

文章编号:1673-0062(2017)02-0056-06

一种改进的多目标人工蜂群算法

陈伟栋,童华刚,郜振华*,张洪亮

(安徽工业大学 管理科学与工程学院,安徽 马鞍山 243000)

摘要:由于基本多目标人工蜂群算法存在着种群盲目搜索、算法开发能力有限等缺点,在利用人工蜂群算法求解多目标优化问题时,提出了一种改进的人工蜂群算法。通过在算法中引入自适应搜索机制和变异机制等操作,使得种群个体可以有针对性地进行更新,同时也大大提高了种群个体的多样性。最后利用几种多目标的测试函数对改进前后的多目标人工蜂群算法的性能进行测试,结果表明:改进后多目标人工蜂群算法具有良好的算法收敛性和均匀性。

关键词:人工蜂群算法;多目标优化问题;自适应搜索;变异操作

中图分类号:TP301.6 **文献标志码:**A

Improved Multi-objective Artificial Bee Colony Algorithm

CHEN Wei-dong, TONG Hua-gang, GAO Zhen-hua*, ZHANG Hong-liang

(Institute of Management Science and Engineering, Anhui University of
Technology, Maanshan, Anhui 243000, China)

Abstract: In the use of artificial colony algorithm to solve multi-objective optimization problems, the standard multi-objective artificial colony algorithm has some shortcomings, such as population blind search, limited algorithmic development capability and so on. An improved artificial colony algorithm is proposed in this paper, which introduces the adaptive algorithm search mechanism and the mechanism of variation operation to make the individual species be targeted for updates and improve the diversity of population greatly. Finally several kinds of multi-objective test function are used to verify the standard and improved multi-objective artificial colony algorithm performance, the comparison result indicates the improved multi-objective artificial colony algorithm has better convergence and uniformity.

key words: artificial bee colony algorithm; multi-objective optimization problem; adaptive search; variation operation

收稿日期:2017-05-15

基金项目:安徽省教育厅人文社科重点项目(SK2016A0168);安徽省社科联社会科学创新发展课题(A2015070)

作者简介:陈伟栋(1992-),男,硕士研究生,主要从事管理科学与工程方向的研究.E-mail:1571803048@qq.com.* 通讯作者:郜振华,1013823212@qq.com

0 引言

在日常生活中,经常会遇到各种各样的目标优化问题,例如:单目标函数优化问题、物流配送中心选址以及路径优化问题等.其中,单目标优化问题求解过程较为简单,但是多目标优化问题^[1]的求解较为复杂,由于多目标之间存在着冲突以致于难以求得一个使得所有目标同时达到最优解的解,因此,在求解多目标优化问题时,最终的求解结果往往是一个 Pareto 最优解^[2]的集合.目前关于此类问题的求解方法主要有线性规划方法、群智能算法等.

2005年, D. Karaboga 提出了人工蜂群算法^[3],由于该算法具有控制参数少、收敛速度快和鲁棒性强等优点而受到了广大学者的关注,与此同时,该算法也被用来求解各种复杂的多目标优化问题.但是基本多目标人工蜂群算法在处理此类问题时存在着一些不足和局限性,例如:种群盲目搜索、算法开发能力有限等.为此,本文在基本多目标人工蜂群算法的基础上引入了自适应搜索机制和变异机制等操作,结合算法的基本原理设计出一种改进的多目标人工蜂群算法流程.

1 多目标优化问题的描述

在工程应用和决策过程中遇到的大多数问题皆可归纳为多目标优化问题,由于多目标优化问题的研究具有较强的实用性和较高的研究价值,因此对于该类问题的研究就显得十分重要.多年来,经过国内外学者不懈的努力和研究,现可将多目标优化问题进行如下描述^[4]:

$$\begin{aligned} & \min [f_1(x), f_2(x), \dots, f_n(x)] \\ & \text{s.t.} \begin{cases} lb \leq x \leq ub \\ Aeq^* x = beq \\ A^* x \leq b \end{cases} \end{aligned} \quad (1)$$

公式(1)中, $f_i(x)$ 表示优化问题的第*i*个目标函数,其中*n*表示目标函数的数量, x 表示优化问题中的自变量, ub 、 lb 分别表示自变量*x*的上下限约束,等式 $Aeq^* x = beq$ 表示对自变量*x*的线性约束,不等式 $A^* x \leq b$ 表示对自变量*x*的非线性约束.

研究发现,在对多目标优化问题的求解过程中,往往会出现为了实现某一目标函数 f_i 达到最优,却使得其他目标函数 $f_k(k \neq i, i \in (1, 2, \dots, n))$ 无法达到最优的情况发生.此时称优化问题的可行解是非劣解,或者说是 Pareto 最优解.也就是

说,多目标优化问题的研究就是要寻找所求解问题的 Pareto 最优解.

下面对多目标优化问题中的一些专业名词进行详细阐述^[5]:

1) 可行解和可行解集:若自变量*x*满足目标函数的所有约束条件,则称自变量*x*为优化问题的可行解,所有可行解组成的解集称为可行解集.

2) Pareto 支配:现假设 x_A 和 x_B 为优化问题可行解集中的两个可行解,若 x_A 和 x_B 满足下述条件: $f_i(x_A) \leq f_i(x_B), \forall i = 1, 2, \dots, n$ 且 $f_i(x_A) < f_i(x_B), \exists i = 1, 2, \dots, n$.则称 x_A 相比于 x_B 是 Pareto 占优的,换言之, x_A Pareto 支配 x_B ,记为 $x_A > x_B$.

3) Pareto 最优解和 Pareto 最优解集:若假设优化问题中的一个可行解 x^* ,若 x^* 当且仅当满足 $\exists x: x^* > x$ 时,则称 x^* 为 Pareto 最优解,所有 Pareto 最优解的集合称为 Pareto 最优解集.

4) Pareto 前端: Pareto 最优解集中的解所对应的目标函数值组成的集合称为 Pareto 前端.

为了评价算法是否实现了预先设定的目标,现引入多目标优化评价指标^[6]对算法的性能进行评价.其中,世代距离 (generational distance, GD)可以有效地反映出所求 Pareto 最优解与全局 Pareto 最优前端的逼近程度,从而评价算法的收敛性;多样性指标 Δ 则用来评价 Pareto 最优解的多样性.下面对这两项评价指标进行详细地阐述.

1) 世代距离

世代距离 (GD) 是用来描述算法所获得的非劣解与问题的真实 Pareto 前端之间的距离,世代距离越小,则说明算法的收敛性越强.计算公式如式(2)所示:

$$GD = \frac{\sqrt{\sum_{i=1}^n \text{dist}_i^2}}{n} \quad (2)$$

公式(2)中, dist_i 表示第*i*个非劣解与真实 Pareto 前端之间的最短距离,*n*为非劣解数量.

2) 多样性指标 Δ

多样性指标 Δ 反映的是非劣解能否均匀地分布在整個均衡面上.其中,多样性指标 Δ 值越小,则说明算法最优解的多样性越强.多样性指标 Δ 的具体计算公式如式(3)所示:

$$\Delta = \frac{h_f + h_1 + \sum_{i=1}^{n-1} |h_i - \bar{h}|}{h_f + h_1 + (n-1)\bar{h}} \quad (3)$$

公式(3)中,在对所有非劣解按照目标函数

值的大小排序的前提下, h_i 为相邻两点间的距离, \bar{h} 为 h_i 的均值, h_f 和 h_1 分别为算法所获得的边界值与相应极端间的距离. n 为非劣解的个数.

2 求解多目标优化问题的人工蜂群算法流程

结合多目标优化问题的特点以及人工蜂群算法的基本原理, 设计出如图 1 所示的基本多目标人工蜂群算法的基本流程图^[7-8].

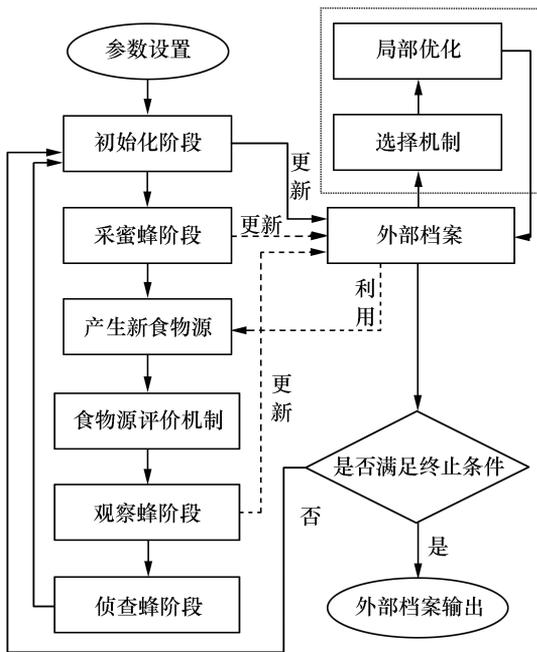


图 1 多目标人工蜂群算法的基本流程图
Fig.1 The basic flowchart of multi-target artificial bee colony

3 算法改进

通过上述对基本多目标人工蜂群算法流程的分析可知, 在算法中, 由于种群个体在进行蜜源位置更新时, 未能有效地根据个体在每个目标上的适应度值自适应调整搜索范围, 导致算法在搜索 Pareto 最优解时盲目性较强. 同时, 种群个体的生成方式较为单一化, 使得算法的开发能力明显存在不足. 为了弥补算法中存在的缺陷, 本文进行了有针对性的改进, 在算法的采蜜蜂阶段和观察蜂阶段, 通过引入交叉操作提高算法的开发能力. 在算法的侦查蜂阶段, 通过自适应搜索操作, 使得算法有针对性地进行搜索, 进而提高可行解的质量. 具体的改进措施如式(6)所述:

1) 引入自适应搜索操作^[9]

个体的适应度值反映了个体的质量, 为使算法搜索时能根据个体在每个目标上的适应度值自适应调整搜索范围, 避免算法盲目搜索, 本文定义个体适应度调节项 T , 具体计算公式如式(4)所示:

$$T = \sum_{j=1}^n \frac{f_j(X_i) - f_j^{\min}}{f_j^{\max} - f_j^{\min}} \quad (4)$$

公式(4)中, n 表示目标个数, f_j^{\min} 和 f_j^{\max} 分别表示当前种群中个体对应的第 j 个目标的最优和最差适应度值; $f_j(X_i)$ 表示个体 X_i 对应第 j 个目标的适应度值.

根据个体适应度调节项 T 设计出如式(5)所示的自适应搜索算子.

$$x'_{id} = x_{id} + R \times T \times \left(\sum_{j=1}^n (\omega_j x_{jd}^j) - x_{id} \right) \quad (5)$$

公式(5)中, R 表示 $[-1, 1]$ 内的随机数; ω_j 表示随机权重 ($\sum_{j=1}^n \omega_j = 1$), 每次迭代都需要随机产生一次 ω_j ; j 表示问题的第 j 个目标, x_{jd}^j 表示个体 X^j 的第 d 维分量.

2) 引入交叉操作^[10]

在本文算法改进过程中, 采用二项交叉与人工蜂群算法相结合. 在采蜜蜂邻域搜索的过程中, 通过与全局最优值进行交叉操作来提高算法的开发能力, 具体公式如式(6)所示:

$$v'_{ij} = \begin{cases} v_{ij}, & \text{rand} < \text{cr} \\ x_j^{\text{Global}} + \beta(x_j^{\text{Global}} - v_{ij}), & \text{其他} \end{cases} \quad (6)$$

上述交叉操作中, 首先针对每一个分量生成一个 $[-1, 1]$ 之间均匀分布的随机值 rand , 若 $\text{rand} < \text{cr}$, 则接受目标分量, 否则保留当前个体的对应分量. 系数 cr 是用来协调算法的搜索能力和开发能力, 当 cr 越大时越有利于开发, 但是会降低搜索能力, cr 越小时越有利于增强算法的搜索能力, 但是会降低算法的开发能力. 其中, β 为 $[-1, 1]$ 之间的随机值.

4 数值实验

为了说明改进后的多目标人工蜂群算法在算法的收敛性和解的多样性上有了明显的改善, 现引入下面具有代表性的 4 个多目标连续测试函数^[11]对改进人工蜂群算法的性能进行测试, 具体测试函数如表 1 所示.

在表 1 中, 函数 ZDT1、ZDT2、ZDT3 和 ZDT4 皆有 2 个目标函数且函数的自变量数目皆为 6 个, 函数的自变量取值范围皆在 $[0, 1]$ 内, 这四个

测试函数的选取具有代表性.同时,针对其他类型的多目标多变量的连续函数,本算法在求解时同样适用.

实验主要分为两部分,在利用人工蜂群算法对上述 4 个测试函数进行求解时,首先需要对算法中的一些参数进行设置,种群大小定为 40,算法的最大迭代次数为 500 次,食物源停留的最大限制搜索次数为 50 次,为了将改进前后的人工蜂群算法的性能进行比较,其中改进后的人工蜂群算法中的参数设置同上所述.运用 MATLAB2010a 软件对测试函数进行运算,运算结果如下所示.

1) 基本多目标人工蜂群算法计算结果

利用基本人工蜂群算法分别对各个测试函数的进行 MATLAB 算法设计、程序编程以及算法仿真可以得到如图 2 所示的各个测试函数的多目标优化结果图.

2) 改进多目标人工蜂群算法计算结果

根据算法的改进策略对改进多目标人工蜂群算法的算法流程进行再设计,结合 MATLAB 软件分别对每个测试函数进行算法编程,运算仿真,将改进后得到的多目标优化结果图汇总如图 3 所示.

表 1 测试函数列表
Table 1 Test function list

函数名称	表达式
ZDT1	$\min f_1(x) = x_1$ $\min f_2(x) = g(x) \left(1 - \left(\frac{x_1}{g(x)} \right)^{0.5} \right)$ $s.t. \quad g(x) = 1 + 9 \left(\sum_{i=2}^n x_i \right) / (n - 1)$
ZDT2	$\min f_1(x) = x_1$ $\min f_2(x) = g(x) \left(1 - \left(\frac{x_1}{g(x)} \right)^2 \right)$ $s.t. \quad g(x) = 1 + 9 \left(\sum_{i=2}^n x_i \right) / (n - 1)$
ZDT3	$\min f_1(x) = x_1$ $\min f_2(x) = g(x) \left[1 - \sqrt{\frac{x_1}{g(x)}} - \frac{x_1}{g(x)} \sin(10\pi x_1) \right]$ $s.t. \quad g(x) = 1 + 9 \left(\sum_{i=2}^n x_i \right) / (n - 1)$
ZDT4	$\min f_1(x) = x_1$ $\min f_2(x) = g(x) \left[1 - \sqrt{\frac{x_1}{g(x)}} \right]$ $s.t. \quad g(x) = 1 + 10(n - 1) + \sum_{i=2}^n (x_i^2 - 10\cos(4\pi x_i))$

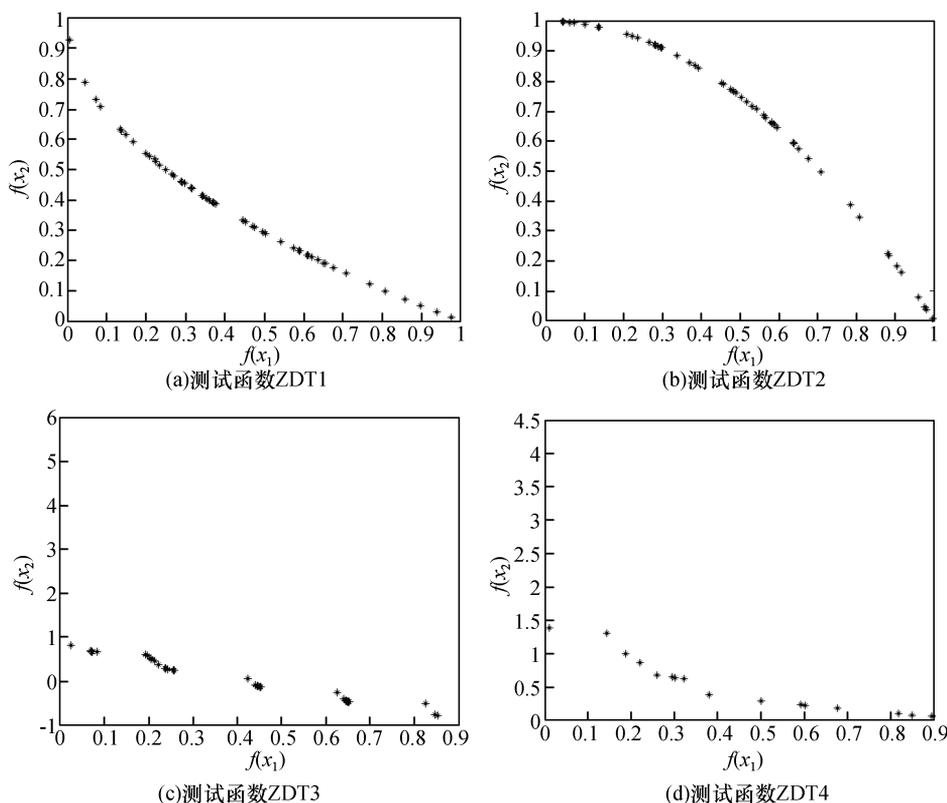


图 2 测试函数的多目标优化结果
Fig.2 Multi-objective optimization of test functions

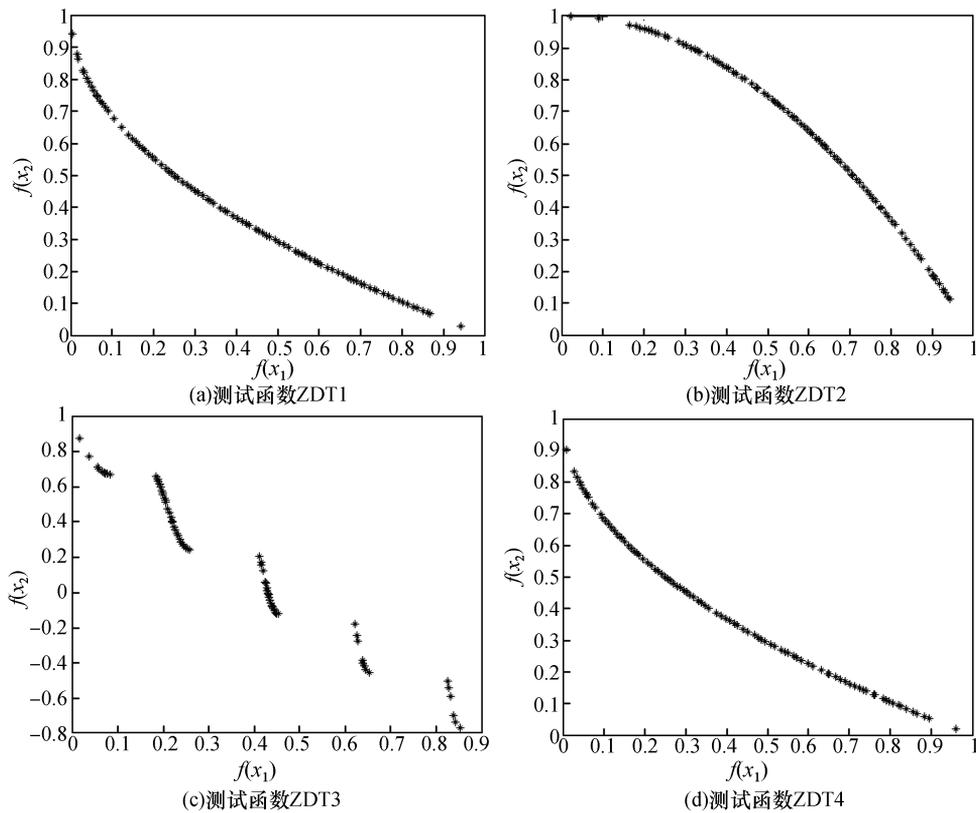


图3 测试函数的多目标优化结果

Fig.3 Multi-objective optimization of test functions

通过比较图2和图3的测试函数的多目标优化结果可以大致发现,在求解多目标测试函数时,改进后的多目标人工蜂群算法在解的均匀性和多样性上表现出了较大的优越性。

最后,为了更加细致地探讨人工蜂群算法改进前后的收敛性和解的多样性,表2中所示的世代距离GD、多样性指标 Δ 以及运行时间 T 的最大值、最小值、平均值以及标准差皆根据改进前后算法求解测试函数10次的运行结果得到的,通过对这些指标数值的处理分析,从而验证改进后多目标人工蜂群算法的优越性。

为了更加方便地对表2中的性能评估指标进行分析,将表2中的指标数值绘制成如图4所示的箱线图^[12]。

从图4的多目标优化性能评估指标箱线图可以发现:在求解多目标优化问题时,改进多目标人工蜂群算法的世代距离GD、多样性指标 Δ 的平均值和标准差明显小于基本多目标人工蜂群算法,说明改进后多目标人工蜂群算法具有较强的收敛性和较高的多样性。但是改进后算法的运行时间 T 明显增加,说明算法改进策略会导致算法的计算量变大,导致求解效率有所下降,因此在后续算法改进工作中应该有所侧重。

表2 多目标优化性能评估指标汇总表

Table 2 Summary table of multi-objective optimization performance evaluation index

	类型	最大值	最小值	平均值	标准差
Z	Δ 改进前	1.318 4	1.133 1	1.219 6	0.063 2
	改进后	1.354 7	0.482 6	0.813 2	0.349 1
D	改进前	0.037 1	2.855×10^{-5}	0.009 6	0.014 2
	改进后	0.021 5	$7.273 5 \times 10^{-6}$	0.004 4	0.006 9
T	改进前	30.384 5	26.213 2	27.780 6	1.360 9
	改进后	35.856 1	33.320 8	34.286 9	0.862 3
Z	Δ 改进前	1.367 9	1.144 1	1.244 8	0.069 5
	改进后	1.347 0	0.541 0	1.064 2	0.341 8
D	改进前	0.084 3	$4.231 5 \times 10^{-5}$	0.028 3	0.035 0
	改进后	0.083 4	2.85×10^{-6}	0.028 1	0.030 7
T	改进前	30.408 2	25.705 3	27.627	1.537 6
	改进后	38.795 9	34.072 1	35.412 2	1.645 2
Z	Δ 改进前	1.367 8	1.240 6	1.334 3	0.038 5
	改进后	1.251 5	0.934 4	1.0700	0.103 9
D	改进前	0.045 9	$4.638 8 \times 10^{-5}$	0.022 2	0.019 3
	改进后	0.043 8	$3.601 8 \times 10^{-5}$	0.008 3	0.016 4
T	改进前	27.843 6	23.789 4	26.204 6	1.240 7
	改进后	33.125 0	27.742 1	29.471 1	1.764 7
Z	Δ 改进前	1.628 9	1.395 7	1.457 4	0.061
	改进后	0.937 7	0.451 8	0.551 4	0.133 8
D	改进前	0.689 2	0.001 7	0.254 6	0.249 6
	改进后	0.007 2	$8.144 4 \times 10^{-5}$	0.000 7	0.002 2
T	改进前	22.475 1	14.703 8	18.548 7	2.744 9
	改进后	35.689 2	32.733 3	34.263 7	0.900 6

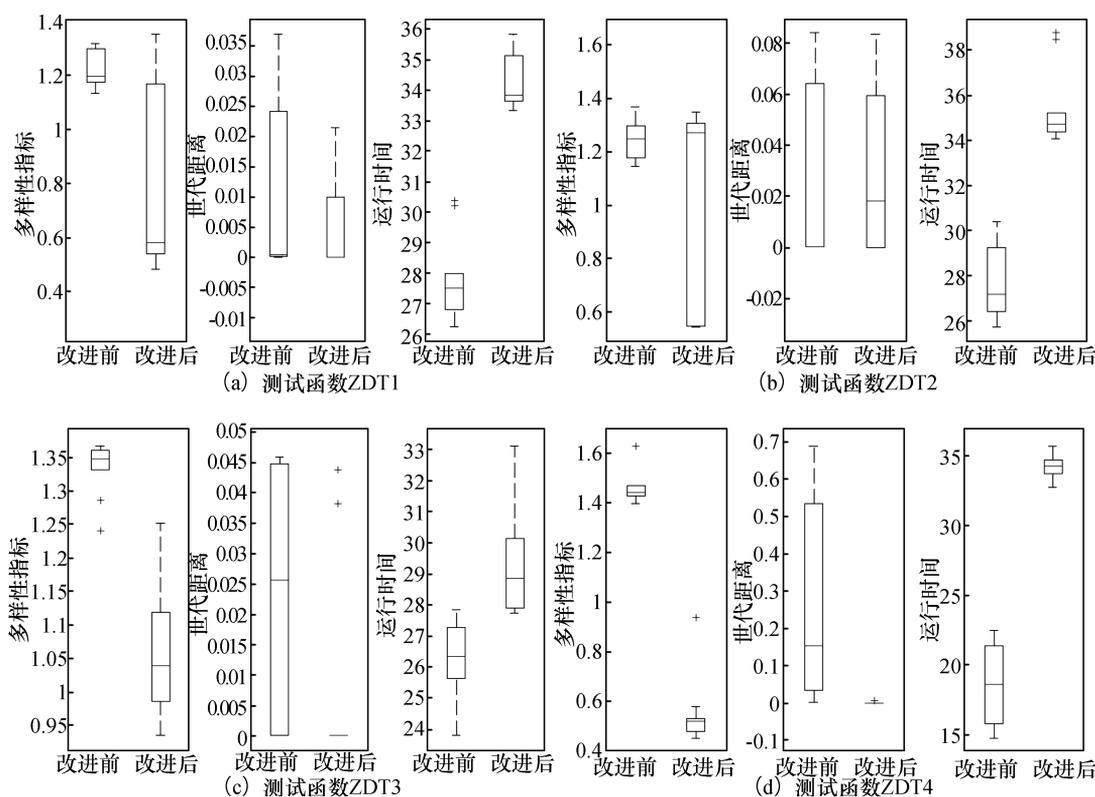


图 4 多目标优化性能评估指标箱线图

Fig.4 Box chart of multi-objective optimization performance evaluation index

5 结 论

为了更好地研究人工蜂群算法求解多目标优化问题,本文在基本多目标人工蜂群算法的基础上引入了自适应搜索操作和变异操作,然后采用几个多目标测试函数对改进算法进行测试,通过引入世代距离、多样性指标验证算法的收敛性和解的多样性,实验结果表明:在对多目标优化问题的求解中,改进后的多目标人工蜂群算法具有较好的收敛性和均匀性。

参考文献:

[1] 肖晓伟,肖迪,林锦国.多目标优化问题的研究概述[J].计算机应用研究,2011,28(3):805-808.
 [2] 江铭炎,袁东风.人工蜂群算法及其应用[M].北京:科学出版社,2014.
 [3] KARABOGA D, AKAY B. A comparative study of Artificial Bee Colony algorithm[J]. Applied Mathematics & Computation, 2009, 214(1): 108-132.
 [4] 肖晓伟,肖迪,林锦国,等.多目标优化问题的研究概述[J].计算机应用研究,2011,28(3):805-808.

[5] 雷德明,严新平.多目标智能优化算法及其应用[M].北京:科学出版社,2009.
 [6] 葛宇,梁静.一种多目标人工蜂群算法[J].计算机科学,2015,42(9):257-262.
 [7] 张长胜.多目标人工蜂群算法及遗传算法的研究与应用[M].沈阳:东北大学出版社,2013.
 [8] HEDAYATZADEH R, HASANIZADEH B, AKBARI R, et al. A multi-objective Artificial Bee Colony for optimizing multi-objective problems[C]. International Conference on Advanced Computer Theory and Engineering. IEEE, 2010: V5-277 -V5-281.
 [9] 葛宇,梁静,王学平,等.改进人工蜂群算法求解多目标连续优化问题[J].计算机科学,2014,41(6):254-259.
 [10] 田野,徐洪华,李福善.一种改进的人工蜂群算法[J].长春理工大学学报(自然科学版),2014,37(5):137-140.
 [11] 胡旺, YEN G G, 张鑫.基于 Pareto 熵的多目标粒子群优化算法[J].软件学报,2014,25(5):1025-1050.
 [12] LUO J, LIU Q, YANG Y, et al. An artificial bee colony algorithm for multi-objective optimisation [J]. Applied Soft Computing, 2017, 50: 235-251.