

基于引导个体的预测策略求解 动态多目标优化问题

郑金华^{1,2}, 彭舟^{1,2}, 邹娟^{1,2}, 申瑞珉^{1,2}

(1.湘潭大学信息工程学院, 湖南湘潭 411105; 2.智能计算与信息处理教育部重点实验室, 湖南湘潭 411105)

摘要: 很多现实的优化问题都是动态多目标问题,这类问题不仅具有多个目标,并且也受环境的影响不断变化.本文基于引导个体的预测策略提出一种新的求解动态多目标优化问题的策略.通过记录每次环境变化初始时和种群自主进化一小段时间后种群中心点位置的前后变化,预测最优解的所在方向.同时根据在该方向上均匀分布的若干检测个体,选出一串非支配的个体作为当前环境下的引导个体.为了避免陷入局部最优,在选出的引导个体周围一个小的区域半径内随机产生若干伴随引导个体.实验结果表明,新策略具有更快的响应环境变化的能力.

关键词: 动态多目标优化; 进化算法; 预测; 引导个体

中图分类号: **文献标识码:** A **文章编号:** 0372-2112 (2015)09-1816-10

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2015.09.021

A Prediction Strategy Based on Guide-Individual for Dynamic Multi-Objective Optimization

ZHENG Jin-hua^{1,2}, PENG Zhou^{1,2}, ZOU Juan^{1,2}, SHEN Rui-min^{1,2}

(1. Institute of Information Engineering, Xiangtan University, Xiangtan, Hunan 411105, China;

Key Laboratory of Intelligent Computing and Information Processing, Ministry of Education, Xiangtan, Hunan 411105, China)

Abstract: Many real-world problems are dynamic multi-objective optimization problem. This kind of problem has multiple objectives, and these objectives change constantly due to the influence of environment. In this paper, a prediction strategy based on guide-individual (GIPS) is proposed. When environment changes, by recording the different center positions between populations in the initial environment and the ones evolving independently after a short time, GIPS predicts the direction of the optimal solutions. Moreover, from uniformly distributed individuals detected in the prediction direction, GIPS selects a bunch of non-dominated individuals as the guide-individuals for the current environment. In addition, the proposed strategy randomly generates a number of associated guide-individuals within a small area in order to avoid population to be trapped into local optimum. Compared with two state-of-the-art prediction-based dynamic multi-objective optimization algorithms, GIPS show faster response to the environmental changes.

Key words: dynamic multi-objective optimization; evolutionary algorithms; prediction; guide-individual

1 引言

动态多目标优化问题 (Dynamic Multi-objective Optimization Problems, DMOPs) 广泛地存在现实生活中, 多个目标之间相互冲突, 同时目标函数随着时间的变化而改变^[1]. 面对一个复杂动态变化的系统, 静态优化方法具有明显的局限性. 在这些问题中, 研究目标是复杂变化的, 传统进化算法的目标是使种群逐渐收敛, 最终获得一个满意的解集, 而这样就会使种群失去多样性, 尤其

到了进化后期, 种群会逐渐失去对环境变化的适应能力, 这是传统进化算法在动态环境中所面临的挑战^[2,3]. 为了及时地追踪到变化后的 Pareto 最优解, 需要在传统的静态多目标算法^[4,5]上做调整, 使其能快速地响应环境的变化.

近些年来, 研究人员在遗传算法、人工免疫算法、协同进化算法、粒子群算法、膜计算等自然计算方法的基础上, 提出了适应 DMOPs 的动态多目标优化算法^[6~12], 这些方法大多集中在保持种群多样性和采用多种群策

略上.然而这些方法在解决 DMOPs 上有些许盲目性,因为种群的多样性保持之后还是靠种群的自主进化能力去寻找最优解,收敛速度是其主要问题.如何针对变化后的目标,为种群进化提供一定的引导方向,对于提高算法的收敛速度和收敛性有着至关重要的作用.

为此,一些学者提出了引入记忆策略^[13-16]和基于预测的方法^[17-19]来解决这一问题.其中记忆策略通过记忆复用以前搜索到的最优解来对新的环境变化做出快速响应,这对于周期性变化的问题能取得不错的效果,而对于非周期性变化的问题或者在第一个周期变化的环境下,种群仍处在盲目进化过程中,算法难以获得较好的收敛性.基于预测的方法,每次环境变化之后,通过预测策略,为种群进化提供引导方向,帮助算法对新变化做出快速响应,预测的准确性是其最主要的难点.至今为止基于预测的方法在 DMOPs 中鲜有深入研究.2006 年 Hatzakis 和 Wallace 提出了一种向前预测策略(Feed-for-ward Prediction Strategy, FPS)^[17],2013 年 Zhou 和 Jin 等人提出了一种种群预测策略(Population Prediction Strategy, PPS)^[19].这些算法都采用预测的方法来解决 DMOPs,取得了一定的效果,但也各自存在一定的缺陷,如 FPS 单纯地采用自回归模型使得预测不够准确,PPS 在环境刚开始变化阶段由于历史信息积累不足导致收敛性较差.

针对以上问题,本文提出一种基于引导个体的预测策略(Prediction Strategy based on Guide-Individual, GIPS).其主要学术贡献表现在:

(1)提出了一种预测种群进化方向的判断算子,在不需要历史信息积累的前提下为预测最优解的所在方向提供依据.

(2)设计了一种引导个体的产生机制,产生的引导个体作为预测的最优解,从而加速种群收敛.

(3)提出了一种伴随个体产生策略,增加了种群的多样性,避免种群陷入局部最优.

本文针对 FDA 系列^[1]和 DMOP 系列^[14]中七个经典的线性测试问题,及 F5~F9 五个新的非线性测试问题^[19],将算法与 FPS 和 PPS 进行比较,实验结果表明,GIPS 比这两种预测策略有更快的响应动态环境变化的性能.

2 动态多目标问题相关概念

不失一般性,以最小化多目标问题为研究对象,一个具有 n 个决策变量, m 个目标函数的动态多目标优化问题可以描述为^[1]:

$$\begin{cases} \min_{x \in \Omega} F(x, t) = (f_1(x, t), f_2(x, t), \dots, f_m(x, t))^T \\ g_i(x, t) \leq 0, i = 1, 2, \dots, p; h_j(x, t) = 0, j = 1, 2, \dots, q \end{cases}$$

其中 t 为时间变量, $x = (x_1, x_2, \dots, x_n)$ 为 n 维决策变

量,其定义域为 Ω , $F = (f_1, f_2, \dots, f_m)$ 为 m 维最小化问题的目标向量, $g_i \leq 0, i = 1, 2, \dots, p$ 为 p 个不等式约束, $h_j = 0, j = 1, 2, \dots, q$ 为 q 个等式约束.

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 $f_i(p) \leq f_i(q), \forall i = \{1, 2, \dots, m\}$ 且 $\exists j \in \{1, 2, \dots, m\}$ 满足 $f_j(p) < f_j(q)$.

定义 2 (Pareto 最优解集(PS)) 设 x 为决策变量, Ω 为决策空间, F 为目标函数, 则 PS^[5] 定义为:

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

定义 3 (Pareto 最优前沿(PF)) 设 x 为决策变量, F 为目标函数, 则 PF^[5] 定义为:

$$PF = \{y = F(x) \mid x \in PS\}$$

3 相关工作

3.1 动态多目标进化算法的一般步骤

动态多目标进化算法一般分为以下几个步骤:

步骤 1 初始化种群, 设置相关参数;

步骤 2 优化算法, 本文将采用 2.2 介绍的 RM-MEDA 算法对种群进行优化.

步骤 3 检测环境变化, 若检测到环境发生改变, 则调用相关处理策略来响应环境变化; 否则, 继续执行优化算法.

步骤 4 响应环境变化的处理策略, 能对环境的变化做出快速并且正确的响应, 使得种群能较快地收敛到新的最优解集. 一般的处理策略有以下几种: 重新初始化种群, 参数调整, 动态迁移, 记忆, 预测等.

步骤 5 终止判断条件.

3.2 RM-MEDA

在宽松的条件下, Karush-Kuhn-Tucker 准则表明, 一个连续 m 个目标的多目标优化问题的 PS 是一个分段连续的 $m-1$ 维流形. 因此, 在 EDA^[20] 的基础上, 结合连续多目标问题的解集分布特征, 2008 年 Zhang 和 Zhou 等人提出了一种基于规则模型的多目标分布估计算法(RM-MEDA)^[21]. 因为随着算法搜索的进行, 种群会逐渐向 PS 逼近, 并均匀地分散在 PS 周围. 所以, RM-MEDA 的核心思想是: 对获得的解聚类, 然后建立概率模型得到分段的流形, 从而分段逼近整个非线性的 PS 流形, 最终通过采样得到新的后代种群.

RM-MEDA 能充分利用当前种群提供的全局信息来产生新个体, 而不需要直接使用种群的局部信息, 具有较强的启发式寻优能力, 尤其对于求解决策变量线性相关的多目标问题, RM-MEDA 能表现出更好的性能^[21].

3.3 基于预测策略的动态多目标进化算法的性能分析
基于预测的方法是解决 DMOPs 的有效方法之一,

通过预测,确定下一次环境变化下的新种群,能加速算法收敛到新的最优解.本文主要对两种有代表性的预测策略进行对比分析,在此基础上提出一种新的预测策略求解 DMOPs.

(1) 向前预测策略(FPS)

FPS^[17]记录目标空间相邻历史 PF 上的边界点信息,通过自回归模型(AR)预测环境变化后 PS 的位置. FPS 中初始种群由三部分构成:环境变化前的非支配解集、被支配的解集以及预测的解集.非支配解集使算法更有利于处理 PS 不随时间改变的 DMOPs,而被支配的解集保持了种群的多样性,使算法能搜索到新的最优解.

(2) 种群预测策略(PPS)

在 PPS^[19]中,最优解集被分成两部分:种群中心点和形状.通过保存一个连续时间序列上种群中心点的位置,采用单元自回归模型(AR)预测下一时刻新的种群中心点.同时,通过记录最近两个时刻种群的形状预测下一时刻新的种群分布.这两部分就构成了环境变化后新的初始种群.

对比这两种策略, FPS 只预测产生一小部分的新种群,其大部分的种群是继承的环境变化前的最终种群; PPS 预测产生整个新种群,而不是仅仅预测几个初始个体.随着算法的运行, PPS 积累的历史信息增加,预测的准确性提高.因此,对于前几次环境变化,由于历史信息积累不足, PPS 的性能较 FPS 差,而对于后几次的环境变化,经验的积累使得 PPS 的性能趋于稳定,优于 FPS^[19].

因此,设计一种预测策略,既不需要历史信息的积累,加快算法在前几次环境变化中的收敛速度,而且其预测的准确性又相对较高,这是本文的研究重点.

4 基于引导个体的预测策略

为了解决动态多目标优化问题中不能快速响应环境的变化,及时地搜索到新的最优解集的问题,本文提出一种基于引导个体的预测策略,包括(1)预测种群进化方向的判断算子;(2)引导个体的产生机制;(3)避免陷入局部最优的伴随个体产生策略等三个方面.根据种群自主的进化能力对进化方向进行判断,在不需要历史信息积累的前提下,使种群能快速地响应环境的变化.在该预测方向上分布并选择产生出一定数量的引导个体,作为预测的最优解,加速了种群的收敛.而伴随个体的产生增加了种群的多样性,避免其陷入局部最优.算法的总体设计如图 1 所示.

从图 1 可以看到,对于上一时刻最终进化状态的种群 $Population_{t-1}$, 和环境变化后该种群自主进化 Δt 时间后的新种群 $Population_{t-1} + \Delta t$, 这两个不同时刻的种群的中心点位置之间的连线方向代表预测的种群进化方

向,根据这个预测方向,从当前种群到决策空间的边界之间均匀分布一定数量的检测个体,即对应图中的 Detecting individual.对这些检测个体进行一次非支配排序后,选出相对较优的若干检测个体作为当前环境下的引导个体,即对应图中 PS_t 附近的 Detecting individual.接着,为了加强局部搜索,避免陷入局部最优,在选出来的引导个体周围随机产生伴随引导个体,即对应图中的 Associated guide-individual.最后,对获得的引导个体和伴随引导个体进行一次非支配排序,选出满足一定数量的最终引导个体,即对应图中用虚线连接的最接近 PS_t 的个体.




图1 GIPS的设计原理

4.1 预测种群进化方向的判断算子

每当环境变化时,种群会自发地向着新的 Pareto 最优解的方向进化,因此利用这一特点,在环境变化产生的初始阶段,让种群自主地进化一小段时间,通过记录种群中心点位置的前后变化,判断出种群在当前环境下的进化方向.预测种群进化方向的判断算子定义如下:

$$\begin{aligned} \partial &= (\partial_1, \dots, \partial_i, \dots, \partial_n) \\ &= (C_1^{t+\Delta t} - C_1^t, \dots, C_i^{t+\Delta t} - C_i^t, \dots, C_n^{t+\Delta t} - C_n^t) \end{aligned} \quad (1)$$

其中 ∂ 表示种群在决策空间中的进化方向向量, C^t 为 t 时刻种群中心点的位置, $C^{t+\Delta t}$ 为 t 时刻种群进化 Δt 时间后新种群中心点的位置, $i = 1, 2, \dots, n$, n 为决策空间的维数.根据式(2)可以得出种群在决策空间中每一维的进化方向.

为了更准确地定义式(1)中种群中心点的位置,本文令 $P^t = \{x^t\}$ 为 t 时刻的进化种群,那么种群中心点的位置可以用式(2)表示:

$$C_i^t = \frac{1}{|P^t|} \sum_{x_i^t \in P^t} x_i^t \quad (2)$$

其中 $|P^t|$ 是种群大小, x_i^t 是 t 时刻个体 x^t 的第 i 维坐标, $i = 1, 2, \dots, n$. 通过计算决策空间每一维中心点位置的前后变化, 判断出种群进化方向, 将结果用一组向量表示, 向前为正, 向后为负.

4.2 引导个体的产生机制

种群进化方向的判断为预测 Pareto 最优解集的位置提供了一个预测依据, 为了更加准确地预测出 Pareto 最优解的位置, 需要得到此方向上的一串最优个体作为预测的引导个体并存入当前种群, 从而加速种群收敛. 首先在种群的决策空间中, 根据种群每一维的最大值和最小值将其均匀等分, 这样可以在当前种群范围内均匀地得到一定数量的初始个体. 然后从初始个体位置到决策空间边界, 以式(1)为方向, 每隔一段同等距离分布一串检测个体. 最后通过一次非支配排序选出 ObSize 个最优个体作为当前环境下的引导个体. 引导个体产生机制的主要步骤见算法 1.

算法 1 引导个体的产生机制

步骤 1 计算种群在决策空间每一维的最大值 \max_i 和最小值 \min_i , 其中 $i = 1, 2, \dots, n$.

步骤 2 根据最大值和最小值将种群在决策空间中的每一维分量分成均匀的 OP 份, 得到 OP 个初始个体, OP 个初始个体的值描述为:

$$Ob_i^j = \min_i + \frac{\max_i - \min_i}{OP} * (j - 1) \quad (3)$$

$$j = 1, 2, \dots, OP$$

步骤 3 根据式(1)所得方向向量 ∂ , 若为正, 则将从决策空间第 i 维的边界最大值到初始个体的距离等分成 OB 份; 若为负, 则将从第 i 维的边界最小值到初始个体的距离等分成 OB 份. 得到的 $OB * (OP - 1)$ 个检测个体表示如下:

$$Ob_i^{k * OP + j} = \begin{cases} Ob_i^j + \frac{Up_i - Ob_i^j}{OB} * k, & \text{if } \partial_i > 0 \\ Ob_i^j - \frac{Ob_i^j - Low_i}{OB} * k, & \text{if } \partial_i < 0 \end{cases}$$

$$j = 1, 2, \dots, OP, k = 1, 2, \dots, OB - 1 \quad (4)$$

其中 Up_i 为决策空间第 i 维的边界最大值, Low_i 为第 i 维的边界最小值.

步骤 4 对获得的 $OB * OP$ 个检测个体进行非支配排序, 选择出 ObSize 个最优个体作为当前时刻的引导个体.

4.3 避免陷入局部最优的伴随个体产生策略

为了增加种群的多样性, 避免由于引导个体的引导而使算法陷入局部最优, 算法在 ObSize 个引导个体周围, 半径为 r 的区域内随机产生 $4 * ObSize$ 个伴随个体, 表示如下:

$$Ob_i^{j * ObSize + k} = Ob_i^j + \text{random}(-r, r) \quad (5)$$

$$j = 1, 2, 3, 4, k = 1, 2, \dots, ObSize$$

对获得的 ObSize 个引导个体及 $4 * ObSize$ 个伴随

个体进行非支配排序, 选择出 $2 * ObSize$ 个相对最优子个体作为最终的引导个体.

4.4 GIPS 算法详细描述

GIPS 在 DMOEA 的总体框架下进行迭代, 目的是得到每次环境变化后的新的初始种群, 使新的种群能快速地响应环境的变化并进行跟踪. GIPS 算法的详细描述见算法 2.

算法 2 基于引导个体的预测算法

初始化. $t := 0$; 随机初始化种群 P_0 ; 迭代次数计数器 $g_t := 0$; 算法总进化代数 g_{\max} .

步骤 1 检测环境变化, 如果环境没有变化, 转步骤 7; 否则利用式(2)计算当前种群每一维的中心位置 C_i^t .

步骤 2 种群自主进化 Δt 时间, 计算进化后的种群每一维的中心位置 $C_i^{t+\Delta t}$, $g_t := g_t + \Delta t$;

步骤 3 根据算法 1 产生 ObSize 个引导个体 Ob_i^j , $i = 1, 2, \dots, ObSize$.

步骤 4 利用式(5)产生伴随个体, 并对产生的伴随个体及引导个体进行非支配排序, 选择出 $2 * ObSize$ 个最终引导个体 Ob_i^j , $i = 1, 2, \dots, 2 * ObSize$.

步骤 5 对产生的引导个体进行边界检测:
如果 $Ob_i^j(x_j) > Up_j$, 则 $Ob_i^j(x_j) = Up_j - \text{random}(0, \Delta r)$;
如果 $Ob_i^j(x_j) < Low_j$, 则 $Ob_i^j(x_j) = Low_j + \text{random}(0, \Delta r)$,
 Δr 为一个很小的区域半径值.

步骤 6 将得到的最终引导个体 Ob_i^j 随机替换掉当前种群 P_t 中的 $2 * ObSize$ 个个体, 最后得到种群大小为 PopSize 的新种群 P_{t+1} .

步骤 7 用 RM-MEDA 对种群进行优化.

步骤 8 如果 $g_t > g_{\max}$, 则输出 P_t 并终止; 否则 $g_t := g_t + 1$, 转步骤 1.

5 测试问题及评价指标

5.1 测试问题

本文采用七个 FDA 系列^[1]和 DMOP 系列^[14]传统问题以及五个新的 F5 ~ F9 系列问题^[19]作为测试问题. 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. 而 F5 ~ F9 系列问题是文献[19]提出的新的一组测试问题, 决策变量之间是非线性相关的, 其中对于 F9, PS 有几次比较大的变化, 将从一个区域跳转到另一个区域, 收敛难度较高.

5.2 评价指标

采用动态的逆世代距离 DIGD^[19,21,22], 作为动态多目标进化算法的性能评价指标. DIGD 评价算法的收敛性和分布性, DIGD 值越小, 表示算法所求解集的收敛性和分布性越好.

6 对比试验

6.1 参数设置

记本文的预测策略为 GIPS, 用于比较的其他两种预测策略分别为前馈预测策略(FPS)^[17]和种群预测策

略(PPS)^[19],三种策略均采用2.2小节提到的RM-MEDA优化算法,GIPS的引导个体个数(ObSize)设定为10,为了减少产生检测个体的计算消耗,本文将每一维分量均匀等分的份数(OP)和预测距离等分的份数(OB)均设定为10,即检测个体总个数与两目标优化问题的种群大小相一致.自主进化时间(Δt)设定为2,局部搜索产生伴随个体的区域半径(r)设定为0.05,环境变化频率(τ_T)设定为25,变化程度(n_T)设定为10,其他两种策略的参数设置及公共参数的设置采用文献[19]中给出的设定.

对每个问题做20次独立实验,每次实验,每种策略跟踪100次环境变化,每次运行的总进化代数为2500代.除去第一次环境变化,将实验结果划分成三个阶段.

6.2 性能评价的统计结果对比

6.2.1 在FDA和DMOP问题上的实验结果分析

表1是三种策略求解FDA及DMOP系列问题时所获得的DIGD性能评价指标的结果,该表显示:

(1)对于决策空间变量线性相关的测试问题,GIPS得到的DIGD的均值均小于FPS和PPS,在三个阶段的指标都比较平均.除了FDA2和DMOP1这两个PS不变的测试问题,在其他测试问题上,GIPS在每个阶段的DIGD指标均好于FPS.

(2)在后两个阶段上,PPS的DIGD指标比较平均,较GIPS略好,但总体来说,指标相差不大,且在FDA2,FDA3,DMOP1这三个测试问题上,GIPS表现出了更好的性能.

(3)在三维的测试问题FDA4上,GIPS每个阶段的DIGD均值均要好于FPS和PPS.

之所以出现这样的结果,究其原因,主要因为GIPS不需要经验的积累,加之引导个体的引入,使其能更快地响应环境的变化,所以GIPS在第一阶段的收敛性极大地好于PPS.同时每次环境变化,引导个体为种群进化提供了明确的方向,相对于FPS采用AR预测模型来说,GIPS的预测更为准确.而对于PS不变的问题,种群的多样性反而会阻碍种群的快速收敛.所以除了FDA2和DMOP1这两个PS不变的测试问题,在其他测试问题上,GIPS在每个阶段的收敛性均好于FPS.

其次,由于环境的周期变化及经验的积累,PPS在后两个阶段的收敛性和分布性将趋于稳定,所以较GIPS略好,但总体来说,相差不大.而对于FDA3这个测试问题,PPS积累的经验还不足以做出准确的预测,需要更多次的算法迭代,所以GIPS在FDA3问题上的每个阶段的平均性能指标都要好于PPS.

对于三维的测试问题FDA4,FPS和PPS的性能表

现差别不大,而GIPS在每个阶段的性能指标均好于FPS和PPS,说明基于引导个体的预测策略更适合高维的动态多目标问题.

表1 三种策略在FDA和DMOP上的DIGD指标

Problems	Statistic	FPS	PPS	GIPS
FDA1	Mean	0.0292	0.0313	0.0116
	1 st stage	0.0601	0.0812	0.0110
	2 nd stage	0.0131	0.0064	0.0111
	3 rd stage	0.0145	0.0063	0.0127
FDA2	Mean	0.0084	0.0100	0.0081
	1 st stage	0.0140	0.0177	0.0130
	2 nd stage	0.0057	0.0065	0.0057
	3 rd stage	0.0056	0.0059	0.0056
FDA3	Mean	0.0416	0.0528	0.0096
	1 st stage	0.0645	0.1016	0.0104
	2 nd stage	0.0218	0.0243	0.0075
	3 rd stage	0.0385	0.0326	0.0110
FDA4	Mean	0.0950	0.0881	0.0703
	1 st stage	0.1011	0.0909	0.0696
	2 nd stage	0.0890	0.0869	0.0691
	3 rd stage	0.0952	0.0865	0.0723
DMOP1	Mean	0.0053	0.0080	0.0049
	1 st stage	0.0073	0.0127	0.0052
	2 nd stage	0.0042	0.0058	0.0047
	3 rd stage	0.0045	0.0056	0.0048
DMOP2	Mean	0.0501	0.0545	0.0152
	1 st stage	0.1165	0.1512	0.0160
	2 nd stage	0.0171	0.0063	0.0143
	3 rd stage	0.0169	0.0061	0.0153
DMOP3	Mean	0.0319	0.0347	0.0123
	1 st stage	0.0689	0.0918	0.0132
	2 nd stage	0.0137	0.0065	0.0106
	3 rd stage	0.0133	0.0062	0.0131

6.2.2 在F5~F8问题上的实验结果分析

表2是三种策略求解F5~F8系列问题时所获得的DIGD性能评价指标的结果,同样也可用上节5.2.1中的原因进行解释,对于决策空间变量非线性相关的测试问题,三种策略总体的性能较在FDA和DMOP系列测试问题上表现略差,说明非线性相关的测试问题收敛难度更大,对预测的准确性要求更高.其中,FPS的收敛性最差,PPS在环境变化后期收敛性慢慢趋于稳定,GIPS在环境变化开始阶段就能快速地跟踪PF,且平均性能好于PPS.

6.2.3 在复杂问题F9上的实验结果分析

表3是三种策略求解复杂问题F9时所获得的DIGD性能评价指标的结果,同上面的实验结果一样,在复杂问题上,GIPS也表现出了比较稳定的收敛性和分布性.

表 2 三种策略在 F5 ~ F8 上的 DIGD 指标

Problems	Statistic	FPS	PPS	GIPS
F5	Mean	0.0896	0.0809	0.0204
	1 st stage	0.1241	0.2090	0.0238
	2 nd stage	0.0696	0.0199	0.0195
	3 rd stage	0.0751	0.0143	0.0180
F6	Mean	0.0380	0.0357	0.0199
	1 st stage	0.0529	0.0797	0.0214
	2 nd stage	0.0310	0.0151	0.0219
	3 rd stage	0.0302	0.0123	0.0165
F7	Mean	0.0399	0.0531	0.0124
	1 st stage	0.0438	0.1326	0.0127
	2 nd stage	0.0359	0.0140	0.0118
	3 rd stage	0.0402	0.0127	0.0127
F8	Mean	0.2093	0.4011	0.1082
	1 st stage	0.3508	0.4611	0.1178
	2 nd stage	0.1233	0.3715	0.0998
	3 rd stage	0.1538	0.3709	0.1073

6.3 获得的解集分布图对比

为了直观地分析各种策略的性能,本文选取 FDA1、DMOP2、F5、F6 及 F9 这五个比较有代表性的测试问题,绘出三种策略在不同时刻求解不同测试问题所获得的解集分布图,如图 2 ~ 图 6 所示,纵横坐标分别代表所获解集在每个目标上的取值,红色圆点为所获解集,蓝

色曲线为 Pareto 最优前沿.

表 3 三种策略在 F9 上的 DIGD 指标

Problems	Statistic	FPS	PPS	GIPS
F9	Mean	0.1387	0.2219	0.0893
	1 st stage	0.2085	0.5205	0.0953
	2 nd stage	0.0910	0.0702	0.0939
	3 rd stage	0.1166	0.0751	0.0788

通过对比,不难得出与上文 5.2 中相同的结论,对于环境一开始的几次变化,GIPS 的收敛性和分布性要远远优于 FPS 和 PPS,说明 GIPS 能更快更准确地响应环境变化.而到了算法运行后期,对于环境的后几次变化,GIPS 同 PPS 一样具有比较好的收敛性和分布性,且略好于 FPS.在处理复杂问题 F9 的能力上,GIPS 的优势就更为直观,无论 FPS 还是 PPS 都不能获得较好的收敛性和分布性,而 GIPS 在某几次环境变化上能较为准确地跟踪到新的最优解,得到其收敛性较好、分布均匀的 Pareto 最优解集.

6.4 运行时间的对比

本文选取 FDA1、FDA4、F5 及 F9 这四个比较有代表性的测试问题,跟踪 100 次环境变化.实验硬件为 Intel Core i3 3.40GHz CPU,4GB 内存的电脑,软件采用 Visual

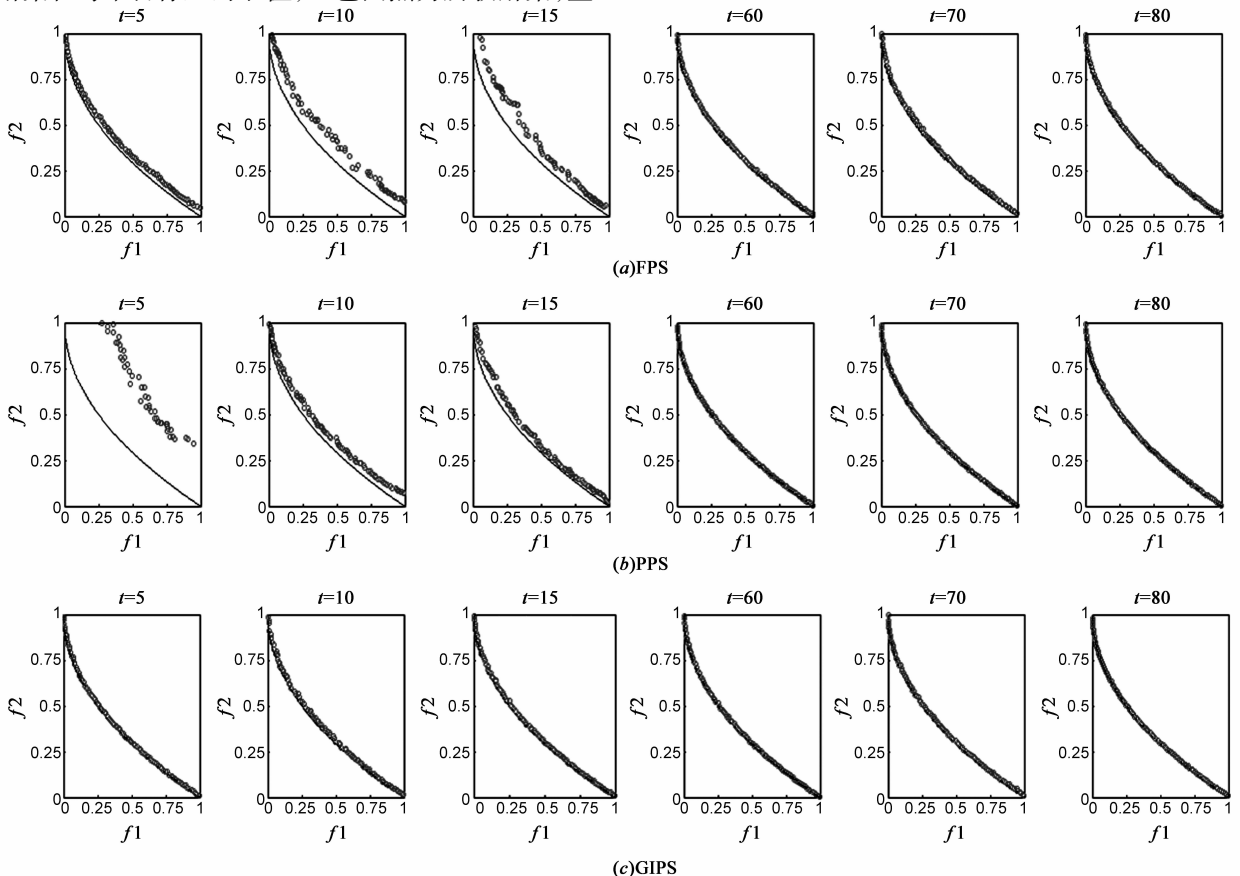


图2 三种策略求解FDA1过程中在六个不同时刻所获得的解集

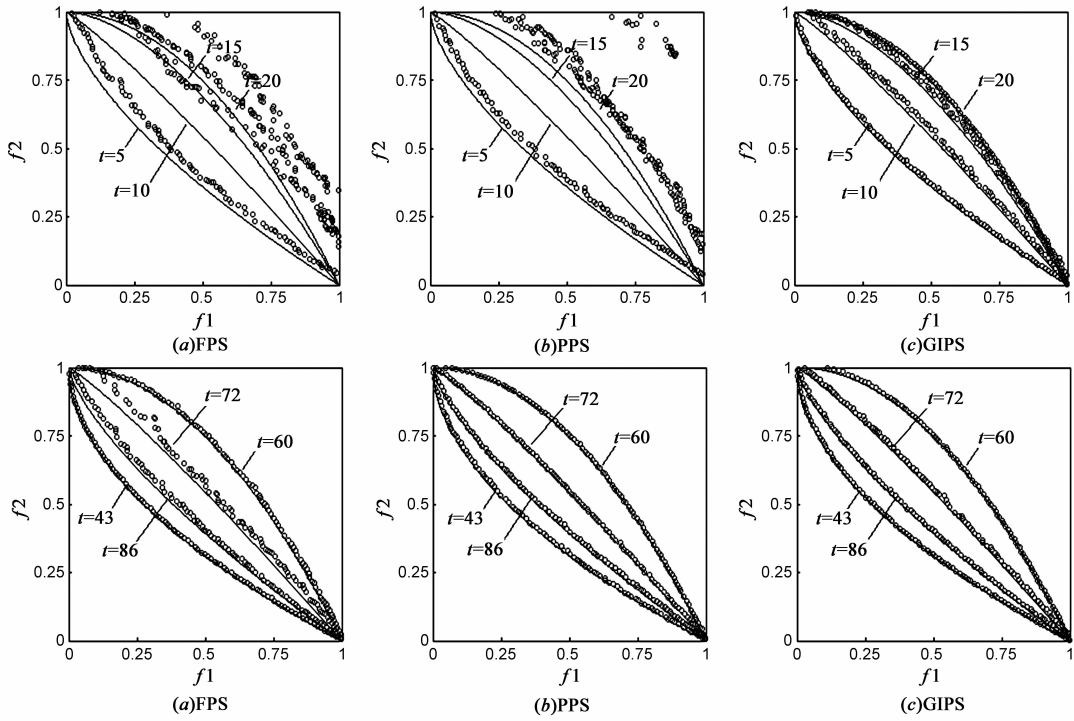


图3 三种策略求解DMOP2过程中在八个不同时刻所获得的解集

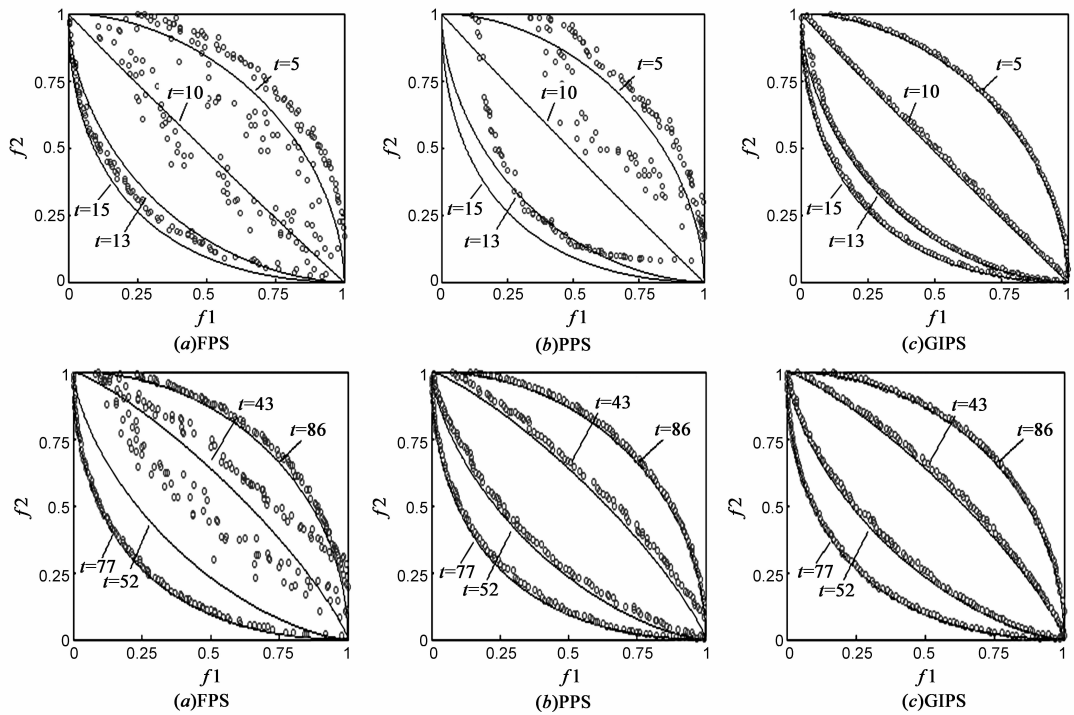


图4 三种策略求解F5过程中在八个不同时刻所获得的解集

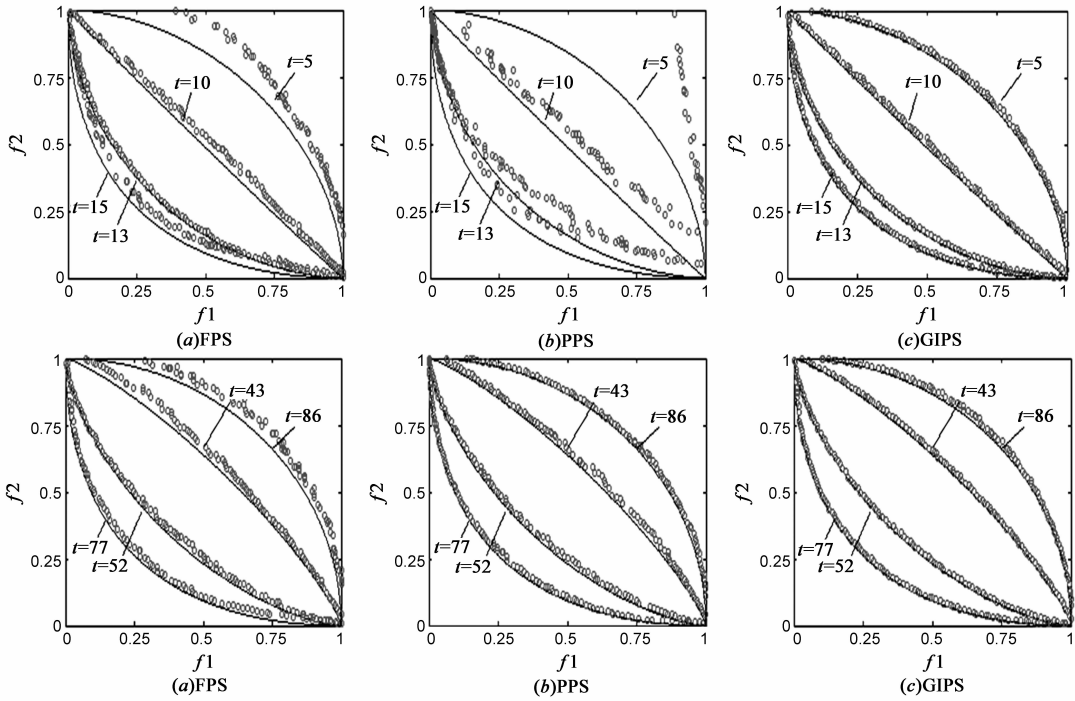


图5 三种策略求解F6过程中在八个不同时刻所获得的解集

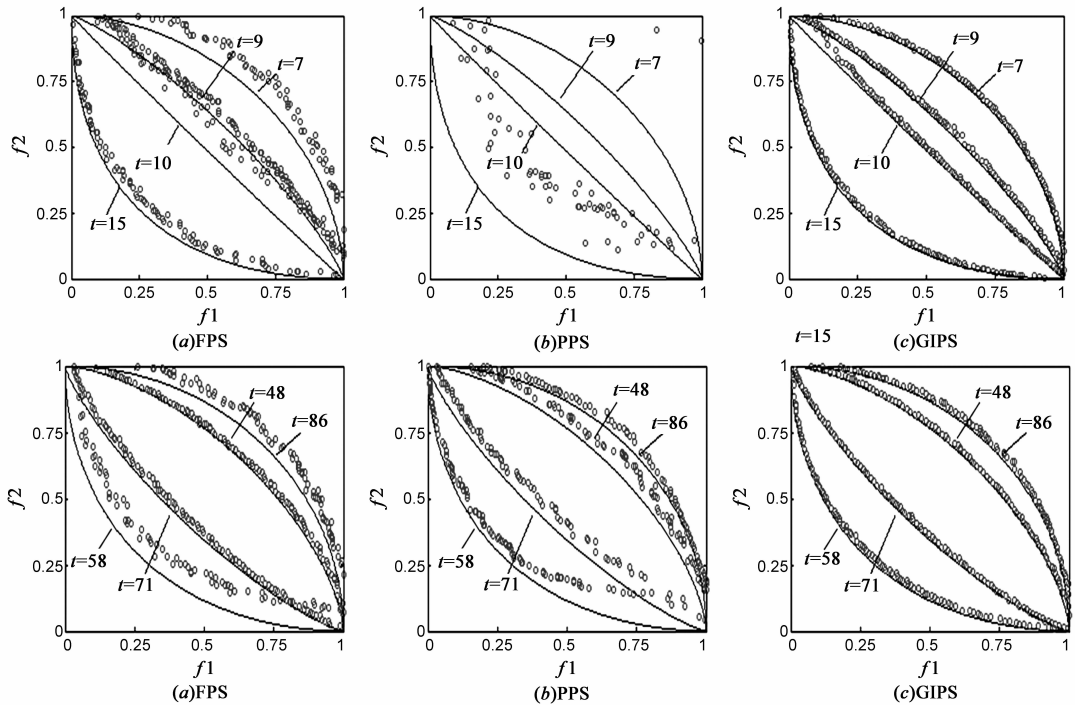


图6 三种策略求解F9过程中在八个不同时刻所获得的解集

Studio 2010.表 4 列出了三种策略求解不同 DMOPs 时所耗费的平均计算时间.

表 4 中:FPS 和 GIPS 在所有问题上耗费的计算时间较少,且相差不大,反映了 FPS 和 GIPS 具有最快的运

行速度;PPS 耗费的时间最多,这可能与 PPS 既要预测种群中心点位置又要预测种群形状有关.此外,GIPS 的时间比 FPS 稍多一点,这主要因为 GIPS 中的引导个体产生比 FPS 更耗时而引起的.

表 4 三种策略求解不同 DMOPs 所花费的平均计算时间(s)

Problems	FPS	PPS	GIPS
FDA1	7.82	8.15	7.90
FDA4	20.74	21.88	20.92
F5	8.68	8.92	8.71
F9	8.76	9.09	8.82

7 总结

本文提出了一种基于引导个体的预测策略(GIPS)来求解动态多目标问题.提出的预测种群进化方向的判断算子为算法准确的预测新的最优解集提供了依据,引导个体的引入加快了算法响应环境变化的速度,从而在环境变化的初始阶段就能获得较好的收敛性和分布性的解集,结合基于规则模型的多目标分布估计算法(RM-MEDA),在 FDA 和 DMOP 系列七个测试问题,以及 F5 ~ F9 五个新测试问题上,与其它两种预测策略算法进行仿真对比.实验结果表明,无论处理线性问题还是非线性问题,GIPS 都能快速地适应环境的变化,以较快的速度获得具有更好的收敛性和分布性的解集,这尤其对于求解非周期性变化的问题有突出的优越性.最后,需要指出的是由于基于种群中心点的位置变化判断种群进化方向的方法在种群尚未较好收敛的情况下,可能出现判断误差,导致算法在某几次环境变化上的预测方向不准确、收敛性不好,因此,设计一种更为精准的判断算子将是我们下一步的研究工作.此外,将预测与记忆的方法相结合,使其能更好地适应周期性变化的动态多目标问题,这也将是我们将来的研究重点之一.

参考文献

[1] Farina M, Deb M, Amato P. Dynamic multiobjective optimization problems: test cases, approximations, and applications[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(5): 425 - 442.

[2] Jin Y, Branke J. Evolutionary optimization in uncertain environments-A survey[J]. IEEE Transactions on Evolutionary Computation, 2005, 9(3): 303 - 317.

[3] Nguyen T T, Yang S, Branke J. Evolutionary dynamic optimization: A survey of the state of the art[J]. Swarm and Evolutionary Computation, 2012, 6(0): 1 - 24.

[4] 郑金华. 多目标进化算法及其应用[M]. 北京: 科学出版社, 2007.

[5] Coello Coello C A, Lamont G B, Van Veldhuizen D A. Evolutionary Algorithms for Solving Multi-objective Problems[M]. 2nd ed. New York: Springer-Verlag, 2007.

[6] 尚荣华, 焦李成, 公茂果, 马文萍. 免疫克隆算法求解动态多目标优化问题[J]. 软件学报, 2007, 18(11): 2700 - 2711.

Shang R H, Jiao L C, Gong M G, Ma W P. An immune algorithm for dynamic multi-objective optimization[J]. Journal of Software, 2007, 18(11): 2700 - 2711. (in Chinese).

[7] 刘淳安, 王宇平. 动态多目标优化的进化算法及其收敛性分析[J]. 电子学报, 2007, 35(6): 1118 - 1121.

Liu C A, Wang Y P. Evolutionary algorithm for dynamic multi-objective optimization problems and its convergence[J]. Chinese Journal of Electronics, 2007, 35(6): 1118 - 1121. (in Chinese)

[8] Greeff M, Engelbrecht A P. Solving dynamic multi-objective problems with vector evaluated particle swarm optimization [A]. IEEE Congress on Evolutionary Computation [C]. Hong Kong: IEEE, 2008. 2922 - 2929.

[9] Huang L, Suh H, Abraham A. Dynamic multi-objective optimization based on membrane computing for control of time-varying unstable plants [J]. Information Sciences, 2011, 181(11): 2370 - 2391.

[10] Liu R, Zhang W, Jiao L, Liu F, Ma J. A sphere-dominance based preference immune-inspired algorithm for dynamic multi-objective optimization[A]. Genetic and Evolutionary Computation Conference [C]. New York, NY, USA: ACM, 2011. 423 - 430.

[11] Wei J, Wang Y. Hyper rectangle search based particle swarm algorithm for dynamic constrained multi-objective optimization problems[A]. IEEE Congress on Evolutionary Computation [C]. Brisbane, Australia: IEEE, 2012. 259 - 266.

[12] Azevedo C R B, Araujo A F R. Generalized immigration schemes for dynamic evolutionary multiobjective optimization [A]. IEEE Congress on Evolutionary Computation [C]. New Orleans, LA, USA: IEEE, 2011. 2033 - 2040.

[13] Deb K, Rao U B N, Karthik S. Dynamic multi-objective optimization and decision-making using modified NSGA-II: A case study on hydro-thermal power scheduling[A]. Proc of the 4th International Conference on Evolutionary Multi-criterion Optimization [C]. Berlin Heidelberg: Springer-Verlag, 2007. 803 - 817.

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

[15] Wang Y, Li B. Investigation of memory-based multi-objective optimization evolutionary algorithm in dynamic environment [A]. IEEE Congress on Evolutionary Computation [C]. Trondheim: IEEE, 2009. 630 - 637.

[16] 刘敏, 曾文华. 记忆增强的动态多目标分解进化算法[J]. 软件学报, 2013, 24(7): 1571 - 1588.

Liu M, Zeng W H. Memory enhanced dynamic multi-objective evolutionary algorithm based on decomposition[J]. Journal of Software, 2013, 24(7): 1571 - 1588. (in Chinese)

- [17] Hatzakis I, Wallace D. Dynamic multi-objective optimization with evolutionary algorithms: A forward-looking approach [A]. Genetic and Evolutionary Computation Conference [C]. Seattle, Washington, USA: ACM, 2006. 1201 – 1208.
- [18] Zhou A, Jin Y, Zhang Q, Sendhoff B, Tsang E. Prediction-based population re-initialization for evolutionary dynamic multi-objective optimization [A]. Evolutionary Multi-Criterion Optimization [C]. Japan: Springer Berlin Heidelberg, 2007. 832 – 846.
- [19] Zhou A, Jin Y, Zhang Q. A population prediction strategy for evolutionary dynamic multiobjective optimization [J]. IEEE Transactions on Cybernetics, 2013, 44(1): 40 – 53.
- [20] Larranaga P, Lozano J A. Estimation of Distribution Algorithms: A New Tool for Evolutionary Computation [M]. New York: Kluwer Academic Publishers, 2001.
- [21] Zhang Q, Zhou A, Jin Y. RM-MEDA: A regularity model based multiobjective estimation of distribution algorithm [J]. IEEE Transactions on Evolutionary Computation, 2008, 12(1): 41 – 63.
- [22] 郑金华, 刘磊, 刘文盼, 邹娟. 一种自适应小生境分布性保持策略 [J]. 电子学报, 2012, 40(11): 2330 – 2335.

Zheng J H, Liu L, Liu W P, Zou J. An adaptive niche for keeping the diversity of solutions in multi-objective evolutionary algorithm [J]. Chinese Journal of Electronics, 2012, 40(11): 2330 – 2335. (in Chinese)

作者简介



郑金华 男, 1963 年生于湖南邵阳, 现为湘潭大学信息工程学院教授, 博士生导师, CCF 高级会员. 主要研究方向为进化计算、智能科学.

E-mail: jhzheng@xtu.edu.cn



彭舟 男, 1989 年 11 月出生, 湖南益阳人. 就读于湘潭大学信息工程学院. 主要研究方向为动态多目标进化算法.

E-mail: zpengtutu@163.com