problem using a modified MOEA/D[J]. Swarm and Evolutionary Computation, 2021, 62: 100858.

[6] 周瑜哲. 基于 NSGA-II 算法的多层共挤吹塑装备张力控制系统研究[J]. 制造业自动化, 2020, 42(2): 24-27.

[7] YI Xiaojian, YU Huiyang, XU Tao. Solving multi-objective weapon-target assignment considering reliability by improved MOEA/D-AM2M[J]. Neurocomputing, 2023, 563: 126906.

[8] 戚远航, 蔡延光, 黄戈文, 等. 带固定半径近邻搜索 3-opt 的离散烟花算法求解旅行商问题[J]. 计算机应用研究, 2021, 38(6): 1642-1647.

[9] SZLAPCZYNSKA R, SZLAPCZYNSKA J, VETTOR R. Ship weather routing featuring w-MOEA/D and uncertainty handling [J]. Applied Soft Computing, 2023, 138: 110142.

[10] GARG V, SHUKLA A, TIWARI R. AERPSO: An adaptive exploration robotic PSO based cooperative algorithm for multiple target searching [J]. Expert Systems with Applications, 2022, 209: 118245.

[11] WANG Yali, LIMMER S, OLHOFFER M, et al. Automatic preference based multi-objective evolutionary algorithm on vehicle fleet maintenance scheduling optimization [J]. Swarm and Evolutionary Computation, 2021, 65: 100933.

[12] YU Hong, FU Zhao, WANG Guoyin, et al. A Multi-objective optimization algorithm based on dynamic user - preference information[J]. Computing, 2022, 104(3): 627-656.

[13] MOHAMMADI A, OMIDVAR M N, LI Xiaodong, et al. Integrating user preferences and decomposition methods for many-objective optimization[C]//2014 IEEE Congress on Evolutionary Computation (CEC). Piscataway, NJ: IEEE, 2014: 421-428.

[14] MOLINA J, SANTANA L V, HERNÁNDEZ-DÍAZ A G, et al. g-dominance; Reference point based dominance for multiobjective metaheuristics [J]. European Journal of Operational Research, 2009, 197(2): 685-692.

[15] HU Jianjie, YU Guo, ZHENG Jinhua, et al. A preference-based multi-objective evolutionary algorithm using preference selection radius[J]. Soft Computing, 2017, 21: 5025-5051.

[16] SAID L B, BECHIKH S, GHÉDIRA K. The r-dominance; A new dominance relation for interactive evolutionary multicriteria decision making [J]. IEEE transactions on Evolutionary Computation, 2010, 14(5): 801-818.

[17] ZHENG Jinhua, XIE Zhunzhi. A study on how to use angle information to include decision maker ' s preferences [J]. Acta Electronica Sinica, 2014, 42(11): 2239-2246.

[18] ZOU Juan, YANG Qite, YANG Shengxiang, et al. Ra - dominance; A new dominance relationship for preference-based evolutionary multiobjective optimization [J]. Applied Soft Computing, 2020, 90: 106192.

[19] ZITZLER E, DEB K, THIELE L. Comparison of multiobjective evolutionary algorithms: Empirical results [J]. Evolutionary Computation, 2000, 8(2): 173-195.

[20] VANVELDHUIZEN D A. Multiobjective evolutionary algorithms; classifications, analyses, and new innovations[M]. Ohio, USA: Air Force Institute of Technology, 1999.