

# 控制与决策

Control and Decision

## 基于知识引导的自适应动态多模态差分进化算法

闫李, 马佳慧, 柴旭朝, 岳彩通, 于坤杰, 梁静, 瞿博阳

### 引用本文:

闫李, 马佳慧, 柴旭朝, 岳彩通, 于坤杰, 梁静, 瞿博阳. 基于知识引导的自适应动态多模态差分进化算法[J]. *控制与决策*, 2023, 38(11): 3048–3056.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0168>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 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>

#### 具有重组学习和混合变异的动态多种群粒子群优化算法

Dynamic multi-population particle swarm optimization algorithm with recombined learning and hybrid mutation

*控制与决策*. 2021, 36(12): 2871–2880 <https://doi.org/10.13195/j.kzyjc.2020.0898>

#### 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>

#### 基于迁移学习灰支持向量回归机的交互式进化计算

Interactive evolutionary computation based on transfer learning grey support vector regression

*控制与决策*. 2021, 36(10): 2399–2408 <https://doi.org/10.13195/j.kzyjc.2020.0420>

#### 基于阈值搜索的多目标人工蜂群算法

A multi-objective artificial bee colony based on limit search strategy

*控制与决策*. 2020, 35(8): 1793–1802 <https://doi.org/10.13195/j.kzyjc.2018.1512>

# 基于知识引导的自适应动态多模态差分进化算法

闫李<sup>1</sup>, 马佳慧<sup>1</sup>, 柴旭朝<sup>1</sup>, 岳彩通<sup>2</sup>, 于坤杰<sup>2</sup>, 梁静<sup>2</sup>, 瞿博阳<sup>1†</sup>

(1. 中原工学院 电子信息学院, 郑州 453000; 2. 郑州大学 电气工程学院, 郑州 453000)

**摘要:** 为充分利用问题求解过程知识, 提升动态多模态优化算法的计算资源利用效率, 提出一种基于知识引导的自适应动态多模态差分进化算法. 首先, 利用自组织映射神经网络实现种群自聚类, 形成稳定的小生境; 然后, 通过对种群全局知识和个体邻域知识的综合学习, 设计一种基于知识引导的自适应差分进化算法, 在对种群进化状态进行实时监测和分析的基础上, 逐层递进地引导不同种群个体自适应地选择最符合当前进化需求的变异方式, 提升种群搜索效率, 平衡种群多样性与收敛性; 最后, 针对问题动态特性, 设计一种基于历史动态过程知识引导的自适应动态响应机制, 通过对历史寻优经验的自适应学习, 预测生成新环境下的潜在精英个体, 引导种群实现精准快速的多峰定位. 实验结果表明, 所提出算法能够有效解决动态多模态优化问题, 且在不同动态环境设置下其求解性能均优于对比算法.

**关键词:** 多模态优化; 动态优化; 差分算法; 知识引导

**中图分类号:** TP18      **文献标志码:** A

**DOI:** 10.13195/j.kzyjc.2022.0168

**引用格式:** 闫李, 马佳慧, 柴旭朝, 等. 基于知识引导的自适应动态多模态差分进化算法[J]. 控制与决策, 2023, 38(11): 3048-3056.

## Adaptive dynamic multimodal differential evolution algorithm based on knowledge guidance

YAN Li<sup>1</sup>, MA Jia-hui<sup>1</sup>, CHAI Xu-zhao<sup>1</sup>, YUE Cai-tong<sup>2</sup>, YU Kun-jie<sup>2</sup>, LIANG Jing<sup>2</sup>, QU Bo-yang<sup>1†</sup>

(1. School of Electronic and Information, Zhongyuan University of Technology, Zhengzhou 453000, China; 2. School of Electrical Engineering, Zhengzhou University, Zhengzhou 453000, China)

**Abstract:** To fully use the knowledge of problem-solving process and improve the computational resource utilization efficiency of dynamic multimodal optimization algorithms, an adaptive dynamic multimodal differential evolution algorithm based on knowledge guidance is proposed. Firstly, a self-organizing mapping (SOM) neural network is used to realize the self-clustering of population and form some stable niches. Secondly, through the comprehensive learning of the population global knowledge and the individual neighborhood knowledge, a knowledge-guided adaptive differential evolution (KADE) algorithm is designed to layer by layer guide the individuals to adaptively choose the mutation strategies that best meets their evolutionary demands. The proposed algorithm can improve the search efficiency of population and balance the diversity and convergence. Finally, when a change happens, an adaptive dynamic response strategy based on the historical experience learning is proposed to predict the positions of the elite individuals in the new environment to achieve a fast convergence. Experimental results show that the proposed SOM-KADE shows superior performance compared with the state-of-the-art algorithms.

**Keywords:** multimodal optimization; dynamic optimization; differential evolution algorithm; knowledge guidance

## 0 引言

多模态优化 (multi-modal optimization, MMO) 问题是科学研究和工程实践中普遍存在的一类优化

问题, 其解空间中可能存在多个全局最优解以及若干局部最优解<sup>[1-4]</sup>, 且通常所指的多模态优化问题一般属于静态问题. 然而, 在实际应用中, 问题环境的

收稿日期: 2022-01-23; 录用日期: 2022-06-24.

基金项目: 国家自然科学基金项目 (62103456, 61976237, 61922072, 61876169); 河南省高校科技创新团队支持计划项目 (22IRTSTHN015); 河南省自然科学基金项目 (202300410511, 212300410321); 中原英才计划项目 (ZYQR201810162); 河南省高等学校青年骨干教师培养计划项目 (2021GGJS111).

责任编辑: 张国山.

†通讯作者. E-mail: quboyang@zut.edu.cn.

\*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

不确定性或问题本身蕴含的动态特性,导致待优化问题会随时间发生动态改变,转化为动态多模态优化问题(dynamic multi-modal optimization problems, DMMOPs)<sup>[5-6]</sup>. 该类问题不仅包含多模态特性,且包含动态特性,如电力系统调度中风电出力的不确定性<sup>[7]</sup>,无人机路径规划中障碍物的出现或地形的动态变化<sup>[8]</sup>. 动态特性的引入加剧了多模态优化问题的复杂度和求解难度,对现有多模态优化算法提出了巨大挑战.

在DMMOPs中,峰的位置和形状会随时间发生动态改变<sup>[9]</sup>,因此,算法求解的关键是如何在优化时间或计算资源受限的情况下,实现对当前环境多个峰值最优解的快速追踪和精确定位. 传统静态多模态优化算法<sup>[2-3]</sup>虽然能够有效地求得问题中一个或多个最优解,但是算法一旦收敛,会导致种群多样性丢失,在问题环境发生改变后,很难对新环境作出及时响应,无法实现对新环境问题的高效求解<sup>[10]</sup>.

现有方法虽然在解决DMMOPs上取得了一定效果,但是仍然存在以下问题.

1) 在动态响应环节,现有算法大多采用简单的历史环境最优解保留机制<sup>[11]</sup>. 但是该方法对历史信息的使用较为盲目,缺少对先前环境寻优过程知识的深度挖掘和学习,可能会影响算法在动态环境,特别是复杂动态环境中的收敛性能<sup>[11-12]</sup>. 因此,如何从历史环境寻优经验中获取动态环境变化模式的相关信息和知识,并据此实现对新环境峰值位置的自适应预测是动态多模态优化算法亟待解决的关键问题.

2) 现有动态多模态算法的研究大多仍然延续传统静态多模态优化算法的思路,算法设计主要集中于问题多模态特性的求解,针对进化算法本身关注不够. 然而,DMMOPs的时变特征要求进化算法能够高效利用有限的计算资源,实现对新环境多峰位置的快速精确定位<sup>[13]</sup>. 因此,为提升算法搜索效率,对种群进化过程知识进行有效提取和高效利用,进而引导个体在有限的计算资源内实现快速准确的收敛可能是一种行之有效的思路.

基于上述分析,本文提出一种基于知识引导的自适应动态多模态差分进化算法. 采用自组织映射神经网络(self organizing feature map, SOM)自适应确定种群个体邻域成员,避免敏感参数对算法性能的影响;通过监测种群进化状态,实时获取种群进化需求,及时增补种群多样性,提高算法的多样性控制能力,避免种群陷入进化停滞. 在此基础上,提出一种基于知识引导的自适应差分算法,通过对种群全局知识

和个体邻域知识的综合学习,实现个体自适应分层变异,提高种群进化效率,同时平衡算法的全局探索与局部开采能力;在动态响应环节,提出基于历史动态过程知识引导的自适应响应机制,通过对历史环境精英个体的自适应知识学习,生成新环境下的潜在精英个体,实现对新环境多个峰值位置的精确预测,帮助算法实现精准快速的多峰定位.

## 1 基于知识引导的自适应动态多模态差分进化算法

本文通过对种群进化过程知识和历史动态过程知识的高效利用,提升算法进化搜索效率以及动态响应环节的自适应能力,最终提出一种基于知识引导的自适应动态多模态差分进化算法. 算法主要包括基于自组织映射网络的小生境生成策略、基于知识引导的自适应差分算法和基于历史动态过程知识引导的自适应动态响应机制3部分.

算法整体流程如下.

step 1: 初始化种群,并对个体进行适应度值评估;

step 2: 判断是否满足终止条件;

step 3: 检测环境是否发生变化,若环境发生改变,则跳至step 6;

step 4: 使用SOM确定个体邻域;

step 5: 执行基于知识引导的自适应差分算法,返回至step 2;

step 6: 执行基于历史动态过程知识引导的自适应动态响应机制,返回至step 4.

### 1.1 基于自组织映射网络的小生境生成策略

本文利用SOM对数据自聚类特性<sup>[14]</sup>,实现对种群个体邻域精准划分. 首先,随机选取种群半数成员作为训练集对SOM进行训练,待网络完成训练后,依次将个体 $x_i$ 送入输入层,在网络输出层上找到其获胜神经元和相邻神经元;然后将映射在邻域神经元上的种群个体作为 $x_i$ 的邻域个体,实现对个体邻域的划分.

### 1.2 基于知识引导的自适应差分算法

受其动态特性的影响,DMMOPs每个多模环境的静态持续时间有限,这便要求优化算法能够高效利用有限的计算评价资源,在下一个环境来临前,及时找到并精准定位当前问题的多个峰值最优解. 因此,如何充分利用种群进化过程知识,引导种群在有限的评价次数内实现快速精准的收敛,是高质量求解DMMOPs的关键. 但是传统DE算法只是通过简单的变异交叉算子生成子代<sup>[15]</sup>,对进化过程知识的使用比较单一,在面对DMMOPs时,可能无法满足问题求

解对收敛速度和多样性双重要求.

因此,本文提出一种基于知识引导的自适应差分算法(knowledge-guided adaptive differential evolution, KADE),在提取当前种群进化状态知识的基础上,对种群个体进化需求进行逐层分析和学习,依据不同个体差异化的进化需求,引导个体自适应选择最匹配当前进化状态的变异方式,在避免计算资源浪费的同时,帮助种群实现快速精准的多峰定位.算法主要包含3个步骤:首先,通过实时监测种群进化状态,对种群的进化过程知识进行提取、分析和学习,实现对种群个体进化需求的准确判断;然后,设计一种新的多样性增强策略,当检测到种群进化出现停滞时,帮助种群跳出当前停滞区域;最后,提出基于分层变异的自适应差分进化算法,依据种群和个体的进化状态,自适应选择最符合当前个体的变异方式,引导个体向种群全局进化信息和邻域信息进行知识学习.

### 1.2.1 基于种群进化状态信息的知识提取

在多峰环境中,当种群对覆盖区域经过一段时间的搜索后,种群个体可能会在部分峰值区域周围聚集,陷入搜索停滞,导致种群对解空间的探索不足,从而丢失部分解空间最优峰.为此,本文提出一种基于种群进化状态信息的知识提取策略,以实时监测种群的进化状态,并在对种群进化过程知识提取和分析的基础上,对种群进化状态作出准确判断,进而为个体进化策略的选择提供依据,提升算法的自适应能力.

该策略通过计算种群个体最优适应度值在进化过程中的变化程度 $\theta$ ,实现对当前种群进化状态的监测和识别.将每代种群中最优个体的适应度值 $f_{\text{best}}(g)$ 存储至 $F_{\text{best}}$ , $g$ 为迭代次数.通过下式对 $\theta$ 进行计算:

$$\theta = \frac{\sum_{y=2}^{\varphi} |F_{\text{best}}(y) - F_{\text{best}}(y-1)|}{\varphi}, \quad (1)$$

其中 $\varphi$ 为监测周期.由式(1)可知, $\theta$ 为种群在一定搜索周期内的进化程度.

该策略通过对种群进化过程知识的提取和分析,判断种群当前进化状态,使得算法能够实时获取种群进化需求,为算法自适应选择进化策略,实现多峰精准定位提供知识引导.

### 1.2.2 多样性增强策略

在进化过程中,为避免进化停滞,在算法中引入一种新的多样性增强策略.该机制在保留当前寻找到的多个峰值最优解的基础上,引导种群其他个体跳出当前局部区域,向其他未探索区域移动,提高种群

多样性和探索能力.具体操作如下:

$$\text{Current\_pop}(g) = \{\text{pop} \setminus \text{Current\_best}(g)\}. \quad (2)$$

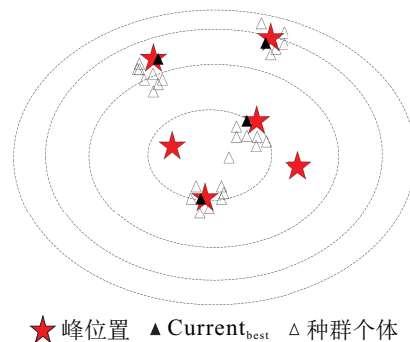
$$V_i = x_{r_1} + F(x_{r_2} - x_{r_3}),$$

$$x_{r_1} \neq x_{r_2} \neq x_{r_3} \neq x_i \in \text{Current\_pop}(g). \quad (3)$$


$$x_{ij} = \begin{cases} v_{ij}, & \text{rand}_j(0, 1) \leq \text{CR or } j = j_{\text{rand}}; \\ x_{ij}, & \text{otherwise.} \end{cases} \quad (4)$$

首先,算法基于SOM对当前种群进行聚类,找出种群中优秀个体并存储至 $\text{Current\_best}(g)$ ,按式(2)生成 $\text{Current\_pop}(g)$ ;然后,对 $\text{Current\_pop}(g)$ 中的个体采用如式(3)和(4)所示的经典DE/rand/1变异算子和交叉算子,对 $\text{Current\_pop}(g)$ 中的个体位置更新,引导个体向未探索区域移动;最后,将 $\text{Current\_best}(g)$ 与更新后的 $\text{Current\_pop}(g)$ 进行合并,生成新的 $\text{pop}(g)$ 继续对当前环境进行寻优.

上述多样性增强策略的工作过程如图1所示.红色五角星为解空间中真实峰的位置,黑色三角形为当前种群通过SOM聚类找到的最优个体,即 $\text{Current\_best}(g)$ .由图1(a)可见,当前环境的解空间中有2个峰仍然未搜索到,但是当前种群在解空间中已出现收敛停滞状态;此时多样性增强策略触发,如图1(b)所示,算法在保留最优个体 $\text{Current\_best}$ 的基础上,帮助陷入停滞状态的种群个体跳出当前最优区域,向解空间未探索区域移动,提升了当前种群的多样性和探索能力.



(a)  $g$ 时刻呈现收敛状态种群



★ 峰位置 ▲  $\text{Current\_best}$  △ 种群个体

(b)  $g$ 时刻执行过多样性增强策略种群

图1 种群多样性增强策略示意图

### 1.2.3 基于分层变异的自适应差分进化算法

传统DE算法对种群进化过程知识的使用比较单一,在面临DMMOPs时,可能无法满足问题求解对收敛速度和多样性的双重要求.为提升DE算法的自适应能力,保证算法能够在有限的计算资源内实现对当前环境多个峰值最优解的准确快速定位,本文在传统DE基础上,设计一种基于知识引导的自适应分层变异策略,通过对种群进化过程知识的综合学习,逐层递进地引导不同进化状态的种群个体自适应地选择最佳变异方式,满足不同个体的进化需求.算法流程如图2所示.

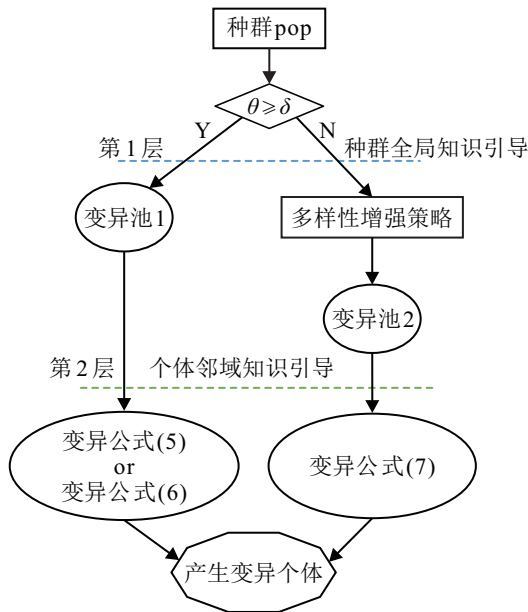


图2 基于分层变异的自适应差分进化算法流程

首先,算法从种群整体进化需求出发,依据所提取的种群进化状态信息进行全局知识学习;然后,通过设置进化程度阈值 $\delta$ 对 $\theta$ 进行判断,引导种群自适应地选择最佳变异池.若 $\theta \geq \delta$ ,则种群可能仍然在快速向最优解靠拢,判断种群对当前区域未充分寻优,此刻应增强种群的收敛性和开采能力;若 $\theta < \delta$ ,则当前种群在一定周期内的搜索进化程度较小,判断种群可能对当前覆盖区域充分寻优,此刻需要提高种群多样性,以增强种群对解空间其他区域的探索能力.具体过程如下.

若 $\theta \geq \delta$ ,则引导种群进入变异池1.在变异池1中,包含两种变异方式,算法通过对个体位置信息以及邻域知识的学习,引导个体自适应选择最符合其进化需求的变异方式.首先,通过SOM找到当前代最优个体并存储至 $\text{Current}_{\text{best}}(g)$ ;然后,判断当前个体 $x_i$ 是否为 $\text{Current}_{\text{best}}$ 成员,若 $x_i \in \text{Current}_{\text{best}}$ ,则依据下式进行变异:

$$v_i = x_i + \text{normrnd}(0, 1). \quad (5)$$

在保留 $x_i$ 当前位置信息的基础上,进一步提升其寻优精度;若 $x_i \notin \text{Current}_{\text{best}}$ ,则进一步对其邻域信息进行分析学习,引导个体依据下式进行变异:

$$v_i = \begin{cases} x_{\text{nbest}} + F(x_{n_{r_1}} - x_{n_{r_2}}), & f(x_i) \leq \bar{f}; \\ x_i + F(x_{g_{r_1}} - x_{g_{r_2}}), & \text{otherwise.} \end{cases} \quad (6)$$

其中: $\bar{f}$ 为 $x_i$ 邻域成员平均适应度值; $x_{n_{r_1}}$ 和 $x_{n_{r_2}}$ 为从 $x_i$ 的邻域 $S$ 中随机选择的个体, $x_{n_{r_1}} \neq x_{n_{r_2}} \neq x_i \in S$ ; $x_{g_{r_1}}$ 和 $x_{g_{r_2}}$ 为从种群中随机选择的个体, $x_{g_{r_1}} \neq x_{g_{r_2}} \neq x_i \notin S$ .若 $f(x_i) \leq \bar{f}$ ,则表明 $x_i$ 是其邻域内较差个体,此刻用邻域最优个体 $x_{\text{nbest}}$ 对 $x_i$ 进行引导,提升其收敛速度并对邻域区域进行充分搜索;若 $f(x_i) > \bar{f}$ ,则表明 $x_i$ 为当前邻域内较优个体,很可能处于峰周围区域,此刻变异基于当前个体进行,并加入全局扰动,保证变异个体 $v_i$ 能够继承父代优势,同时避免 $x_i$ 为局部峰值状况.

若 $\theta < \delta$ ,则引导种群进入变异池2.当前种群在选择进入变异池2前,应先经过多样性增强策略的处理,以帮助种群跳出当前收敛区域,提升其全局探索能力.然而,多样性增强策略对于个体的引导相对盲目,并未使用个体邻域信息和知识.因此,为进一步增强种群探索能力,有效引导个体向未探索峰值移动,变异池2依据个体 $x_i$ 在邻域内的适应度水平,引导 $x_i$ 对以下两种变异方式进行自适应选择:

$$v_i = \begin{cases} x_i + \frac{f(x_{g_{r_3}}) - f(x_{g_{r_4}})}{f(x_{\text{gbest}}) - f(x_{\text{worst}})} \times (x_{g_{r_3}} - x_{g_{r_4}}), & f(x_i) > \bar{f}; \\ x_i + \text{normrnd}(0, 1), & \text{otherwise.} \end{cases} \quad (7)$$

其中: $x_{\text{gbest}}$ 和 $x_{\text{gworst}}$ 为当前种群内适应度最优和最差个体; $x_{g_{r_3}}$ 和 $x_{g_{r_4}}$ 为从种群中随机选择的个体, $x_{g_{r_3}} \neq x_{g_{r_4}} \neq x_i \notin \text{Current}_{\text{best}}$ .根据式(7),若 $f(x_i) > \bar{f}$ , $x_i$ 为邻域内较优个体,则通过引入高斯扰动,引导个体在当前位置周围进行变异,增强局部开采能力;若 $f(x_i) \leq \bar{f}$ ,则通过 $x_{g_{r_3}}$ 和 $x_{g_{r_4}}$ 的适应度值对比控制 $x_i$ 的搜索方向<sup>[16]</sup>,当 $f(x_{g_{r_3}}) > f(x_{g_{r_4}})$ 时,个体 $x_i$ 向其周围可能存在峰的区域移动,增强其局部开采能力,当 $f(x_{g_{r_3}}) < f(x_{g_{r_4}})$ 时,则帮助 $x_i$ 跳出当前所在区域向其他峰值区域移动,增强其全局探索能力.

在变异操作完成后,执行交叉和选择操作.学习率 $F$ 和交叉率 $\text{CR}$ 控制种群个体的学习变异程度,而算法在求解DMMOPs时,种群个体在不同时刻对变异程度的需求不同.因此,为找到更符合种群 $g$ 时刻进化需求的 $F$ 和 $\text{CR}$ ,本文设计一种新的参数自适应调整策略,具体计算如下式所示:

$$F(i) = \frac{\sum \text{Succ}_F}{\text{size}(\text{Succ}_F)}, \quad (8)$$

$$CR(i) = \frac{\sum Succ\_CR}{size(Succ\_CR)}. \quad (9)$$

其中  $Succ\_F$  和  $Succ\_CR$  分别存储进化过程中子代成功替换父代时的学习率和交叉率. 通过计算  $Succ\_F$  与  $Succ\_CR$  的平均值, 实时调整个体  $x_i$  的  $F(i)$  和  $CR(i)$ . 初始时刻  $F_0(i)$  和  $CR_0(i) \in \text{rand}(0, 1)$ .

### 1.3 基于历史动态过程知识引导的自适应动态响应机制

为深度挖掘并充分利用历史环境寻优信息, 本文提出一种基于历史动态过程知识引导的自适应动态响应机制. 所提出算法通过对先前环境动态过程所积累的寻优经验知识的自适应学习, 引导相邻环境中的精英个体生成新环境下的潜在精英个体, 实现算法对新环境下峰值位置的精确预测, 保证新生成种群的收敛速度; 同时, 对剩余个体进行随机重初始化, 保证种群对新环境的探索能力.

假设当前环境时刻为  $t$ . 首先, 基于 SOM 找出  $t$  时刻种群中的精英个体  $Elite\_indi$ , 重新计算  $Elite\_indi$  适应度值, 判断环境是否发生变化. 若环境发生变化, 则存储  $Elite\_indi$  至  $Elite(t)$ ; 然后, 通过下式对历史动态过程知识进行挖掘和分析, 计算  $Elite$  中相邻环境精英个体移动步长的平均值  $L$ :

$$L = \frac{\sum_{t=2}^{size(Elite)} (Elite(t) - Elite(t-1))}{size(Elite)}, \quad (10)$$

并利用  $L$  对新环境中的峰值位置进行预测, 生成新环境下的潜在精英个体  $Predi\_indi(t+1)$ , 即

$$Predi\_indi(t+1) = \text{Gaussian}(Elite\_indi, L). \quad (11)$$

式(11)中: 采用高斯变异方式, 设置均值为  $Elite\_indi$ , 标准差为  $L$ , 围绕  $t$  时刻中的精英个体  $Elite\_indi$  对  $t+1$  时刻生成预测个体  $Predi\_indi(t+1)$ . 种群中的其余个体按下式进行随机初始化:

$$\text{New\_indi}(t+1) = \text{rand} \times (x_{\max} - x_{\min}) + x_{\min}. \quad (12)$$

最后, 预测种群与初始化种群组合生成新环境下的初始种群为

$$\text{pop}(t+1) = \text{predi\_indi}(t+1) + \text{New\_indi}(t+1). \quad (13)$$

该响应机制通过对预测精英个体移动步长的自适应控制, 实现算法对历史动态过程知识的自适应学习, 保证算法在面对不同环境变化程度时均能够作出快速有效的响应, 提升算法在动态环境下的鲁棒性.

## 2 实验仿真和结果分析

### 2.1 实验设置

本文选用移动峰值基准测试函数<sup>[9]</sup>(moving peaks benchmark, MPB) 验证所提出算法和策略在求解 DMMOPs 时的有效性. 采用的性能指标为离线误差<sup>[12, 17-18]</sup>以及种群多样性水平<sup>[19]</sup>. 实验所需的其他参数设置如下: 种群规模  $NP$  为 100, 进化程度阈值  $\delta$  为 0.001, 监测周期  $\varphi$  为 10<sup>[19]</sup>, 预测精英个体数为 5; 最大评价次数为 500 000, 环境总数  $T$  为 100, MPB 其他参数设置如表 1 所示, 算法独立运行次数为 30.

表 1 MPB 函数的参数设置

参数名称	参数值
峰的数量	10
变化频率 $U$	5 000
峰的高度变化参数 (height_severity)	7.0
峰的宽度变化参数 (width_severity)	1.0
峰的形状	锥形
有无基础函数	无
位移长度 $S$	1.0
维度 $D$	5
相关性系数 $\lambda$	0
解空间范围	[0, 100]
峰高度变化范围	[30.0, 70.0]
峰宽度变化范围	[1, 12]
峰初始高度	50.0

### 2.2 所提出策略有效性验证

本节通过展示离线误差收敛曲线, 进化过程中种群实时分布、多样性水平变化曲线以及所提出策略消融实验分析, 验证不同策略的有效性.

为验证所提出算法在动态环境中收敛速度, 给出了前 10 个环境下的离线误差变化曲线, 实验结果为所提出算法独立运行 30 次的平均值. 实验环境设置为: 环境变化频率  $U$  为 5 000, 峰数为 10, 峰移动步长  $S$  为 1, 实验结果如图 3 所示. 算法在第 1 环境中需要消耗 4 600 个评价次数才能趋于收敛. 但是, 在后续的 9 个环境中, 算法收敛所消耗的评价次数逐渐减少, 在第 6 环境中收敛所需评价次数减少至 2 000 个, 在第 10 环境中则仅需 1 300 个评价次数. 这是因为, 所设计的基于历史动态过程知识引导的自适应动态响应机制能够利用算法在先前环境中的寻优经验和知识, 实现对新环境下峰值位置的精准预测, 提升种群在新环境中的收敛速度. 同时, 随着动态环境的持续演进, 算法对历史经验知识的积累将不断增加, 其预测精度也会持续改进, 因此在后续环境中算法收敛所消耗的评价次数呈现减少趋势; 此外, 所设计的自适应分层变异策略能够依据个体进化需求匹配最佳变异方式, 进一步提升了种群的搜索效率和收敛速度.




图 3 SOM\_KADE 离线误差收敛曲线

为进一步验证算法中各策略的有效性,将对所提出策略进行消融实验,3种变体算法分别为:1) 仅将SOM\_KADE中的分层变异策略替换为基于随机概率选择变异策略的方式,供选择变异策略包括:  $DE \setminus target\_to\_best \setminus 1, DE \setminus best \setminus 2, DE \setminus rand \setminus 1, DE \setminus rand \setminus 2$ ; 2) 仅将SOM\_KADE算法中的响应策略替换为以下方法进行对比:当环境发生变化时,使用前一环境中搜索到的最优解作为初始种群的一部分个体,而另一部分个体随机初始化; 3) 仅剔除SOM\_KADE算法中的多样性增强策略的方式. 实验参数设置如下:峰值个数分别为2、5、10、20、30、50、100,变化频率为5000,峰移动步长为1,实验结果为独立运行30次的平均值. 实验结果如图4所示,由图4可见,随着环境中峰值个数的不断增加,算法寻优难度逐渐增大,但是所提出SOM\_KADE算法在不同峰值个数时均表现出最优性能. 图中蓝色曲线表明,所设计的基于历史动态过程知识引导的自适应动态响应机制能够大幅提升算法在求解动态多模态问题时的性能,问题峰值个数越多,性能优势越明显. 此外,与其他两种变体算法相比,SOM\_KADE在不同峰值个数设置下的求解性能均有所提升,验证了分层变异和多样性增强策略的有效性能.

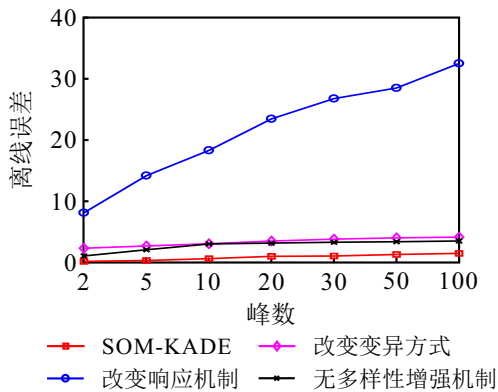


图 4 SOM\_KADE 与其不同变体的性能对比

### 2.3 与其他算法的对比

本节选取现有经典动态多模态优化算法与SOM\_KADE在一系列不同参数设置的MPB函数上

进行对比实验,验证所提出算法在不同测试环境下的求解性能. 其中测试环境包括:改变峰数、变化频率、移动长度  $S$  以及相关系数  $\lambda$ ,在此仅展示不同峰数环境下的实验结果. 所选对比算法包括:mQSO<sup>[20]</sup>、CDDE\_Ar<sup>[17]</sup>、CPSO<sup>[12]</sup>、PSO\_CP<sup>[21]</sup>、CPSO\_NN-IT<sup>[11]</sup>、CDDE\_Ar\_NNIT<sup>[11]</sup>、CDER<sup>[18]</sup>、CESO<sup>[22]</sup>、SPSO<sup>[23]</sup>、DynDE<sup>[24]</sup>、rSPSO<sup>[25]</sup>、ESCA<sup>[22]</sup>、DASA<sup>[26]</sup>、HmSO<sup>[27]</sup>.

表2为所有算法在不同数量峰时的离线误差性能对比,表2给出的offline\_error值为算法运行30次的平均值,不同峰个数下的最优结果加粗显示. MPB其他参数设置如表1所示. 由表2可见,随着峰个数的增加,所有算法的离线误差均逐渐增大,这是因为在有限计算资源下,峰个数越多,算法实现多峰精准定位越困难. 然而,所提出算法在绝大多数实验环境中均表现最优;在峰数为2时,仅次于CPSO,峰个数为100时,稍差于CPSO与CESO,但是仍然处于同一量级. 这表明所提出多样性增强策略和分层变异策略能够自适应控制种群多样性,有效解决在DMMOPs中多样性与收敛性难以平衡的问题.

### 2.4 复杂动态环境下算法性能分析

在第2.1节实验设置中,已默认当环境发生变化时,当前环境内所有峰均会发生改变. 因此,基于最优解适应度值是否变化的动态检测机制很容易监测到环境变化,进而驱动动态响应机制工作. 但是,在实际动态多模态问题中,环境变化时可能仅有部分峰发生改变. 此时,算法检测到环境发生变化的难度增加,甚至无法作出及时响应,直接影响算法的求解性能. 因此,本节在MPB问题中引入变化峰值比例(cpeak)<sup>[28]</sup>,即仅令问题环境的部分峰发生变化,验证所提出算法在复杂动态环境下的求解性能,cpeak分别设置为0.1、0.3、0.5、0.7、0.9、1. 0.1表示仅有10%的峰值发生变化,1表示全部峰均发生变化,实验其他参数设置与第2.1节一致,实验结果如图5所示.

由图5可见,当cpeak较小时,大部分算法的离线误差值增大,优化性能降低. 这表明,当cpeak较小时,算法成功检测到环境变化的难度增加,已收敛种群无法及时增加多样性,影响种群在新环境下的探索能力. 此外,由图5可见,所提出算法的离线误差值随cpeak的变化,波动较小,表现出较强的鲁棒性. 这主要是因为SOM\_KADE中引入了种群进化状态信息检测机制以及多样性增强策略,使得算法能够实时检测种群进化状态,即使动态检测机制失效,仍然能够及时检测到种群进化发生停滞,进而启动多样性增强策略,保证种群在新环境中的探索能力.

表2 不同数量峰条件下算法离线误差均值(标准差)对比

算法	峰数						
	2	5	10	20	30	50	100
CPSO	<b>0.0056</b> (0.01)	0.36 (0.15)	0.71 (0.10)	1.18 (0.09)	1.34 (0.07)	1.42 (0.07)	<b>1.09</b> (0.03)
CDER	2.60 (0.63)	8.02 (0.34)	5.52 (0.16)	7.49 (0.27)	5.51 (0.12)	5.79 (0.15)	4.12 (0.1)
mCPSO	3.36 (0.26)	2.07 (0.08)	2.08 (0.07)	2.64 (0.07)	2.63 (0.08)	2.65 (0.06)	2.49 (0.04)
rSPSO	1.10 (0.03)	1.04 (0.03)	1.50 (0.08)	2.20 (0.07)	2.62 (0.07)	2.72 (0.08)	2.93 (0.06)
mQSO	3.47 (0.23)	1.81 (0.07)	1.80 (0.06)	2.42 (0.07)	2.48 (0.07)	2.50 (0.06)	2.36 (0.04)
ESCA	— —	— —	1.54 (0.02)	1.89 (0.04)	1.52 (0.02)	1.67 (0.02)	1.61 (0.01)
CESO	— —	— —	1.38 (0.02)	1.72 (0.02)	1.24 (0.01)	1.45 (0.01)	1.28 (0.02)
PSO_CP	— —	— —	1.31 (0.06)	— —	2.02 (0.07)	2.14 (0.08)	2.04 (0.07)
SPSO	2.31 (0.11)	2.15 (0.07)	2.51 (0.01)	3.21 (0.07)	3.64 (0.07)	3.84 (0.08)	4.01 (0.07)
HmSO	— —	1.18 (0.04)	1.42 (0.04)	1.50 (0.06)	1.65 (0.04)	1.66 (0.06)	1.68 (0.03)
SOM_KADE	0.20 (0.06)	<b>0.35</b> (0.01)	<b>0.65</b> (0.03)	<b>1.03</b> (0.01)	<b>1.08</b> (0.03)	<b>1.33</b> (0.10)	1.51 (0.02)




图5 不同cpeak下算法性能对比

### 3 实际应用

为验证所提出算法在解决实际问题时的优化性能,将所提出算法应用于无人机航迹规划问题中.在无人机执行攻击任务时,为提高执行任务的隐蔽性,同时防止多个无人机关间发生飞行碰撞,提高任务执行效率,需要求解出多条路径供无人机选择;此外,无人机野外飞行时经常会伴随环境的某些动态变化,如出现鸟类,环山地区出现剧烈“山风”等.这些不确定因素会对无人机飞行构成动态威胁,这便要求算法能够及时对这些动态威胁作出响应,重新规划飞行航迹.

本文假设以山脉为主要地形特征,无人机不能穿

越山脉飞行<sup>[29]</sup>;用几何球体的数学模型作为威胁代价<sup>[30]</sup>,模拟军事中的雷达探测、防空炮区域以及动态威胁区域;航迹长度使用最为常用的距离代价计算公式<sup>[29]</sup>.同时,通过设置以下两种场景类型验证所提出算法在解决实际问题时的优化性能以及在复杂环境中自适应能力:场景1,动态威胁区域靠近起飞点;场景2,多个动态威胁区域出现在无人机飞行过程中.地貌环境和威胁区域的俯视图如图6所示.

实验结果如图6所示,图6(a)为所提出算法在场景1中求得的飞行航迹,由图6(a)可见,所提出算法规划出的多条航迹均能够有效规避飞行区域中的威胁区域,其中红线为无人机在飞行过程中无动态威胁时的最优路径,蓝色虚线为出现动态威胁时算法重新规划出的最优路径.实验结果表明,当动态威胁临时出现于起飞点附近时,所提出算法依然能够作出快速准确的响应,重新规划出能够避开新威胁的航迹,表明所提出算法拥有在环境发生改变时对航迹进行自适应实时调整的能力.图6(b)为场景2的实验结果,蓝色虚线为所提出算法在出现多个动态威胁时重新规划出的可行航迹.由图6(b)可见,所提出算

法调整后的航迹变化幅度最小且响应耗时最少,表现出较强的自适应性和鲁棒性. 绿色虚线为算法 CPSO 重新规划结果, 该航迹虽然能成功躲避动态威胁, 但是与所提出算法结果相比航迹调整幅度较大且响应耗时较多. 而算法 SPSO 的重新规划航迹仅成功躲避动态威胁区域 2, 如图 6(b) 中粉色虚线所示. 由表 3 可见, SOM\_KADE 在算法 30 次运行的最优值、最差值和平均值 3 方面均表现最优, 验证了所提出算法求解该问题的优越性.

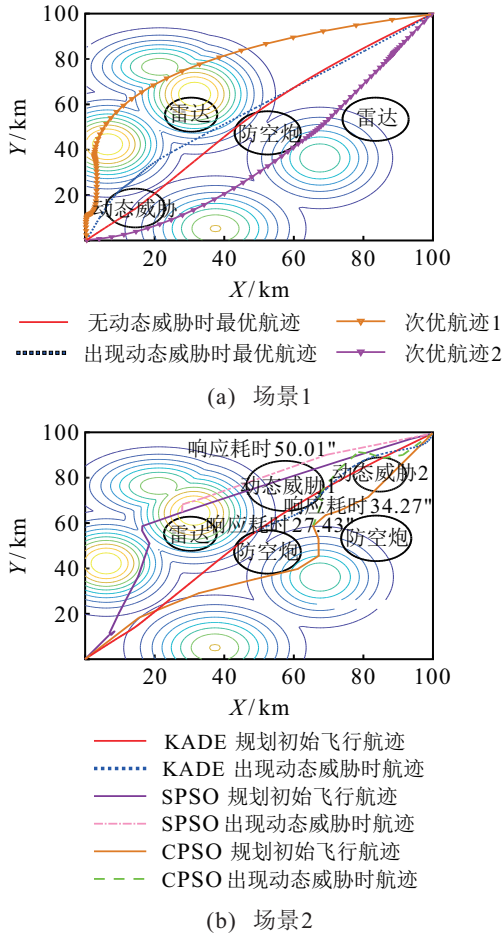


图 6 无人机飞行航迹示意图

表 3 不同算法航迹代价统计结果比较

算法	最优值	最差值	平均值
CPSO	184.47	194.67	189.57
SPSO	195.66	212.18	203.92
SOM_KADE	<b>141.80</b>	<b>187.13</b>	<b>164.47</b>

### 4 结 论

所提出算法基于对种群进化过程信息的知识提取, 实时跟进种群进化需求, 通过多样性增强策略和基于知识引导的自适应分层变异策略协同作用, 高效利用静态持续环境中的有限评价资源, 实现在动态环境中的多峰收敛; 在响应环节, 算法基于对历史寻优经验的自适应学习生成新环境下的预测精英个体, 同时结合随机重初始化个体, 在提升新种群收敛速度的

同时保持其多样性.

在对比实验中, 通过改变峰数量、环境变化频率等参数, 验证了基于知识引导的自适应分层变异策略的有效性, 即使在环境变化速度加快、多峰的情况下所提出算法依然能够在有限评价资源内实现对解空间精准快速的多峰定位; 通过增大动态环境变化程度, 进一步验证了所提出动态响应机制的有效性和鲁棒性. 此外, 复杂动态环境下的实验结果表明, SOM\_KADE 通过各策略的协同作用, 在动态环境仅发生部分变化时, 依然表现出较好的优化性能和鲁棒性. 最后将所提出算法应用于无人机航迹规划问题中, 实验结果表明, SOM\_KADE 能够有效求解该问题.

### 参考文献 (References)

- [1] Xu P L, Luo W J, Xu J F, et al. An alternative way of evolutionary multimodal optimization: Density-based population initialization strategy[J]. Swarm and Evolutionary Computation, 2021, 67: 100971.
- [2] Dai Z Y, Fang W, Tang K, et al. An optima-identified framework with brain storm optimization for multimodal optimization problems[J]. Swarm and Evolutionary Computation, 2021, 62: 100827.
- [3] Sheng W G, Wang X, Wang Z D, et al. Adaptive memetic differential evolution with niching competition and supporting archive strategies for multimodal optimization[J]. Information Sciences, 2021, 573: 316-331.
- [4] Ahmed R, Nazir A, Mahadzir S, et al. Niching grey wolf optimizer for multimodal optimization problems[J]. Applied Sciences, 2021, 11(11): 4795.
- [5] Ozsoydan F B, Baykasoğlu A. Quantum firefly swarms for multimodal dynamic optimization problems[J]. Expert Systems with Applications, 2019, 115: 189-199.
- [6] Gölcük İ, Ozsoydan F B. Quantum particles-enhanced multiple Harris Hawks swarms for dynamic optimization problems[J]. Expert Systems with Applications, 2021, 167: 114202.
- [7] Cheng T L, Chen M Y, Wang Y X, et al. Adaptive robust method for dynamic economic emission dispatch incorporating renewable energy and energy storage[J]. Complexity, 2018, 2018: 2517987.
- [8] Goel U, Varshney S, Jain A, et al. Three dimensional path planning for UAVs in dynamic environment using glow-worm swarm optimization[J]. Procedia Computer Science, 2018, 133: 230-239.
- [9] Branke J. Memory enhanced evolutionary algorithms for changing optimization problems[C]. Proceedings of the Congress on Evolutionary Computation-CEC99. Washington, 1999: 1875-1882.

- [10] Luo W J, Lin X, Zhu T, et al. A clonal selection algorithm for dynamic multimodal function optimization[J]. *Swarm and Evolutionary Computation*, 2019, 50: 100459.
- [11] Liu X F, Zhan Z H, Gu T L, et al. Neural network-based information transfer for dynamic optimization[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 31(5): 1557-1570.
- [12] Yang S X, Li C H. A clustering particle swarm optimizer for locating and tracking multiple optima in dynamic environments[J]. *IEEE Transactions on Evolutionary Computation*, 2010, 14(6): 959-974.
- [13] Hu J, Zeng J, Tan Y. A diversity-guided particle swarm optimizer for dynamic environments[C]. *International Conference on Life System Modeling and Simulation*. Heidelberg, 2007, 9: 239-247.
- [14] Kohonen T. Self-organized formation of topologically correct feature maps[J]. *Biological Cybernetics*, 1982, 43(1): 59-69.
- [15] Storn R, Price K. Differential evolution a simple and efficient heuristic for global optimization over continuous spaces[J]. *Journal of global optimization*, 1997, 11(4): 341-359.
- [16] Hong Z, Chen Z G, Liu D, et al. A multi-angle hierarchical differential evolution approach for multimodal optimization problems[J]. *IEEE Access*, 2020, 8: 178322-178335.
- [17] Halder U, Das S, Maity D. A cluster-based differential evolution algorithm with external archive for optimization in dynamic environments[J]. *IEEE Transactions on Cybernetics*, 2013, 43(3): 881-897.
- [18] Li C H, Yang S X. A general framework of multipopulation methods with clustering in undetectable dynamic environments[J]. *IEEE Transactions on Evolutionary Computation*, 2012, 16(4): 556-577.
- [19] Zou J, Deng Q, Zheng J H, et al. A close neighbor mobility method using particle swarm optimizer for solving multimodal optimization problems[J]. *Information Sciences*, 2020, 519: 332-347.
- [20] Blackwell T, Branke J. Multiswarms, exclusion, and anti-convergence in dynamic environments[J]. *IEEE Transactions on Evolutionary Computation*, 2006, 10(4): 459-472.
- [21] Liu L L, Yang S X, Wang D W. Particle swarm optimization with composite particles in dynamic environments[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2010, 40(6): 1634-1648.
- [22] Lung R I, Dumitrescu D. A collaborative model for tracking optima in dynamic environments[C]. *IEEE Congress on Evolutionary Computation*. Singapore, 2007: 564-567.
- [23] Parrott D, Li X D. Locating and tracking multiple dynamic optima by a particle swarm model using speciation[J]. *IEEE Transactions on Evolutionary Computation*, 2006, 10(4): 440-458.
- [24] Mendes R, Mohais A S. DynDE: A differential evolution for dynamic optimization problems[C]. *IEEE Congress on Evolutionary Computation*. Edinburgh, 2005: 2808-2815.
- [25] Bird S, Li X D. Using regression to improve local convergence[C]. *IEEE Congress on Evolutionary Computation*. Singapore, 2007: 592-599.
- [26] Korosec P, Silc J. The differential ant-stigmergy algorithm applied to dynamic optimization problems[C]. *IEEE Congress on Evolutionary Computation*. Trondheim, 2009: 407-414.
- [27] Kamosi M, Hashemi A B, Meybodi M R. A hibernating multi-swarm optimization algorithm for dynamic environments[C]. *The 2nd World Congress on Nature and Biologically Inspired Computing*. Kitakyushu, 2010: 363-369.
- [28] Li C H, Yang S X, Yang M. An adaptive multi-swarm optimizer for dynamic optimization problems[J]. *Evolutionary Computation*, 2014, 22(4): 559-594.
- [29] Yang P, Tang K, Lozano J A, et al. Path planning for single unmanned aerial vehicle by separately evolving waypoints[J]. *IEEE Transactions on Robotics*, 2015, 31(5): 1130-1146.
- [30] Zhang D F, Duan H B. Social-class pigeon-inspired optimization and time stamp segmentation for multi-UAV cooperative path planning[J]. *Neurocomputing*, 2018, 313: 229-246.

## 作者简介

闫李(1987—),男,副教授,博士,从事计算智能的研究, E-mail: yanli@zut.edu.cn;

马佳慧(1994—),女,硕士生,从事计算智能的研究, E-mail: xxmjhy@163.com;

柴旭朝(1982—),男,副教授,博士,从事计算智能的研究, E-mail: xzchai@zut.edu.cn;

岳彩通(1990—),男,副教授,博士,从事计算智能的研究, E-mail: zzuyuecaitong@163.com;

于坤杰(1990—),男,副教授,博士,从事计算智能的研究, E-mail: yukunjie@zzu.edu.cn;

梁静(1981—),女,教授,博士生导师,从事计算智能的研究, E-mail: liangjing@zzu.edu.cn;

瞿博阳(1984—),男,教授,博士,从事计算智能的研究, E-mail: quboyang@zut.edu.cn.