

# 控制与决策

Control and Decision

## 基于参考线的预测策略求解动态多目标优化问题

李二超, 赵雨萌

引用本文:

李二超, 赵雨萌. 基于参考线的预测策略求解动态多目标优化问题[J]. 控制与决策, 2020, 35(7): 1547–1560.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2018.1442>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 基于R2指标的昂贵多目标进化算法

Expensive multi-objective optimization algorithm based on R2 indicator

控制与决策. 2020, 35(4): 823–832 <https://doi.org/10.13195/j.kzyjc.2018.0597>

### 基于分解的预测型动态多目标粒子群优化算法

Decomposition-based predictive dynamic multi-objective particle swarm optimization algorithm

控制与决策. 2019, 34(6): 1307–1318 <https://doi.org/10.13195/j.kzyjc.2017.1604>

### 基于参考点的高维多目标粒子群算法

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

控制与决策. 2017, 32(4): 607–612 <https://doi.org/10.13195/j.kzyjc.2016.0387>

### 基于分解和差分进化的多目标粒子群优化算法

Multi-objective particle swarm optimization algorithm based on decomposition and differential evolution

控制与决策. 2017, 32(3): 403–410 <https://doi.org/10.13195/j.kzyjc.2016.0186>

### 一种基于进化知识融合的多目标人工蜂群算法

A multi-objective artificial bee colony based on evolutionary knowledge integrated

控制与决策. 2017, 32(12): 2176–2182 <https://doi.org/10.13195/j.kzyjc.2016.1322>

# 基于参考线的预测策略求解动态多目标优化问题

李二超<sup>†</sup>, 赵雨萌

(兰州理工大学 电气工程与信息工程学院, 兰州 730050)

**摘要:** 为了快速且准确地跟踪动态多目标优化问题变化的 Pareto 前沿与 Pareto 解集, 在不依靠历史信息的前提下, 提出一种基于参考线预测策略的求解动态多目标优化问题的算法 (RLPS). 该算法通过记录每个参考线关联的种群个体在环境变化初始时和个体自主进化一小段时间后个体位置的变化, 预测最优个体所在方向, 同时在该方向上均匀分布若干延伸个体, 选出每个参考线关联的非支配个体作为当前环境下的引导个体, 在选出的引导个体邻域内随机产生若干伴随个体增加种群多样性. 通过 5 个标准动态测试函数对该算法测试, 并与两个现有算法作对比分析, 实验结果表明所提出的算法具有更快地响应环境变化的能力.

**关键词:** 动态多目标优化; 参考线; 预测; 引导个体

中图分类号: TP273

文献标志码: A

## Prediction strategy based on reference line for dynamic multi-objective optimization

LI Er-chao<sup>†</sup>, ZHAO Yu-meng

(College of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

**Abstract:** In order to track the Pareto front and Pareto solution set of dynamic multi-objective optimization problems quickly and accurately, an algorithm based on a reference line prediction strategy is proposed to solve dynamic multi-objective optimization problems without relying on historical information. The algorithm predicts the direction of the optimal individual by recording the changes of individual position at the beginning of the environmental change and a short period of time after the individual's self-evolution. At the same time, non-dominated individuals associated with each reference line are selected as the guided individuals according to the uniform distribution of several extend individuals in this direction. The results of 7 benchmark problems and the comparison with other two existing dynamic multi-objective algorithms indicate that the proposed algorithm can maintain better performance in dealing with dynamic multi-objective problems.

**Keywords:** dynamic multi-objective optimization; reference line; prediction; guide-individual

## 0 引 言

现实中许多实际优化问题, 例如动态车辆路径规划<sup>[1]</sup>、动态生产调度和最优控制器的动态设计等, 其待优化的目标会跟随环境发生动态变化, 从而导致最优解随之发生改变, 这类问题统称为动态多目标优化问题.

动态多目标优化问题 (dynamic multi-objective optimization problems, DMOPs) 是指多个目标之间经常冲突, 同时目标函数、约束函数和相关参数都可能随着时间的变化而改变的问题, 如何跟踪变化后的最新最优解集是求解 DMOPs 的主要难点<sup>[2]</sup>. 对于

这个动态的问题, 传统的静态多目标优化算法具有明显的局限性<sup>[3-4]</sup>. 在早期研究中, 如加入移民策略的 DNSGA2 算法<sup>[5]</sup> 和加入免疫策略<sup>[6]</sup> 的动态优化算法等基于静态算法改进的动态多目标优化算法, 只能在环境变化较小的情况下对 DMOPs 的 PS 进行跟踪.

近年来, 为了解决算法对 PS 跟踪能力不足的问题, 研究者们在此基础上提出了许多适应 DMOPs 的动态多目标优化算法<sup>[7-9]</sup>, 这些方法大多集中保持了种群多样性, 使新的种群具有响应环境变化的能力, 然而这些方法具有太多不确定性, 不能提供正确的引导, 具有盲目性. 因此, 在环境变化后, 如何对种群提

收稿日期: 2018-10-22; 修回日期: 2019-02-18.

基金项目: 国家自然科学基金项目 (61763026).

责任编辑: 巩敦卫.

<sup>†</sup>通讯作者. E-mail: lecstarr@163.com.

供一种有效的引导成为了研究的重点.

为此,一些学者提出了许多预测策略来解决这类问题,这些预测策略大多基于历史信息累计,对种群进化提供有效引导,帮助算法对环境变化作出快速响应,预测的准确性是其难点<sup>[10-13]</sup>. Hatzakis等<sup>[10]</sup>提出一种前馈方法,该方法记录目标空间相邻历史信息PF面上的边界点信息,通过自回归模型预测新的最优解集位置,但是该方法预测模型提供信息有限,忽略了最优PF的分布特性,影响了预测效果. Zhou等<sup>[11]</sup>提出一种基于种群预测的动态多目标优化算法,该算法利用种群中心点建立时间序列同时考虑了最优PF的分布性,但是该方法要求最优PS或环境变化模态之间具有相似性或者显性规律,降低了适应性. 郑金华等<sup>[12]</sup>提出了一种基于引导个体的预测策略,该策略是基于种群中心点的位置变换判断种群进化方向,但是在种群尚未较好收敛的情况下可能出现判断失误,导致算法在某几次环境变化的预测上方向不准确,收敛性不好. 陈美蓉等<sup>[13]</sup>提出了一类寻找动态鲁棒Pareto最优解集的进化优化方法,该方法基于某一时刻下的Pareto较优解,以一定稳定性阈值逼近未来多个连续动态环境下的真实前沿,从而直接作为这些环境下的Pareto解集,以减小计算代价,但该方法针对不同动态多目标优化问题需选取不同的参数用于调整. 丁进良等<sup>[14]</sup>提出一种基于参考点预测的动态多目标优化算法(PDMOP),该算法对关联到相同参考点的个体建立时间序列,并对这些时间序列通过线性回归模型预测新环境下的种群,保持多样性增加预测精度,但是该算法依靠历史信息,收敛速度较慢. 刁鹏飞等<sup>[15]</sup>提出一种基于分解技术的动态多目标引力搜索算法,并提出了一种新的对最优解的预测模型,以缩小环境变化后各子问题的搜索空间,提高算法的求解效率,但这种预测策略只针对环境变化前相邻子问题最优解间的预测. Li等<sup>[16]</sup>提出了一种基于特殊点的预测策略,由前馈中心点预测的非支配集是预测群体的主体,将预测模型预测的特殊点集作为指导个体,使得策略跟踪PF更加精确,对环境的响应更加迅速. 自适应分集保持策略可以根据问题的难易程度自适应地引入不同数目的随机个体以保持种群的多样性. 对于决策变量非线性相关的问题,该算法较优,然而,对于决策变量线性相关的问题,由于缺少局部开发功能,该算法效果略差.

针对以上问题,本文提出一种基于参考线的预测策略(RLPS),与现有算法相比,该算法具有如下优势:

1) 利用参考线结构化分布有指导地增加种群多样性,实现收敛速度与种群多样性平衡.

2) 提出一种预测个体进化方向的判断算子,在不需历史信息积累的前提下为预测最优解所在方向提供依据.

3) 将参考线与预测策略相结合,可抵消由于种群尚未收敛对部分个体预测方向不准确而造成的影响.

4) 设计延伸个体和伴随个体的产生机制,选择引导个体作为最优解,避免种群陷入局部最优,同时加速种群收敛.

本文选取FDA1、FDA2、FDA3、FDA4、FDA5<sup>[17]</sup>、DMOP1和DMOP2<sup>[18]</sup>5个典型的动态测试函数,将RLPS算法与DNSGA2<sup>[5]</sup>和PDMOP<sup>[14]</sup>算法进行对比研究,实验结果表明,RLPS算法在保持种群的收敛性和分布性的同时,具有更好的收敛速度,可以更好地对环境变化作出响应.

## 1 问题描述

不失一般性,以最小多目标优化问题为研究对象,一个具有 $n$ 维决策变量, $m$ 个目标函数的动态多目标优化问题可以描述为<sup>[19]</sup>

$$\begin{cases} \min F(x, t) = \{F_1(x, t), F_2(x, t), \dots, F_m(x, t)\}; \\ \text{s.t. } g(x, t) \leq 0, \\ h(x, t) = 0, \\ x \in \Omega, x \subset R^n. \end{cases} \quad (1)$$

其中: $t$ 为时间变量, $x = (x_1, x_2, \dots, x_n)^T$ 为 $n$ 维决策变量, $g$ 和 $h$ 分别为不等式约束和等式约束, $\Omega$ 为决策空间, $F$ 为与时间变量 $t$ 有关的 $m$ 维目标函数.

**定义1 (Pareto 支配)** 设 $p$ 和 $q$ 是种群中的任意两个个体, $p$ 支配 $q$ 表示为 $F(p) < F(q)$ ,当且仅当 $F_i(p) \leq F_i(q) (\forall i = \{1, 2, \dots, m\})$ 满足 $F_i(p) < F_i(q)$ .

**定义2 (Pareto 最优解集, PS)** 设 $x$ 为决策变量, $\Omega$ 为决策空间, $F$ 为目标函数,定义为

$$\text{PS} = \{x \in \Omega | \exists x^* \in \Omega, F(x^*) < F(x)\}.$$

**定义3 (Pareto 最优前沿, PF)** 设 $x$ 为决策变量, $F$ 为目标函数,定义 $\text{PF} = \{y = F(x) | x \in \text{PS}\}$ .

根据PS和PF的变化情况,动态多目标优化问题可分为4类:

第1类: PS随时间变化, PF不随时间变化;

第2类: PS不随时间变化, PF随时间变化;

第3类: PS和PF都随时间变化;

第4类: PS和PF都不随时间变化.

### 2 基于参考线关联个体的预测策略

在不需要历史信息累计的情况下,本文提出一种基于参考线关联个体的预测策略.该策略解决了动态多目标优化问题中不能快速响应环境变化、及时地搜索到新的PF和PS的问题,其中包括4个方面:1)个体参考线关联及选择;2)预测个体进化方向的判断算子;3)延伸个体的产生机制;4)伴随个体产生策略.算法的设计原理如图1所示.

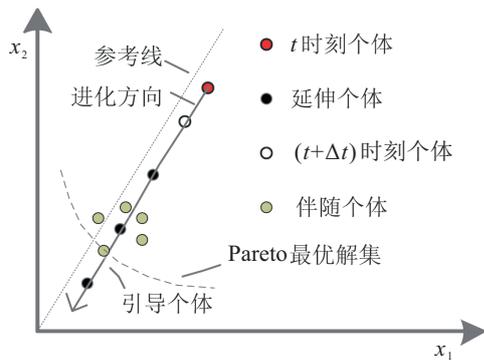


图1 RLPS设计原理

图1中的红色点个体为t时刻关联参考线的个体,环境变化后该个体自主进化为新个体(白色点),这两个不同时刻的个体位置之间连线方向代表预测个体的进化方向.根据这个预测方向,从当前个体到决策空间的边界之间均匀分布一定数量的延伸个体(黑色点),并通过基于参考线的选择策略选出相对较优的延伸个体.在选出的延伸个体周围随机产生伴随个体(绿色点),以避免种群陷入局部最优,增加多样性.最后,对所有的伴随个体及选出的延伸个体通过基于参考线的选择策略选出一定数量的引导个体.

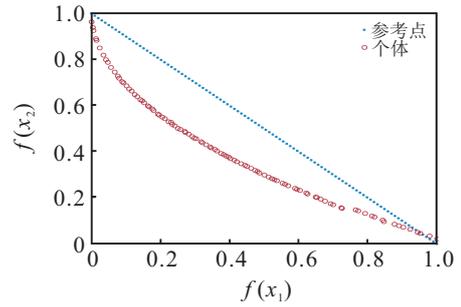
#### 2.1 个体参考线关联与选择

本文采用文献[20]的方法设计均匀分布在超平面上的参考点,参考点的集合Z如下所示:

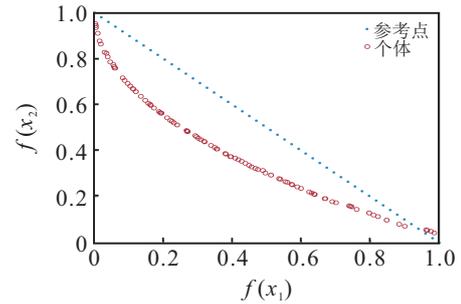
$$\begin{cases} Z_i = (z_i^1, z_i^2, \dots, z_i^M), \\ z_i^j \in \left\{ \frac{0}{p}, \frac{1}{p}, \dots, \frac{p}{p} \right\}, \sum_{j=1}^M z_i^j = 1. \end{cases} \quad (2)$$

其中:  $i = 1, 2, \dots, H, H = \binom{M+p-1}{p}$  为参考点的数目,  $M$  为目标函数的个数,  $p$  为每维坐标分段的个数.对于本文需要解决的问题,作如下对比测试:分别将  $H$  数值设置为100、50和10,在环境变化3次时,对FDA1测试函数的测试效果对比如图2所示,由于图中参考线分布过密影响视觉效果,图中用参考点代替参考线进行示意.可明显看出,随着  $H$  数值的逐渐减小,种群的分布性逐渐变差,从而导致算法的分布性变差.为了保持算法种群良好的分布性,本文设

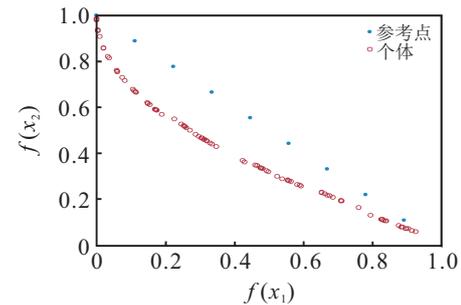
置  $H \approx N, N$  为种群大小.当生成参考点个数  $H$  约为100时,参考点结构分布如图3所示.连接每个参考点和原点作为参考线,参考线结构分布如图4所示.



(a) H个数为100



(b) H个数为50



(c) H个数为10

图2 RLPS设计原理图

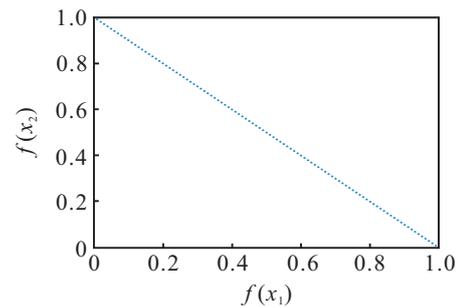


图3 参考点结构分布图

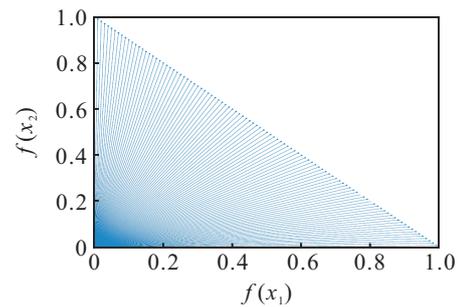


图4 参考线结构分布图

使用向量的方法计算每个个体到参考线的距离,如图5所示,原点O到参考点的向量设置为 $\vec{a}$ ,原点到个体的向量设置为 $\vec{b}$ , $\vec{a}$ 与 $\vec{b}$ 的夹角设置为 $\theta$ ,计算距离 $d$ 的过程如下所示:

$$\cos \theta = \frac{\vec{a} \cdot \vec{b}}{|\vec{a}| \cdot |\vec{b}|}, \quad (3)$$

$$\sin \theta = \sqrt{1 - \cos^2 \theta}, \quad (4)$$

$$d = |\vec{b}| \cdot \sin \theta. \quad (5)$$

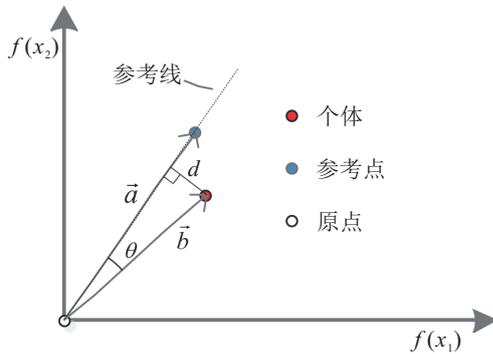


图5 向量方法计算示意图

计算出每个个体与所有参考线的距离 $d$ ,并将个体与 $d$ 最小的参考线进行关联.当相邻参考线之间存在相同的关联个体时,由于参考线分布密度较大,且发生该情况的概率较小,从两条相邻参考线之间随机选择其中一条作为该关联个体的关联参考线对算法影响不大,本文选择目标 $f(x_1)$ 略小的参考线加以关联.基于参考线的选择策略是选出每个参考线关联的非支配等级最低的个体,并将其从原先的种群中移除,再从剩下的个体中依次根据参考线关联选择,直至选出的个体数达到初始种群规模.

### 2.2 预测个体进化方向的判断算子

当环境发生变化时,种群会自主向PF和PS方向进化,基于这个特点,在环境变化的初始阶段,通过记录每个参考线上关联个体(当一个参考线关联多个个体时取其中心点)的前后位置变化,判断每个参考线关联个体在当前环境下的进化方向.由于选取环境变化后的第1代种群,可能由于种群尚未收敛出现判断误差,而当种群自主进化一小段 $\Delta t$ 后,有了初步的收敛方向,因此选择自主进化 $\Delta t$ 时间后的种群进行判断,可大大减少判断误差.预测个体进化方向的判断算子表示如下:

$$D = (D_1, \dots, D_i, \dots, D_n) = (C_1^{t+\Delta t} - C_1^t, \dots, C_i^{t+\Delta t} - C_i^t, \dots, C_n^{t+\Delta t} - C_n^t). \quad (6)$$

其中: $D$ 为个体在决策空间中的进化方向, $C_i^t$ 为第 $i$ 维决策变量在 $t$ 时刻该个体的位置, $C_i^{t+\Delta t}$ 为第 $i$ 维

决策变量在 $t$ 时刻后进化了 $\Delta t$ 时间后新个体的位置, $i = 1, 2, \dots, n$ , $n$ 为决策空间的维数.若每个参考线关联多个个体,则该参考线个体的中心点表示为

$$C_i^t = \frac{1}{P} \sum_{p \in P} v_p^t. \quad (7)$$

其中: $P$ 为该参考线关联的个体数量, $v_p^t$ 为 $t$ 时刻个体在决策空间中的位置.

通过计算决策空间中每一维每个参考线关联个体位置的变化,判断出个体进化的方向,将每个结果用一组向量表示,前后分别用正负表示.

### 2.3 延伸个体的产生机制

为了更加准确地预测PS的位置,在预测的个体进化方向上延伸出一串均等分的预测个体 $p$ ,通过基于参考线的选择策略选出当前环境下较优的延伸个体,具体步骤详见算法1.

#### 算法1 延伸个体产生机制.

step 1: for  $j = 1 : H // H$ 为参考线数目.

step 2: 根据式(2)所得方向 $D$ ,若为正,则从决策空间第 $i$ 维的边界最大值到个体的距离均等分成 $P$ 份;若为负,则从决策空间第 $i$ 维的边界最小值到个体的距离均等分成 $P$ 份,得到检测个体表示如下:

$$p_i^j = \begin{cases} x_i^j + \frac{i_{\max} - x_i^j}{P} k, & D_i > 0; \\ x_i^j - \frac{x_i^j - i_{\min}}{P} k, & D_i < 0; \end{cases} \quad (8)$$

$$k = 1, 2, \dots, P - 1.$$

其中 $i_{\max}$ 为决策空间第 $i$ 维的边界最大值, $i_{\min}$ 为第 $i$ 维的边界最小值.

step 3: end

step 4: 对生成的PH个检测个体进行非支配排序,并根据参考线选择出 $E$ 个个体作为当前最优延伸个体.

### 2.4 伴随个体产生策略

为了增加种群的多样性,避免由于延伸个体的引导使种群陷入局部最优,在每个最优延伸个体邻域产生 $A$ 个新的伴随个体 $a$ ,伴随个体采用步长变异的方法产生,产生方式如下:

$$a_i^k = p_i^j + 0.5L \text{ or } a_i^k = p_i^j - 0.5L; \\ k = 1, 2, \dots, A, j = 1, 2, \dots, H, \\ L = \text{random}(0, 0.1). \quad (9)$$

### 2.5 RLPS算法步骤

RLPS算法以PDMOP算法为基本框架,对其预测策略等进行了改进.RLPS算法的伪代码如算法2所示.

**算法2 RLPS算法伪代码.**

step 1: 参数及种群初始化. 设置初始化参数, 进化代数  $gen$ , 在决策空间内随机生成种群规模为  $pop$  的初始种群  $C$ , 初始环境  $t$ , 环境变化幅度  $\tau_T$ , 环境变化频率  $n_T$ .

step 2: 环境检测. 如果环境发生变化, 则跳转 step 3, 否则, 跳转 step 7.

step 3: 预测个体进化方向. 种群自主进化  $\Delta t$  时间, 根据式(6)计算每个参考线个体进化方向  $D$ .

step 4: 生成延伸个体  $e$  和伴随个体  $a$ ; 根据算法1和式(9), 对其进行边界检测. 如果  $x_i > Up_j$ , 则  $x_i = Up_j$ . 如果  $x_i < Low_j$ , 则  $x_i = Low_j$ .

step 5: 生成引导个体. 对  $e \cup a$  进行非支配排序, 重新关联参考线, 通过参考线关联选择引导个体  $g$ .

step 6: 替换个体. 将得到的引导个体  $g$  替换掉当前种群中非支配排序等级较高的个体, 得到新种群.

step 7: 交叉变异. 以一定的交叉概率  $p_c$ 、变异概率  $p_m$ , 对当前种群  $C$  进行进化操作, 生成子代种群  $C_c$ .

step 8: 关联与选择个体. 对  $C \cup C_c$  进行非支配排序, 将其每个个体与参考线关联, 并根据参考线关联选择  $pop$  个个体作为下一代种群.

step 9: 判断是否满足停止条件. 若满足, 则停止; 否则, 跳转 step 2.

**2.6 计算复杂度分析**

本小节介绍 RLPS 算法在一代中的计算复杂性. 设种群规模  $pop$  为  $N$ , 目标函数的个数为  $m$ , 则本算法求解目标函数值的时间复杂度为  $O(mN)$ ; 设参考线规模  $H$  为  $N_1 N_2 \dots N_H$ , 个体参考线关联部分中计算个体与参考线之间距离的时间复杂度为  $O(m(N_1 + N_2 + \dots + N_K)^2)$ , 种群更新的时间复杂度为  $O(m(N_1 + N_2 + \dots + N_K)^2)$ . 综上, 本文算法迭代一次的最坏时间复杂度为  $O(mN) + O(m(N_1 + N_2 + \dots + N_K)^2)$ , 所以本文算法的时间复杂度为  $O(mN^2)$ .

**3 实验仿真及结果分析****3.1 测试问题**

本文选取7个FDA系列和DMOP系列传统典型问题<sup>[17-19]</sup>作为测试函数, 涵盖了3类动态多目标问题. 其中FDA系列问题的决策变量之间是线性相关的, DMOP系列问题是对FDA系列问题的扩展, 如表1所示.

**3.2 评价指标**

本文采用3个评价指标来评价算法的性能, 具体

如下:

1) 反向世代距离<sup>[21]</sup>(IGD). 衡量算法的收敛性和种群的多样性, 值越小, 说明性能越好, 公式如下:

$$IGD = \frac{1}{|P|} \sum_{i=1}^{|P|} d_i. \quad (10)$$

其中:  $|P|$  为真实PF中的种群个体个数,  $d_i$  为真实PF中的每个个体到算法选出的种群个体的最短距离.

2) 世代距离<sup>[22]</sup>(GD). 计算个体到真实PF上的最近点的平均距离, 值越小, 说明PS的收敛性越好, 越靠近真实前沿, 公式如下:

$$GD = \frac{\sqrt{\sum_{x \in P} d(x, P)}}{|P^*|}. \quad (11)$$

其中:  $d(x, P)$  为个体  $x$  到PF面  $P$  的欧氏距离,  $|P^*|$  为算法求得的种群个体.

3) Schott的间隔度量<sup>[21]</sup>(SP)指标. 计算所求得的解集在目标空间上的分布性, 值越小, 说明分布越均匀, 公式如下:

$$SP = \sqrt{\frac{1}{|P^*| - 1} \sum_{i=1}^{|P^*|} (D_i - \bar{D})^2}. \quad (12)$$

其中:  $D_i$  为算法选出的种群中的每个个体到真实PF中的个体的最短距离,  $|P^*|$  为算法求得的种群个体,  $\bar{D}$  为  $D_i$  的平均值.

**3.3 参数设置**

1) 进化部分: 种群规模 ( $pop$ ) 设定为100, 进化代数 ( $gen$ ) 设定为500, 交叉概率设定为0.9, 变异概率设定为0.1.

2) 预测部分: 为了减少预测个体的计算消耗, 均等分的预测个体数 ( $P$ ) 设定为5, 延伸个体个数 ( $E$ ) 设定为10, 伴随个体个数 ( $A$ ) 设定为5, 自主进化时间 ( $\Delta t$ ) 设定为5(经多次实验分析可得, 自主进化时间越长, 预测效果越好, 但时间过长失去了预测的意义, 因而本文选取中间值5).

3) 环境代数设定: 环境变化频率 ( $\tau_i$ ) 设定为30(经多次实验得, 该参数小于30时, 所有的算法都没有收敛, 大于30时, 所有算法都基本收敛, 均不具有比较的意义, 因而本文选择30), 环境变化幅度 ( $n_i$ ) 设定为5. 算法运行300代停止, 共10个环境(个别算法运行450代, 共15个环境), 每个算法独立运行20次.

**3.4 实验结果与分析**

对于每一类测试问题, 都将本文算法(RLPS)与DNSGA2和PDMOP算法进行对比, 分别计算IGD、GD和SP三种评价指标, 计算结果均值如表2所示.

表1 测试函数

测试函数	定义	特征
FDA1	$f_1(X_I, t) = x_1, f_2 = gh$ $g(X_{II}, t) = 1 + \sum_{x_i \in X_{II}} (x_i - G(t))^2,$ $h(f_1, g, t) = 1 - \sqrt{\frac{f_1}{g}}$ $G(t) = \sin(0.5\pi t), t = \frac{1}{n_t} \lfloor \frac{\tau}{\tau_t} \rfloor$ $X_{II} = (x_1) \in [0, 1], X_{II} = (x_2, \dots, x_{20}) \in [-1, 1]$	第1类问题 PS(t) : $x_1 \in [0, 1]$ $x_i = G(t), i = 2, 3, \dots, 20$ PF(t) : $f_1 = x_1, f_2 = 1 - \sqrt{f_1}$
FDA2	$f_1(X_I) = x_1, f_2 = gh$ $g(X_{II}) = 1 + \sum_{x_i \in X_{II}} (x_i)^2$ $H(t) = 0.75 + 0.7 \sin(0.5\pi t), t = \frac{1}{n_t} \lfloor \frac{\tau}{\tau_t} \rfloor$ $G(t) = H(t) + \sum_{x_i \in X_{III}} (x_i - H(t))^2$ $h(X_{III}, f_1, g) = 1 - \left(\frac{f_1}{g}\right)^{G(t)^{-1}}$ $X_I = (x_1) \in [0, 1], X_{II} = (x_2, \dots, x_{16}) \in [-1, 1],$ $X_{III} = (x_{17}, \dots, x_{31}) \in [-1, 1]$	第2类问题 PS(t) : $x_1 \in [0, 1]; x_i = 0, i = 2, 3, \dots, 16$ $x_j = -1, j = 17, \dots, 31$ PF(t) : $f_1 = x_1$ $f_2 = 1 - (f_1)^{(H(t)+ X_{III} (1+H(t))^2)^{-1}}$
FDA3	$f_1(X_I) = \sum_{x_1 \in X_{II}} x_i^{F(t)}, f_2 = gh$ $g(X_{II}) = 1 + G(t) + \sum_{x_i \in X_{II}} (x_i - G(t))^2$ $h(f_1, g) = 1 - \sqrt{\frac{f_1}{g}}, G(t) = \sin(0.5\pi t)$ $F(t) = 10^{2 \sin(0.5\pi t)}, t = \frac{1}{n_t} \lfloor \frac{\tau}{\tau_t} \rfloor$ $X_I = (x_1, \dots, x_5) \in [0, 1], X_{II} = (x_6, \dots, x_{30}) \in [-1, 1]$	第3类问题 PS(t) : $x_1 \in [0, 1]; x_i = 0, i = 1, \dots, 5$ $x_i = G(t), i = 6, \dots, 30$ PF(t) : $f_1 = x_1, f_2 = (1 + G(t)) \cdot \left(1 - \frac{\sqrt{f_1}}{1 + G(t)}\right)$
FDA4	$f_1(x) = (1 + g_1 + g_2) \cos(0.5\pi X_I)$ $f_2(x) = (1 + g_1 + g_2) \sin(0.5\pi X_I)$ $g_1(x) = \sum_{x \in X_{II}} (x_i - 0.5)^2, g_2(x) = \sum_{x \in X_{III}} (x_i - G(t))^2$ $G(t) =  \sin(0.5\pi t) $ $t = \frac{1}{n_t} \lfloor \frac{\tau}{\tau_t} \rfloor$ , where : $x_i \in [0, 1], i = 1, 2, \dots, 20$ $X_I = (x_1), X_{II} = (x_2, \dots, x_{10}), X_{III} = (x_{11}, \dots, x_{20})$	第1类问题 PS(t) : $x_1 \in [0, 1]; x_i = 0.5, x_i \in X_{II}$ $x_i = G(t), x_i \in X_{III}$ PF(t) : $f_1(x) = \cos(0.5\pi x_1)$ $f_2(x) = \sin(0.5\pi x_1)$
FDA5	$f_1(x) = (1 + g_1) \cos(0.5\pi x_1) + (1 + g_2) \cos(0.5\pi y_1)$ $f_2(x) = (1 + g_1) \sin(0.5\pi x_1) + (1 + g_2) \sin(0.5\pi y_1)$ $g_1(x) = \sum_{x \in X_{II}} (x_i - 0.5)^2, g_2(x) = G(t) + \sum_{x \in X_{III}} (x_i - G(t))^2$ $y_1 = x_1^{F(t)}, G(t) =  \sin(0.5\pi t) ,$ $F(t) = 1 + 100 \sin^4(0.5\pi t)$ $t = \frac{1}{n_t} \lfloor \frac{\tau}{\tau_t} \rfloor$ , where : $x_i \in [0, 1], i = 1, 2, \dots, n$ $X_I = (x_1), X_{II} = (x_2, \dots, x_{16}), X_{III} = (x_{17}, \dots, x_{31})$	第3类问题 PS(t) : $x_1 \in [0, 1], x \in X_I$ $x_i = 0.5, x \in X_{II}$ $x_i = G(t), x_i \in X_{III}$ PF(t) : $f_1(x) = \cos(0.5\pi x_1) + (1 + G(t)) \cos(0.5\pi y_1)$ $f_2(x) = \sin(0.5\pi x_1) + (1 + G(t)) \sin(0.5\pi y_1)$
DMOP1	$f_1(X_I) = x_1, f_2(X_{II}) = gh,$ $g(X_{II}) = 1 + 9 \cdot \sum_{i=2}^m x_i^2, h(f_1, h) = 1 - \left(\frac{f_1}{g}\right)^{H(t)}$ $H(t) = 0.75 \cdot \sin(0.5\pi t) + 1.25, t = \frac{1}{n_t} \lfloor \frac{\tau}{\tau_t} \rfloor$ where : $x_i \in [0, 1], i = 1, 2, \dots, 10;$ $X_I = (x_1), X_{II} = (x_2, \dots, x_{10})$	第2类问题 PS(t) : $x_1 \in [0, 1]$ PF(t) : $f_1 = x_1, f_2 = 1 - f_1^{H(t)}$
DMOP2	$f_1(X_I) = x_1, f_2(X_{II}) = gh,$ $g(X_{II}) = 1 + \sum_{i=2}^m (x_i - G(t))^2, h(f_1, g) = 1 - \left(\frac{f_1}{g}\right)^{H(t)}$ $H(t) = 0.75 \sin(0.5\pi t) + 1.25,$ $G(t) = \sin(0.5\pi t), t = \frac{1}{n_t} \lfloor \frac{\tau}{\tau_t} \rfloor$ where : $x_i \in [0, 1], i = 1, 2, \dots, 10;$ $X_I = (x_1), X_{II} = (x_2, \dots, x_{10})$	第3类问题 PS(t) : $x_1 \in [0, 1]$ PF(t) : $f_1 = x_1, f_2 = 1 - f_1^{H(t)}$

表2 3种算法所获解集的性能指标

问题	性能指标	DNSGA2	PDMOP	RLPS
FDA1	IGD	0.0769	0.0227	<b>0.0137</b>
	GD	0.0951	0.0186	<b>0.0068</b>
	SP	0.0246	0.007	<b>0.0057</b>
FDA2	IGD	0.1374	0.1168	<b>0.0518</b>
	GD	0.1050	0.3944	<b>0.0735</b>
	SP	0.1373	0.0572	<b>0.0206</b>
FDA3	IGD	0.2966	0.2793	<b>0.2753</b>
	GD	<b>1.2385</b>	1.5663	3.1419
	SP	1.2255	<b>0.3816</b>	1.1572
FDA4	IGD	0.0270	0.0244	<b>0.0228</b>
	GD	0.0271	0.0164	<b>0.0134</b>
	SP	<b>0.0023</b>	0.0040	0.0072
FDA5	IGD	0.9057	0.5992	<b>0.5373</b>
	GD	0.9588	0.5613	<b>0.5404</b>
	SP	0.1942	<b>0.1488</b>	0.756
DMOP1	IGD	0.0049	0.0088	<b>0.0049</b>
	GD	0.0029	0.0017	<b>0.0007</b>
	SP	0.0011	0.0044	<b>0.0009</b>
DMOP2	IGD	0.1352	0.0920	<b>0.0693</b>
	GD	<b>0.0605</b>	0.1458	0.0665
	SP	<b>0.0305</b>	0.0693	0.6384

由表2数据可以看出,3种算法对于FDA1、FDA2、FDA4和DMOP1测试问题都有很好的效果,对于FDA3、FDA5和DMOP2的PF和PS都时变类型的测试问题的效果略差,通过数值对比,可明显看出本文提出的算法(RLPS)求得的种群的性能指标大部

分优于DNSGA2和PDMOP算法,表中加粗数值为实验有效数值.为了更好地对比3种算法的优劣,本文将3种算法分别运行了300~450代,计算了10~15个环境下的性能指标,并截取了部分时刻的解集分布图进行对比分析,具体如下.

1) 第1类问题.

本文选择了FDA1和FDA4测试函数作第1类问题的代表,每一个环境下的指标均值如图6和图7所示,部分环境下的解集分布如图8和图9所示.

对于这类问题,本文分别计算了3个算法10个环境下的3个性能指标均值,选取6个具有代表性的环境下的解集分布图进行对比分析.对于FDA1测试问题,RLPS算法在环境前3次变化中表现出了很好的收敛性,但种群分布不是很均匀,经分析在参考线选择策略中,由于初始种群分布不均,有些参考线并未关联个体,算法集中保持了局部最优解,变异后对个体的分布性影响略小,从而导致种群分布不是很均匀,但经过几代进化,种群的分布性得到了改善,对算法的整体影响不大;对于FDA4算法,RLPS算法在环境前3次变化中同样表现了很好的收敛性,在分布性上,个别的个体出现偏离的现象,经分析在参考线选择策略中,该个体是其所在参考线的最优解,因而被保留下来,但经过几代进化,已然可以收敛,对算法的整体影响不大.

综上分析,在环境变化初期,RLPS算法可更快地响应环境的变化,经过几代进化,RLPS算法的分布性、多样性、覆盖性与其他算法相差不大,说明RLPS

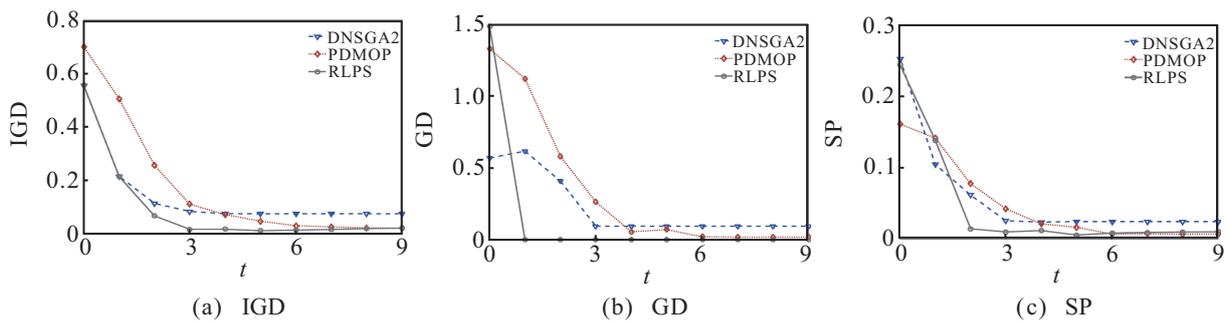


图6 FDA1的性能指标

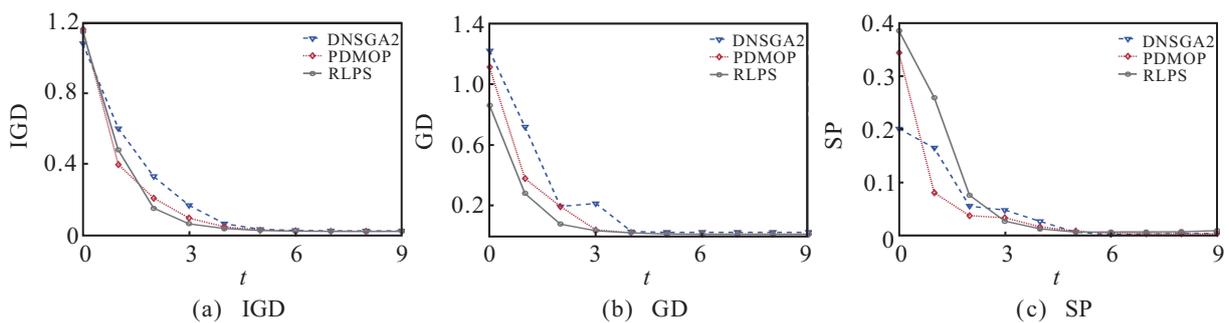


图7 FDA4的性能指标

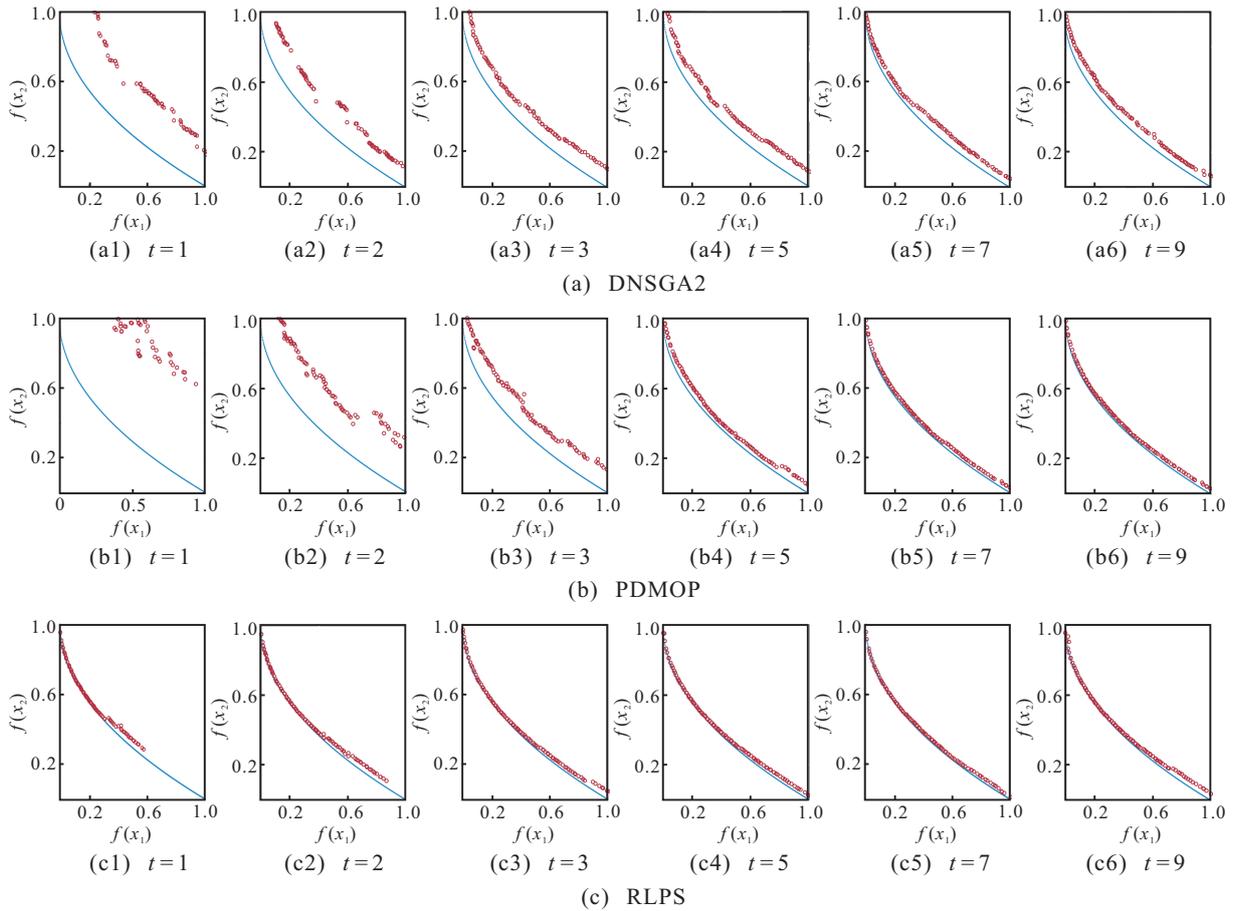


图8 FDA1的解集分布图

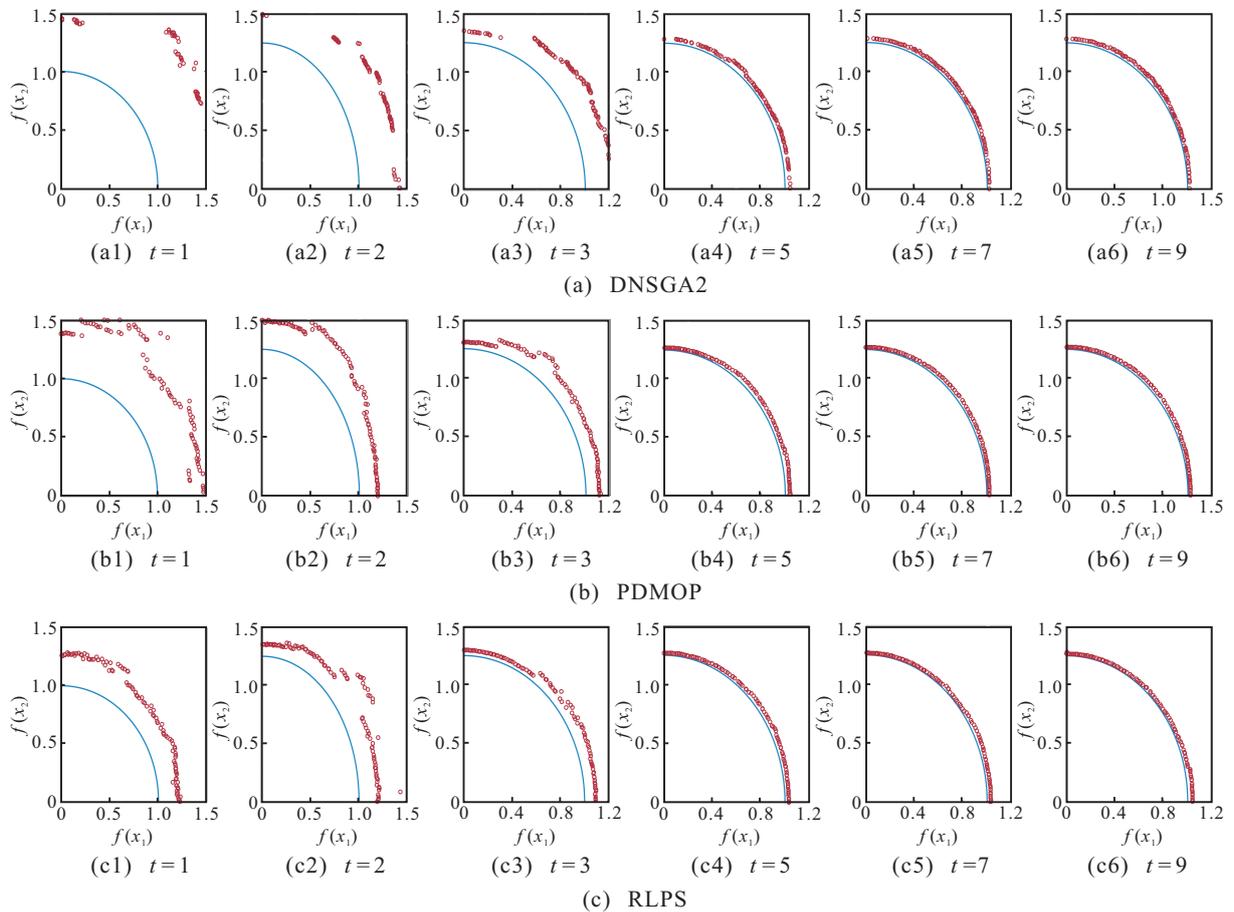


图9 FDA4的解集分布图

算法可以更好地适用于第1类问题.

2) 第2类问题.

本文选择了FDA2和DMOP1测试函数作为第

2类问题的代表, 每一个环境下的指标均值如图10和图11所示, 部分环境下的解集分布如图12和图13所示.

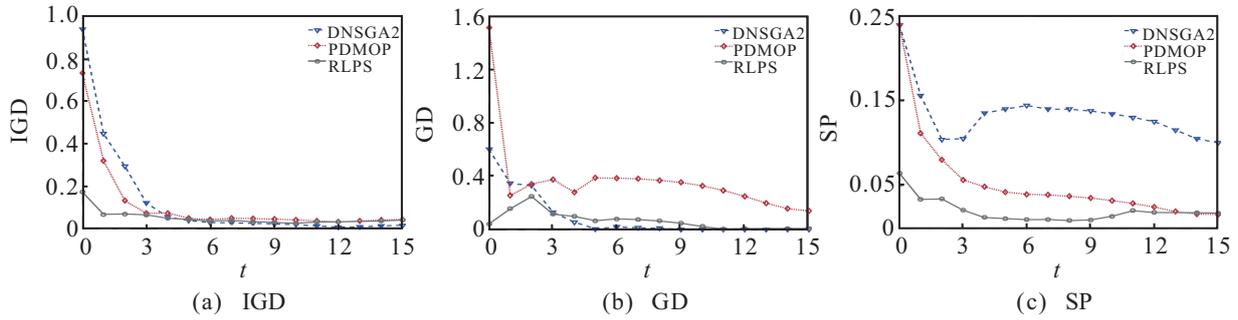


图10 FDA2的性能指标

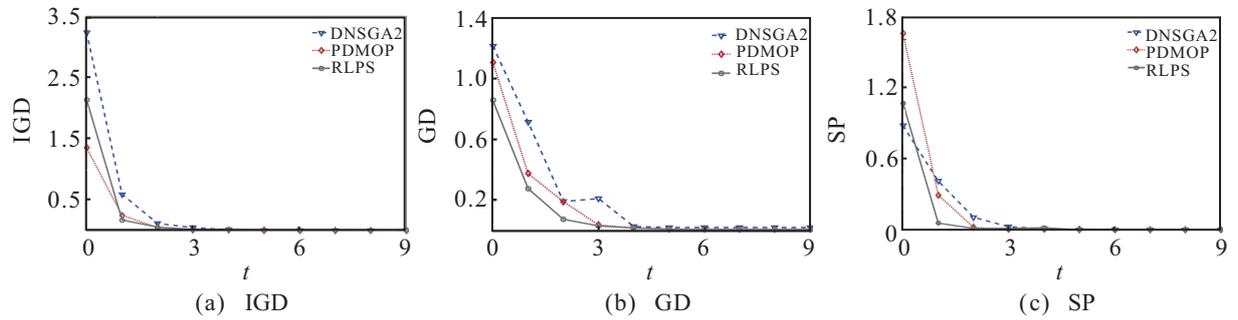


图11 DMOP1的性能指标

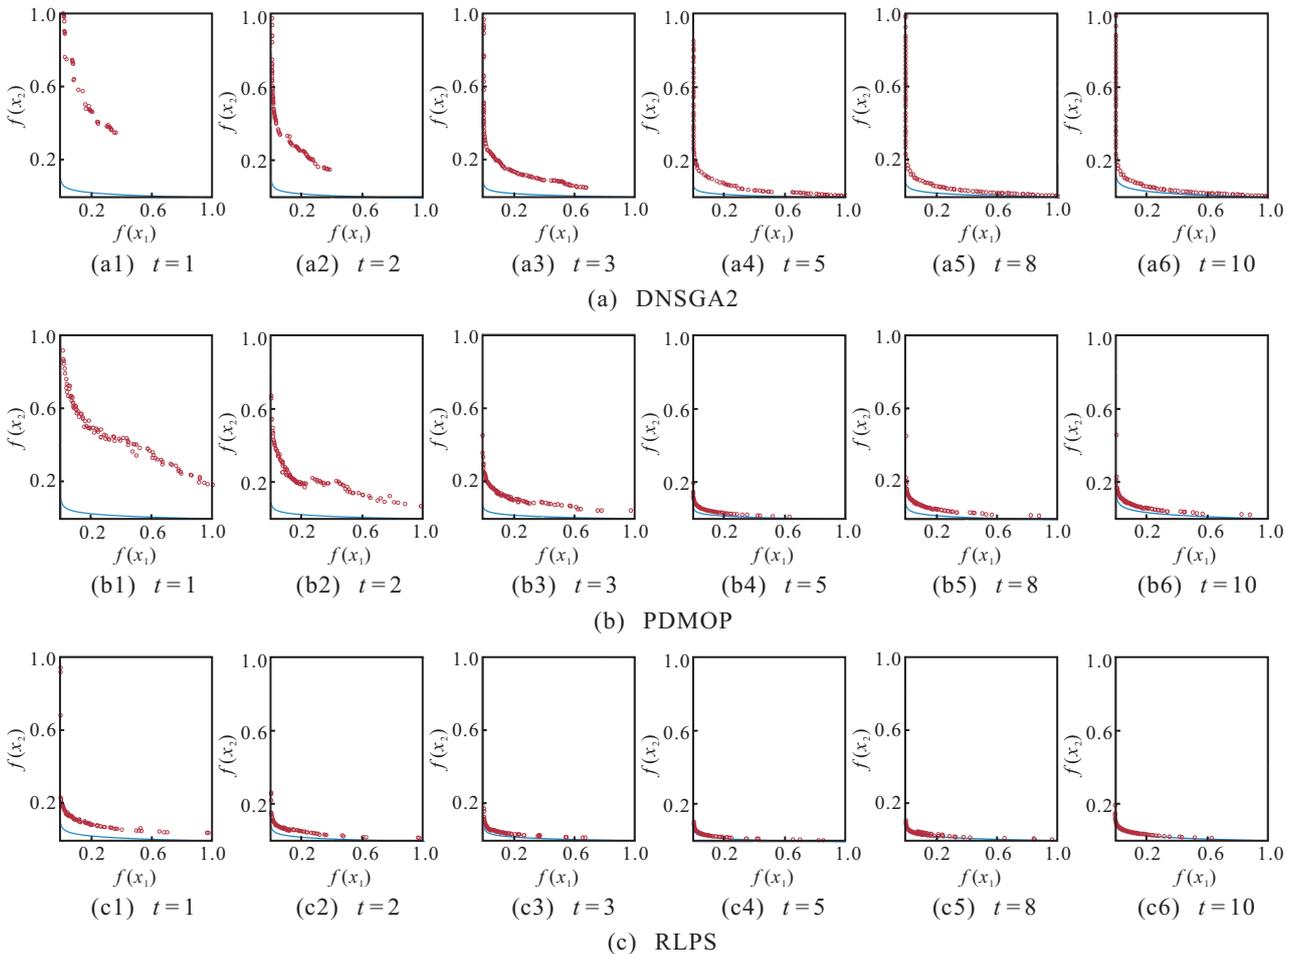


图12 FDA2的解集分布图

对于这类问题,为了更好地观察分析前沿的变化情况,本文分别计算了3个算法16个环境下的3个性能指标均值,选取6个有代表性的环境下的解集分布图进行对比分析.通过整体对比可以看出,RLPS算法求得的解集均优于其他算法各项性能.对于FDA2测试问题,最优PF呈现凹型变化,前3个环境下RLPS算法收敛效果明显优于其他算法,进化几代后,DNSGA2的分布性更好.对于DMOP1测试问题,最优PF呈现凸显至凹型的变化,在环境变化前3次,RLPS算法求得解集收敛速度明显更快.经过几代进化,种群分布性依然欠佳,具体原因与第1类问题分析相同,随着种群的进化,在环境后几次变化中,3

种算法性能相差不大.综上分析,RLPS算法在环境前3次变化中效果尤为明显,可以更好地适用于第2类问题.

3) 第3类问题.

本文选择了FDA3、FDA5和DMOP2三个测试函数作为第3类问题的代表,每一个环境下的指标均值分别如图14~图16所示,部分环境下的解集分布分别如图17~图19所示.

可以看出,对于PF和PS都变化的问题,3种算法的收敛速度相比前两类问题较慢.在环境变化的前几次,RLPS算法对环境的响应速度略大于其他两种算法,GD和SP指标不理想是由于预测的部分个体偏

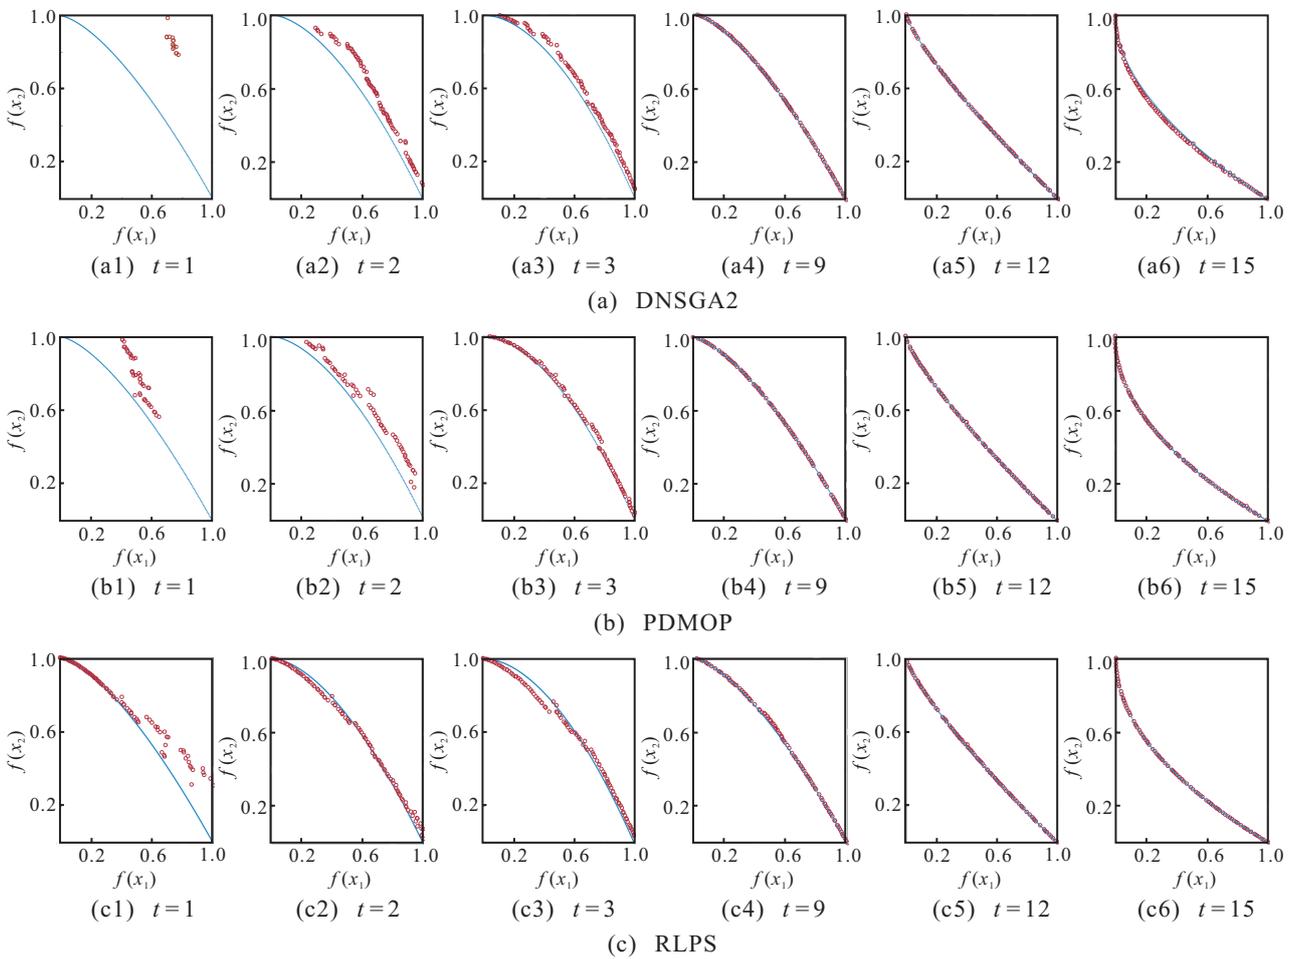


图13 DMOP1的解集分布图

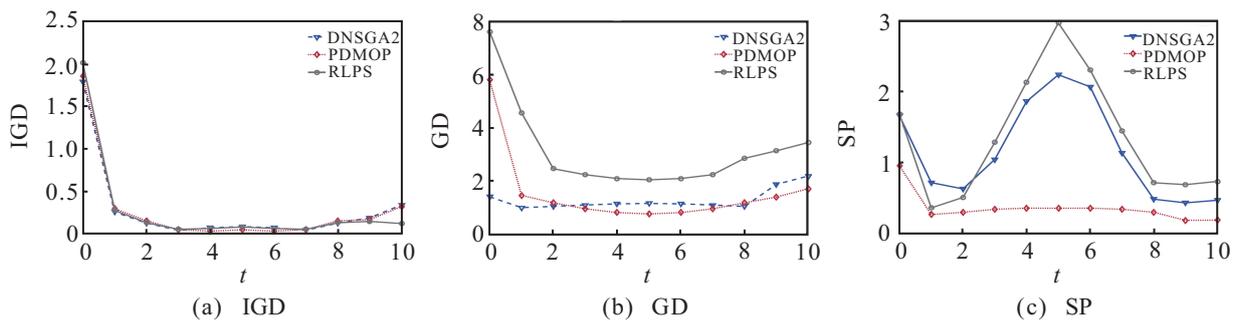


图14 FDA3的性能指标

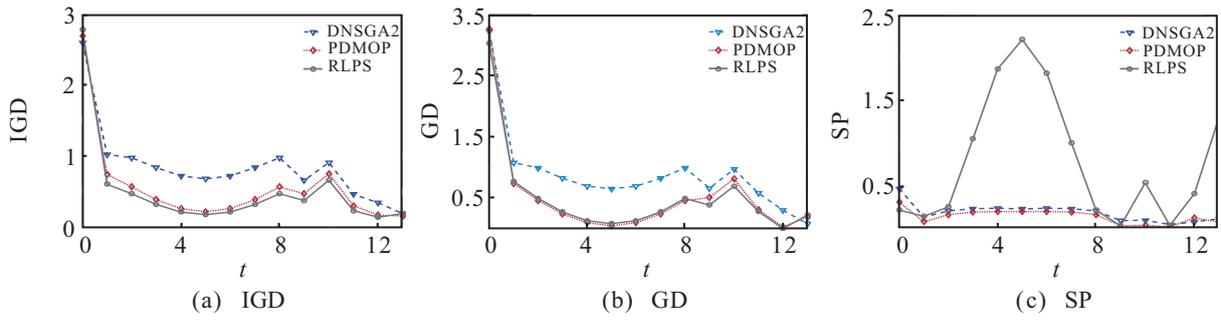


图 15 FDA5的性能指标

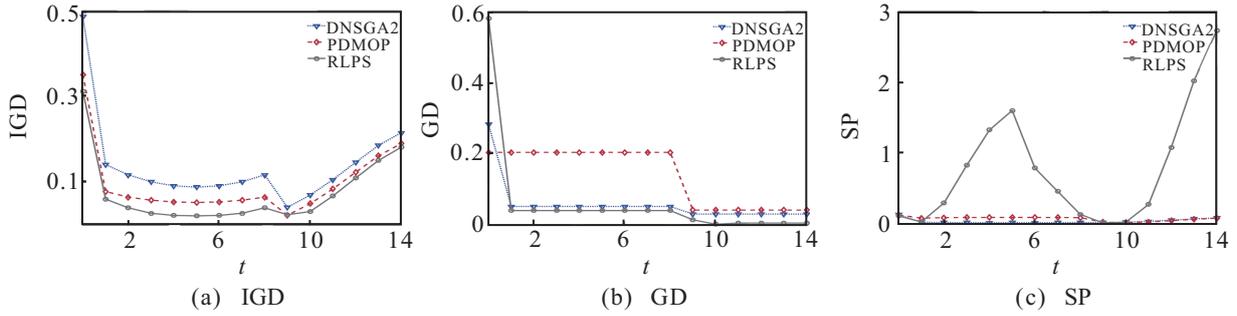


图 16 DMOP2的性能指标

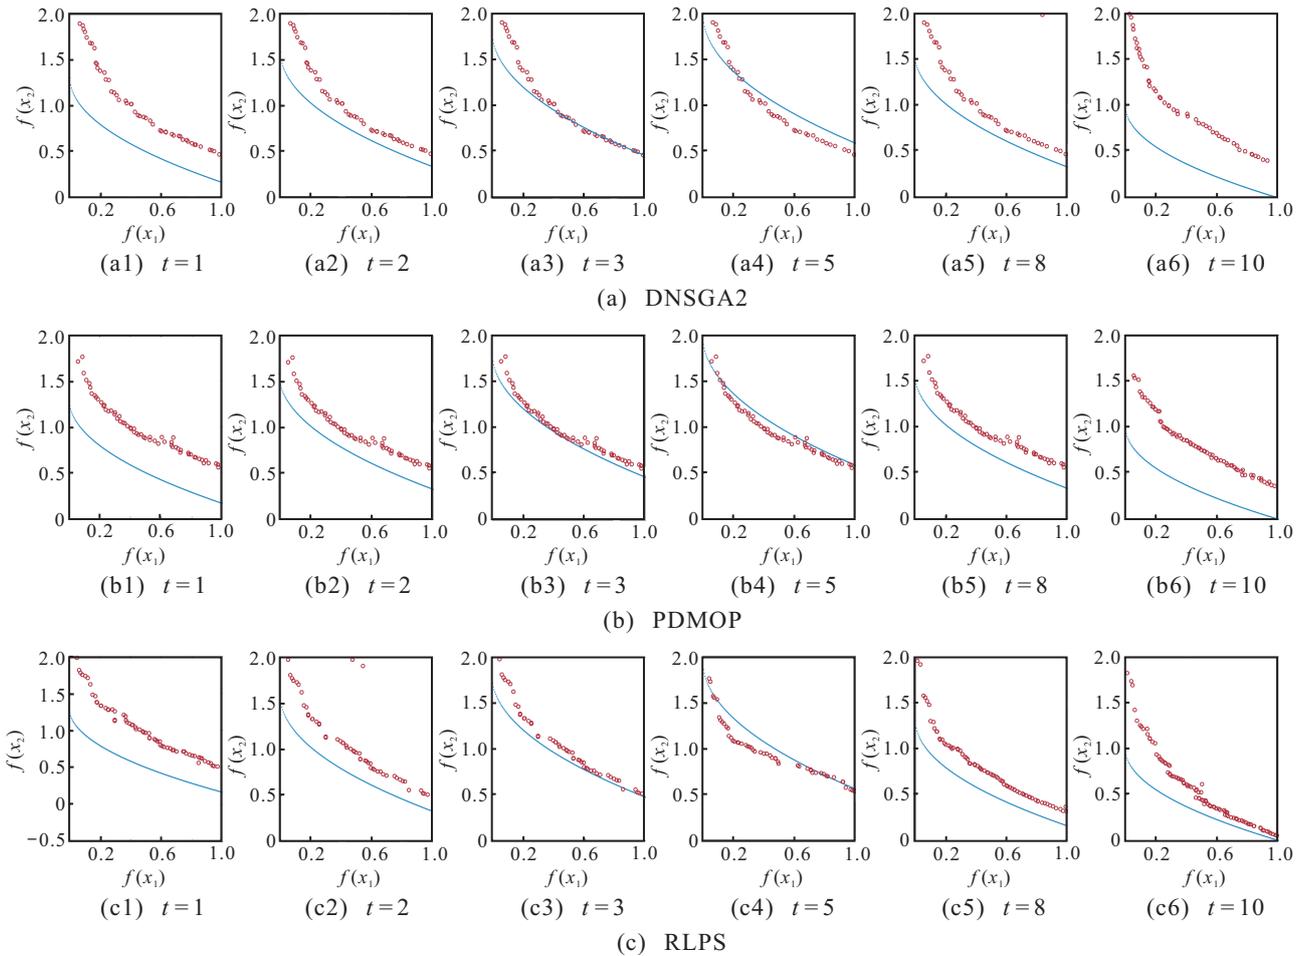


图 17 FDA3的解集分布图

离造成的整体指标数值不理想,但大部分个体的收敛趋势较好.对于周期性问题,到后期由于没有历史信息的累计,RLPS算法的性能相比PDMOP算法欠佳,但是对于环境变化前期和非周期性问题的,RLPS算法

表现出较好的性能.

综合分析,RLPS算法的大部分性能均优于其他算法,相比于其他算法可以更好地适用于非周期性第3类问题.

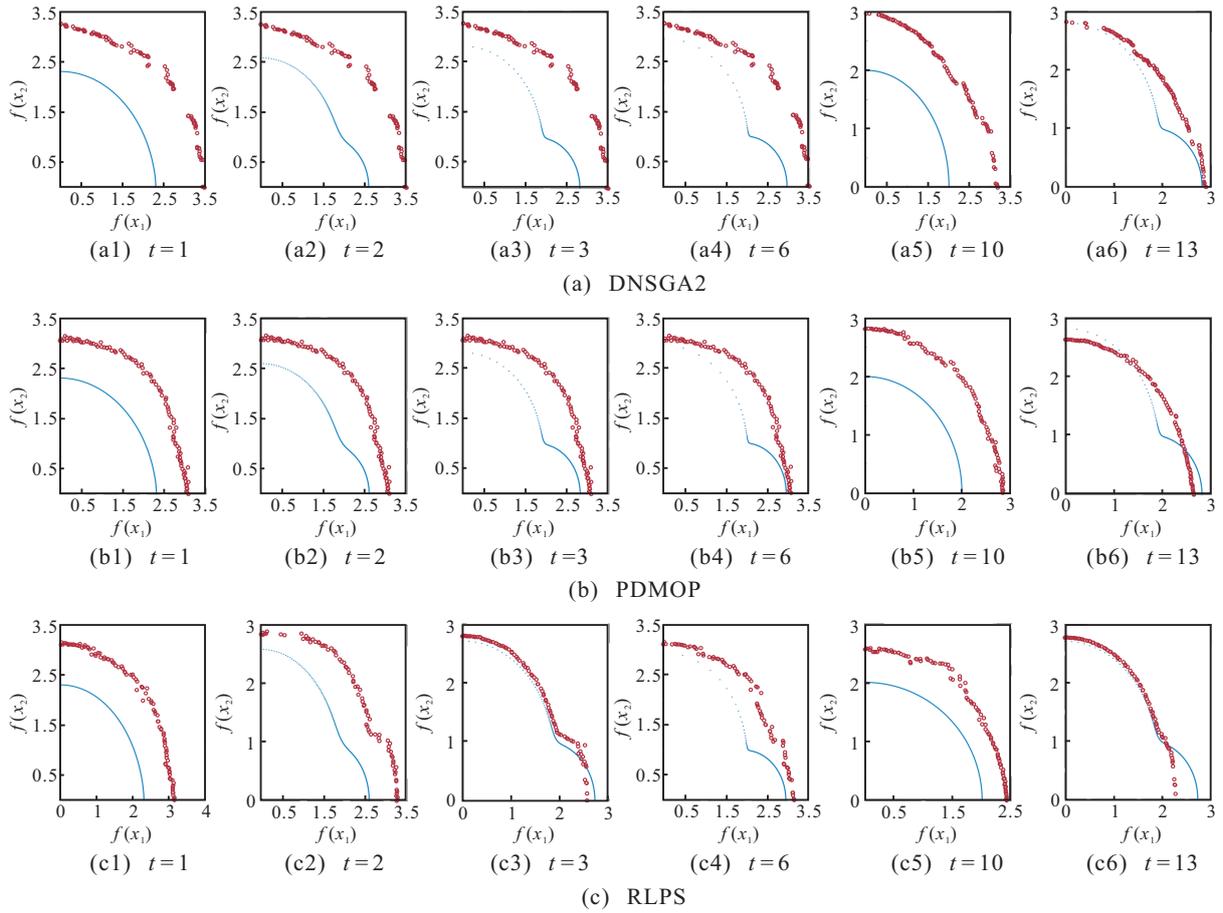


图 18 FDA5的解集分布图

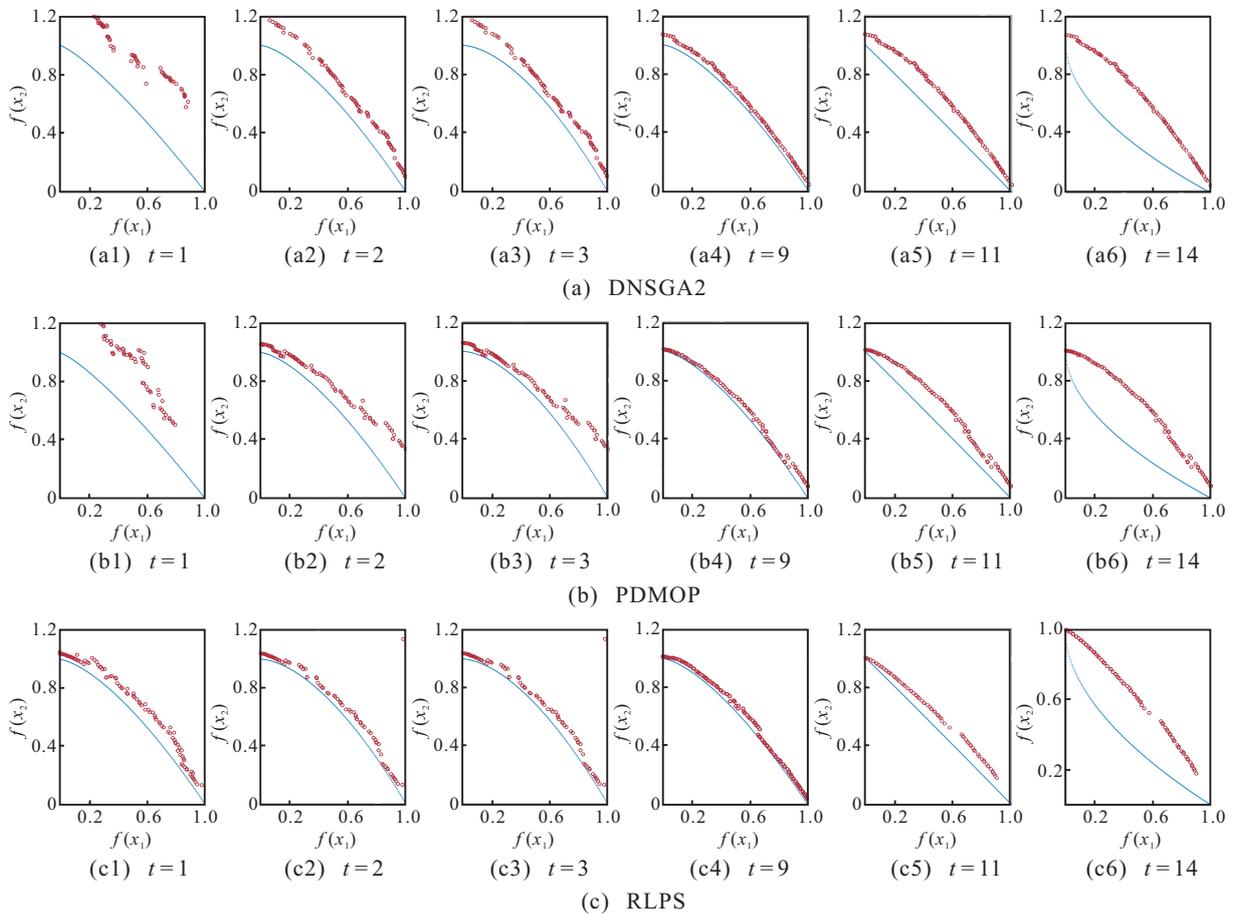


图 19 DMOP2的解集分布图

通过对3种算法的IGD、GD和SP性能指标的统计分析可知,本文提出的RLPS算法在环境变化前期有明显的优势,对非周期性问题具有更快的收敛速度、更好的收敛程度,在目标空间有均匀的分布性,有保持多样性的能力和对真实PF较广的覆盖性,适用于解决多种动态优化问题,更适用于解决非周期性问题。

#### 4 结论

针对动态多目标优化问题,本文提出了一种基于参考线的预测策略的动态多目标优化算法(RLPS),该算法不依靠历史信息的累计,更多适用于非周期性变化的动态问题。算法提出的预测个体进化方向的预测算子为预测新的最优PS提供了依据,将参考线与预测策略相结合,抵消了由于部分个体预测方向不准确带来的影响,引导个体加入加快了算法对环境响应的速度,结合个体与参考线的关联和选择机制,在FDA1、FDA4、FDA5、DMOP1和DMOP2五个标准动态测试函数上对该算法测试,并与DNSGA2和PDMOP两个现有算法作对比。实验结果表明,RLPS算法在获得好的分布性和收敛性的同时,具有更快的响应环境变化的能力,可以适用于多种动态问题,有很好的科研价值。此外,将该预测方法与依靠历史信息的方法相结合,可以更好地适应周期性变化的动态多目标问题。该预测方法目前除了适用于目标数参数变化类动态问题外,经过改进还可以适用于静态问题或者其他类型的动态问题,这些将是未来研究的重点。

#### 参考文献(References)

- [1] Guo Yi-nan, Cheng Jian, Luo Sha, et al. Robust dynamic multi-objective vehicle routing optimization method[J]. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 2018, 15(6): 1891-1903.
- [2] Farina M, Deb M, Amato P. Dynamic multi-objective optimization problems: Test cases, approximations, and applications[J]. IEEE Transactions on Evolutions Computation, 2004, 8(5): 425-442.
- [3] 郑金华. 多目标进化算法及应用[M]. 北京: 科学出版社, 2007: 12-38.  
(Zheng J H. Multiple objective evolutionary algorithms and its applications[M]. Beijing: Science Press, 2007: 12-38.)
- [4] Coello C A C, Lamont G B, Veldhuizen D A V. Evolutionary algorithms for solving multi-objective problems[M]. 2nd ed. New York: Kluwer Academic, 2002.
- [5] Deb K, Udaya B R N, Karthik S. Dynamic multi-objective optimization and decision—Making using modified NSGA-II: A case study on hydro-thermal power scheduling[C]. Evolutionary Multi-criterion Optimization. Berlin: Springer, 2007: 803-817.
- [6] Zhang Z. Multi-objective optimization immune algorithm in dynamic environments and its application to greenhouse control[J]. Applied Soft Computing, 2008, 8(2): 959-971.
- [7] Liu R, Zhang W, Jiao L, et al. A sphere-dominance based preference immune-inspired algorithm for dynamic multi-objective optimization[C]. Proceedings of Genetic and Evolutionary Computation Conference. Portland, 2010: 423-430.
- [8] Azevedo C R B, Araújo A F R. Generalized immigration schemes for dynamic evolutionary multi-objective optimization[C]. IEEE Congress on Evolutionary Computation. New Orleans, 2011: 2033-2040.
- [9] Wei J, Wang Y. Hyper rectangle search based particle swarm algorithm for dynamic constrained multi-objective optimization problems[C]. IEEE World Congress on Computational Intelligence. IEEE, 2012: 1-8.
- [10] Hatzakis I, Wallace D. Dynamic multi-objective optimization with evolutionary algorithms: A forward-looking approach[C]. Conference on Genetic and Evolutionary Computation. New York, 2006: 1201-1208.
- [11] Zhou A, Jin Y, Zhang Q. A population prediction strategy for evolutionary dynamic multi-objective optimization[J]. IEEE Transactions on Cybernetics, 2013, 44(1): 40-53.
- [12] 郑金华, 彭舟, 邹娟, 等. 基于引导个体的预测策略求解动态多目标优化问题[J]. 电子学报, 2015, 43(9): 1816-1825.  
(Zheng J H, Peng Z, Zou J, et al. A prediction strategy based on guide-individual for dynamic multi-objective optimization[J]. Acta Electronica Sinica, 2015, 43(9): 1816-1825.)
- [13] 陈美蓉, 郭一楠, 杨振, 等. 一类新型动态多目标鲁棒进化优化方法[J]. 自动化学报, 2017, 43(11): 2014-2032.  
(Chen M R, Guo Y N, Yang Z, et al. A novel dynamic multi-objective robust evolutionary optimization method[J]. Acta Automatica Sinica, 2017, 43(11): 2014-2032.)
- [14] 丁进良, 杨翠娥, 陈立鹏, 等. 基于参考点预测的动态多目标优化算法[J]. 自动化学报, 2017, 43(2): 313-320.  
(Ding J L, Yang C E, Chen L P, et al. Dynamic multi-objective optimization algorithm based on reference point prediction[J]. Acta Automatica Sinica, 2017, 43(2): 313-320.)

[15] 刁鹏飞, 毕晓君, 王艳娇. 基于分解技术的动态多目标引力搜索算法[J]. 系统工程理论与实践, 2018, 38(5): 1300-1309.  
(Diao P F, Bi X J, Wang Y J. Dynamic multi-objective gravitational searching algorithm based on decomposition[J]. System Engineering—Theory & Practice, 2018, 38(5): 1300-1309.)

[16] Li Q, Zou J, Yang S, et al. A predictive strategy based on special points for evolutionary dynamic multi-objective optimization[J]. Soft Computing, 2018(1): 1-17.

[17] Xu B, Zhang Y, Gong D, et al. Environment sensitivity-based cooperative co-evolutionary algorithms for dynamic multi-objective optimization[J]. IEEE/ACM Transactions Comput Biol Bioinform, 2017(99): 1-1.

[18] Goh C K, Tan K C. A competitive-cooperative evolutionary paradigm for dynamic multi-objective optimization[J]. IEEE Transactions on Evolutionary Computation, 2009, 13(1): 103-127.

[19] Farina M, Deb K, Amato P. Dynamic multi-objective optimization problems: Test cases, approximations, and applications[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(5): 425-442.

[20] Cheng R, Jin Y, Narukawa K, et al. A multi-objective evolutionary algorithm using gaussian process-based inverse modeling[J]. IEEE Transactions on Evolutionary Computation, 2015, 19(6): 838-856.

[21] Jiang S, Yang S. A steady-state and generational evolutionary algorithm for dynamic multi-objective optimization[J]. IEEE Transactions on Evolutionary Computation, 2017, 21(1): 65-82.

[22] Van Veldhuizen D A V, Lamont G B. On measuring multi-objective evolutionary algorithm performance[C]. Proceedings of the Congress on Evolutionary Computation. La Jolla, 2002: 204-211.

作者简介

李二超(1980—), 男, 教授, 博士生导师, 从事人工智能、进化计算等研究, E-mail: lecstarr@163.com;

赵雨萌(1995—), 女, 硕士生, 从事动态多目标优化的研究, E-mail: 1097926993@qq.com.

(责任编辑: 孙艺红)

下 期 要 目

基于阈值搜索的多目标人工蜂群算法 . . . . . 赵新秋, 等

一种融合信任和项目卷积描述信息的PMF算法 . . . . . 王建芳, 等

求解电力系统经济调度问题的改进粒子群优化算法 . . . . . 梁 静, 等

基于矩阵李群表示及容积卡尔曼滤波的视觉惯导里程计新方法 . . . . . 闫德立, 等

空间机器人基于比例因子识别的自校正反馈神经网络容错算法设计 . . . . . 雷荣华, 等

带有随机测量数据丢失及切换拓扑的传感器网络分布式 $l_2$ - $l_\infty$ 滤波器设计 . . . . . 朱凤增, 等

基尼指数成本量指导的抗遮挡光场深度估计方法 . . . . . 张旭东, 等

融合可信性评价的Web服务组合QoS优化 . . . . . 韩 敏, 等

动态加权非参数判别分析 . . . . . 高云龙, 等

基于焊件识别与位姿估计的焊接机器人视觉引导 . . . . . 王 斐, 等

基于LNS-DEWKECA算法的多模态工业过程故障检测 . . . . . 顾幸生, 等

基于深度残差生成式对抗网络的样本生成方法 . . . . . 王 星, 等

信息物理环境下不确定系统的随机分布式预测控制 . . . . . 杨晓峰, 等

机载光电稳瞄平台的扰动观测分数阶控制方法 . . . . . 王春阳, 等

基于多模型假设检验的认知无线频谱感知方法 . . . . . 刘 宝, 等

基于改进电子搜索算法的梯级水库联合发电优化调度 . . . . . 王丽萍, 等

考虑随机不确定性的常态仿真模型确认试验设计 . . . . . 锁 斌, 等

基于暗通道先验的自适应超像素去雾算法 . . . . . 安 冬, 等