

# 多目标进化算法研究进展<sup>\*</sup>)

郑向伟 刘弘

(山东师范大学信息科学与工程学院 济南 250014)

**摘要** 进化算法具有本质上并行、不要求导或其他辅助知识、一次运行产生多个解和简单易于实现等优点,被视为求解多目标优化问题的有效方法,目前已经形成了各种不同的多目标进化算法(MOEA)。本文首先回顾了多目标进化算法的研究起源,给出了多目标优化问题的数学描述;其次,详细分析了第一代多目标进化算法,其主要特征是简单易于实现,包括 NSGA、NPGA、MOGA 等,并指出这一代算法研究的成绩与不足;然后,对第二代多目标进化算法作了全面分析,指出其特征是强调效率,以精英保留策略为实现机制,且对 SPEA、PAES、NSGA II、NPGA2、PESA、Micro-GA 等方法进行分析比较,还对这一代的研究作了总结;最后,对多目标进化算法的研究趋势作了展望和预测。

**关键词** 多目标优化,多目标进化算法,Pareto 非劣最优,精英保留策略

## Progress of Research on Multi-Objective Evolutionary Algorithms

ZHENG Xiang-Wei LIU Hong

(School of Information Science and Engineering, Shandong Normal University, Jinan 250014)

**Abstract** Evolutionary Algorithms (EAs) have become popular in multi-objective optimization problems, which are parallel in nature and don't require differentiability of objective functions and constraints, and also which deal with a set of possible solutions in a single run. Many Multi-Objective Evolutionary Algorithms (MOEAs) are proposed at present. Firstly, this paper reviews the origin of MOEAs; secondly, the first generation MOEAs are analyzed, which are characterized by simplicity, such as NSGA, NPGA, MOGA and so on, and the achievements and shortage during the first generation are also discussed. Thirdly, the MOEAs developed during the second generation, including SPEA, PAES, NSGA II, NPGA2, PESA, Micro-GA and etc., are detailed and compared, which use elitism to improve the efficiency. At last, some important research areas of MOEA are addressed.

**Keywords** Multi-objective optimization, MOEA, Pareto non-dominance, Elitism

## 1 引言

工程实践和科学研究中优化问题大多是多目标优化问题(Multi-objective Optimization Problem, MOP),各目标之间通过决策变量相互制约,对其中一个目标优化必须以其它目标作为代价,而且各目标的单位又往往不一致,因此很难客观地评价多目标问题解的优劣性。例如,在设计一座桥梁时,我们一方面希望建设桥梁的费用最小,另一方面希望桥梁具有最大的安全性。与单目标优化问题的本质区别在于,多目标优化问题的解不是唯一的,而是存在一个最优解集合,集合中元素称为 Pareto 最优或非劣最优(non-dominance)。求解它们需要用不同于单目标优化的数学工具,甚至最优的含义也发生了变化<sup>[1,2]</sup>。

自 1950 年以来,运筹学研究人员已经建立了许多方法解决 MOP。在专业文献中,有许多数学规划技巧解决 MOP,如多目标加权法、分层序列法、约束法、目标规划法等。然而,传统数学规划方法存在一些缺陷,例如有些方法对 Pareto 前沿比较敏感,当 Pareto 前沿是凹的或者不连续时,这些方法失效;有些方法要求目标函数和约束条件可微;有些方法每次运行只产生一个解,求多个解时需要运行多次,效率较低。而自 1975 年 John Holland 提出遗传算法(Genetic Algorithm,

GA)以来,基于生物模拟的进化算法(Evolutionary Algorithm, EA)得到了深入研究,由于其具有并行、不要求导或其它辅助知识、一次产生多个解和简单易于实现等优点,被视为求解 MOP 的有效方法。将进化算法用于求解多目标优化问题,被称为进化多目标优化(Evolutionary Multi-objective Optimization, EMO),研究人员已经提出了多种用于求解多目标的进化算法(Multi-objective Evolutionary Algorithm, MOEA)<sup>[3]</sup>。

进化多目标优化始于 1967 年, R. S. Rosenberg 在其博士论文提出了使用遗传算法解决 MOP,然而他当时并没有建立实际的多目标优化算法, MOP 被表述为单目标问题,并用遗传算法求解<sup>[4]</sup>。David Schaffer 是 20 世纪 80 年代中期第一个设计多目标进化算法的人,其方法称为向量评价遗传算法(Vector Evaluated Genetic Algorithm, VEGA)<sup>[5]</sup>。一般认为, MOEA 发展到今天经历了两个阶段<sup>[6]</sup>:第一阶段从 20 世纪 80 年代中期到 90 年代中期, MOEA 以简单为特征,称为第一代 MOEA,主要包括 NSGA、NPGA、MOGA 等<sup>[7]</sup>;第二阶段从 20 世纪 90 年代中期至今, MOEA 以效率为特征,以精英保留策略为实现机制,称为第二代 MOEA,主要包括 SPEA、SPEA2、PAES、NSGA II、PESA 等。

本文首先介绍了进化多目标优化的研究起源,接着给出

<sup>\*</sup> 本文得到国家自然科学基金(69975010, 60374054);山东省自然科学基金(Y2003G01)的支持。郑向伟 博士研究生,主要研究方向为计算智能、计算机辅助设计、CSCW 等;刘弘 博士,教授,博士生导师,主要研究方向为 CSCW、多 Agent 系统、进化计算等。

了 MOP 的数学描述,详细分析了第一代 MOEA 和第二代 MOEA 的主要算法和各个发展阶段的特点,然后对 MOEA 的研究趋势作了预测和分析,最后对全文作了总结。

## 2 多目标优化问题的数学描述

多目标优化问题是指具有两个或者两个以上目标需要同时优化的问题,且多个目标相互制约,有时还存在目标约束。MOP 的解并不局限于单个解,而可能多个解,是某种折衷或妥协,求解 MOP 常求解问题的 Pareto 最优解集。多目标优化问题数学描述如下:

$$\begin{aligned} \text{Min } f(x) &= [f_1(x), f_2(x), \dots, f_k(x)] \\ \text{s. t. } g_i(x) &(0, i=1, 2, \dots, h, x \in R_n) \end{aligned} \quad (1)$$

其中,  $f_i (1 \leq i \leq k)$  为目标函数,  $g_i$  是约束,问题具有  $n$  个决策变量、 $k$  个目标函数和  $h$  种约束。当只有单个目标时,最优解就是在给定约束条件下使目标函数值最大的解,当多个目标要同时最优时,最优解就是 Pareto 最优集。MOEA 常用到如下几个基本概念:

(1) Pareto 支配 (Pareto dominance)。解  $x_0$  支配  $x_1 (x^0 < x^1)$ , 当且仅当

$$\begin{aligned} f_i(x_0) &\leq f_i(x_1), \forall i=1, 2, \dots, k; \\ f_i(x_0) &< f_i(x_1), \exists i \in \{1, 2, \dots, k\}. \end{aligned}$$

(2) Pareto 最优 (Pareto optimal) 或 Pareto 非劣最优 (Pareto non-dominance)。如果解  $x^0$  是 Pareto 最优的解当且仅当  $\exists x^1: x^1 < x^0$ 。

(3) Pareto 最优集 (Pareto optimal set)。所有 Pareto 最优解的集合:

$$P_s = \{x^0 \mid \nexists x^1 < x^0\}.$$

(4) Pareto 前沿或均衡面 (Pareto front)。所有 Pareto 最优解对应的目标函数值所形成的区域,表示为:

$$P_F = \{f(x) = (f_1(x), f_2(x), \dots, f_k(x)) \mid x \in P_s\}.$$

## 3 以简单为特征的第一代 MOEA

MOEA 的研究可以追溯到 1967 年, R. S. Rosenberg 在其博士论文提出了使用遗传算法解决 MOP, 然而他当时并没有建立实际的多目标优化算法, MOP 被表述为单目标问题, 并用遗传算法求解。一般认为, David Schaffer 是 20 世纪 80 年代中期第一个设计多目标进化算法的人, 其方法称为向量评价遗传算法 VEGA, 是一种修改了选择机制的简单 GA。在每一代, 根据各个目标函数按比例完成选择, 生成多个子种群, 并在子种群上使用通常的交叉和变异操作, 然后将这些种群混合在一起, 形成新的种群。这种将所有个体混合起来的做法等价于将适应度函数线性加权求和, 只不过权重取决于当前世代; 同时, VEGA 也无法保证优良个体遗传到下一代。

VEGA 之后, 研究人员采用了几种简单方法解决 MOP。最主要的当属线性加权函数法, 即把所有目标函数线性加权成一个单一值, 将其直接作为 EA 的适应度。非线性加权函数也比较流行。分层排序法也是一种常用的方法, 它首先选出最重要的目标, 即第一目标, 在不考虑其他目标的情况下, 采用单目标优化方法对其进行优化; 在保持第一目标性能的情况下, 对第二个目标求优; 依次类推, 直至求出所有目标。

尽管当时已经有很多研究, 但真正把 Pareto 最优结合到 EA 的是 David E. Goldberg<sup>[8]</sup>。在分析了 VEGA 之后, Goldberg 提出使用非劣最优排序 (sorting) 和选择机制使种群向多目标优化问题的 Pareto 前沿移动, 其思想是首先找出种群中

非劣的解集, 赋予它们最高的秩 (rank), 并将它们从下种群中删除; 再从剩余的种群中找出下一个非劣的解集, 并赋予它们次高的秩; 这一过程继续下去, 直到确定种群所有个体的秩才结束。Goldberg 也建议使用小生境 (niche) 技巧以防止收敛到单个 Pareto 解, 例如适应度共享方法 (sharing method) 允许 EA 个体都分布在 Pareto 前沿。尽管 Goldberg 没有实现实际的算法过程, 但后来建立的算法都受到这种思想的影响。

最有代表性的第一代 MOGA 方法包括:

(1) MOGA (Multi-Objective Genetic Algorithm)

1993 年, Carlos M. Fonseca 和 Peter J. Fleming 提出了 MOGA<sup>[9]</sup>。在 MOGA 中, 一个个体的秩等于当前种群中支配它的染色体数目, 所有非劣个体的秩均为 1 (所有这样的个体适应度都相同, 以便能以相同的概率被选择使用), 而被支配的个体依据属于它们所在区域的种群密度被惩罚 (适应度共享用于验证个体区域的拥挤程度)。适应度的分配方式如下: (a) 基于个体的秩将种群排序; (b) 利用线性或非线性的插值方法在最低序号 (非劣最优个体) 与最高序号 ( $\leq N$ ) 之间进行插值; (c) 具有相同序号的个体的适应值共享, 即通过除以相同序号的个体数得到新的适应值; 可以给不同序号的个体分配固定不变的适应值。MOGA 算法的主要优点是算法执行相对容易且效率高, 缺点是算法易受小生境大小影响, 但值得一提的是 Fonseca 与 Fleming 已经从理论上解决了小生境的大小的计算问题。

(2) NSGA (Nondominated Sorting Genetic Algorithm)

NSGA 是由 Srinivas 和 Deb 在 1994 年提出的<sup>[10]</sup>, 发表在 IEEE 的 "Evolutionary Computation" 杂志上。NSGA 基于 Goldberg 的建议对个体分类, 形成多个层次。在选择操作之前, 个体基于非劣最优进行排序; 所有非劣的个体分为一类, 并引进决策向量空间的共享函数法, 保持种群的多样性。然后, 忽略这些已经分类的个体, 考虑另一层非劣的个体; 这个过程一直持续, 直到将所有个体分类。由于在第一个 Pareto 前沿中的个体有最大的适应度, 因此它们被复制的机会更多。NSGA 的优点是优化目标个数任选, 非劣最优解分布均匀, 允许存在多个不同等效解; 缺点是由于 Pareto 排序要重复多次, 计算效率较低, 计算复杂度为  $O(MN^3)$  (其中  $M$  为目标数量,  $N$  为种群大小), 未采用精英保留策略, 共享参数  $\sigma_{share}$  需要预先确定。

(3) NPGA (Niche-Pareto Genetic Algorithm)

Jeffrey Horn 等于 1994 提出了 NPGA<sup>[11]</sup>, 使用基于 Pareto 支配的锦标赛选择模式。算法的基本思想非常巧妙: 随机选择两个个体, 与来自种群的一个子集比较 (典型地, 子集占整个种群的 10%), 若其中一个个体支配子集, 而另一个个体被子集支配, 则非劣个体获胜; 所有其它情况被视为一结 (tie, 即互不支配)。当有结存在时, 通过适应度共享确定锦标赛结果。因为该算法的非劣最优解选择是基于种群的部分而非全体, 所以其优点是能很快找到一些好的非劣最优解域, 并能维持一个较长的种群更新期; 缺点是除需要设置共享参数外, 还需要选择一个适当的锦标赛规模, 因而限制了该算法的实际应用效果。

在第一代 MOEA 发展期间, 很少进行不同方法之间的比较研究。但比较上述三种方法的人一致认为, MOGA 最优, 依次是 NPGA 和 NSGA。这一时期的特点是强调算法的简单性, 但缺乏验证方法, 也没有标准测试函数<sup>[38]</sup>。这一时期的一个重要成果是 Masahiro Tanaka 建立了第一个结合用户

偏好的 MOEA<sup>[12]</sup>。这点非常重要,因为现实应用中用户往往并不要求得整个 Pareto 解集,而只是需要一小部分解(或者仅一个)。若用户可以定义一种偏好,则可缩小搜索空间,只扩大 Pareto 前沿的某些区域。许多年来,没有几个研究人员关注这一问题。另一成果是 Fonsenca 和 Fleming 在 1995 年的进化计算杂志上发表了该时期的研究进展<sup>[7]</sup>, Fonsenca 提出了第一个性能测试量度函数,其特点是不需要预先知道问题的 Pareto 前沿;同时, Fonsenca 也给出了为处理约束时修改 Pareto 支配关系的方法。这一时期主要的教训是:一个成功的 MOEA 除结合一种好的机制选择非劣个体外(但未必基于 Pareto 支配概念),还应具有好的机制维护种群多样性(如适应度共享方法就是其中的一种)。

#### 4 以效率为特征的第二代 MOEA

一般认为,第二代 MOEA 以精英保留策略为标志,并以其作为一种标准机制。尽管在早期的 MOEA 研究中有些方法已经涉及到了精英保留策略的思想,但多数作者认为 Echart Zitzler 的贡献可以作为 MOEA 的一个里程碑,主要因为 IEEE transactions on Evolutionary Computation 上发表了其的 SPEA 方法<sup>[13]</sup>。在他的文章发表之后,许多研究人员开始把外部种群(external population; secondary population 次种群)结合到他们的 MOEA 中,使用精英保留策略成了共同的实践。事实上,使用精英保留策略是保证 MOEA 收敛的一个理论要求,因此就体现了其重要作用。

在 MOP 中,精英保留策略通常指使用外部种群保存进化过程中所出现的非劣个体。使用精英保留策略的动机主要源于这样的事实:在当前种群非劣的个体未必在后面形成种群非劣,故需要用一种方法来保证向用户报告的解对于算法产生的其它解也非劣。因此,一种直观的方法就是在外部档案(external archive)中存放已经发现的非劣解。若一个解是劣的,则不允许其进入外部档案;相反地,若一个解支配外部档案中的解,则需要删除被支配者。外部档案的使用也引起了一些问题<sup>[39]</sup>:(1)外部档案如何与主种群交互?换句话说,我们如何从外部档案和主种群中选择个体?或者是否仅从主种群选择个体,忽略外部档案的个体吗?(2)若外部档案的容量有限,当存满外部档案之后,应如何处理?因为外部档案总是有限的,这个问题必须考虑和关注。(3)除了使用 Pareto 支配,是否对一个欲进入外部档案的非劣个体施加附加的标准?如能否使用解的分布密度作为附加标准?

与外部档案相关的问题已经从经验和理论方面进行了研究。除了使用外部档案,精英保留策略也可以使用 $(\mu+\lambda)$ 选择机制,让父代与子代进行竞争,对那些非劣的个体增加一些附加标准,再选择进入下一代。例如,是否能够提供更好的解分布。第二代 MOEA 期间代表性方法包括以下几种:

(1) SPEA (Strength Pareto Evolutionary Algorithm) 和 SPEA 2 (Strength Pareto Evolutionary Algorithm 2)

SPEA 是由 Zitzler 于 1999 年提出的<sup>[14]</sup>,借助外部种群实现精英保留策略。在每一代,将非劣个体复制到外部种群,然后计算外部种群中每个个体的强度。这个强度值与支配个体的染色体数目成比例,类似于 MOGA 中的排序值。在 SPEA 中,当前种群个体的适应度值是按照外部种群中支配它的非劣解的强度之和计算的,适应度值的计算同时考虑了接近真正 Pareto 前沿的程度和解的分布。SPEA 使用基于距离的小生境半径和 Pareto 支配,确保解沿着 Pareto 前沿分

布,但其效率依赖于外部种群非劣解的多少。事实上,由于外部种群非劣解参与到了 SPEA 的选择过程中,若其规模太大,就会减小选择压力,放慢收敛速度。作者采用了聚类技巧删除其中的个体,从而使其大小限制在一定的门限之内。

然而, SPEA 也有其不足之处,具体表现是:在选择压力非常低时, SPEA 几乎变成随机搜索; SPEA 使用聚类删除外部种群个体,有可能丢失外部种群中的非劣解<sup>[15]</sup>。2001 年, Zitzler 提出了 SPEA 的改进版本 SPEA2,主要改进包括:(i)采用了一种细粒度的适应度分配策略。对每个个体,既考虑了支配它的个体,又考虑了被它支配的个体;(ii)引入密度函数的概念。一个个体的密度定义为第  $k$  个距它最近的个体间距离成反比,  $D(i)=1/(\sigma_i^k+2)$ ,  $\sigma_i^k$  表示个体  $i$  与种群和精英集合中各个个体之间的第  $k$  个邻居的距离,  $k=\sqrt{N+N}$  从而提高搜索效率;(iii)包含在外部种群中的个体数目保持不变,使用截断算子删除个体,以保证边界解的保留。

(2) PAES (Pareto Archived Evolution Strategy)

PAES 由 Joshua D. Knowles 和 David W. Corne 于 2000 年提出<sup>[16]</sup>。PAES 由 1+1 策略和历史档案组成,后者记录了以前找到的那些非劣解。这个集合用作参考集合,以便每个变异的个体与之比较,在 PAES 中被称作精英保留策略。然而,此算法一个有意义的方面是其通过排挤过程维持多样性的方法。排挤过程将目标空间以迭代方式划分,每个解基于其目标值被放置在一个格子位置。因为这个过程是自适应的,故不需要附加参数,算法的计算复杂度为  $O(aMN)$ ,其中  $a$  为档案长度,  $M$  为目标数目,  $N$  为种群大小。这种自适应格子已被好几个 MOEA 采用,正是这一贡献使 Knowles 非常出名。

(3) NSGA II (Nondominated Sorting Genetic Algorithm II)

NSGA II 是 NSGA 的改进版本,2002 年提出<sup>[17,18]</sup>。在 NSGA II 中,对每个解来说,需要确定多少解支配它和它支配的解集。NSGA II 需要估计围绕着种群中一个特定解的解密度,即沿着问题的每个目标计算两个解之间的平均距离,这个值被称为密集距离(crowding measure)。在选择期间, NSGA II 密集比较算子既考虑种群中个体的非劣解秩,也考虑密集距离。也就是说,优先选择非劣解;但当两个解具有相同的非劣解秩时,则选择那个不处于拥挤距离区域内的解。与前面那些算法的精英保留策略使用外部种群不同, NSGA II 的精英保留策略使用 $(\mu+\lambda)$ 选择,包含了最好的父代和子代个体。正是这种机制使新一代种群比前一代种群更有效,效果更好,在过去的几年中非常流行,并成为许多其他 MOEA 的比较对象。

(4) NPGA2 (Niche Pareto Genetic Algorithm)

NPGA2 由 Erichson 等人于 2001 年提出<sup>[19]</sup>,是 NPGA 的修订版本,使用 Pareto 排序,并保持锦标赛选择。NPGA2 不使用外部种群,精英机制类似 NSGA II 的机制;小生境计数按照注入下一代中的个体计算,而不是当前代个体。

(5) PESA (Pareto Envelope-based Selection Algorithm)

PESA 是由 Corne 等于 2000 年提出的<sup>[20]</sup>,使用小的内部种群和大的外部种群,使用类似 PAES 中的表现型空间超级格子划分方法维持种群的多样性。然而,其选择机制基于前面提到的密集距离(crowding measure)的概念。这种方法同样用于决定哪些个体进入下一代外部种群,即进化过程中产生的非劣解。在 PESA 中,外部种群在算法中起非常重要的

作用,一方面它决定着多样性的模式,另一方面决定着这种方法的选择方式。有修订版本的 PESA II<sup>[21]</sup>,除了基于区域的选择外,其他方面与 PESA 相同。在基于区域的选择中,选择单元是一个超级盒(hyperbox),而不是个体,即首先选择一个超级盒,然后在其中任选一个个体。这种方法的动机是为了减少传统的 MOEA 的计算费用,即减少传统的基于 Pareto 的排序计算。

#### (6) Micro-GA (Micro-Genetic Algorithm)

Micro-GA 是由 Coello Coello 和 Toscano Pulido 于 2001 年提出的<sup>[22]</sup>,是一种包含小的种群和重新初始化过程的 GA,其过程如下:首先,产生随机的种群,并注入种群内存,种群内存分为可替代和不可替代两部分。不可替代部分在整个运行过程中保持不变,提供算法所需要的多样性;可替代部分则随算法的运行而变化。在每一轮运行开始, Micro-GA 的种群从种群内存的两部分选择个体,包含随机生成的个体(不可替代部分)和进化个体(可替代部分); Micro-GA 使用传统的遗传操作;其后,从最终的种群选择两个非劣向量,与外部种群中的向量比较。若与外部种群的向量比较,任何一个都保持非劣,则将其注入外部种群,并从外部种群中删除所有被它支配的个体。 Micro-GA 使用三种形式的精英:(1)在风部循环中保持的非劣的个体;(2)可替代内存中的个体;(3)每个内部循环中生成的标称角替代种群中的个体。

第二代 MOEA 以强调效率和使用精英保留策略为特征,但也有许多其他方法。适应度共享不再是维持多样性的唯一选择;除了来自 PAES 的自适应格子,研究人员已采用聚类技巧、拥挤、熵、基于集合的方法等;另外,一些研究人员采用了交配限制模式;最近,开始采纳 Pareto 支配的松弛形式,作为一种机制促进探索,因而维持多样性。从这些机制中, $\epsilon$ -支配( $\epsilon$ -dominance)越来越流行,不仅是由于其效率,还在于其理论基础合理。

在第二代 MOEA 期间,许多研究人员提出了 MOEA 性能量度的措施和方法,从而可以进行 MOEA 的定量比较。Zitzler 等认为,当评价一个 MOEA 的性能时应考虑以下方面<sup>[23]</sup>: a) 能够找到的最大 Pareto 最优解集; b) 算法所找到的 Pareto 前沿与已知的全局前沿的最小距离(当已知全局前沿才可以比较); c) 找到解的最大宽度,以便能够有一个尽可能平滑、均匀的矢量分布。

这当然也会出现一些新的问题。一方面,为应用性能量度评价 MOEA,需要事先知道准确的 Pareto 前沿位置,而在有些情况下,根本无法事先知道 Pareto 前沿;另一方面,用一种单一的性能量度方法判断上述三个方面是不可能的,或者说,判断一个 MOEA 的性能问题也是一个 MOP。

一旦研究人员提出性能量度措施,批评也随着而来。一些研究人员则认为许多量度措施是有偏见的。换句话说,有些情况下,性能量度提供的结果与我们看到的图形表示并不一致。相反地,当应用性能量度评价产生的结果值得怀疑时,有些研究人员又回到了图形比较上。尽管这方面工作进展缓慢,研究人员已经提出不同类型性能量度,每次不是仅考虑一种算法,而是两种,这些性能量度函数被称为是二元(binary)的(以前的被称为一元(unary)的)。在 2002 年,真相终于被揭开:由于一元性能量度与 Pareto 支配不一致,因而得到的结果是不可靠的,而二元性能量度能够克服这些限制<sup>[24]</sup>。

与此同时,其他一些研究人员设计了测试函数。最显著的当属 Kalyanmoy Deb 的工作<sup>[25]</sup>。1999 年,他提出了一种

设计 MOP 的方法,其后被使用多年。后来,又提出了替代测试函数的方法,不再需要枚举过程去生成准确的 Pareto 前沿,并且这些测试函数是可规模化的,因而被广泛使用。今天的研究人员用 3 个或 3 个以上目标函数及 10 个或 10 个以上决策变量的问题就可验证他们的 MOEA。

## 5 研究趋势

MOEA 研究取得了大量成果,已被应用于许多领域。根据现有的参考文献,可分为:工程领域应用、工业领域应用和科学领域应用三类。其中,工程领域的应用最多。工程领域代表性应用有电子工程、水力工程、结构工程、航空工程、机器人和控制等;工业领域代表性应用有设计与制造、调度、管理;科学领域代表性应用有化学、物理、药学、计算机科学等。然而,有些领域的应用相对较少,如元胞自动机<sup>[26]</sup>、模式识别<sup>[27]</sup>、数据挖掘<sup>[28]</sup>和金融<sup>[29]</sup>等方面。

从整体上而言,MOEA 尚不能算成熟和完善,仍有一些问题需要研究,如:

(1)使用 Pareto 支配的松弛形式调整 MOEA 的收敛<sup>[30]</sup>。从这些机制看, $\epsilon$ -支配是最流行的机制,但并不是唯一可行的机制。 $\epsilon$ -支配允许控制问题解接近 Pareto 前沿的粒度,因此使用这种机制加速收敛是可能的。

(2)为方便求解,如何将单目标优化问题转换为多目标优化。例如,有些研究人员提出将约束作为目标<sup>[31]</sup>;有些研究人员提出将单目标分解为多个部分等<sup>[32]</sup>。这些过程在消除问题的局部最优方面是有帮助的,在过去几年里已获得很多关注。

(3)MOEA 参数控制是一个较少被关注的方面<sup>[33]</sup>,有没有可能设计一种 MOEA,使其自动调整其参数,替代用户手工调整参数,加快算法收敛。已有学者提出了一些自适应和在线适应过程,但最近好像没有太大进展。

(4)开发独立于平台和程序设计语言的 MOEA 实现,以期成为验证新算法的统一平台。如, PISA 已经迈出了重要的一步,也有更多工作需要开展<sup>[34]</sup>。

(5)怎样处理“多个”目标的问题?最近研究表明,传统的 Pareto 排序模式在多于 3 到 4 个目标时,运行效果就不理想<sup>[35]</sup>。

(6)使用其他仿生方法求解多目标优化,如使用微粒群优化方法、微分进化、人工免疫系统、蚁群优化算法等<sup>[36]</sup>。

此外,仍有一些基本问题有待研究<sup>[37]</sup>。如对于一个 MOEA 来说,多目标优化问题求解困难的根源是什么?当前已有 MOEA 的维数限制是多少?除了使用 Pareto 排序,是否可应用其他机制(如采用来自对策论的概念)到 EA 中产生非劣解?

**结论** 通过前面的分析可知,各种不同的 MOEA 具有一些共同的特征,包括精英保留策略、种群多样性、个体适应度的赋值等。在研究 MOEA 时,掌握它们的共性,可以节省大量的时间和精力。而掌握各种 MOEA 的不同特点则可以了解其长处与不足、可应用的领域等,为进一步研究提供基础和思路。

本文首先回顾了多目标进化算法的研究起源,给出了多目标优化问题的数学描述;其次,详细分析了以简单为特征的第一代多目标进化算法,包括 NSGA、NPGA、MOGA 等,并指出这一代算法研究的成绩与不足;然后,对第二代多目标进化算法作了全面分析,指出其特征是强调效率,以精英保留策

略为实现机制,且对 SPEA,PAES,NSGA II,NPGA2,PESA、Micro-GA 等方法进行分析比较,还对这一代的研究作了总结;最后,对多目标进化算法的研究趋势作了展望和预测。

### 参考文献

- Zitzler E, Laumanns M, Bleuler S. A tutorial on evolutionary multiobjective optimization. In: Srensen K, Gandibleux X, Sevaux M, et al. ed. Meta-heuristics for Multiobjective Optimization. Lecture Notes in Economics and Mathematical Systems, Springer, 2004, 35:3~37
- 谢涛,陈火旺,康立山. 多目标优化的演化算法. 计算机学报, 2003, 26(8): 997~1003
- Coello C A C. An Updated survey of evolutionary multiobjective optimization techniques; State of the art and future trends. In: Proceedings of the 1999 Congress on Evolutionary Computation, Washington D C, 1999. 3~13
- Rosenberg R S. Simulation of genetic populations with biochemical properties; [PhD thesis]. Ann Harbor, Michigan; University of Michigan, 1967
- David S J. Multiple Objective Optimization with Vector Evaluated Genetic Algorithms. In: Proceedings of the First International Conference on Genetic Algorithms, Lawrence Erlbaum, 1985. 93~100
- Coello C A C. Twenty Years of Evolutionary Multi-objective Optimization; A Historical View of the Field. IEEE Computational Intelligence Magazine, 2006, 1(1):28~36
- Fonseca C M, Fleming P J. An Overview of Evolutionary Algorithms in Multi-objective Optimization<sup>[J]</sup>. Evolutionary Computation, 1995, 3(1):1~16
- Goldberg D E. Genetic Algorithms in Search, Optimization and Machine Learning. Reading, Massachusetts: Addison-Wesley Publishing Company, 1989
- Fonseca C M, Fleming P J. Genetic Algorithms for Multi-objective Optimization; Formulation, Discussion and Generalization. In: Forrest S, ed. oceedings of the Fifth International Conference on Genetic Algorithms, pages San Mateo, California, 1993. 416~423
- Srinivas N, Deb K. Multiobjective Optimization Using Nondominated Sorting in Genetic Algorithms. Evolutionary Computation, 1994, 2(3):221~248
- Horn J, Nafpliotis N, Goldberg D E. A Niche Pareto Genetic Algorithm for Multiobjective Optimization. In: Proceedings of the First IEEE Conference on Evolutionary Computation, IEEE World Congress on Computational Intelligence, vol1. Piscataway, New Jersey, June 1994. 82~87
- Tanaka M, Tanino T. Global optimization by the genetic algorithm in a multiobjective decision support system. In: Proceedings of the 10th International Conference on Multiple Criteria Decision Making, vol2. 1992. 261~270
- Zitzler E, Thiele L. Multiobjective Evolutionary Algorithms: A Comparative Case Study and the Strength Pareto Approach. IEEE Transactions on Evolutionary Computation, 1999, 3(4): 257~271
- Zitzler E, Thiele L. Multiobjective Optimization Using Evolutionary Algorithms-A Comparative Study. In: Eiben A E, ed. Parallel Problem Solving from Nature V, Amsterdam, September 1998. 292~301
- Zitzler E, Laumanns M, Thiele L. SPEA2: Improving the Strength Pareto Evolutionary Algorithm. In: Giannakoglou K, et al. eds. EUROGEN 2001. Evolutionary Methods for Design, Optimization and Control with Applications to Industrial Problems, Athens, Greece, 2002. 95~100
- Knowles J D, Corne D W. Approximating the Nondominated Front Using the Pareto Archived Evolution Strategy. Evolutionary Computation, 2000, 8(2):149~172
- Deb K, Agrawal S, Pratap A, et al. A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II. In: Schoenauer M, et al. eds. Proceedings of the Parallel Problem Solving from Nature VI Conference, Paris, France, 2000. 849~858
- Deb K, Pratap A, Agarwal S, et al. A Fast and Elitist Multiobjective Genetic Algorithm; NSGA-II. IEEE Transactions on Evolutionary Computation, 2002, 6(2):182~197
- Erickson M, Mayer A, Horn J. The Niche Pareto Genetic Algorithm 2 Applied to the Design of Groundwater Remediation Systems. In: Zitzler E, Deb K, Thiele L, eds. First International Conference on Evolutionary Multi-Criterion Optimization. Springer-Verlag. Lecture Notes in Computer Science No. 1993, 2001. 681~695
- Corne D W, Knowles J D, Oates M J. The Pareto Envelope-based Selection Algorithm for Multiobjective Optimization. In: Schoenauer M, Deb K, Rudolph G, eds. Proceedings of the Parallel Problem Solving from Nature VI Conference. Paris, France, 2000. 839~848
- Corne D W, Knowles J D, Oates M J. PESA-II; Region-based Selection in Evolutionary Multiobjective Optimization. In: Spector L, et al. eds. Proceedings of the Genetic and Evolutionary Computation Conference (GECCO'2001). San Francisco, California, 2001. 283~290
- Coello C A, Pulido G T. A Micro-Genetic Algorithm for Multiobjective Optimization. In: Zitzler E, Deb K, Thiele L, eds, First International Conference on Evolutionary Multi-Criterion Optimization. Springer-Verlag. Lecture Notes in Computer Science No. 1993, 2001. 126~140
- Zitzler E, Deb K, Thiele L. Comparison of Multiobjective Evolutionary Algorithms; Empirical Results. Evolutionary Computation, 2000, 8(2):173~195
- Fonseca C M, Fleming P J. On the Performance Assessment and Comparison of Stochastic Multiobjective Optimizers. In: Voigt H-M, et al. eds. Parallel Problem Solving from Nature-PPSN IV, Lecture Notes in Computer Science, Berlin, Germany, September 1996. 584~593
- Deb K. Multi-Objective Genetic Algorithms; Problem Difficulties and Construction of Test Problems. Evolutionary Computation, 1999, 7(3):205~230
- Oliveira G M, Bortot J C, Oliveira P B. Multiobjective evolutionary search for one-dimensional cellular automata in the density classification task. In: Standish R, Bedau M, Abbass H, eds. Artificial Life VIII; The 8th International Conference on Artificial Life, Cambridge, Massachusetts, MIT Press, 2002. 202~206
- Oliveira L S, Sabourin R, Bortolozzi F, et al. Feature Selection Using Multi-Objective Genetic Algorithms for Handwritten Digit Recognition. In: Proceedings of the 16th International Conference on Pattern Recognition (ICPR'2002), volume 1. Quebec City, Canada. IEEE Computer Society Press. August 2002. 458~571
- Pappa G, Freitas A, Kaestner C A A. Multi-Objective Algorithms for Attribute Selection in Data Mining. In: C A. Coello C, Lamont G B, eds. Applications of Multi-Objective Evolutionary Algorithms, World Scientific, Singapore, 2004. 603~626
- Schlottmann F, Seese D. Financial Applications of Multi-Objective Evolutionary Algorithms; Recent Developments and Future Research Directions. In: Coello C A C, Lamont G B, eds. Applications of Multi-Objective Evolutionary Algorithms, World Scientific, Singapore, 2004. 627~652
- Laumanns M, Thiele L, Deb Y, et al. Combining Convergence and Diversity in Evolutionary Multi-objective Optimization. Evolutionary Computation, 2002, 10(3):263~282
- Coello C A C, Aguirre A H. Design of Combinational Logic Circuits through an Evolutionary Multiobjective Optimization Approach. Artificial Intelligence for Engineering, Design, Analysis and Manufacture, 2002, 16(1):39~53
- Jensen M T. Guiding Single-Objective Optimization Using Multi-objective Methods. In: Raidl G, et al. eds. Applications of Evolutionary Computing. Evoworkshops 2003; EvoBIO, EvoCOP, EvoIASP, EvoMUSART, EvoROB, and EvoSTIM, Essex, UK, April 2003. Springer. Lecture Notes in Computer Science Vol 2611, April 2003. 199~210
- Buche D, Muller S, Koumoutsakos P. Self-Adaptation for Multi-objective Evolutionary Algorithms. In: Carlos M. Fonseca C M, et al. eds. Evolutionary Multi-Criterion Optimization. Second International Conference, EMO 2003, Faro, Portugal, Springer. Lecture Notes in Computer Science. Vol 2632, April 2003. 267~281
- Bleuler S, Laumanns M, Thiele L, et al. PISA-A Platform and Programming Language Independent Interface for Search Algo-

- rithms. In: Fonseca C M, et al. eds. Evolutionary Multi-Criterion Optimization, Second International Conference, EMO 2003, Faro, Portugal, Springer. Lecture Notes in Computer Science. Volume 2632, April 2003. 494~508
- 35 Purshouse R C. On the Evolutionary Optimisation of Many Objectives:[PhD thesis]. Sheffield, U K;Department of Automatic Control and Systems Engineering, The University of Sheffield, September 2003
- 36 Kennedy J, Eberhart R C. Swarm Intelligence. San Francisco, California, Morgan Kaufmann Publishers, 2001
- 37 Sefrioui M, Periaux J. Nash Genetic Algorithms; examples and applications. In: 2000 Congress on Evolutionary Computation,

vol1. San Diego, California, IEEE Service Center, July 2000, 509~516

- 38 Van Veldhuizen D A, Lamont G B. Multi-objective Evolutionary Algorithms: Analyzing the State-of-the-Art. Evolutionary Computation, 2000, 8(2):125~147
- 39 Knowles J, Corne D. Properties of an Adaptive Archiving Algorithm for Storing Nondominated Vectors. IEEE Transactions on Evolutionary Computation, 2003, 7(2):100~116
- 40 Laumanns M, Thiele L, Deb K, et al. Combining Convergence and Diversity in Evolutionary Multi-objective Optimization. Evolutionary Computation, 2002, 10(3):263~282

(上接第 112 页)

略改善数据的局部性,尽量变远程访问为本地访问,从而提高存储系统乃至整个系统的性能。为了对共享存储管理进行优化,本文针对动态数据局部性优化技术——页迁移策略进行了研究,并提出了一种基于遗传算法的动态页迁移策略。

### 参 考 文 献

- 1 Amza C, et al. TreadMaks: Shared Memory Computing on Networks of Workstations. IEEE Computer, February 1996
- 2 Agarwal A, et al. The MIT Alewife Machine: Architecture and Performance. In: the Proceedings of the 22<sup>nd</sup> Annual International Symposium on Computer Architecture, June 1995

- 3 Bircsak J, et al. Extending OpenMP for NUMA machines. Supercomputing 2000, Dallas, Texas, 2000
- 4 Culler D E, et al. Parallel Computer Architecture (Second Edition). Morgan Kaufmann Publishers Inc, 1996
- 5 Gharachorloo K. The Plight of Software Distributed Shared Memory. In: Proceedings of 1<sup>st</sup> Workshop on Software DSMs, 1999
- 6 Bligh M J, Hansen D. Linux memory management on larger machines. The linux Symposium, Ottawa, Canada, 2003
- 7 Nikolopoulos D, et al. Scheduler-activated dynamic page migration for multiprogrammed DSM multiprocessors. Journal of Parallel and Distributed Computing, 2002, 62960:1069~1103

(上接第 180 页)

可以看出, EDGA 在运行到第 16 代迁移时就收敛了,  $shortpathlength_4 = 3158$ ,  $elapsed\_time = 0.3440$ 。由于迁移间隔为 10 代,那么达到总体收敛的时间是 160 代,而 SGA 收敛代数达到了 450 左右。同时,最优路径综合代价改进前为 3803,改进后是 3158。由此可以看出 EDGA 的优越性。

#### 3) SGA、DGA、EDGA 性能比较

我们将本文提出的 EDGA 算法中的迁移策略与一般基于网络拓扑(DGA)的迁移策略进行了对比,从实验结果可以看出 EDGA 的性能优越于 DGA。三种方法的性能对比如图 4 所示。




图 4 SGA、DGA、EDGA 性能比较

**结论** 本文提出了一种改进的分布式遗传算法,对多约束条件下移动 Agent 的迁移策略最优问题进行了求解,通过仿真实现证明了所提算法的优越性。由于本文所讨论的属于

静态迁移路由,而网络环境是动态变化的,因此下一步工作将进一步研究动态环境下移动 Agent 迁移策略的全局最优问题。

### 参 考 文 献

- 1 Kotz D, Gray R S. Mobile agents and the future of the Internet: [rep. Dartmouth College]. 1999. 7~13
- 2 Acharva A, Ranganathan M, Saltz J. Sumatra: A language for resource-aware mobile programs. In: Proc. of Mobile Object Systems: Towards the Programmable Internet. Berlin: Springer, 1997. 111~130
- 3 Glitho R H, et al. Mobile Agents and Their Use for Information Retrieval. IEEE Network, 2002. 34~41
- 4 Iqbal A, Baumann J, Straber M. Efficient algorithms to find optimal agent migration strategies. Stuttgart university: [Tech Rep: TR-1998-05]. 1998
- 5 刘大有,杨博,杨巍,王生生. 基于履行图的移动 Agent 迁移策略. 计算机研究与发展, 2003(6): 838~845
- 6 郭忠文,等. 基于相关分析与神经网络的 Agent 迁移策略. 见:第五届全球智能控制与自动化大会, 2004, 6: 1958~1962
- 7 武成岗,史忠植. 基于模块化移动 Agent 及其调度算法. 软件学报, 2002(8): 1628~1636
- 8 Yuan X, Liu X. Heuristic Algorithms for Multi-Constrained Quality of Service Routing. In: Proceedings of IEEE INFOCOM, April 1997. 58~62
- 9 Korkmaz T, Krunz M. Multi-constrained Optimal Path Selection. In: Proc. of IEEE INFOCOM, 2000. 113~118