

多目标蚁群优化研究综述

刁兴春¹ 刘 艺¹ 曹建军² 尚玉玲¹

(中国人民解放军理工大学指挥信息系统学院 南京 210007)¹ (南京电讯技术研究所 南京 210007)²

摘 要 多目标蚁群优化是一类重要的多目标进化算法,它在解决多目标优化问题,尤其是多目标组合优化方面,具有优异的性能。首先,通过总结多目标蚁群优化的研究成果,将多目标蚁群优化分为基于帕累托的方法、基于指标函数的方法和目标分解法3类,并阐述了每类方法的特点和代表性算法;然后,展现了多目标蚁群优化在实际问题中的广泛应用;最后,探讨了目前多目标蚁群优化存在的问题。

关键词 多目标蚁群优化,多目标进化算法,帕累托优化,指标函数,分解

中图分类号 TP301.6 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.10.002

Reviews of Multiobjective Ant Colony Optimization

DIAO Xing-chun¹ LIU Yi¹ CAO Jian-jun² SHANG Yu-ling¹

(College of Command Information Systems, PLA University of Science and Technology, Nanjing 210007, China)¹

(Nanjing Telecommunication Technology Institute, Nanjing 210007, China)²

Abstract Multiobjective ant colony optimization is one of the important multiobjective evolutionary algorithms, which has excellent performance in multiobjective optimization problems especially multiobjective combinational optimization problems. In this paper, we summarized the development of the multiobjective ant colony optimization and classified it into three classes, i. e. method based on pareto's relation, method based on indicators and method based on decomposition. Besides, we also summarized each method's characteristics and its classical algorithms. We showed its spread applications in real problems. In the end, we discussed the existing problems in multiobjective ant colony optimization.

Keywords Multiobjective ant colony optimization, Multiobjective evolutionary algorithms, Pareto optimality, Indicator function, Decomposition

1 引言

多目标优化是指目标个数在2个以上且目标间不可比较的优化问题^[1]。多目标优化问题由来已久,在实际生活中应用广泛,已经成为热门的研究方向^[2-3]。典型的多目标优化问题包括多目标旅行商问题、多目标背包问题、车间作业调度问题等^[4-6]。多目标优化问题一般是NP难的,无法获得最优解,因此使用启发式算法获取次优解成为解决该问题的主要方法,即多目标进化算法。多目标进化算法主要分为两类:一类通过模拟生物的进化过程,将优化生成的解编码为基因,再通过基因的交叉和变异生成精英后代来求解问题,这类算法包括改进增强帕累托进化算法^[7]、基于分解的多目标进化算法^[8]、非支配排序遗传算法III^[9]等;另一类通过模仿生物的生存活动行为进行求解,如模仿蚂蚁觅食行为的多目标蚁群优化^[10]、模仿鸟类飞行的多目标粒子群算法^[11]和模仿蝙蝠飞行的多目标蝙蝠算法^[12]等。

多目标蚁群优化是一类优秀的多目标进化算法,它模拟蚂蚁的觅食行为,在蚂蚁寻找食物的过程中不断释放被称为信息素的物质,蚂蚁的栖息地到食物源的路径越短,该路径上通过的蚂蚁的数量就越多,信息素就越强,从而指引蚂蚁的行为,该行为也被称为信息正反馈。正是由于使用了正反馈机制,多目标蚁群优化比其他优化算法在获取次优解方面具有更好的性能。此外,该算法还具有内在的分布式结构和较强的鲁棒性等特点。作为蚁群优化在多目标领域的拓展,多目标蚁群算法也在实际生活中得到了广泛的关注与应用^[13-16],特别是蚁群优化在组合优化问题中优异的性能表现^[17],也在求解多目标组合优化的问题中得到了体现^[18-20]。

虚拟化技术对数据中心计算资源的有效利用起到了关键的作用。为了解决虚拟机到物理机的映射问题,文献^[21]提出了多目标蚁群优化算法,以最小化计算资源消耗和电力损耗,取得了满意的效果。文献^[22]利用多目标蚁群优化对3个目标同时进行优化,即最小化电力消耗、最小化计算资源消

到稿日期:2016-09-26 返修日期:2017-01-07 本文受国家自然科学基金资助项目(61371196),中国博士后科学基金特别资助项目(201003797),解放军理工大学预研基金项目(20110604,41150301)资助。

刁兴春(1964—),男,硕士,研究员,主要研究方向为数据工程,E-mail:diaoxch640222@163.com;刘 艺(1990—),男,博士生,主要研究方向为数据质量、进化算法,E-mail:albertliu20th@163.com;曹建军(1975—),男,博士,工程师,主要研究方向为数据质量、进化算法,E-mail:jianjuncao@yeah.net;尚玉玲(1990—),女,硕士生,主要研究方向为数据质量、进化算法,E-mail:1533765046@qq.com。

耗、最小化数据中心内部网络间的通讯消耗,与3种单目标算法以及多目标遗传算法的对比显示出了该方法的优越性。

文献[24]针对组装供应链的优化提出了一种解决两目标优化的多目标蚁群算法,以最小化原材料的开销以及产品生产的时间;在笔记本供应链上的测试结果表明,采用多目标蚁群优化能够在收敛性和误差率上获得满意的效果。文献[25]利用多目标蚁群优化解决软件需求的选择问题,将优化的目标定义为最大化用户的满意度和最小化软件部署规模,在两个数据集上该算法与贪心随机适应搜索算法和多目标遗传算法的对比显示,该算法在解的收敛性、分布的多样性以及运算时间上都更优。

实体分辨是识别出同一客观实体的不同描述,是数据清洗的关键步骤之一[26-27]。在高维数据中,由于样本的规模小于特征的个数,造成模型的训练时间较长;此外,不相关特征也导致分类精度较低。针对此问题,文献[28]提出使用多目标蚁群优化进行特征选择,选择的特征子集满足最大化分类准确性以及分类器间的不相似性的目标,实验结果验证了多目标蚁群优化在解决子集问题时的优异性能。

本文总结多目标蚁群优化近年的发展和研究成果,介绍典型的多目标蚁群优化算法,讨论目前存在的问题,旨在为多目标蚁群优化的进一步发展提供依据。本文第2节给出多目标优化的相关概念;第3节对近年来多目标蚁群优化的研究进行分类,并介绍每类中具有代表性的算法;最后探讨目前多目标蚁群优化存在的问题。

2 多目标优化的相关概念

多目标优化问题可描述如下[29]:

$$\min F(x) = (f_1(x), f_2(x), \dots, f_m(x))^T, x \in \Omega \quad (1)$$

其中,决策向量 $x = (x_1, x_2, \dots, x_n)$ 属于非空决策空间 Ω ,目标函数向量 $F: \Omega \rightarrow \Delta$ 由 $m(m \geq 2)$ 个目标组成, Δ 是目标空间。

帕累托支配(Pareto Dominance):给定两个解 $x, y \in \Omega_f$,以及它们对应的目标向量 $F(x), F(y) \in R^m$,当且仅当 $\forall i \in \{1, 2, \dots, m\}, f_i(x) \leq f_i(y)$ 且 $\exists j \in \{1, 2, \dots, m\}, f_j(x) < f_j(y)$ 时, x 支配 y (表示为 $x < y$)。

帕累托最优解(Pareto Optimal Solution): $x^* \in \Omega_f$ 是帕累托最优解,当且仅当不存在另一个解 $x \in \Omega_f$ 支配它。帕累托最优解又称非支配解(Nondominated Solution)。

帕累托集(Pareto Set):所有帕累托最优解的并集称为帕累托集,表示为 $PS = \{x \in \Omega_f \mid \exists y \in \Omega_f, y < x\}$ 。

帕累托前沿(Pareto Front, PF):帕累托集对应的目标向量集合称为帕累托前沿。

近似集合(Approximation Set):设 $A \subset \Delta$ 为目标向量的集合,用 $A = \{a_1, a_2, \dots, a_{|A|}\}$ 表示。如果 A 中任意一个目标向量都不支配或等于 A 中其他的目标向量,则称 A 为一个近似集合[30]。

多目标优化的目标是获得靠近 PF 的近似集合 A ,包括两个子目标: A 中的所有解尽可能地靠近 PF; A 中的所有解尽可能地散布在目标空间[31]。

根据优化目标,需要从两个方面对一个近似集合进行度量:1)收敛性,即解在目标空间对真实帕累托前沿的接近程度;2)多样性,即解在帕累托前沿的散布程度。

3 多目标蚁群优化的研究进展

按照对多目标处理技术的不同,可以将多目标蚁群算法分为3类:基于帕累托的方法(1),基于指标函数的方法(2),目标分解法(3)。表1按照3种分类方式对本文引用文献的来源与发表时间做了归纳,小括号中的数字表示其所属的类别。本文相关文献来源于 IEEE Xplore Digital Library, ACM Digital Library, SpringerLink, Google Scholar 与 Elsevier Scencedirect 数据库。

表1 相关文献分类

	2000—2012年	2013年	2014年	2015年
IEEE Xplore	[36](1)	[48](3)	[22](1), [23](1)	[19](1), [33](1), [42](1), [50](3)
ACM Digital Library	[37](1), [41](1)	—	—	[25](1)
SpringerLink	[40](1)	[32](1)	—	[34](1), [46](2)
Elsevier Scencedirect	—	[16](1), [21](1)	[13](1), [24](1)	[10](1), [15](1), [20](1), [47](2)
Google Scholar	[38](1), [39](1)	[14](1)	—	[6](1), [43](1)

3.1 基于帕累托的方法

基于帕累托的方法将多个目标作为整体进行优化搜索,通过帕累托支配关系在候选解中选择帕累托最优解。该方法起步较早,意义直观,也是在实际问题中使用最多的方法[32-34]。该方法研究的热点主要集中在4个方面:群体数量的设置,信息素矩阵和启发式矩阵的设置,与之相关的信息素值、启发式值的聚合方法,以及信息素更新解的选择方式,如图1所示。




图1 基于帕累托的多目标蚁群优化分类

(1)群体数量的设置:群体数量设置的本质在于群体内蚂蚁搜索空间的不同。单群体中,蚂蚁对整个帕累托前沿进行搜索。在多群体的情况下,群体的设置一般有两种方式:1)对每个目标设置一个群体,群体内的蚂蚁对该目标进行优化;2)将帕累托前沿进行分割,每个群体内的蚂蚁对帕累托前沿的一部分进行搜索。

(2)信息素矩阵与启发式矩阵的设置:一共有4种设置方式,即单信息素矩阵单启发式矩阵、单信息素矩阵多启发式矩阵、多信息素矩阵单启发式矩阵和多信息素矩阵多启发式矩阵。在多个信息素矩阵或启发式矩阵的情况下,一般是对应优化目标的个数来设置信息素矩阵或启发式矩阵。由于在多目标优化的问题中单个信息素矩阵会导致优化过程中信息的不完整,即丢失边界信息,最终只能获取帕累托前沿的一部分,因此在多数的研究中,算法会设置多个信息素矩阵[35]。

(3)信息素值与启发式值聚合方式:在多目标蚁群优化

中,蚂蚁通过状态转移概率选择路径。以多目标旅行商问题为例,蚂蚁 k 在访问节点 i 之后访问节点 j 的概率为:

$$p_{ij}^k = \frac{[\tau_{ij}]^\alpha \cdot [\eta_{ij}]^\beta}{\sum_{j \in N_i^k} [\tau_{ij}]^\alpha \cdot [\eta_{ij}]^\beta} \quad (2)$$

其中, τ_{ij} 是边 (i, j) 在当前迭代中的信息素值; η_{ij} 是静态启发式信息,表示边 (i, j) 的“好坏”程度; N_i^k 表示蚂蚁 k 在访问节点 i 之后可选择的路径候选集。因此,在设置多个信息素矩阵和启发式矩阵时,需要将它们对应的多个信息素或启发式值聚合成单个值来计算状态转移概率。常用的聚合方式有加权和、加权和和随机法 3 种。

1) 加权和:通过权重相加将多个信息素值或启发式值聚合成一个值。

$$\tau_{ij} = \omega_1 \tau_{ij}^1 + \omega_2 \tau_{ij}^2 + \dots + \omega_H \tau_{ij}^H \quad (3)$$

$$\eta_{ij} = \omega_1 \eta_{ij}^1 + \omega_2 \eta_{ij}^2 + \dots + \omega_H \eta_{ij}^H \quad (4)$$

其中, $\omega = \{\omega_1, \omega_2, \dots, \omega_H\}$ 是权重向量,且 $\omega_1 + \omega_2 + \dots + \omega_H = 1, H \geq 2$ 。

2) 加权和:通过权重相乘将多个信息素值或启发式值聚合成一个值。

$$\tau_{ij} = (\tau_{ij}^1)^{\omega_1} \cdot (\tau_{ij}^2)^{\omega_2} \cdot \dots \cdot (\tau_{ij}^H)^{\omega_H} \quad (5)$$

$$\eta_{ij} = (\eta_{ij}^1)^{\omega_1} \cdot (\eta_{ij}^2)^{\omega_2} \cdot \dots \cdot (\eta_{ij}^H)^{\omega_H} \quad (6)$$

其中, $\omega = \{\omega_1, \omega_2, \dots, \omega_H\}$ 是权重向量,且 $\omega_1 + \omega_2 + \dots + \omega_H = 1, H \geq 2$ 。

3) 随机法:给定满足均匀分布的随机数,通过比较随机数与参数的关系,决定使用其中一个信息素矩阵或启发式矩阵对应的值。

加权和与加权和方法均采用权重向量来控制信息素的重要程度,而信息素矩阵的设置一般与优化的目标相对应,因此通过调整权重向量,算法能够获取到偏向某个目标的解。随机法能够通过调整比较参数来改变使用某个信息素矩阵的概率,从而获得偏好重要目标的解。然而,随机法目前只运用在两目标的优化问题中,将其拓展到更多的目标优化领域是需要解决的关键问题。

(4) 信息素矩阵更新解:给定更新信息素矩阵的候选解集 A^{udp} ,从 A^{udp} 中选择 N^{udp} 个解更新信息素矩阵,有 3 种常用的更新解选择方式。

1) 非支配解:用 A^{udp} 中的非支配解更新信息素矩阵,若非支配解的个数超过 N^{udp} ,则采用截断机制处理。

2) 目标最好解(Best of Objective):若设置了多个信息素矩阵,则按照其中一个目标上评估值的降序从 A^{udp} 中选择最好的 N^{udp} 个解来更新信息素矩阵。如果仅设置一个信息素矩阵,则用 $m \cdot N^{udp}$ 个解更新信息素矩阵,其中 m 为目标个数。

3) 权重目标最好解(Best of Objective Per Weight):对采用权重 ω 的目标,为其设置一个包含 N^{udp} 个解的更新列表。若 $\omega = 0$,仅保留第一个目标的更新列表;若 $\omega = 1$,保留第 m 个目标的更新列表。

非支配解的方法较为简单,使用范围也最为广泛,然而该方法在算法运行后期会生成大量的非支配更新解,即使采用截断机制,也难以避免收敛时间较长的问题。目标最好解是

比较平衡的信息素矩阵更新解选择方式,目前权重目标最好解仅在文献[36]中得到使用,其性能与权重的设置相关,较为复杂。

文献[37]提出了一种多目标蚁群优化方法 Bicriterion-Ant,该方法设置多个群体,每个群体使用多个信息素矩阵和启发式矩阵,并且通过加权积的方法对其进行聚合来计算蚂蚁路径选择的状态转移概率。每个群体内的蚂蚁通过使用不同的权重向量聚合信息素矩阵优化帕累托前沿的一部分,权重向量采用叠加的方式生成,即相邻群体之间共享 50% 的权重值。图 2 给出了算法设置的 4 个群以及每个群包含 7 只蚂蚁时的叠加权重设置。迭代结束后,使用本次迭代产生的非支配解更新群体内的信息素矩阵,更新群体信息素矩阵的方式有两种:1) 源更新,即更新产生当前非支配解的群体对应的信息素矩阵,如图 3 所示;2) 域更新,即将档案中的所有非支配解按照某个目标上的评估进行值排序,并根据设置的群体数量进行分配,然后使用分配到对应群体中的非支配解更新信息素矩阵,如图 4 所示。




图 2 权重向量叠加设置示意图

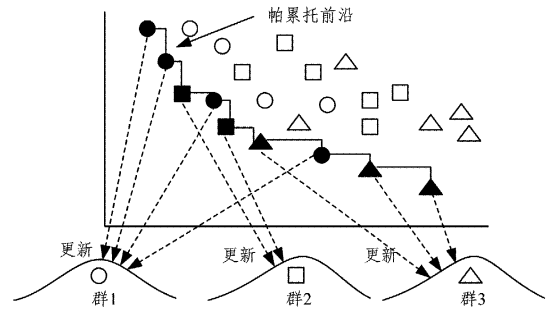


图 3 源更新方式

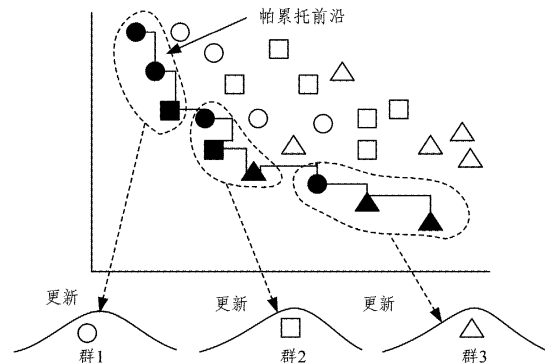


图 4 域更新方式

文献[38]提出了多蚂蚁群系统 (Many Ant Colony System, MACS)。该方法针对每个目标设置一个信息素矩阵,并基于单个启发式矩阵采用加权积的方式聚合信息素值。每只蚂蚁使用不同的权重向量聚合信息素值。迭代过程中,算法使用档案中的非支配解更新信息素矩阵。

文献[39]提出了解决两目标优化的 COMPETants 多目标蚁群算法。COMPETants 对两个目标各设置一个群体,在每个群体中设置一个信息素矩阵和一个启发式矩阵,在迭代过程中每个群体独立构建路径解。算法中存在一定数量的蚂蚁(称为“蜘蛛”),“蜘蛛”通过加权和方法聚合两个群体的信息素值,并通过计算状态转移概率来搜索路径解,有效避免了群体各自搜索路径时造成的边缘解信息丢失。该算法取每个群体中一定数量的非支配解来更新各自群体的信息素矩阵。

文献[40]提出了帕累托蚁群优化(Pareto Ant Colony Optimization, P-ACO)来解决两目标优化问题。P-ACO 使用单个群体,对每个目标设置一个信息素矩阵,并用加权和方法进行聚合。该算法使用目标最好解与次好解来更新相应的信息素矩阵。P-ACO 也设置了多个启发式矩阵,每个目标对应一个启发式矩阵,使用加权和聚合启发式值。然而,文献[41]指出采用一个或者多个启发式矩阵在获取帕累托最优解的性能上并没有显著的区别。

文献[36]提出了4种不同形式的多目标蚁群优化 $mACO$ 来解决两目标优化问题。算法的第一个形式 $mACO-1$ 使用多群体,每个目标设置一个群体,群体内设置一个信息素矩阵和一个启发式矩阵,优化各个目标。此外, $mACO-1$ 设置附加群体,搜索整个帕累托前沿;附加群体通过随机法选择另外两个群体的信息素值与启发式值。附加群体对应每个目标保留了迄今为止最好的路径解,更新各自对应群体的信息素矩阵,使用权重目标最好解更新信息素矩阵。与 $mACO-1$ 相比, $mACO-2$ 仅在信息素值的聚合方式上有所变化, $mACO-2$ 使用加权和聚合信息素值。 $mACO-3$ 只包含一个信息素矩阵和一个启发式矩阵,并使用非支配解更新信息素矩阵。与 MACS 和 BicriterionAnt 算法的更新方式不同的是, $mACO-3$ 对解中包含的路径最多只更新一次。 $mACO-4$ 为每个目标设置一个信息素矩阵,信息素值聚合的方式与 $mACO-1$ 相同,即采用随机法选择信息素值。此外, $mACO-4$ 与 $mACO-3$ 中信息素矩阵的设置方式一致,仅设置一个信息素矩阵。 $mACO-4$ 使用目标最好解更新信息素矩阵。

文献[42]提出了一种多准则网站优化蚁群算法(Multi-criteria Website Optimization Ant Colony Optimization)。该算法对3个目标进行优化,对每个目标设置一个信息素矩阵和一个启发式矩阵,采用加权积的方法聚合信息素和启发式值。此外,该算法设置了3个群体,每个群体优化一个目标,通过权重向量控制群体对目标的优化程度,使用目标最好解更新信息素矩阵。

文献[43]提出了基于蚁群系统的帕累托增强蚁群优化算法(Pareto Strength Ant Colony Optimization, PSACO)。PSACO 使用一个信息素矩阵,并采用与改进的增强帕累托进化算法[7]相同的支配概念,通过设置长度固定的全局非支配解档案,使用文献[7]中的方法将当前迭代生成解与全局非支配解档案进行合并。每轮迭代完成后,使用档案中的非支配解更新信息素矩阵。

文献[23]为了解决小区快速充电站的设置问题,提出了

一种单群体多目标蚁群优化算法。其优化目标是最小化线路设置开销和分布式电力网中的电力损耗。针对优化的两个目标,该方法设置了对应的启发式矩阵,并使用加权积合并启发式值。此外,该算法设置了一个信息素矩阵。针对实际问题的测试结果表明了该方法的有效性。

基于帕累托的多目标蚁群算法起步较早,研究成果较多。由于直接采用帕累托最优的概念,因此它的结果具有显著的直观意义,使用范围较广。然而,它需要考虑算法的组成部分以及相关的参数设置,且算法的运行参数依赖于具体的求解问题,泛化性能较弱。

3.2 基于指标函数的方法

指标函数有度量帕累托解质量的指示函数,它将相关帕累托集合的支配强度关系映射到实数上,根据指标函数的评价结果,可以对算法的收敛性和解集的分布性作比较。其中常用的指标函数有 Epsilon 指标 I_ϵ^+ 、Hypervolume 指标 I_{HD} 和 R2 指标^[44-46]。Epsilon 指标可表示为:

$$I_\epsilon^+(x_1, x_2) = \min_{\epsilon} (f_i(x_1) - \epsilon \leq f_i(x_2)), i \in \{1, \dots, m\} \quad (7)$$

如图5所示,它表示解 x_1 弱支配解 x_2 需要移动的最短距离(如果解 x_1 支配解 x_2 或其对应目标向量相等,则解 x_1 弱支配解 x_2)。




图5 Epsilon 指标示意图

Hypervolume 指标可表示为:

$$I_{HD}(x_1, x_2) = \begin{cases} H(x_2) - H(x_1), & \text{如果 } x_2 \succ x_1 \\ H(x_2 + x_1) - H(x_1), & \text{否则} \end{cases} \quad (8)$$

其中, $H(x_1)$ 表示被 x_1 支配的目标空间超体积(Hypervolume), $I_{HD}(x_1, x_2)$ 表示被 x_2 支配而不被 x_1 支配的空间体积,如图6所示。Hypervolume 指标是一种综合度量方法,它能够同时反映出解的收敛性和多样性。文献[45]证明了Hypervolume指标与帕累托支配具有严格的一致性,即当解集的Hypervolume指标值最大时,解集收敛至帕累托最优。




图6 Hypervolume 指标示意图

文献[47]提出了一种解决多目标背包问题的基于指标函数的多目标蚁群优化方法(Indicator-Based Ant Colony Optimization, IBACO),该方法使用指标函数的评估值指导蚂蚁搜索帕累托前沿。IBACO 设置一个信息素矩阵和一个启发式

矩阵,并分别使用 Epsilon 指标和 Hypervolume 指标对蚂蚁找到的路径解进行比较,即指标函数的值越大,路径解越好,通过比较指标值更新算法的帕累托档案。IBACO 使用蚁群系统的精英方法,即只有全局非支配档案中的蚂蚁可以更新信息素矩阵。当前迭代结束后,IBACO 将全局非支配档案中路径解的指标值作为更新增量来更新信息素矩阵。在 2~4 个目标上的对比实验表明,IBACO 的收敛性较好,且执行时间较短。

文献[46]基于 R2 指标提出了解决连续优化问题的多目标蚁群优化 iMOACO,其中 R2 指标的定义如下:

$$R2(A,U) = \frac{1}{|U|} \sum_{u \in U, a \in A} \min\{u(a)\} \quad (9)$$

其中, A 表示近似集合, U 是效用函数 u 的集合,效用函数 $u: \mathbb{R}^m \rightarrow \mathbb{R}$ 是决策用户的偏好模型,它将每个目标向量映射到一个标量值。

iMOACO 使用 R2 指标对迭代过程中蚂蚁产生的新解与档案解进行合并排序,选择一定数量的较好解更新档案。与 MOEA/D、非支配排序遗传算法 III 等算法的对比显示了 iMOACO 算法的优越性。

基于指标函数的方法是近年来出现的一种新型多目标蚁群优化算法,它采用指标函数评价算法获取的最优解,因此对算法本身的设计要求较低,可在单目标蚁群优化算法的基础上直接拓展使用。然而,其获得次优解的可解释性较弱,且该类算法本身的性能依赖于所选择的指标函数,根据问题的特点选择合适的指标函数是该类算法应用的关键。

3.3 目标分解法

文献[8]提出了基于分解的多目标进化算法。该方法通过对多目标问题进行权重分解,将其转化为一系列的标量优化子问题,每一个标量优化子问题就是一个单目标优化问题。它们通过交换各自解的信息来加快收敛速度。由于临近子问题通常通过聚合系数的欧氏距离决定,相近的权重向量对应子问题的最优解也相近,因此解信息的交换一般发生在临近的子问题之间。常用的聚合方法有:加权和法,切比雪夫方法,边界交叉法。由于加权和法与切比雪夫方法使用得较多,下面对其重点介绍。

1) 加权和法

$$\max g^{ws}(x|\lambda) = \sum_{i=1}^H \lambda_i f_i(x), x \in \Omega \quad (10)$$

2) 切比雪夫方法

$$\max g^{te}(x|\lambda, z^*) = \min_{1 \leq i \leq H} \{\lambda_i |f_i(x) - z_i^*|\}, x \in \Omega \quad (11)$$

其中, $\lambda = \{\lambda_1, \lambda_2, \dots, \lambda_H\}$ 为权重向量,且 $\lambda_1 + \lambda_2 + \dots + \lambda_i + \dots + \lambda_H = 1, \lambda_i \geq 0$ 。 $z^* = (z_1^*, z_2^*, \dots, z_H^*)^T$ 称为参考点,且 $z_i^* = \min\{f_i(x) | x \in \Omega\}$ 。通过标量化分解,每个标量优化子问题的最优解就是一个帕累托最优解,因此对帕累托前沿的搜索可以转化为求解标量优化子问题的最优解问题。

基于分解的多目标进化算法,文献[48]提出了基于分解的多目标蚁群优化 MOEA/D-ACO。通过加权和和切比雪夫方法将多目标分解转换为单目标子问题,每只蚂蚁求解一个子问题,如图 7 所示。




图 7 基于分解的多目标蚁群优化示意图

MOEA/D-ACO 算法有两个特点。

(1) 个体更新:通过邻居最优解对蚂蚁个体的当前最优解进行更新。设蚂蚁 i 的邻居为 $B(i)$,它包含权重向量在欧氏距离中距离蚂蚁 i 最近的 T 只蚂蚁,MOEA/D-ACO 选择邻居蚂蚁 $B(i)$ 生成的最好路径解对蚂蚁 i 的当前最好路径解进行更新。通过个体更新,蚂蚁之间进行了信息交流。

(2) 组信息素矩阵更新:MOEA/D-ACO 将 N 只蚂蚁分割成 k 个组,每个组优化帕累托前沿的一部分,在每个组内设置一个信息素矩阵和一个帕累托档案,用组内蚂蚁生成的解更新帕累托档案,每轮迭代结束后,使用帕累托档案中的解更新当前组的信息素矩阵。

此外,MOEA/D-ACO 根据最大最小蚂蚁系统^[49]的结论,对信息素矩阵更新后的值设定上限和下限,以防止陷入局部最优。在 2~4 个目标的多目标背包问题上的对比实验表明,MOEA/D-ACO 优于 BicriterionAnt。

基于分解的多目标进化算法,文献[50]提出了基于分解的二进制多目标蚁群优化 MOEA/D-BACO。MOEA/D-BACO 与 MOEA/D-ACO 使用了相同的分解方式,并且包含个体更新和组信息素矩阵更新组件。不同之处在于,MOEA/D-BACO 为了有效解决无约束多目标二元二次规划问题,将 MOEA/D-ACO 中使用的蚁群优化替换为二进制蚁群优化算法来求解分解后的标量子问题。实验结果显示,MOEA/D-BACO 优于 MOEA/D 和非支配排序遗传算法 II。

目标分解法使用目标分解框架将多目标优化问题转换为标量单目标优化问题,从而可以直接采用单目标优化算法求解。由于 MOEA/D 是目前为止性能较好的基于分解的多目标进化算法,目前的目标分解法也以 MOEA/D 的目标分解方法为主,而将采用遗传算法求解单目标优化的方法替换为其他单目标优化方法,因此目标分解法的性能与目标分解的方法(如加权和、切比雪夫方法和边界交叉法)和单目标优化方法相关。

结束语 多目标蚁群优化经过十几年的发展,已经成为了多目标优化算法中较为常用的进化算法之一,许多研究成果也表明了该方法的有效性与应用的广泛性。然而,多目标蚁群优化仍然存在许多亟待解决的问题。

(1) 多目标蚁群优化的收敛性证明。尽管存在众多对多目标蚁群优化的研究,但是针对多目标蚁群优化收敛性的证明并不多见。因此,在实际的运用中,需要依据问题的特点调整参数,以获取最优性能。然而该方法的经验性较强,且需要

耗费大量的时间来优化参数,这也限制了多目标蚁群优化的应用与进一步推广。

(2)基于帕累托的方法的拓展。从研究的范围来看,基于帕累托的方法主要在两目标问题上进行优化求解,信息素矩阵和启发式矩阵的设置与聚合方式也难以拓展到3个目标以上的问题中。此外,随着目标维度的增加,优化算法的收敛性与多样性会急剧恶化^[51],如何在高维目标空间中保持多目标蚁群优化良好的收敛性与多样性也是需要进一步研究的问题。

(3)指标函数计算复杂度的优化。相比于基于帕累托的方法,指标函数法在最优解的选择方面具有天然的优势。通过指标函数将解在各个目标上的适应度转换成单个值进行比较,其结果与帕累托方法一样具有严格的单调性。然而,指标函数的计算复杂度较高,在解决复杂优化问题时消耗大量的计算资源。如何降低指标函数的计算复杂度,是基于指标函数的多目标蚁群优化需要解决的关键问题。

(4)目标分解权重的优化。目标分解法是通过权重向量将多目标优化问题分解成单目标量子问题来进行求解,因此权重向量的设置决定了算法的优化性能,设置的权重越多,分解得到的子问题越多,算法的搜索性能越好,同时也会消耗较多的计算资源。此外,聚合方法的不同也会对算法的结果产生影响^[31]。如何平衡有限的计算资源和算法性能,选择合适的聚合方法,是目标权重法面临的主要困难。

(5)信息素更新值的深入研究。在多目标蚁群优化中,通过信息素矩阵的更新,加强信息正反馈是其特有的优势,正是这种采用“优化时学习”的原则^[52],使得多目标蚁群优化具有比其他算法更好的性能。然而,在许多研究成果中,作者并没有给出确定信息素更新值的原因,也没有验证更新值的不同对问题求解效果的影响,尤其是存在多个信息素矩阵的条件下,信息素矩阵更新值的不同是否会对求解产生更深的影 响,也是未来需要深入探讨的问题。

(6)实现的公开化。尽管多目标蚁群优化的研究成果丰硕,然而鲜有研究人员公开其算法的源代码。由于不同的研究人员对算法的理解以及代码的实现不尽相同,因此会造成复现结果的不一致,从而阻碍了不同研究人员之间的深入交流和进一步探索的可能性。

参 考 文 献

- [1] ASAFUDDOULA M, RAY T, SARKER R. A Decomposition Based Evolutionary Algorithm for Many Objective Optimizaion [J]. IEEE Transactions on Evolutionary Computation, 2015, 19(3):445-460.
- [2] MUKHOPADHYAY A, MAULIK U, BANDYOPADHYAY S, et al. A Survey of Multiobjective Evolutionary Algorithms for Data Mining: Part I [J]. IEEE Transactions on Evolutionary Computation, 2014, 18(1):4-19.
- [3] MUKHOPADHYAY A, MAULIK U, BBANDYOPADHYAY S, et al. Survey of Multiobjective Evolutionary Algorithms for Data BANDYOPADHYAY: Part II [J]. IEEE Transactions on Evolutionary Computation, 2014, 18(1):20-35.
- [4] WANG Z T, GUO J S, ZHENG M F, et al. Uncertain Multi-objective Traveling Salesman Problem [J]. European Journal of Operational Research, 2015, 241(2):478-489.
- [5] ISHIBUCHI H, AKEDO N, NOJIMA Y. Behavior of Multi-objective Evolutionary Algorithm on Many-Objective Knapsack Problem [J]. IEEE Transactions on Evolutionary Computation, 2015, 19(2):264-283.
- [6] ARIYASINGHA I D I D, FERNANDO T G I. A Performance Study for the Multiobjective Ant Colony Optimization Algorithms on the Job Shop Scheduling Problem [J]. International Journal of Computer Applications, 2015, 132(14):1-8.
- [7] ADHAM A M, MOHD-GHAZALI N, AHMAD R. Performance Optimization of A Microchannel Heat Sink Using the Improved Strength Pareto Evolutionary Algorithm (SPEA2) [J]. Journal of Engineering Thermophysics, 2015, 24(1):86-100.
- [8] ZHANG Q F, LI H. MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition [J]. IEEE Transactions on Evolutionary Computation, 2007, 11(6):712-731.
- [9] DEB K, JAIN H. An Evolutionary Many-Objective Optimization Algorithm Using Reference-Point-Based Nondominated Sorting Approach, Part I: Solving Problems With Box Constraints [J]. IEEE Transactions on Evolutionary Computation, 2014, 18(4):577-601.
- [10] ARIYASINGHA I D I D, FERNANDO T G I. Performance Analysis of the Multiobjective Ant Colony Optimization Algorithms for the Traveling Salesman Problem [J]. Swarm and Evolutionary Computation, 2015, 23:11-26.
- [11] XU G, LIU B B, SONG J, et al. Multiobjective Sorting-Based Learning Particle Swarm Optimization for Continuous Optimization [J/OL]. Natural Computing, <https://doi.org/10.1007/s11047-016-95-48-3>.
- [12] YANG S X. Bat Algorithm for Multiobjective Optimization [J]. International Journal of Bio-Inspired Computation, 2012, 3(5):267-274.
- [13] ANGELO J S, BERNARDINO H S, BARBOSA H J C. Ant Colony Approaches for Multiobjective Structural Optimization Problems with A Cardinality Constraint [J]. Advances in Engineering Software, 2014, 80:101-115.
- [14] WANG X Q, ZHAO Y, WANG D, et al. Improved Multiobjective Ant Colony Optimization Algorithm and Its Application in Complex Reasoning [J]. Chinese Journal of Mechanical Engineering, 2013, 26(5):1031-1040.
- [15] ANGELO J S, BERNARDINO H S, BARBOSA H J C. Ant Colony Approaches for Multiobjective Structural Optimization Problems with A Cardinality Constraint [J]. Advances in Engineering Software, 2015, 80:1010-115.
- [16] XU R, CHEN H P, LI X P. A Biobjective Scheduling Problem on Batch Machines Via A Pareto Based Ant Colony System [J]. International Journal of Production Economics, 2013, 14(1):371-386.
- [17] LI K Q, DIAO X C, CAO J J. Survey on Ant Colony Optimization Algorithms for Stochastic Combinatorial Optimization [J]. Application Research of Computers, 2010, 27(12):4406-4409. (in Chinese)

- 李凯齐,刁兴春,曹建军. 蚁群优化算法在求解随机组合优化问题中的应用综述[J]. 计算机应用研究, 2010, 27(12): 4406-4409.
- [18] TAN Y, SHI Y H, BUARQUE F, et al. Advances in Swarm and Computational Intelligence[M]. Springer, 2015: 197-204.
- [19] LIN P P, ZHANG J, CONTRERAS M A. Applying Pareto Ant Colony Optimization to Solve Biobjective Forest Transportation Planning Problems[C]// IEEE International Conference on Information Reuse & Integration. 2015: 795-802.
- [20] WANG L J, SHEN J, LUO J Z. Facilitating An Ant Colony Algorithm for Multiobjective Data Intensive Service Provision[J]. Journal of Computer and System Sciences, 2015, 81(4): 734-746.
- [21] GAO Y Q, GUAN H B, QI Z W, et al. A Multiobjective Ant Colony System Algorithm for Virtual Machine Placement in Cloud Computing[J]. Journal of Computer and System Sciences, 2013, 79(8): 1230-1242.
- [22] MALEKLOO M, KARA N. Multiobjective ACO Virtual Machine Placement in Cloud Computing Environments[C]// Globecom 2014 Workshop-Cloud Computing System, Networks, and Applications. 2014: 112-116.
- [23] NOPBHORN L, PHONRATTANASAK P. Multiobjective Ant Colony Optimization for Fast Charging Stations Planning in Residential Area[C]// 2014 IEEE Innovative Smart Grid Technologies-Asia. 2014: 290-295.
- [24] MONCAYO-MARTINEZ L A, RECIO G. Bi-criterion Optimization for Configuring An Assembly Supply Chain Using Pareto Ant Colony Meta-Heuristic[J]. Journal of Manufacturing Systems, 2014, 33(1): 188-195.
- [25] SAGRADO J D, AGUILA I M D, ORELLANA F J. Multiobjective Ant Colony Optimization for Requirements Selection[J]. Empirical Software Engineering, 2015, 20(3): 577-610.
- [26] CAO J J, DIAO X C, WANG T, et al. Research on Domain-Independent Data Cleaning: A Survey[J]. Computer Science, 2010, 37(5): 26-29. (in Chinese)
曹建军,刁兴春,汪挺,等. 领域无关数据清洗研究综述[J]. 计算机科学, 2010, 37(5): 26-29.
- [27] TAN M C, DIAO X C, CAO J J. Survey on Entity Resolution [J]. Computer Science, 2014, 41(4): 9-12. (in Chinese)
谭明超,刁兴春,曹建军. 实体分辨研究综述[J]. 计算机科学, 2014, 41(4): 9-12.
- [28] CAO J J, LIU Y, DIAO X C, et al. A New Design of Ensemble Classifiers for High-Dimension Entity Resolution[C]// Proceedings of International Conference on Information Quality (ICIQ 2016). Ciudad Real, Spain, 2016.
- [29] YU P L. Cone Convexity, Cone Extreme Points, and Nondominated Solutions in Decision Problems with Multiobjectives[J]. Journal of Optimization Theory & Applications, 1974, 14(3): 319-377.
- [30] ZITZLER E, THIELE L, LAUMANN S M, et al. Performance Assessment of Multiobjective Optimizers: An Analysis and Review[J]. IEEE Transactions on Evolutionary Computation, 2003, 7(2): 117-132.
- [31] LI B D, LI J L, TANG K, et al. Many-Objective Evolutionary algorithms: a survey[J]. ACM Computing Surveys, 2015, 48(1): 1-35.
- [32] BERRICHI A, YALAOUI F. Efficient Biobjective Ant Colony Approach to Minimize Total Tardiness and System Unavailability for A Parallel Machine Scheduling Problem[J]. International Journal of Advanced Manufacturing Technology, 2013, 68(9-12): 2295-2310.
- [33] SUN X S, LU C, LIU S X, et al. Multiobjective ACO Algorithm for Slab Selecting and Charging Scheduling in Hot Rolling Production[C]// The 5th Annual IEEE International Conference on Cyber Technology in Automation, Control and Intelligent Systems. 2015: 703-708.
- [34] ZHAO B X, GAO J M, CHEN K, et al. Two Generation Pareto Ant Colony Algorithm for Multiobjective Job Shop Scheduling Problem with Alternative Process Plans and Unrelated Parallel Machines [J/OL]. Journal of Intelligent Manufacturing, <https://doi.org/10.1007/s10845-015-1091-Z>.
- [35] LOPEZ I M, STUTZLE T. The Automatic Design of Multiobjective Ant Colony Optimization Algorithms[J]. IEEE Transactions on Evolutionary Computation, 2012, 16(6): 861-875.
- [36] ALAYA I, SOLNON C, GHDIRA K. Ant Colony Optimization for Multiobjective Optimization Problems[C]// IEEE ICTAI. 2007: 450-457.
- [37] IREDI S, MERKLE D, MIDDENDOF M. Bi-criterion Optimization with Multi Colony Ant Algorithms[C]// International Conference on Evolutionary Multi-Criterion Optimization. 2001: 359-372.
- [38] BARÁN B, SCHAERER M. A Multiobjective Ant Colony System for Vehicle Routing Problem with Time Windows[C]// The 21st IASTED Conference on Application Informatics. 2003: 97-102.
- [39] DOERNER K, HARTL R F, REIMANN M. Are COMPETants More Competent for problem solving? —The case of a multiple objective transportation problem[J]. Central Europe Journal of Operation, 2003, 11(2): 115-141.
- [40] DOERNER K, GTJAHN W, HARTL R, et al. Pareto Ant Colony Optimization: A Metaheuristic Approach to Multiobjective Portfolio Selection[J]. Annals of Operations Research, 2004, 131(1-4): 79-99.
- [41] LÓPEZ-IBÁÑEZ M, STÜTZLE T. The Impact of Design Choices of Multiobjective Ant Colony Optimization Algorithms on Performance: An Experimental Study on the Biobjective TSP [C]// Genetic and Evolutionary Computation. 2010: 71-78.
- [42] DILIP K, KUMAR T V V. Multicriteria Website Optimization Using Multiobjective ACO[C] // International Conference on Reliability. 2015: 1-6.
- [43] FERNANDO T G I. Ant Colony Optimization Based Simulation of 3D Automatic Hose/Pipe Routing[D]. London: Brunel University, 2009.
- [44] ZITZLER E, KÜNZLI S. Indicator Based Selection in Multiobjective Search [M] // Parallel Problem Solving from Nature-PPSN VIII. Springer, 2004.

结束语 本文研究了数据中心的虚拟机管理机制,在虚拟机的初始放置阶段,通过 MDFF 算法优化数据中心能耗。在虚拟机动态调整阶段,利用动态阈值的方法,根据负载的需求动态整合虚拟机,达到降低能耗的目的。对于超载的物理机节点,综合考虑迁移时间与 CPU 资源占用,减少迁移代价,降低 SLA 违背率。仿真实验表明,本文调度机制在能耗、虚拟机迁移次数方面取得了较好的效果。下一步将研究某些特定应用的特征,利用应用特征信息更好地进行虚拟机的初始配置,减少虚拟机动态迁移的消耗。

参 考 文 献

- [1] State of the Data Center 2011 [EB/OL]. [2016-08-05]. <http://www.emersonnetworkpower.com/en-US/Solutions/infographics/Pages/2011DataCenterState.aspx>.
- [2] YE K J, WU Z H, JIANG X H, et al. Power Management of Virtualized Cloud Computing Platform[J]. Chinese Journal of Computers, 2012, 35(6): 1262-1285. (in Chinese)
叶可江, 吴朝晖, 姜晓红, 等. 虚拟化云计算平台的能耗管理[J]. 计算机学报, 2012, 35(6): 1262-1285.
- [3] DONG Y, ZHOU L, JIN Y, et al. Improving Energy Efficiency for Mobile Media Cloud via Virtual Machine Consolidation[J]. Mobile Networks and Applications, 2015, 20(3): 370-379.
- [4] HIEU N T, DI FRANCESCO M, JÄÄSKI A Y. A virtual machine placement algorithm for balanced resource utilization in cloud data centers[C]//2014 IEEE 7th International Conference on Cloud Computing. IEEE, 2014: 474-481.
- [5] HUANG Z N, LI H S, ZHAO J. Virtual Machine Placement Algorithm Based on Improved Genetic Algorithm[J]. Computer Science, 2015, 42(S2): 406-407, 416. (in Chinese)
黄兆年, 李海山, 赵君. 基于双适应度遗传算法的虚拟机放置的研究[J]. 计算机科学, 2015, 42(S2): 406-407, 416.
- [6] ZHU X, YOUNG D, WATSON B J, et al. 1000 islands: Integrated capacity and workload management for the next generation data center[C]//International Conference on Autonomic Computing, 2008(ICAC'08). IEEE, 2008: 172-181.
- [7] ADHIKARI J, PATIL S. Double threshold energy aware load balancing in cloud computing[C]//2013 Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT). IEEE, 2013: 1-6.
- [8] BELOGLAZOV A, BUYYA R. Adaptive threshold-based approach for energy-efficient consolidation of virtual machines in cloud data centers[C]//Proceedings of the 8th International Workshop on Middleware for Grids, Clouds and e-Science. ACM, 2010: 1-6.
- [9] BEATY K A, BOBROFF N, KOCHUT A. Dynamic placement of virtual machines for managing violations of service level agreements(SLAs); U. S. Patent 8,291,411[P]. 2012-10-16.
- [10] TANG Z, MO Y, LI K, et al. Dynamic forecast scheduling algorithm for virtual machine placement in cloud computing environment[J]. The Journal of Supercomputing, 2014, 70(3): 1279-1296.
- [11] FAN X, WEBER W D, BARROSO L A. Power provisioning for a warehouse-sized computer[C]//International Symposium on Computer Architecture(DBLP). 2007: 13-23
- [12] XU F, LIU F, LIU L, et al. iaware: Making live migration of virtual machines interference-aware in the cloud[J]. IEEE Transactions on Computers, 2014, 63(12): 3012-3025.
- [13] BELOGLAZOV A, BUYYA R. Optimal online deterministic algorithms and adaptive heuristics for energy and performance efficient dynamic consolidation of virtual machines in cloud data centers[J]. Concurrency and Computation: Practice and Experience, 2012, 24(13): 1397-1420.
- [14] FU X, ZHOU C. Virtual machine selection and placement for dynamic consolidation in Cloud computing environment[J]. Frontiers of Computer Science, 2015, 9(2): 322-330.
- [15] CALHEIROS R N, RANJAN R, BELOGLAZOV A, et al. CloudSim: a toolkit for modeling and simulation of cloud computing environments and evaluation of resource provisioning algorithms[J]. Software: Practice and Experience, 2011, 41(1): 23-50.
- [16] SPECpower_ssj2008 Results [EB/OL]. [2016-08-05]. http://www.spec.org/power_ssj2008/results.
- (上接第 13 页)
- [45] BADER J, ZITZLER E. HypE: An Algorithm for Fast Hypervolume Based Many-objective Optimization[J]. IEEE Transactions on Evolutionary Computation, 2011, 19(1): 45-76.
- [46] FALCON C J G, COELLO C A C. IMOACO_R: A New Indicator Based Multiobjective Ant Colony Optimization for Continuous Search Spaces[M]. Springer, 2015.
- [47] MANSOUR I B, ALAYA I. Indicator Based Ant Colony Optimization for Multiobjective Knapsack Problem[J]. Procedia Computer Science, 2015, 60(1): 448-457.
- [48] LI K, ZHANG Q F, BATTITI R. MOEA/D-ACO: A Multiobjective Evolutionary Algorithm Using Decomposition and Ant Colony[J]. IEEE Transactions on Cybernetics, 2013, 43(6): 1845-1859.
- [49] STÜTZLE T, HOOS H H. Max Min Ant System[J]. Future Generation Computer Systems, 2000, 16(9): 889-914.
- [50] SOUZA M Z D, POZO A T R. Multiobjective Binary ACO for Unconstrained Binary Quadratic Programming[C]//Brazilian Conference on Intelligent Systems, 2015: 86-91.
- [51] WANG H D, JIAO L C, YAO X. Two_Arch2: An Improved Two-Archive Algorithm for Many-Objective Optimization[J]. IEEE Transactions on Evolutionary Computation, 2015, 19(4): 524-541.
- [52] BATTI R, BRUNATO M, MASCIA F. Reactive Search and Intelligent Optimization [J]. Operations Research/Computer Science Interfaces Series, 2008, 45(3): 151-153.