

DOI: 10.7652/xjtuxb201810002

# 使用新预测模型的动态多目标优化算法

李智翔<sup>1</sup>, 李赟<sup>1</sup>, 贺亮<sup>1</sup>, 沈超<sup>2</sup>

(1. 盲信号处理重点实验室, 610041, 成都;

2. 西安交通大学智能网络与网络安全教育部重点实验室, 710049, 西安)

**摘要:** 针对实际应用中动态多目标优化算法对快速变化的最优解集跟踪能力不强的问题,提出了一种使用结合中心点预测值和垂直扰动分量的新预测模型的动态多目标优化算法。首先,计算变化前最优解集的中心点作为预测对象,改变了通常使用全部解进行预测的方式,提升了算法效率;其次,结合算法迭代的历史信息,选取位置、速度、加速度作为预测的状态向量,保证了算法对大多数情形下解集整体变化的跟踪预测能力;最后,为预测的新解添加了垂直于预测变化方向的超平面随机扰动,增强了解集的多样性,进而提升了算法收敛速度。实验结果表明,该算法在 75% 的测试函数集上的性能优于其他 3 种经典的动态多目标优化算法,其耗时较经典的基于卡尔曼滤波预测的动态多目标优化算法平均减少了 39%。

**关键词:** 动态多目标优化;进化算法;卡尔曼滤波;预测模型

**中图分类号:** TP391   **文献标志码:** A   **文章编号:** 0253-987X(2018)10-0008-08

## A Dynamic Multiobjective Optimization Algorithm with a New Prediction Model

LI Zhixiang<sup>1</sup>, LI Yun<sup>1</sup>, HE Liang<sup>1</sup>, SHEN Chao<sup>2</sup>

(1. National Key Laboratory of Science and Technology on Blind Signal Processing, Chengdu 610041, China;

2. MOE Key Lab for Intelligent Networks and Network Security, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** A new dynamic multiobjective optimization algorithm is proposed to solve the problem that the existing dynamic multiobjective optimization algorithms have poor ability to track the rapid changing optimal solutions for practical applications, and the algorithm uses a new prediction model that combines the prediction value of central point and the vertical disturbance component. First, the central point of the optimal solution set before change is calculated as a prediction object, which changes the way that all solutions are usually used for prediction and improves the efficiency of the algorithm. Second, the history information of the algorithmic iterations is combined to select the location, velocity and acceleration as a state vector of prediction. The tracking ability for change in the solution set is ensured in most circumstances. At last, a hyperplane random disturbance that is perpendicular to the predicted direction of change is added to the predicted new solution to enhance the diversity of the knowledge set, and the convergence speed of the algorithm is improved. Experimental results show that the proposed algorithm is superior to the other 3 state-of-the-art dynamic multiobjective evolutionary

收稿日期: 2018-03-21。 作者简介: 李智翔(1989—),男,博士生;沈超(通信作者),男,副教授,博士生导师。 基金项目: 国家自然科学基金资助项目(61773310,U1736205)。

网络出版时间: 2018-07-13      网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20180713.2129.016.html>

algorithms in 75% test cases, and the run time of the algorithm is 39% lower than those of dynamic multiobjective optimization algorithms based on Kalman filter.

**Keywords:** dynamic multiobjective optimization; evolutionary algorithm; Kalman filter; prediction model

在许多实际的工程问题,如规划调度、数据挖掘、资源分配、电路设计、控制系统等等问题中,由于问题的复杂性,优化目标往往不止一个,多个优化目标之间相互冲突并且取值随时间变化,这样的优化问题被称作动态多目标优化问题(dynamic multiobjective optimization problems, DMOPs)<sup>[1]</sup>。与求解静态多目标优化问题不同,在处理动态多目标优化问题时,需要在每次环境发生变化之前找到近似最优解集,这就要求算法能够跟踪随时间变化的环境<sup>[2]</sup>。特别地,当环境变化的速度较快时,动态多目标优化问题的求解难度进一步提升。

近些年来,在动态多目标优化问题的相关研究领域,学者做了很多工作,其中一部分研究工作针对如何在动态多目标优化算法的迭代过程中检测环境变化。文献[3]提出了一种最常见的基于解再计算方式检测环境变化的方法,文献[4]提出了一种基于反转模型的两阶段检测的方法,文献[5]则通过解的分布性来判断环境的变化情况。动态多目标优化算法为了在变化发生时加快收敛速度,通常需要在变化时增加解集的多样性。文献[6]通过优化变异算子来增加解集的多样性,文献[7]通过对部分解进行重定位来增加解集的多样性,文献[8]通过引入多种群协同进化机制,使得不同种群采用不同的进化策略,从而增加了解集的多样性。为了跟随和预测环境的变化,一些学者对基于历史记录的方法进行了深入研究:文献[9]采用记忆串的方式对历史信息进行记录,保持解的多样性并快速响应新的环境变化;文献[10]提出了通过维护一个外部存储空间来保留历史信息,利用历史信息实现对变化后的最优解集进行快速逼近;文献[11]通过对动态变化的环境进行学习,自适应地调整算法参数,从而提升了算法效率。除了对历史信息的记录,学者们还提出采用预测的方法对变化后的环境进行主动判断和逼近,已有的研究成果包括对最优解的变化进行预测<sup>[12]</sup>、对区域的变动进行预测<sup>[13]</sup>、对变化发生的时间进行预测<sup>[14]</sup>等。与其他思路相比,采用预测思想的算法取得了较好的效果,但该类算法应用于实际问题求解时仍存在对快速变化的最优解集的跟踪能力不强,算法运行效率较差等问题,有待进一步解决。

本文采用预测解集变化的思路,提出了一种基于卡尔曼滤波的动态多目标优化算法(dynamic multiobjective optimization evolutionary algorithm based on decomposition with Kalman filter, DD-KF)。卡尔曼滤波是一种利用包含噪声的观测数据对未来数据进行预测的方法,其思想在动态优化算法中得到了广泛的使用<sup>[15-16]</sup>。卡尔曼滤波能够快速、准确地跟踪线性系统的变化,具有计算复杂度低、抗噪声干扰能力强等特点,适合动态多目标优化算法用来在环境变化时快速逼近最优解。与已有算法为每个解维护一个卡尔曼滤波模型不同,DDKF算法提出了一种全新的预测模型,一方面通过记录每次环境变化前解集的中心并使用卡尔曼滤波对该中心进行预测,利用中心变化的方向和幅度对一部分新解进行放置和搜索,并且为每个新解增加垂直于变化方向的随机扰动以丰富新解的多样性;另一方面,保持一部分解不变,避免因变化方向无规律时导致预测偏差较大影响解的收敛速度。与其他3种算法在标准测试集上的对比实验表明,本文DDKF算法在大多数测试函数上得到的结果优于其他3种算法,并且算法运行时间较已有的基于卡尔曼滤波模型进行预测的MOEA/D-KF算法<sup>[15]</sup>更短,从而说明了DDKF算法的有效性。

## 1 背景知识

### 1.1 动态多目标优化问题

一个动态多目标优化问题的优化模型如下

$$\begin{aligned} \min \mathbf{F}(\mathbf{x}, t) &= (f_1(\mathbf{x}, t), \dots, f_m(\mathbf{x}, t))^T \\ \text{s. t. } \begin{cases} h_i(\mathbf{x}, t) = 0, & i = 1, \dots, n_h \\ g_i(\mathbf{x}, t) \geq 0, & i = 1, \dots, n_g \\ \mathbf{x} \in \Omega_x, & t \in \Omega_t \end{cases} \end{aligned} \quad (1)$$

式中: $m$ 表示目标空间的维数; $n_h$ 和 $n_g$ 分别表示等式约束与不等式约束的数量; $\Omega_x \subseteq \mathbf{R}^n$ 表示决策空间; $t$ 为离散时间序列,定义为 $t = (1/n_t) \lfloor (\tau/\tau_t) \rfloor$ ,其中 $n_t$ 、 $\tau_t$ 、 $\tau$ 分别表示变化的程度、变化的频度以及迭代次数, $\tau$ 表示时间空间; $\mathbf{F}(\mathbf{x}, t): \Omega_x \times \Omega_t \rightarrow \mathbf{R}^m$ 表示对 $t$ 时刻的解 $\mathbf{x}$ 估值的目标函数,其所在空间为目标空间。当优化问题的优化目标多于一个时,通常不存在使所有目标函数同时达到最优的解,所以动

态多目标优化问题在特定时刻的解通常为一个解集,其中每个解都不严格优于其他解,该解集被称为 Pareto 最优解集,简称最优解集(记作  $S_{PS}$ ),其在目标空间对应的点集称作 Pareto 最优面,简称最优面(记作  $S_{PF}$ )<sup>[17]</sup>。

## 1.2 基于分解的多目标优化算法

基于分解的多目标进化算法的核心思想是通过降维的方式将一个高维的多目标优化问题转换成若干子问题,子问题通常是单目标优化问题。每个子问题对应原多目标优化问题的一个解,由于不同子问题的参数不同,因此通过合理地选择参数,所有子问题的解组合起来就构成了原多目标优化问题的最优解集。在求解的过程中,子问题既可以独立求解,也可以通过对比采纳参数相近的邻居子问题得到的解加速自身的收敛速度。与其他多目标优化算法相比,基于分解的多目标优化算法通常具有较好的收敛速度并且能够得到分布多样性更优的解集<sup>[18]</sup>。

## 1.3 卡尔曼滤波预测模型

参考文献[19],考虑一个线性系统的状态差分方程如下

$$\mathbf{x}_t = \mathbf{A}\mathbf{x}_{t-1} + \mathbf{B}\mathbf{u}_{t-1} + \mathbf{w}_{t-1} \quad (2)$$

式中: $\mathbf{x}_t \in \mathbf{R}^n$  为  $t$  时刻的系统状态变量; $\mathbf{A}$  为  $n \times n$  的转换矩阵; $\mathbf{u}_{t-1}$  为  $t-1$  时刻的系统输入,长度为  $l$ ;  $\mathbf{B}$  为将输入转换为状态的矩阵,大小为  $n \times l$ ;  $\mathbf{w}_{t-1}$  为  $t-1$  时刻的系统噪声。 $t$  时刻的测量值  $\mathbf{z}_t \in \mathbf{R}^m$  可表示为

$$\mathbf{z}_t = \mathbf{H}\mathbf{x}_t + \mathbf{v}_t \quad (3)$$

式中: $\mathbf{H}$  是状态变量到测量的转换矩阵,其大小为  $m \times n$ ;  $\mathbf{v}_t$  为  $t$  时刻的测量噪声。假设任意时刻的系统噪声  $\mathbf{w}$  和测量噪声  $\mathbf{v}$  是相互独立的白噪声,且具有如下多元高斯分布

$$\left. \begin{aligned} p(\mathbf{w}) &\sim N(0, \mathbf{Q}) \\ p(\mathbf{v}) &\sim N(0, \mathbf{R}) \end{aligned} \right\} \quad (4)$$

式中  $\mathbf{Q}, \mathbf{R}$  分别为系统噪声和测量噪声的协方差矩阵。卡尔曼滤波的预测模型采用迭代的形式,模型估计某一时刻的状态,之后收到带有噪声的测量值反馈后对模型进行修正,如此往复。卡尔曼滤波预测模型的公式分为时间更新和测量更新两个部分,时间更新和测量更新的公式如下

$$\left. \begin{aligned} \hat{\mathbf{x}}_t^- &= \mathbf{A}\hat{\mathbf{x}}_{t-1} + \mathbf{B}\mathbf{u}_{t-1} \\ \mathbf{P}_t^- &= \mathbf{A}\mathbf{P}_{t-1}\mathbf{A}^T + \mathbf{Q} \end{aligned} \right\} \quad (5)$$

$$\left. \begin{aligned} \mathbf{K}_t &= \mathbf{P}_t^- \mathbf{H}^T (\mathbf{H} \mathbf{P}_t^- \mathbf{H}^T + \mathbf{R})^{-1} \\ \hat{\mathbf{x}}_t &= \hat{\mathbf{x}}_t^- + \mathbf{K}_t (\mathbf{z}_t - \mathbf{H} \hat{\mathbf{x}}_t^-) \\ \mathbf{P}_t &= (\mathbf{I} - \mathbf{K}_t \mathbf{H}) \mathbf{P}_t^- \end{aligned} \right\} \quad (6)$$

式中: $\hat{\mathbf{x}}_t^-$  为  $t$  时刻估计的状态向量; $\hat{\mathbf{x}}_{t-1}$  为  $t-1$  时刻结合测量值更新后的状态向量; $\mathbf{P}_t^-$  为  $t$  时刻估计的误差协方差矩阵; $\mathbf{P}_{t-1}$  为  $t-1$  时刻更新后的误差协方差矩阵; $\mathbf{K}_t$  为  $t$  时刻的卡尔曼增益,其值越大表示测量值越准确可信。通过设定状态变量和误差协方差矩阵的初值(可设置为 0,不依赖于初值的选取),结合不断的观测数据  $\mathbf{z}_t$ ,即可实现对状态变量未来值的预测。

## 2 动态多目标优化算法 DDKF

### 2.1 卡尔曼滤波模型设计

取  $\mathbf{x}_t$  为  $t$  时刻变化之后  $t+1$  时刻变化之前求得的最优解集的中心点,计算公式为

$$\mathbf{x}_t = \frac{1}{|S_t|} \sum_{\mathbf{x} \in S_t} \mathbf{x} \quad (7)$$

式中: $S_t$  表示  $t$  时刻求得的最优解集; $|S_t|$  为最优解集的大小。本文使用卡尔曼滤波预测模型对  $\mathbf{x}_t$  进行跟踪,记系统状态变量为

$$\mathbf{X} = [\mathbf{x} \quad \mathbf{v} \quad \mathbf{a}]^T \quad (8)$$

式中: $\mathbf{x}$  为决策空间的变量; $\mathbf{v}$  表示  $\mathbf{x}$  的一阶导数,即观测对象的速度; $\mathbf{a}$  为  $\mathbf{x}$  的二阶导数,即观测对象的加速度。采用这样的定义,有利于将更多的历史数据用来进行预测。系统只能通过  $\mathbf{x}$  进行观测,有

$$\mathbf{A} = \begin{bmatrix} 1 & 1 & 0 \\ 0 & 1 & 1 \\ 0 & 0 & 1 \end{bmatrix} \quad (9)$$

$$\mathbf{H} = [1 \quad 0 \quad 0]^T \quad (10)$$

式中:矩阵  $\mathbf{A}$  的值表示这里的卡尔曼滤波模型为二阶线性模型;矩阵  $\mathbf{H}$  的值表示在该问题中只能测量到系统状态变量的第一维,即观测对象的位置。结合式(5)可以看出,对观测对象下一时刻的位置的预测,与上一时刻的位置、速度的预测值和上一时刻的位置测量值有关。

### 2.2 新解集的生成

当根据卡尔曼滤波预测模型得到  $t+1$  时刻的预测值  $\mathbf{x}_{t+1}$  时,可以计算出相应的位移为

$$\mathbf{d}_t = \mathbf{x}_{t+1} - \bar{\mathbf{x}}_t \quad (11)$$

式中, $\mathbf{x}_t$  为  $t+1$  时刻变化之前根据式(7)计算得到的中心点观测值。若仅通过中心点的位移对新解的变化方向进行预测,事实上假设了各个解变化方向的一致性,然而对动态多目标优化问题而言,变化前后的各个最优解的变化方向并不一定完全一致。本文算法通过维护一个卡尔曼滤波模型降低了计算复杂性,但新解的多样性会因此受到影响,进而影响算

法的收敛效率。为了进一步增加新解的多样性,这里选择对新解增加一个与位移方向垂直的分量。与位移方向垂直的超平面定义为

$$V(d_t) = \{v \in \mathbf{R}^n : \|v\| = 1, d_t \cdot v = 0\} \quad (12)$$

对  $t+1$  时刻变化之前得到的解集中的任意一个解  $x$ ,所对应的新解  $x_{\text{new}}$  的计算方式如下

$$x_{\text{new}} = \begin{cases} x, & p_{\text{rand}} \leq p_n \\ x + d_t + vN(0,1), & \text{其他} \end{cases} \quad (13)$$

式(13)表明:一部分新解按照概率  $p_n$  保持不变,避免预测产生错误;其他新解则在原始解的基础上叠加预测的位移分量和垂直的超平面扰动分量。这样处理能够进一步增加新解的多样性,避免因变化方向预测的错误带来对收敛速度的影响。

以二维目标空间为例,本文算法在环境变化时的预测策略如图 1 所示,图中  $\bar{x}_{t-2}, \bar{x}_{t-1}, \bar{x}_t$  是对应的中心点,虚线箭头为变化方向。当  $t$  时刻环境变化时,算法使用卡尔曼滤波模型预测  $\bar{x}_t$  的位置并确定变化方向,通过向当前解集叠加变化方向对应的向量和垂直与变化方向的扰动量(用虚线表示)得到新解集,即图 1 中的空心点。当  $\bar{x}_t$  预测值较准确时,新解集较原解集距离新最优面更近,且扰动量保证了解的多样性,从而加速了算法的收敛。




图 1 本文算法在环境变化时的预测模型

2.3 算法流程

- 步骤 1 初始化种群、权重向量、邻居大小等参数;
- 步骤 2 利用该子问题对应的个体解  $x^i$  与邻居子问题集合中随机选取的解产生下一代解  $x_{\text{new}}^i$ ;
- 步骤 3 对邻居集合中每一个解  $x^j$ ,如果当前子问题对新产生的解  $x_{\text{new}}^i$  更优,则用  $x_{\text{new}}^i$  替换  $x^j$ ;
- 步骤 4 判断环境是否发生变化:若未变化,则跳转至步骤 9;若环境发生变化,继续执行步骤 5;
- 步骤 5 应用式(7)生成当前时刻的中心点,即测量值  $z_t$ ;
- 步骤 6 应用式(6)进行卡尔曼滤波测量更新;
- 步骤 7 利用式(5)进行卡尔曼滤波时间更新,得到对下一时刻的预测值  $x_{t+1}$ ;

- 步骤 8 根据式(11)~式(13)计算生成新一代解;
- 步骤 9 进行下一代进化。若算法达到终止条件,则返回结果,算法结束;否则返回步骤 2。

3 实验分析

3.1 实验设置

为了验证本文 DDKF 算法的有效性,选择 3 种优秀的动态多目标优化算法进行对比测试。这 3 种算法分别是 DNSGAI 算法<sup>[20]</sup>、MOEA/D-KF 算法<sup>[15]</sup>及 PPS 算法<sup>[21]</sup>。其中 DNSGAI 是在经典的多目标优化算法 NSGAI 的基础上针对动态多目标优化问题重新设计的算法;MOEA/D-KF 是一种为每个解构造一个卡尔曼滤波预测模型的基于分解的动态多目标优化算法;PPS 算法对分布进行了估计,并采用了一种时间序列回归分析的技术进行预测。

本文选择使用 10 个动态多目标测试函数对上述算法进行对比测试,这些测试函数选自文献[21-23]。测试函数的特征如表 1 所示。

表 1 测试函数属性

| 测试函数  | 目标空间<br>维度 | 决策空间<br>维度 | 特征                       |
|-------|------------|------------|--------------------------|
| FDA1  | 2          | 20         | $S_{PF}$ 固定, $S_{PS}$ 变化 |
| FDA4  | 3          | 20         | $S_{PF}$ 固定, $S_{PS}$ 变化 |
| dMOP1 | 2          | 20         | $S_{PF}$ 变化, $S_{PS}$ 固定 |
| dMOP2 | 2          | 20         | $S_{PF}$ 变化, $S_{PS}$ 变化 |
| F5    | 2          | 20         | $S_{PF}$ 变化, $S_{PS}$ 变化 |
| F6    | 2          | 20         | $S_{PF}$ 变化, $S_{PS}$ 变化 |
| F7    | 2          | 20         | $S_{PF}$ 变化, $S_{PS}$ 变化 |
| F8    | 3          | 20         | $S_{PF}$ 变化, $S_{PS}$ 变化 |
| F9    | 2          | 20         | $S_{PF}$ 变化, $S_{PS}$ 变化 |
| F10   | 2          | 20         | $S_{PF}$ 变化, $S_{PS}$ 变化 |

DNSGAI 算法、MOEA/D-KF 算法以及 PPS 算法的参数参照相应文献进行设置,其他参数设置如下:种群大小为 100;算法执行代数 为 4 000 代,变化程度  $n_t=10$ ,式(13)中  $p_n=0.3$ 。此外,为了对 4 种算法在动态多目标优化问题发生变化前充分收敛和未充分收敛的情况进行分析,令环境变化频度  $\tau_t$  的值分别取 40 和 5,其他参数不变。4 种算法在 10 个测试函数上分别运行 20 次。

为了对 4 种算法在不同时刻得到解集的收敛性和多样性进行综合评估,本文选择了常用的性能度量指标平均反向距离( $d_{\text{MIGD}}$ )<sup>[21]</sup>对算法得到的解集进行分析。平均反向距离是对适用于静态多目标优

化算法的反向距离指标( $d_{\text{IGD}}$ )<sup>[24]</sup>在时间上的平均。令  $P_t^*$  表示  $t$  时刻最优面上均匀分布的点的集合,  $S_t$  表示  $t$  时刻通过算法得到的最优解集, 则平均反向距离通过下式计算

$$d_{\text{MIGD}} = \frac{1}{|T|} \sum_{t \in T} \frac{\sum_{x \in P_t^*} \text{dist}(\mathbf{x}, S_t)}{|P_t^*|} \quad (14)$$

式中:  $\text{dist}(\mathbf{x}, S_t)$  表示解  $\mathbf{x}$  到  $S_t$  中距离最近的解的欧氏距离;  $|P_t^*|$  指参考最优解集合  $P_t^*$  的大小。本文测试函数的目标空间为二维或三维, 对二维目标空间的测试函数,  $|P_t^*|$  的大小设置为 1 000, 目标函数分别用  $f_1$  和  $f_2$  表示; 对三维目标空间的测试函数,  $|P_t^*|$  的大小设置为 10 000, 目标函数分别用  $f_1$ 、 $f_2$  和  $f_3$  表示。平均反向距离指标能够同时对算法得到解集的收敛性和多样性进行综合度量, 该指标的值越小, 算法的性能越优。

3.2 实验结果和分析

4 种算法在 10 个测试函数上的平均反向距离指标均值测试结果如表 2 所示。可以看出: 针对环境变化频度  $\tau_t$  取 40 的情形, 本文提出的 DDKF 算法在 10 个测试函数中的 8 个测试函数上的平均反向距离指标测试结果优于其他 3 种算法, 而 MOEA/D-KF 算法和 PPS 算法分别在 dMOP2 和 F7 测试函数上最优; 针对环境变化频度  $\tau_t$  取 5 的情形, 本文提出的 DDKF 算法在 10 个测试函数中的 7 个测试函数上的平均反向距离指标结果优于其他 3 种算法, 而 MOEA/D-KF 算法在 FDA1 测试函数上最优, PPS 算法在 dMOP1 和 F7 两个测试函数上最

优。测试结果说明, 本文提出的 DDKF 算法在大多数测试函数上优于其他 3 种算法, 当环境变化频度  $\tau_t$  由 40 变成 5 时, MOEA/D-KF 算法、PPS 算法和本文提出的 DDKF 算法得到的平均反向距离指标结果平均有 3~5 倍的增大, 而 DNSGAI 算法得到的结果平均有 1 个数量级左右的增大, 其增幅大于其他 3 种算法。这是因为当环境变化频度  $\tau_t$  由 40 变成 5 时, 每次变化之间的迭代次数减少, 由于算法均不能充分收敛, 相应的平均反向距离指标结果均较原先的值变差, 但此时本文提出的 DDKF 算法在大部分测试函数上仍优于其他 3 种算法。此外, 与 DNSGAI 算法采用随机初始化策略对种群进行处理相比, 其他 3 种算法均采用了各自不同的预测策略, 其效果优于 DNSGAI 的随机初始化策略, 尤其是当环境变化频度  $\tau_t$  的值取 5 时, 算法在两次变化之间的迭代次数较少, 无法充分收敛, 此时具有预测策略的 3 种算法的优势更加明显。

为了进一步说明本文提出的 DDKF 算法的有效性, 选取 F6 测试函数对上述 4 种算法在环境变化频度  $\tau_t$  的值取 40 时的测试结果进行深入分析。首先对 4 种算法在 F6 上不同时刻的反向距离指标的值进行对比, 结果如图 2 和图 3 所示。可以看出: 本文提出的 DDKF 算法在迭代次数为 5 之后基本趋于稳定, 反向距离随环境变化的波动很小, 且平均值小于其他 3 种算法; MOEA/D-KF 算法及 PPS 算法的结果相当, 但 PPS 波动性较小; 从算法的稳定性来讲, 本文算法优于 MOEA/D-KF 算法; DNSGAI 算法的结果差于其他 3 种算法, 且波动性较强。

表 2 4 种算法的平均反向距离比较

| 测试函数  | $d_{\text{MIGD}}$ |            |               |               |               |               |                |               |
|-------|-------------------|------------|---------------|---------------|---------------|---------------|----------------|---------------|
|       | DNSGAI 算法         |            | MOEA/D-KF 算法  |               | PPS 算法        |               | DDKF 算法        |               |
|       | $\tau_t=40$       | $\tau_t=5$ | $\tau_t=40$   | $\tau_t=5$    | $\tau_t=40$   | $\tau_t=5$    | $\tau_t=40$    | $\tau_t=5$    |
| FDA1  | 0.0582            | 0.641      | 0.0198        | <b>0.0768</b> | 0.0136        | 0.0809        | <b>0.00963</b> | 0.0801        |
| FDA4  | 0.287             | 1.49       | 0.148         | 0.444         | 0.157         | 0.307         | <b>0.105</b>   | <b>0.251</b>  |
| dMOP1 | 0.00883           | 0.0931     | 0.00773       | 0.0319        | 0.00560       | <b>0.0215</b> | <b>0.00492</b> | 0.0267        |
| dMOP2 | 0.109             | 0.720      | <b>0.0377</b> | 0.152         | 0.0428        | 0.154         | 0.0385         | <b>0.151</b>  |
| F5    | 0.132             | 0.692      | 0.0287        | 0.0979        | 0.0344        | 0.121         | <b>0.0154</b>  | <b>0.0853</b> |
| F6    | 0.115             | 1.11       | 0.0580        | 0.276         | 0.0539        | 0.234         | 0.0252         | 0.0964        |
| F7    | 0.0871            | 1.05       | 0.0388        | 0.124         | <b>0.0259</b> | <b>0.0981</b> | 0.0314         | 0.108         |
| F8    | 0.425             | 2.87       | 0.225         | 0.667         | 0.207         | 0.715         | <b>0.0934</b>  | <b>0.349</b>  |
| F9    | 0.324             | 2.54       | 0.152         | 0.633         | 0.166         | 0.667         | <b>0.0718</b>  | <b>0.291</b>  |
| F10   | 0.109             | 0.989      | 0.0611        | 0.201         | 0.0586        | 0.140         | <b>0.0328</b>  | <b>0.0803</b> |

注: 黑体数据表示最优值




图 2 4 种算法在 F6 测试函数上不同迭代次数的反向距离对比




图 3 4 种算法在 F6 测试函数上的反向距离的箱线图对比

为了观察不同时刻 4 种算法得到的解的分布情况,这里选取了  $t$  为 65、67、69、71、73 s 这 5 个时刻 4 种算法得到的解在目标空间的值,其结果如图 4 至图 7 所示。图中实线为不同时刻的最优面,点为不同时刻求得的解集。可以看出,本文提出的 DD-KF 算法在这 5 个时刻的解均优于其他 3 种算法的对应解,收敛性好且分布较为均匀,基本覆盖了整个最优面;PPS 算法和 MOEA/D-KF 算法的结果次之,收敛性较好但分布不够均匀,最优面的一些片段附近并没有相应的解;而 DMSGALL 算法的收敛性差于上述 3 种算法,分布均匀程度与 MOEA/D-KF 算法和 PPS 算法相当。

为了对比分析不同算法的时间效率,将 4 种算法在上述 10 个测试函数上分别运行 10 次,记录并对比总的运行时间。令本文提出算法 DDKF 的总运行时间为 1,其他 3 种算法的总运行时间与本文算法运行时间的比值如表 3 所示。

表 3 4 种算法的运行时间对比

| 算法  | DMSGALL | MOEA/D-KF | PPS  | DDKF |
|-----|---------|-----------|------|------|
| 用时比 | 0.41    | 1.63      | 1.56 | 1.00 |

由表 3 可以看出,DMSGALL 算法的运行时间最短,本文 DDKF 算法次之,而 MOEA/D-KF 算法和 PPS 算法运行时间较长。这是因为:与其他 3 种算法相比,DMSGALL 采用的随机初始化策略较为简单,




图 4 在测试函数 F6 上 DMSGALL 算法的结果分布




图 5 在测试函数 F6 上 MOEA/D-KF 算法的结果分布




图 6 在测试函数 F6 上 PPS 算法的结果分布




图 7 在测试函数 F6 上 DDKF 算法的结果分布

时间复杂度较低;与 PPS 使用的回归模型相比,本文 DDKF 算法使用的单个状态向量的卡尔曼滤波模型时间复杂度更低,而 MOEA/D-KF 尽管也采用了卡尔曼滤波模型,但该算法对每一个解分别构造一个卡尔曼滤波模型,而本文仅构造了一个卡尔曼滤波模型,因此本文提出的 DDKF 算法运行时间优于 MOEA/D-KF 算法和 PPS 算法。

## 4 结 论

当环境发生变化时,如何快速均匀地收敛到新的最优面是动态多目标优化算法需要解决的一个核心问题。本文设计了一种新的预测方法,一方面使用卡尔曼滤波模型对不同时刻的解集中心点进行跟踪,预测其变化;另一方面为新解集在预测的变化方向的垂直超平面上增加一个扰动量,使得新解集保持充分的多样性。与其他优秀算法在公开测试集上的对比实验结果证明了本文提出算法的有效性。如何优化选取参考点以及如何在环境不变时加速算法收敛是今后研究的重点。

## 参考文献:

- [1] NGUYEN S, ZHANG M, JOHNSTON M, et al. Automatic design of scheduling policies for dynamic multi-objective job shop scheduling via cooperative co-evolution genetic programming [J]. IEEE Transactions on Evolutionary Computation, 2014, 18(2): 193-208.
- [2] MARICHELVAM M K, PRABAHARAN T, YANG X S. A discrete firefly algorithm for the multi-objective hybrid flowshop scheduling problems [J]. IEEE Transactions on Evolutionary Computation, 2014, 18(2): 301-305.
- [3] NGUYEN T T. Continuous dynamic optimisation using evolutionary algorithms [D]. Birmingham, UK: University of Birmingham, 2011: 161-220.
- [4] 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.
- [5] MORRISON R W. Designing evolutionary algorithms for dynamic environments [M]. Berlin, Germany: Springer-Verlag, 2003: 25-69.
- [6] RIEKERT M, MALAN K M, ENGELBRECHT A P. Adaptive genetic programming for dynamic classification problems [C]// IEEE Congress on Evolutionary Computation. Piscataway, NJ, USA: IEEE, 2009: 674-681.
- [7] WOLDESENBET Y G, YEN G G. Dynamic evolutionary algorithm with variable relocation [J]. IEEE Transactions on Evolutionary Computation, 2009, 13(3): 500-513.
- [8] 张世文, 李智勇, 陈少森, 等. 基于生态策略的动态多目标优化算法 [J]. 计算机研究与发展, 2014, 51(6): 1313-1330.  
ZHANG Shiwen, LI Zhiyong, CHEN Shaomiao, et al. Dynamic multi-objective optimization algorithm based on ecological strategy [J]. Journal of Computer Research and Development, 2014, 51(6): 1313-1330.
- [9] 刘敏, 曾文华, 刘玉珍. 动态进化多目标优化中的串式记忆方法 [J]. 计算机科学, 2016, 43(12): 241-247.  
LIU Min, ZENG Wenhua, LIU Yuzhen. Bunchy memo method for dynamic evolutionary multi-objective optimization [J]. Computer Science, 2016, 43(12): 241-247.
- [10] JIANG S, YANG S. A steady-state and generational evolutionary algorithm for dynamic multiobjective optimization [J]. IEEE Transactions on Evolutionary Computation, 2017, 21(1): 65-82.
- [11] 焦儒旺, 曾三友, 李晰, 等. 基于学习的动态多目标方法求解约束优化问题 [J]. 武汉大学学报(理学版), 2017, 63(2): 177-183.  
JIAO Ruwang, ZENG Sanyou, LI Xi, et al. Constrained optimization by solving equivalent dynamic constrained multi-objective based on learning [J]. Journal of Wuhan University (Natural Science Edition), 2017, 63(2): 177-183.
- [12] 陈美蓉, 郭一楠, 巩敦卫, 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(11): 2014-2032.  
CHEN Meirong, GUO Yinan, GONG Dunwei, et al. A novel dynamic multi-objective robust evolutionary optimization method [J]. Acta Automatica Sinica, 2017(11): 2014-2032.
- [13] ZHOU A, JIN Y, ZHANG Q, et al. Prediction-based population re-initialization for evolutionary dynamic multi-objective optimization [C]// International Conference on Evolutionary Multi-Criterion Optimization. Berlin, Germany: Springer-Verlag, 2007: 832-846.
- [14] COSTA E. Improving prediction in evolutionary algorithms for dynamic environments [C]// Conference on Genetic and Evolutionary Computation. New York, USA: ACM, 2009: 875-882.

- [15] MURUGANANTHAM A, ZHAO Y, GEE S B, et al. Dynamic multiobjective optimization using evolutionary algorithm with Kalman filter [J]. *Procedia Computer Science*, 2013, 24(1): 66-75.
- [16] YAN J, YUAN D, XING X, et al. Kalman filtering parameter optimization techniques based on genetic algorithm [C]//IEEE International Conference on Automation and Logistics. Piscataway, NJ, USA: IEEE, 2008: 1717-1720.
- [17] DEB K, KALYANMOY D. Multi-objective optimization using evolutionary algorithms [M]. New York, USA: John Wiley & Sons, Inc., 2001: 1-20.
- [18] ANUPAM T, DIPTI S, KRISHNENDU S, et al. A survey of multiobjective evolutionary algorithms based on decomposition [J]. *IEEE Transactions on Evolutionary Computation*, 2017, 21(3): 440-462.
- [19] WELCH G, BISHOP G. An introduction to the Kalman filter [M]. Chapel Hill, NC, USA: University of North Carolina at Chapel Hill, 2001: 1-16.
- [20] 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 [M]//Lecture Notes in Computer Science: Vol 4403. Heidelberg, Germany: Springer Verlag, 2007: 803-817.
- [21] 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.
- [22] FARINA M, DEB K, AMATO P. Dynamic multiobjective optimization problems: test cases, approximations, and applications [J]. *IEEE Transactions on Evolutionary Computation*, 2004, 8(5): 425-442.
- [23] GOH C K, TAN K C. A competitive-cooperative co-evolutionary paradigm for dynamic multiobjective optimization [J]. *IEEE Transactions on Evolutionary Computation*, 2009, 13(1): 103-127.
- [24] BOSMAN P A N, THIERENS D. The balance between proximity and diversity in multiobjective evolutionary algorithms [J]. *IEEE Transactions on Evolutionary Computation*, 2003, 7(2): 174-188.
- [本刊相关文献链接]
- 史晓军,李珊,魏亚东,等. 纳米流体矩形微通道热沉结构参数多目标优化. 2018, 52(5): 56-61. [doi: 10.7652/xjtuxb201805008]
- 文键,李科,刘育策,等. 利用流固耦合分析的板翅式换热器锯齿型翅片多目标优化. 2018, 52(2): 130-135. [doi: 10.7652/xjtuxb201802020]
- 付学中,方宗德,关亚彬,等. 采用 NSGA-II 算法的面齿轮副小轮拓扑修形多目标优化. 2017, 51(7): 98-104. [doi: 10.7652/xjtuxb201707015]
- 王斯民,简冠平,肖娟,等. 缠绕管式换热器结构参数多目标优化数值模拟研究. 2017, 51(5): 9-15. [doi: 10.7652/xjtuxb201705002]
- 罗健旭,彭培培,徐颖,等. 污水处理过程的多目标优化. 2017, 51(3): 129-135. [doi: 10.7652/xjtuxb201703022]
- 杨扬,Chun-Ta LU,王菲菲,等. 众筹项目的社交网络影响力预测与分析. 2017, 51(4): 91-96. [doi: 10.7652/xjtuxb201704014]
- 崔宁,秦四成,赵丁选. 液压挖掘机并联混合节能动力系统多目标优化控制策略. 2016, 50(6): 116-121. [doi: 10.7652/xjtuxb201606018]
- 王斯民,王萌萌,顾昕,等. 螺旋折流板换热器结构参数多目标优化的数值模拟. 2015, 49(11): 14-19. [doi: 10.7652/xjtuxb201511003]
- 邓涛,林椿松,李亚南,等. 采用 NSGA-II 算法的混合动力能量管理控制多目标优化方法. 2015, 49(10): 143-150. [doi: 10.7652/xjtuxb201510023]
- 柯俊,史文库,钱琛,等. 采用遗传算法的复合材料板簧多目标优化方法. 2015, 49(8): 102-108. [doi: 10.7652/xjtuxb201508017]
- 戴慧珺,曲桦,赵季红. 利用非精确参数的移动互联网业务感知多目标优化 QoS 路由算法. 2014, 48(2): 86-92. [doi: 10.7652/xjtuxb201402015]
- 李彬,宋立明,李军,等. 长叶片透平级多学科多目标优化设计. 2014, 48(1): 1-6. [doi: 10.7652/xjtuxb201401001]
- 刘连理,李庆,顾运,等. 电力定价策略的多目标优化模型及其应用. 2013, 47(10): 115-120. [doi: 10.7652/xjtuxb201310020]
- 陈旭,王伊卿,孙琨,等. 高速列车车厢夹层板断面结构的多目标优化. 2013, 47(1): 62-67. [doi: 10.7652/xjtuxb201301013]
- 刘星,梅雪松,陶涛,等. 一种零耦合滚齿全误差模型及其预测方法. 2016, 50(10): 42-48. [doi: 10.7652/xjtuxb201610007]
- 王菲菲,杨扬,蒋飞,等. 面向用户话题相似性特征的链路预测方法. 2016, 50(8): 103-109. [doi: 10.7652/xjtuxb201608017]
- 赵振冲,王晓丹. 引入拒识的最小风险弹道目标识别. 2018, 52(4): 132-138. [doi: 10.7652/xjtuxb201804019]
- 杨源,库涛,查宇飞,等. 快速多特征金字塔的尺度目标跟踪方法. 2016, 50(10): 49-56. [doi: 10.7652/xjtuxb201610008]
- 吴杰,冯祖仁,刘恒,等. 水下目标多元声传感阵列网络定位方法. 2015, 49(4): 40-45. [doi: 10.7652/xjtuxb201504007]

(编辑 刘杨)