

## 一种基于 $\varepsilon$ -支配的多目标自组织迁移算法

林志毅<sup>1</sup>, 王玲玲<sup>2</sup>

(1. 广东工业大学 计算机学院, 广州 510006; 2. 武汉大学 软件工程国家重点实验室, 武汉 430072)

**摘要:** 提出一种基于  $\varepsilon$ -支配关系的多目标自组织迁移算法. 首先对基于混合迁移行为的自组织迁移算法进行改进, 将全面学习的思想引入个体的迁移过程中, 使得个体的每个分量都可以向其他个体学习, 从而进行充分的信息交换; 通过引入学习因子扩展个体的迁移方向, 使得步长可灵活变化, 进而利用改进算法快速搜索多目标函数的 Pareto 最优解, 并采用  $\varepsilon$ -支配关系以保持种群分布性; 最后通过实验分析表明了所提出方法的有效性.

**关键词:** 多目标优化;  $\varepsilon$ -支配; 自组织迁移算法;  $\varepsilon$ -支配关系的多目标自组织迁移算法

中图分类号: TP273

文献标志码: A

### A new $\varepsilon$ -dominance based multi-objective self-organizing migrating algorithm

LIN Zhi-yi<sup>1</sup>, WANG Ling-ling<sup>2</sup>

(1. Faculty of Computer, Guangdong University of Technology, Guangzhou 510006, China; 2. State Key Lab of Software Engineering, Wuhan University, Wuhan 430072, China. Correspondent: LIN Zhi-yi, E-mail: lzy291@gdut.edu.cn)

**Abstract:** A  $\varepsilon$ -dominance based multi-objective self-organizing migrating algorithm(EMSOMA) is proposed. Firstly, a hybrid migrating behavior based self-organizing migrating algorithm(HBSOMA) is improved to quickly search the Pareto optimal solutions of the multi-objective optimization problems. The improved HBSOMA introduces the idea of comprehensive learning into the migration process, in which each component of individual can learn from different individuals for exchanging information adequately. Moreover, a learning factor is employed in the migration process to extend the migrating direction and change the step size flexibly. And based on the  $\varepsilon$ -dominance relationship, EMSOMA can maintain the diversity of the population. Finally, the experiment analysis shows the effectiveness of the proposed method.

**Key words:** multi-objective optimization;  $\varepsilon$ -dominance; self-organizing migrating algorithm;  $\varepsilon$ -dominance based multi-objective self-organizing migrating algorithm

## 0 引言

现实世界的多目标优化问题存在多个彼此冲突的目标, 如何获取这些问题的最优解是研究的热点. 进化算法作为一类启发式群体搜索算法, 适用于求解多目标优化问题. Schaffer 于 1985 年首次提出了基于向量评估的 VEGA 算法<sup>[1]</sup>, 此后, 多目标进化算法得到了长足的发展, 出现了 NSGAI<sup>[2]</sup>、 $\varepsilon$ -MOEA<sup>[3]</sup>、MOPSO-CD<sup>[4]</sup>、AMOS<sup>[5]</sup> 和 CMOA-BDC<sup>[6]</sup> 等算法. Laumanns 等<sup>[7]</sup> 于 2002 年提出了  $\varepsilon$ -支配的概念, 对传统 Pareto 支配机制发起挑战, 成为当前多目标进化算法的一个研究热点. 自组织迁移算法(SOMA)是

Zelinka 等<sup>[8]</sup> 于 2000 年提出的一种基于群体自组织行为的新型进化算法, 与其他进化算法相比, SOMA 具有易于并行化、所需调整参数较少的优点, 已广泛应用于函数优化<sup>[9]</sup>、电磁优化<sup>[10]</sup>、多目标优化<sup>[11]</sup> 等领域. 虽然 SOMA 算法对单目标优化问题有较好的效果, 但存在容易陷入局部最优的缺陷, 其主要原因是没有考虑个体之间的行为差异, 使所有个体都朝着当前最优个体方向前进, 当最优个体位置出现停滞时, 会使其他个体迅速靠近该最优个体, 从而导致群体多样性迅速下降, 陷入局部最优.

近年来, 为了避免 SOMA 算法陷入局部最优, 学

收稿日期: 2013-10-17; 修回日期: 2014-02-04.

基金项目: 广东高校优秀青年创新人才培养计划项目(2012LYM.0054); 广州市科技计划项目(2012Y2-00046, 2013Y2-00043).

作者简介: 林志毅(1979—), 男, 讲师, 博士, 从事自然计算、信息安全的研究; 王玲玲(1979—), 女, 讲师, 博士, 从事自然计算、图像识别的研究.

者对其进行改进,取得了一些成果.文献[9-11]提出了基于混合迁移行为的自组织迁移算法(HBSOMA)和基于反向学习的自组织迁移算法;Leandro将文化算法引入SOMA算法框架中,形成了文化自组织迁移算法<sup>[10]</sup>,这些均在一定程度上提高了算法的性能.到目前为止,绝大部分SOMA算法的研究都集中在单目标优化方面,多目标优化方面仅有文献[12]将非支配排序和拥挤距离的概念与SOMA算法相结合,提出了多目标自组织迁移算法(MOSOMA).但是,MOSOMA采用的是传统的非支配排序,需要耗费较多的时间才能获得较好的分布度,也没有对基本SOMA算法存在容易陷入局部最优的问题进行改进,因此难以获得较为满意的结果.

鉴于此,为了进一步提高SOMA算法求解多目标优化问题的性能,本文在HBSOMA算法和 $\varepsilon$ -支配的基础上,提出一个新的基于 $\varepsilon$ -支配的多目标自组织迁移算法(EMSOMA).该算法首先针对HBSOMA算法未考虑负方向上的搜索和步长固定不利于精细搜索的问题,对其进行进一步改进,增加了迁移过程的全面学习和学习因子等机制,进而提高了HBSOMA算法的搜索能力;然后,利用 $\varepsilon$ -支配方法的精英保留策略对外部档案保存得到的非劣解集进行更新,使算法在演化过程中不会丢失精英解,并能快速获得分布较均匀的非劣解集;最后,通过一组标准测试问题进行实验验证,所得结果表明了EMSOMA得到的非劣解集分布较均匀,能够较好地逼近真实Pareto前沿,在收敛性和多样性上与所比较算法相当.

## 1 基于 $\varepsilon$ -支配关系的多目标自组织迁移算法 EMSOMA

EMSOMA是在HBSOMA算法的基础上采用基于 $\varepsilon$ -支配关系的精英保留策略以求解多目标优化问题.设置一个外部档案Archive,采用 $\varepsilon$ -支配关系使得外部档案具有较好的分布性和多样性,并利用精英保留策略确保算法的收敛性.引入全面学习和学习因子等机制对HBSOMA进行改进,进而利用该改进算法生成新个体,再通过种群更新方法实现种群的进化.

### 1.1 外部档案的更新策略

EMSOMA使用一个外部档案Archive存储求解所得的非劣解集,并采用文献[7]提出的 $\varepsilon$ -支配方法进行该Archive的更新.设 $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_r)$ 为目标函数容差数组,每个解在Archive中分配一个识别数组Box = (box<sub>1</sub>, box<sub>2</sub>, ..., box<sub>r</sub>).其中: $r$ 为目标函数个数;box <sub>$j$</sub> 计算为

$$\text{box}_j = [(f_j - f_j^{\min})/\varepsilon_j], \quad (1)$$

$f_j$ 为个体第 $j$ 个目标的函数值, $f_j^{\min}$ 为第 $j$ 个目标的可能最小函数值.识别数组Box将整个目标空间划分为若干个网格,并规定每个网格只能存放一个解,每个解根据相应的识别数组Box按 $\varepsilon$ -支配方法存储到对应的网格中.根据上述思想,外部档案的更新算法如下所示.

**算法 1** 外部档案的更新算法 Update( $X, x$ ).

- 1: Input:  $X, x$  //  $X$  为当前的外部档案,  $x$  为新个体
- 2: if  $\exists x' \in X$  such that  $x' \prec_\varepsilon x$  then // 如果存在  $x'$   $\varepsilon$ -支配  $x$ , 则拒绝接受  $x$
- 3: Output:  $X$ ; // 算法终止
- 4: else // 如果档案不存在个体  $\varepsilon$ -支配  $x$ , 则
- 5:  $D := \{x' \in X | x \prec_\varepsilon x'\}$
- 6: if  $D \neq \phi$  then // 有个体被  $x$   $\varepsilon$ -支配
- 7:  $X := \{X \setminus D\}$
- 8:  $X' := X \cup \{x\}$
- 9: Output:  $X'$ ; // 算法终止
- 10: else
- 11: if  $\exists x' \in X$  such that  $x.\text{Box} == x'.\text{Box}$  then //  $x$  和  $x'$  在同一网格
- 12: if  $x \preceq x'$  or  $\text{distance}(x', x.\text{Box}) > \text{distance}(x, x.\text{Box})$  then //  $x$  支配  $x'$  或者  $x$  比  $x'$  更接近网格
- 13:  $X' := \{X \setminus x'\} \cup \{x\}$  // 删除  $x'$  接受  $x$
- 14: end if
- 15: else // Archive 中没有个体与  $x$  在同一网格
- 16:  $X' := X \cup \{x\}$
- 17: end if
- 18: end if
- 19: end if
- 20: Output:  $X'$ . // 算法终止

其中 distance 函数的计算方式如下:

$$\text{distance}(x, y) = \sqrt{\sum_{i=1}^r (x.f_i - y.\text{box}_i)^2}. \quad (2)$$

### 1.2 改进的个体迁移过程

基本SOMA的核心为种群中个体的迁移过程,其基本思想是在每次迁移过程中,个体以步长Step向种群的最好个体(领导者leader)跳跃,一直持续到最大迁移路径长度PathLength为止,记录在跳跃过程遇到的最好位置,并与原先位置对比,然后个体朝两者中的较优位置迁移.

虽然基本SOMA具有较快的收敛速度,但是在迁移过程中,其他个体总朝着当前最优位置正方向

移动, 当最优位置产生停滞时, 其他个体迅速靠拢, 从而导致算法早熟收敛. 从多态性角度分析, 其主要原因是基本 SOMA 没有考虑个体的行为差异, 使所有个体都朝着当前最优解靠近<sup>[9]</sup>. 文献 [9] 提出了基于混合迁移行为的自组织迁移算法 HBSOMA, 在基本 SOMA 中引入差分进化的迁移方式, 使个体能朝多个方向迁移, 从而提高了算法跳出局部最优的可能. 然而, 与基本 SOMA 一样, HBSOMA 中的个体在迁移过程中依旧只朝着最优解或其他解的正方向跳跃, 即跳跃只在正方向的  $(0, \text{PathLength})$  范围内. 由于其跳跃时未考虑最优解或其他解的负方向, 负方向上的一些搜索空间被忽略, 进而降低了算法全局搜索的能力. 此外, HBSOMA 将步长 Step 设置为一个固定值, 并且限定个体迁移的步长必须为 Step 的整数倍, 从而导致个体的搜索路径较为单一, 无法进行更精细的局部搜索, 使得算法的求解精度不能提高.

为了克服 HBSOMA 存在的问题, 本文将全面学习的思想引入到 SOMA 算法的迁移过程中, 并增加学习因子. 在每一次迁移过程中, 当前个体的每一维以随机的方式从种群或 Archive 群体中选择一个与当前个体不同的个体, 向该个体的对应维学习, 并在迁移过程中引入学习因子  $\alpha$ ,  $\alpha$  为  $[-1, 1]$  区间内均匀分布的随机数, 对每一维都是随机生成. 此外, 由于在搜索过程中可能会得到比当前最优个体更好的个体, 如果等到下一次循环才更新最优个体信息, 则会导致种群中当次循环剩余个体的搜索成为多余搜索. 因此, 有必要及时更新搜索过程中的最优个体信息, 从而进一步提高算法的搜索性能.

在考虑多目标优化的基础上, 上述改进个体迁移过程如下所示.

**算法 2** 改进的个体迁移过程.

1:  $t \leftarrow \text{PathLength} // t \in (0, \text{PathLength})$

2: for  $i = 1$  to  $N$  do //  $N$  为种群规模

3: while  $t \leq \text{PathLength}$  do

4: 生成 PRTVector;

5:  $\text{CR} = \text{rand}(0, 1)$ ;

6: if  $\text{rand}(0, 1) > \text{CR}$  then

7: for  $j = 1$  to  $\text{dim}$  do //  $\text{dim}$  为问题维数

8: 从种群或 Archive 群体中随机选择一个与当前个体不同的个体  $v$ ;

9:

$$X_{\text{temp}} = X_{i, \text{start}}^{ML} + \alpha(X_v^{ML} - X_{i, \text{start}}^{ML})t\text{PRTVector}$$

10: end for

11: else

12: 找出与当前个体  $i$  不同的两个个体  $v_1, v_2$

13: for  $j = 1$  to  $\text{dim}$  do

14:

$$X_{\text{temp}} = X_{i, \text{start}}^{ML} + \alpha(X_{v_2, \text{start}}^{ML} - X_{v_1, \text{start}}^{ML})t\text{PRTVector}$$

15: end for

16: end if

17: 计算  $f(X_{\text{temp}})$ ; // 计算  $X_{\text{temp}}$  适应值

18: update( $X, X_{\text{temp}}$ ); // 根据算法 1, 利用  $X_{\text{temp}}$  更新外部档案

19: updatepop(pop,  $X_{\text{temp}}$ ); // 利用  $X_{\text{temp}}$  更新种群, 方法见第 2.3 节

20:  $t \leftarrow t + \text{Step}$

21: end while

22: end for

其中: PathLength 为迁移的最大步长值; 函数 rand(0, 1) 用于生成  $[0, 1]$  区间内的随机数;  $X_{i, \text{start}}^{ML}$  为第  $i$  个个体迁移开始时的位置; 参数 PRT 为  $[0, 1]$  区间内的一个实数, 向量 PRTVector 的生成依赖于 PRT, 如果 PRT 小于或等于  $(0, 1)$  的随机实数, 则 PRTVector 的值为 0, 否则为 1.

在上述改进的个体迁移过程中, 全面学习的引入使得每个个体的信息既可能来自全局最优解, 也可能来自其他个体相应位的学习, 使得个体之间能够实现较为充分有效的信息交流, 有效增加种群的多样性, 进而提高 HBSOMA 算法对复杂问题的求解能力. 学习因子  $\alpha$  的引入将个体的跳跃范围扩大为  $(-\text{PathLength}, \text{PathLength})$ , 使个体的跳跃可沿着正负两方向进行, 提高了算法的全局搜索能力. 学习因子  $\alpha$  还起到动态改变步长的作用, 使步长不再是一个固定值, 从而提高算法的局部搜索能力和求解精度. 此外, 在上述迁移过程中还利用 Archive 群体中的非劣个体作为基点, 指导种群演化, 不仅可以加快算法收敛到全局最优解的速度, 而且由于每次是随机选取, 也在一定程度上避免了单目标求解过程中陷入局部最优解的问题.

### 1.3 种群更新方法

与外部档案更新方法不同, 种群更新方法采用传统 Pareto 支配方式, 具体如下:

1) 如果新个体被种群中的任一个体 Pareto 支配, 则不接受新个体;

2) 如果新个体不被种群任一个体 Pareto 支配, 且新个体 Pareto 支配种群中的任一个体, 则新个体随机替换被其支配的一个个体;

3) 如果以上都不满足, 则意味着新个体与种群中个体为非支配关系, 新个体随机替换种群的一个个体, 从而使种群在保证规模不变的情况下加入新个体.

#### 1.4 新算法流程和时间复杂度分析

综合以上步骤, 算法 3 给出了 EMSOMA 的算法流程.

**算法 3** EMSOMA 算法流程.

输入: 种群大小  $N$ 、 $\varepsilon$  参数大小、初始步长 Step、PathLength 等参数;

输出:  $X$  (非支配解集).

Step 1: 初始化. 生成初始种群  $P$  和档案集  $X = \{\cdot\}$ , 设定迁移代数  $ML = 0$ .

Step 2: 适应值计算. 计算  $P$  中个体的适应值, 将其中的不可支配个体复制到外部档案  $X$  中.

Step 3: 按算法 2 进行种群  $P$  的个体迁移.

Step 4: 如果不满足终止条件, 则令  $ML = ML + 1$ , 从 Step 3 处开始重新进化; 否则,  $X$  即为最终输出.

根据 EMSOMA 算法的流程, 分析算法在最坏情形下第  $ML$  代的计算时间消耗, 设进化种群  $P_{ML}$  的规模为  $N$ , 外部档案  $X_{ML}$  的大小为  $E$ ,  $m$  为目标函数维数,  $r$  为目标数. 初始化种群的时间复杂度为  $O(Nm)$ , 种群中每个个体适应值的时间复杂度为  $O(Nmr)$ , 将种群划分为可支配和不可支配个体的时间复杂度为  $O(N^2r)$ . 算法 2 的时间复杂度为  $O(iN(m+mr+E^2r))$  ( $i = \text{PathLength}/\text{Step}$ ), 总时间复杂度为  $O(Nm + Nmr + iNm + iNmr + iNE^2r)$ . 选择合适的参数  $\varepsilon$  使  $E$  与  $N$  同阶 (目标数一般较小, 为个位数, 此略), 则上述一次迭代的时间复杂度可简化为  $O(2Nm + 2iNm + iN^3)$  (种群更新时间忽略不计).

## 2 实验分析

本文实验采用文献 [2] 的 6 个多目标测试函数 (KUR, ZDT1-4, ZDT6) 和文献 [13] 的 2 个 ZDT 变种函数 ZDT1.1 和 ZDT2.1 (变量线性相关的测试函数) 作为测试用例, 以验证 EMSOMA 的性能. 将 EMSOMA 与 NSGAI,  $\varepsilon$ -MOEA, MOPSO-CD 和 AMOSA 等多目标进化算法进行比较分析, 以表明 EMSOMA 的有效性和优越性. 本文采用当代距离指标 GD 度量非劣解集的收敛性<sup>[1]</sup>, 采用  $\Delta$  准则<sup>[2]</sup>度量非劣解集的多样性.

### 2.1 参数设置

所有算法均采用实数编码, 将共同参数作如下设置: 种群规模  $N = 100$ , 终止条件为评价次数超过 100 000. 在 EMSOMA 和  $\varepsilon$ -MOEA 算法中, 为了使得最终获得的非劣解个数在 100 左右, 对于 KUR,  $\varepsilon = (0.035, 0.035)$ ; 对于 ZDT1, ZDT2, ZDT4, ZDT1.1 和

ZDT2.1,  $\varepsilon = (0.0070, 0.0070)$ ; 对于 ZDT3,  $\varepsilon = (0.0025, 0.0025)$ ; 对于 ZDT6,  $\varepsilon = (0.0065, 0.0065)$ . EMSOMA 的其他参数设置如下: PathLength = 2.1, Step = 0.21, PRT = 0.10. NSGAI 的其他参数设置与文献 [2] 一致,  $\varepsilon$ -MOEA 的其他参数设置与文献 [3] 一致, MOPSO-CD 的其他参数设置与文献 [4] 一致, AMOSA 的其他参数设置与文献 [5] 一致.

### 2.2 实验结果分析

EMSOMA 采用 C++ 语言实现, 所有测试均在 Pentium 4 3.40 G CPU、1 G 内存和 Windows XP 操作系统环境下进行. 对于每个测试函数, 算法均独立运行 20 次, 并进行 GD 和  $\Delta$  值的统计. 本文将 EMSOMA 的统计结果与  $\varepsilon$ -MOEA、MOPSO-CD、NSGAI 和 AMOSA 进行比较. 在上述参数设置的情况下, 表 1 为各算法 GD 平均值的比较, 图 1 和图 2 为各算法在 ZDT3 和 ZDT6 函数上 GD 平均值与评价次数的关系曲线.




图 1 ZDT3 各算法 GD 与评价次数的关系




图 2 ZDT6 各算法 GD 与评价次数的关系

由表 1 可见, EMSOMA 具有很好的收敛性, 其 GD 平均值均较小, 在 20 次运算中均收敛于优化问题的真正 Pareto 前沿, 且在所有测试函数上均优于 MOPSO-CD、NSGAI 和 AMOSA. 在 KUR、ZDT1 和 ZDT2 上, 表现稍逊于  $\varepsilon$ -MOEA, 在其他 5 个测试函数上优于  $\varepsilon$ -MOEA. AMOSA 的收敛性尚可, 但对函数 ZDT6 的效果较差, 且整体表现比 EMSOMA 和  $\varepsilon$ -MOEA 差. NSGAI、MOPSO-CD 的收敛性要差很多, 尤其对于 ZDT4、ZDT6 两个测试函数, 容易陷入问题的局部 Pareto 前沿. 由图 1 和图 2 可见, EMSOMA 能

表 1 各算法 GD 平均值的比较

Algorithm	Problem							
	KUR	ZDT1	ZDT2	ZDT3	ZDT4	ZDT6	ZDT1.1	ZDT2.1
MOPSO-CD	0.0167	0.0070	0.0009197	0.1371	0.4427	0.6260	0.0343	0.0132
$\epsilon$ -MOEA	<b>0.0077</b>	<b>0.0002073</b>	<b>0.0002247</b>	0.000005287	0.00003869	0.0778	0.0038	0.0059
EMSOMA	0.0078	0.0002416	0.0002266	<b>0.000004698</b>	<b>0.00002285</b>	<b>0.0000004582</b>	<b>0.0036</b>	<b>0.0041</b>
NSGAI	0.0127	0.0247	0.0010	0.0197	2.34622	0.2204	0.0145	0.0116
AMOS	0.0244	0.0044	0.0008138	0.0059	0.0006102	0.8713	0.0061	0.0049

表 2 各算法  $\Delta$  平均值的比较

Algorithm	Problem							
	KUR	ZDT1	ZDT2	ZDT3	ZDT4	ZDT6	ZDT1.1	ZDT2.1
MOPSO-CD	0.2848	0.2839	0.2670	0.6106	1.6304	1.1576	0.3198	0.2970
$\epsilon$ -MOEA	0.2628	0.3535	<b>0.2422</b>	0.4909	0.3613	<b>0.1844</b>	0.3137	0.3046
EMSOMA	<b>0.2615</b>	<b>0.2669</b>	0.2903	0.4902	<b>0.2760</b>	0.2343	<b>0.2699</b>	<b>0.2902</b>
NSGAI	0.4951	0.4243	0.4346	<b>0.4031</b>	0.4514	0.7611	0.3935	0.3758
AMOS	0.7143	0.5951	0.5940	0.7021	0.7566	1.0809	0.7857	0.9834

较快地逼近真实 Pareto 前沿, 其收敛速度与  $\epsilon$ -MOEA 相当, 优于其他比较算法. 这表明所设计的多目标自组织迁移算法 EMSOMA 能更有效地求解所测试的函数, 并较快地收敛于真正的 Pareto 前沿.

表 2 为各算法多样性的统计结果. 由表 2 可见, 在 KUR、ZDT1、ZDT4、ZDT1.1 和 ZDT2.1 五个测试函数上, EMSOMA 要优于其他 4 个算法. 在 ZDT3 上, 虽然 NSGAI 的多样性优于 EMSOMA, 但其收敛性的表现较 EMSOMA 差得多, 在 ZDT6 上也可以得到类似结果. 对于 ZDT2,  $\epsilon$ -MOEA 在多样性和收敛性上均稍优于 EMSOMA. 从表 2 的整体结果对比而言, EMSOMA 的多样性比  $\epsilon$ -MOEA 稍好, 比 MOPSO-CD、NSGAI 和 AMOS 好得多, 进一步验证了本文所设计算法的有效性.

为了弥补数值评价方式不直观的缺陷, 并进一步了解各算法性能的优劣, 本文给出各算法在 ZDT3、ZDT4 和 ZDT6 三个测试函数上运行一次所得非劣解集的对比图, 如图 3~图 5 所示, 其中 True POF 表示优化问题的真正 Pareto 前沿.




图 3 ZDT3 所得非劣解集的 Pareto 前沿比较

从图 3~图 5 可以看出, 与其他 4 种算法相比, EMSOMA 的 Pareto 前沿更接近优化问题的真正 Pareto 前沿, 且更均匀地覆盖整个 Pareto 前沿. 值得

注意的是, 由于采用了同样的  $\epsilon$  值, 对于前沿面分布几乎接近垂直和水平时, 很多 Pareto 解得不到保存, 所以相对较为稀疏 (如 ZDT3 的右下部分), 需要进一步研究.




图 4 ZDT4 所得非劣解集的 Pareto 前沿比较




图 5 ZDT6 所得非劣解集的 Pareto 前沿比较

### 3 结 论

本文将自组织迁移算法应用于多目标领域, 提出了一种新的多目标自组织迁移算法 EMSOMA. 首先给出一个改进自组织迁移算法, 在基于混合迁移行为的自组织迁移算法 HBSOMA 中引入全面学习和学习因子, 以进行个体间充分的信息交换, 扩大个体的迁移范围, 并及时更新个体信息, 确保了算法的多样性和收敛性, 从而进一步提高自组织迁移算法求解多目标优化问题的性能. 利用改进算法进行 Pareto 最优前沿的搜索, 得到的非劣解由外部档案 Archive 保存, 并

使用  $\varepsilon$  支配方法进行 Archive 更新, 保证了算法的多样性和均匀性.

通过 8 个标准测试函数对 EMSOMA 进行测试, 并与  $\varepsilon$ -MOEA、MOPSO-CD 和 NSGAI 算法进行对比. 结果表明, EMSOMA 具有较好的收敛性和多样性, 且算法稳定性较好, 在 20 次运算中均能有效收敛于所测试问题的真正 Pareto 前沿. 下一步的工作是研究 EMSOMA 在其他领域上的应用.

#### 参考文献(References)

- [1] Zhou Aimin, Ou Bo-yang, Li Hui, et al. Multiobjective evolutionary algorithms: A survey of the state of the art[J]. *Swarm and Evolutionary Computation*, 2011, 1(1): 32-49.
- [2] Kalyanmoy Deb, Amrit Pratap, Sameer Agarwal, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(2):182-197.
- [3] Kalyanmoy Deb, Manikant Mohan, Shikhar Mishra. Towards a quick computation of well-spread pareto-optimal solutions[C]. *The 2nd Int Conf Evolutionary Multi-Criterion Optimization*. Faro: Springer, 2003: 222-236.
- [4] Raquel C R, Naval P C, An effective use of crowding distance in multiobjective particle swarm optimization[C]. *Proc of Genetic and Evolutionary Computation Conf*. Washington DC: ACM Press, 2005: 257-264.
- [5] Bandyopadhyay S, Saha S, Maulik U, et al. A simulated annealing-based multiobjective optimization algorithm: AMOSA[J]. *IEEE Trans on Evolutionary Computation*, 2008, 12(3): 269-283.
- [6] 耿焕同, 朱海峰, 张茜, 等. 均衡分布性与收敛性的协同进化多目标优化算法[J]. *控制与决策*, 2013, 28(1): 55-60.  
(Geng H T, Zhu H F, Zhang Q, et al. Co-evolutionary multi-objective optimization algorithm with balanced diversity and convergence[J]. *Control and Decision*, 2013, 28(1): 55-60.)
- [7] Laumanns M, Thiele L, Deb K, et al. Combining convergence and diversity in evolutionary multiobjective optimization[J]. *Evolutionary Computation*, 2002, 10(3): 263-282.
- [8] Zelinka I, Lampinen J. SOMA-self-organizing migrating algorithm[C]. *Proc of the 6th Int Conf on Soft Computing*. Brno: Technical University Press, 2000: 177-187.
- [9] 林志毅, 李元香, 王玲玲. 基于混合迁移的自组织迁移算法[J]. *计算机科学*, 2008, 35(12): 175-177.  
(Lin Z Y, Li Y C, Wang L L. Hybrid migrating behavior based self-organizing migrating algorithm[J]. *Computer Science*, 2008, 35(12): 175-177.)
- [10] Leandro dos Santos Coelho, Piergiorgio Alotto. Electromagnetic optimization using a cultural self-organizing migrating algorithm approach based on normative knowledge[J]. *IEEE Trans on Magnetics*, 2009, 45(3): 1446-1449.
- [11] Kadlec P, Raida Z. A novel multi-objective self-organizing migrating algorithm[J]. *Radio Engineering*, 2011, 20(4): 804-816.
- [12] 林志毅, 王玲玲. 基于反向学习的自组织迁移算法[J]. *计算机科学*, 2012, 39(5): 217-218.  
(Lin Z Y, Wang L L. Opposition-based self-organizing migrating algorithm[J]. *Computer Science*, 2012, 39(5): 217-218.)
- [13] Zhang Q, Zhou A, Jin Y. RM-MEDA: A regularity model-based multiobjective estimation of distribution algorithm[J]. *IEEE Trans on Evolutionary Computation*, 2008, 12(1): 41-63.

(责任编辑: 郑晓蕾)