



时空视角下的动态多目标进化算法研究综述

范勤勤, 李盟, 黄文焘, 姜庆超

引用本文:

范勤勤, 李盟, 黄文焘, 姜庆超. 时空视角下的动态多目标进化算法研究综述[J]. 控制与决策, 2024, 39(1): 1–16.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1899>

您可能感兴趣的其他文章

Articles you may be interested in

[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>

[基于分解的多目标多因子进化算法](#)

A multiobjective multifactorial evolutionary algorithm based on decomposition

控制与决策. 2021, 36(3): 637–644 <https://doi.org/10.13195/j.kzyjc.2019.0525>

[多模态多目标优化综述](#)

A survey on multimodal multiobjective optimization

控制与决策. 2021, 36(11): 2577–2588 <https://doi.org/10.13195/j.kzyjc.2020.1509>

[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>

时空视角下的动态多目标进化算法研究综述

范勤勤^{1†}, 李 盟¹, 黄文焘², 姜庆超³

(1. 上海海事大学 物流研究中心, 上海 201306; 2. 上海交通大学 电力传输与功率变换控制教育部重点实验室, 上海 200240; 3. 华东理工大学 能源化工过程智能制造教育部重点实验室, 上海 200237)

摘 要: 现实中的多目标优化问题会随时间或环境的变化而发生改变, 因此在全周期优化过程中, 环境变化检测和算法响应是求解动态多目标优化问题的两大关键步骤, 为此重点对动态多目标进化算法方面的研究进行总结. 为有效求解动态多目标优化问题, 大量追踪性能优良的动态多目标进化算法在近 20 年里被提出, 但是很少有文献从时空角度对已有研究进行分析和报道, 鉴于此, 从该视角对动态多目标进化算法研究进行综述. 首先介绍动态多目标优化的基本概念、问题和性能指标; 然后从时空视角对近 5 年提出的动态多目标进化算法研究进行分别介绍; 最后列出目前动态多目标进化算法方面研究存在的一些挑战, 并对未来研究进行展望.

关键词: 进化计算; 动态多目标优化; 全周期优化; 时变; 空变

中图分类号: TP301

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1899

引用格式: 范勤勤, 李盟, 黄文焘, 等. 时空视角下的动态多目标进化算法研究综述[J]. 控制与决策, 2024, 39(1): 1-16.

A research survey of dynamic multi-objective evolutionary algorithms from spatiotemporal perspective

FAN Qin-qin^{1†}, LI Meng¹, HUANG Wen-tao², JIANG Qing-chao³

(1. Logistics Research Center, Shanghai Maritime University, Shanghai 201306, China; 2. Key Laboratory of Control of Power Transmission and Conversion of Ministry of Education, Shanghai Jiao Tong University, Shanghai 200240, China; 3. Key Laboratory of Smart Manufacturing in Energy Chemical Process of Ministry of Education, East China University of Science and Technology, Shanghai 200237, China)

Abstract: Actual multi-objective optimization problems change with time or environments (called as dynamic multi-objective optimization problems, DMOPs), thus detection of environmental change and algorithm response are two key steps to solve DMOPs during the full-cycle optimization. This paper focuses on summarizing the research on the latter one, i.e., dynamic multi-objective evolutionary algorithms (DMOEAs). To solve DMOPs effectively, a large number of DMOEAs with good tracking performance have been proposed in the past two decades. However, few literatures analyse and report the existing studies from the spatiotemporal perspective. Therefore, this paper introduces review of research on DMOEAs from this view. First, the basic concepts, DMOPs, and performance indicators are introduced. Then, the research on DMOEAs proposed in the past five years are introduced from the spatiotemporal view. Finally, some current challenges exist in DMOEAs are given, and future studies are prospected.

Keywords: evolutionary computation; dynamic multi-objective optimization; full cycle optimization; time-varying; space-variant

0 引 言

多目标优化问题 (multi-objective optimization problems, MOPs) 是普遍存在于科学研究和实际应用中的一类问题, 且受到广泛关注和研究^[1-2]. 但是, 部分 MOPs 会根据时间或环境发生改变, 此类问题

可称为动态多目标优化问题 (dynamic multi-objective optimization problems, DMOPs). 相比于静态多目标优化问题, 求解 DMOPs 不仅需要在每个时间步或环境找到帕累托解集 (Pareto set, PS), 而且需要维持一定的种群多样性以适应不断变化的环境. 同时, 进

收稿日期: 2022-11-03; 录用日期: 2023-03-11.

基金项目: 上海市浦江人才计划项目 (22PJJD030); 国家自然科学基金项目 (61603244); 国家自然科学基金山东联合基金项目 (U2006228).

责任编辑: 巩敦卫.

[†]通讯作者. E-mail: forever123fan@163.com.

化算法(evolutionary algorithm, EA)可以被看作一类具有“偏见”的数据生成器或采样器,具有良好的深度和宽度搜索能力^[3]. 因此,为了能够在动态环境下快速跟踪变化的PS,各类追踪性能优良的动态多目标进化算法(dynamic multi-objective evolutionary algorithms, DMOEAs)被不断提出. 近年来,尤其是基于预测和迁移学习的DMOEAs持续受到众多研究人员的关注^[4-6],其主要优势在于可以从以往经验/数据中得到可用知识提高新环境或 t 时刻下的初始种群质量,故能大大提高DMOEAs在动态环境下的追踪能力和适应能力. 此外,为验证DMOEAs的性能和弥补现实动态多目标优化问题的局限性,多个“人造”动态多目标测试集被不断提出^[7-11],其中,最知名和最早的标准测试集FDA由Farina等^[7]于2004年提出.

在全周期动态优化过程中,环境变化检测和算法响应是求解DMOPs的两大关键步骤,故现有文献大都是从以上两个方面开展研究. 因为算法响应属于动态多目标进化算法研究的一部分,所以本文主要从动态多目标进化算法方面对现有研究进行归纳,对于环境变化检测方面的研究将不再对其进行综述. 到目前为止,虽然国内外已有许多关于动态多目标优

化方面的综述文献^[12-17],但是它们大多是从方法或策略的角度进行总结. 比如,DMOEAs被分成以下几类:种群多样性维持/提高策略、记忆策略、预测策略、迁移学习方法、多种群策略. 但是,从DMOPs本身来看,它们不仅是空间映射问题,还是时间映射问题,即DMOPs具有时变和空变特性.

对于DMOPs而言,其决策空间与目标空间的时变关系见图1. 从图1可以看出,在 t 和 $t+1$ 时刻,虽然决策空间中解集分布完全一样,但是它们在目标空间中的分布发生了改变. 因此,过去和现在的解集在未来时刻可能提供不了有益帮助或参考,这给DMOPs的求解带来麻烦,也是动态优化问题难以求解的原因之一. 决策空间和目标空间的空变关系如图2所示. 由图2可知,目标空间的解集分布会随着决策空间位置的改变而发生改变,这不仅是动态优化问题所具有的特性,大多数静态优化问题也有此特性. 因此,如何从巨大的搜索空间中找到PS是一件困难的事情. 同时,对于DMOPs而言,时变和空变的特性往往相互交织,由于现有DMOEAs的采样能力和演化信息保存能力存在诸多不足,它们无法面对复杂的动态环境.




图1 决策空间与目标空间的时变关系




图2 决策空间与目标空间的空变关系

根据“动态”“多目标优化”“进化算法”“预测策略”“迁移学习”等关键词,通过中国知网(CNKI)对2012~2022年间的相关文献进行检索,得到34篇中文文献. 同时根据“dynamic multi-objective”“evolutionary algorithm”“differential evolution”“prediction strategy”“transfer learning”等关键词,通过Web of Science(WoS)进行检索,得到2012~2022年发表的相关文献共109篇. 依据以上检索结果,从

中英文文献发表比例和文献发表量两个方面进行统计分析,结果如图3所示. 由图3可知,近10年关于动态多目标优化的文献发表量逐年递增. 同时,英文文献占文献数量的比重较大. 可见,动态多目标优化的研究受到诸多学者的关注. 此外,根据关键词,本文还采用知识图谱的方法对检索到的文献进行聚类,结果如图4所示,节点大小表示关键词出现的频次,连线表示关键词之间的共享关系. 由图4可见,进化

算法出现的频次最高, 这表明进化算法是一种求解 DMOPs 的主要方法. 另外, 出现频次较高的其他关键词为“遗传算法”“预测策略”“多目标优化”等, 可

见遗传算法和预测方法在动态多目标优化领域使用较多. 总体而言, 动态多目标优化仍然是进化计算领域的一个热门研究.




图3 2012~2022年文献统计数据




图4 动态多目标优化领域的关键词聚类图

1 动态多目标优化问题

DMOPs 是指其目标函数与决策变量随着时间或环境变化而变化的一类优化问题, 最小化 DMOPs^[7] 定义如下:

$$\begin{aligned} \min \mathbf{F}(\mathbf{x}, t) &= \{f_1(\mathbf{x}, t), f_2(\mathbf{x}, t), \dots, f_m(\mathbf{x}, t)\}. \\ \text{s.t. } h_i(\mathbf{x}, t) &\geq 0, i = 1, 2, \dots, p; \\ g_j(\mathbf{x}, t) &= 0, j = 1, 2, \dots, q. \end{aligned} \quad (1)$$

其中: t 为环境(时间)变量, $\mathbf{x} \in \mathbb{R}^n$ 为决策空间, $\mathbf{F} = \{f_1, f_2, \dots, f_m\}$ 为 m 维最小化目标向量, $h_i(\mathbf{x}, t)$ ($1 \leq i \leq p$) 和 $g_j(\mathbf{x}, t)$ ($1 \leq j \leq q$) 分别为第 i 个不等式约束和第 j 个等式约束.

对于 DMOPs, 相关定义如下.

定义1 (动态 Pareto 支配) 第 t 时刻或环境下, 有任意两个决策向量 $\mathbf{a}$ 、 $\mathbf{b}$, 满足 $\mathbf{a}$ 支配 $\mathbf{b}$ 表示为 $\mathbf{a} \prec \mathbf{b}$ 当且仅当 $f_i(\mathbf{a}, t) \leq f_i(\mathbf{b}, t), \forall i = 1, 2, \dots, m$ 且 $\exists j =$

$1, 2, \dots, m$ 满足 $f_j(\mathbf{a}, t) < f_j(\mathbf{b}, t)$.

定义2 (Pareto 最优解集(PS)) 在任意 t 时刻或环境下, 若式(1)中解集 $\mathbf{x}$ 内的任意可行解均不被其他解所支配, 则该解集称为 Pareto 最优解集, 记作 $\text{PS}(t)$, 表示为

$$\text{PS}(t) = \{\mathbf{x} \in \mathbb{R}^n | \neg \exists \mathbf{y} \in \mathbb{R}^n, \mathbf{y} \prec \mathbf{x}\}. \quad (2)$$

定义3 (Pareto 前沿(PF)) 在 t 时刻或环境下, Pareto 最优解集在目标空间中的目标向量称为 Pareto 前沿, 记作 $\text{PF}(t)$, 有

$$\text{PF}(t) = \{\mathbf{F}(\mathbf{x}, t) | \mathbf{x} \in \text{PS}(t)\}. \quad (3)$$

Farina 等^[7] 将 DMOPs 划分为 4 类, 具体分类结果见表 1. 从表 1 可以看出, 该结果主要是从决策空间和目标空间的角度对 DMOPs 进行分类.

类型 1: 当时间或环境发生变化时, 该类型的 DMOPs 在决策空间中的 PS 发生变化, 但是在目标

表1 4类DMOPs

	PS(t) 变化	PS(t) 不变
PF(t) 变化	类型2	类型3
PF(t) 不变	类型1	类型4

空间中的PF没有发生变化.因此,针对该类型的DMOPs,DMOEAs需要在巨大的搜索空间里快速定位新环境中PS的位置.从时空特性来看,PS不仅随着时间的变化而变化,而且在空间也发生了改变,因此类型1具有时空特性.

类型2:在进入下一个时刻 $t+1$ 时,类型2的DMOPs在决策空间中的PS和目标空间中的PF均发生变化.该类型的DMOPs给DMOEAs在下一时刻或新环境的搜索带来麻烦.可以看出,类型2的DMOPs同样具有时变和空变特性.

类型3:当时间从 t 变化到 $t+1$ 时,DMOPs在决策空间中的PS没有发生变化,但目标空间中的PF发生了变化.此类型的DMOPs可能不会对DMOEAs的搜索带来麻烦,但它会由于PF的复杂度发生改变,从而影响最后的选择结果.不同于类型1和类型2,类型3的变化主要在于目标空间,因此类型3的DMOPs同样具有时变和空变特性.

类型4:该类型的PS和PF并不随着时间发生改变.虽然类型4在现实世界中是存在的,但学者们大多研究前3种类型的DMOPs.对于类型4,可以知道它具有空变特性,但是由于PS和PF都不随时间发生改变,不具有时变特性.

2 测试函数

为验证算法性能,通常使用动态多目标优化问题对动态多目标进化算法进行测试.它们可以帮助算法设计者或使用者认识和完善动态多目标进化算法.目前来看,由于实际的动态多目标优化问题难以大量获取,且存在分析困难,现有研究大都使用“人造”动态多目标优化问题对所提出算法进行追踪性能评估.此外,对于已有动态多目标优化问题,PS(t)和PF(t)的变化形式对它们有着重要的影响.一般来说,PS(t)和PF(t)变化越复杂测试函数便越难求解,因此通过PS(t)和PF(t)的变化,学者们构造出多个动态多目标优化函数测试集.

基于静态多目标优化问题DTLZ测试集^[18]和ZDT测试集^[19],Farina等^[7]设计了一套动态多目标测试函数集FDA1~FDA5.在FDA系列测试集中,PS(t)和PF(t)会随着时间或环境的改变发生一些简单的变化,且决策变量之间是线性相关的.FDA1和FDA4为类型1的测试函数,FDA2为类型3的测

试函数,FDA3和FDA5为类型2的测试函数.为了进一步有效验证DMOEAs的性能,Goh等^[20]提出一组dMOP系列测试函数集,在FDA测试集的基础上添加了新的动态特性.具体而言,虽然dMOP3与FDA1有一些相似特性,但dMOP3中决定解分布的变量是随时间变化的.即相比FDA1,dMOP3引入了随机性的动态变化.另外,Zhou等^[21]提出F5~F10等系列动态多目标测试函数,该测试函数集的决策变量之间是非线性相关的.其中,F5~F7为双目标优化问题,F8为三目标优化问题,且它们的空间变化特性相对平稳,即两个连续时间或环境下PF的几何形状较为相似.F9和F10为复杂的双目标优化问题,相比F5~F7找到其真实PF更为困难.因此,它们对DMOEAs追踪性能有着更高要求.

为进一步有效测试DMOEAs的性能.Gee等^[8]提出一组新的动态多目标基准测试集GTA,使用时变适应度地形模态、权衡连通性、权衡退化等动态特征构造复杂DMOPs.文献[10]提出一种新的DMOPs生成器,基于该生成器生成一组包含10个具有不同动态特性的测试函数JY1~JY10.JY测试集不仅有以上测试函数所具有的动态特性,还包含其他动态特性.比如,混合的Pareto前沿(凹和凸)、决策变量间的时变非单调依赖关系、混合变化、随机变化.同样,Jiang等^[11]提出一组动态多目标测试函数集DF1~DF14,并添加了新的动态特性.例如,DF13测试函数考虑了PF(t)的不连通性;DF14测试函数考虑了PF(t)的退化性.考虑到大多数动态多目标基准测试函数不具有随机性、变化形式单一、目标函数形式单一等问题,文献[22]提出一组随机的基准测试集RDP,该测试集含有8个测试函数,并使用随机时间序列构造测试函数.此外,该测试集还考虑多种复杂的动态特性,如欺骗性、多模态性、有偏性以及复杂的PF几何形状等.

基于以上介绍,现将部分动态多目标优化问题测试集^[7,9-11,20,22-27]从变化类型、PF几何形状、决策变量间是否存在非线性关系、混合变化、随机变化、时变、空变这7个方面进行归纳,如表2所示.需要说明的是,表2所列DMOPs均具有时变和空变特性,即个体在空间位置上的变化会导致其在目标空间中的变化,同时优化问题都随着时间的变化而发生改变.

随着各类动态多目标测试集被不断提出,对DMOEAs追踪性能的评价也越来越公正和公平,这也将极大提高DMOEAs在实际应用中的可信性和可靠性.

表2 动态多目标测试函数

测试套件	变化类型(I~IV)	PF几何形状	决策变量间是否存在非线性关系	混合变化	随机变化	时变	空变
FDA	type I, II, III	连续, 凹, 凸, 时变曲率, 时变位置	×	×	×	✓	✓
dMOP	type I, II, III	连续, 凸, 时变曲率	×	×	✓	✓	✓
DIMP	type I	连续, 凹, 凸	×	×	×	✓	✓
HE	type III	连续, 非连续, 时变曲率	✓	×	×	✓	✓
JY	type I, II, III	混合PF组件, 连续, 非连续, 时变曲率, 时变位置	✓	✓	✓	✓	✓
DSW	type II	连续, 凸, 时变位置	×	×	×	✓	✓
UDF	type II, III	连续, 非连续, 时变曲率, 时变位置	✓	×	✓	✓	✓
T	type III, IV	连续, 凹, 凸	×	×	×	✓	✓
ZJZ	type II	连续, 时变曲率	✓	×	×	✓	✓
DF	type I, II, III, IV	连续, 非连续, 凹, 凸, 时变曲率, 时变位置	✓	×	×	✓	✓
RDP	type I, II, III	混合PF组件, 连续, 凹, 凸, 时变曲率, 时变位置	✓	✓	✓	✓	✓

3 动态多目标优化算法的性能评价指标

虽然学者们提出不同动态特性的测试集以验证DMOEAs的性能,但是如何评价算法的优劣同样是一件重要的事,这将直接影响算法的设计、选择和应用.因此,在静态多目标性能指标研究的基础上,各种动态多目标的性能评价指标也被相继提出.总体而言,相比于静态多目标性能评价指标,动态多目标性能指标主要是对全周期优化过程的评价.因此,静态多目标性能评价可以看作是动态多目标性能评价中某个时间/环境的评价;而动态多目标性能评价是全周期优化过程静态多目标性能评价的总和.与静态多目标性能评价指标类似,动态多目标性能评价指标也可分为以下3类:收敛性性能指标、多样性性能指标、综合性性能指标.

3.1 收敛性性能指标

1) 世代距离(generational distance, GD).

GD^[28]可被用来评估多目标优化算法的收敛性能,定义如下:

$$GD(t) = \frac{\sum_{i \in |PF(t)|} d(i, PF^*(t))}{|PF(t)|}. \quad (4)$$

其中: $PF(t)$ 为 t 时刻下算法获得的PF逼近; $PF^*(t)$ 为 t 时刻下的真实PF; $d(i, PF^*(t))$ 为 $PF(t)$ 上个体 i 与 $PF^*(t)$ 中距离 i 最近的个体之间的欧氏距离.因此, GD值可以评价 $PF(t)$ 与 $PF^*(t)$ 的逼近程度, GD值越小该算法的收敛性越好.

假设环境变化次数为 T , 则 T 个环境变化次数下的平均GD为

$$\overline{GD} = \frac{1}{T} \sum_{t=1}^T GD(t). \quad (5)$$

2) 变量空间(variable space, VD).

为评估多目标优化算法的收敛性, Goh等^[20]提出一种变量迭代距离的性能指标VD, 定义如下:

$$VD_{\text{offline}} = \frac{\tau_{\max}}{\tau_T} \sum_{\tau=1}^{\tau_{\max}} VD(\tau) I(\tau).$$

$$I(\tau) = \begin{cases} 1, & \tau \% \tau_T = 0; \\ 0, & \text{otherwise.} \end{cases}$$

$$VD(\tau) = \frac{1}{n_{ps}} \left(n_{ps} \sum_{i=1}^{n_{ps}} d_i^2 \right)^{\frac{1}{2}}. \quad (6)$$

其中: $\%$ 为取模运算符; τ 为当前迭代次数, τ_T 为环境变化的频率, n_{ps} 为第 τ 代种群中 Pareto 支配解的个数. 与GD相似, VD_{offline} 值越小表明该算法的收敛性越好.

3.2 多样性性能指标

1) 间距SP(spacing).

Schott^[29]提出一种用来评估PF多样性的性能指标SP, 定义如下:

$$SP(t) = \sqrt{\frac{1}{|PF(t) - 1|} \sum_{i=1}^{|PF(t)|} (d_i - \bar{d})^2}. \quad (7)$$

$SP(t)$ 用来评价PF中个体之间的分布性, $SP(t)$ 值越小表明算法获得的PF越均匀.

假设环境变化次数为 T , 则 T 个环境变化次数下的平均SP为

$$\overline{SP} = \frac{1}{T} \sum_{t=1}^T SP(t). \quad (8)$$

$\overline{SP}$ 值越小表明相应的动态多目标优化算法所得的PF分布越均匀.

2) 间距 Δ (spacing).

Deb等^[30]提出另一种评估PF多样性的性能指标 Δ ,定义如下:

$$\Delta = \sum_{i=1}^{|\text{PF}(t)|} \frac{d_i - \bar{d}}{|\text{PF}(t)|}. \quad (9)$$

Δ 值越小表明相应的动态多目标优化算法所得的PF分布越均匀.

假设环境变化次数为 T ,则 T 个环境变化次数下的平均 Δ 为

$$\bar{\Delta} = \frac{1}{T} \sum_{t=1}^T \Delta(t). \quad (10)$$

3) 最大覆盖度MS (maximum spread).

MS是Zitzler等^[31]于1999年提出的用来衡量PF逼近覆盖真实PF的程度,定义如下:

$$\text{MS}(t) = \sqrt{\frac{1}{m} \sum_{i=1}^m \left[\frac{\min[\overline{\text{PF}}_i(t), \overline{\text{PF}}_i(t)^*] - \max[\text{PF}_i(t), \text{PF}_i(t)^*]}{\overline{\text{PF}}_i(t)^* - \text{PF}_i(t)^*} \right]^2}. \quad (11)$$

MS(t)越大表明所得PF逼近的分布越均匀.

假设环境变化次数为 T ,则 T 个环境变化次数下的平均最大覆盖度 $\overline{\text{MS}}$ 为

$$\overline{\text{MS}} = \frac{1}{T} \sum_{t=1}^T \text{MS}(t). \quad (12)$$

3.3 综合性性能指标

1) 超体积HV (hyper volume).

HV^[32]是一种用于综合评价算法收敛性和分布性的指标,定义如下:

$$\text{HV}(t) = \text{volume} \left(\bigcup_{i=1}^{|\text{PF}(t)|} v_i \right). \quad (13)$$

其中: volume 为体积, v_i 为由参考点和个体 i 形成的超体积. HV值越大表明算法所得到的PF逼近收敛性越好,分布越均匀.

假设环境变化次数为 T ,则 T 个环境变化次数下的平均HV为

$$\overline{\text{HV}} = \frac{1}{T} \sum_{t=1}^T \text{HV}(t). \quad (14)$$

2) 覆盖范围CS (coverage scope).

Zhang等^[33]提出一种覆盖范围指标CS,该指标根据得到的非支配解集之间的平均最大距离量化它们的平均宽度,定义如下:

$$\text{CS}(t) = \frac{1}{|\text{PF}(t)|} \sum_{i=1}^{|\text{PF}(t)|} \max\{|f(x_i) - f(x_j)|\}. \quad (15)$$

其中: $x_i, x_j \in \text{PF}, i < j = 1, 2, \dots, |\text{PF}(t)|$. 显然, CS(t)值越大表明算法获得的非支配解集的平均宽

度越大,即覆盖范围越广.

假设环境变化次数为 T ,则 T 个环境变化次数下的平均CS为

$$\overline{\text{CS}} = \frac{1}{T} \sum_{t=1}^T \text{CS}(t). \quad (16)$$

平均CS越大表明相应算法的性能越好.

3) 反世代距离IGD (inverted generational distance).

IGD^[34]用于同时评价算法的收敛性和多样性,定义如下:

$$\text{IGD}(\text{PF}^*(t), \text{PF}(t)) = \frac{\sum_{v \in \text{PF}^*(t)} d(v, \text{PF}(t))}{|\text{PF}^*(t)|},$$

$$d(v, \text{PF}(t)) = \min_{u \in |\text{PF}(t)|} \sqrt{\sum_{j=1}^m (f_j^v - f_j^u)^2}, \quad (17)$$

其中 v 和 u 分别为 $\text{PF}^*(t)$ 和 $\text{PF}(t)$ 中的点. IGD值越小表明该算法的收敛性和多样性越好.

假设环境变化次数为 T ,则 T 个环境变化次数下的平均IGD为

$$\overline{\text{IGD}} = \frac{1}{T} \sum_{t=1}^T \text{IGD}(t). \quad (18)$$

4 动态多目标进化算法研究进展

动态多目标优化是演化计算领域的研究热点和难点之一,算法框架如图5所示. 相比于静态多目标优化问题,除了要找到PS和PF,动态多目标优化还要进行环境变化检测和算法响应. 因此,DMOEAs不仅能够某一固定时刻或环境下尽可能快地找到PS,还能快速适应不断变化的环境以完成全周期优化的目标. 为实现以上目标,各类追踪性能优良的DMOEAs算法被不断提出. 同时,如何维持种群多样性和提供知识成为DMOEAs算法的研究重点. 本文将从时空角度对近5年提出的DMOEAs算法进行介绍和分析,并以算法响应策略保留/生成个体的时空属性进行分类. 比如,基于记忆和预测的方法主要考虑时间影响,而不是它们对现有演化信息的空间影响. 此类方法主要通过提供不同时间维度的知识(即“过去”或“未来”个体/数据)加速算法收敛. 又比如,从相似性的角度看,迁移学习偏向于空间的学习,因此迁移个体具有“数据”的空间属性.

4.1 时间视角

相比于静态优化问题,求解动态优化问题的难点在于其时变性. 对于DMOEAs而言,一方面,必须拥有好的追踪能力和适应能力来面对不断变化的环境;另一方面,优化问题的时间特性可能会使其之前得到




图5 动态多目标进化算法框架

的演化信息在未来时刻/环境成为搜索的“阻碍”,换句话说,过去和现在的演化信息(即知识)对未来不一定会有帮助. 因此,为解决DMOPs的时变问题,许多学者采取保存过去信息和预测未来信息的方式提高算法追踪性能,其中记忆策略和预测策略是两种典型方法.

基于记忆方法主要使用存档隐式或显式地存储过去的演化信息,并指导算法搜索. 从时间维度看,基于记忆方法可以使算法回到“过去”. 对于部分动态多目标优化问题而言,虽然它们会随着环境或时间发生改变,但一般不会发生剧烈变化. 因此,针对变化较缓慢或上一个时刻与下一个时刻之间有很大相关性的动态多目标优化问题,该方法有着显著优势.

文献[35]利用记忆方法存储历史演化信息,进而为算法的种群演化提供帮助. 实验结果表明,所提出算法的追踪性能明显优于比较算法. Wang等^[36]提出一种基于3种不同记忆方法的动态多目标进化算法,该算法将3种记忆方法(显示记忆、局部搜索记忆和混合记忆)与一个改进的非支配排序遗传算法(non-dominated sorting genetic algorithms, NSGA-II)相结合来提升其求解动态多目标优化问题的能力. 从实验结果分析可知,相比重启策略,记忆策略具有更好的搜索性能和鲁棒性.

文献[37]提出一种记忆增强的动态多目标分解进化算法,该算法将多目标分解思想与记忆方法相结合,当检测到环境发生变化时,先将一些代表性解存至记忆池,然后检索记忆信息并重复使用之前环境中的非支配解来响应当前的最新变化. 与其他3种记忆增强的动态多目标优化算法进行性能比较的结果表明,所提出算法能以最快速度获得收敛性和多样性较

好的解集,并具有更好的鲁棒性. Azzouz等^[38]提出一种基于变化程度的自适应种群管理策略,在该策略中记忆策略、局部搜索和随机策略均用来提升算法的追踪性能. 同时,针对优化问题变化前后相关或变化较小的情况,提出一种基于记忆的策略来充分使用过去得到的演化信息. 此外,还使用一种基于细胞密度的方式对外部存档进行更新,这有助于提高存档个体的多样性以提高算法的进化动力. 实验结果表明,相比于其他DMOEs,该算法能够有效适应环境变化,并能找到更好的PF逼近.

虽然基于记忆的方法能够有效解决特定类型的DMOPs,但是它在应对 $PS(t)$ 剧烈变化或前后 $PS(t)$ 不相关等场景仍存在诸多困难. 因此,学者们近年来将研究重点放在预测方法上,其基本思路是将群体演化信息作为数据,然后使用基于数据驱动的方法生成预测种群以促使DMOEs快速找到 $PS(t)$ 附近区域. 从时间维度看,使用预测方法可以使得种群“提前”到达有潜力的搜索区域.

Hatzakis等^[39]将预测模型与进化算法相结合来求解DMOPs,并提出一种前向反馈预测策略(feed-forward prediction strategy, FPS). 该策略使用自回归模型预测生成新个体,然后与当前环境下的一些非支配解和部分随机解一起构成初始种群. 实验结果表明,该方法能够有效求解变化频率较高的DMOPs. Rong等^[40]提出一种多方向预测方法(multi-direction prediction approach, MDP),并将其与粒子群优化算法相结合求解DMOPs. 首先在每一个时刻保存多个能够充分描述PS形状和多样性的代表性个体,当检测到环境发生变化后,所提出算法利用这些代表性个体确定的多个预测方向得到新环境下的PS;然后根据

新的PS生成新的代表性个体,其余个体则随机生成;最后将以上两部分个体合并生成新环境下的初始种群.通过与其他DMOEAs比较,实验结果表明MDP策略均优于所比较的方法.此外,为减少求解DMOPs的计算资源,Zou等^[41]提出一种拐点引导的预测进化算法(knee-guided prediction evolutionary algorithm, KPEA).不同于以往保存所有非支配解的方式,KPEA算法只保存拐点区域和边界区域的非支配解.当环境发生改变时,通过最小曼哈顿距离识别全局拐点.同时,基于全局拐点在新环境中的移动,使用预测方法生成新的拐点,并对其进行有针对性的搜索.通过一系列的实验计算和比较,结果表明KPEA算法具有较好的追踪能力和较快的收敛速度,适用于环境变化较快的DMOPs. Liang等^[42]结合改进的分解进化多目标优化算法(multi-objective evolutionary algorithm based on decomposition, MOEA/D)和基于反馈的预测策略(feedback-based prediction strategy, FPS)提出MOEA/D-FPS. FPS有两种反馈机制,分别是修正反馈(correction feedback, CF)和有效性反馈(effectiveness feedback, EF).当检测到环境变化后,CF会构建一个代表性个体,使用一阶微分预测模型作为初始预测模型对该个体进行预测,并通过步长探索法对预测模型进行修正;然后EF分为两个阶段重新初始化种群.第1阶段,根据修正后的预测模型对种群中一半的个体进行重新初始化.第2阶段,EF在第1阶段重新初始化种群的基础上,使用两轮轮盘赌方法重新初始化种群中剩余的另一半个体.将该算法与其他有竞争力的DMOEAs在22个测试函数上进行性能比较,结果验证了MOEA/D-FPS的有效性. Zhao等^[5]提出一种基于历史搜索过程学习的动态多目标进化优化算法.与以往研究不同,该算法不是仅通过前一时刻的PS预测后一时刻的PS,而是考虑整个历史的演化信息.经过一系列实验计算和比较,结果表明该算法无论在求解效果还是在求解效率上均具有很强的竞争力. Chen等^[43]提出一种基于集成卡尔曼滤波的预测方法(prediction method based on ensemble kalman filter, EnKFPS)求解DMOPs.该算法根据环境变化时的历史种群信息,利用EnKFPS预测新的种群中心点;然后使用它重新初始化种群.实验结果表明,该算法在大多数测试函数上均优于所比较的算法.

除以上方法外,采用预测方法对决策变量进行预测也是一种有效方法.文献[44]提出一种基于决

策变量分析(decision variables analysis, DVA)的预测策略来求解DMOPs. DVA主要分为3个步骤:首先,当检测到环境发生变化时,分析每个决策变量对新环境下个体的影响;然后,根据不同的决策变量和历史信息,采用不同的预测方法生成新个体;最后,使用一种基于角度的自适应选择策略从新生成的个体中选择收敛性和多样性较好的个体构成初始种群.实验结果表明,DVA在求解一些复杂DMOPs时均具有较好的求解效果. Sun等^[45]提出一种量化引导双预测策略进化算法(novel quantile-guided dual prediction strategies evolutionary algorithm, NQDPEA),利用非支配解中分位数的历史信息引导对应的子种群找到下一个时刻的PS,并通过前一时刻的近似PF中值得到新的PF逼近在决策空间中的解集.实验结果表明,NQDPEA能够高效求解DMOPs,但是还需要考虑提高种群的多样性.除了在决策空间中预测PS的变化,为预测PF的变化趋势, Zhou等^[6]提出一种多视角预测进化搜索方法来求解DMOPs,根据进化过程中得到的历史非支配解,分别从决策空间和目标空间进行预测,通过一个核化自编码方法分别生成决策空间的新解和新的PF逼近在决策空间中对应的解,并将这两部分构成新环境下的初始种群.经过常用测试函数和一个电影推荐问题的测试,实验结果表明了该方法在求解基准DMOPs和实际DMOPs方面均具有较好的表现.

使用单一预测方法有时无法适应新的优化环境,因此诸多学者考虑集成多种预测方法来提高种群的预测能力. Xu等^[46]将中心点预测策略与CTI预测策略相结合,提出一种结合决策空间和目标空间的混合预测策略求解DMOPs.所提出算法能够根据中心点在决策空间中进行预测,而且可以通过CTI预测目标空间的解集.另外,对于周期性变化的DMOPs,该算法在预测个体中添加一些历史个体作为记忆集,此外还引入多样性维持策略维持种群的多样性.通过13个测试函数的测试,并与4种基于预测策略的动态多目标优化算法相比较,结果表明算法能够有效解决DMOPs.同样, Rambabu等^[47]提出一种基于混合预测模型的专家系统来求解DMOPs,利用4种预测模型(包括卡尔曼滤波预测模型的两种变体、线性回归预测模型、随机初始化策略)提高整体预测精度.同时,该算法在优化过程中使用门控网络对4种预测模型实现自适应切换,通过13个函数的测试结果表明算法具有很好的追踪性能. Wang等^[48]提出一

种基于集成学习的预测策略(ensemble learning based prediction strategy, ELPS),使用4种预测模型,即线性预测模型、基于拐点的自回归模型、基于种群的自回归模型、随机初始化模型。当检测到环境发生变化时,算法能够根据历史信息预测生成新个体,并将它们作为初始种群。实验结果表明,ELPS在未知变化环境中具有良好的鲁棒性能。

为解决历史解与当前解的非线性关系问题, Jiang等^[49]利用一个增量支持向量机(incremental support vector machine, ISVM)分类器学习之前时刻所得历史演化种群,并使用训练后的ISVM生成高质量的初始种群。实验结果表明,该方法可以帮助DMOEAs快速和准确地解决DMOPs。Cao等^[50]提出一种基于支持向量回归(support vector regression, SVR)的动态多目标优化算法,基本思路是通过SVR模型对历史数据进行学习,并预测生成新环境下的解。将其与几种先进动态多目标优化算法进行对比,实验结果表明该算法具有很强的竞争力,但在求解某些特定类型DMOPs时存在效果不佳的情况。为此, Xu等^[4]提出一种基于增量支持向量机在线预测的动态多目标进化算法,首先通过合成少数类过采样技术(synthetic minority over-sampling technique, SMOTE)对训练样本进行预处理;然后利用连续获得的PS在线训练ISVM,当检测到环境发生变化时使用训练好的ISVM筛选出非支配个体,并生成下一时刻的初始种群。该方法的优点是可以识别出任意两个解之间的非线性关系,并且能够充分利用历史演化信息。选取一定数量的测试函数对其进行测试,结果表明算法在解决DMOPs时具有很强的竞争力。

强化学习方法能够学习环境特征并利用环境信息指导时变环境下的种群进化,因此各类强化学习方法也被用于辅助DMOEAs来提升追踪性能。Zou等^[51]提出一种基于强化学习的动态多目标优化进化算法(reinforcement learning-based dynamic multi-objective evolutionary algorithm, RL-DMOEAs),将强化学习框架与基于拐点预测、基于中心点预测和基于指标的局部搜索3种变化响应机制进行集成以提高其局部和全局的追踪能力。实验结果表明,RL-DMOEAs能够有效追踪大多数测试函数的PF变化,保持种群多样性并提高算法收敛速度。此外,文献^[52]提出一种基于逆强化学习(inverse reinforcement learning, IRL)驱动的动态多目标进化算法。不同于以往研究,该算法的特点是采用IRL作为代理训练模

型,将专家演示数据作为初始训练集,通过IRL模型得到最优策略生成大量有前途的个体。此外,该算法提出的 Q 学习变化响应机制继续搜索可行的非支配解。选取CEC 2015测试函数对其进行测试,结果表明IRL可以辅助该算法在动态环境下的追踪能力。传统机器学习方法通常假设不同环境下的动态优化问题解服从相同的分布。为了克服独立同分布带来的局限性, Ma等^[53]提出一种基于特征信息预测(feature information prediction, FIP)的动态多目标优化算法,利用不同环境下种群个体的分布来预测下一时刻的种群,当检测到环境发生变化后,通过联合分布自适应方法(joint distribution adaptation, JDA)构造映射函数。该方法将上一时刻目标空间中的特殊个体作为特征信息,并将其映射到高维空间得到下一时刻的特征信息,对于剩余个体,则让它们在边界范围内随机生成,最后将特征信息与剩余个体合并成下一时刻的初始种群。与4种有竞争力的DMOEAs进行性能比较,实验表明算法在收敛性和多样性方面能够取得很好效果。

在解决DMOPs的时变问题方面,基于记忆策略的动态多目标进化算法主要通过直接使用过去的信息/知识来加速算法收敛,但某些情况下只注重演化信息的时间特性,反而会导致其在空间维度上丢失多样性,当环境发生变化后,难以维持算法提供足够的进化动力来找到新环境下的PS。基于预测的动态多目标进化算法在时间维度上能够为DMOEAs提供有用知识以提高算法收敛,但与基于记忆策略一样,较少考虑演化信息的空间特性,可能会使其缺少进化动力,从而不能有效引导种群进化。

4.2 空间视角

静态优化问题和动态优化问题均具有空变特性。一般而言,优化问题的空变复杂度由维度、约束、目标函数等方面决定,因此对于解空间结构类似的优化问题,诸多学者使用迁移学习和多任务优化等方法达到快速搜索和定位的目的。而对于解空间结构存在较大差别的优化问题,大多数研究通过提高种群多样性提升算法的探索能力,保证算法有足够的进化动力对整个空间进行搜索,从而找到满意解。

迁移学习是一种机器学习方法,能够将源任务中的知识迁移到目标任务中。基于迁移学习的这一固有特性,可以从一个问题中获得的有用经验来解决一些解空间结构相似的优化问题,因此迁移学习也被用于求解动态多目标优化问题^[54]。

Wang等^[55]提出一种基于回归迁移学习的动态多目标优化算法(regression transfer learning prediction based dynamic multi-objective optimization algorithm, RTLP-DMOA). 算法的主要目的是生成一个优秀初始种群来加速搜索过程,当检测到环境变化时,RTLP-DMOA利用历史种群信息建立回归迁移学习模型生成新个体,并从预测的新个体中选择一些高质量解作为初始种群,从而提高算法的追踪能力. 通过与其他3个先进DMOEAs进行性能比较,结果表明RTLP-DMOA在大多数的测试函数上有优异表现. 但是,迁移学习通常需要较大的计算成本,为解决该问题,Jiang等^[56]提出一种基于流形迁移学习的快速动态多目标进化算法(memory-driven manifold transfer learning-based dynamic multi-objective evolutionary algorithm, MMTL-DMOE). 将基于记忆的预测策略与流形迁移学习相结合,同时,将历史PS存储在外部存档中作为训练样本集,根据训练样本集得到流行空间迁移模型. 当检测到环境发生变化时,该算法首先从外部存档中选取一部分的精英个体;然后,根据流形空间迁移模型生成新环境下的迁移个体;最后将新环境下的迁移个体与存档中的精英个体进行合并得到新环境下的初始种群. 实验结果表明,MMTL-DMOE不仅在于诸多性能指标上优于所比较的算法,而且在计算速度上提高了两个数量级. 虽然迁移学习有许多优点来辅助DMOEAs提高其追踪能力,但是负迁移会浪费一些计算资源和降低搜索效率. 为解决该问题,文献^[57]考虑将高质量个体与迁移学习相结合,从而提出一种基于拐点的不平衡迁移学习方法(knee point-based imbalanced transfer learning method-based dynamic multi-objective evolutionary algorithm, KT-DMOE)求解DMOPs. 该方法将目标空间划分为多个区域,每个区域都有一个拐点,当环境发生变化时,通过趋势预测模型来对每个区域生成新的拐点. 此外,KT-DMOE还使用一种解决数据不平衡的方法(即TrAdaboost)构建迁移学习模型,以此生成新环境下高质量的初始种群. 实验结果表明,KT-DMOE在保证追踪性能的同时,大大提高了计算效率. Jiang等^[58]提出一种基于个体迁移学习的动态多目标优化算法(individual transfer-based dynamic multi-objective evolutionary algorithm, IT-DMOE). 算法中,预搜索策略和个体迁移是其两大主要步骤. 预搜索策略先筛选出一些精英个体构成引导种群,从而避免因个体

聚集而导致负迁移情况的发生. 个体迁移部分首先筛选出精英个体与其他解作为训练样本;然后采用TrAdaboost方法构建迁移学习模型;最后使用该模型生成高质量的初始种群. 与其他基于迁移学习的动态多目标优化算法相比,IT-DMOE在寻找PS的速度上有显著提高,并大大提高了追踪性能.

除以上研究外,学者提出诸多基于迁移学习的其他DMOEAs. 比如,He等^[59]提出一种基于环境选择和迁移学习的动态多目标优化进化算法(dynamic multi-objective optimal evolutionary algorithm based on environmental selection and transfer learning, DMOEA-ESTL),通过环境选择策略获得引导个体,并将引导个体分为有变化和无变化两种类型. 当环境发生变化时,对于有变化的个体,通过构建迁移学习模型生成新环境中的引导个体,并对无变化的个体进行校正,然后将校正后的个体也作为新环境中的引导个体. 实验结果表明,DMOE-ESTL能够有效解决DMOPs. 文献^[60]提出一种基于域自适应学习(domain adaptation learning, DAL)策略的动态多目标优化算法,通过引入子空间分布对齐方法建立源域与目标域之间的映射矩阵. 当检测到环境发生变化时,通过该映射模型得到转移个体,并与历史PS合并形成新环境下的初始种群. 此外,为了增强初始种群的多样性,算法根据两个相邻历史环境下PS中心点之间的差值产生“噪声”个体,并将其添加到初始种群中. 通过12个测试函数的测试,并与其他6种DMOEAs进行比较,结果表明该算法的追踪性能要优于所比较的算法. 目前,大多数动态响应策略都是针对具有规则环境变化的DMOPs,为了有效解决环境变化随机的DMOPs,Guo等^[61]提出一种基于知识引导转移策略的动态多目标进化优化算法(knowledge guided transfer strategy for dynamic multi-objective optimization evolutionary algorithm, KTS-DMOE). 该算法首先建立一个知识池用来保存从历史Pareto最优解中提取的有效知识,当检测到环境发生变化时,根据提出的知识匹配策略从知识池中选取最具有价值的知识,从而促进知识的正向转移. 此外,KTS-DMOE还提出一种混合转移策略,根据转移知识与当前环境的相似程度自适应地选择最合适的转移策略包括知识重用技术和基于子空间分布对齐方法生成新的初始种群. 将其与5个DMOEAs进行性能比较,实验结果表明该算法能够有效求解环境规则变化和随机

变化的DMOPs. 为进一步提高迁移学习挖掘历史演化信息的能力, Ye等^[62]提出一种知识引导贝叶斯分类的动态多目标优化算法(knowledge-guided Bayesian classification based dynamic multi-objective evolutionary algorithm, KGB-DMOEA), 使用贝叶斯模型对历史所有演化信息进行学习, 并以此生成一个高质量的初始种群. 与其他5种有竞争力的算法相比, 实验结果表明KGB-DMOEA有最好的追踪性能, 但是在环境发生剧烈变化或者环境之间不相似的情况下, KGB-DMOEA的追踪性能会大大降低.

除决策空间的相似性学习和多样性保持外, 学者们使用维持目标空间的多样性方法提升DMOEA的追踪性能. 比如, Ravichandran等^[63]提出一种基于分解的文化算法(cultural algorithm based on decomposition, CA/D)求解DMOPs, 主要思路是使用切比雪夫方法将DMOPs分解为若干个标量优化子问题并同时求解, 然后根据权重向量的距离定义子问题之间的邻域关系和邻域之间的共享信息对每个子问题进行优化. 实验结果表明, CA/D在复杂的测试函数上性能十分优越. Ou等^[64]提出一种基于Pareto分解和截断的动态多目标优化进化算法(Pareto-based evolutionary algorithm using decomposition and truncation, PDTEA). 该算法由3部分组成: 1) 交配选择策略, 采用分解的方法选择两个多样性良好的个体作为交配亲本; 2) 在环境选择过程中提出一种改进的截断方法估计种群密度, 以保持种群在空间中有良好的多样性; 3) 提出一种基于探索(exploration)和开发(exploitation)的动态响应策略, 探索(exploration)策略引导种群向新环境中的潜在区域进化, 开发(exploitation)策略则在各潜在区域内充分搜索新的高质量个体. 经过实验分析得出, PDTEA在收敛性和多样性以及对变化的响应速度方面均具有很强的竞争力. 文献^[65]提出一种基于变化强度的动态多样性引入策略(dynamic diversity introduction strategy, DDIS), 并将其与MOEA/D相结合从而提出DDIS-MOEA/D来求解DMOPs. DDIS通过对比评估环境变化强度与默认环境强度确定多样性个体引入的比例和环境变化强度的类型; 然后分别采用逆建模和随机初始化方法作为环境响应策略以适应剧烈变化环境和平稳变化的环境; 最后根据变化的剧烈程度或频率构造3种不同混合变化类型的DMOPs, 并选取这3种测试函数对所提出算法进行测试, 结果表明DDIS-MOEA/D能够适应复杂的环境变化.

上述基于迁移学习的动态多目标优化算法对于具有解空间结构相似的DMOPs具有很好的求解效果, 因为它能够快速地将历史环境中的特征信息转移到新环境中, 使得算法快速找到新环境下的PS位置. 但是该方法仍有一些缺陷, 比如过多强调空间维度的学习就会人为割裂演化信息在时间维度上的联系. 上述提高种群多样性的方法主要有引入一定比例的随机个体、对种群中的部分个体进行超突变、将上一环境的PS作为新环境的初始种群. 这些方法均可以有效提高算法的进化动力, 使之能够有足够能力探索搜索空间, 但是会给算法收敛带来麻烦, 比如负迁移是使用迁移学习方法中经常出现的情况.

4.3 时空视角

除了从时间维度或空间维度对DMOEA进行研究外, 部分学者还同时考虑DMOPs的时变和空变特性, 因此研究中不仅考虑演化信息的时间特性, 还考虑其空间特性以提高DMOEA的追踪性能.

在众多动态策略中, 考虑演化信息的时空特性非常有必要, 而基于空间维度的多种群策略和基于时间维度的预测策略是两种有效方法. 因此, 将两种策略融合是一种高效求解DMOPs的手段. Wang等^[66]提出一种基于灰色预测的动态多目标进化算法(grey prediction-based dynamic multi-objective evolutionary algorithm, GP-DMOEA). 首先将整个种群划分为多个子种群, 然后利用每个子种群聚类中的质心点采用灰色预测方法进行预测, 生成部分初始种群. 同时, 为了更准确地检测环境变化, 从每个聚类中选择一些个体检测环境变化. 通过实验对比得出GP-DMOEA具有良好的追踪性能. 文献^[67]提出一种基于关键点预测的动态多目标优化算法(key points-based dynamic multi-objective evolutionary algorithm, KDMOEA), 同样是将整个种群划分为多个子种群, 不仅使用优劣解距离法(technique for order preference by similarity to ideal solution, TOPSIS)确定每个子种群的关键点(包括极点和质心点), 而且根据每个个体的TOPSIS值在环境选择和交配选择过程中为下一步选择出更好的个体. 当检测到环境发生变化时, 利用每个子种群中的极点和质心点, 采用序列预测方法获得初始种群. 通过与其他动态多目标优化算法相比较, 结果表明KDMOP能够在动态环境下快速追踪PS. Wei等^[68]提出一种基于特殊点和多区域拐点的预测方法(prediction strategy based on special points and multi-region knee points, MRKPs). 当

环境发生变化时,新环境下的初始种群由4个子种群组成:前馈中心点预测的非支配解、表示变化环境中PF形状的代表性个体、多区域拐点策略选择的个体、自适应多样性维护策略引入的多样性个体.实验结果表明,当环境变化较小时MRKPs具有良好的追踪性能,但当环境变化非常剧烈时MRKPs的追踪性能会下降.

Liu等^[69]提出一种动态多目标进化框架,采用Steffensen方法从预测和多样性维持两方面对进化过程进行控制.实验结果表明,该算法能够快速追踪PS,但是存在计算成本较高的问题.Ma等^[70]提出的多区域协同进化动态多目标优化算法(multiregional co-evolutionary dynamic multi-objective optimization algorithm, MRCDMO)主要分为两部分:多区域预测策略(multiregional prediction strategy, MPR)和多区域多样性维持机制(multiregional diversity maintenance mechanism, MRDM).当检测到环境发生变化时,MPR根据不同子区域的中心点建立差分模型来预测新个体,MRDM则在下一个预测的子区域内随机生成其他个体,这两部分个体构成了新环境下的初始种群.为了验证所提出算法的性能,使用12个不同特性的DMOPs对其进行测试,结果表明MRCDMO在PS变化较大的测试问题上有优越的追踪性能.文献^[71]提出一种基于决策变量分类的动态多目标优化协同进化算法(decision variable classification-based cooperative coevolutionary evolutionary algorithm, CCEA-DVC),将决策变量分为收敛变量(convergence variables, CS)和多样性变量(diversity variables, DS),并引入分别代表CS的亚种群和代表DS的亚种群.当检测到环境变化时,采用预测方法和多样性引入方法对CS和DS生成新环境下的初始种群.CCEA-DAC与其他4种DMOEAs在16个不同动态特性的测试函数上的比较结果表明算法具有很强的竞争力.

Hu等^[72]提出一种基于分层预测(layered prediction, LP)和子空间多样性维护(subspace-based diversity maintenance, SDM)的动态多目标优化算法.一旦检测到环境发生变化,LP策略快速响应环境变化,使种群快速找到新的PF逼近.SDM策略则被用来保持种群在空间维度上的多样性.Zheng等^[73]提出一种对抗分解和邻域演化的动态多目标粒子群优化算法(dynamic multi-objective particle swarm optimization algorithm based on adversarial decomposition and neighborhood evolution,

ADNEPSO).在静态优化过程中,ADNEPSO通过当前种群与对抗种群进行协同进化,并提出一种新的粒子更新策略以确保在环境变化前尽可能快地找到理想PS.当环境发生变化时,该算法利用历史信息进行预测并定位新的PS.同时,为了保证新种群的多样性,通过当前全局最优信息来保留部分粒子并搜索潜在区域.实验结果表明,算法能够有效响应环境变化,实现快速收敛,并在收敛性和多样性方面均具有不错的表现.文献^[74]提出一种基于特殊点迁移成分分析的动态多目标进化算法(special point-based transfer component analysis for dynamic multi-objective optimization algorithm, SPTr-RM-MEDA).当检测到环境发生变化时对特殊点及其邻域进行采样,然后利用这些信息进行迁移学习,从而预测新环境下的部分初始个体.此外,该算法还采用自适应多样性引入策略,通过高斯突变随机生成新环境下的剩余个体.结果表明,SPTr-RM-MEDA与其他5种具有代表性的算法相比,能够找到更好的PF逼近.由于以上研究均未考虑环境变化类型的影响,文献^[75]提出一种基于变化类型的自适应响应策略(novel change type-based self-adaptive response strategy, CTSRS),可以检测出PS随环境变化的类型,一种PS随时间变化而变化,另一种PS保持不变.当遇到PS随时间变化的类型时采用线性预测策略作为环境响应策略,根据历史环境中的PS预测下一时刻初始种群的位置.在PS保持不变的情况下,采用动态突变多样性引入策略自适应地选择一定数量的个体进行突变.将该算法与其他6种DMOEAs进行性能比较,结果表明算法具有很好的追踪性能.

由于维持种群多样性(空间维度)和提供知识(时间维度)能够有效帮助DMOEAs的追踪性能,考虑演化信息的时空特性十分重要.通过预测方法在时间维度上提供有用知识和提高种群在空间维度上的多样性,可以有效提高DMOEAs在不同动态环境下的追踪和适应能力.

5 动态多目标进化算法研究进展

到目前为止,关于动态多目标优化方面的研究已取得诸多令人欣喜的结果,但由于动态多目标优化问题有着复杂的时变和空变特性,还需解决以下几个挑战:

1) 由于DMOPs具有很强的时变特性,如何提高DMOEAs的追踪能力至关重要.虽然部分机器学习(如迁移学习、预测算法)被用于提升DMOEAs的追

踪性能,但是仍缺乏使用新颖有效的机器学习来进一步提升其长期学习能力. 比如,使用终身学习、深度强化学习、多任务学习等方法来辅助提高DMOEAs响应环境的速度和准度. 此外,有别于一些大样本/大数据的机器学习方法,针对特定环境或时刻,尤其是变化幅度剧烈和频率较快的场景,如何引入零样本/少样本学习来为算法寻优过程提供更“个性化”的信息,这是一个值得关注的研究方向.

2) 对于部分DMOPs而言,需要在较短时间内(即时变周期短)完成对其求解,故如何缩短计算时间也是一个亟需解决的问题. 高性能计算技术已经被广泛应用于人工智能的各个研究领域,然而在动态多目标优化领域只有少量类似研究^[76]. 考虑到部分动态多目标优化对实时性要求较高,研究基于高性能计算的动态多目标优化十分必要. 同时,由于计算资源限制,现有动态多目标进化优化算法无法处理更多的演化信息,甚至影响其追踪能力,故利用高性能计算技术可以为实际动态多目标优化问题的求解奠定技术基础.

3) 除了提高动态多目标进化算法的追踪性能外,其在动态环境下的适应性和鲁棒性也十分重要,这主要是由于空变和时变特性会对DMOPs的求解带来极大困难. 因此,如何使用自适应方法/技术实现动态多目标进化算法操作算子、参数、算法结构的自我调整十分关键. 此外,鉴于超启发式算法可以有效发挥不同算法的优势^[77-78],将其与动态多目标进化算法进行结合也是一个值得研究的问题.

4) 优化问题的搜索空间(空间特性)会随着其维度的增加而增大,大规模优化问题逐渐受到诸多学者的关注. 然而,目前极少有关于动态多目标大规模优化方面的研究,该研究方向将是未来进化计算研究所要亟需解决的难点之一,尤其是针对实际的动态多目标大规模优化问题,提出通用求解算法是未来研究的一个重要方向.

6 结 论

相比于静态优化问题,动态优化问题会更加贴近实际,也是一类更加普遍存在的优化问题. 这主要是由于现实优化问题的目标、决策变量、约束条件、决策变量等都会随着时间/环境的变化而发生改变. 同时,DMOPs是一类普遍存在的优化问题,且具有明显的时空变化特性. 因此,求解DMOPs不仅需要快速准确的环境变化检测能力,还需要DMOEAs具备良好的追踪性能和适应各种复杂环境的能力. 鉴于此,

研究人员提出不少有效的环境变化检测方法和追踪性能好、适应能力强、鲁棒性能好的DMOEAs. 本文主要从新的视角(即时空)对近5年(2018年~2022年)的DMOEAs算法进行综述. 首先,介绍了DMOPs的数学形式和基本概念;然后,对常用的动态多目标优化问题测试集和性能评价指标进行简要介绍,并从时空的角度详细阐述近5年DMOEAs的研究进展;最后,指出动态多目标优化所面临的挑战,并展望未来的研究方向.

参考文献(References)

- [1] Hua Y C, Liu Q Q, Hao K R, et al. A survey of evolutionary algorithms for multi-objective optimization problems with irregular Pareto fronts[J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(2): 303-318.
- [2] Tian Y, Si L C, Zhang X Y, et al. Evolutionary large-scale multi-objective optimization: A survey[J]. ACM Computing Surveys, 2022, 54(8): 1-34.
- [3] Fan Q Q, Cao B, Li N. Balancing broad and deep searches in evolutionary computation via a parallel zoning search[J]. Evolutionary Intelligence, 2022, 15(3): 1637-1656.
- [4] Xu D J, Jiang M, Hu W Z, et al. An online prediction approach based on incremental support vector machine for dynamic multiobjective optimization[J]. IEEE Transactions on Evolutionary Computation, 2022, 26(4): 690-703.
- [5] Zhao Q, Yan B, Shi Y H, et al. Evolutionary dynamic multiobjective optimization via learning from historical search process[J]. IEEE Transactions on Cybernetics, 2022, 52(7): 6119-6130.
- [6] Zhou W, Feng L, Tan K C, et al. Evolutionary search with multiview prediction for dynamic multiobjective optimization[J]. IEEE Transactions on Evolutionary Computation, 2022, 26(5): 911-925.
- [7] 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.
- [8] Gee S B, Tan K C, Abbass H A. A benchmark test suite for dynamic evolutionary multiobjective optimization[J]. IEEE Transactions on Cybernetics, 2017, 47(2): 461-472.
- [9] Helbig M, Engelbrecht A P. Benchmarks for dynamic multi-objective optimisation algorithms[J]. ACM Computing Surveys, 2014, 46(3): 1-39.
- [10] Jiang S Y, Yang S X. Evolutionary dynamic multiobjective optimization: Benchmarks and algorithm comparisons[J]. IEEE Transactions on Cybernetics,

- 2016, 47(1): 198-211.
- [11] Jiang S Y, Yang S X, Yao X, et al. Benchmark functions for the CEC'2018 competition on dynamic multiobjective optimization[R]. Newcastle University, 2018.
- [12] 郭一楠, 汤万宝, 陈国玉, 等. 动态多目标进化优化研究进展[J]. 信息与控制, 2021, 50(2): 162-173.
(Guo Y N, Tang W B, Chen G Y, et al. Research progress on dynamic multi-objective evolutionary optimization[J]. Information and Control, 2021, 50(2): 162-173.)
- [13] 马永杰, 陈敏, 龚影, 等. 动态多目标优化进化算法研究进展[J]. 自动化学报, 2020, 46(11): 2302-2318.
(Ma Y J, Chen M, Gong Y, et al. Research progress of dynamic multi-objective optimization evolutionary algorithm[J]. Acta Automatica Sinica, 2020, 46(11): 2302-2318.)
- [14] 刘若辰, 李建霞, 刘静, 等. 动态多目标优化研究综述[J]. 计算机学报, 2020, 43(7): 1246-1278.
(Liu R C, Li J X, Liu J, et al. A survey on dynamic multi-objective optimization[J]. Chinese Journal of Computers, 2020, 43(7): 1246-1278.)
- [15] Jiang S Y, Zou J, Yang S X, et al. Evolutionary dynamic multi-objective optimisation: A survey[J]. ACM Computing Surveys, 2023, 55(4): 1-47.
- [16] Nguyen T T, Yang S X, Branke J. Evolutionary dynamic optimization: A survey of the state of the art[J]. Swarm and Evolutionary Computation, 2012, 6: 1-24.
- [17] Azzouz R, Bechikh S, Ben Said L. Dynamic multi-objective optimization using evolutionary algorithms: A survey[J]. Recent Advances in Evolutionary Multi-objective Optimization, 2016: 31-70.
- [18] Deb K, Thiele L, Laumanns M, et al. Scalable test problems for evolutionary multiobjective optimization[C]. Advanced Information and Knowledge Processing. London: Springer-Verlag, 2005: 105-145.
- [19] Zitzler E, Deb K, Thiele L. Comparison of multiobjective evolutionary algorithms: Empirical results[J]. Evolutionary Computation, 2000, 8(2): 173-195.
- [20] 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.
- [21] 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.
- [22] Ruan G, Zheng J H, Zou J, et al. A random benchmark suite and a new reaction strategy in dynamic multiobjective optimization[J]. Swarm and Evolutionary Computation, 2021, 63: 100867.
- [23] Koo W T, Goh C K, Tan K C. A predictive gradient strategy for multiobjective evolutionary algorithms in a fast changing environment[J]. Memetic Computing, 2010, 2(2): 87-110.
- [24] Mehnen J, Rudolph G, Wagner T J S. Evolutionary optimization of dynamic multiobjective functions[R]. Berlin: University Stadtbibliothek Dortmund, 2006.
- [25] Biswas S, Das S, Suganthan P N, et al. Evolutionary multiobjective optimization in dynamic environments: A set of novel benchmark functions[C]. IEEE Congress on Evolutionary Computation. Beijing, 2014: 3192-3199.
- [26] Huang L, Suh I 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.
- [27] Zhou A M, Jin Y C, Zhang Q F, et al. Prediction-based population re-initialization for evolutionary dynamic multi-objective optimization[C]. Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2007: 832-846.
- [28] van Veldhuizen D A, Lamon G B. Evolutionary computation and convergence to a pareto front[C]. Late Breaking Papers at the Genetic Programming Conference. Piscataway: IEEE, 1998: 221-228.
- [29] Schott J R. Fault tolerant design using single and multicriteria genetic algorithm optimization[D]. Cambridge: Massachusetts Institute of Technology, 1995.
- [30] 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.
- [31] Zitzler E, Thiele L. Multiobjective evolutionary algorithms: A comparative case study and the strength Pareto approach[J]. IEEE Transactions on Evolutionary Computation, 1999, 3(4): 257-271.
- [32] Schutze O, Esquivel X, Lara A, et al. Using the averaged Hausdorff distance as a performance measure in evolutionary multiobjective optimization[J]. IEEE Transactions on Evolutionary Computation, 2012, 16(4): 504-522.
- [33] Zhang Z H, Qian S Q. Artificial immune system in dynamic environments solving time-varying non-linear constrained multi-objective problems[J]. Soft Computing, 2011, 15(7): 1333-1349.
- [34] van Veldhuizen D A, Lamont G B. On measuring multiobjective evolutionary algorithm performance[C]. Proceedings of the Congress on Evolutionary Computation. La Jolla, 2002: 204-211.

- [35] Branke J. Memory enhanced evolutionary algorithms for changing optimization problems[C]. Proceedings of the Congress on Evolutionary Computation-CEC99. Washington, 2002: 1875-1882.
- [36] Wang Y, Li B. Investigation of memory-based multi-objective optimization evolutionary algorithm in dynamic environment[C]. IEEE Congress on Evolutionary Computation. Trondheim, 2009: 630-637.
- [37] 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.)
- [38] Azzouz R, Bechikh S, Ben Said L. A dynamic multi-objective evolutionary algorithm using a change severity-based adaptive population management strategy[J]. Soft Computing, 2017, 21(4): 885-906.
- [39] Hatzakis I, Wallace D. Dynamic multi-objective optimization with evolutionary algorithms: A forward-looking approach[C]. Proceedings of the 8th Annual Conference on Genetic and Evolutionary Computation. Seattle, 2006: 1201-1208.
- [40] 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.
- [41] Zou F, Yen G G, Tang L X. A knee-guided prediction approach for dynamic multi-objective optimization[J]. Information Sciences, 2020, 509: 193-209.
- [42] Liang Z P, Zou Y, Zheng S X, et al. A feedback-based prediction strategy for dynamic multi-objective evolutionary optimization[J]. Expert Systems with Applications, 2021, 172: 114594.
- [43] Chen M, Ma Y J. Dynamic multi-objective evolutionary algorithm with center point prediction strategy using ensemble Kalman filter[J]. Soft Computing, 2021, 25(7): 5003-5019.
- [44] 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.
- [45] Sun H, Cao A R, Hu Z Y, et al. A novel quantile-guided dual prediction strategies for dynamic multi-objective optimization[J]. Information Sciences, 2021, 579: 751-775.
- [46] Xu P, Wu X M, Guo M, et al. A hybrid predictive strategy carried through simultaneously from decision space and objective space for evolutionary dynamic multiobjective optimization[J]. Wireless Communications and Mobile Computing, 2019, 2019: 1-17.
- [47] Rambabu R, Vadakkepat P, Tan K C, et al. A mixture-of-experts prediction framework for evolutionary dynamic multiobjective optimization[J]. IEEE Transactions on Cybernetics, 2020, 50(12): 5099-5112.
- [48] Wang F, Li Y X, Liao F S, et al. An ensemble learning based prediction strategy for dynamic multi-objective optimization[J]. Applied Soft Computing, 2020, 96: 106592.
- [49] Jiang M, Hu W Z, Qiu L M, et al. Solving dynamic multi-objective optimization problems via support vector machine[C]. The 10th International Conference on Advanced Computational Intelligence. Xiamen, 2018: 819-824.
- [50] Cao L L, Xu L H, Goodman E D, et al. Evolutionary dynamic multiobjective optimization assisted by a support vector regression predictor[J]. IEEE Transactions on Evolutionary Computation, 2020, 24(2): 305-319.
- [51] Zou F, Yen G G, Tang L X, et al. A reinforcement learning approach for dynamic multi-objective optimization[J]. Information Sciences, 2021, 546: 815-834.
- [52] Zou F, Yen G G, Zhao C. Dynamic multiobjective optimization driven by inverse reinforcement learning[J]. Information Sciences, 2021, 575: 468-484.
- [53] Ma X M, Yang J M, Sun H, et al. Feature information prediction algorithm for dynamic multi-objective optimization problems[J]. European Journal of Operational Research, 2021, 295(3): 965-981.
- [54] Ruan G, Minku L L, Menzel S, et al. When and how to transfer knowledge in dynamic multi-objective optimization[C]. IEEE Symposium Series on Computational Intelligence. Xiamen, 2020: 2034-2041.
- [55] Wang Z Z, Jiang M, Gao X, et al. Evolutionary dynamic multi-objective optimization via regression transfer learning[C]. IEEE Symposium Series on Computational Intelligence. Xiamen, 2020: 2375-2381.
- [56] Jiang M, Wang Z Z, Qiu L M, et al. A fast dynamic evolutionary multiobjective algorithm via manifold transfer learning[J]. IEEE Transactions on Cybernetics, 2021, 51(7): 3417-3428.
- [57] Jiang M, Wang Z Z, Hong H K, et al. Knee point-based imbalanced transfer learning for dynamic multiobjective optimization[J]. IEEE Transactions on Evolutionary Computation, 2021, 25(1): 117-129.
- [58] Jiang M, Wang Z Z, Guo S H, et al. Individual-based transfer learning for dynamic multiobjective optimization[J]. IEEE Transactions on Cybernetics, 2021, 51(10): 4968-4981.
- [59] He Q, Xiang Z, Ren P. An environmental selection

- and transfer learning-based dynamic multiobjective optimization evolutionary algorithm[J]. *Nonlinear Dynamics*, 2022, 108(1): 397-415.
- [60] Chen G Y, Guo Y N, Huang M Y, et al. A domain adaptation learning strategy for dynamic multiobjective optimization[J]. *Information Sciences*, 2022, 606: 328-349.
- [61] Guo Y N, Chen G Y, Jiang M, et al. A knowledge guided transfer strategy for evolutionary dynamic multiobjective optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2022(99): 1.
- [62] Ye Y L, Li L J, Lin Q Z, et al. Knowledge guided Bayesian classification for dynamic multi-objective optimization[J]. *Knowledge-Based Systems*, 2022, 250: 109173.
- [63] Ravichandran R, Kobti Z. Solving dynamic multi-objective optimization problems using cultural algorithm based on decomposition[C]. *Proceedings of the 3rd International Conference on Vision, Image and Signal Processing*. Vancouver, 2019: 1-6.
- [64] Ou J W, Zheng J H, Ruan G, et al. A Pareto-based evolutionary algorithm using decomposition and truncation for dynamic multi-objective optimization[J]. *Applied Soft Computing*, 2019, 85: 105673.
- [65] Liu R C, Yang P, Liu J D. A dynamic multi-objective optimization evolutionary algorithm for complex environmental changes[J]. *Knowledge-Based Systems*, 2021, 216: 106612.
- [66] Wang C F, Yen G G, Jiang M. A grey prediction-based evolutionary algorithm for dynamic multiobjective optimization[J]. *Swarm and Evolutionary Computation*, 2020, 56: 100695.
- [67] Wang C F, Yen G G, Zou F. A novel predictive method based on key points for dynamic multi-objective optimization[J]. *Expert Systems with Applications*, 2022, 190: 116127.
- [68] Wei L X, Guo Z Y, Fan R, et al. A prediction strategy based on special points and multiregion knee points for evolutionary dynamic multiobjective optimization[J]. *Applied Intelligence*, 2020, 50(12): 4357-4377.
- [69] Liu T Y, Cao L, Wang Z. A multipopulation evolutionary framework with Steffensen's method for dynamic multiobjective optimization problems[J]. *Memetic Computing*, 2021, 13(4): 477-495.
- [70] 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.
- [71] Xie H P, Zou J, Yang S X, et al. A decision variable classification-based cooperative coevolutionary algorithm for dynamic multiobjective optimization[J]. *Information Sciences*, 2021, 560: 307-330.
- [72] Hu Y R, Zheng J H, Jiang S Y, et al. Handling dynamic multiobjective optimization environments via layered prediction and subspace-based diversity maintenance[J]. *IEEE Transactions on Cybernetics*, 2023, 53(4): 2572-2585.
- [73] Zheng J H, Zhang Z Y, Zou J, et al. A dynamic multi-objective particle swarm optimization algorithm based on adversarial decomposition and neighborhood evolution[J]. *Swarm and Evolutionary Computation*, 2022, 69: 100987.
- [74] Liu R C, Li N X, Peng L Y, et al. A special point-based transfer component analysis for dynamic multi-objective optimization[J]. *Complex & Intelligent Systems*, 2023, 9(2): 1229-1245.
- [75] Li J X, Liu R C, Wang R N. A change type-based self-adaptive response strategy for dynamic multi-objective optimization[J]. *Knowledge-Based Systems*, 2022, 243: 108447.
- [76] Fan Q Q, Wang Y H, Ersoy O K, et al. Dynamic multi-objective optimization via sliding time window and parallel computing[C]. *Lecture Notes in Computer Science*. Cham: Springer International Publishing, 2021: 45-57.
- [77] Fan Q Q, Yan X F, Zhang Y L. Auto-selection mechanism of differential evolution algorithm variants and its application[J]. *European Journal of Operational Research*, 2018, 270(2): 636-653.
- [78] Fan Q Q, Zhang Y L, Li N. An autoselection strategy of multiobjective evolutionary algorithms based on performance indicator and its application[J]. *IEEE Transactions on Automation Science and Engineering*, 2022, 19(3): 2422-2436.

作者简介

范勤勤(1986—), 男, 副教授, 博士, 从事进化计算、机器学习、过程控制与优化等研究, E-mail: forever123fan@163.com;

李盟(1999—), 女, 硕士生, 从事进化计算、机器学习等研究, E-mail: lmmm166@163.com;

黄文焘(1988—), 男, 副教授, 博士, 从事交直流电力系统控制保护与稳定、舰船电力系统控制保护与能量管理、进化计算等研究, E-mail: hwt8989@sjtu.edu.cn;

姜庆超(1986—), 男, 教授, 博士, 从事复杂过程建模、监测、优化等研究, E-mail: qchjiang@ecust.edu.cn.