

基于多源交配选择策略的重组算子与多目标优化研究

张 屹¹, 陆逸舟¹, 王 帅¹, 陆瞳瞳²

(1. 常州大学机械与轨道交通学院, 江苏常州 213164; 2. 常州大学商学院, 江苏常州 213164)

摘 要: 本文提出了一种基于多源交配选择的多目标进化算法(Multi-source Mating Selection based Multi-objective Evolutionary Algorithms, MMSEA)。在MMSEA算法中, 谱聚类被用来挖掘种群规则特性, 基于所获得的种群结构化信息设计了一种多源交配选择重组算子来引导算法搜索, 通过为每个个体设置多个交配选择源, 在利用相似个体重组加速算法收敛的同时较好地保持了种群的多样性。实验结果表明, 所提重组算子可以有效提升算法性能, 将MMSEA与多种主流的多目标进化算法进行实验对比研究与参数灵敏度分析的结果表明, MMSEA在求解具有复杂特性的典型多目标优化问题测试集时表现出较强的竞争力。

关键词: 聚类学习; 进化算法; 交配选择; 多目标优化

中图分类号: TP18

文献标识码: A

文章编号: 0372-2112(2021)09-1754-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20200397

Research on Reproduction Operator and Multi-objective Optimization Based on Multi-source Mating Selection Strategy

ZHANG Yi¹, LU Yi-zhou¹, WANG Shuai¹, LU Tong-tong²

(1. School of Mechanical Engineering and Rail Transit, Changzhou University, Changzhou, Jiangsu 213164, China;

2. School of Business, Changzhou University, Changzhou, Jiangsu 213164, China)

Abstract: This work proposes a multi-source mating selection based multi-objective evolutionary algorithm (MMSEA). In MMSEA, the spectral clustering algorithm is used to exploit the property of the multi-objective optimization problems. Based on the obtained population structure information, a multi-source mating selection strategy is designed to guide the algorithm search. The convergence of the algorithm is accelerated and the diversity of the population is maintained by setting multiple mating selections for each individual and using similar-based reproduction. The experimental results show that the proposed reproduction operator can effectively improve the performance of the algorithm. MMSEA is experimentally compared with variety of mainstream multi-objective evolutionary algorithms, and parameter sensitivity is also performed. In these experiments, MMSEA demonstrates strong competitiveness over the other approaches in solving typical multi-objective optimization problems with complex characteristics.

Key words: clustering learning; evolutionary algorithm; mating selection; multi-objective optimization

1 引言

在进化多目标优化中, 环境选择和个体重组是其两个基本组件^[1]. 环境选择的作用是选择优秀个体组成父代种群进入下一代, 而个体重组是利用所选择的父代个体进行重组操作产生新个体. 然而, 当前多目标进化算法的研究大都集中于环境选择的设计和研发中, 而针对多目标优化重组算子的研究较少^[2]. 大多数

多目标进化算法仍是直接采用为单目标优化而设计的重组算子, 例如传统的交叉、变异算子(Crossover/Mutation), 模拟二进制交叉(SBX)和分布估计算法(EDAs)等^[3]. 然而这些为单目标优化而设计的重组算子由于忽略了多目标优化问题特性, 因此在求解多目标问题时无法始终表现出良好的性能, 尤其是在处理具有复杂特性的多目标优化问题时^[2].

区别于传统的单目标优化问题,多目标优化问题不仅存在 Pareto 解集 (Pareto Solution Set, PS), 且 PS 呈现出良好的规则特性, 即 PS 在变量空间 (也称决策空间) 中存在 $(m-1)$ 维的流形结构 (Manifold Structure), 利用此规则特性可以有效提高优化算法性能^[2].

近年来, 为利用多目标优化问题特性提高算法性能, 一些基于聚类学习的重组算子成为了多目标优化领域的研究热点, 即利用聚类学习技术挖掘种群结构化信息, 将交配父代选择限制于近邻中, 从而提升种群的局部开采能力加速算法收敛. Zhang 等人^[3], 将自组织映射 (SOM) 的学习过程和多目标进化过程相融合, 减少了计算开销. Sun 等人^[4]考虑了进化数据的非平稳特征, 一种基于在线聚类的多目标进化算法被提出. Li 等人^[5]通过设计自适应的交配限制策略, 平衡多目标进化算法的局部开采和全局勘探. 总的来说, 众多研究工作表明利用聚类学习方法挖掘优化问题信息从而引导算法搜索是一种提升多目标进化算法性能的有效手段.

然而, 当前基于聚类学习的交配限制策略仅直接地设置同一类和整个种群作为父代个体的选择来源, 虽然利用近邻个体重组增强了算法的局部开采从而加速了算法收敛, 但仅依靠全局种群的随机重组不仅限制了算法产生有效新解的效率, 而且难以实现种群的全局勘探以保持其多样性^[6]. 因此, 对于基于聚类学习的重组算子, 如何有效的为个体重组设置交配选择源仍是一个值得深入研究的问题, 而本文也专注于个体重组交配选择源的研究.

在本文工作中, 利用谱聚类算法^[7]挖掘种群规则特性, 基于所获得的种群结构化信息, 将每一个个体的交配父代限制于三个选择来源: (1) 相同类中个体, (2) 所在类及邻近类中个体和 (3) 整个种群. 通过设置交配限制概率来实现三种父代选择来源的平衡, 从而提出了一种多源交配选择的重组算子 (Multi-source Mating Selection, MMS). 将基于多源交配选择的重组算子与快速非支配环境选择^[8]集成后, 最终提出了基于多源交配选择的多目标进化算法 (MMSEA).

与传统单目标重组算子相比, 基于多源交配选择的重组算子利用了种群规则特性信息来引导算法搜索; 与现有基于聚类学习的多目标重组算子相比, 本文提出通过设置多个成包含关系的父代个体选择来源来增强算法的局部开采和全局勘探能力, 且不同交配选择源中的个体结构化信息得到有效保留和应用.

此外, 由于环境选择和个体重组之间呈现出高度的非线性关系^[9], 对于一个多目标进化算法而言, 很难区分环境选择和个体重组对算法的贡献, 为证明本文所提的基于多源交配选择的重组算子的有效性, 将

MMSEA 与同使用快速非支配排序环境选择的一种经典多目标进化算法 NSGA-II^[8]做对比分析, 利用具有复杂 PF 的 GLT^[10]测试集作为测试问题. 后与 4 种当前主流的算法 IM-MOEA^[11]、MOEA/D-CMA^[12]、RM-MEDA^[2]和 SMEA^[3]在 GLT 和 LZ^[13]测试集上做系统性实验对比以及参数灵敏度分析. 实验研究结果表明, 集成了多源交配选择重组算子的 MMSEA 在求解具有复杂特性的多目标优化问题时确实可以有效提高算法性能, 与其他几种主流的进化算法相比, 仍表现出明显的性能优势.

2 基于多源交配选择的多目标进化算法

2.1 MMSEA 算法框架描述

以下符号将会应用到 MMSEA 算法框架的描述中:

K : 聚类数目;

N : 种群大小;

T : 最大进化代数;

β_1 和 β_2 : 交配限制概率;

MMSEA 算法的流程如下:

Step1 初始化 初始化种群 $P = \{x^1, \dots, x^n\}$, 并构建一个外部种群 $A = P$.

Step2 聚类操作 利用谱聚类算法对外部种群 A 进行聚类分析获取聚类结果: $C = \{C^1, C^2, \dots, C^K\}$;

Step3 构建交配池 对于每一个个体 x^i 设置交配源 Q^i :

$$Q^i = \begin{cases} \textcircled{1}C^{K_i} & , \text{if } \text{rand} < \beta_1 \\ \textcircled{2}C^{K_i} \cup C_{\text{Nei}}^{K_i} & , \text{else if } \beta_1 \leq \text{rand} \leq \beta_2 \\ \textcircled{3}A & , \text{other wise} \end{cases}$$

其中 $\textcircled{1}C^{K_i}$ 表示 x^i 所在聚类类别解的集合, rand 表示产生一个在 $[0, 1]$ 中的随机数, $\textcircled{2}C^{K_i} \cup C_{\text{Nei}}^{K_i}$ 表示类 C^{K_i} 及其两个相邻类, $\textcircled{3}A$ 表示整个种群. 其中, 三种交配源之间的关系为 $\textcircled{1} \in \textcircled{2} \in \textcircled{3}$, 即 $\textcircled{2}$ 是 $\textcircled{3}$ 的一个子种群, $\textcircled{1}$ 是 $\textcircled{2}$ 的一个子种群. 并执行 Step4~Step5;

Step4 新解产生 产生新解 y^i 是通过使用差分进化算子^[13] (Differential Evolution, DE) 生成. 首先使用差分进化算子产生一个新初始解, 再利用多项式变异算子变异新产生的解, 为了使新解可行, 在变异操作的前后均根据情况对新解进行修补. 直至产生与原种群 P 相同规模的后代种群 O .

Step5 环境选择 本文直接使用了当前较为流行的 NSGA-II^[17] 中的快速非支配排序环境选择, 即利用快速非支配排序将种群 $[P, O]$ 划分至不同的支配等级中, 在依据拥挤距离依次从最差的支配等级中删除劣解直至与原种群规模一致. 关于环境选择的具体细节参见文献^[17].

Step6 判断终止条件 若算法的迭代次数达到上限 T , 则终止算法, 并且输出最终种群 F , 否则跳转到 Step2.

首先在算法初始化阶段获得初始种群 P 并且设置交配限制率 β_1 和 β_2 . 在迭代过程中建立与初始相同的外部辅助种群 A , 对辅助种群 A 进行谱聚类操作得到聚类结果 $\{C^K\}$. 对于每一个解 x^i 根据其交配限制概率选择一个交配源 Q^i , 其来源分别为: 相同类 ① C^{K_i} 、相同类和近邻类 ② $C^{K_i} \cup C_{N_{\text{nei}}}^{K_i}$ 和全局种群 ③ A . 基于交配池 Q^i 利用差分进化算子 (DE) 生成当前解 x^i 的一个新解 y^i , 并利用环境选择算子对种群 P 进行更新.

2.2 谱聚类算法

谱聚类是一种基于图论的聚类方法, 通过对样本数据的拉普拉斯矩阵的特征向量进行聚类, 从而达到对样本数据聚类的目的^[14]. 谱聚类可以理解为将高维空间的数据映射到低维, 再在低维空间用其他聚类方法 (例如 K-means 算法等) 进行聚类. 其具体的三个步骤如下:

Step1: 利用点对之间的相似性, 构建相似度矩阵 S . 再根据相似度矩阵构建邻接矩阵 W 和度矩阵 D ;

Step2: 构建拉普拉斯矩阵 L , 并计算 L 的特征值和特征向量, 并取前 K 个特征值对应的特征列向量构成矩阵 U ;

Step3: 对矩阵 U 中的行向量, 采用 K-means 等聚类方法完成聚类.

比起传统的 K-Means^[15] 算法, 谱聚类对数据分布的适应性更强, 聚类效果更优秀, 可实现对任意形状的数据的聚类, 有助于处理复杂 PS 或 PF 的多目标优化问题, 因此在本文中我们选择谱聚类算法来探索种群的结构化信息. 关于谱聚类的具体细节可参见文献[8].

2.3 新解产生

本文将 MOEA/D-DE^[13] 算法中新解生成方法直接应用于 MMSEA 算法. 生成新解的过程为: 由 DE 算子生成初始解, 再将多项式变异算子的变异应用于新生成的解, 具体内容如算法 1 所示.

3 实验与结果分析

下文主要是对本文所提出的算法 (MMSEA) 的性能进行评估. 首先介绍了测试函数以及算法综合评价性能指标; MMSEA 与同样基于快速非支配环境选择的 NSGA-II 算法进行对比, 以证明本文所提重组算子的有效性; 为了进一步验证 MMSEA 算法性能, 与几种当前主流的多目标进化算法进行实验对比分析.

3.1 测试函数与性能指标

本文选取了 GLT1-GLT6, LZ1-LZ9 等 15 个目标测

算法 1: $y^i = \text{Generate}(x^i, Q^i, @DE)$

输入:

x^i : 当前解个体;

Q^i : 交配池;

输出:

新解个体 y_i ;

1. 在交配池 Q^i 中随机挑选两个与当前解 $x^i, (1, \dots, n)$ 不同的父类 x_j^i 和 x_k^i ;

2. 建立新的解集 $y' = (y_1', \dots, y_n')$:

$$y_i' = \begin{cases} x^i + F \times (x_j^i - x_k^i), & \text{if rand}() < CR \\ x^i, & \text{other wise} \end{cases}$$

3. 设定 x^i 的边界条件为 a_i 和 b_i ;

4. 校正新解 $y_i': y_i'' = \begin{cases} a_i, & \text{if } y_i' < a_i \\ b_i, & \text{else if } y_i' > b_i; \\ y_i', & \text{other wise} \end{cases}$

5. 校正后的解 y_i'' 产生变异, 并得到新解 y_i :

$$y_i = \begin{cases} y_i'' + \delta_i \times (b_i - a_i), & \text{if rand}() < p_m \\ y_i'', & \text{other wise} \end{cases}$$

其中 $r = \text{rand}()$,

$$\delta_i = \begin{cases} \left[2r + (1 - 2r) \left(\frac{b_i - y_i''}{b_i - a_i} \right)^{\eta_m + 1} \right]^{\frac{1}{\eta_m + 1}} - 1, & \text{if } r < 0.5 \\ 1 - \left[2 - 2r + (2r - 1) \left(\frac{y_i'' - a_i}{b_i - a_i} \right)^{\eta_m + 1} \right]^{\frac{1}{\eta_m + 1}}, & \text{other wise} \end{cases}$$

6. return 新的解 y_i .

试函数测试 MMSEA 算法的性能. 其中, GLT 测试集有着复杂 PF 前沿, 而 LZ 测试集有着复杂 PS 流形结构. 评价指标采用反世代距离评价指标^[16] (Inverted Generational Distance, IGD) 来衡量算法的多样性与收敛性.

反世代距离评价指标是一个综合性能评价指标, 它主要通过计算每个在真实帕累托前沿面上的点 (个体) x^* 到算法获取的个体集合 P 之间的最小距离和, 来评价算法的收敛性能和分布性能. 其定义如下:

$$IGD(P^*, P) = \frac{\sum_{x^* \in P^*} d(x^*, P)}{|P^*|}$$

其中 $d(x^*, P)$ 是指点 x^* 与算法获取的个体集合 P 之间的最短欧氏距离, $|P^*|$ 是指 P^* 中点的个数. IGD 值越小, 算法的综合性能包括收敛性和分布性能越好.

3.2 MMSEA 重组算子有效性分析

如前所述, 为了验证多源交配选择重组算子的有效性, 我们将 MMSEA 与 NSGA-II 进行对比 (如表 1 所示), 并将 NSGA-II 中模拟二进制交叉重组算子用 DE 算子进行替换以确保实验公正性. 选择 GLT 测试集作为两种算法的求解问题, 并独立求解 20 次. 所有的参数

设置与 3.3 节中相同,其中每组测试问题的最优解用粗体标出.

表 1 NSGA-II 与 MMSEA 求解 GLT 测试题独立运行 20 次的 IGD 的平均值(标准差)

测试函数	NSGA-II	MMSEA
GLT1	8.2936e-3 (5.98e-3)	2.9465e-3 (1.00e-4)
GLT2	3.3987e-2 (1.45e-3)	3.2800e-2 (1.67e-3)
GLT3	1.2138e-2 (1.48e-2)	5.9587e-3 (3.34e-4)
GLT4	4.9892e-2 (5.64e-2)	6.6418e-3 (2.49e-4)
GLT5	4.9198e-2 (2.04e-3)	4.8740e-2 (2.22e-3)
GLT6	6.3403e-2 (2.45e-2)	6.3373e-2 (3.68e-2)

从表 1 中可以看出对于具有复杂的 PF 特性的 GLT 测试集,集成了多源交配选择重组算子和 NSGA-II 在 GLT 测试集上都取得了极大地性能改进,这说明本文

所提的多源交配选择重组算子对于提升多目标算法性能是确实有效的.

3.3 MMSEA 与多种算法比较

为了进一步测试 MMSEA 算法的性能,将其与四种主流的多目标进化算法进行实验对比,即与 IM-MOEA, MOEA/D-CMA, RM-MEDA 和 SMEA. 以上 4 种对比算法的贡献都集中于个体重组,为排除环境选择对于算法性能的影响,除 MOEA/D-CMA 外所有算法统一采用 NSGA-II 的环境选择,实验结果如表 2 所示. 其中,算法的初始参数配置如下所示.

公共参数设置 种群大小: $N = 100, M = 15$; 终止条件:最大进化迭代次数 $T = 300$; 运行次数:每种算法独立运行每道测试题 30 次;差分进化算子控制参数: $F = 0.5, CR = 1$; 多项式变异算子控制参数: $p_m = 1/n, \eta_m = 20$.

表 2 IM-MOEA、MOEA/D-CMA、RM-MEDA、SMEA 和 MMSEA 求解 GLT 和 LZ 测试集 30 次的 IGD 的平均值(标准差)

测试函数	IM-MOEA	MOEA/D-CMA	RM-MEDA	SMEA	MMSEA
GLT1	2.1636e-2 (2.24e-3) †	3.7308e-3 (5.03e-5) †	9.9458e-3 (1.68e-2) ≈	5.2948e-3 (3.75e-3) †	3.1258e-3 (2.08e-4)
GLT2	4.1655e-1 (1.88e-1) †	2.9392e-1 (5.57e-2) †	3.3213e-2 (3.71e-3) ≈	3.2962e-2 (9.05e-4) ≈	3.2481e-2 (9.56e-4)
GLT3	1.1281e-1 (2.21e-2) †	4.6405e-2 (2.43e-2) †	1.6649e-2 (1.68e-2) ≈	1.9911e-2 (1.81e-2) †	9.4225e-3 (6.98e-3)
GLT4	2.4272e-2 (5.49e-3) †	2.7759e-2 (5.40e-2) †	4.0532e-2 (6.81e-2) †	1.9493e-2 (3.52e-2) †	1.9480e-2 (4.36e-2)
GLT5	7.6796e-2 (5.56e-3) †	6.2254e-2 (3.89e-3) †	5.0443e-2 (2.98e-3) ≈	4.9678e-2 (2.59e-3) ≈	4.8980e-2 (2.55e-3)
GLT6	7.5728e-2 (4.85e-3) †	9.8866e-2 (4.34e-2) †	5.7637e-2 (5.32e-3) †	5.9097e-2 (2.17e-2) ≈	5.5325e-2 (2.31e-2)
LZ1	8.4173e-3 (4.81e-4) †	4.4249e-3 (1.11e-4) †	3.7063e-3 (2.07e-4) †	7.3968e-3 (4.12e-4) †	3.6975e-3 (2.77e-5)
LZ2	8.4498e-2 (2.14e-2) †	6.7479e-2 (1.49e-2) ≈	8.9720e-2 (1.40e-2) †	6.2417e-2 (1.11e-2) ≈	6.1696e-2 (9.67e-3)
LZ3	5.0090e-2 (1.83e-2) †	4.2813e-2 (2.62e-2) ≈	3.5804e-2 (5.82e-3) ≈	4.6491e-2 (4.71e-3) †	3.4521e-2 (3.58e-3)
LZ4	4.3677e-2 (1.35e-2) ≈	5.9531e-2 (3.26e-2) †	3.7985e-2 (4.51e-3) ≈	5.2835e-2 (7.94e-3) †	3.7098e-2 (7.19e-3)
LZ5	3.9430e-2 (1.21e-2) ≈	3.6349e-2 (1.22e-2) ≈	3.0716e-2 (6.67e-3) §	4.2955e-2 (3.27e-3) †	3.4080e-2 (4.41e-3)
LZ6	1.6939e-1 (4.64e-2) §	1.3494e-1 (1.88e-2) §	2.0677e-1 (9.50e-2) §	2.2759e-1 (7.56e-2) §	6.3633e-1 (3.31e-1)
LZ7	1.7771e-1 (3.65e-2) ≈	2.0807e-2 (3.55e-2) §	3.1515e-1 (1.60e-1) †	3.0218e-1 (3.99e-2) †	1.9785e-1 (3.60e-2)
LZ8	2.1978e-1 (2.62e-2) §	1.1129e-1 (5.44e-2) §	2.3777e-1 (1.29e-1) §	3.0552e-1 (6.48e-2) ≈	3.2844e-1 (6.24e-2)
LZ9	7.7967e-2 (1.15e-2) †	7.8318e-2 (3.17e-2) †	9.3384e-2 (1.34e-2) †	6.2245e-2 (1.00e-2) ≈	5.9312e-2 (1.01e-2)
†/§/≈	10/3/2	9/3/3	6/6/3	8/6/1	
Mean Rank	3.7333	3.2667	3.1333	3.2000	1.7333

IM-MOEA 参数设置 参考向量个数: $M = 15$; 逆模型分组参数: $L = 3$.

MOEA/D-CMA 参数设置 聚类数目: $K = 5$; RM-

MEDA 参数设置: Local PCA 聚类数目: $K = 5$; Local PCA 中最大迭代次数: $T = 50$; 抽样扩展率: $\delta = 0.25$.

SMEA 参数设置 初始学习率: $\tau_0 = 0.9$; 邻居交配

池大小: $H = 10$; 交配限制率: $\beta = 0.9$.

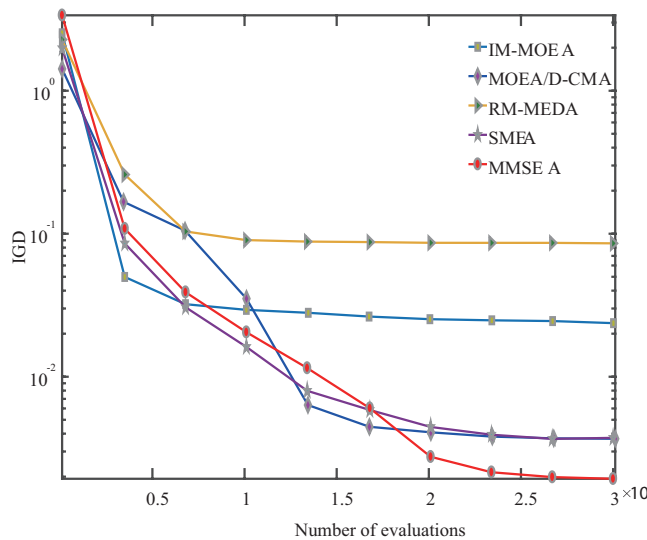
MMSEA 参数设置 聚类数目: $K = 8$; 交配限制概率: $\beta_1 = 0.6$ 和 $\beta_2 = 0.8$.

由于算法运行具有随机性,因此对于每个算法对应其测试问题,都独立运行30次,取IGD平均值如表2所示,最优解由粗体标出.同时,在比较MMSEA算法和任意对比算法在获得平均指标值时,并展开在5%显著水平上Wilcoxon秩和检验,用以观察算法平均指标值之间差异的显著性.“†”,“§”,“~”分别表示MMSEA算法在5%显著水平上是优于,劣于或相似于比较算法对于该问题的求解性能.此外,平均秩排序结果一并给出.

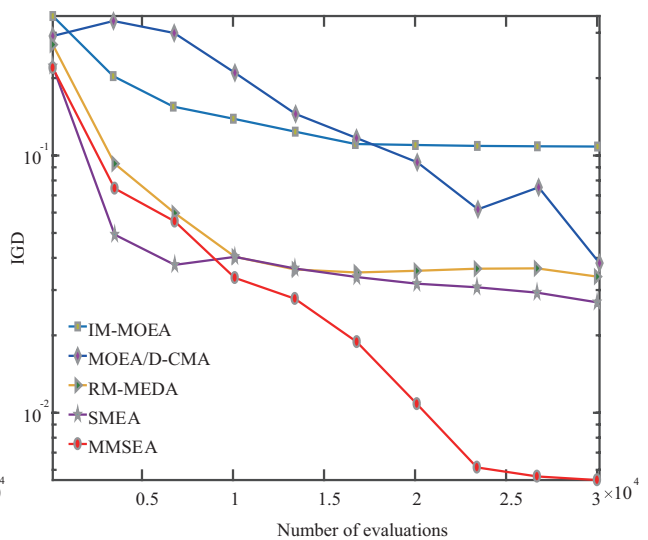
表2显示,在IGD指标上,IM-MOEA, MOEA/D-

CMA, RM-MEDA, SMEA 和 MMSEA 算法分别取得0、3、1、0和11个最佳IGD平均指标值.在所有其他比较算法的15个比较中,在5%显著水平上Wilcoxon秩和检验的表现上,MMSEA算法取得了10、9、6和8个显著优势IGD指标.平均秩排序结果表明MMSAE获得了最好的排序结果.

为分析MMSEA求解效率,图1绘制了IM-MOEA, MOEA/D-CMA, RM-MEDA, SMEA 和 MMSEA 五种算法在对GLT1、GLT3问题每道测试题进行30次独立求解过程中获取中位IGD指标值的随进化代数的变化曲线.由图1中可以看出,MMSEA算法在求解GLT1和GLT3测试题时总能以最快的收敛速度获取最低的IGD指标值.



(a) 求解GLT1的变化曲线



(b) 求解GLT3的变化曲线

图1 IM-MOEA, MOEA/D-CMA, RM-MEDA, SMEA 和 MMSEA 求解GLT1、GLT3测试集30次中获得中位IGD指标值时的变化曲线

综合上述分析, MMSEA 算法在与 IM-MOEA, MOEA/D-CMA, RM-MEDA 和 SMEA 四种当前主流算法相比,在求解具有复杂PF或PS的GLT和LZ测试集时具有一定的竞争力.

3.4 MMSEA 参数敏感性研究

在MMSEA算法中,聚类数目 K 和交配限制率 β_1, β_2 是重要控制参数.为分析MMSEA对设置参数的敏感性,通过设置不同的参数值进行实验,并分析性能指标的统计结果.

对于交配限制概率而言,设置六种不同组合的交配限制概率,即 $(\beta_1/\beta_2) = (0.2/0.4), (0.2/0.6), (0.2/0.8), (0.4/0.6), (0.4/0.8), (0.6/0.8)$,其余参数未做改动.如图2所示,对于GLT1和GLT3两个测试问题独立运行20次,在不同的 β_1 和 β_2 组合值条件下时,IGD平均值总体变化并不明显,但当 (β_1/β_2) 取 $(0.6/0.8)$ 时MMSEA总




图2 MMSEA算法在不同 β_1 和 β_2 组合值下GLT1和GLT3系列套件独立运行20次的IGD指标值的平均值和标准差

能获得较优的IGD值,本文的试验对比中也将这一组参数作为实验对比中的参数设置.

图 3 展示了在不同聚类数目 $K = 2, 4, 6, 8, 10$ 时, MMSEA 在独立求解 GLT 测试集 20 次 IGD 指标的平均值与标准差直方图. 从图 3 中可以看出, 除当 $K = 2$ 时的 IGD 值相对较差, 但整体表现波动较小, 表明算法整体性能受到不同 K 值的影响不大.




图 3 MMSEA 算法在不同 K 值下 GLT 系列套件独立运行 20 次的 IGD 指标值的平均值和标准差

综上所述, MMSEA 对控制参数值不是特别敏感, 该算法具有良好的鲁棒性. 但应该注意的是, 最合适的参数值应与具体问题有关.

4 结束语

为设计适用于多目标优化的重组算子, 本文利用谱聚类挖掘多目标优化问题的规则特性, 根据所获得的聚类信息为种群中每一个个体设置三个父代个体选择来源, 从而设计一种基于多源交配选择的重组算子, 使得算法在利用相似个体重组加速算法收敛的同时, 通过多源交配选择保持了多样性. 将所提重组算子与环境选择集成后, 最终提出了基于多源交配选择的多目标进化算法 (MMSEA).

本文选择了带有复杂 PF 或 PS 的 GLT 和 LZ 测试集作为求解问题, 将其与经典的 NSGA-II 进行实验分析以证明所提重组算子的有效性. 通过测试 MMSEA 算法与其余四种主流多目标优化算法的性能, 相比于其他四种算法, MMSEA 算法在 IGD 指标上具有明显的优势, 说明 MMSEA 算法对比当前主流算法仍有不错的性能表现. 后续工作将利用 MMSEA 算法求解实际工程问题, 并对算法在求解实际问题时做适当调整.

参考文献

[1] Zhou A M, Qu B Y, Li H, et al. Multiobjective evolutionary algorithms: A survey of the state of the art[J]. *Swarm and Evolutionary Computation*, 2011, 1(1): 32 – 49.

[2] Zhang Q F, Zhou A M, Jin Y C. RM-MEDA: A regularity model-based multiobjective estimation of distribution algorithm[J]. *IEEE Transactions on Evolutionary Computation*,

2008, 12(1): 41 – 63.

[3] Zhang H, Zhou A M, Song S M, et al. A self-organizing multiobjective evolutionary algorithm[J]. *IEEE Transactions on Evolutionary Computation*, 2016, 20(5): 792 – 806.

[4] Sun J Y, Zhang H, Zhou A M, et al. Learning from a stream of nonstationary and dependent data in multiobjective evolutionary optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2019, 23(4): 541 – 555

[5] 李欣. 基于聚类的多目标演化算法交配限制策略研究[D]. 哈尔滨: 哈尔滨工业大学, 2019.

Li X. Study of clustering-based mating restriction strategies for multiobjective evolutionary algorithms[D]. Harbin: Harbin Institute of Technology, 2019. (in Chinese)

[6] Wang S, Zhang H, Zhang Y, et al. A spectral clustering-based multi-source mating selection strategy in evolutionary multi-objective optimization[J]. *IEEE Access*, 2019, 7: 131851 – 131864.

[7] Luxburg U. A tutorial on spectral clustering[J]. *Statistics and Computing*, 2007, 17(4): 395 – 416.

[8] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multi-objective genetic algorithm: NSGA-II[J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(2): 182 – 197.

[9] de Jong K. Evolutionary computation: A unified approach [A]. *Proceedings of the 2016 on Genetic and Evolutionary Computation Conference Companion*[C]. New York, NY, USA: ACM, 2016. 185 – 199.

[10] Gu F, Liu H L, Tan K C. A multiobjective evolutionary algorithm using dynamic weight design method[J]. *International Journal of Innovative Computing, Information and Control*, 2012, 8(5 (B)): 3677 – 3688.

[11] Cheng R, Jin Y C, Narukawa K, et al. A multiobjective evolutionary algorithm using Gaussian process-based inverse modeling[J]. *IEEE Transactions on Evolutionary Computation*, 2015, 19(6): 838 – 856.

[12] Li H, Zhang Q, Deng J. Biased multiobjective optimization and decomposition algorithm[J]. *IEEE Transactions on Cybernetics*, 2017, 47(1): 52 – 66.

[13] Li H, Zhang Q F. Multiobjective optimization problems with complicated Pareto sets, MOEA/D and NSGA-II[J]. *IEEE Transactions on Evolutionary Computation*, 2009, 13(2): 284 – 302.


[14] 李伶俐. 谱聚类算法及其应用综述[J]. *软件导刊*, 2016, 15(07): 54 – 56.

[15] 陶莹, 杨锋, 刘洋, 等. K 均值聚类算法的研究与优化[J]. *计算机技术与发展*, 2018, 28(06): 90 – 92.

Tao Y, Yang F, Liu Y, et al. Research and optimization

- of K-means clustering algorithm[J]. Computer Technology and Development, 2018, 28(06): 90 – 92.(in Chinese)
- [16] 张屹, 余振, 李子木, 等. 基于模糊C均值聚类的锦标赛选择机制与多目标优化研究[J]. 电子学报, 2017, 45(11): 2677 – 2684.
Zhang Y, Yu Z, Li Z M, et al. Tournament selection for multiobjective optimization based on fuzzy C-means clustering method[J]. Acta Electronica Sinica, 2017, 45(11): 2677 – 2684.(in Chinese)
- [17] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multi-objective genetic algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182 – 197.

作者简介



张屹 男, 1976年12月出生, 甘肃兰州人, 博士、教授、博士生导师、国家自然科学基金委机械学科评审专家. 分别于2000年、2005年在中国科学技术大学获工学学士学位和工学博士; 2006年至2008年在中国科学技术大学工程力学博士后流动站从事博士后研究, 主要研究方向为机电系统现在设计方案、智能计算等.

E-mail: jxzhanyi1976@126.com



陆逸舟 男, 1996年5月出生, 江苏南京人, 2014年获得常州工学院工学学士学位, 现为常州大学动力工程在读硕士研究生, 主要研究方向为多目标优化算法.

E-mail: luyizhou9605@163.com



王帅 男, 1993年4月出生, 江苏徐州人, 2020年获常州大学硕士学位, 现就读于华东师范大学信息学部计算机科学与技术学院博士研究生, 主要研究方向为多目标优化算法.

E-mail: wangshuai515658@163.com



陆瞳瞳(通讯作者) 女, 1977年2月出生, 江苏无锡人, 副教授. 主要研究方向为多目标优化算法.

E-mail: ppgug@126.com