

基于多策略融合的混合多目标蝗虫优化算法

王 博^{1*}, 刘连生¹, 韩绍程¹, 祝世兴²

(1. 中国民航大学 基础实验中心, 天津 300300; 2. 中国民航大学 航空工程学院, 天津 300300)

(* 通信作者电子邮箱 b-wang@cauc.edu.cn)

摘 要:为提高蝗虫优化算法(GOA)求解多目标问题的性能,提出一种基于多策略融合的混合多目标蝗虫优化算法(HMOGOA)。首先,利用Halton序列建立初始种群,保证种群在初始阶段具有均匀分布和较高多样性;然后,通过差分变异算子引导种群变异,促进种群向优势个体移动同时进行更大范围寻优;最后,利用自适应权重因子根据种群优化情况动态调整算法全局搜索和局部寻优能力,提高优化效率及解集质量。选取7个典型函数进行实验测试,并将HMOGOA与多目标蝗虫优化、多目标粒子群(MOPSO)、基于分解的多目标进化(MOEA/D)及非支配排序遗传算法(NSGA II)对比分析。实验结果表明,该算法避免了其他四种算法的局部最优问题,明显提高了解集分布均匀性和分布广度,具有更好的收敛精度和稳定性。

关键词:多目标优化;蝗虫优化算法;差分变异算子;自适应权重因子;Halton序列

中图分类号:TP183 **文献标志码:**A

Hybrid multi-objective grasshopper optimization algorithm based on fusion of multiple strategies

WANG Bo^{1*}, LIU Liansheng¹, HAN Shaocheng¹, ZHU Shixing²

(1. Basic Experimental Center, Civil Aviation University of China, Tianjin 300300, China;

2. Aviation Engineering Institute, Civil Aviation University of China, Tianjin 300300, China)

Abstract: In order to improve the performance of Grasshopper Optimization Algorithm (GOA) in solving multi-objective problems, a Hybrid Multi-objective Grasshopper Optimization Algorithm (HMOGOA) based on fusion of multiple strategies was proposed. First, the Halton sequence was used to establish the initial population to ensure that the population had a uniform distribution and high diversity in the initial stage. Then, the differential mutation operator was applied to guide the population mutation, so as to promote the population to move to the elite individuals and extend the search range of optimization. Finally, the adaptive weight factor was used to adjust the global exploration ability and local optimization ability of the algorithm dynamically according to the status of population optimization, so as to improve the optimization efficiency and the solution set quality. With seven typical functions selected for experiments and tests, HMOGOA were compared with algorithms such as multi-objective grasshopper optimization, Multi-Objective Particle Swarm Optimization (MOPSO), Multi-Objective Evolutionary Algorithm based on Decomposition (MOEA/D) and Non-dominated Sorting Genetic Algorithm II (NSGA II). Experimental results indicate that compared with the above algorithms, HMOGOA avoids falling into local optimum, makes the distribution of the solution set significantly more uniform and broader, and has greater convergence accuracy and stability.

Key words: multi-objective optimization; Grasshopper Optimization Algorithm (GOA); differential mutation operator; adaptive weight factor; Halton sequence

0 引言

工程实践和科学研究中很多决策及设计问题同时涉及两个或以上的目标,这些问题称为多目标优化(Multi-Objective Optimization, MOO)^[1]。由于MOO问题中各目标函数之间一般存在内在冲突,很难得到使所有目标同时达到最佳状态的解决方案,求解过程中通常需要经过权衡得到一组相互折中的解集^[2]。

近几十年来,国内外学者针对MOO问题开展了大量研究工作,涌现了众多优化算法,主要可以分为两类:基于偏好信息的方法和Pareto最优解法^[3]。第一类优化方法根据每个目标函数的重要性设定权重系数并计算它们的加权和,从而将MOO问题转化为单目标优化问题。此类方法较为简单,但权重系数的选择直接影响最终优化结果,实际应用中权重系数的设定带有一定主观性、随机性,很难得到客观准确的优化结果。第二类优化方法同时对多个子目标优化,通过搜索得到

收稿日期:2020-03-19;**修回日期:**2020-05-11;**录用日期:**2020-05-13。 **基金项目:**中国民用航空局科技项目(MHRD201019);天津市教委科研项目(2018KJ246);中央高校基本科研业务费项目中国民航大学专项(3122017048)。

作者简介:王博(1982—),男,天津人,讲师,硕士,主要研究方向:智能优化算法; 刘连生(1960—),男,甘肃兰州人,教授,硕士,主要研究方向:智能故障诊断、智能优化算法; 韩绍程(1981—),男,天津人,副教授,硕士,CCF会员,主要研究方向:智能优化算法、数字图像处理; 祝世兴(1958—),男,黑龙江青冈人,教授,硕士,主要研究方向:机械设计优化。

一组不存在优劣关系的非支配最优解(即 Pareto 最优解)。该方法能够获得一组较高质量的最优解集,供决策者从中选择最合适的解,相较第一类方法应用更广泛^[4]。

蝗虫优化算法(Grasshopper Optimization Algorithm, GOA)是 Saremi 等^[5]受蝗虫捕食过程中种群行为的启发,在 2016 年提出的一种新型启发式智能优化算法。GOA 简单,计算复杂度较低,具有较高的收敛速度。近年来,为提高 GOA 的性能众多学者做了大量研究工作。Mafarja 等^[6]利用动态种群进化(Evolutionary Population Dynamics, EPD)策略改进了 GOA 的种群选择机制,有效避免了算法过早收敛,提高算法的准确性。Luo 等^[7]提出将高斯变异引入 GOA 以增强局部搜索能力,利用 Levy 飞行策略和反向学习机制(Levy flight and Opposition-Based Learning, LOBL)提高了算法的全局搜索能力和搜索效率。Taher 等^[8]改进了 GOA 的变异机制和种群更新策略,避免了局部最优。Mirjalili 等^[9]于 2017 年首次将 GOA 应用于多目标问题,提出了多目标蝗虫优化算法(Multi-Objective Grasshopper Optimization Algorithm, MOGOA)。黄超等^[10]利用曲线自适应策略调整控制参数,提高算法收敛速度,提出一种求解移动机器人路径规划问题的 MOGOA。目前,多目标蝗虫优化算法由于采用了标准 GOA 的基本框架,继承了蝗虫优化算法在复杂度和收敛速度上的优势,具有较好的应用前景;但由于 GOA 的天然缺陷,限制了其优化性能。首先,由于种群采用优势个体引导的更新机制,易造成群体进化聚集,算法容易陷入局部最优;其次,调整算法搜索能力的重要参数 c 只随迭代次数被动变化,导致算法全局搜索和局部开发的不平衡,降低了收敛效率和解集质量。

针对上述问题,本文提出一种混合多目标蝗虫优化算法(Hybrid Multi-Objective Grasshopper Optimization Algorithm, HMOGOA)。HMOGOA 利用 Halton 序列进行种群初始化,增强了初始种群的多样性以及分布均匀性;由差分变异算子引导种群更新,提高了算法全局搜索能力避免陷入局部最优,改善了解集分布特性;加入自适应权重因子,根据种群优化情况动态调整算法的全局搜索和局部开发能力,提高了算法优化效率和解集质量。采用 ZDT、CEC09 系列函数对算法进行仿真实验,通过与多目标蝗虫优化、多目标粒子群(Multi-Objective Particle Swarm Optimization, MOPSO)、基于分解的多目标进化(Multi-Objective Evolutionary Algorithm based on Decomposition, MOEA/D)、非支配排序遗传(Non-dominated Sorting Genetic Algorithm II, NSGA II)等算法对比,表明 HMOGOA 具有更好的优化性能和稳定性。

1 标准多目标蝗虫优化算法

多目标蝗虫优化算法是一种求解多目标优化问题的 GOA。它模拟了蝗虫的捕食行为,算法中每个搜索个体(即蝗虫个体)的位置代表了问题的一种解决方案。算法通过判断不同解之间的支配关系寻找 Pareto 解,并借助外部档案集存储优化过程中的临时解。其优化过程分为探索和开发两部分。在探索阶段,搜索个体在整个解空间内进行快速随机移动寻找所有可能的解;而在开发阶段,搜索个体根据已有信息对部分区域进行精细搜索寻找最优解^[11]。这恰好与蝗虫在成虫和幼虫时期的运动特点相吻合。蝗虫种群运动的数学模型^[12]为:

$$X_i = S_i + G_i + A_i \quad (1)$$

其中: X_i 是第 i 只蝗虫在种群中的位置, S_i , G_i , A_i 分别代表第 i 只蝗虫受到的种群间社交作用、重力以及风力的影响。种群间的社交作用是影响蝗虫运动的最主要因素,可通过下述公式描述:

$$S_i = \sum_{j=1, j \neq i}^N s(d_{ij}) \hat{d}_{ij} \quad (2)$$

$$\begin{cases} d_{ij} = |x_j - x_i| \\ \hat{d}_{ij} = (x_j - x_i)/d_{ij} \\ s(r) = fe^{(-r/l)} - e^{-r} \end{cases} \quad (3)$$

其中: d_{ij} 为第 i 只与第 j 只蝗虫之间的距离, $\hat{d}_{ij}$ 为第 i 只与第 j 只蝗虫之间的单位向量,函数 $s(r)$ 为蝗虫间的社会作用力。由于重力对蝗虫种群的影响较小可以忽略不计,同时假设风向始终指向最佳个体所处的位置,蝗虫位置的更新模型可表示为:

$$x_i^d(t+1) = c * \left\{ \sum_{j=1, j \neq i}^N c \frac{ub_d - lb_d}{2} s(|x_j^d(t) - x_i^d(t)|) \frac{x_j(t) - x_i(t)}{d_{ij}} \right\} + \hat{T}_d \quad (4)$$

其中: ub_d , lb_d 分别表示蝗虫在 d 维度上的位置上界和下界; $\hat{T}_d$ 表示当前种群中优势引导个体的位置;参数 c 为线性缩减系数,它随着迭代次数增加减小算法全局搜索能力的同时提高局部寻优能力,计算公式如下所示:

$$c = c_{\max} - l \frac{c_{\max} - c_{\min}}{L} \quad (5)$$

标准 MOGOA 流程如图 1 所示。




图1 标准 MOGOA 流程

Fig. 1 Flow chart of standard MOGOA

2 混合多目标蝗虫优化算法

为提高 MOGOA 的性能,需解决两方面问题:1)种群更新过程中,缺少个体间信息的交换,进化容易集中在优势个体的邻域范围内进行,导致算法全局搜索能力下降,算法过早收敛陷入局部最优。2)衰减系数 c 是 GOA 求解 MOO 问题过程中的一个重要参数,它与迭代次数呈线性反比关系,主要限制算法的搜索区域,平衡全局搜索能力和局部寻优能力。优化前期, c 数值较大,促进个体在整个解空间内搜索所有可能的优势解;优化后期,其数值减小,有利于种群在当前解的局部区域寻优,使最优解能够收敛到理想 Pareto 解集。通常 MOO 的优化过程并不随迭代次数线性变化,应当根据种群进化过程合理控制算法的搜索能力。

因此,本文从提高初始种群质量降低种群进化聚集的概率,加强进化过程中个体信息交换,提高种群多样性,根据种群进化状态平衡算法全局搜索和局部开发能力3个方面,提高 MOGOA 的优化性能,提出一种混合多目标蝗虫优化算法。

2.1 基于Halton序列初始化

算法初始阶段蝗虫种群的位置随机产生,极易出现种群分布不均的情况,造成搜索个体的初始位置集中于局部极值点附近,导致算法陷入局部最优。Halton序列是一种低差异化序列,能够生成在搜索空间内均匀分布的点集^[13]。由随机法和Halton序列生成的一组二维个体分布情况如图2所示。图2(a)、(b)分别为使用两种方法生成个体的散点分布图,图2(c)、(d)为个体数量的分布直方图。通过对比可见,相较于随机方法Halton序列产生的个体在二维空间上分布更均匀,没有聚集情况,同时处于不同数值区间的个体数量更平均,表明Halton序列能够生成分布均匀性更好的个体。为此,本文采用Halton序列初始化种群,提高初始种群质量有效避免局部最优。




图2 随机法与Halton序列生成个体的分布情况

Fig. 2 Distribution of individuals generated by random method and Halton sequence

通常一个 M 维的 Halton 序列可表示为 $H_M(n) = \{H_{p_1}(n), H_{p_2}(n), \dots, H_{p_M}(n)\} (n=1, 2, \dots, N)$ 。 $H_{p_i}(n)$ 是一维 Halton 序列,它是一个长度为 N 的序列,定义^[14]如下:

$$H_{p_i}(n) = \{\phi_{p_i}(n)\}; n = 1, 2, \dots, N \quad (6)$$

其中 p_i 为质数, $\phi_{p_i}(n)$ 是关于 p_i 的基逆函数,可表示为:

$$\phi_{p_i}(n) \equiv b_0/p_i + b_1/p_i^2 + \dots + b_k/p_i^{k+1} \quad (7)$$

假设 $X=(x_{ij})$ 是一个 $M \times N$ 维的蝗虫种群, x_{ij} 为种群中的个体,它的位置范围是 $[x_{\min}, x_{\max}]$, h_{ij} 是通过 Halton 序列生成的随机数,则该种群个体的初始位置为:

$$x_{ij}(0) = x_{\min} + h_{ij}(x_{\max} - x_{\min}) \quad (8)$$

2.2 基于差分变异算子的种群更新策略

MOO 需要在优化过程中不断寻找所有非支配解,组成非支配解集。由于多目标问题的解空间由多个分段连续区域组成,为使解集能够逼近真实 Pareto 最优前沿且分布更均匀,优化过程中搜索个体在决策空间中的搜索方向应指向真实 Pareto 前沿,且可以在平行于真实 Pareto 前沿的流行区域移动^[15-16]。图3反映了 MOGOA 优化过程中种群进化趋势。图中以 ZDT1 为目标函数,由 10 个初始父代解利用 MOGOA 产生 1 000 个新的子代解。可以明显看出搜索个体由优势个体引导沿不同轨迹向着目标位置移动,最终聚集到真实 Pareto 前沿的部分区域,表明 MOGOA 的种群更新策略易使算法陷入局部最优。针对该问题,在单目标蝗虫优化算法中,文献[6]中采取了动态种群进化策略,文献[7]中利用了 Levy 飞行和

反向学习策略改进个体的更新机制^[2]。分别将 EPD 和 LOBL 策略应用于多目标蝗虫优化算法,以 ZDT1 为测试函数,由图3中的 10 个父代解出发,产生 1 000 个子代解,得到的种群进化情况如图4、5所示。图4中 EPD 策略一定程度扩大了搜索个体在进化过程中的寻优范围,但依然无法避免解聚集;而图5中 LOBL 策略虽然增强了算法的全局搜索能力,但种群搜索范围过大影响了算法的收敛性能。由此说明,EPD 和 LOBL 策略对 MOGOA 性能的改善有限。




图3 MOGOA进化示意图

Fig. 3 Schematic diagram of MOGOA evolution




图4 基于EPD的MOGOA进化示意图

Fig. 4 Schematic diagram of MOGOA evolution based on EPD




图5 基于LOBL的MOGOA进化示意图

Fig. 5 Schematic diagram of MOGOA evolution based on LOBL

由于差分算子有利于种群间信息交换,促进全局探索,改善种群分布和收敛精度,因此本文提出一种基于差分变异算子的种群更新策略。差分变异算子及个体更新公式如下:

$$\begin{aligned} \hat{V}_i(t) = & \alpha_0(r * X_{s_i}(t) + (1-r) * ((X_{s_i}(t) - X_{c1'}(t)) + \\ & (X_{s_i}(t) - X_{c2'}(t)))) + \alpha_1 * X_{r_i}(t) \end{aligned} \quad (9)$$

$$x_i^d(t+1) = c^* \left\{ \sum_{j=1, j \neq i}^N c \frac{ub_d - lb_d}{2} s \left(\left| x_j^d(t) - x_i^d(t) \right| \right) \frac{x_j(t) - x_i(t)}{d_{ij}} \right\} + \hat{V}_i(t) \quad (10)$$

式(9)中, α_0, α_1 为缩放系数 ($\alpha_0, \alpha_1 \in (0, 2]$), r 为 $(0, 1)$ 内的随机数, $X_{s_i}(t)$ 表示以较大概率在解集稀疏区域选取的个体, $X_{c_i}(t), X_{c_2}(t)$ 表示以较大概率在解集密集区域选取的个体, $X_{s_i}(t)$ 表示由当前解集随机选取的个体, 上述4个种群个体互不相同。 $X_{s_i}(t), X_{c_1}(t), X_{c_2}(t)$ 组成的差分算子实现了种群个体间优势信息的交换, 能够提高算法的全局寻优能力, 有助于算法跳出局部最优, 改善收敛精度。而随机个体 $X_{r_i}(t)$ 可以增加变异的随机性, 避免过早收敛。为验证差分变异算子对MOGOA的改善作用, 同样选取图3中的父代解作为初始解, 以ZDT1为目标函数, 利用基于差分变异算子的MOGOA生成1000个子代解, 进化结果如图6所示。由图中可见, 差分变异算子能够引导种群在父代解构成的带状区域变异, 可以改善解空间的整体分布性能。




图6 基于差分变异算子的MOGOA进化示意图

Fig. 6 Schematic diagram of MOGOA evolution based on differential evolution operators

对于当前种群 $\{X_i(t)\} (i=1, 2, \dots, N)$ 中个体 $X_i(t)$, 基于差分变异算子的种群更新具体方法如下:

首先, 针对当前 Pareto 解集 $P_c^* = \{X_i^*(t) | i=1, 2, \dots, N_s\}$, 利用 Deb 提出的方法计算全部解的拥挤距离 $d_i^c (i=1, 2, \dots, N_s)$ [17]。由拥挤距离衡量解集分布密度, d_i^c 的数值越小说明解分布的越密集, 反之分布较稀疏。

然后, 分别根据式(11)和式(12)计算解集 P_c^* 中每个种群个体的密集选中概率 p_i^d 及稀疏选中概率 p_i^s 。当概率为 p_i^d 时能够以较大概率选择解空间内分布密集区域的个体, 而概率为 p_i^s 时则以较大概率稀疏区域的个体。先以概率 p_i^d 从 P_c^* 选出优势个体 $X_{c_1}(t), X_{c_2}(t)$, 同时以概率 p_i^s 选取个体 $X_{s_i}(t)$, 再随机从 P_c^* 中选出个体 $X_{r_i}(t)$ 。

$$p_i^d = 1/d_i^c; \quad i = 1, 2, \dots, N_s \quad (11)$$

$$p_i^s = d_i^c / \sum_{j=1}^{n_p} d_j^c; \quad i = 1, 2, \dots, N_s \quad (12)$$

最后, 根据式(9)计算差分变异算子 $\hat{V}_i(t)$, 并完成个体 $X_i(t)$ 的更新操作。

2.3 自适应权重因子

多目标问题的优化是一个复杂的过程具有随机性, MOGOA 求解过程中 c 是一个开环参数, 单纯通过它无法有效平衡全局搜索和局部寻优能力 [18]。根据种群进化状态调节参数 c 的衰减速度, 实现闭环控制, 有助于提高种群的搜索效率

和收敛精度。通常种群进化过程中个体的分布特性是影响算法性能的一个重要因素 [19]。本文以群体分布均匀性和分散广度作为进化过程反馈信息, 提出种群进化状态动态评价指标 (Evolution State Metric, ESM)。ESM 定义如下:

$$Q_{\text{ESM}} = \sqrt{\frac{1}{N_s - 1} \sum_{i=1}^{N_s-1} (d_i' - \bar{d}')^2} + \sum_{m=1}^M d(P_c^*, P_m^{\max}) \quad (13)$$

其中: N_s 为当前解的数量, M 为目标函数的数量, d_i' 表示当前 Pareto 解集中相邻解的欧氏距离, $\bar{d}'$ 表示 d_i' 的平均值, $P_m^{\max}$ 表示理想 Pareto 解集中使第 m 个目标函数取得最大值的解 (即理想解空间第 m 维上的极值解), $d(P_c^*, P_m^{\max})$ 表示当前解集与理想解空间第 m 维上极值解的最短距离。式(13)中第一项表示当前解集相邻解之间距离的标准差, 体现了解集分布的均匀度, 数值越小解集分布越均匀; 第二项表示当前解集与理想解空间各维度上极值点的最短距离之和, 体现了解集分布的广度, 其值越小说明解集分布范围越广。图7所示为MOGOA针对目标函数ZDT4运行三次得到的ESM数值随迭代次数变化曲线。可以看出ESM是波动变化的, 算法每次运行过程中其变化幅度与趋势不同, 说明种群进化状态具有非线性和不确定性, 根据进化过程调节算法搜索能力有助于提高算法性能。因此, 本文建立基于ESM的自适应权重因子 w_a , 在种群更新公式中加入自适应权重因子, 通过权重因子调整参数 c 的衰减速度平衡算法的全局搜索和局部寻优能力。

自适应权重因子 w_a 和种群个体更新公式如下:

$$w_a = 1 + 0.1 * \left(1 + e^{-\left(Q_{\text{ESM}} / 1000 \right)^2} \right)^{-1} \quad (14)$$

$$x_i^d(t+1) = w_a * c^*$$

$$\left\{ \sum_{j=1, j \neq i}^N c \frac{ub_d - lb_d}{2} s \left(\left| x_j^d(t) - x_i^d(t) \right| \right) \frac{x_j(t) - x_i(t)}{d_{ij}} \right\} + \hat{V}_i(t) \quad (15)$$

其中, w_a 数值根据种群进化状态变化。种群进化状态不佳时 ESM 数值较大, 说明解分布较集中、均匀性不好, 此时 w_a 数值增加大可减缓 c 的衰减速度, 促进搜索个体在更大区域寻找新解; 反之 ESM 数值较小, 说明搜索个体在目标空间内分布均匀且分布范围广, w_a 数值减小, 可以促进算法局部寻优, 提高收敛精度和收敛速度。实现了根据算法寻优过程动态调整全局搜索和局部开发能力, 提高了算法的优化效率, 有效改善了 Pareto 最优解集的质量。




图7 ESM变化曲线

Fig. 7 Variation curve of ESM

2.4 混合多目标蝗虫优化算法的流程

混合多目标蝗虫优化算法的伪代码流程如下:

- 1) 初始化相关参数: 种群规模 N , 外部档案集规模 N_A , 迭代次数 $t=1$, 最大迭代次数 $T_{\max}$, 参数 c 的最大值 $c_{\max}$ 、最小值 $c_{\min}$;
- 2) 利用 Halton 序列产生初始种群 P , 并建立一个空的外部档案集 PA ;

- 3) 计算 P 中所有个体的适应度值, 寻找非支配解并存储在 PA 中;
- 4) while $t < T_{\max}$ do
- 5) for $i = 1$ to N do
- 6) 根据式(5)、式(14)更新参数 c 和自适应权重因子 w_a ;
- 7) 根据 2.2 节所述方法由 PA 中选取个体 $X_{s_i}(t)$ 、 $X_{c1}(t)$ 、 $X_{c2}(t)$ 、 $X_{r_i}(t)$, 依据式(9)计算差分变异算子 $\hat{V}_i(t)$, 根据式(15)更新种群个体位置;
- 8) end for
- 9) 计算所有个体的适应度值, 寻找非支配解并更新 PA ;
- 10) if $|PA| > N_A$
- 11) 在 PA 解分布密集区域随机删除 $(|PA| - N_A)$ 个解;
- 12) end if
- 13) $t = t + 1$;
- 14) end while
- 15) 输出 PA 即 Pareto 最优解集。

3 实验及分析

3.1 测试问题及实验设置

本文为验证 HMOGOA 的性能, 以 MOGOA、MOPSO、MOEA/D 及 NSGA II 作为对比算法, 选取 ZDT、CEC2009 系列测试函数集中的两目标函数(ZDT1、ZDT2、ZDT3、ZDT4)和三目标函数(UF8、UF9、UF10), 使用软件 Matlab2016a 进行仿真实验测试。

实验过程中, 所有算法的相关参数均设置一致以保证公平性: 种群规模 $N=100$, 外部档案集规模 $N_A=100$, 迭代次数 $T_{\max}=100$ 。HMOGOA、MOGOA 参数 c 的取值范围均设置为: $c_{\max}=1$, $c_{\min}=0.0005$ 。其他算法参数设置如下: MOPSO 算法惯性权重因子 $w=0.5$, 个体学习因子 $c_1=2$, 社会学习因子 $c_2=2$, 变异率 $p_m=0.1$; MOEA/D 算法邻域大小 $T=15$, 交叉概率 $p_c=0.5$; NSGA II 算法交叉概率 $p_c=0.7$, 变异概率 $p_m=0.02$ 。为避免随机误差对测试结果的影响, 针对每个测试函数所有算法均运行 30 次。

3.2 性能指标

为分析比较不同优化算法的性能, 选取两种评价指标来量化分析算法的性能。具体性能指标^[20]如下:

1) 反世代距离 (Inverted Generational Distance, IGD)。IGD 反映了算法求得的 Pareto 解集 P 与真实 Pareto 前沿之间的距离, 它是评价算法收敛性的指标。其值越小说明所求解越逼近真实 Pareto 前沿, 表明算法的收敛性越好, 解的精度越高。IGD 定义如下:

$$IGD = \frac{1}{N_P} \sqrt{\sum_{i=1}^{N_P} d_i^{TP2}} \quad (16)$$

其中, N_P 为真实 Pareto 前沿中解的数量, d_i^{TP} 为真实 Pareto 前沿中的第 i 个解与解集 P 间的最短欧氏距离。

2) 分布度量指标 (Δ)。 Δ 体现了所求 Pareto 最优前沿相对真实前沿的分布广度及均匀度, 它是评价 Pareto 解分布特性的指标。 Δ 数值越小说明解的多样性越高、分布范围越广、分布均匀度越好, 非支配解能够更好地覆盖整个真实 Pareto 解集。 Δ 的定义如下:

$$\Delta = \frac{d_f + d_l + \sum_{i=1}^{N_p-1} |d_i - \bar{d}|}{d_f + d_l + (N_p - 1)\bar{d}} \quad (17)$$

其中: N_p 为所求解的个数, d_i 为 Pareto 前沿中相邻点间的距离, $\bar{d}$ 为 d_i 的平均值, d_f 、 d_l 为 Pareto 最优前沿与真实前沿边界点之间的最短距离。

3.3 实验结果及分析

五种算法针对多目标问题测试所得各项性能指标的均值 (Mean) 和方差 (Var) 如表 1、2 所示, 同一测试问题中的最优数值加粗显示。

表 1 IGD 实验结果

Tab. 1 Results of IGD

测试函数	统计量	算法				
		HMOGOA	MOGOA	MOPSO	MOEA/D	NSGA II
ZDT1	Mean	6.79E-05	1.17E-03	2.62E-04	5.30E-04	1.82E-03
	Var	4.81E-11	1.13E-07	2.41E-09	3.26E-08	2.38E-07
ZDT2	Mean	6.44E-05	2.09E-03	2.82E-04	8.72E-03	2.47E-03
	Var	1.13E-10	2.64E-06	1.09E-09	6.17E-05	1.08E-06
ZDT3	Mean	2.12E-03	2.59E-03	5.64E-03	7.07E-03	2.88E-02
	Var	1.61E-10	7.67E-07	1.16E-06	5.62E-07	1.84E-07
ZDT4	Mean	6.06E-05	1.03E-02	1.89E-02	7.44E-03	5.63E-03
	Var	3.06E-11	3.42E-05	3.87E-05	9.28E-05	4.63E-06
UF8	Mean	1.74E-03	3.35E-03	2.78E-03	3.66E-03	2.93E-03
	Var	8.55E-09	4.37E-07	1.20E-07	5.55E-06	2.75E-07
UF9	Mean	2.21E-03	3.38E-03	2.03E-03	2.42E-03	2.72E-03
	Var	1.04E-08	2.97E-07	3.86E-07	2.29E-06	1.98E-06
UF10	Mean	2.71E-03	5.20E-03	4.15E-03	1.04E-02	4.80E-03
	Var	9.21E-08	7.51E-03	1.68E-05	2.19E-05	1.55E-06

表 2 Δ 实验结果

Tab. 2 Results of Δ

测试函数	统计量	算法				
		HMOGOA	MOGOA	MOPSO	MOEA/D	NSGA II
ZDT1	Mean	5.64E-01	1.06E+00	8.24E-01	1.06E+00	9.03E-01
	Var	1.54E-03	2.27E-02	8.22E-03	2.06E-03	6.52E-02
ZDT2	Mean	5.67E-01	1.08E+00	9.69E-01	1.08E+00	1.05E+00
	Var	1.11E-03	1.29E-02	9.26E-02	4.80E-03	6.08E-02
ZDT3	Mean	8.03E-01	1.14E+00	1.11E+00	1.33E+00	8.53E-01
	Var	5.27E-04	1.02E-02	3.05E-02	8.22E-03	1.01E-03
ZDT4	Mean	6.02E-01	1.08E+00	1.06E+00	1.08E+00	1.22E+00
	Var	2.29E-03	4.08E-03	5.17E-02	3.38E-03	5.85E-02
UF8	Mean	6.82E-01	1.40E+00	7.76E-01	1.21E+00	1.26E+00
	Var	2.72E-03	3.46E-03	2.39E-02	7.48E-03	3.51E-02
UF9	Mean	7.32E-01	1.36E+00	9.06E-01	1.14E+00	9.02E-01
	Var	5.88E-03	6.29E-03	1.34E-02	1.57E-02	4.28E-03
UF10	Mean	7.50E-01	1.28E+00	8.02E-01	1.25E+00	1.29E+00
	Var	4.02E-03	7.51E-03	1.33E-01	2.00E-02	5.02E-02

由表 1 可见, 相较于 MOPSO、MOEA/D、NSGA II 算法, HMOGOA 的 IGD 数值在大部分测试函数上明显优于此三种算法, 只是在函数 UF9 上稍差于 MOPSO, 但数值相近且明显优于其他两种算法, 表明 HMOGOA 的收敛性优于此三种算法。而对于 MOGOA, HMOGOA 的收敛性能和收敛稳定性在全部测试问题上都体现出了明显优势。由此说明 HMOGOA 采取的基于差分变异算子的更新策略有助于引导种群向理想解空间中目标个体位置移动。

通过表 2 对比分析五种算法的分布性能指标可以看出, 由于 HMOGOA 在进化初期提高了初始种群分布性, 避免了算法前期陷入局部最优; 差分变异算子能够提高全局搜索能力, 改善解集分布特性; 同时采用自适应权重因子平衡全局和局部寻优能力, 提高了最优解集的质量。因此, HMOGOA 在所有测试问题上的分布性能均明显优于其他算法。

图 8 所示为 HMOGOA、MOGOA、MOPSO、MOEA/D 的 Pareto 最优前沿分布图。通过图 8 可以看出, 对于函数 ZDT3, HMOGOA 求得的解相较其他三种算法能均匀分布在函数的 4

个波谷上,收敛精度更好。对于函数ZDT1、ZDT2,HMOGOA与其他算法相比能更均匀分布在真实Pareto前沿面上。

而对于三目标问题,HMOGOA求得解的数量更多,能够较好地逼近真实Pareto前沿,且分布更均匀。




图8 各算法对部分函数的Pareto前沿对比

Fig. 8 Comparison of Pareto optimal front for some benchmark functions obtained by various algorithms

为进一步比较HMOGOA与其他算法性能之间的显著优势,本文利用Wilcoxon秩和检验按照显著性水平 $\alpha=0.05$,将HMOGOA分别与其他四种算法进行对比分析。分析结果如表3所示,“+”“-”“ $\approx$ ”分别表示HMOGOA的性能指标明显优于、劣于或近似于对比算法。由表3可以看出,HMOGOA的IGD、 Δ 指标在大部分测试函数上,相较于MOGOA、MOPSO、MOEA/D、NSGA II具有明显优势,只是在个别测试函数上近似于MOPSO、MOEA/D。通过上述实验分析可知,本文提出的HMOGOA性能明显优于MOGOA,算法具有较高的收敛精度和较好的分布性能,且稳定性较高。

表3 Wilcoxon秩和检验结果

Tab. 3 Results of Wilcoxon rank-sum test

指标	对比算法	测试函数						
		ZDT1	ZDT2	ZDT3	ZDT4	UF8	UF9	UF10
IGD	MOGOA	+	+	+	+	+	+	+
	MOPSO	+	+	+	+	+	$\approx$	+
	MOEA/D	+	+	+	+	+	$\approx$	+
	NSGA II	+	+	+	+	+	+	+
Δ	MOGOA	+	+	+	+	+	+	+
	MOPSO	+	+	+	+	+	+	$\approx$
	MOEA/D	+	+	+	+	+	+	+
	NSGA II	+	+	+	+	+	+	+

4 结语

本文为提高 MOGOA 的优化性能,提出一种混合多目标蝗虫优化算法。该算法利用 Halton 序列初始化种群,使初始种群具有较好的多样性和分布特性,减小了算法过早收敛的概率;设计基于差分变异算子的种群更新机制,促进种群向优势个体移动的同时进行更大范围寻优,实现种群间优势个体的信息交换,提高了算法的全局寻优能力,有效避免算法陷入局部最优,提升了解集的分布特性,改善了收敛精度;引入自适应权重因子,根据种群进化状态反馈信息动态调整算法的全局搜索和局部开发能力,实现算法寻优能力的闭环精细控制,提高了算法的优化效率和最优解集质量。通过与四种多目标优化算法的对比实验表明, HMOGOA 的性能相较于 MOGOA 有明显提升,算法具有较好的收敛精度、分布广度、分布均匀性和稳定性。下一步研究的主要内容是算法对于求解高维多目标优化问题的性能。

参考文献(References)

- [1] 谢承旺,许雷,赵怀瑞,等. 应用精英反向学习的多目标烟花爆炸算法[J]. 电子学报, 2016, 44(5): 1180-1188. (XIE C W, XU L, ZHAO H R, et al. Multi-objective fireworks optimization algorithm using elite opposition-based learning [J]. Acta Electronica Sinica, 2016, 44(5): 1180-1188.)
- [2] MIRJALILI S, JANGIR P, MIRJALILI S Z, et al. Optimization of problems with multiple objectives using the multi-verse optimization algorithm[J]. Knowledge-Based Systems, 2017, 134: 50-71.
- [3] SEIFOLLAHI-AGHMIUNI S, BOZORG-HADDAD O. Multi objective optimization with a new evolutionary algorithm[J]. Water Resources Management, 2018, 32: 4013-4030.
- [4] DEB K. Multi-objective optimisation using evolutionary algorithms: an introduction [M]// TUTUM C, HATTEL J H. Multi-objective Evolutionary Optimisation for Product Design and Manufacturing. London: Springer, 2011: 3-34.
- [5] SAREMI S, MIRJALILI S, LEWIS A. Grasshopper optimisation algorithm theory and application [J]. Advances in Engineering Software, 2017, 105: 30-47.
- [6] MAFARJA M, ALJARAHA L, HEIDARI A A, et al. Evolutionary population dynamics and grasshopper optimization approaches for feature selection problems [J]. Knowledge-Based Systems, 2018, 145: 25-45.
- [7] LUO J, CHEN H, ZHANG Q, et al. An improved grasshopper optimization algorithm with application to financial stress prediction [J]. Applied Mathematical Modelling, 2018, 64: 654-668.
- [8] TAHER M A, KAMEL S, JURADO F, et al. Modified grasshopper optimization framework for optimal power flow solution [J]. Electrical Engineering, 2019, 101: 121-148.
- [9] MIRJALILI S Z, MIRJALILI S, SAREMI S, et al. Grasshopper optimization algorithm for multi-objective optimization problems [J]. Applied Intelligence, 2018, 48: 805-820.
- [10] 黄超,梁圣涛,张毅,等. 基于多目标蝗虫优化算法的移动机器人路径规划[J]. 计算机应用, 2019, 39(10): 2859-2864. (HUANG C, LIANG S T, ZHANG Y, et al. Path planning of mobile robot based on multi-objective grasshopper optimization algorithm [J]. Journal of Computer Applications, 2019, 39(10): 2859-2864.)
- [11] NEVE A G, KAKANDIKAR G M, KULKARNI O. Application of grasshopper optimization algorithm for constrained and unconstrained test functions [J]. International Journal of Swarm Intelligence and Evolutionary Computation, 2017, 6(3): 1-7.
- [12] EWEES A A, ELAZIZC M A, HOUSSEIN E H. Improved grasshopper optimization algorithm using opposition-based learning [J]. Expert Systems with Applications, 2018, 112: 156-172.
- [13] 张翔宇,董增川,马红亮. 基于改进多目标遗传算法的小浪底水库优化调度研究[J]. 水电能源科学, 2017, 35(1): 65-68. (ZHANG X Y, DONG Z C, MA H L. Study on optimization operation of xiaolangdi reservoir based on improved multi-objective genetic algorithm [J]. Water Resources and Power, 2017, 35(1): 65-68.)
- [14] WEERASINGHE G, CHI H M, CAO Y Z. Particle swarm optimization simulation via optimal halton sequences [J]. Procedia Computer Science, 2016, 80: 772-781.
- [15] 戚玉涛,刘芳,常伟远,等. 求解多目标问题的 Memetic 免疫优化算法[J]. 软件学报, 2013, 24(7): 1529-1544. (QI Y T, LIU F, CHANG W Y, et al. Memetic immune algorithm for multiobjective optimization [J]. Journal of Software, 2013, 24(7): 1529-1544.)
- [16] QIU X, XU J X, TAN K C, et al. Adaptive cross-generation differential evolution operators for multiobjective optimization [J]. IEEE Transactions on Evolutionary Computation, 2016, 20(2): 232-244.
- [17] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm: NSGA- II [J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.
- [18] ARORA S, ANAND P. Chaotic grasshopper optimization algorithm for global optimization [J]. Neural Computing and Applications, 2019, 31: 4385-4405.
- [19] 耿焕同,陈哲,陈正鹏,等. 一种基于群体分布特征的自适应多目标粒子群优化算法[J]. 控制与决策, 2017, 32(8): 1386-1394. (GENG H T, CHEN Z, CHEN Z P, et al. A self-adaptive multi-objective particle swarm optimization algorithm based on swarm distribution characteristic [J]. Control and Decision, 2017, 32(8): 1386-1394.)
- [20] JIANG S W, ONG Y S, ZHANG J, et al. Consistencies and contradictions of performance metrics in multiobjective optimization [J]. IEEE Transactions on Cybernetics, 2014, 44(12): 2391-2404.

This work was partially supported by the Science and Technology Project of Civil Aviation Administration of China (MHRD201019); the Science and Technology Project of Tianjin Education Department (2018KJ246); the Fundamental Research Funds for the Central Universities of CAUC(3122017048).

WANG Bo, born in 1982, M. S., lecturer. His research interests include intelligent optimization algorithm.

LIU Liansheng, born in 1960, M. S., professor. His research interests include intelligent fault diagnosis, intelligent optimization algorithm.

HAN Shaocheng, born in 1981, M. S., associate professor. His research interests include intelligent optimization algorithm, digital image processing.

ZHU Shixing, born in 1958, M. S., professor. His research interests include mechanical design optimization.