



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



自适应分组和拥挤距离更新的多目标狼群算法

赵嘉, 吕丰, 肖人彬, 樊棠怀, 董文飞, 王晖

引用本文:

赵嘉, 吕丰, 肖人彬, 樊棠怀, 董文飞, 王晖. 自适应分组和拥挤距离更新的多目标狼群算法[J]. *控制与决策*, 2024, 39(11): 3772–3780.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.1121>

您可能感兴趣的其他文章

Articles you may be interested in

基于改进多目标优化算法的分布式数据中心负载调度

Multi-objective optimization of energy and performance management in distributed data centers

控制与决策. 2021, 36(1): 159–165 <https://doi.org/10.13195/j.kzyjc.2019.0702>

自适应Jaya算法求解多目标柔性车间绿色调度问题

Multi-objective flexible job shop green scheduling problem with self-adaptive Jaya algorithm

控制与决策. 2021, 36(7): 1714–1722 <https://doi.org/10.13195/j.kzyjc.2019.1773>

一种求解约束多目标问题的协作进化算法

A collaborative evolutionary algorithm for solving constrained multi-objective problems

控制与决策. 2021, 36(11): 2656–2664 <https://doi.org/10.13195/j.kzyjc.2020.0791>

基于自适应正态云模型的灰狼优化算法

Grey wolf optimization algorithm based on adaptive normal cloud model

控制与决策. 2021, 36(10): 2562–2568 <https://doi.org/10.13195/j.kzyjc.2020.0233>

基于多种群分解预测的动态多目标引力搜索算法

Dynamic multi-objective gravitational searching algorithm based on multi-population decomposition prediction

控制与决策. 2021, 36(12): 2910–2918 <https://doi.org/10.13195/j.kzyjc.2020.1002>

自适应分组和拥挤距离更新的多目标狼群算法

赵嘉^{1,2†}, 吕丰^{1,2}, 肖人彬³, 樊棠怀^{1,2}, 董文飞^{1,2}, 王晖^{1,2}

(1. 南昌工程学院 信息工程学院, 南昌 330000; 2. 南昌工程学院 南昌市智慧城市物联感知与协同计算重点实验室, 南昌 330099; 3. 华中科技大学 人工智能与自动化学院, 武汉 430074)

摘要: 鉴于狼群算法在单目标优化问题中具有良好的求解能力, 借助狼群的生物习性并用于求解多目标优化问题, 提出自适应分组和拥挤距离更新的多目标狼群算法(MOWPA-AG)。首先, 模拟狼群中的家族聚集性, 提出兼顾种群多样性和分散搜索的自适应分组策略, 对种群进行分层并帮助种群扩散检索 Pareto 最优解; 然后, 设计基于拥挤距离的群体更新机制, 使种群保持快速进化的同时获得最优解集; 为验证算法的性能, 在 9 种不同的基准测试问题上进行测试, 并与经典及新进多目标优化算法进行比较以验证 MOWPA-AG 的有效性; 最后, 将 MOWPA-AG 用于解决实际工程四杆桁架结构问题, 以体现所提出算法的普适性。

关键词: 群智能算法; 多目标优化; 狼群算法; Pareto 最优; 自适应分组; 工程优化

中图分类号: TP18 文献标志码: A

DOI: 10.13195/j.kzyjc.2023.1121

引用格式: 赵嘉, 吕丰, 肖人彬, 等. 自适应分组和拥挤距离更新的多目标狼群算法[J]. 控制与决策, 2024, 39(11): 3772-3780.

Multi-objective wolf pack algorithm based on adaptive grouping strategy and crowding distance

ZHAO Jia^{1,2†}, LV Feng^{1,2}, XIAO Ren-bin³, FAN Tang-huai^{1,2}, DONG Wen-fei^{1,2}, WANG Hui^{1,2}

(1. School of Information Engineering, Nanchang Institute of Technology, Nanchang 330000, China; 2. Nanchang Key Laboratory of IoT Perception and Collaborative Computing for Smart City, Nanchang Institute of Technology, Nanchang 330099, China; 3. School of Artificial Intelligence and Automation, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: In view of the wolf pack algorithm has good solving ability in single objective optimization problems, a multi-objective wolf pack algorithm(MOWPA-AG) based on adaptive grouping and updating of crowded distance is proposed by taking the advantages of the wolf pack biological habit and being used to solve multi-objective optimization problems. Firstly, an adaptive grouping strategy considering population diversity and dispersed search is proposed to simulate family aggregation in wolf packs. The strategy stratifies populations, separates populations and helps population diffusion search Pareto optimal solutions. Then, a population renewal mechanism based on crowding distance is designed, which enables the population to maintain rapid evolution while obtaining the optimal solution set. In order to verify the performance of the proposed algorithm, nine different benchmark testing problems are tested, and the effectiveness of the proposed algorithm is verified by comparing with other classic and recent multi-objective optimization algorithms. Finally, the MOWPA-AG is applied to solve the problem of four-bar truss structure in practical engineering, which shows the universality of the proposed algorithm.

Keywords: swarm intelligence algorithm; multi-objective optimization; wolf pack algorithm; Pareto optimal; adaptive grouping; engineering optimization

0 引言

现实生活中存在许多需要同时优化多个目标的问题, 且各优化目标之间往往相互制约、相互冲突。如车辆路径问题中有最短的行驶路径与最少的用

车数量^[1], 聚类问题中有最大的类内紧密度和最小的类间紧密度^[2-3], 模式挖掘问题要求寻找最频繁且最完整的模式^[4]等。将这类问题称为多目标优化问题(multi-objective optimization problem, MOP)^[5]。鉴

收稿日期: 2023-08-07; 录用日期: 2024-02-14.

基金项目: 创新科技 2030-“新一代人工智能”重大项目(2018AAA0101200); 国家自然科学基金项目(52069014).

责任编辑: 巩敦卫.

†通讯作者. E-mail: zhaojia925@163.com.

于其普遍存在于实际应用和科学研究中,研究求解MOP具有重要的现实意义.而模仿生物群体行为的群智能算法作为人工智能领域的研究热点,因其有着独特的自组织性和稳健性等特点,被认为是解决多目标优化问题的普遍方法.

狼群算法(wolf pack algorithm, WPA)是吴虎胜等^[6]在2013年提出的一种新兴群智能算法,算法模拟狼群协同捕猎的过程,利用角色分工与交互更好地探索解空间,使其能够以较大的概率快速找到一个最优解.算法提出的时间不长,但相较于其他仿生智能算法,狼群算法具有全局搜索能力强、适应性强、收敛速度快等优势,现已广泛应用于工业智能^[7]、机器学习^[8]、智能控制^[9]等多个领域.

目前,标准狼群算法并不能直接用于求解多目标优化问题,为此许多学者研究算法的改进方案,旨在能够有效应用到多目标问题.如荀洪凯等^[10]设计了多目标启发式狼群算法,由于该算法融入了编码解码模式,仅适用于离散多目标优化问题.李小川等^[11]将多目标问题转化为单目标问题后用狼群算法解决,为狼群算法解决多目标问题提供了一种新的思路.针对微电网系统的多目标优化调度,马文等^[12]将非支配排序和个体密度引入狼群算法,提出基于个体密度的多目标狼群算法.上述算法给出了狼群算法应用于多目标优化问题的解决方案,取得了较好的应用效果,但所提算法不适用于连续优化问题,且算法的策略设计未充分考虑狼群的生物习性,增加了算法的理解难度,同时优化效果有待进一步提升.

为此,本文借助狼群的生物习性,提出一种自适应分组和拥挤距离更新的多目标狼群算法(multi-objective wolf pack algorithm based on adaptive grouping strategy and crowding distance, MOWPA-AG).MOWPA-AG具有如下特点:1)提出自适应分组策略,该策略基于狼群中的家族聚集性,一方面通过对种群分层维护种群多样性,另一方面帮助种群扩散检索Pareto最优解;2)设计基于拥挤距离的群体更新机制,该机制淘汰种群中较弱解,添加较优解,帮助种群快速进化的同时跳出局部最优,有利于收敛到真实的Pareto最优解.以上两种策略分工明确,作用于MOWPA-AG的不同阶段,增强算法的勘探能力和寻优能力,使算法能够有效求解多目标优化问题.

1 相关工作

1.1 多目标优化问题

多目标优化问题一般可描述为

$$\min F(x) = (f_1(x), f_2(x), \dots, f_m(x))^T.$$

$$\text{s.t. } g_i(x) \leq 0, \quad i = 1, 2, \dots, q;$$

$$h_j(x) = 0, \quad j = 1, 2, \dots, p. \quad (1)$$

其中: $x = (x_1, x_2, \dots, x_n) \in X \subset R_n$ 为 n 维决策向量; X 为 n 维决策空间; $F(x)$ 为由决策空间向目标空间映射的函数; $g(x)$ 和 $h(x)$ 分别为 q 个不等式约束和 p 个等式约束.

对于某个 $x \in X$,若满足式(1)中的约束条件,则称 x 为可行解,决策空间中所有可行解组成的集合称为可行解集合,记为 X_f ,当且仅当

$$\begin{cases} \forall i = 1, 2, \dots, m : f_i(x_A) \leq f_i(x_B), \\ \exists j = 1, 2, \dots, m : f_j(x_A) < f_j(x_B) \end{cases}$$

成立时,称 x_A 支配 x_B ,记作 $x_A \prec x_B$.若 $\neg \exists x \in X_f$,使得 $x \prec x^*$ 成立,则称 x^* 为非支配解,决策空间中所有非支配解的集合称为Pareto最优解集(Pareto-optimal set, PS),其对应目标向量组成的曲面称为Pareto最优前沿(Pareto-optimal front, PF).

1.2 狼群算法

WPA有着明确的社会分工,该算法将狼群分为头狼、探狼和猛狼,并从狼群协作捕猎过程中抽象出游走、召唤和围攻3种智能行为,以及“胜者为王”的头狼产生规则和“强者生存”的狼群更新机制.算法基本流程如下.

step 1: 狼群初始化.在 D 维空间随机初始化生成 N 匹人工狼,第 i 匹人工狼的位置表示为 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$,其中 x_{id} 为第 i 匹人工狼在第 d ($d = 1, 2, \dots, D$)维中的位置.

step 2: 选取初始解空间中目标函数值最优的人工狼作为头狼,除头狼外,选择最佳的 L 匹人工狼作为探狼,其中 L 为 $[N/(\alpha + 1), N/\alpha]$ 间的随机整数, α 为探狼比例因子.探狼向 h 个方向搜索猎物,记录每次感知到的猎物气味浓度后回到原来的位置.在解空间中,探狼 i 在 d 维空间的侦察路径为

$$x_{id}^p = x_{id} + \sin(2\pi \times p/h) \times \text{step}_a^d. \quad (2)$$

其中: x_{id}^p 为向第 p ($p = 1, 2, \dots, h$)个方向行进后探狼 i 在第 d 维空间中的位置; step_a^d 为第 d 维空间的游走步长.设第 d 维变量的取值范围为 $[\min_d, \max_d]$,则 $\text{step}_a^d = |\max_d - \min_d|/S$, S 为步长因子.

step 3: 召唤行为.头狼通过嚎叫召唤周围的猛狼,受到召唤的 M ($M = N - L - 1$)匹猛狼向头狼所处的位置迅速聚集,猛狼 i 在第 $k + 1$ 次迭代时,在第 d 维空间中所处位置为

$$x_{id}^{k+1} = x_{id}^k + \text{step}_b^d \cdot (g_d^k - x_{id}^k)/|g_d^k - x_{id}^k|. \quad (3)$$

其中: g_d^k 为第 k 代群体的头狼在第 d 维空间所处的位置, step_b^d 为第 d 维空间的奔袭步长.

当某一猛狼 i 与猎物(即头狼所在位置)的距离 d_{i_leader} 小于判定距离 d_{near} 时, 转入围攻行为, 围攻行为遵循下式:

$$x_{id}^{k+1} = x_{id}^k + \lambda \cdot \text{step}_c^d \cdot |G_d^k - x_{id}^k|. \quad (4)$$

其中: λ 为 $[-1, 1]$ 内均匀分布的随机数, G_d^k 为猎物在第 d 维空间所处的位置, step_c^d 为第 d 维空间的攻击步长. 攻击步长取游走步长的一半, 判定距离 d_{near} 可由下式估算得到:

$$d_{near} = \frac{1}{D \cdot \omega} \cdot \sum_{d=1}^D |\max_d - \min_d|. \quad (5)$$

其中: D 为待寻优变量的维数, ω 为距离判定因子.

step 4: 更新机制. 在每次迭代的最后淘汰最差的 R 匹人工狼, 再随机生成 R 匹人工狼, 满足“强者生存”的狼群更新机制. 这里 R 取 $[N/(2 \times \beta), N/\beta]$ 间的随机整数, β 为群体更新比例因子.

2 自适应分组和拥挤距离更新的多目标狼群算法

WPA 通过模拟狼群协作捕猎的群体行为演化而来, 整个种群由头狼领导, 头狼负责感知信息与决策, 指挥整个狼群行动, 探狼和猛狼负责执行头狼的指令, 探狼捕获到猎物时向头狼汇报, 头狼根据探狼传递出的信息指挥猛狼对猎物进行围攻, 这种生物学行为彰显出狼群群体智慧的魅力.

WPA 虽然在解决单目标问题时展现出较好的全局收敛性和计算鲁棒性, 但由于多目标问题的解是由一组非劣解集合组成的, 而 WPA 为单一解, 将 WPA 应用在多目标问题中仍存在一系列问题: 1) 人工狼个体的适应度值大小无法直接通过目标函数值进行比较; 2) WPA 本质上是头狼引导其他人工狼向头狼方向进行搜索, 在解决多目标问题中易陷入局部最优; 3) WPA 中的群体更新机制依据适应度值进行淘汰, 而多目标问题中无法直接通过适应度值淘汰较差个体.

为了解决上述出现的一系列问题并将 WPA 应用于多目标问题中, 结合狼群的生物学特性从两个方面对 WPA 进行改进, 提出 MOWPA-AG.

2.1 自适应分组策略

为了维护狼群的生存与发展, 每个狼群的捕猎活动都由头狼领导, 但除头狼领导狼群以外, 还有另一种族群呈现现象——即多个族群共存. 在很多地区, 狼是相对弱势的群体, 在面对如狮子、猎豹等大型

猫科动物时, 单一族群就会在气势上略显薄弱, 导致狼群生存困难, 这时需发展出由多个族群共同组成的规模庞大的狼群, 在这些族群中并没有绝对地位的统治者, 各个族群的领导者即头狼互相配合, 联合各族群共同狩猎大型的猎物. 基于这一生物学机理, 本文在狼群算法的基础上设计自适应分组策略(adaptive grouping, AG), 并对上述狼群行为和规则进行具体描述和实现.

自适应分组策略模拟狼群中多族群共存的特性, 基于非支配排序^[13]将种群划分为多个族群, 并生成多个头狼领导各自族群.

MOWPA-AG 中自适应分组策略流程如下:

1) 对整个种群编号, 并对种群执行非支配排序, 若排序后的种群中存在 t 个非支配个体, 则设定该 t 个个体为头狼, 以这些头狼作为领导者生成 t 个组, 将非支配排序后各头狼支配的剩余人工狼编号添加进各自组内.

2) 为避免人工狼同时出现在两个头狼所领导的组内, 对各组内的所有编号进行两两查重, 若出现重复编号, 则比较该编号所对应个体与两个组内头狼间的欧氏距离, 将与头狼相距较远的重复个体所对应的编号从该头狼组中删除.

同时, 为了防止种群经非支配排序后仅有一个非支配个体, 其他个体均向该个体学习从而陷入局部最优的情况, 当面对这一情况时, 将非支配排序后等级为 2 的 h 个个体同样看作头狼, 并产生 $h + 1$ 个组执行上述操作.

如图 1 所示, 对于一个未规划的种群, 假定执行非支配排序后存在 4 个非支配个体(即图 1 中黑色圆点标记的个体), 划分为 4 个组, 执行自适应分组后的剩余人工狼(即橙色圆点的标记个体)按上述规则分配到各组内.




图 1 自适应分组后种群位置示意图

2.2 基于拥挤距离的群体更新机制

狼群算法中, 群体更新机制模拟狼群中“强者生存”这一生物学原型, 是维护种群多样性的重要机

制,其依据个体的适应度值选出其中最差个体进行更新.但在多目标问题中,无法直接通过比较适应度值的大小选出最差个体,因此设计基于拥挤距离的群体更新机制,选出待更新个体.

拥挤距离^[13]用来计算种群中的某个体与该种群其他个体之间的距离,具体公式如下:

$$D(j) = \sum_{i=1}^k \frac{f_i(j+1) - f_i(j-1)}{f_{i\max} - f_{i\min}}, \quad (6)$$

其中 $f_i(j-1)$ 、 $f_i(j+1)$ 为与个体 j 相邻的两个个体第 i 个目标函数的值.

MOWPA-AG中群体更新机制改进后,个体淘汰步骤如下.对每一次迭代后的种群进行非支配排序,设需要群体更新的数量为 R ,经过非支配排序,将整个种群中非劣解的个数假设为 m ,其余个体数为 $N-m$,其中 N 为整个种群个体数.按如下策略进行更新:

1) 若 $N-m > R$,则在 $N-m$ 个个体中选择最差的 R 个个体进行淘汰;

2) 若 $N-m < R$,则先对 $N-m$ 个个体进行群体更新,后对 m 个个体进行拥挤度距离计算,选择其中最差的 $R-(N-m)$ 个个体进行淘汰.

对经过以上方案选出的个体进行淘汰,并将基于种群中较优秀个体产生新的个体加入种群,产生公式如下:

$$X_{\text{new}} = X_{\text{best}}((0.1 \times \partial + 1) + 1). \quad (7)$$

其中: X_{new} 为新产生的个体, X_{best} 为种群中较优个体, ∂ 为随机产生的一个0到1的数.

2.3 算法流程

结合前文,MOWPA-AG流程如下.

step 1: 初始化种群.设置狼群中人工狼数量以及位置 x ,最大迭代次数 t ,最大游走次数 T_{\max} ,距离判定因子 w ,步长因子 S ,更新比例因子 b .

step 2: 对初始化后的种群执行自适应分组策略,将每组中最优个体定义为头狼.

step 3: 游走行为.对分组后除头狼以外的个体执行向周围 h 个方向游走,人工狼 i 在游走过程中所处位置为式(2),选取 h 个方向中最好的位置作为该人工狼的新位置,在游走行为中若人工狼搜索到的猎物气味浓度优于组内头狼,则人工狼成为组内头狼,直到迭代至最大游走次数 T_{\max} ,游走行为结束,重新执行自适应分组并进入下一行为模式.

step 4: 召唤行为.每组头狼向组内其他人工狼发起召唤,周围人工狼以式(3)向头狼发起奔袭,在奔袭过程中,若人工狼感知到的猎物气味浓度优于其所在组内头狼,则该人工狼取代头狼发起召唤.在奔袭过

程中,若人工狼与头狼之间的位置 d 小于 d_{near} ,则进入围攻行为.

step 5: 围攻行为.此时经过奔袭后的人工狼距其组内头狼较近,将头狼位置视为猎物的位置,其他人狼向猎物发起围攻,围攻行为为可用式(4)表示.

step 6: 群体更新机制.结束完3种智能行为后,对种群执行基于拥挤距离的群体更新,淘汰 R 匹人工狼,并根据式(7)加入新的 R 匹人工狼.

step 7: 判断是否达到最大迭代次数,若达到则输出种群中的非劣解,否则转至step 2.

2.4 算法收敛性分析

Markov链是一种无后效性的随机过程,特点是未来状态的概率分布只依赖于当前状态,而与过去状态无关,常被应用于分析收敛性问题^[14].MOWPA-AG是一种不断进行迭代的过程,每一代种群均由上一代种群执行几种智能行为后产生,而与过去种群无关.因此,MOWPA-AG的种群序列是Markov链.

设定狼群状态由狼群位置构成,搜索空间为 H ,人工狼位置为 X , $X \in F$, $\eta_k = (X_1, X_2, \dots, X_N)$ 为算法第 k 代种群状态, N 为人工狼个数, X_i 为第 i 个人工狼状态,人工狼状态由 X_i 转移到 X_j 的概率转移矩阵为 P_{ij} .

定义1 设 P_{ij} 为Markov链的转移概率矩阵,对于状态空间中的任意两个状态,若 $\forall i, j \in H$,存在 $k \geq 1$,使得 $P_{ij}^k > 0$,则称此Markov链是不可约的.

定义2 设 $U = \{k | k \geq 1, P_{ij}^k > 0, \forall i, j \in H\}$ 是非空集合且 U 的最大公约数为1,则称此Markov链是非周期的.

定义3 设 $u_i = \sum_k P_{ij}^k$,对于常返状态 i ,若 $u_i < +\infty$,则称 u_i 是正常返.当 j 为正常返且非周期,则称此Markov链是遍历的.

定义4 若一个进化算法满足如下两个条件,则此进化算法以概率1收敛于问题的最优解^[15]:

1) 对于可行解中任意两点 x_1 和 x_2 , x_2 是 x_1 由算法中的各种算子可达的.

2) 种群序列 $\eta_k = (X_1, X_2, \dots, X_N)$ 是单调的.

引理1 MOWPA-AG的解序列是一个有限齐次Markov链.

证明 由于优化问题的搜索空间是有限的,且人工狼个数是有限的,可以推知狼群状态空间是有限的,为此构成有限的Markov链.另一方面,由于MOWPA-AG算法是由自适应分组、游走、召唤、围攻、群体更新等一系列行为组成,第 $k+1$ 代的种群仅依赖第 k 代种群,且由于自适应分组的存在,下一

代种群质量均优于上一代种群. 为此, 经过MOWPA-AG进行随机处理得到的优化解序列是一个有限齐次Markov链. \square

引理2 MOWPA-AG算法种群的Markov链是遍历链.

证明 首先证明算法种群序列是不可约的. 由于 $\eta_k > 0$, 而算法的状态转移矩阵 P_{ij} 仅与状态 i, j 有关, 矩阵 P_{ij} 是正定的, 由定义1可知此Markov链是不可约的. 其次证明MOWPA-AG是非周期的Markov链. 对于给定的 $k > 0, \exists j \in H$, 使得 $P > 0$, 由定义2知 $k = 1$, 因此集合 U 的最大公约数为1, MOWPA-AG是非周期的Markov链. 最后证明MOWPA-AG是遍历链. 由于算法中人工狼的状态更新是由自适应分组、游走、召唤、围攻4种智能行为组成, 而这些行为均在独立随机过程中进行, 即概率均处于 $(0, 1)$, 可得状态转移矩阵 $0 < P_{ij} < 1$. 设 $\varepsilon = \max\{P_{ij}; \forall i, j \in H\}$, 由定义3和Cauchy-Riemann方程可知 $u_i < +\infty$, 即MOWPA-AG的Markov链是遍历链. \square

引理3 MOWPA-AG以概率1收敛于全局最优解.

证明 由于MOWPA-AG在WPA的基础上添加了自适应分组和拥挤距离更新的策略, 这两种策略均具有保留优秀解的功能, 即每一次迭代后产生的解均不弱于迭代前的解, 由此可得出结论MOWPA-AG的种群序列 η_k 是单调的. 已证MOWPA-AG算法种群序列的Markov链是遍历且有限齐次的, 定义4中的条件1)和2)显然成立, 即MOWPA-AG以概率1收敛于全局最优解. \square

2.5 算法时间复杂度分析

由于WPA采用3种行为遍历所有人工狼, 但3种行为均为串行, 其时间复杂度表示为 $O(N)$. MOWPA-AG算法在WPA的基础上添加自适应分组策略主要取决于以下步骤:

1) 非支配排序. 该操作的时间复杂度为 $O(m \times N^2)$, 其中 m 为目标函数个数.

2) 对种群进行分组. 对所有个体进行编号分组, 该操作时间复杂度为 $O(N)$.

3) 对组内重复编号进行查重, 该操作时间复杂度为 $O(N^2)$.

综上, 自适应分组策略的时间复杂度可近似为 $O(m \times N^2) + O(N^2)$. 由于 m 在多目标优化问题中至少为2, MOWPA-AG的时间复杂度可近似为 $O(m \times N^2)$. 同时选取经典的MOFA和NSGA-II与本文算法进行时间复杂度比较, 其中MOFA的时间复杂度近

似为 $O(N^2)$, NSGA-II的时间复杂度近似为 $O(m \times N^2)$. 比较可得, 在处理低维多目标优化问题时($m \ll N$), MOWPA-AG与这两种经典算法的时间复杂度在同一数量级上. 在处理高维度多目标优化问题时, MOWPA-AG与NSGA-II的时间复杂度在同一数量级上, 与MOFA相比时间复杂度偏高.

3 实验与结果

3.1 与经典多目标优化算法进行比较

为验证MOWPA-AG性能, 将MOWPA-AG与MOPSO^[16]、NSGA-II^[17]、MOEA/D^[18]、PESA-II^[19]和MOFA^[20]五种经典的多目标优化算法在ZDT、Viennet、DTLZ系列函数^[21-22]上进行实验验证, 所用对比算法的参数来自对应文献.

为了评价MOWPA-AG的综合性能, 采用IGD^[23]评价算法的优劣程度. 为保证算法比较的公平性, 所有算法最大迭代次数maxgen设置为300, 由于其中部分算法采用外部档案策略, 为保证公平, 对5种经典多目标算法采用种群规模50、外部档案100、设置MOWPA-AG种群规模为100来进行对比. 为减少随机因素的干扰, 所有算法在每个测试函数上均独立运行30次, 评价指标为每个算法独立运行30次后的平均值.

表1给出了MOWPA-AG与其他5种经典算法在9个测试函数上IGD的均值标准差及Friedman检验结果, 6种算法在同一测试函数上指标的最优值用加粗数据表示. 根据表1, 从算法的综合性能看, MOWPA-AG在9个测试函数中有5次取得最优且相较于其他5种算法都存在数量级上的优势, 在3目标问题上与最优的IGD值处于相同数量级, 这一结果充分表明本文算法的综合性能较好.

表1同时从Friedman检验中给出了6种多目标优化算法在IGD指标上的结果. 可以发现, MOWPA-AG在检验中排名第一, 随后是PESA-II、MOPSO、NSGA-III、MOFA、MOEA/D最差. Friedman检验结果表明, MOWPA-AG相较于其他5种对比算法而言综合性能较好, 且算法精确度以及所得解集也处于较优的位置.

由实验结果可知, MOWPA-AG是一种可行有效的多目标优化算法, 且表现出了很强的全局搜索能力和收敛性. 究其原因: 首先, WPA自身在全局搜索能力方面便具有优势, 因此MOWPA-AG延续了WPA的优势来求解多目标问题; 另一方面, MOWPA-AG结合狼群的另一种生物学特性, 运用自适应分组策略有效维护种群的多样性, 有效提升算法的勘探能力, 保证了MOWPA-AG收敛性、综合性的有效性能.

表 1 MOWPA-AG 与 5 种经典算法在 IGD 上的实验结果与 Friedman 检验结果

instances	results	MOPSO	NSGA-III	MOEA/D	PESA-II	MOFA	MOWPA-AG
ZDT1	Mean	1.13e-02	1.64e-02	3.46e-01	1.06e-01	2.60e-02	6.48e-03
	std	2.70e-03	9.03e-03	1.82e-01	2.52e-02	4.68e-03	2.96e-03
ZDT2	Mean	5.90e-01	1.54e-01	1.62e+00	1.78e-01	6.04e-02	4.95e-03
	std	4.46e-01	6.42e-02	6.35e-01	6.78e-02	2.93e-02	3.77e-04
ZDT3	Mean	5.48e-02	7.11e-02	4.54e-01	1.24e-01	3.57e-02	1.64e-02
	std	6.53e-02	2.48e-02	2.06e-01	1.97e-02	1.00e-02	1.40e-02
ZDT4	Mean	2.57e+00	1.82e+00	5.99e+00	2.08e+00	1.83e-01	4.69e-03
	std	1.47e+00	4.18e-01	5.42e+00	1.34e+00	1.78e-01	2.13e-04
ZDT6	Mean	8.40e-02	8.51e-02	3.73e+00	1.18e-02	3.00e-01	1.27e-02
	std	4.11e-01	1.29e-01	1.31e+00	1.71e-02	8.83e-02	3.14e-02
Viennet1	Mean	1.41e-01	3.49e-01	4.15e-01	9.67e-02	7.69e-01	5.53e-01
	std	7.19e-02	2.84e-01	3.14e-01	8.39e-03	1.51e-01	1.03e-01
Viennet3	Mean	7.38e-02	9.39e-02	6.22e-01	9.92e-02	9.70e-02	6.95e-01
	std	2.44e-03	9.89e-02	1.92e-01	1.19e-02	7.37e-03	2.78e-01
DTLZ4	Mean	1.53e-01	1.66e-01	4.07e-01	1.51e-01	1.75e-01	3.33e-01
	std	7.25e-03	9.51e-03	6.02e-02	8.63e-03	9.75e-03	4.31e-02
DTLZ7	Mean	2.54e-01	2.33e+00	2.42e+00	8.83e-02	1.57e+00	9.54e-02
	std	5.47e-01	1.39e-01	1.82e-01	1.54e-02	7.15e-01	1.50e-01
friedman	result	2.89	3.33	5.67	2.89	3.56	2.67

3.2 与新进多目标优化算法进行比较

为进一步验证 MOWPA-AG 的有效性, 将 MOWPA-AG 与 7 种新近的多目标优化算法 MONSFA^[24]、dMOFA^[25]、Top^[26]、MOEA/DACD^[27]、NSLS^[28]、SMSEMOA^[29] 和 MOEA/IGD-NS^[30] 进行比较, 所有对比算法的参数设置均来自对应文献. 选取 6 个基准 MOP 测试问题组成的测试集合, 分别包括 5 个 2-目标测试函数和 1 个 3-目标测试函数, 利用 IGD 评价指标评判算法的优劣. 为确保公平, 实验中最大迭代次数设置为 300 次, 所有算法种群数设置为 100. 为平衡随机性, 算法独立运行 30 次, 结果取其平均值, 实验结果由表 2 给出, 其中加粗数据表示不同

算法在同一个测试函数上的最优值.

根据表 2, MOWPA-AG 在 6 个测试函数中取得了 4 次最优的 IGD 均值, MONSFA、dMOFA 各取得 1 次最优, 其中 MOWPA-AG 在 ZDT2、ZDT4 这两个测试函数中均取得了一个数量级的优势. 表 2 同时采用 Friedman 检验给出了 MOWPA-AG 与 7 种新近算法基于 IGD 指标的结果. 可以看出, MOWPA-AG 排名第一, ToP 次之, 随后依次是 MOEA/IGD-NS、NMPSO、MOEA/DACD、NSLS、MONSFA, 最差的是 SMSEMOA, Friedman 检验的结果与表 2 中 IGD 均值结果保持一致. 综合来看, MOWPA-AG 较其他 7 种对比算法表现出更强的收敛性和多样性.

表 2 MOWPA-AG 与 7 种新近算法的 IGD 实验结果及 Friedman 检验结果

instances	results	MONSFA	ToP	NMPSO	MOEA/DACD	NSLS	SMSEMOA	MOEA/IGD-NS	MOWPA-AG
ZDT1	Mean	7.220e-02	8.660e-03	3.040e-02	6.120e-02	6.620e-02	1.213e-01	1.618e-02	6.480e-03
	std	5.460e-03	1.560e-03	1.380e-02	4.800e-03	1.330e-02	8.260e-03	1.960e-03	2.960e-03
ZDT2	Mean	1.130e-01	1.460e-02	1.950e-02	1.020e-01	1.190e-01	5.620e-01	3.026e-02	4.950e-03
	std	7.680e-03	2.860e-03	3.820e-03	7.900e-03	2.480e-02	1.080e-03	1.590e-03	3.770e-04
ZDT3	Mean	1.300e+00	1.680e-02	1.060e-01	3.240e-02	7.540e-02	1.024e-01	6.642e-02	1.640e-02
	std	3.400e-03	8.020e-03	5.480e-04	2.700e-03	1.430e-02	1.020e-02	5.670e-02	1.400e-02
ZDT4	Mean	2.460e+00	3.300e+00	2.340e-01	1.580e+00	2.380e-01	1.224e+00	1.650e-02	4.690e-03
	std	2.350e-01	1.820e+00	7.200e-03	2.800e-01	1.090e-01	2.170e-02	2.700e-03	2.130e-04
ZDT6	Mean	2.330e-01	3.860e-03	4.360e-03	2.140e-01	3.520e-03	8.963e-01	4.461e-03	1.270e-02
	std	8.700e-03	3.770e-04	4.640e-04	9.400e-03	1.300e-04	2.390e-05	7.780e-04	3.140e-02
DTLZ4	Mean	8.340e-03	6.120e-02	8.840e-02	5.140e-03	7.550e-02	3.310e-01	1.006e-01	3.330e-01
	std	1.100e-03	8.460e-03	1.230e-01	3.800e-04	7.600e-02	2.670e-01	2.160e-01	4.310e-02
friedman	result	6.17	3.17	4.17	3.83	4.50	7.00	4.33	2.83

经过两次实验比较可知, MOWPA-AG 是一种可行有效的多目标优化算法, 表现出很强的收敛性和多样性.

4 工程应用

为验证算法的有效性, 将 MOWPA-AG 算法应用在工业工程的真实问题中. Tanabe 等^[31] 于 2020 年自主整合了一套真实世界多目标优化问题的测试集并将其公开, 该测试集包括各个领域内共 16 个多目标优化问题, 问题集合了不同目标数量、不同 Pareto 前沿、不同设计变量的测试函数, 对于评估多目标优化算法性能有重要意义. 本文选取其中的一个问题进行求解, 并与 5 个经典多目标算法进行比较. 这一问题案例最早由 Zitzler 等^[32] 提出, 他对四杆桁架结构进行了详细的分析, 将该问题以数学模型表示, 且最

先将多目标问题的视角代入这一工程问题中. 从数学上来讲, 该问题的数学模型为

$$\begin{aligned} \min f_1(x) &= L(2x_1 + \sqrt{2}x_2 + \sqrt{x_3} + x_4), \\ f_2(x) &= \frac{FL}{E} \left(\frac{2}{x_1} + \frac{2\sqrt{2}}{x_2} - \frac{2\sqrt{2}}{x_3} + \frac{2}{x_4} \right); \\ \text{s.t. } \frac{F}{\sigma} &\leq x_1 \leq 3\frac{F}{\sigma}, \\ \sqrt{2}\frac{F}{\sigma} &\leq x_2 \leq 3\frac{F}{\sigma}, \\ \sqrt{2}\frac{F}{\sigma} &\leq x_3 \leq 3\frac{F}{\sigma}, \\ \frac{F}{\sigma} &\leq x_4 \leq 3\frac{F}{\sigma}. \end{aligned} \tag{8}$$

其中: x_i 为横截面积; $F = 10 \text{ kN}$; E 为弹性模量, 取 $E = (2) \times 10^5 \text{ kN/cm}^2$; L 为桁架截面的长度, 取 $L = 200 \text{ cm}$; σ 为特征应力, 取 $\sigma = 10 \text{ kN/cm}^2$.

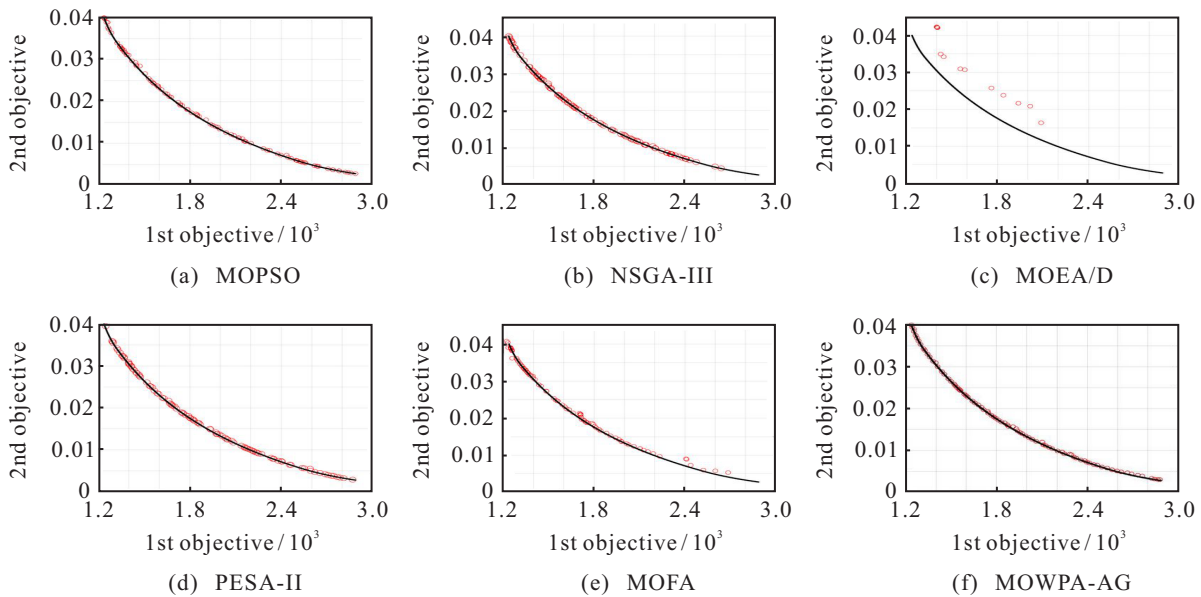


图 2 6种算法在四杆桁架问题中的 Pareto 曲线

通过 IGD 指标评判 MOWPA-AG 面对这一工程问题的性能, 并与其他 5 种经典多目标算法进行比较, 为了减少随机干扰的因素, 所有算法在该问题中均独立运行 30 次, 评价指标所得数据为算法运行 30 次后的平均值. 表 3 给出了 MOWPA-AG 与其他 5 种经典多目标算法在这一问题中 IGD 的平均值和标准差. 其中 MOWPA-AG 最优, 接着是 PESA-II、MOPSO、NSGA-III、MOFA, MOEA/D 最差. 图 2 展示

了 MOWPA-AG 与其他 5 种经典算法在 300 次迭代后所有非支配解与真实 Pareto 前沿的对比. 可以发现, 图中结果与表 3 中数据相符, 因此可以得出如下结论: 通过 MOWPA-AG 可以有效解决这一工程问题, 且得到的解与真实 Pareto 接近一致. 此外, 表中结果表明 MOWPA-AG 在针对这一工程实践问题中, 相较于其他基础算法展现出了较优的效果, 即后续可将其继续应用至解决更多的工程问题.

表 3 MOWPA-AG 与 5 种经典算法在四杆桁架问题中基于 IGD 上的实验结果

problem	results	MOPSO	NSGA-III	MOEA/D	PESA-II	MOFA	MOWPA-AG
Four-Bar	Mean	9.89e+00	1.06e+01	4.65e+02	6.59e+00	1.08e+01	5.75e+00
Truss	std	4.85e-01	2.17e+00	3.99e+01	4.89e-01	3.83e+00	5.23e-01

5 结论

优化问题在计算机领域具有非常重要的应用价值,通过群智能算法解决优化问题一直是研究的热点之一^[33]. 狼群算法在单目标优化问题中展现了良好的求解能力,为将其优势用于多目标优化问题,本文提出自适应分组和拥挤距离更新的多目标狼群算法. 首先,模拟狼群的家族聚集性提出了自适应分组策略,根据狼群中个体差异实现狼群分化,兼顾了种群多样性,保证了算法的全局搜索能力以及解集的多样性;其次,为加快算法收敛,设计了基于拥挤距离的群体更新机制,帮助种群快速进化,在多目标领域广泛使用的多个基准测试函数中,将MOWPA-AG与经典及新近算法进行了研究比较. 实验结果表明,所提出的MOWPA-AG具有强的竞争力,是解决多目标优化问题的一种可行选择.

本文的研究重点是狼群算法应用于多目标优化问题,群智能算法对参数敏感,下一步将重点研究MOWPA-AG对参数的自适应,以及将MOWPA-AG应用于求解高维、大规模多目标优化问题,以推动群智能优化^[34]研究的发展.

参考文献(References)

- [1] 刘长石, 陈慧璇, 吴张. 城市物流配送的混合车辆路径规划模型与优化算法[J]. 控制与决策, 2023, 38(3): 759-768.
(Liu C S, Chen H X, Wu Z. Programming model and optimization algorithm for the mixed fleet vehicle routing problem in urban logistics distribution[J]. Control and Decision, 2023, 38(3): 759-768.)
- [2] 赵嘉, 王刚, 吕莉, 等. 面向流形数据的测地距离与余弦互逆近邻密度峰值聚类算法[J]. 电子学报, 2022, 50(11): 2730-2737.
(Zhao J, Wang G, Lü L, et al. Density peaks clustering algorithm based on geodesic distance and cosine mutual reverse nearest neighbors for manifold datasets[J]. Acta Electronica Sinica, 2022, 50(11): 2730-2737.)
- [3] 赵嘉, 姚占峰, 吕莉, 等. 基于相互邻近度的密度峰值聚类算法[J]. 控制与决策, 2021, 36(3): 543-552.
(Zhao J, Yao Z F, Lyu L, et al. Density peaks clustering based on mutual neighbor degree[J]. Control and Decision, 2021, 36(3): 543-552.)
- [4] Zhang X Y, Duan F C, Zhang L, et al. Pattern recommendation in task-oriented applications: A multi-objective perspective application notes[J]. IEEE Computational Intelligence Magazine, 2017, 12(3): 43-53.
- [5] Farag M A, El-Shorbagy M A, Mousa A A, et al. A new hybrid metaheuristic algorithm for multi-objective optimization problems[J]. International Journal of Computational Intelligence Systems, 2020, 13(1): 920-940.
- [6] 吴虎胜, 张凤鸣, 吴庐山. 一种新的群体智能算法——狼群算法[J]. 系统工程与电子技术, 2013, 35(11): 2430-2438.
(Wu H S, Zhang F M, Wu L S. New swarm intelligence algorithm—Wolf pack algorithm[J]. Systems Engineering and Electronics, 2013, 35(11): 2430-2438.)
- [7] Xiu-wu Y U, Hao Y U, Liu Y, et al. A clustering routing algorithm based on wolf pack algorithm for heterogeneous wireless sensor networks[J]. Computer Networks, 2020, 167: 106994.
- [8] Menassel R, Nini B, Mekhaznia T. An improved fractal image compression using wolf pack algorithm[J]. Journal of Experimental & Theoretical Artificial Intelligence, 2018, 30(3): 429-439.
- [9] Wu H S, Zhang F M. A uncultivated wolf pack algorithm for high-dimensional functions and its application in parameters optimization of PID controller[C]. IEEE Congress on Evolutionary Computation. Beijing, 2014: 1477-1482.
- [10] 荀洪凯, 陶翼飞, 张源, 等. 多目标启发式狼群算法求解不相关并行机分批调度问题[J]. 信息与控制, 2023, 52(1): 93-103.
(Xun H K, Tao Y F, Zhang Y, et al. Multi-objective heuristic wolf pack algorithm for unrelated parallel machine batch scheduling problem[J]. Information and Control, 2023, 52(1): 93-103.)
- [11] 李小川, 刘媛华, 王影歌. 求解多目标带时间窗VRP的文化狼群算法[J]. 计算机应用研究, 2020, 37(4): 1025-1029.
(Li X C, Liu Y H, Wang Y G. Cultural wolf pack algorithm for solving multi-objective VRP with time window[J]. Application Research of Computers, 2020, 37(4): 1025-1029.)
- [12] 马文, 耿贞伟, 张莉娜, 等. 基于改进多目标狼群算法的微电网调度优化[J]. 电子技术应用, 2017, 43(11): 124-127.
(Ma W, Geng Z W, Zhang L N, et al. The improved multi-objective wolf colony algorithm based microgrid scheduling optimization[J]. Application of Electronic Technique, 2017, 43(11): 124-127.)
- [13] Deb K, Agrawal S, Pratap A, et al. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II[C]. Parallel Problem Solving from Nature PPSN VI. Berlin, Heidelberg: Springer, 2000: 849-858.
- [14] 李军华, 黎明. 元胞遗传算法的收敛性分析和收敛速度估计[J]. 模式识别与人工智能, 2012, 25(5): 874-878.
(Li J H, Li M. Convergence analysis and convergence rate estimate of cellular genetic algorithms[J]. Pattern Recognition and Artificial Intelligence, 2012, 25(5): 874-878.)
- [15] Bäck T. Evolutionary algorithms in theory and practice:

- Evolution strategies, evolutionary programming, genetic algorithms[M]. New York: Oxford University Press, 1996.
- [16] Coello C A C, Pulido G T, Lechuga M S. Handling multiple objectives with particle swarm optimization[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3): 256-279.
- [17] 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.
- [18] Qi Y, Ma X, Liu F, et al. MOEA/D with adaptive weight adjustment[J]. Evolutionary Computation, 2014, 22(2): 231-264.
- [19] Gadhvi B, Savsani V, Patel V. Multi-objective optimization of vehicle passive suspension system using NSGA-II, SPEA2 and PESA-II[J]. Procedia Technology, 2016, 23: 361-368.
- [20] Zhao J, Chen D D, Xiao R B, et al. Multi-objective firefly algorithm with adaptive region division[J]. Applied Soft Computing, 2023, 147: 110796.
- [21] Deb K, Thiele L, Laumanns M, et al. Scalable multi-objective optimization test problems[C]. Proceedings of the 2002 Congress on Evolutionary Computation. Honolulu, 2002: 825-830.
- [22] Tang L X, Wang X P. A hybrid multiobjective evolutionary algorithm for multiobjective optimization problems[J]. IEEE Transactions on Evolutionary Computation, 2013, 17(1): 20-45.
- [23] Li W K, Wang W L, Wang Z, et al. Opposition-based multi-objective whale optimization algorithm with global grid ranking[J]. Neurocomputing, 2019, 341(C): 41-59.
- [24] Tsai C W, Huang Y T, Chiang M C. A non-dominated sorting firefly algorithm for multi-objective optimization[C]. The 14th International Conference on Intelligent Systems Design and Applications. Okinawa, 2014: 62-67.
- [25] Martínez S Z, Coello Coello C A. A multi-objective particle swarm optimizer based on decomposition[C]. Proceedings of the 13th Annual Conference on Genetic and Evolutionary Computation. Dublin, 2011: 69-76.
- [26] Liu Z Z, Wang Y. Handling constrained multiobjective optimization problems with constraints in both the decision and objective spaces[J]. IEEE Transactions on Evolutionary Computation, 2019, 23(5): 870-884.
- [27] Wang L P, Zhang Q F, Zhou A M, et al. Constrained subproblems in a decomposition-based multiobjective evolutionary algorithm[J]. IEEE Transactions on Evolutionary Computation, 2016, 20(3): 475-480.
- [28] Chen B L, Zeng W H, Lin Y B, et al. A new local search-based multiobjective optimization algorithm[J]. IEEE Transactions on Evolutionary Computation, 2015, 19(1): 50-73.
- [29] Zitzler E, Künzli S. Indicator-based selection in multiobjective search[C]. International Conference on Parallel Problem Solving from Nature. Berlin, Heidelberg: Springer, 2004: 832-842.
- [30] Tian Y, Zhang X Y, Cheng R, et al. A multi-objective evolutionary algorithm based on an enhanced inverted generational distance metric[C]. IEEE Congress on Evolutionary Computation. Vancouver, 2016: 5222-5229.
- [31] Tanabe R, Ishibuchi H. An easy-to-use real-world multi-objective optimization problem suite[J]. Applied Soft Computing, 2020, 89: 106078.
- [32] Zitzler E, Deb K, Thiele L. Comparison of multiobjective evolutionary algorithms: Empirical results[J]. Evolutionary Computation, 2000, 8(2): 173-195.
- [33] Zhao J, Chen W P, Xiao R B, et al. Firefly algorithm with division of roles for complex optimal scheduling[J]. Frontiers of Information Technology & Electronic Engineering, 2021, 22(10): 1311-1333.
- [34] 肖人彬, 陈峙臻. 从群智能优化到群智能进化[J]. 南昌工程学院学报, 2023, 42(1): 1-10.
(Xiao R B, Chen Z Z. From swarm intelligence optimization to swarm intelligence evolution[J]. Journal of Nanchang Institute of Technology, 2023, 42(1): 1-10.)

作者简介

赵嘉(1981—), 男, 教授, 硕士生导师, 从事智能计算与计算智能、模式识别与大数据挖掘等研究, E-mail: zhaojia925@163.com;

吕丰(1998—), 男, 硕士生, 从事群智能算法的研究, E-mail: 748540847@qq.com;

肖人彬(1965—), 男, 教授, 博士生导师, 从事复杂系统建模与分析、群集智能等研究, E-mail: rbxiao@163.com;

樊棠怀(1962—), 男, 教授, 博士生导师, 从事仿生信息处理、多传感器信号融合等研究, E-mail: fantanghuai@163.com;

董文飞(1999—), 女, 研究生, 从事群智能算法的研究, E-mail: 2360813125@qq.com;

王晖(1982—), 男, 教授, 硕士生导师, 从事进化计算、群智能算法等研究, E-mail: huiwang@whu.edu.cn.