

控制与决策

Control and Decision

基于决策变量关系的动态多目标优化算法

呼子宇, 李紫晗, 孙浩, 魏立新, 王聪

引用本文:

呼子宇, 李紫晗, 孙浩, 魏立新, 王聪. 基于决策变量关系的动态多目标优化算法[J]. *控制与决策*, 2024, 39(1): 78–86.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0500>

您可能感兴趣的其他文章

Articles you may be interested in

基于R2指标和目标空间分解的高维多目标粒子群优化算法

R2 indicator and objective space partition based many-objective particle swarm optimizer

控制与决策. 2021, 36(9): 2085–2094 <https://doi.org/10.13195/j.kzyjc.2020.0113>

一种求解约束多目标问题的协作进化算法

A collaborative evolutionary algorithm for solving constrained multi-objective problems

控制与决策. 2021, 36(11): 2656–2664 <https://doi.org/10.13195/j.kzyjc.2020.0791>

基于多种群分解预测的动态多目标引力搜索算法

Dynamic multi-objective gravitational searching algorithm based on multi-population decomposition prediction

控制与决策. 2021, 36(12): 2910–2918 <https://doi.org/10.13195/j.kzyjc.2020.1002>

基于分类的多策略预测方法求解动态多目标优化问题

Classification-based multi-strategy prediction method for dynamic multi-objective optimization problems

控制与决策. 2021, 36(7): 1569–1580 <https://doi.org/10.13195/j.kzyjc.2019.1320>

基于向量角分解的高维多目标进化算法

Many-objective evolutionary algorithm based on vector angle decomposition

控制与决策. 2021, 36(3): 761–768 <https://doi.org/10.13195/j.kzyjc.2019.0925>

基于决策变量关系的动态多目标优化算法

呼子宇^{1,2†}, 李紫晗^{1,2}, 孙浩^{1,2}, 魏立新^{1,2}, 王聪^{1,2}

(1. 燕山大学 电气工程学院, 河北 秦皇岛 066004;

2. 燕山大学 智能控制系统与智能装备教育部工程研究中心, 河北 秦皇岛 066004)

摘要: 动态多目标优化问题 (DMOPs) 需要进化算法跟踪不断变化的 Pareto 最优前沿, 从而在检测到环境变化时能够及时有效地做出响应. 为了解决上述问题, 提出一种基于决策变量关系的动态多目标优化算法. 首先, 通过决策变量对收敛性和多样性贡献大小的检测机制将决策变量分为收敛性相关决策变量 (CV) 和多样性相关决策变量 (DV), 对不同决策变量采用不同的优化策略; 其次, 提出一种局部搜索多样性维护机制, 使个体在 Pareto 前沿分布更加均匀; 最后, 对两部分产生的组合个体进行非支配排序构成新环境下的种群. 为了验证 DVR 的性能, 将 DVR 与 3 种动态多目标优化算法在 15 个基准测试问题上进行比较, 实验结果表明, DVR 算法相较于其他 3 种算法表现出更优的收敛性和多样性.

关键词: 动态多目标优化; 进化算法; 预测; 决策变量关系; 引导个体; 多样性保持

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0500

引用格式: 呼子宇, 李紫晗, 孙浩, 等. 基于决策变量关系的动态多目标优化算法 [J]. 控制与决策, 2024, 39(1): 78-86.

A dynamic multi-objective optimization algorithm based on the relationship of decision variables

HU Zi-yu^{1,2†}, LI Zi-han^{1,2}, SUN Hao^{1,2}, WEI Li-xin^{1,2}, WANG Cong^{1,2}

(1. School of Electrical Engineering, Yanshan University, Qinhuangdao 066004, China; 2. Engineering Research Center of the Ministry of Education for Intelligent Control System and Intelligent Equipment, Yanshan University, Qinhuangdao 066004, China)

Abstract: Dynamic multi-objective optimization problems require evolutionary algorithms (EAs) to track the changing Pareto-optimal front (PF) at different times, then can respond effectively and timely when environmental changes are detected. In order to solve the above problem, a dynamic multi-objective optimization algorithm based on the relationship of decision variables is proposed. Firstly, through the detection mechanism of the contribution of decision variables to convergence and diversity, the decision variables are divided into convergence decision variables (CV) and diversity decision variables (DV). Secondly, different optimization strategies are adopted for different types of decision variables. And a local search diversity maintenance mechanism is proposed to make individuals more evenly distributed in the Pareto front. Finally, the non-dominated sort of the combined solutions generated by the two parts constitutes the population in the new environment. In order to verify the performance of relationship of decision variables, relationship of decision variables is compared with three dynamic multi-objective optimization evolutionary algorithms on the 15 benchmark functions. Experimental results demonstrate that the DVR algorithm exhibits better convergence and distribution than the other three algorithms.

Keywords: dynamic multi-objective optimization; evolutionary algorithm; prediction; relationship of decision variables; guide individual; diversity maintenance

0 引言

动态多目标优化问题 (dynamic multi-objective

optimization problems, DMOPs) 在工业应用和科学研究中受到广泛关注, 如生产调度、机器学习等^[1-2]. 在

收稿日期: 2022-03-29; 录用日期: 2022-07-06.

基金项目: 国家自然科学基金项目 (62003296, 62073276); 国家重点研发计划项目 (2018YFB1702300); 河北自然科学基金项目 (F2020203031); 河北省教育厅科技项目 (QN2020225).

责任编辑: 唐加福.

†通讯作者. E-mail: hzy@ysu.edu.cn.

DMOPs中, Pareto 最优前沿 (Pareto-optimal front, PF) 和 Pareto 最优集 (Pareto-optimal set, PS) 并不总是固定的, 由于动态和不确定因素的存在, 现有的进化算法 MOEAs (multi-objective evolutionary algorithms) 在求解 DMOPs 时面临挑战^[3]. 为了解决 DMOPs, 近年来提出了许多动态多目标进化算法 (dynamic multi-objective evolutionary algorithms, DMOEAs). 大多数现有的 DMOEAs 通过将经典的 MOEAs^[4] 与高效的动态技术相结合而构建, 大致分为以下两种类型^[5-6]:

1) 基于多样性的方法. 基于多样性的方法可根据增强多样性的方式分为两类: 多样性引入^[7] 和多样性保护^[8]. 多样性引入法考虑了动态环境中种群多样性的潜在损失, 一旦检测到环境变化便会引入随机或变异个体. 多样性保护法仅依赖于静态进化能力寻找一组最优解, 因此缺乏算法的收敛能力. Deb 等^[9] 基于 NSGA-II 提出了两种 DMOEAs (DNSGAI-A 和 DNSGA-II-B). 当环境发生变化时, DNSGAI-A 算法会产生一些随机重新初始化的个体, 而 DNSGA-II-B 算法现有种群的一定比例个体会被突变个体所取代. 在遗传算法 (genetic algorithms, GA) 中, 探索一种替代突变策略以在不断变化的环境中增加多样性. 这两种基于多样性的方法可以根据环境变化的类型自适应地寻找最优个体.

2) 基于预测的方法. 在环境发生变化后, 通过预测的方法指导种群进化, 使用历史信息对新环境的种群初始化, 以帮助种群快速适应新的环境^[10-11]. Zhou 等^[12] 提出了一种基于种群的预测策略 (PPS), 将 Pareto 解集分为中心点和流形两部分, 通过自回归 (autoregression, AR) 模型, 使用连续时间序列中心点预测下一个时刻的中心, 并使用先前时刻的流形估计下一时刻的流形. 因此, 当检测到环境发生变化时, PPS 通过组合预测中心和估计流形初始化整个种群. 早期进化搜索阶段历史信息不足, 预测质量不高, 但随着算法的运行和历史信息的积累, 预测的准确性将不断提高. Rong 等^[13] 提出了一种多方向预测策略, 通过聚类方法选择代表性个体, 根据环境变化严重程度确定代表性个体的数量, 通过多个代表性个体的进化方向预测决策空间中 Pareto 解的新位置, 以便在环境发生变化时重新初始化种群. Ma 等^[14] 提出了一种多区域预测策略, 根据环境变化的强度确定子区域的数量, 将个体划分到不同区域, 通过子区域的中心点来确定多个进化方向, 以此来估计 Pareto 解集的移动趋势和位置.

基于预测的方法使用预测机制为每次环境变化后的种群进化提供指导方向, 使算法能够快速响应

新的变化. 其主要缺点是完全依赖于训练模型, 训练过程中使用的数据不能反映真实情况. 基于多样性的方法可以保持或增加种群的多样性, 但盲目增加多样性会导致收敛缓慢, 因此采用预测方法与多样性引入方法相结合的设计可以进一步弥补上述缺陷. 如今, 大多数 DMOEAs 以相同的方式进化决策变量, 而没有考虑决策变量的不同特征, 不能处理进化过程中产生的有效信息. 最近, 已有针对基于决策变量分类的相关研究 (decision variable analysis, DVA)^[15], 通过判断扰动个体之间的支配关系, 将决策变量划分为不同的类型. DVA 将混合决策变量视为多样性相关变量, 该变量分类策略无法进一步将混合决策变量进行区分. 混合决策变量仍然可以进一步划分, 因为其中一些决策变量对收敛的贡献更大, 而另一些决策变量对多样性的贡献更大. 由此, 提出了一种检测决策变量对多样性和收敛性贡献大小机制. 目前, 已有基于角度的决策变量分类方法^[16], 该分类方法存在两点缺陷: 第一, 在计算角度时, 仅使用超平面的法线 $f_1 + f_2 + \dots + f_m = 1$ 作为收敛方向, 无法准确区分 Pareto 前沿不规则形状的混合变量, 因此在决策变量分析时加入参考向量的指导是必要的; 第二, 当不同维度决策变量具有相同的角度或者投影长度时, 无法进一步区分决策变量对收敛性的贡献大小, 因此使用角度和投影长度的组合设计可以进一步对决策变量进行分类.

本文基于上述研究, 提出一种基于决策变量关系的动态多目标优化算法. 该算法加入参考向量的指导, 根据决策变量对收敛性和多样性的贡献大小对其进行分类, 并且对不同类型的决策变量采用不同的进化策略, 更好地平衡多样性和收敛性. 算法特点是: 1) 根据对收敛性和多样性贡献大小, 将决策变量分为收敛性相关变量 (CV) 和多样性相关变量 (DV); 2) 针对不同类型的决策变量提出不同的进化策略; 3) 提出一种局部搜索多样性维持策略, 搜索附近的个体增加种群的多样性.

1 背景知识

1.1 动态多目标优化问题

考虑最小化动态多目标优化问题, 定义为

$$\min F(x, t) = \{f_1(x, t), f_2(x, t), \dots, f_m(x, t)\}.$$

$$\text{s.t. } g_i(x, t) \leq 0, \quad i = 1, 2, \dots, p;$$

$$h_j(x, t) = 0, \quad j = 1, 2, \dots, q. \quad (1)$$

其中: $x_i = \{x_1, x_2, \dots, x_n\}$ 为决策空间 Ω 中 n 维决策变量, $F(x, t) = (f_1, f_2, \dots, f_m)$ 为 m 维最小化目标

向量, $g(x, t) \leq 0$ 和 $h(x, t) = 0$ 为不等式约束和等式约束. 时间变量 t 定义为 $t = (1/n_t) \lfloor \tau/\tau_t \rfloor$. 其中: τ 为迭代次数, n_t 为环境变化强度, τ_t 为环境变化频率.

1.2 引导个体

将种群中所有个体进行非支配排序, 在非支配个体中选取多个能够充分描述 Pareto 前沿形状和多样性的代表性个体. 当非支配解的个数大于目标空间维度时, 将中心点、边界点和采样点结合作为引导个体. 目标空间中某一维度边界点是最远的, 因此可以很好地描述 Pareto 前沿的位置; 采样点不受边界点的影响, 能够很好地反应数据的分布情况. 当非支配解的个数小于或等于目标空间的维度时, 选取所有非支配解作为引导个体. 下面分别对3部分进行介绍.

1) 边界点.

对于极小值问题, 边界点是目标空间中某一维度上具有最小值的个体. 如图1(a)所示, 边界点是目标

空间第1维度和第2维度的最小值. 边界点的数量等于目标空间的维度. 如果目标空间的维度为3或3以上, 则边界点的数量将为3或3以上.

2) 中心点.

t 时刻中心点的计算公式如下:

$$C_i^t = \frac{1}{|\text{PS}^t|} \sum_{x \in \text{PS}^t} x_i^t. \quad (2)$$

其中: PS^t 为 t 时刻的 Pareto 解集, $|\text{PS}^t|$ 为 PS^t 中解的个数, x_i^t 为 PS^t 中第 i 个解.

3) 采样点.

系统采样法是将所有样本值由小到大进行排序, 对样本数据进行等间距采样. 样本总数与采样点数比值向下取整等于分段间隔 k , 在 $(1, k)$ 中用简单随机抽样选择第1个采样点, 然后根据步长 k 抽取样本进行等间距采样. 与平均值相比采样点不受极值的影响, 可以更好地指示数据的分布.

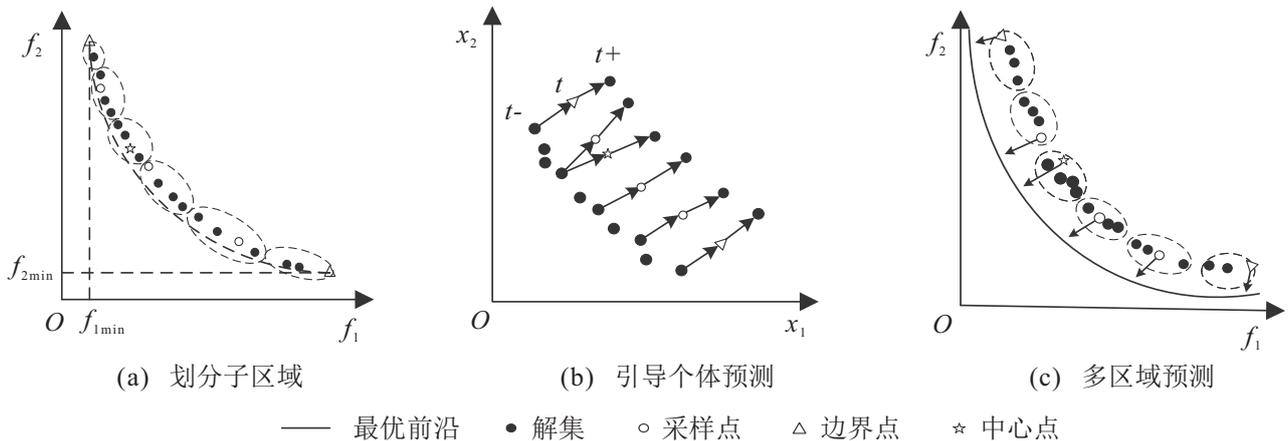


图1 多区域预测策略

2 分类预测及多样性保持策略

为了在不断变化的环境中生成接近 Pareto 前沿的种群, 提出一种基于决策变量关系的动态多目标优化算法, 其主要思想是根据决策变量对收敛性和多样性的贡献大小, 分析每个决策变量对个体的影响. 该方法将决策变量分为收敛性相关变量和多样性相关变量, 对两类决策变量分别采取不同的预测策略. 此外, 为了使个体分布更加均匀, 提出一种多样性维护方法, 主要包括决策变量分类、分类预测策略、局部搜索多样性保持策略等步骤, 具体内容如下.

2.1 决策变量关系

采用收敛性相关程度 (convergence relevance degree, CRD) 值测量每个决策变量对收敛性和多样性的贡献大小. 每个决策变量的 CRD 值包含两个因素: 角度 θ 和投影长度 LN. 首先, 对种群 P 中 N 个

个体进行重新初始化, 在目标空间中均匀产生 n 个权重向量 $\lambda_i = \{\lambda_1, \lambda_2, \dots, \lambda_n\}$, 权重向量的个数与决策变量维度相等; 然后, 计算种群中所有个体与 n 个权重向量之间的欧氏距离, 从个体中选择与每个权重向量 λ_i 距离最近的 n_{Sel} 个候选个体 $x_{ij} (i = 1, 2, \dots, n, j = 1, 2, \dots, n_{\text{Sel}})$; 最后, 对所有候选个体进行 n_{Per} 次扰动, 对扰动个体进行归一化处理, 产生拟合直线 L_{ij} , 计算拟合线 L_{ij} 与权重向量 λ_i 之间的夹角 θ_{ij} 和投影长度 LN_{ij} . 通过下式计算每个决策变量对应的 CRD 值:

$$\text{CRD}_{ij} = \left(1 + \frac{\theta_{ij} - \theta_{\min}}{\theta_{\max} - \theta_{\min}}\right) \times e^{-\text{LN}_{ij}}. \quad (3)$$

其中: θ_{ij} 和 LN_{ij} 分别为拟合直线 L_{ij} 与权重向量 λ_i 之间的夹角和投影长度, θ_{\min} 和 θ_{\max} 分别为当前代数角度的最小值和最大值.

对每个权重向量选择两个最近的候选个体 x_i^{near1}

和 $x_i^{\text{near}2}$ (图2(a)), 分别对候选个体的第 i 维度进行 6 次扰动, 对扰动个体进行归一化处理, 产生拟合直线 L_{i1} 和 L_{i2} (图2(b)). 计算拟合线 L_{i1} 和 L_{i2} 与权重向量 λ_i 之间的夹角 θ_{i1} 、投影长度 LN_{i1} 和夹角 θ_{i2} 、投影长度 LN_{i2} . 通过式(3)分别计算两个候选个体对应的 CRD 值 (CRD_{i1} 和 CRD_{i2}). CRD 值小表示对收敛性的贡献大于对多样性的贡献, 这是因为角度反映了对收敛方

向的搜索偏差, 较小的角度 θ 表示决策变量 x_i 对收敛方向具有更大的贡献; 投影长度 LN 表示沿收敛方向的搜索强度, 较大的投影长度表示沿收敛方向的扰动幅度较大. 使用 k -means 聚类方法将 5 个决策变量对应的 CRD 分为两个群集, 距离原点最近的点所在群集对应的决策变量被划分为收敛性相关变量, 其余归类为多样性相关变量.

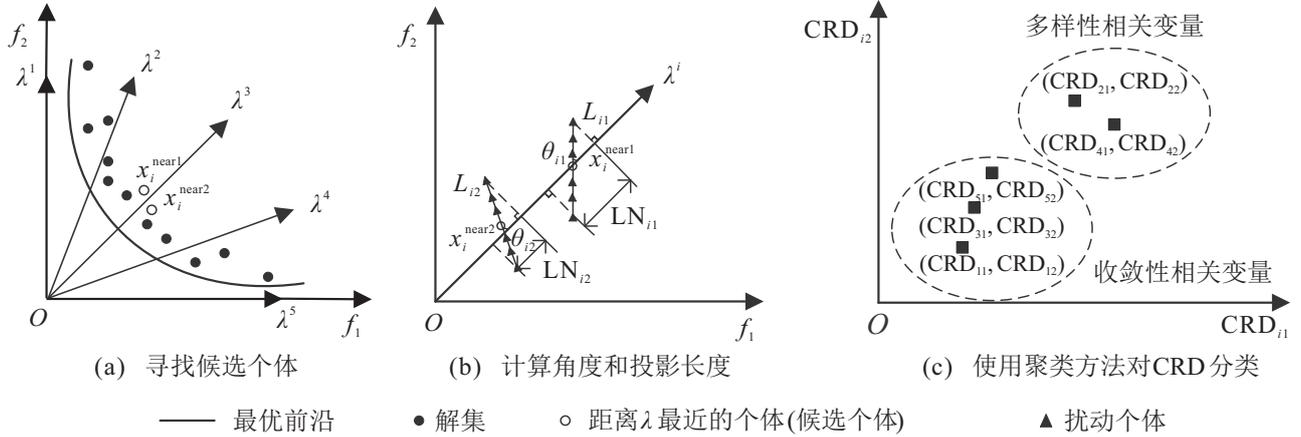


图2 决策变量分类

2.2 分类预测策略

当检测到环境发生变化时, 分类预测策略可以找到近似真实 Pareto 解集的解. 与其他预测策略不同之处在于, 分类预测策略根据上一时刻 (t 时刻) 和当前时刻 ($t+1$ 时刻) 每个维度决策变量的类型进行分类, 并且采取不同的优化策略. 如果第 i 维决策变量在 t 时刻为收敛性决策变量, 在 $t+1$ 时刻为多样性决策变量, 或者在 t 时刻为多样性决策变量, 在 $t+1$ 时刻为收敛性决策变量, 则历史信息对于优化种群不起作用, 因此第 i 维决策变量采用随机初始化策略. 当 t 时刻和 $t+1$ 时刻均为多样性决策变量时, 采用精度可控变异算子预测策略. 当 t 时刻和 $t+1$ 时刻均为收敛性决策变量时, 提出了一种多区域预测策略.

2.2.1 精度可控变异算子策略

决策变量 x_i 在上一时刻和当前时刻均为多样性决策变量时, 采用精度可控变异算子策略. 该策略生成具有所需搜索精度的新个体, 用于开发和探索决策空间. 对于种群中所有个体 $x = [x_1, x_2, \dots, x_N]^T$, x_i 为 x 的第 i 维度, 开发 x 附近的个体, 探索远离 x 的个体. 具体如下:

$$\begin{aligned} x_i^{\text{new}} &= x_i + \alpha, \\ x_i^{\text{new}} &= x_i - \alpha, \\ \alpha &= \frac{1}{10^{\text{random}(p)}} \times \text{random}(9). \end{aligned} \quad (4)$$

式(4)的变异算子可以在初始值上产生一个小的变异, 以开发 x 附近的个体. 参数 p 为调节决策空间开发的搜索精度参数. 函数 $\text{random}(p)$ 可以生成 $1 \sim p$ 范围内的随机均匀分布的整数. 有

$$\begin{aligned} x_i^{\text{new}} &= x_i + \beta, \\ x_i^{\text{new}} &= x_i - \beta, \\ \beta &= 10^{\text{random}(q)} \times \text{random}(9). \end{aligned} \quad (5)$$

式(5)的变异算子可以产生远离初始值的个体. 参数 q 为调节决策空间探索的搜索精度参数. 该方法有助于全局搜索跳出局部最优, 增加种群的多样性.

为了开发和探索新的个体, 产生 $[1, 4]$ 内的随机整数 r , 当 $r=1$ 时, $x_i^{\text{new}} = x_i + \alpha$; 当 $r=2$ 时, $x_i^{\text{new}} = x_i - \alpha$; 当 $r=3$ 时, $x_i^{\text{new}} = x_i + \beta$; 当 $r=4$ 时, $x_i^{\text{new}} = x_i - \beta$.

2.2.2 多区域预测策略

决策变量 x_i 在当前时刻和上一时刻均为收敛性决策变量时, 采用多区域预测方法. 为了将个体划分到不同的子区域中, 在非支配解中对目标空间任一维度目标函数值由小到大排序选取引导个体, 选择方法参照第 1.2 节, 并计算个体与引导个体之间的欧氏距离. 如图 1(a) 所示, 将个体划分到距离最近的引导个体所属区域, 子区域的个数与引导个体的个数相等. 使用多个引导个体而不是仅使用中心点进行预测, 称为多区域预测. 基于引导个体的预测方法通过

不同时刻的引导个体计算进化方向,每个引导个体的进化方向代表该区域所有个体的进化方向.同时考虑预测精度和计算成本,基于前两个环境中引导个体提供的历史信息构建多个时间序列模型,预测多个子区域的进化方向.如图1(b)所示, t 时刻引导个体解集 $c^t = \{c_1^t, c_2^t, \dots, c_r^t\}$, c_i^t 为 c^t 中任意一个引导个体.首先在 $t-1$ 时刻所有非支配解中寻找距离 c_i^t 最近的个体 c_j^{t-1} , c_j^{t-1} 为 c_i^t 的父代.进化步长定义如下:

$$\Delta c_i^t = c_i^t - c_j^{t-1}, \quad i = 1, 2, \dots, r, \quad (6)$$

其中 r 为引导个体的个数,即子区域的个数.通过引导个体 c^t 的进化步长计算 $t+1$ 时刻该区域其他个体的位置,有

$$x_i^{t+1} = x_i^t + \Delta c_i^t + \varepsilon^t. \quad (7)$$

其中: $i = 1, 2, \dots, r$; $\varepsilon^t \sim N(0, \sigma^t)$, ε^t 是正态分布均值为0方差为 σ^t 的一个随机数. σ^t 计算公式如下:

$$\sigma^t = \frac{1}{r} \sum_{i=1}^r |\Delta c_i^t|. \quad (8)$$

其中: x_i^t 为第 t 次环境变化获得的解, x_i^{t+1} 为第 $t+1$ 次环境变化的预测解.如图2(c)所示,每个子区域 $t+1$ 时刻的个体根据其所在子区域的引导个体的进化方向进化产生.

2.3 局部搜索多样性保持策略

多样性保持策略在动态优化中起着重要的作用.动态环境中,环境随着时间不断发生变化,在环境变化的每一个时期,种群会朝着适应环境的方向进化,容易导致局部最优.因此,需要引入一些不同的个体增加种群的多样性,多样性保持策略在环境变化时具有引入多样性个体的作用.

本文提出一种局部搜索多样性保持策略.在决策空间中,计算所有个体的中心点 C 每个维度到上边界和下边界的距离,其中相对较小的距离与较大的距离的比值 d_j 如下:

$$d_{j \min} = \min\{|x_j - l_j|, |x_j - u_j|\}, \quad (9)$$

$$d_{j \max} = \max\{|x_j - l_j|, |x_j - u_j|\}, \quad (10)$$

$$d_j = d_{j \min} / d_{j \max}. \quad (11)$$

通过下式产生每个子区域中的新个体:

$$x_{ij}^{t+1} = x_{ij}^t + N(0, d_j). \quad (12)$$

其中: x_{ij}^t 为 t 时刻第 i 个个体的第 j 维决策变量, x_{ij}^{t+1} 为 $t+1$ 时刻第 i 个个体的第 j 维决策变量的预测解. $N(0, d_j)$ 是均值为0方差为 d_j 的正态分布.

2.4 算法流程

所提出算法的具体流程如下.

输入: 种群大小 N ;

输出: 产生的新种群 P_{new} .

step 1: 初始化种群,计算种群个体的目标函数值.

step 2: 若两个时刻目标函数值相等则转至 step 9,若环境发生变化则继续执行 step 3.

step 3: 产生一组均匀分布的权重向量 $\lambda_i = \lambda_1, \lambda_2, \dots, \lambda_n$, 权重向量的个数与决策变量的维度相等.

step 4: 由第2.1节,对种群进行决策变量分类,分为收敛性决策变量 CV 和多样性决策变量 DV.

step 5: 由第2.2.1节,对多样性决策变量使用精度可控变异算子策略产生新个体 Q_{dv} .

step 6: 由第2.2.2节,对收敛性决策变量使用多区域预测策略产生新个体 Q_{cv} .

step 7: 由第2.3节,使用局部搜索多样性保持策略产生种群 R .

step 8: Q_{dv} 和 Q_{cv} 组成种群 Q , 合并种群 Q 与 R , 进行非支配排序,选择 N 个最优个体.

step 9: 采用静态算法 MOEA/D-DE 进行优化.

step 10: 进行下一代优化,若算法达到终止条件则结束并返回种群 P_{new} , 否则转至 step 2.

3 实验仿真结果及分析

为验证所提出算法的有效性,选取15个动态多目标优化测试函数进行仿真实验.将所提出算法与3种动态多目标进化算法 MDP^[13]、SGEA^[17] 和 DMOES^[18] 进行比较,给出测试函数、对比算法介绍以及算法参数设置、实验结果分析和进一步讨论.

3.1 测试函数

使用15个典型的测试函数进行实验仿真,测试问题包括 FDA 测试集 ($FDA_1 \sim FDA_5$) 和 F 测试集 ($F_1 \sim F_{10}$)^[12]. FDA 测试集具有线性相关的决策变量,并且是动态多目标中最常用的测试集,广泛用于测试 DMOEA 的性能.其中 $FDA_1 \sim FDA_3$ 是二维目标空间中的 DMOPs, FDA_4 和 FDA_5 是具有三维目标空间中的 DMOPs. FDA 基准测试问题本质上是静态 MOPs 的延伸,在全面分析动态优化算法的性能时有一定的局限性. F 系列测试集表征了更复杂的实际优化问题,其中包括决策变量的非线性相关问题.

3.2 参数设置

测试函数环境变化严重程度 $n_t = 10$, 环境变化频率 $\tau_t = 20, 25, 30$. 环境变化100次,4种算法每个

问题独立运行20次. 种群大小 $N = 100$, 决策变量的维度 $n = 10$. 4种算法均采用MOEA/D-DE静态优化算法, 邻域大小设为20, 采用切比雪夫分解方法. 在所提出算法中, 每个维度所选候选个体数 $n_{\text{Sel}} = 2$, 对每个候选个体进行的扰动次数 $n_{\text{Per}} = 4$, 采样点的个数为3, 精度可控的变异参数 p 和 q 均设置为1. SGEA^[17] 算法中交叉概率 $p_c = 1.0$, 变异概率为 $p_m = 1/n$, 交叉和变异的分布指数 η_c 、 $\eta_m = 20$. MDP^[13] 和 DMOES^[18] 参数设置依照原文献.

3.3 性能评价指标

为了评估解的收敛性和多样性, 在静态多目标优化中常采用反向世代距离IGD(inverse generation distance, IGD)^[19] 和间距度量(spacing metric, SP)^[20] 评价算法的综合性能. IGD计算方式如下:

$$\text{IGD}(P^{t^*}, P^t) = \frac{\sum_{j \in P^{t^*}} d(j)}{|P^{t^*}|}. \quad (13)$$

其中: P^{t^*} 为 t 时刻真实 Pareto 前沿上均匀分布的最优解集, P^t 为 t 时刻近似的 Pareto 解集, $|P^{t^*}|$ 为 P^{t^*} 的基数, $d(v, P^t) = \min_{u \in P^t} \|F(v) - F(u)\|$ 用来计算 v 与 P^t 之间的最小欧氏距离. IGD 度量是指由该算法获得的近似 Pareto 前沿与实际 Pareto 前沿之间的拟合度, 值越小算法性能越好. 由于 IGD 多用于评价静态算法性能, 引入平均反向世代距离(MIGD)进行度量, 计算方式如下:

$$\text{MIGD}(P^{t^*}, P^t) = \frac{1}{|T|} \sum_{t \in T} \text{IGD}(P^{t^*}, P^t). \quad (14)$$

其中: $t \in T$ ($T = \{1, 2, \dots\}$) 为运行中的一组离散时间点, $|T|$ 为 T 的基数. 与 IGD 相同, MIGD 度量值越小算法的性能越好.

3.4 实验结果及分析

将所提出算法与其他3种DMOEA在FDA和F测试问题上进行比较. 对于每个算法跟踪100次环境变化, 每个测试问题独立运行20次. 表1列出4种算法在15个测试问题上的MIGD评价指标统计结果, 比较了4种算法在收敛性、多样性方面的性能, 平均值和标准差的最佳结果用粗体标记.

对实验结果的具体分析如下. MIGD用来评估不同环境下算法的收敛性和多样性. 由表1可见, 在大部分测试问题上, 所提出算法的MIGD值小于其他3种算法, 表明所提出算法优于其他3种算法, 这得益于对收敛性和多样性决策变量采用不同的优化策略. 环境变化频率不同时, 所提出算法在测试函数

FDA₄、FDA₅、 $F_4 \sim F_8$ 、 F_{10} 上均表现最优. 在 Pareto 前沿不随时间发生变化的测试函数 FDA₁ 和 F_1 上, 当 $\tau_t = 20$ 、25 时, MDP 算法的性能表现最好, SGEA 性能仅次于 MDP; 当 $\tau_t = 30$ 时, 所提出算法具有最小的 MIGD 值. 值得注意的是, 所提出算法与 MDP 之间的比较, 后者根据环境变化的严重程度采用 k -means 均值将种群划分为多个区域, 并通过基于中心的预测指导每个区域; 所提出算法则通过决策变量分类方法及引导个体将种群划分为多个子区域, 并通过引导个体计算子区域的进化步长. 图3分别给出4种算法在测试函数 FDA₁、FDA₃、FDA₅、 F_1 、 F_5 、 F_8 上的 IGD 曲线. 6 个测试实例中, 所提出算法在大多代数中显示出比其他算法更低的 IGD 值, 表明所提出算法产生的解集更加接近真实的 Pareto 前沿, 这主要得益于对收敛性决策变量采用基于引导个体划分的多区域预测策略, 可以使种群更好地向 Pareto 前沿收敛.

上述 IGD 性能指标分析表明, 所提出算法相较于其他算法具有优越性. 为了更好地展现4种算法在不同时刻产生的 Pareto 解在 Pareto 前沿上的分布, 图4~图6给出测试问题 F_1 、FDA₂、 F_5 的前沿. 图4为环境变化频率为30时, F_1 在 $t = 10$ 、20、30、40、50 的4种策略的最终 Pareto 前沿总体分布. F_1 的 Pareto 前沿不随时间发生变化, 为了更加直观地观察 Pareto 前沿和真实前沿的变化, 将不同时刻的前沿展示在同一副图中, f_1 和 f_2 取值范围均为 $[0, 1]$. 如图5所示, 选取测试函数 FDA₂ 在 $t = 10$ 、23、36、60 时刻解的 Pareto 前沿分布. 所提出算法在测试函数 FDA₂ 上分布性略差于 MDP 算法. 如图6所示, 选取测试函数 F_5 在 $t = 15$ 、32、39、61 时刻解的 Pareto 前沿分布. 由图5和图6可以看出, 由于采用了决策变量分类方法、分区域预测方法和多样性保持策略, 所提出算法在保证解集收敛性的同时分布性也很好, 其他3种算法的收敛性和分布性略差于所提出算法.

实验结论如下: 所提出算法将决策变量分为收敛性相关变量和多样性相关变量, 并将与收敛性相关变量的种群个体分配至不同的子区域, 在环境发生变化时, 通过同一子区域中引导个体的进化方向确定该区域其他个体的进化方向. 对于多样性相关变量采取随机初始化和精度可控变异算子策略, 使解集的分布更加均匀. 对两种决策变量使用不同的进化策略, 使所提出算法在加速收敛的同时能够保持多样性和分布性. 实验结果表明, 所提出算法比其他3种算法更能适应不断变化的环境.

表1 4种算法的MIGD统计

instance	(n_t, τ_t)	MDP	SGEA	DMOES	DVR (本文算法)
FDA1	(10,20)	8.544 3e-03(9.118 1e-05)	9.083 7e-03(1.447 1e-04)	1.670 8e-02(9.772 7e-04)	9.438 1e-03(2.251 3e-04)
	(10,25)	6.946 7e-03(1.140 0e-04)	7.209 9e-03(7.419 7e-05)	1.024 8e-02(3.009 1e-04)	7.227 0e-03(2.189 2e-04)
	(10,30)	6.088 7e-03(3.119 5e-05)	6.282 0e-03(1.163 5e-04)	7.605 1e-03(3.245 9e-04)	6.052 9e-03(6.178 6e-05)
FDA2	(10,20)	7.205 4e-03(1.108 5e-04)	7.517 4e-03(3.809 3e-05)	1.375 5e-02(7.387 6e-04)	1.359 1e-02(9.332 7e-04)
	(10,25)	6.355 4e-03(2.416 6e-04)	6.490 6e-03(1.052 4e-04)	9.631 3e-03(5.971 6e-04)	9.475 0e-03(3.597 3e-04)
	(10,30)	5.791 4e-03(4.678 0e-05)	6.564 0e-03(7.963 7e-05)	1.014 7e-02(4.812 9e-04)	8.136 6e-03(1.547 8e-04)
FDA3	(10,20)	7.346 4e-02(9.303 4e-04)	7.321 6e-02(1.244 4e-03)	6.948 7e-02(2.133 1e-03)	7.532 4e-02(1.364 0e-03)
	(10,25)	7.281 7e-02(9.619 9e-04)	7.215 9e-02(8.344 7e-04)	7.186 7e-02(1.998 7e-03)	7.371 7e-02(8.641 6e-04)
	(10,30)	7.242 2e-02(8.182 3e-04)	3.091 7e-02(7.232 1e-04)	7.167 6e-02(1.369 5e-03)	7.289 6e-02(9.315 7e-04)
FDA4	(10,20)	3.895 0e-02(9.552 3e-05)	3.896 3e-02(2.407 7e-04)	3.886 5e-02(9.080 0e-04)	3.331 4e-02(2.342 9e-04)
	(10,25)	3.705 8e-02(6.003 0e-05)	3.713 3e-02(7.032 3e-05)	3.315 7e-02(1.404 8e-04)	3.116 7e-02(1.392 8e-04)
	(10,30)	3.614 4e-02(4.419 4e-05)	3.569 8e-02(4.638 6e-05)	3.124 5e-02(1.070 1e-04)	3.020 1e-02(6.791 0e-05)
FDA5	(10,20)	6.578 8e-02(4.410 1e-04)	6.235 4e-02(1.504 5e-04)	1.166 5e-01(9.671 4e-03)	5.430 5e-02(3.764 7e-04)
	(10,25)	6.094 3e-02(1.384 4e-04)	5.962 0e-02(7.777 3e-05)	8.882 0e-02(7.115 7e-03)	5.025 7e-02(1.902 3e-04)
	(10,30)	5.889 4e-02(7.513 3e-05)	5.823 3e-02(5.551 5e-05)	7.187 0e-02(7.970 1e-03)	4.828 1e-02(1.754 6e-04)
F1	(10,20)	8.585 2e-03(1.015 3e-04)	9.045 0e-03(1.901 1e-04)	1.636 4e-02(1.173 3e-03)	9.292 4e-03(1.500 8e-04)
	(10,25)	6.998 1e-03(6.655 1e-05)	7.196 7e-03(1.003 3e-04)	1.016 3e-02(4.153 7e-04)	7.005 4e-03(6.635 2e-05)
	(10,30)	6.086 8e-03(5.171 3e-05)	6.220 5e-03(3.018 8e-05)	7.539 4e-03(3.140 0e-04)	6.055 7e-03(6.384 8e-05)
F2	(10,20)	9.128 8e-03(6.064 7e-04)	1.120 6e-02(4.682 8e-04)	8.258 9e-02(5.034 7e-03)	6.769 7e-02(3.132 1e-03)
	(10,25)	6.192 6e-03(7.835 4e-04)	8.465 8e-03(4.630 7e-04)	4.241 5e-02(3.028 8e-03)	3.328 0e-02(2.090 5e-03)
	(10,30)	4.959 3e-03(1.052 4e-04)	6.630 1e-03(3.137 9e-04)	2.393 2e-02(2.732 8e-03)	1.966 0e-02(1.057 5e-03)
F3	(10,20)	9.565 6e-03(9.599 8e-05)	9.619 9e-03(1.559 9e-04)	2.134 9e-02(1.310 9e-03)	1.098 1e-02(2.012 8e-04)
	(10,25)	7.148 0e-03(5.179 2e-05)	7.256 2e-03(1.034 7e-04)	1.236 3e-02(1.122 3e-03)	7.698 9e-03(1.805 9e-04)
	(10,30)	5.989 1e-03(4.217 2e-05)	6.005 2e-03(3.605 0e-05)	8.012 2e-03(2.635 1e-04)	6.121 3e-03(8.518 7e-05)
F4	(10,20)	1.626 7e+00(2.090 9e-04)	1.628 0e+00(3.422 3e-04)	1.680 1e+00(9.209 4e-03)	1.625 7e+00(3.977 9e-04)
	(10,25)	1.624 7e+00(1.451 7e-04)	1.625 8e+00(1.260 3e-04)	1.653 3e+00(3.490 0e-03)	1.623 2e+00(1.827 3e-04)
	(10,30)	1.623 7e+00(8.781 7e-05)	1.624 6e+00(1.188 0e-04)	1.637 4e+00(2.451 8e-03)	1.621 7e+00(8.013 9e-05)
F5	(10,20)	1.989 0e-01(1.322 8e-02)	2.261 4e-01(2.869 4e-02)	1.334 7e-01(7.872 1e-03)	8.327 8e-02(5.223 7e-03)
	(10,25)	1.478 4e-01(1.022 1e-02)	1.722 4e-01(1.655 8e-02)	7.834 9e-02(1.209 3e-02)	5.238 5e-02(4.624 3e-03)
	(10,30)	1.120 6e-01(8.401 6e-03)	1.228 4e-01(1.471 7e-02)	6.127 9e-02(8.159 3e-03)	3.893 5e-02(2.511 8e-03)
F6	(10,20)	2.538 4e-01(4.801 4e-02)	1.263 6e-01(1.693 1e-02)	8.640 3e-02(1.132 3e-02)	6.416 4e-02(4.934 3e-03)
	(10,25)	1.401 8e-01(1.725 0e-02)	9.244 1e-02(7.341 1e-03)	5.283 1e-02(7.460 4e-03)	4.853 6e-02(3.367 2e-03)
	(10,30)	1.040 3e-01(1.602 4e-02)	6.715 2e-02(5.059 4e-03)	4.109 5e-02(3.667 5e-03)	4.078 5e-02(4.766 2e-03)
F7	(10,20)	1.568 3e-01(2.519 9e-02)	1.155 5e-01(1.071 2e-02)	9.172 5e-02(3.894 8e-03)	6.416 4e-02(5.201 2e-03)
	(10,25)	1.069 8e-01(1.166 6e-02)	8.597 5e-02(8.165 5e-03)	5.785 9e-02(3.142 4e-03)	4.624 8e-02(2.613 8e-03)
	(10,30)	7.709 9e-02(5.732 2e-03)	6.866 7e-02(7.736 3e-03)	4.237 4e-02(3.007 5e-03)	3.723 2e-02(3.242 1e-03)
F8	(10,20)	5.983 3e-02(5.070 0e-04)	5.604 4e-02(3.409 3e-04)	5.825 3e-02(1.189 6e-03)	4.462 8e-02(2.326 3e-04)
	(10,25)	5.175 8e-02(2.914 2e-04)	5.004 7e-02(1.756 5e-04)	4.368 0e-02(4.264 4e-04)	3.745 7e-02(1.608 6e-04)
	(10,30)	4.732 5e-02(1.998 1e-04)	4.635 7e-02(1.457 6e-04)	3.698 0e-02(1.708 1e-04)	3.398 2e-02(7.135 2e-05)
F9	(10,20)	3.836 3e-01(2.564 7e-02)	4.858 9e-01(1.020 5e-01)	1.676 6e-01(1.965 0e-02)	2.074 8e-01(2.538 3e-02)
	(10,25)	2.601 0e-01(2.418 0e-02)	3.554 5e-01(7.777 1e-02)	1.042 1e-01(1.612 6e-02)	1.252 3e-01(2.431 0e-02)
	(10,30)	1.735 9e-01(1.926 6e-02)	2.284 3e-01(3.656 5e-02)	7.386 3e-02(1.271 9e-02)	1.014 7e-01(1.530 7e-02)
F10	(10,20)	2.383 2e-01(1.553 6e-02)	2.471 9e-01(1.223 3e-02)	2.042 4e-01(1.532 5e-02)	7.472 4e-02(3.136 8e-03)
	(10,25)	1.785 5e-01(6.686 9e-03)	1.935 8e-01(1.138 3e-02)	1.369 5e-01(1.127 7e-02)	4.674 4e-02(1.669 7e-03)
	(10,30)	1.377 8e-01(6.814 7e-03)	1.415 5e-01(1.238 3e-02)	9.562 7e-02(7.703 3e-03)	3.559 5e-02(1.572 0e-03)
平均值/标准差		13/12	1/13	5/7	26/13

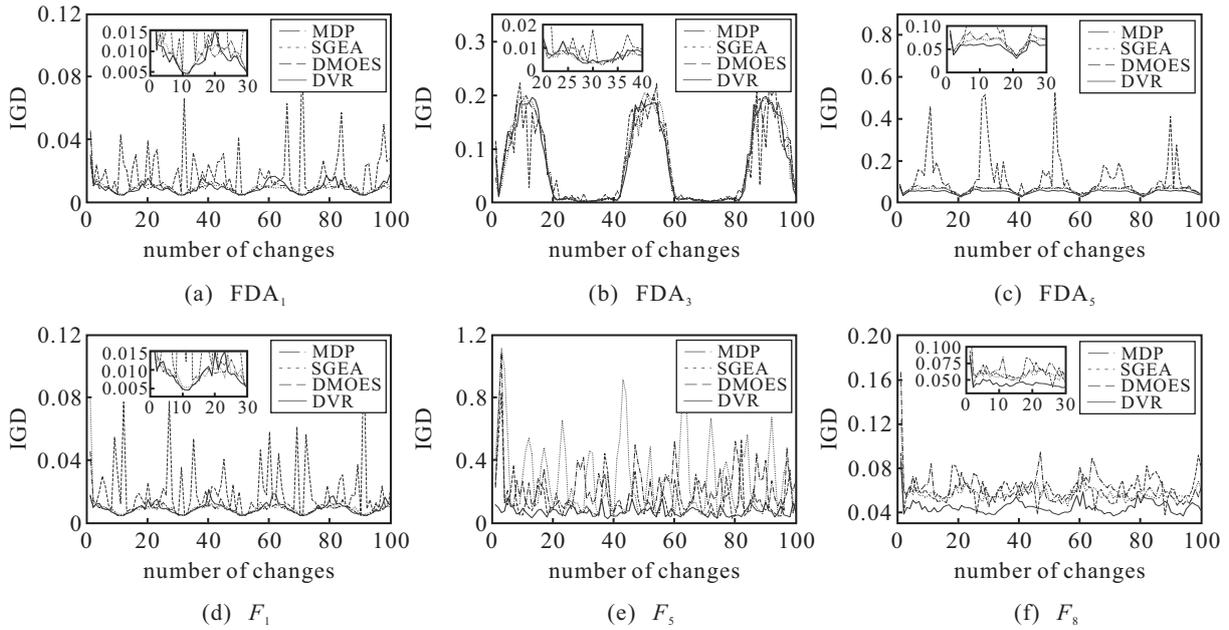


图3 各算法在6个测试函数上的IGD对比曲线 ($n_t = 10, \tau_t = 10$)

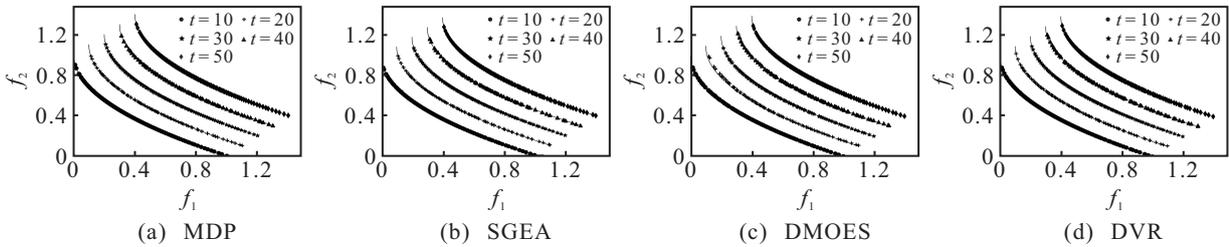


图4 各算法在测试函数F₁不同时刻t的前沿分布 ($n_t = 10, \tau_t = 30$)

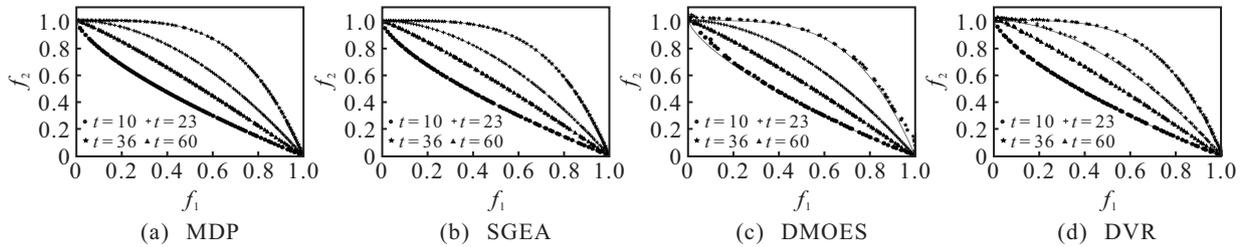


图5 各算法在测试函数FDA₂不同时刻t的前沿分布 ($n_t = 10, \tau_t = 30$)

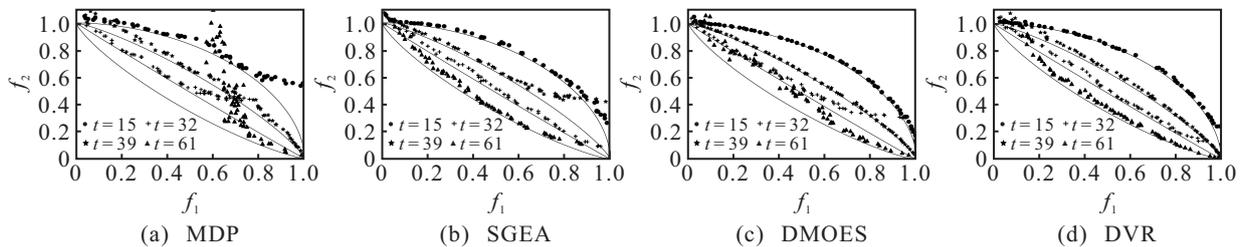


图6 各算法在测试函数F₅不同时刻t的前沿分布 ($n_t = 10, \tau_t = 30$)

4 结论

为了快速响应环境变化,使种群更好地适应新环境,本文提出了一种基于决策变量关系的动态多目标优化算法. 该算法根据决策变量对收敛性和多样性的贡献大小将决策变量分为两类,并对不同类别的决策变量采取不同的进化优化策略. 通过系统抽

样的方法确定引导个体,将种群个体划分到不同的子区域,并通过引导个体的进化方向指导该子区域个体的进化,确保了Pareto前沿的收敛性和分布的多样性. 通过该算法提出的多样性维护机制,使种群分布更加均匀.

使用15个动态多目标测试问题与3种动态多目

标优化算法在不同的环境下进行比较,实验结果表明,所提出算法在环境发生变化时能够更好地追踪不断变化的 Pareto 前沿或 Pareto 解集,且具有良好的分布性. 该算法尚未涉及变目标个数或高维的问题,可作为下一步的研究内容.

参考文献(References)

- [1] Han Y Y, Gong D W, Jin Y C, et al. Evolutionary multiobjective blocking lot-streaming flow shop scheduling with machine breakdowns[J]. IEEE Transactions on Cybernetics, 2019, 49(1): 184-197.
- [2] Jiang M, Huang Z Q, Qiu L M, et al. Transfer learning-based dynamic multiobjective optimization algorithms[J]. IEEE Transactions on Evolutionary Computation, 2018, 22(4): 501-514.
- [3] 马学敏, 杨景明, 孙浩, 等. 基于多区域中心点预测的动态多目标优化算法[J]. 控制与决策, 2022, 37(10): 2477-2486.
(Ma X M, Yang J M, Sun H, et al. Dynamic multi-objective optimization algorithm based on multi-regional center point prediction[J]. Control and Decision, 2022, 37(10): 2477-2486.)
- [4] Hu Z Y, Yang J M, Cui H H, et al. MOEA3D: A MOEA based on dominance and decomposition with probability distribution model[J]. Soft Computing, 2019, 23(4): 1219-1237.
- [5] 刘建昌, 赵阳杰, 李飞, 等. 基于R2指标的昂贵多目标进化算法[J]. 控制与决策, 2020, 35(4): 823-832.
(Liu J C, Zhao Y J, Li F, et al. Expensive multi-objective optimization algorithm based on R2 indicator[J]. Control and Decision, 2020, 35(4): 823-832.)
- [6] Zhang H, Sun J, Liu T, et al. Balancing exploration and exploitation in multi-objective evolutionary optimization[J]. Information Sciences, 2019, 497: 129-148.
- [7] Trojanowski K, Michalewicz Z. Evolutionary optimization in non-stationary environments[J]. Journal of Computer Science and Technology, 2000, 1(2): 93-124.
- [8] Chen R Z, Li K, Yao X. Dynamic multiobjectives optimization with a changing number of objectives[J]. IEEE Transactions on Evolutionary Computation, 2017, 22(1): 157-171.
- [9] 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.
- [10] Peng Z, Zheng J H, Zou J, et al. Novel prediction and memory strategies for dynamic multiobjective optimization[J]. Soft Computing, 2015, 19(9): 2633-2653.
- [11] Gee S B, Tan K C, Alippi C. Solving multiobjective optimization problems in unknown dynamic environments: An inverse modeling approach[J]. IEEE Transactions on Cybernetics, 2017, 47(12): 4223-4234.
- [12] Zhou A M, Jin Y C, Zhang Q F. A population prediction strategy for evolutionary dynamic multiobjective optimization[J]. IEEE Transactions on Cybernetics, 2014, 44(1): 40-53.
- [13] Rong M, Gong D W, Zhang Y, et al. Multidirectional prediction approach for dynamic multiobjective optimization problems[J]. IEEE Transactions on Cybernetics, 2019, 49(9): 3362-3374.
- [14] Ma X M, Yang J M, Sun H, et al. Multiregional co-evolutionary algorithm for dynamic multiobjective optimization[J]. Information Sciences, 2021, 545: 1-24.
- [15] Zheng J H, Zhou Y B, Zou J, et al. A prediction strategy based on decision variable analysis for dynamic multi-objective optimization[J]. Swarm and Evolutionary Computation, 2021, 60: 100786.
- [16] Zhang X Y, Tian Y, Cheng R, et al. A decision variable clustering-based evolutionary algorithm for large-scale many-objective optimization[J]. IEEE Transactions on Evolutionary Computation, 2018, 22(1): 97-112.
- [17] Jiang S Y, Yang S X. A steady-state and generational evolutionary algorithm for dynamic multiobjective optimization[J]. IEEE Transactions on Evolutionary Computation, 2016, 21(1): 65-82.
- [18] Zhang K, Shen C N, Liu X M, et al. Multiobjective evolution strategy for dynamic multiobjective optimization[J]. IEEE Transactions on Evolutionary Computation, 2020, 24(5): 974-988.
- [19] 呼子宇, 李玉林, 魏之慧, 等. 面向复杂超多目标优化问题的自适应增强学习进化算法[J]. 控制与决策, 2022, 37(11): 2849-2859.
(Hu Z Y, Li Y L, Wei Z H, et al. Adaptive boosting learning evolutionary algorithm for complex many-objective optimization problems[J]. Control and Decision, 2022, 37(11): 2849-2859.)
- [20] Zitzler E, Thiele L, Laumanns M, et al. Performance assessment of multiobjective optimizers: An analysis and review[J]. IEEE Transactions on Evolutionary Computation, 2003, 7(2): 117-132.

作者简介

呼子宇(1989—), 男, 副教授, 硕士生导师, 从事复杂系统建模、多目标进化算法、人工智能等研究, E-mail: hzy@ysu.edu.cn;

李紫晗(1996—), 女, 硕士生, 从事动态多目标优化算法的研究, E-mail: lzh960812@163.com;

孙浩(1985—), 男, 讲师, 硕士生导师, 从事智能优化算法、深度神经网络、轧制过程控制等研究, E-mail: sunhao@ysu.edu.cn;

魏立新(1977—), 男, 教授, 博士生导师, 从事轧制过程建模、人工智能与神经网络应用、轧制过程自动控制等研究, E-mail: Wlx2000@ysu.edu.cn;

王聪(1998—), 女, 硕士生, 从事动态多目标优化算法的研究, E-mail: congwysu@163.com.