

DOI:10.19651/j.cnki.emt.2210716

决策空间自组织多模态多目标鲸鱼优化算法研究*

刘智睿¹ 杨志刚¹ 赵志伟² 苏皓^{1,3} 葛超^{1,3}(1. 华北理工大学电气工程学院 唐山 063210; 2. 唐山学院 唐山 063000;
3. 唐山市半导体集成电路重点实验室 唐山 063000)

摘要: 针对当前多模态多目标优化算法在获得 Pareto 解集的完整性、收敛性方面的不足,提出了一种决策空间自组织多模态多目标鲸鱼优化算法(MMO_SOM_WOA)。首先将鲸鱼优化算法首次用于求解多模态多目标问题,通过鲸鱼优化算法本身的随机性提高寻找 Pareto 解集完整性的能力。其次将自组织映射网络与鲸鱼优化算法相结合,迭代开始时为鲸鱼优化算法建立良好的邻域。最后使用精英反向学习策略初始化种群和非支配排序机制获得均匀且完整的解。通过与当前 5 种经典算法在多模态多目标优化问题上进行仿真对比,结果表明 MMO_SOM_WOA 算法兼顾 Pareto 解集的多样性和 Pareto 解的完整性,收敛速度和收敛精度均得到提升具有较高的性能,有效解决多模态多目标优化问题。

关键词: 多模态多目标优化;决策空间;自组织映射网络;鲸鱼优化算法;精英反向学习;Pareto 最优解集

中图分类号: TP301.6 文献标识码: A 国家标准学科分类代码: 520.1

Research on self-organizing multi-modal multi-objective whale optimization algorithm in decision space

Liu Zhirui¹ Yang Zhigang¹ Zhao Zhiwei² Su Hao^{1,3} Ge Chao^{1,3}(1. School of Electrical Engineering, North China University of Technology, Tangshan 063210, China;
2. Tangshan University, Tangshan 063000, China;
3. Tangshan Key Laboratory of Semiconductor Integrated Circuits, Tangshan 063000, China)

Abstract: Aiming at the deficiency of current multi-mode multi-objective optimization algorithm in obtaining the integrity and convergence of Pareto solution set, a decision space self-organizing multi-mode multi-objective whale optimization algorithm (MMO_SOM_WOA) is proposed. First, whale optimization algorithm is used to solve multi-modal multi-objective problems for the first time, and the ability to find the integrity of Pareto solution set is improved through the randomness of whale optimization algorithm itself. Secondly, the self-organizing mapping network is combined with whale optimization algorithm to establish a good neighborhood for whale optimization algorithm at the beginning of iteration. Finally, the elite reverse learning strategy is used to initialize the population and non dominated sorting mechanism to obtain uniform and complete solutions. Through simulation comparison with the current five classical algorithms on multi-modal multi-objective optimization problems, the results show that MMO_SOM_WOA algorithm takes into account both the diversity of Pareto solution set and the integrity of Pareto solution. The convergence speed and convergence accuracy are improved and have high performance, effectively solving multi-modal and multi-objective optimization problems.

Keywords: multi-mode multi-objective optimization; decision space; self-organizing mapping network; whale optimization algorithm; elite reverse learning; Pareto optimal solution set

0 引言

面对实际工程中经常出现的需要对多个目标同时优

化,且目标与目标之间存有相互冲突的情况,如何减小冲突,均衡目标之间的关系,将这类情况称为多目标优化问题^[1],并相继提出 NSGA-II^[2]、MOEA/D^[3]、Omni-

收稿日期:2022-07-18

*基金项目:河北省自然科学基金(F202109006)、河北省自然科学基金-钢铁联合研究基金(E2019105123)、河北省高等学校科学技术研究项目(ZD2019311)资助

optimizer^[4]等的各种多目标优化算法,并应用到解决实际问题当中,如分布式电源配电网络^[5],列车运行过程优化^[6],云计算多目标任务调度^[7]等。当有多个需优化的目标同时具有多模态特性,这类问题被称为多模态多目标优化问题^[8]。在保障 Pareto 解的多样性和逼近性好的前提下,找到更多的 Pareto 解集为决策者提供不同的选择策略具有举足轻重的作用^[9]。

随着多模态多目标优化问题受到学者们的关注和重视,为了找到更多更精确的 Pareto 最优解集,国内外许多学者在决策空间上提出了各种方法。在多目标算法的基础上 Liang 等^[10]提出了一种在决策空间中生成小生境建立交配池的多目标进化算法(DN_NSGAII)。该算法改进了选择算子、将决策空间的拥挤度作为选择的标准。仿真结果验证该算法能够找到更多的 Pareto 最优解。Qu 等^[11]将自组织映射网络(self-organizing mapping network,SOM)、特殊拥挤距离(special crowding distance,SCD)方法应用到一起,对多个 PS 进行定位和维护。SOM 网络可以映射出不同的小生境种群,提高决策空间种群多样性。Yue 等^[12]提出了使用环形拓扑结构构建邻域和对拥挤距离进行改进的多模态多目标粒子群优化算法(MO_Ring_PSO_SCD),通过粒子间的前后交流形成环形结构生成小生境的方法,以促进种群交流找到更多的 PS。然而,环形拓扑结构形成的过程可能不能完全表示当前个体的真正邻域。因此,群体之间可能出现错误的信息交流。Zhang 等^[13]提出了一种多模态多目标基于聚类的粒子群算法(MMO_CLRPSO),该算法首先在决策空间中对变量进行聚类,将种群进行分类形成多个子种群,在子种群间进化。其次通过子种群进化的非支配解集形成环拓扑结构,提高了局部搜索能力。Liang 等^[14]提出了一种利用欧氏距离自组织小生境的形成方法来提高算法性能。然而,由于小生境形成过程中的参数较为固定,不利于种群多样性的形成。Liang 等^[15]提出了一种能够同时兼顾决策空间和目标空间拥挤度的 SCD 排序方法,将 SCD 应用到非支配排序当中,合理选择下一代个体,由于 SCD 是一种有效的环境选择指标,因此被广泛应用于解决多模态多目标问题。

鲸鱼优化算法(whale optimization algorithm,WOA)^[16]是在 2016 年提出的新型群体智能算法,由其操作简单、参数易调、易跳出局部最优等优点,被广泛应用在作业车间调度,函数求解^[17]等实际问题中。但在多模态多目标优化研究当中很少涉及到 WOA。

综上所述,针对多模态多目标问题,获得一个完整且分布良好的 PS 和 PF 仍然是一个具有挑战性的任务。因此本文提出一种决策空间自组织的多模态多目标鲸鱼优化算法,算法首次将 WOA 算法用于处理多模态多目标问题,同时受 SOM 网络的启发,迭代开始时在决策空间中为种群自组织生成小生境,为进化过程确定种群。并应用精英反向学习策略初始化种群,为种群进化提供可靠的、多样性的

个体,最后应用非支配排序机制提高决策空间和目标空间的多样性。本算法能够提高找到 Pareto 最优解集的能力,在收敛速度和收敛精度方面具有较好的性能,可用于求解复杂的现实工程问题。

1 相关内容

1.1 多模态多目标优化问题

在多目标优化问题中,当目标空间的一个目标值在决策空间中有 2 个及以上的解与之对应时,该情形的优化问题被称为多模态多目标优化问题。可以简单地理解为两个以上的 Pareto 解集(PS1,PS2)对应同一个 Pareto 前沿(PF),如图 1 所示。

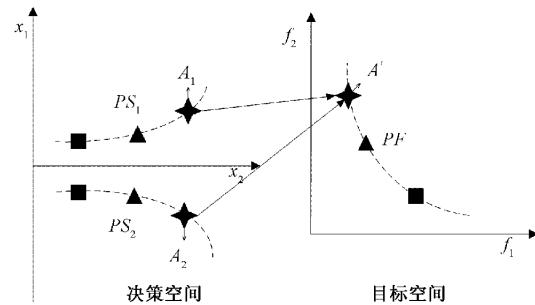


图 1 多模态多目标优化问题

1.2 鲸鱼优化算法

WOA 是根据座头鲸的特殊捕猎行为启发后所提出的。鲸鱼由其独特的泡泡网觅食行为进行觅食,对此行为进行模拟后,可将鲸鱼优化算法分为 3 个阶段,分别是包围捕食、螺旋更新、搜寻猎物。

1) 包围捕食

鲸鱼把目前搜集到的猎物资源共享,然后鲸鱼逐渐向当前集群中最靠近猎物的那只鲸鱼靠拢,逐步缩小了整个鲸群的覆盖范围,从而完成了对猎物的封锁。该环节鲸鱼的更新公式如下:

$$\begin{cases} \mathbf{X}_{t+1} = \mathbf{X}_t^* - \mathbf{A} \cdot \mathbf{D} \\ \mathbf{D} = |C \cdot \mathbf{X}_t^* - \mathbf{X}_t| \end{cases} \quad (1)$$

式中: t 为当前迭代次数; \mathbf{X}_t 为 t 代鲸鱼位置; \mathbf{X}_t^* 是全局最优位置; $\mathbf{A} = 2a \cdot r_1 - a$ 和 $C = 2r_2$ 为系数矩阵, r_1 和 r_2 为区间 $[0,1]$ 上的随机数; a 为收敛因子, $a = 2 - 2t/T$, T 为最大迭代次数。

2) 螺旋更新

在螺旋更新阶段,当鲸鱼发现猎物之后,以螺旋的向上方式渐渐的靠近猎物,并进行猎杀,螺旋靠近猎杀过程表达式为:

$$\mathbf{X}_{t+1} = \mathbf{X}_t^* + \mathbf{D} \cdot e^{bt} \cos(2\pi l) \quad (2)$$

式中: \mathbf{D} 如式(1)所示, b 为对数螺旋形状进行限制的常数; l 为区间 $[0,1]$ 之间的随机数。

鲸鱼在螺旋靠近猎物的过程中,还会以猎物为中心点进行收缩以实现对猎物包围的目的,为了表达这种行为,需

要对包围捕食和螺旋更新进行同步更新。更新公式为：

$$\mathbf{X}_{t+1} = \begin{cases} \mathbf{X}_t^* - A \cdot |C \cdot \mathbf{X}_t^* - \mathbf{X}_t|, & p < 0.5 \\ \mathbf{X}_t^* + \mathbf{D} \cdot e^{bl} \cos(2\pi l), & p \geq 0.5 \end{cases} \quad (3)$$

式中： p 为区间 $[0, 1]$ 之间的随机数。

3) 随机搜索

为提高鲸鱼算法的全局搜索能力, 规定当系数 $|A| \geq 1$ 时, 鲸鱼会进行全局随机搜索, 在当前种群中随机选取一个个体作为全局最优个体, 并向这个最优个体进行靠拢, 通过此种方式对鲸鱼个体进行更新。其搜索更新方式为:

$$\begin{cases} \mathbf{X}_{t+1} = \mathbf{X}_{rand} - A \cdot \mathbf{D} \\ \mathbf{D} = |C \cdot \mathbf{X}_{rand} - \mathbf{X}_t| \end{cases} \quad (4)$$

式中: \mathbf{X}_{rand} 为随机在当前群体中选取的鲸鱼个体。

2 决策空间自组织的鲸鱼优化

2.1 SOM 建立邻域种群过程

SOM 用于提取邻域关系信息^[18], 这有助于指导邻域内的重组以生成新的解决方案。其优点能很好地保持多个 PS 的局部拓扑性质。在本研究中, 使用一次 SOM 建立当前解决方案的邻域种群。SOM 被用来将相似的解聚类到同一个种群中, 为接下来的进化提供不同的进化种群。通过 SOM 建立邻域种群分两个过程, 学习过程: 1) 根据训练选择获胜神经元及更新神经元的权值; 2) 将与获胜神经元相似的神经元聚类到一个集合当中。

首先构建 SOM 模型: 通过鲸鱼的位置信息初始化神经元权重向量 $\mathbf{w}^u = (\mathbf{w}_1^u, \mathbf{w}_2^u, \dots, \mathbf{w}_n^u)$, 学习率 (η_0), 学习半径 (σ_0), 学习率和学习半径如下公式进行更新:

$$\eta = \eta_0 \cdot (1 - t/T) \quad (5)$$

$$\sigma = \sigma_0 \cdot (1 - t/T) \quad (6)$$

式中: t 为当前迭代次数, T 为最大迭代次数。

通过距离公式 $\|\mathbf{z}^u - \mathbf{z}^{u^*}\|_2$ 计算每个神经元之间的距离, 选择训练数据, 根据距离指标确定获胜神经元 u^* 及其邻域神经元, 进行聚类操作整合到集合 U 的过程, 公式如下:

$$u^* = \arg \min_{1 \leq u \leq M} \|\mathbf{x} - \mathbf{w}^u\|_2 \quad (7)$$

$$U = \{1 \leq u \leq M \wedge \|\mathbf{z}^u - \mathbf{z}^{u^*}\|_2 < \sigma\} \quad (8)$$

通过公式对神经元的权值进行更新:

$$\mathbf{w}^u = \mathbf{w}^u + \eta \cdot \exp(\|\mathbf{z}^u - \mathbf{z}^{u^*}\|_2)(\mathbf{x} - \mathbf{w}^u) \quad (9)$$

根据训练过程确定获胜神经元 u^* , 通过获胜神经元确定其邻域神经元, 为每个鲸鱼位置确定一个新的种群。其目的为在决策空间当中的全域范围内自组织多个小生境, 以定位更多的 Pareto 解集, 通过非支配排序, 当前种群当中排名第一的鲸鱼个体为全局最优个体。之后的进化过程在当前小生境当中进化。

2.2 精英反向学习策略

种群初始化的优劣影响优化算法的寻优性能, 优秀的初始种群有益于算法找到全局最优解。通常种群初始化的

方法是通过随机产生的, 这样就可能出现种群聚集的情况, 导致种群多样性变差。因此, 本文将精英反向学习^[19]引用到多模态多目标当中的种群初始化阶段, 利用随机初始化后的精英个体, 通过精英个体的优越性, 构造反向种群, 合并两个种群选择优秀的个体作为初始种群, 从而提升初始种群质量和多样性。精英反向学习策略为:

$$\mathbf{x}_{i,j} = rand() \cdot [\max(\mathbf{x}_{i,j}) + \min(\mathbf{x}_{i,j})] - \mathbf{x}_{i,j} \quad (10)$$

式中: $\mathbf{x}_{i,j}$ 为 D 维 ($j = 1, 2, \dots, D$) 搜索空间中的第 i 个个体 ($i = 1, 2, \dots, N$), $rand()$ 为区间 $[0, 1]$ 的随机数, $\max(\mathbf{x}_{i,j})$ 和 $\min(\mathbf{x}_{i,j})$ 分别为第 j 维决策空间个体的最大值和最小值, 求得反向解后, 判断是否越界, 需对其进行越界处理, 同时提出一种新的越界处理办法:

$$\begin{aligned} \mathbf{x}_{i,j} &= \mathbf{x}_{i,j} - rand() \cdot \mathbf{x}_{i,j} \\ &\text{if } \mathbf{x}_{i,j} < \mathbf{x}_{l,j} \text{ or } \mathbf{x}_{i,j} > \mathbf{x}_{u,j} \end{aligned} \quad (11)$$

式中: $\mathbf{x}_{l,j}$ 和 $\mathbf{x}_{u,j}$ 分别表示决策空间中 j 维空间中限定边界值的最大值和最小值, 当判断越界之后, 为此向量提供一个随机的反向向量避免其越界, 优点在于保留当前个体的部分信息, 为个体进化成为优秀个体提供机会。

精英反向学习策略的具体步骤如下:

- 1) 随机初始化个数为 N 的种群 POP , 通过非支配排序策略选取前 $N/2$ 个优秀个体组成精英群体 Q 。
- 2) 通过式(10)求出精英后代 Q^* , 应用式(11)判断是否越界, 并进行越界处理。
- 3) 合并种群 N 和种群 Q^* , 再次通过非支配排序选取 N 个优秀的个体作为进化种群 POP 。

2.3 自适应权重

受群体智能优化算法的启发, 在鲸鱼的更新阶段加入一个随迭代次数变化的惯性权重 w , 在迭代开始前期, 个体分布较为广泛, 通过最优鲸鱼位置着重引导提高其他个体的全局搜索能力。随着迭代次数的增加, 每个个体逐渐找到最优位置, 最优鲸鱼位置的权重变小, 使得鲸鱼位置快速收敛到当前个体的最优位置, 因此提出一种新的自适应惯性权重 w , 表达式如下:

$$w = (-\tanh(-2 + 4 \times (t/T) + 1)/2) \quad (12)$$

根据 \tanh 函数的表达式, 惯性权重 w 在根据迭代次数在 $(1, 0)$ 之间非线性变化, 这样既保证的算法的全局搜索能力, 同时能够提高算法的收敛性, 改进后的算法位置更新公式变为:

$$\mathbf{X}_{t+1} = \begin{cases} w^* \mathbf{X}_t^* - A \cdot |C \cdot \mathbf{X}_t^* - \mathbf{X}_t|, & p < 0.5 \\ w^* \mathbf{X}_t^* + \mathbf{D} \cdot e^{bl} \cos(2\pi l), & p \geq 0.5 \end{cases} \quad (13)$$

$$\begin{cases} \mathbf{X}_{t+1} = w \times \mathbf{X}_{rand} - A \cdot \mathbf{D} \\ \mathbf{D} = |C \cdot \mathbf{X}_{rand} - \mathbf{X}_t| \end{cases} \quad (14)$$

2.4 MMO_SOM_WOA 算法流程及具体步骤

1) MMO_SOM_WOA 算法具体步骤

MMO_SOM_WOA 算法主要依照反向精英学习策略初始化种群, 迭代开始时采用 SOM 模型在决策空间中生

成不同的种群,在当前种群中应用鲸鱼算法进行迭代寻优的过程,其算法流程如图2所示。

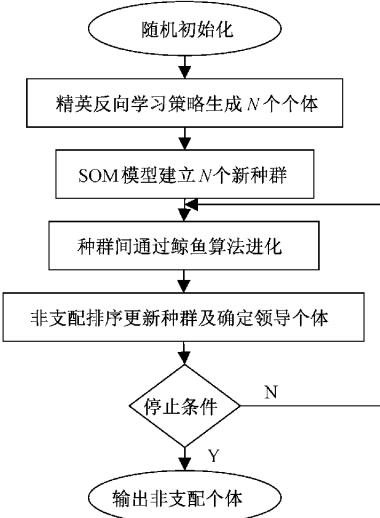


图2 MMO_SOM_WOA 算法流程

2) MMO_SOM_WOA 算法具体步骤

算法1 MMO_SOM_WOA 算法

输入:种群规模 N 的随机种群 POP , 最大评估次数 A , SOM参数学习率 (η_0) 和学习半径 (σ_0)。

输出:所有种群个体放到一起通过非支配排序输出非支配解。

- (1)对种群 POP 进行目标评价,通过式(10)~(11)的经营反向学习策略生成个数为 N ,新的种群为 POP 。
- (2)通过种群 POP 初始化 SOM 参数,训练数据 $TS = POP, w^1, w^2, \dots, w^N = POP$,通过 SOM 模型运用式(5)~(9)找到每个个体的邻域个体并以此生成个数为 N 个不同大小的小生境种群。
- (3)在每个种群间通过鲸鱼算法通过式(13)~(14)进行迭代更新。
- (4)通过非支配排序策略找到当前种群当中的最优个体指导群间进化的语句。
- (5)若满足最大迭代次数或者满足评价次数输出,否则返回步骤(2)。

3 仿真结果与分析

3.1 测试函数

为了验证 MMO_SOM_WOA 算法的性能,选取 11 个经典多模态多目标优化问题的测试函数。在不同的测试函数上测试本文算法与经典算法的性能。

3.2 仿真设置与评价指标

本文选取 5 种多模态多目标优化算法和一种多目标算法通过仿真对比验证本算法的有效性。其分别是 SMPSO_

MM^[11]、MO_Ring_PSO_SCD^[12]、DN-NSGII^[9]、Omni-optimizer^[5]、NSGII^[3]。参数设置与对比算法保持一致。种群规模 和最大评估次数 设置为 8×10^2 和 8×10^4 ,在测试问题上独立运行 20 次。值取均取结果的平均值和标准差。

本文采用 Pareto 解集的近似性 PSP^[12] 指标和超体积 HV^[20] 指标验证算法的性能。PSP 指标用于衡量决策空间 PS 的收敛性和多样性, HV 用于衡量算法寻找到 PF 的收敛性和多样性。

3.3 仿真结果

1) 种群规模敏感性分析

对于大多数优化算法来说,种群规模非常重要。虽然在大多数情况下,较大的总体规模可以提高算法的性能,但应考虑计算的时间。为分析种群规模对本算法的影响,选取 PSP 作为性能指标进行不同种群规模的实验。将种群规模设定为 $N=200, 400, 600, 800, 1\,000$,最大评价次数 A 均为 $100 \times N$ 。所得结果如图 3 所示。

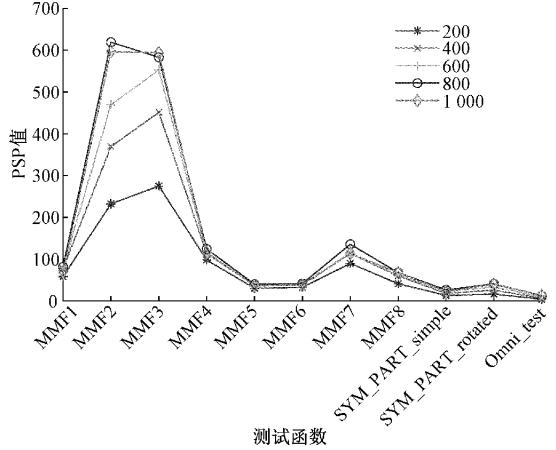


图3 种群规模对算法性能影响

随着种群规模的增加,算法性能逐渐增强,其主要原因是,随着种群数量的增加,种群初始化时能够产生更多随机的全局个体,同时 SOM 模型提供的小生境当中能包含更多的邻域个体,为鲸鱼进化提供更多的搜索空间。但 $N=800$ 和 $N=1\,000$ 时算法的性能差距很小,过多的初始种群设置也不能在过多的提高算法的性能,所以算法的种群尺寸仍设定为 $N=800$ 。

2) 策略性能对比

验证各个策略对 MMO_SOM_WOA 算法的影响,将 MMO_SOM_WOA 算法与 MMO_WOA(只有鲸鱼优化求解多模态多目标问题)、MMO_WOA_I(带有自适应权重的鲸鱼优化算法)、MMO_WOA_II(带有 SOM 模型的鲸鱼优化算法),进行验证,表 1 表示为不同的策略的算法的 PSP 指标的均值及标准差。

从表 1 的数据可以看出,MMO_WOA 算法在解决多模态多目标问题时的 PSP 值是较差的,也就是说只有鲸鱼优化时不能很好的解决此类问题。在鲸鱼优化算法的基础

表 1 不同策略的 PSP 指标统计(均值与标准差)

指标	MMO_SOM_WOA	MMO_WOA_II	MMO_WOA_I	MMO_WOA
MMF1	81.80±2.25	78.46±3.71	52.23±2.26	45.61±1.86
MMF2	618.82±31.79	565.22±29.26	238.44±10.22	126.04±12.07
MMF3	582.75±51.42	490.99±34.89	267.98±9.99	149.57±11.91
MMF4	124.28±4.68	117.61±8.21	86.76±2.28	74.95±4.13
MMF5	40.16±1.77	37.79±1.46	30.63±1.31	24.81±0.78
MMF6	41.81±1.65	38.96±1.23	32.23±0.78	27.38±0.49
MMF7	135.76±5.31	114.64±6.05	90.12±4.36	75.82±3.91
MMF8	67.93±2.57	62.61±3.32	38.34±1.98	29.05±1.87
SYM_simple	26.38±3.11	23.56±3.52	18.54±1.73	14.31±1.27
SYM_rotated	41.03±2.48	35.05±2.51	23.88±2.01	14.77±1.28
Omni_test	12.44±2.13	10.44±2.68	8.31±1.23	5.21±1.30

上加入一个自适应惯性权重,能够很好提高鲸鱼优化算法对于找到 PSP 值能力,说明所提的自适应权重有较好的性能。在此基础上在决策空间当中加上 SOM 模型可以看出 PSP 值有一个较大的提升,原因在于迭代开始时为鲸鱼个体创建了一个良好的种群进化环境,在此环境当中可以很好的发挥鲸鱼算法的优势,能够找到更多的 Pareto 最优解集。MMO_SOM_WOA 算法当中存在精英反向学习策略,提高了初始种群的质量和多样性,同时也帮助提高了

算法找到更好 Pareto 最优解集的可能性。

3) 不同算法性能对比

本节内容为了验证提出算法的性能,与多模态多目标算法 SMPSO_MM、MO_Ring_PSO_SCD、DN_NSGII、Omni-optimizer 和经典多目标优化算法 NSGII 进行对比试验,分别比较不同算法在决策空间和目标空间上的获得 Pareto 解集和 Pareto 解的能力,不同算法在决策空间的评价指标 PSP 值和目标空间的评价指标 HV 值由表 2、3 展示并进行分析。

表 2 不同算法在 12 个测试函数上的 PSP 指标统计(均值与标准差)

指标	MMO_SOM_WOA	SMPSO_MM	MO_Ring_PSO_SCD	DN_NSGII	Omni-optimizer	NSGII
MMF1	81.80±2.25	76.91±2.54	66.81±2.44	44.63±4.26	47.88±5.75	25.65±2.67
MMF2	618.82±31.79	158.87±12.01	99.59±14.23	68.94±32.83	71.87±30.51	47.54±18.86
MMF3	582.75±51.42	191.45±11.73	141.41±13.79	79.28±22.86	78.97±23.51	67.88±20.12
MMF4	124.28±4.68	137.45±4.34	113.83±3.53	39.42±9.54	38.65±5.54	22.35±4.77
MMF5	40.16±1.77	39.73±1.08	32.68±0.099	14.39±1.33	14.75±1.41	12.83±2.26
MMF6	41.81±1.65	40.85±0.92	36.59±1.24	17.85±1.31	17.56±1.44	13.92±1.21
MMF7	135.76±5.31	130.09±2.29	107.24±4.57	87.82±16.75	17.29±1.46	33.23±4.69
MMF8	67.93±2.57	52.48±1.99	46.96±1.88	14.92±4.62	15.45±5.92	0.78±0.21
SYM_PART simple	26.38±3.11	21.25±2.78	21.85±1.37	0.393±0.14	0.52±0.77	0.02±0.01
SYM_PART rotated	41.03±2.48	16.67±1.71	18.25±1.12	4.18±5.00	2.02±2.87	0.07±0.05
Omni_test	12.44±2.13	8.37±0.69	7.41±1.42	1.11±0.196	0.93±0.13	0.51±0.03

首先,由表 2 的 PSP 指标比较不同算法在决策空间获得 Pareto 解集的能力,PSP 值越大说明获得的 PS 在决策空间中能够找到更多的 PS 解集。可以看出在大部分的测试函数上展现出 MMO_SOM_WOA 算法的优越性能,这得益于各策略之间的优越性,SOM 模型在迭代开始时为鲸鱼算法确定优秀的种群提供良好的进化空间,鲸鱼算法本身的优势又为找到更多大 Pareto 解集提供了机会,精英反向学习策略为种群提升了质量和多样性。尤其是在 MMF2 和 MMF3 测试函数上,能够找到更多更准确的

Pareto 最优解。SMPSO_MM 算法要稍劣于本算法,在 MMF4 测试函数上展现了它的优势,要好于本算法。MO_Ring_PSO_SCD 算法与前两种算法有较大的劣势,但算法同样能够找到较优的 Pareto 解,得益于他在个体间形成的环形拓扑邻域,不局限于小生境参数的影响。其次是 DN_NSGII,Omni-optimizer,两种算法都考虑决策空间的分布情况,作为环境选择的标准,都能够提升一些算法的性能,最后是 NSGII 算法,PSP 值低的根本原因是没有考虑决策空间的拥挤距离,删除了大量可保留的优质解,所以决策

表3 不同算法在12个测试函数上的Hv指标统计(均值与标准差)

指标	MMO_SOM_WOA	SMPSO_MM	MO_Ring_PSO_SCD	DN_NSGII	Omni-optimizer	NSGII
MMF1	$3.66 \times 10^0 \pm 1.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 1.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 7.84 \times 10^{-4}$	$3.67 \times 10^0 \pm 2.21 \times 10^{-4}$	$3.67 \times 10^0 \pm 1.22 \times 10^{-3}$	$3.67 \times 10^0 \pm 5.24 \times 10^{-4}$
MMF2	$3.66 \times 10^0 \pm 8.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 5.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 1.03 \times 10^{-2}$	$3.67 \times 10^0 \pm 6.16 \times 10^{-5}$	$3.66 \times 10^0 \pm 4.43 \times 10^{-3}$	$3.67 \times 10^0 \pm 7.26 \times 10^{-4}$
MMF3	$3.66 \times 10^0 \pm 4.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 4.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 1.65 \times 10^{-4}$	$3.67 \times 10^0 \pm 3.02 \times 10^{-5}$	$3.66 \times 10^0 \pm 1.15 \times 10^{-2}$	$3.67 \times 10^0 \pm 3.43 \times 10^{-4}$
MMF4	$3.33 \times 10^0 \pm 3.00 \times 10^{-4}$	$3.33 \times 10^0 \pm 2.00 \times 10^{-4}$	$3.33 \times 10^0 \pm 1.68 \times 10^{-4}$	$3.33 \times 10^0 \pm 2.95 \times 10^{-5}$	$3.32 \times 10^0 \pm 2.21 \times 10^{-6}$	$3.33 \times 10^0 \pm 1.62 \times 10^{-4}$
MMF5	$3.66 \times 10^0 \pm 1.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 0.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 2.62 \times 10^{-4}$	$3.67 \times 10^0 \pm 2.21 \times 10^{-5}$	$3.67 \times 10^0 \pm 1.78 \times 10^{-5}$	$3.67 \times 10^0 \pm 5.55 \times 10^{-4}$
MMF6	$3.66 \times 10^0 \pm 1.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 2.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 5.62 \times 10^{-4}$	$3.67 \times 10^0 \pm 3.43 \times 10^{-5}$	$3.67 \times 10^0 \pm 7.88 \times 10^{-5}$	$3.67 \times 10^0 \pm 5.97 \times 10^{-4}$
MMF7	$3.66 \times 10^0 \pm 1.00 \times 10^{-4}$	$3.66 \times 10^0 \pm 0.19 \times 10^{-4}$	$3.66 \times 10^0 \pm 9.62 \times 10^{-4}$	$3.6 \times 10^0 \pm 4.64 \times 10^{-5}$	$3.67 \times 10^0 \pm 1.71 \times 10^{-5}$	$3.67 \times 10^0 \pm 3.01 \times 10^{-4}$
MMF8	$3.21 \times 10^0 \pm 1.00 \times 10^{-4}$	$3.21 \times 10^0 \pm 1.00 \times 10^{-4}$	$3.21 \times 10^0 \pm 1.30 \times 10^{-3}$	$3.21 \times 10^0 \pm 1.20 \times 10^{-4}$	$3.21 \times 10^0 \pm 7.07 \times 10^{-5}$	$3.21 \times 10^0 \pm 1.28 \times 10^{-3}$
SYM_PART_simple	$1.32 \times 10^0 \pm 5.00 \times 10^{-4}$	$1.32 \times 10^0 \pm 1.00 \times 10^{-3}$	$1.32 \times 10^0 \pm 2.91 \times 10^{-4}$	$1.32 \times 10^0 \pm 3.11 \times 10^{-4}$	$1.32 \times 10^0 \pm 2.43 \times 10^{-4}$	$1.32 \times 10^0 \pm 1.88 \times 10^{-4}$
SYM_PART_rotated	$1.32 \times 10^0 \pm 3.00 \times 10^{-4}$	$1.32 \times 10^0 \pm 7.00 \times 10^{-4}$	$1.32 \times 10^0 \pm 3.32 \times 10^{-4}$	$1.32 \times 10^0 \pm 2.20 \times 10^{-4}$	$1.32 \times 10^0 \pm 2.39 \times 10^{-4}$	$1.32 \times 10^0 \pm 6.02 \times 10^{-4}$
Omni_test	$6.20 \times 10^1 \pm 6.00 \times 10^{-4}$	$6.21 \times 10^1 \pm 6.00 \times 10^{-3}$	$6.206 \times 10^1 \pm 3.62 \times 10^{-4}$	$6.206 \times 10^1 \pm 2.39 \times 10^{-4}$	$6.206 \times 10^1 \pm 2.22 \times 10^{-4}$	$6.206 \times 10^1 \pm 3.38 \times 10^{-4}$

空间中的评价表现较差。

其次,由表3可以看出,在目标空间上的评价指标HV不同算法都很接近,原因是不同算法均使用了非支配排序策略,非支配排序同样考虑了目标空间的分布情况并进行了优化处理,所以均能够找到准确的解。

为了更清晰直观的展示不同算法的PSP值,画出折线图进行直观展示,如图4所示。

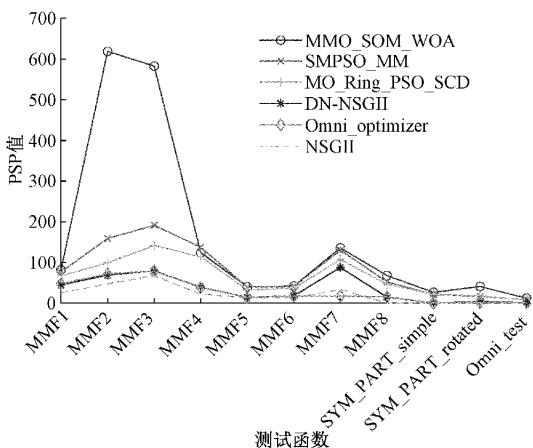


图4 各算法PSP折线比较图

对于图中同一算法的连线在不同测试函数上对比可以看出,MMO_SOM_WOA 算法在不同测试函数上的PSP指标均大于对比算法的PSP值,所以在决策空间中能够找到更多的PS解集,综上所述本文所提的算法在决策空间和目标空间有较高的搜索性能。

4) MMO_SOM_WOA 性能分析

为验证算法在收敛速度和收敛精度的方面的性能,将多模态多目标优化算法(MMO_SOM_WOA、SMPSO_MM、MO_Ring_PSO_SCD、DN_NSGII、Omni-optimizer)在MMF4上进行比较,MMF4的PS分布情况如图5所示。

其PS平均分配在4个子区域且每个区域面积相等,均有一个PS集对应PF。验证算法的收敛性是指每次迭代后个体搜索到不同区域上PS集的比例,理论上讲,个体落在不同区域的比例应该是相同的均为25%,以此来验证算法的收敛性。不同迭代次数个体落在不同区域的比例,如图6所示。

如图6(a)所示,MMO_SOM_WOA 算法在前期有较大的波动,原因是通过SOM自组织形成种群和自适应权重,为进化提供了丰富的种群信息,提高了算法的全局搜索能力。在迭代到60次时,已经搜索到广域位置,逐步提

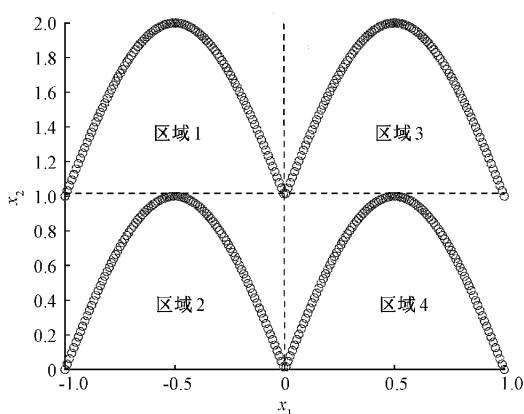
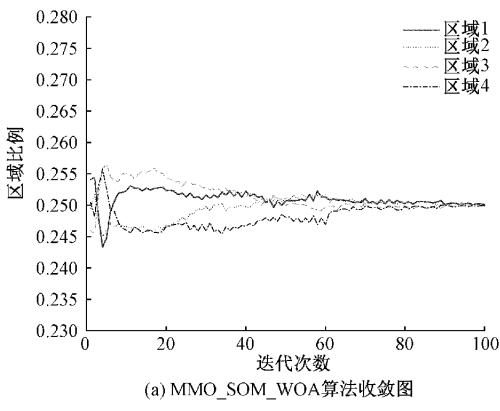
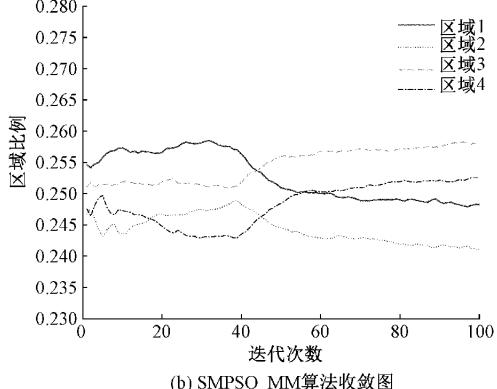


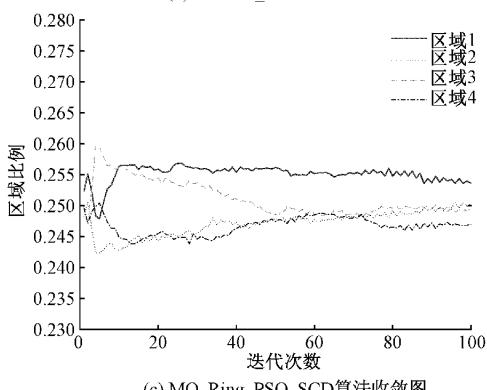
图 5 MMF4 测试问题中 PS 解的分布



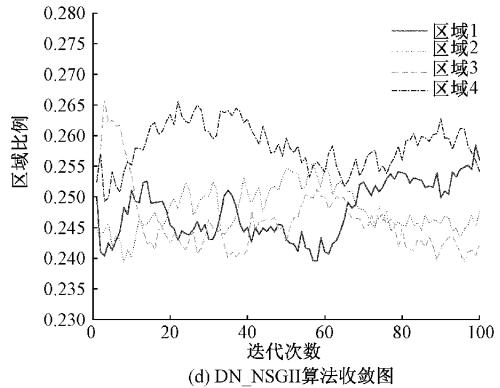
(a) MMO_SOM_WOA 算法收敛图



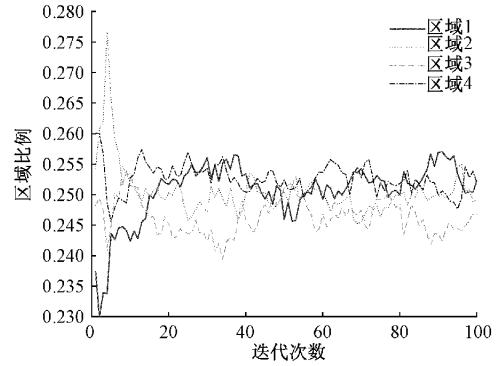
(b) SMPSO_MM 算法收敛图



(c) MO_Ring_PSO_SCD 算法收敛图



(d) DN_NSGII 算法收敛图



(e) Omni-optimizer 算法收敛图

图 6 MMO_SOM_WOA 性能比较图

高搜索的精度,各区域的个体比例区域逐渐稳定,接近25%。SMPSO_MM 算法在区域 2 和 3 的位置能够接近25%,但其他区域波动较大,整体一直处于波动阶段,稳定性不足。MO_Ring_PSO_SCD 算法区域 2 和 3 能够收敛到25%左右,但部分区域 4 的解收敛到区域 1 当中收敛性略差于本算法。DN_NSGII 和 Omni-optimizer 算法的解大部分收敛到了区域 1 和区域 4 当中,每个区域解的比例有较大的波动变化且极不稳定。综上可得,MMO_SOM_WOA 算法在收敛速度和收敛精度上都展现出较好的性能。

4 结 论

本文提出了一种决策空间自组织的多模态多目标鲸鱼优化算法,为更好地提高决策空间的搜索能力,在决策空间当中应用 SOM 模型,为寻优过程提供良好的小生境种群,提高种群进化的多样性和协作交流能力。提出一种新的自适应权重策略提高随机搜索能力和搜索精度并且首次将鲸鱼优化算法用于求解多模态多目标问题,同时通过精英反向学习策略初始化种群,提高了初始种群的质量和多样性。根据实验数据充分验证了其优势性和可靠性。通过仿真实验比较,MMO_SOM_WOA 算法能够找到尽可能多的 Pareto 最优解集,具有较为明显的优势。且算法在搜索速度和收敛精度上都具有较好的性能。各策略共同提升了算法求解多模态多目标问题的整体性能。能够

在现实工程应用中解决实际问题,为决策者提供更多的选择方法。

参考文献

- [1] COELLO C A C, PULIDO G T, LECHUGA M S. Handling multiple objectives with particle swarm optimization[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3): 256-279.
- [2] ELARBI M, BECHIKH S, GUPTA A, et al. A new decomposition-based NSGA-II for many-objective optimization [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2017, 48 (7): 1191-1210.
- [3] TRIVEDI A, SRINIVASAN D, SANYAL K, et al. A survey of multiobjective evolutionary algorithms based on decomposition [J]. IEEE Transactions on Evolutionary Computation, 2016, 21(3): 440-462.
- [4] DEB K, TIWARI S. Omni-optimizer: A procedure for single and multi-objective optimization [C]. International Conference on Evolutionary Multi-Criterion Optimization, Springer, Berlin, Heidelberg, 2005: 47-61.
- [5] 刘云,张洁羽,樊浩研,等.分布式电源配电网多目标优化重构方法研究[J].国外电子测量技术,2021, 40(3):83-87.
- [6] 王龙达,王兴成,刘罡,等.基于偏好的列车运行过程多目标鲨鱼优化算法[J].仪器仪表学报,2020,41(10): 245-256.
- [7] 马学森,谈杰,陈树友,等.云计算多目标任务调度的优化粒子群算法研究[J].电子测量与仪器学报,2020, 34(8):133-143.
- [8] 岳彩通,梁静,瞿博阳,等.多模态多目标优化综述[J].控制与决策,2021,36(11):2577-2588.
- [9] WANG Y, YANG Z, GUO Y, et al. A novel multi-objective competitive swarm optimization algorithm for multi-modal multi objective problems[C]. 2019 IEEE Congress on Evolutionary Computation(CEC), IEEE, 2019: 271-278.
- [10] LIANG J J, YUE C T, QU B Y. Multimodal multi-objective optimization: A preliminary study[C]. 2016 IEEE Congress on Evolutionary Computation(CEC), IEEE, 2016: 2454-2461.
- [11] QU B Y, LI G, LIANG J J, et al. A self-organized speciation based multi-objective particle swarm optimizer for multimodal multi-objective problems[J]. Applied Soft Computing, 2020, 86: 105886.
- [12] YUE C T, QU B Y, LIANG J J. A multiobjective particle swarm optimizer using ring topology for solving multimodal multiobjective problems[J]. IEEE Transactions on Evolutionary Computation, 2017, 22(5): 805-817.
- [13] ZHANG W, LI G, ZHANG W, et al. A cluster based PSO with leader updating mechanism and ring-topology for multimodal multi-objective optimization[J]. Swarm and Evolutionary Computation, 2019, 50: 100569.
- [14] LIANG J J, GUO Y, YUE C T, et al. A self-organizing multi-objective particle swarm optimization algorithm for multimodal multi-objective problems[C]. International Conference on Swarm Intelligence. Springer, Cham, 2018: 550-560.
- [15] LIANG J J, QIAO K, YUE C T, et al. A clustering-based differential evolution algorithm for solving multimodal multi-objective optimization problems[J]. Swarm and Evolutionary Computation, 2021, 60: 100788.
- [16] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.
- [17] 孟宪猛,蔡翠翠.基于精英反向学习和Lévy飞行的鲸鱼优化算法[J].电子测量技术,2021,44(20):82-87.
- [18] 张敏灵,陈兆乾,周志华.SOM算法、LVQ算法及其变体综述[J].计算机科学,2002(7):97-100.
- [19] ZHOU Y, WANG R, LUO Q. Elite opposition-based flower pollination algorithm[J]. Neurocomputing, 2016, 188: 294-310.
- [20] JIANG S, ZHANG J, ONG Y S, et al. A simple and fast hypervolume indicator-based multiobjective evolutionary algorithm [J]. IEEE Transactions on Cybernetics, 2014, 45(10): 2202-2213.

作者简介

刘智睿,硕士研究生,主要研究方向为多模态多目标优化、复杂系统控制与建模。

E-mail:915557317@qq.com

杨志刚(通信作者),硕士研究生,副教授,主要研究方向为智能群优化、多目标优化。

E-mail:yzg-lzy@163.com

赵志伟,博士,教授,主要研究方向为人工智能和板带轧制,包括进化算法、群智能算法。

E-mail:wzzwzz@sina.com

苏皓,博士,副教授,主要研究方向为机器人智能控制系统。

E-mail:66265591@qq.com

葛超,博士,教授,主要研究方向为多智能体系统建模与控制、混沌系统采样控制。

E-mail:gechao365@126.com