

一种新颖的基于双档案机制的多目标混沌粒子群优化算法

潘黎铖¹, 叶松², 刘佳琪², 张逸然³, 刘兴高¹

(1. 浙江大学 控制科学与工程学院, 浙江 杭州 310027;

2. 中国航天科技第一研究院, 北京 100076; 3. 中国航空工业成都飞机设计研究所, 四川 成都 610041)

摘要:为了解决多目标优化问题中寻找折中最优解集的同时兼顾解集的收敛性与多样性的国际难点,提出一种基于双档案机制的多目标混沌粒子群优化算法(a multi-objective chaotic particle swarm optimization-diversity archive, CMOPSO-DA)。建立收敛性档案(convergence archive, CA)和多样性档案(diversity archive, DA),针对粒子群的收敛性和多样性指标进行粒子群的迭代更新;对来自CA或DA的粒子应用遗传算子构建全局最优解,提高全局最优解的优化质量;引入混沌寻优,提高算法的局部搜索能力,使最优解集更趋近于Pareto解集。在5个国际经典基准函数上,与3种代表性的多目标优化算法进行了详细的比较研究,测试结果表明,CMOPSO-TA算法在兼顾最优解集的收敛性与多样性方面具有极大的优势,可以解决多目标优化问题。

关键词:多目标粒子群优化;双档案机制;混沌寻优;收敛性与多样性;Pareto最优解集

中图分类号:TP273 文献标识码:A 文章编号:1003-7241(2025)06-0028-06

A Novel Multi-objective Chaotic Particle Swarm Optimization Algorithm Based on Dual-archive Mechanism

PAN Li-cheng¹, YE Song², LIU Jia-qi², ZHANG Yi-ran³, LIU Xing-gao¹

(1. College of Control Science and Engineering, Zhejiang University, Hangzhou 310027, China;

2. The First Research Institute of China Aerospace Science and Technology, Beijing 100076, China;

3. Chengdu Aircraft Design and Research Institute of Aviation Industry of China, Chengdu 610041, China)

Abstract: To address the international challenge of finding a compromise Pareto optimal solution set while balancing convergence and diversity, this paper proposes a multi-objective chaotic particle swarm optimization algorithm based on a dual-archive mechanism-diversity archive (CMOPSO-DA). It establishes a convergence archive (CA) and diversity archive (DA) and iteratively updates the particle swarm based on their respective convergence and diversity metrics, applying genetic operators to particles from CA or DA to construct global optimal solutions and enhance optimization quality, introduces chaotic search to improve the algorithm's local search ability and make the optimal solution set approach the Pareto optimal solution set. The proposed algorithm is compared with three representative multi-objective optimization algorithms on five international benchmark functions in detail. The results show that CMOPSO-DA has significant advantages in balancing the convergence and diversity of the optimal solution set, and is of great significance for solving multi-objective optimization problems.

Keywords: multi-objective particle swarm optimization; dual-archive mechanism; chaotic optimization; convergence and diversity; Pareto optimal solution set

0 引言

在社会生产、科学实践以及经济建设中,多目标优化问题(multiobjective optimization problem, MOP)一直以来是一类常见且难以解决的优化问题。其主要特点是多个目标之间是相互矛盾的,其中一个目标的优化必须以其他目标的损失作为代价。此类问题通常不存在唯一的全局最优解,而是存在一个最优解组成的集合,称为Pareto解集,解集在目标空间中的映射称为Pareto前沿^[1]。

传统的MOP的求解是通过线形加权法、极大极小法等方法对多个目标进行权衡。而随着进化算法的出现,MOP的求解精度在传统优化算法的基础上有了长足的提升。常见的进化算法有遗传算法^[2]、差分进化算法^[3]、灰狼算法^[4]、蚁群算法^[5]、粒子群算法^[6-7]等。

其中,粒子群算法(particle swarm optimization, PSO)是二十世纪末提出并在MOP上得到发展和应用的群智能优化算法。Malik等^[8]使用轮盘赌选择全局最优解用于指导粒子群的进化方向;而Zhu等^[9]则是基于竞

赛机制从外部档案中选择全局最优解。

多目标粒子群优化(multiobjective particle swarm optimization, MOPSO)算法求解得到的近似Pareto解集有两个硬性的要求,一是尽可能地收敛到真实Pareto前沿,二是尽可能均匀地分布在真实Pareto前沿上。大多数MOPSO算法都是基于精英机制将非支配解保存在外部档案中,以提高收敛性,却忽视了解集的多样性。国内外学者就此提出了不同的档案更新策略以平衡解集的收敛性和多样性,比如基于密度的档案更新策略^[10]。遗憾的是,单一的外部档案可能难以聚集兼具收敛性和多样性的最优解。

本文提出了一种基于双档案机制的多目标混沌粒子群优化算法,在多目标粒子群算法的基础上,添加了一个额外的外部档案,平衡了Pareto解集的收敛性和多样性;提出了新的全局最优解构建策略,对来自两个外部档案的粒子应用遗传算子以构建全局最优解,能够提高全局最优解的质量;将混沌寻优引入了MOPSO算法中,使搜索能够跳出局部最优,对解空间进行更精细的搜索,有利于找到非支配解。通过在5个基准函数上与其他几种多目标优化算法的对比研究,表明所提出的算法能够更好地平衡收敛性和多样性。

1 背景

1.1 多目标优化问题

一般来说,多目标优化问题的数学描述^[11]如下:

$$\begin{aligned} \min_{x \in \Omega^n} f(x) &= \{f_1(x), f_2(x), \dots, f_m(x)\} \\ \text{s.t. } g_j(x) &\leq 0, 0 \leq j \leq k \end{aligned} \quad (1)$$

式中, $x = [x_1, x_2, \dots, x_n]^T$ 为 n 维决策向量, Ω^n 为决策变量的可行空间, $g_j(x)$ 为第 j 个等式和不等式约束, 映射函数 $f_i(x)$ 为第 i 个目标函数, m 为目标函数总个数。

求解多目标优化问题,需引入以下定义。

定义 1: $\forall x_a, x_b \in \Omega^n$ 若对于 $\forall i \in \{1, 2, \dots, m\}$, 都有 $f_i(x_a) \leq f_i(x_b)$, 且 $\exists i \in \{1, 2, \dots, m\}$, 使得 $f_i(x_a) < f_i(x_b)$, 则称 x_a 支配 x_b , 记作 $f(x_a) \succ f(x_b)$ 。

定义 2: 对于 $x_a \in \Omega^n$, 当且仅当 $\neg \exists x_b \in \Omega^n$, 使得 $f(x_b) \succ f(x_a)$ 时, x_a 为 Pareto 最优解。所有最优解 x_a 的集合称为 Pareto 最优解集, 对应的目标函数值所组成的曲线或者曲面称为 Pareto 前沿。

多目标优化算法的目的就在于找到尽可能接近真实 Pareto 最优解集的非支配解, 并使之对应的 Pareto 前沿尽可能地均匀分布在真实 Pareto 前沿上。

1.2 粒子群优化算法

PSO 是一种处理非线性优化问题的元启发式群智能

优化算法。该算法中的每个粒子将通过两种学习经验更新自身的位置信息, 从而表现出个体智能和群体智能。一种是粒子根据自己的经验得到的个体最优解, 也称为局部极值 $pbest$ 。另一种是根据整个粒子种群的经验得到的群体最优解, 表示个体粒子有向群体最优解靠近的趋势, 称为全局极值 $gbest$ 。PSO 算法中粒子的位置和速度更新公式如下:

$$v_{i,j}(t+1) = wv_{i,j}(t) + c_1r_1(pb_{i,j}(t) - x_{i,j}(t)) + c_2r_2(gb_j(t) - x_{i,j}(t)) \quad (2)$$

$$x_{i,j}(t+1) = x_{i,j}(t) + v_{i,j}(t+1) \quad (3)$$

式中, $p_{bi}(t) = (p_{bi,1}(t), p_{bi,2}(t), \dots, p_{bi,n}(t))$ 为第 i 个粒子的个体最优解, $Gb(t) = (gb_1(t), gb_2(t), \dots, gb_n(t))$ 为群体最优解, c_1 为个体学习因子, c_2 为群体学习因子, $w > 0$ 为惯性因子, r_1 和 r_2 为 $[0, 1]$ 间的随机数, t 表示进化代数。

1.3 混沌寻优

混沌是非线性动力学系统中由于内禀随机性而产生的一种运动形式, 具有随机性、有界性、搜索性以及初值敏感性^[12]。混沌运动由于其搜索性能在一定范围内不重复地遍历混沌空间中的所有状态。Logistic 映射是一种典型的混沌系统, 能够产生一系列混沌序列, 其数值表达式如下:

$$z_{n+1} = \theta z_n(1 - z_n), n \in \{1, 2, \dots\} \quad (4)$$

式中, $0 < \theta \leq 4$ 为控制参数, n 为混沌映射次数, $z_0 \in [0, 1]$, 当 $\theta = 4$ 时, 系统呈现完全混沌状态。

2 基于双档案机制的多目标混沌粒子群优化算法

所提出的 CMOPSO-DA 算法的基本框架如算法 1 所示。

算法 1 Genenral framework of CMOPSO-DA

- 1: Initialize population
- 2: Evaluate initial population
- 3: Initialize CA and DA to empty set
- 4: Randomly select global best solution from non-dominated solutions set in initial population
- 5: Set $t=0$
- 6: repeat
- 7: Update population
- 8: Update CA and DA with updated population
- 9: Select global best solution from CA and DA
- 10: Apply chaotic map search to global best solution
- 11: $t=t+1$
- 12: until $t=MAX_ITERATION$

该算法的新颖之处在于引入了双档案机制、基于双档案的 $gbest$ 的选择以及局部混沌寻优。首先, 在 CMOP-

SO-DA 算法中建立了 CA 和 DA 两个合作档案,其中 CA 的目标是使得 Pareto 解集收敛到真正的 Pareto 前沿,而 DA 的目标是使 Pareto 解集均匀地分布在 Pareto 前沿上。所以 CA 需要通过评估收敛性的策略进行档案更新,DA 则是通过评估多样性的策略进行档案更新。其次,从 CA 或 DA 中随机选取亲本,利用遗传算子从亲本中生成子代作为全局最优解。此外,全局最优解进一步地通过混沌映射进行局部搜索,避免陷入局部最优解,这样得到的全局最优解兼顾了多样性和收敛性,还具备全局搜索能力。

如算法 1 所示,CMOPSO-DA 的主要组成部分为:双档案的更新策略、全局最优解的选择方法和混沌映射局部搜索方案。接下来将对每个组成部分进行详细的描述。

2.1 双档案更新策略

双档案的更新策略流程如算法 2 所示。

算法 2 Update CA and DA with updated population

```

1: for i=1 to popsize do
2:   if individual(i) is non-dominated solution then
3:     if no member in CA and DA can dominates an individual
       (i) then
4:       Set individual(i).Dflag=False
5:     if individual(i) dominates any member in CA and DA
       then
6:       Set individual(i).Dflag= True
7:     Randomly delete a dominated member
8:   end if
9:   if individual(i).Dflag==True then
10:    Add individual(i) to CA
11:   else
12:    Add individual(i) to DA
13:   end if
14: end if
15: end if
16: end for
17: if sizeof(CA)+sizeof(DA) > ARCHIVE_SIZE then
18:   for i=1 to sizeof(DA) do
19:     DA(i).length=MAX_REAL
20:   for j=1 to sizeof(CA) do
21:     if DA(i).length>EDist(CA(j),DA(i)) then
22:       DA(i).length=EDist(CA(j), DA(i))
23:     end if
24:   end for
25: end for
26: repeat
27:   Delete the member of DA with the shortest length
28: until sizeof(DA)+sizeof(CA)==ARCHIVE_SIZE
29: end if

```

对于更新后的种群中每一个粒子,将其与种群的剩余粒子进行适应度函数的比较。如果它是一个支配解,则将被丢弃,否则进入下一步的档案更新(第 1 行-2 行)。来自种群的非支配解将与 CA 和 DA 两个档案中的所有成员进行适应度函数的比较,这将有 3 种可能性。在第 1 种情况下,该粒子被两个档案中的某一个粒子支配,于是就被丢弃。在第 2 种情况下,该粒子可以支配两个档案中的一些成员,则被支配的成员中将随机移除一个,并且该粒子进入 CA(第 5 行-10 行)。在第 3 种情况下,该粒子和两个档案中的粒子均不能互相支配,该粒子将进入 DA(第 4 行,11 行-12 行)。循环上述过程,直到遍历完所有更新后的种群中的粒子。

当两个档案的总大小溢出时,则需要删除操作(第 17 行-29 行)。值得注意的是,删除操作只针对 DA 中的粒子。首先对 DA 中的所有粒子计算各自到 CA 中最近的粒子的距离。在实际的计算中计算的是 DA 中的每个粒子到 CA 中所有粒子的欧氏距离,然后选择最短的一个。迭代删除 DA 中距离 CA 最短的粒子,直到两个档案的总大小等于所设定的容量上限。

2.2 全局最优解的选择方法

在 MOPSO 算法中,种群演化的方向与全局最优解的选择方法密切相关,合适的选择方法往往可以增强一个种群向真实 Pareto 前沿的收敛能力以及收敛速度。

在基于双档案更新策略对 CA 和 DA 进行更新后,种群中在收敛性和多样性上表现更好的粒子被保留了下来。为了利用两个档案中代表收敛性和多样性的粒子以进一步提高全局最优解的质量,提出了从 CA 和 DA 中采样亲本,并基于遗传算子对亲本进行杂交生成全局最优解的方法,如算法 3 所示。

算法 3 Select global best solution from CA and DA

```

1: Randomly select two particles from CA and DA respec-
   tively
2: Apply SBX operator to selected particles and generate
   two offspring  $x_{p_1}$  and  $x_{p_2}$ 
3: Apply PM operator to  $x_{p_1}$  and  $x_{p_2}$  and generate  $\tilde{x}_{p_1}$  and  $\tilde{x}_{p_2}$ 
4: Depend dominance relation between  $\tilde{x}_{p_1}$  and  $\tilde{x}_{p_2}$ 
5: if  $f(\tilde{x}_{p_1}) > f(\tilde{x}_{p_2})$  then
6:   Select  $\tilde{x}_{p_1}$  as gbest
7: else if  $f(\tilde{x}_{p_2}) > f(\tilde{x}_{p_1})$  then
8:   Select  $\tilde{x}_{p_2}$  as gbest
9: else
10: Randomly select gbest from  $\tilde{x}_{p_1}$  and  $\tilde{x}_{p_2}$ 
11: end if

```

首先,分别随机地从更新后的CA和DA中选择一个亲本。然后对两个亲本应用遗传算法中的遗传算子,本文选取了模拟二进制交叉(SBX)算子以及多项式变异(PM)算子。

假设 $x^{CA}=(x_1^{CA}, x_2^{CA}, \dots, x_n^{CA})$ 和 $x^{DA}=(x_1^{DA}, x_2^{DA}, \dots, x_n^{DA})$ 是分别从CA和DA中选取两个亲本,则SBX算子可表示为

$$\begin{cases} x_{p_1} = 0.5[(1+\gamma)x^{CA} + (1-\gamma)x^{DA}] \\ x_{p_2} = 0.5[(1-\gamma)x^{CA} + (1+\gamma)x^{DA}] \end{cases} \quad (5)$$

式中, x_{p_1} 和 x_{p_2} 为通过模拟二进制交叉生成的两个子代,参数 γ 的计算方式如下:

$$\gamma = \begin{cases} (2\mu)^{\frac{1}{1+\eta_c}}, & \mu \leq 0.5 \\ (2-2\mu)^{\frac{1}{1+\eta_c}}, & \mu > 0.5 \end{cases} \quad (6)$$

式中, μ 为 $[0, 1]$ 上均匀分布的随机数, η_c 为分布指数。模拟二进制交叉操作后,再对生成的子代以 p_m 的变异概率进行多项式型变异。以子代 $x_{p_1}=(x_{p_1,1}, x_{p_1,2}, \dots, x_{p_1,n})$ 为例进行说明,PM算子定义如下:

$$\tilde{x}_{p_1,j} = \begin{cases} x_{p_1,j} + \xi_j(u_j - l_j), & \text{rand} < p_m \\ x_{p_1,j}, & \text{其他} \end{cases} \quad (7)$$

式中, u_j 和 l_j 分别表示第 j 个维度的上界和下界,参数 ξ_j 的计算方式如下:

$$\xi_j = \begin{cases} [2\delta + (1-2\delta)(1-\varepsilon_1)^{1+\eta_m}]^{\frac{1}{1+\eta_m}}, & \delta \leq 0.5 \\ 1 - [2(1-\delta) + (2\delta-1)(1-\varepsilon_2)^{1+\eta_m}]^{\frac{1}{1+\eta_m}}, & \delta > 0.5 \end{cases} \quad (8)$$

$$\varepsilon_1 = \frac{x_{p_1,j} - l_j}{u_j - l_j}, \varepsilon_2 = \frac{u_j - x_{p_1,j}}{u_j - l_j} \quad (9)$$

式中, δ 为 $[0, 1]$ 上均匀分布的随机数, η_m 为分布指数。

根据上述SBX算子和PM算子从CA和DA中生成了两个子代,对它们进行支配关系确定后选择非支配解或者随机选择一个子代作为全局最优解。

2.3 混沌寻优局部搜索方案

算法4 Apply chaotic map search to global best solution

- 1: Set $gbest = gbest_0 = \tilde{x}_p$ which selected from algorithm 3
- 2: for $i=1$ to CHAOTIC_ITERATION do
- 3: Compute $gbest_i = \theta \cdot gbest_{i-1} (1 - gbest_{i-1})$
- 4: if $f(gbest_i) > f(gbest_{i-1})$ then
- 5: Set $gbest = gbest_i$
- 6: break
- 7: end if
- 8: end for

由于MOPSO容易陷入局部最优解,因此引入混沌寻优,对由CA和DA中杂交得到全局最优解进一步进行混沌迭代,使得MOPSO算法能够跳出局部最优解,逼近真实的Pareto前沿。混沌寻优局部搜索方案如算法4所示,本文采取Logistic混沌映射。

3 实验验证

在本节中,将针对广泛使用的基准测试ZDT系列函数^[13]对所提出的CMOPSO-DA算法进行实验测试。同时为了验证其性能,将CMOPSO-DA与现有的3种多目标粒子群算法MOPSO^[14]、SMP^[15]和dMOPSO^[16]进行了比较。

3.1 基准测试函数

本文使用了ZDT系列的基准测试函数对所提出的算法以及其余多目标粒子群算法进行实验比较。具体地说,使用了来自ZDT系列测试函数中的4个双目标优化问题。事实上,ZDT系列共有6个多目标优化问题,但是ZDT5是一个离散优化问题,所提算法以及对比较算法都是针对连续实值优化问题,因此将该优化问题排除在外,不进行相关的测试。

3.2 性能指标

本文选取了两个性能指标对所提算法以及对比较算法进行评估。

(1) 世代距离(GD)指标^[17]。GD指标主要通过计算由测试算法获得的近似Pareto前沿到沿真实Pareto前沿均匀分布的解上最近解的平均距离来评估算法,GD越小说明算法的收敛性能越好。

$$GD = \sqrt{\sum_{i=1}^s d_i^2} / s \quad (10)$$

式中, s 为近似Pareto解集中解的个数, d_i 为第 i 个解到最接近的真实Pareto解之间的欧氏距离。

(2) 空间评价(Δ)指标。 Δ 指标衡量获得的近似Pareto解集的分布情况,其值越小表示解集的分布性越好。

$$\Delta = \frac{\sum_{i=1}^m d(e_i, \Theta) + \sum_{x \in \Theta} |d(x, \Theta) - \bar{d}|}{\sum_{i=1}^m d(e_i, \Theta) + (|\Theta| - m)\bar{d}} \quad (11)$$

$$d(x, \Theta) = \min_{y \in \Theta, y \neq x} \|f(x) - f(y)\| \quad (12)$$

$$\bar{d} = \sum_{x \in \Theta} d(x, \Theta) / |\Theta| \quad (13)$$

式中, (e_1, e_2, \dots, e_m) 为真实Pareto解集中的极值解, Θ 为算法获得的近似Pareto解集。

3.3 基准实验设置以及结果

考虑到测试环境的公平性,对于优化问题ZDT1-3

与ZDT6,所有的测试算法均设置种群规模 N 设为200,外部档案的最大规模 Z 设为200,最高评价次数设置 Z 为50 000次;而优化问题ZDT4是一个多峰函数,存在多重局部Pareto前沿,大多数算法难以收敛到真实Pareto前沿,因此设置种群规模 N 设为300,外部档案的最大规模 Z 设为300,最高评价次数设置为300 000次。所有算法均独立运行30次,在2个性能指标上进行评估。在参数设置上,所提出的CMOPSO-DA算法中CA与DA的大小设置为与种群数量相同大小,变异概率 p_m 设为 $1/m$,分布指标 η_c 和 η_m 均设为20,MOPSO、SMP SO和dMOPSO的关键参数均与参考论文中的设置相同。粒子群更新算法中的学习因子 c_1 以最大值2.5随评价次数线性递减,学习因子 c_2 以最小值1.5随评价次数线性递增,速度权重 w 在区间 $[0.4, 0.6]$ 上从最大值开始随评价次数线性递减。

表1和表2分别给出了3种基于PSO的多目标算法MOPSO、SMP SO、dMOPSO以及所提算法CMOPSO-DA在ZDT系列问题上GD指标和 Δ 指标的均值和标准差。其中,粗体表示均值最优结果,粗斜体表示均值第二优结果。

表1 ZDT测试函数GD性能统计

测试函数	GD	MOPSO ^[4]	SMP SO ^[5]	dMOPSO ^[6]	Current Work
ZDT1	Mean	3.5277e-2	1.5840e-4	8.3305e-4	1.1290e-4
	STD	1.49e-2	7.10e-5	2.40e-4	2.20e-5
ZDT2	Mean	6.7377e-1	2.3258e-4	9.8507e-4	1.3519e-4
	STD	5.64e-1	3.31e-4	4.82e-4	6.33e-5
ZDT3	Mean	4.2314e-2	3.8457e-4	6.4356e-4	1.6849e-4
	STD	1.29e-2	9.04e-4	1.43e-4	5.10e-5
ZDT4	Mean	1.5440e+0	2.2075e-3	4.8258e-5	1.3294e-5
	STD	4.00e0	8.79e-3	2.02e-5	4.87e-6
ZDT6	Mean	7.4851e-3	3.3165e-3	4.6648e-5	6.7095e-5
	STD	1.02e-2	9.61e-3	7.03e-5	9.39e-5

表2 ZDT测试函数 Δ 性能统计

测试函数	Δ	MOPSO ^[4]	SMP SO ^[5]	dMOPSO ^[6]	Current Work
ZDT1	Mean	6.4578e-3	6.7379e-3	3.1946e-3	2.7760e-3
	STD	1.16e-3	7.39e-4	4.84e-4	3.92e-4
ZDT2	Mean	4.8592e-3	3.3482e-3	3.5799e-3	2.5733e-3
	STD	2.62e-3	2.61e-4	8.34e-4	4.56e-4
ZDT3	Mean	6.7966e-3	7.7151e-3	9.9181e-3	2.9387e-3
	STD	1.79e-3	2.10e-3	1.05e-3	5.19e-4
ZDT4	Mean	7.5410e-3	3.8052e-3	2.4515e-3	3.0137e-3
	STD	7.70e-3	3.13e-3	2.90e-5	3.82e-4
ZDT6	Mean	1.4742e-2	4.9228e-2	3.0367e-3	2.4140e-3
	STD	1.66e-2	1.35e-1	6.58e-4	4.18e-4

从表1可以看出,所提算法CMOPSO-DA的GD指标

在ZDT1-4测试函数上相比于其他算法都要小,数量级都在 10^{-4} 及以下,而在ZDT6上仅比dMOPSO结果低了 2×10^{-5} ,表明CMOPSO-DA的收敛性能非常好,得到的Pareto解集基本收敛到真实的Pareto前沿。从表2的 Δ 指标统计来看,CMOPSO-DA的多样性也很优秀, Δ 指标都以 10^{-3} 的数量级接近于0,除了在ZDT4问题上位列第二以外,其他测试函数上的结果都为最优,表明CMOPSO-TA算法在提高了收敛性能的基础上,也得到了较好的解集分布性,平衡了收敛性和多样性。

3.4 全局最优解选择策略以及混沌寻优的有效性

本节进行了消融实验,分别针对基于CA和DA的全局最优解选择策略以及混沌寻优的有效性进行了验证。验证实验仅针对多峰函数ZDT4,实验室设置与2.1节相同,在2个性能指标上的统计结果如表3以及表4所示。其中W/O-Op表示从CA与DA的合集中随机选取全局最优解以代替遗传算子的选择策略,W/O-Chaos表示去除混沌寻优步骤,W/O-Op&Chaos表示两者同时进行。

表3 ZDT4测试函数上消融实验的GD性能统计

GD	Current Work	W/O-Op&Chaos	W/O-Op	W/O-Chaos
Mean	1.3294e-5	2.8484e-3	2.5731e-5	2.4536e-5
STD	4.87e-6	6.32e-3	5.17e-6	8.84e-6

表4 ZDT4测试函数上消融实验的 Δ 性能统计

Δ	Current Work	W/O-Op&Chaos	W/O-Op	W/O-Chaos
Mean	3.0137e-3	6.5153e-3	3.8513e-3	3.7664e-3
STD	3.82e-4	5.65e-3	9.31e-4	2.69e-4

从结果来看,基于遗传算子的全局最优解选择策略以及混沌寻优策略都起到了改进的作用。去除任意一种策略的测试结果都低于CMOPSO-DA算法的结果。此外,W/O-Chaos在两个性能指标上的结果都优于W/O-Op,可见基于CA和DA的遗传算子选择策略对全局搜索能力的提升性能优于混沌寻优起到的局部搜索能力增强效果。

4 结束语

本文提出以一种基于双档案机制的多目标混沌粒子群优化算法。算法将双档案机制与多目标粒子群算法相结合,替代了主流的单一档案机制,以解决现有算法在多样性和收敛性之间难以平衡的问题;采用了基于这双档案的全局最优解选择策略,使构建的全局最优解不仅多元化,而且质量高;针对算法易陷入局部最优的问题,提出了针对全局最优解的混沌寻优局部搜索方案。仿真实验的对比结果表明,与其他算法相比,所提出的CMOPSO-DA算法在收敛性以及空间多样性之间具有更好的

平衡能力。未来的工作是针对双档案的更新策略以及全局最优解的筛选方法进行优化。

参考文献：

[1] Hua Y, Liu Q, Hao K, 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] Deng W, Zhang X, Zhou Y, et al. An enhanced fast non-dominated solution sorting genetic algorithm for multi-objective problems[J]. Information Sciences, 2022(585): 441–453.

[3] Khaparde A R, Alassery F, Kumar A, et al. Differential Evolution Algorithm with Hierarchical Fair Competition Model[J]. Intelligent Automation & Soft Computing, 2022, 33(2): 1045–1062.

[4] Asghari K, Masdari M, Gharehchopogh F S, et al. A chaotic and hybrid gray wolf-whale algorithm for solving continuous optimization problems[J]. Progress in Artificial Intelligence, 2021, 10(3): 349–374.

[5] Hu R, Li Y, Qian B, et al. An enhanced ant colony algorithm combined with clustering decomposition for solving complex green vehicle routing problem[J]. Acta Automatica Sinica, 2022, 48(12): 3006–3023.

[6] Zhao S, Zeng D, Wang W, et al. Mutation grey wolf elite PSO balanced XGBoost for radar emitter individual identification based on measured signals[J]. Measurement, 2020(159): 107777.

[7] Liu X, Gu Y, He S, et al. A robust reliability prediction method using weighted least square support vector machine equipped with chaos modified particle swarm optimization and online correcting strategy[J]. Applied Soft Computing, 2019(85): 105873.

[8] Malik M Z, Kumar M, Soomro A M, et al. Strategic planning of renewable distributed generation in radial distribution system using advanced MOPSO method[J]. Energy Reports, 2020(6): 2872–2886.

[9] Zhu M, Han F. Multi-objective Particle Swarm Optimization based on Space Decomposition for Feature Selection [C]//2021 17th International Conference on Computational Intelligence and Security(CIS). IEEE, 2021: 387–391.

[10] Xu G, Liu B, Song J, et al. Multi-objective sorting-based learning particle swarm optimization for continuous optimization[J]. Natural Computing, 2019(18): 313–331.

[11] Zhang W, Huang W M. Multi-strategy adaptive multi-objective particle swarm optimization algorithm based on swarm partition[J]. Acta Automatica Sinica, 2022, 48(10): 2585–2599.

[12] Saha S, Mukherjee V. A novel multiobjective chaotic symbiotic organisms search algorithm to solve optimal DG allocation problem in radial distribution system[J]. International Transactions on Electrical Energy Systems, 2019, 29(5): 2839.

[13] Zitzler E, Deb K, Thiele L. Comparison of multiob-

jective evolutionary algorithms: Empirical results[J]. Evolutionary computation, 2000, 8(2): 173–195.

[14] Coello C A C, Lechuga M S. MOPSO: A proposal for multiple objective particle swarm optimization[C]//Proceedings of the 2002 Congress on Evolutionary Computation. CEC'02(Cat. No. 02TH8600). IEEE, 2002(2): 1051–1056.

[15] Nebro A J, Durillo J J, Garcia-Nieto J, et al. SMP-SO: A new PSO-based metaheuristic for multi-objective optimization[C]//2009 IEEE Symposium on computational intelligence in multi-criteria decision-making(MCDM). IEEE, 2009: 66–73.

[16] Lee K B, Kim J H. DMOPSO: Dual multi-objective particle swarm Optimization[C]//2014 IEEE Congress on Evolutionary Computation(CEC). IEEE, 2014: 3096–3102.

[17] Yong-Jie M, Min C, Ying G, et al. Research progress of dynamic multi-objective optimization evolutionary algorithm[J]. Acta Automatica Sinica, 2020, 46(11): 2302–2318.

作者简介: 潘黎铖(1998—), 男, 硕士研究生, 研究方向: 多目标优化算法, 智能优化。

通信作者: 刘兴高(1968—), 男, 教授, 研究方向: 工业自动化, 动态优化算法, 动态博弈与优化。