

文章编号: 2095-2163(2020)09-0081-05

中图分类号: TP301.6

文献标志码: A

基于 NSGA-II 的偏好分解的多目标优化算法研究

谢倩文, 何利力

(浙江理工大学信息学院, 杭州 310018)

摘要: 对于多目标优化问题, 传统的优化算法不能够很好地处理复杂的 Pareto 前沿 (PF) 上的收敛和分布问题, 收敛性和分布性二者不能得到较好的平衡; 利用改进后的边界交叉方法, 超平面根据补足位移移动, 形成新的标准目标向量, 使得更多的个体分布在可行区域; 决策者偏好的高维多目标优化算法, 能够有效地减小搜索空间, 解决算法后期收敛放缓和种群退化的问题。本文提出基于偏好向量分解的多目标优化算法, 基于 NSGA-II 的偏好分解的多目标优化算法, 将偏好信息作为促进解向最优解移动的条件, 能够加快收敛速度, 找到接近的真实的 Pareto 最优前沿解 (POF)。本文将 (NSGA-RPIPBI) 和非支配排序遗传算法 (NSGA-II)、基于优势和分解的多目标进化算法 (MOEA/DD) 在多目标问题测试集 DTLZ1-4 上进行多维目标测试, NSGA-RPIPBI 在解集的收敛性和分布性效果更好。

关键词: 高维多目标优化; 分解; 偏好向量

Many-object optimization algorithm with preference based on decomposition

XIE Qianwen, HE Lili

(School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

【Abstract】 For multi-objective optimization problems, traditional optimization algorithms cannot handle the convergence and distribution problems on the complex Pareto front (PF) effectively, which causes that convergence and distribution cannot be well balanced. Utilizing the improved Penalty-Based Boundary Intersection (PBI), the hyperplane moves according to the complementary displacement to form a new standard coordinate system, so that more individuals are distributed in feasible areas. And for the high-dimensional target optimization algorithm, it can effectively reduce the search space, solving the situation of slow convergence and population degradation in the later stage of the algorithm. The multi-objective optimization algorithm based on preference vector decomposition (NSGA-RPIPBI) proposed in this paper uses preference information as a condition for promoting the solution to move to the optimal solution, which can speed up the convergence and find the close real Pareto Optimal Frontier Solution (POF). In this paper, NSGA-RPIPB, non-dominated sorting genetic algorithm (NSGA-II) and multi-objective evolutionary algorithm based on advantage and decomposition (MOEA/DD) are tested on multi-objective problem test set DTLZ1-4, and the results shows that NSGA-RPIPBI has a better convergence and distribution effect on the solution set.

【Key words】 many-object optimization; decomposition; preference vector

0 引言

涉及两个或者多个要优化的冲突目标的问题称为多目标优化问题 (Multi-objective Optimization Problem, MOP)。由于各个目标之间相互排斥, 无法取得在各个目标上的最优解。如何取得最优解或者逐渐靠近最优解的近似解, 成为研究多目标进化算法 (MOEA) 的重点。目前的研究主要从两个方面着手, 一种是通过加权的方式, 将多目标优化问题转化成单目标优化问题; 另外一种就是基于 Pareto 支配关系得到非支配解。Deb K 提出使用带有精英策略的、非支配的排序算法 NSGA-II, 能够在真正的 Pareto 前沿附近找到最优的解 $I^{[1]}$, 但 NSGA-II 算

法对于高维多目标优化问题, Pareto 非支配解会越来越多, 维度越大, 拥挤距离在高维空间的计算也会更加复杂。张青富、李辉提出的 MOEA/D 对于低维简单 PF 的多目标优化问题效果很好, 根据分解方法能生成一组均匀分布的解, 可扩展性高、收敛快、计算复杂度低^[2]。但当有复杂的 Pareto 前沿时, MOEA/D 的均匀分布就会被破坏。而偏好优化算法通过建立偏好的初始条件, 在进化迭代的过程中不断朝着偏好方向去搜索, 减小搜索范围, 找到离偏好信息最接近的解。为了求解基于偏好关系的多目标问题, Molina 在参考点附近估计有效设置, 提出了适用于 MO 进化算法和 MO 元启发算法的 g-

基金项目: 国家重点研发计划 (2018YFB1700702)。

作者简介: 谢倩文 (1996-), 女, 硕士研究生, 主要研究方向: 智能软件与数据处理; 何利力 (1966-), 男, 博士, 教授, 博士生导师, 主要研究方向: 数据分析、企业智能。

通讯作者: 何利力 Email: llhe@zju.edu.cn

收稿日期: 2020-06-15

Dominance^[3];王丽萍等通过将偏好信息和分解的多目标算法相结合,消除参考点的不同区域对算法收敛性的影响^[4]。针对高维的多目标问题,Deb, K 提出了基于参考点的非支配排序方法的进化多目标优化算法 NSGA-III^[5];Yuan 等人提出的 θ -DEA,利用基于分解的 MOEA 中的适应性评估方案,来增强最近提出的非支配排序遗传算法 III 的收敛性^[6];Shouyong Jiang 提出的 SPEA/R 基于参考方向的密度估计器,在多目标问题上显示出非常好的竞争性能^[7];Ke Li 等人提出的 MOEA/DD 结合了基于优势和分解的方法,使用权重向量指定和评估子区域,得到收敛良好和分布良好的点集^[8]。

在许多应用领域中,多目标矛盾的协调也是研究的重点。Li 等提出了基于分解的多目标离散人工蚁群算法,对考虑工序启动时间的置换流水车间调度问题求解^[9];李明峰研究了一种加权惩罚适应度的多目标气象航线模型,得到了航行的最有航线^[10];王原针对群体智能机器人泛用性,提出了基于可变参数的多目标控制模型优化算法^[11]。

1 多维偏好多目标分解算法 NSGA-RPIPB1

1.1 改进的 PBI Approach (IPBI) 方法

基于分解的多目标进化算法的代表 MOEA/D 的算法思想是通过聚合函数,将多目标问题分解成多个单目标优化的子问题,同时对每个子问题进行优化。而每个子问题得到的最优解对于讨论的 MOP 都是最优的。MOEA/D 的每一个子问题由一个均匀分布的权重向量构成,每生成一个新解,则基于聚合函数对该子问题附近的解进行替换。

边界交叉聚合方法 (Penalty-Based Boundary Intersection, PBI) 是使 $F(x)$ 尽可能的逼近 Pareto 前沿,通过采用惩罚的方法来处理约束,式(1)。

$$\begin{aligned} \min \text{imize } g^{\text{bip}}(x | \lambda, z^*) &= d_1 + \theta \cdot d_2, \\ \text{subject to } x &\in \Omega. \end{aligned} \quad (1)$$

其中, $z^* = (z_1^*, z_2^*, \dots, z_m^*)^T$ 是参考点,对于任意的 $i = 1, \dots, m$, 有 $z_i^* = \min \{f_i^*(x) | x \in \Omega\}$ ^[3], z_i^* 从几何意义上表示每个坐标轴方向上的最小值,将所有方向的最小值组合成一个参考点。 d_1 代表 $f(x)$ 到理想点的向量投影在 λ 方向上的投影长度,其值越小表示越优,式(2); d_2 表示 $f(x)$ 到 λ 方向的垂直距离,式(3)。 θ 表示一个惩罚约束, θ 的大小决定了了解的分布性和收敛性。 θ 越大,解的分布性越好,保证了种群的多样性; θ 越小,能够更小范围的搜索,收敛效果更优,通常取 $\theta = 5$ 。

$$d_1 = \frac{\| (z^* - F(x))^T \cdot \lambda \|}{\| \lambda \|}, \quad (2)$$

$$d_2 = \| F(x) - (z^* - d_1 \cdot \frac{\lambda}{\| \lambda \|}) \| . \quad (3)$$

对于一些比较复杂 PF 问题,传统的 PBI Approach 方法会丢失一些平缓解,导致解的分布不均匀,本文针对这个不足提出了改进的 PBI Approach (Improvement PBI Approach)。在种群迭代过程中,为了让个体和参照点的距离越来越小,个体逼近参照点形成的超平面即可达到效果。 $w = (1, 1, \dots, 1)^T$ 表示该超平面的法向量。 d_1 表示目标点 $F(x)$ 投影在从 Pareto 前沿出发的沿 w 方向的投影点到参考点的距离,式(4); d_2 表示目标点 $f(x)$ 到 w 的距离,式(5)。

$$d_1 = \frac{\| (F(x) - P - z^*)^T \cdot w \|}{w}, \quad (4)$$

$$d_2 = \| F(x) - P - (z^* + d_1 \cdot \frac{w}{\| w \|}) \| . \quad (5)$$

如果参照点边界点沿着法向量穿过 POF,落在 POF 上的交点就会变成 POF 的边界点,那么交点以上的部分就会被舍弃,破坏了解的整体分布效果。为了使得到的解有较好的分布,就需要让 POF 上的点落在超平面上的投影点都分布在第一象限,所以超平面和目标都需要改动。对于每一个目标,其落在超平面的投影点为 $f(x) = (f_1(x), f_2(x), \dots, f_m(x))$, 而补足位移 $d = (d_1, d_2, \dots, d_m)$ 就是每个投影点在每一个目标分量上的最小值,式(6)。

$$d_i = \min_{x \in F} f_i(x), i \in \{1, 2, \dots, m\}. \quad (6)$$

根据补足位移来移动超平面就会达到实验效果,使得转换后的目标解的边界值也能落在超平面上。

1.2 NSGA-II 算法

NSGA-II 是一种非支配排序算法。对于大多数问题,提出一个选择算子,该算子通过组合父代和后代种群,选择最佳的 N 个解决方案(根据适应度和分布)来创建新的种群空间。董骏峰研究的一种个体领域的构建方法,采用相应的淘汰策略,使得求出的解集有更好的分布性和良好的收敛性^[12];Elarbi, M.提出了新的基于分解优势关系来处理多目标优化问题,将 RP 支配地位替换为 Pareto 支配地位^[13];Zhichao Lu 提出的 NSGA-Net,以贝叶斯网络的形式找到具有竞争力的神经网络结构,探索潜在的神经网络体系结构的空[14]。

NSGA-II 的快速非支配排序将种群按照支配等级全部划分,在同一等级的非支配解中,利用拥挤度使得解在目标空间中分布均匀,式(7)。

$$n_d = n_d + (f_m(i+1) - f_m(i-1)) / (f_m^{\max} - f_m^{\min}). \quad (7)$$

其中, f_m^{\max} 和 f_m^{\min} 分别表示所有个体在第 m 个目标方向的分量的最大值和最小值; $f_m(i+1)$ 表示在当前等级中第 i 个点的后一个目标值; $f_m(i-1)$ 表示在当前非支配解中第 i 个点的前一个目标值, 当前非支配解中的前后两个边界的拥挤度都为 ∞ 。

在种群中先按照 Pareto 等级由低到高排列。在同一 Pareto 等级的个体按照拥挤度大小从大到小依次放入父代种群, 直到父代种群个体数量饱和为止, 至此新一代的父代种群生成。新的父代种群生成后, 开始新一轮的选择交叉和变异, 生成子代种群, 父子代种群合并, 进行快速非支配排序, 根据排序结果计算拥挤度, 选择合适个体组成新父代种群, 一直迭代到满足最大迭代种群数时停止迭代。

NSGA-III 算法是在 NSGA-II 的基础上的改进, NSGA-II 算法的选择策略主要根据拥挤度, 在高维目标中效果不明显。NSGA-III 加入了一组预先定义的参考点, 使用权重向量生成方法, 针对超平面生成均匀分布的权重向量。 M 是优化目标的个数, 对于每个优化目标, 沿着维度方向划分 H 份, 那么参考点的数量为式(8):

$$baseSize = C_{H+m-1}^{m-1}. \quad (8)$$

选定参考点, 借助参考点找到其对应的近似 Pareto 最优解。

1.3 偏好向量的参考机制

基于参考点的多目标进化算法 MOEAs 大都通过参考点来测量群体质量的好坏。在基于参考方向的强度 Pareto 进化算法中, 基于参考向量的局部适应度分配方案保留了该子区域中最有希望的个体。最近, 田调整参考点的位置, 以保持极端点和解决方案, 以实现更好的多样性^[16]; 金飞飞在决策过程尽可能多地保留决策者的偏好信息, 基于得分函数定义由于偏好关系, 在有序一致性的情况下, 选择最优的决策方案^[17]。在设计偏好多目标优化算法时, 应该考虑的重点包括如何保证偏好区域的可控性以及分布性。

本文提出的算法在种群初始化之前, 根据目标维度的大小生成了均匀分布的权重向量, 第一层的偏好向量和偏好范围由决策者规定, 通过与偏好向量相互作用, 使得权重向量分布在偏好向量的交互半径内。第一次的偏好向量在一定的迭代次数内保持不变, 当达到改变条件后, 选取当前迭代种群的最优解作为第二次的偏好, 再次将更新后的权重向量

向偏好方向转移。

初始设置: r 表示交互范围; 决策者给定的 λ_{ref} 是偏好方向; λ_i 为初始化之后均匀分布的权重向量; λ_i' 为第一层交互所需权重向量, 式(9)。

$$\lambda_i' = \frac{\lambda_{ref} + r \cdot (\lambda_i - \lambda_{ref})}{\|\lambda_{ref} + r \cdot (\lambda_i - \lambda_{ref})\|}. \quad (9)$$

在迭代次数满足一定条件后, 选择当前种群中最符合偏好的解作为再次进化的新的偏好方向。在更新后的偏好向量的指导下, 利用偏好向量和新的权重向量的夹角, 权重向量越靠近偏好方向, 两者之间的夹角就越小, 权重向量会被选择再次进入进化部分的几率越高, 式(10)。

$$\cos(\theta_i) = \frac{\lambda_{newref} \cdot \lambda_i'}{\|\lambda_{newref}\| \cdot \|\lambda_i'\|}. \quad (10)$$

得到的值越大, 说明距离偏好向量越近, 越有机会被选取。

1.4 RP 策略

为了产生更加有效的参照点, 覆盖率更大, 参照点在生成时需要进行动态调整。需要把一些无效的参照点舍去, 在参照点密度高的区域重新生成参考点, 新生成的参考点根据第一次交互产生的最优解作为偏好参考, 再次进行偏好调整。

重新生成的参考点数量, 式(11)^[18]:

$$baseSize = C_{H+m-1}^{m-1}. \quad (11)$$

再次生成新的 H 值, 式(12):

$$H = \operatorname{argmin}_H C_{H+m-1}^{m-1} \geq N \times baseSize / |R_p|. \quad (12)$$

其中, N 代表种群大小, R_p 表示附近有解的参照点个数。 H 值如果满足公式(12), H 即可确定下来, 新生成的参照点数量也可确定。

2 算法设计

在该算法中, 初始化种群数量 N 以及初始的权重向量和理想点位置、移动位移。在迭代次数未达到的情况下, 每次迭代生成的新个体, 通过个体选择, 将一部分子代种群和父代种群统一起来, 形成新种群。根据新种群中经过环境选择之后的个体动态调整参考点得到均匀分布的解。算法描述如下:

算法 NSGA-RPIPBI: Framework of the NSGA-RPIPBI procedure

输入: 种群迭代大小, 优化问题 MOP

输出: Pareto 非支配解

1: 初始化: 初始化权重向量 W , 初始化种群 N , 得到初始理想点 z^* 和移动位移 d

2: *while* $ItrCounter < MaxItrCounter$ *do* (迭代

次数未达到)

3: $Individual = Recombination + Mutation$
(交叉变异进化生成新个体)

4: $R_{ItrCounter} = N \cup Individual$ (合并子代种群和父代种群)

5: $P_{ItrCounter} = EnvironmentSelection(R_{ItrCounter})$
(进行环境选择)

6: $AdjustingReferencePoints$ (根据新种群调整参考点)

7: $ItrCounter ++$

8: $end\ while$

9: $return\ P_{ItrCounter}$

3 仿真实验及分析

3.1 参数设置

本实验研究的多目标数量即目标维度设定为基数 3 至 5;同时初始化种群数量,种群规模设定为 300 至 500;参数 Mr 用来控制迭代次数,得到相对精准的超平面;参数 fr 表示动态参数调整的次数,需要适当的参数调整,得到更好的参照点;父代种群通过交叉变异操作形成子代种群。具体参数值设置见表 1。

表 1 参数设置

Tab. 1 Parameter settings

参数	参数值	备注
目标维度	3/5	
种群规模	300/500	
Mr	0.7	和 fr 共同作用
fr	0.05	控制 RP 操作执行的频率
交叉概率	$P_c = 1.0$	
突变概率	$P_m = 1/N$	
θ	5	

3.2 算法性能评价指标

分布性 (Distribution): 衡量算法得到的解在 Pareto 前沿上面的分布情况,是否能够均匀分布,以及是否覆盖到整个 Pareto 前沿。

收敛性 (Convergence): 衡量算法得到的解与真实的 Pareto 前沿的距离^[19],距离越小,逼近程度越好。

反向代间距离 IGD (Inverted Generational Distance): 表示真实 Pareto 前沿中每个解到近似解中所有解的欧氏距离的最小值。IGD 越小,表示得到的解的收敛效果和分布效果更好。

3.3 算法性能测试对比

种群迭代次数 = 500,目标维数 = 3

(1)NSGA-RPIPBI 测试结果。随着迭代次数

的增加,目标曲线越来越趋于稳定,如图 1 所示。

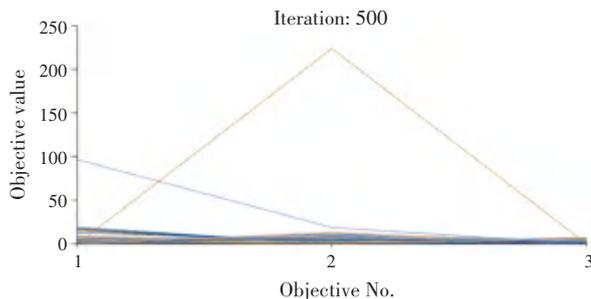


图 1 NSGA-RPIPBI 测试结果

Fig. 1 Test result of NSGA-RPIPBI

(2)NSGA-II 测试结果。算法后期收敛效果不能一直保持,如图 2 所示。

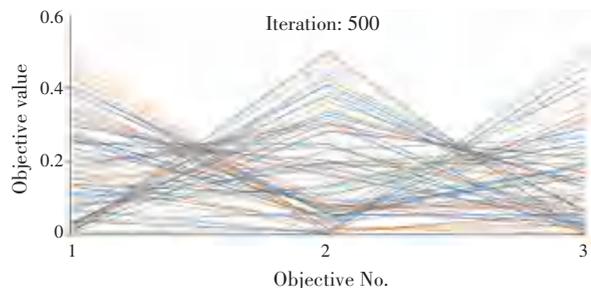


图 2 NSGA-II 测试结果

Fig. 2 Test result of NSGA-II

(3)MOEA/DD 算法测试结果。MOEA/DD 在 100 代之后没有明显的优化,如图 3 所示。

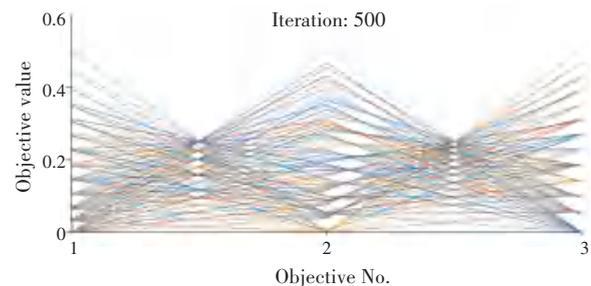


图 3 MOEA/DD 测试结果

Fig. 3 Test result of MOEA/DD

种群迭代次数 = 300,目标维数 = 5

(1)NSGA-RPIPBI 测试结果。种群迭代结果越来越稳定,并且收敛性一直保持良好,如图 4 所示。

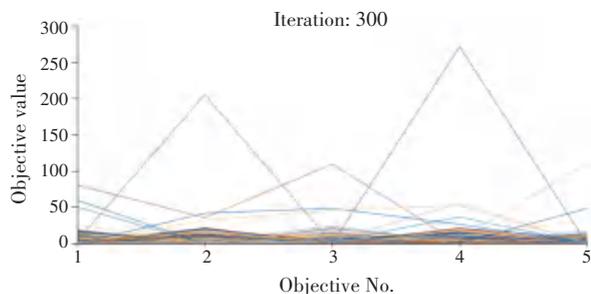


图 4 NSGA-RPIPBI 测试结果

Fig. 4 Test result of NSGA-RPIPBI

(2) NSGA-II 测试结果。迭代达到一定次数后,收敛性不能得到保证,如图5所示。

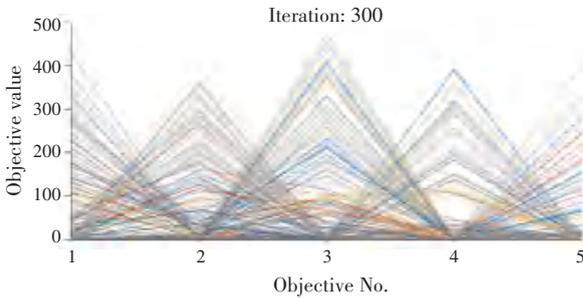


图5 NSGA-II 测试结果

Fig. 5 Test result of NSGA-II

(3) MOEA/DD 测试结果。迭代达到一定次数后,收敛性不能得到保证,如图6所示。

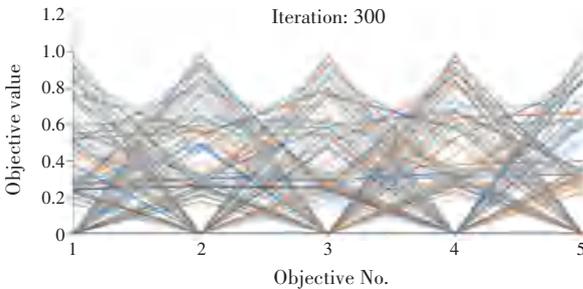


图6 MOEA/DD 测试结果

Fig. 6 Test result of MOEA/DD

通过对比测试结果,NSGA-RPIPBI 相比较 NSGA-II 和 MOEA/DD 来说,得到的解更加靠近真实的最优解,同时 NSGA-RPIPBI 收敛效果更好,收敛速度更快。通过动态调整参照点,NSGA-RPIPBI 的优势就是能够保证全局的参照点是均匀分布的,通过这些参照点得到的解也是均匀分布的,所以对于真实的最优解来说,会更加具有参考价值。

4 结束语

本文为了得到更加分布均匀的解和选择带有偏好机制的解集,提出了偏好分解的多目标优化算法 NAGA-RPIPBI。该算法利用分解算法得到均匀分布的权重向量,同时加入决策者的偏好信息,引导得到的解向 POF 收敛,更好地体现解的收敛;同时针对 NSGA-II 在复杂前沿分布不均匀的问题也提出了改进。通过移动超平面,增加了覆盖最优解的区域。最后,通过在测试函数上的对比实验,NAGA-RPIPBI 比 NSGA-II 和 MOEA/DD 算法展示出了更好的收敛性和稳定性。

参考文献

[1] DEB K. A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.

[2] ZHANG Qingfu, LI Hui. MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition [J]. IEEE Transactions on Evolutionary Computation, 2007, 11, (6): 712-731.

[3] MOLINA, JULIÁN, et al. G-Dominance: Reference Point Based Dominance for Multiobjective Metaheuristics [J]. European Journal of Operational Research, 2009, 197(2): 685-692.

[4] 王丽萍,章鸣雷,邱飞岳,等. 基于角度惩罚距离精英选择策略的偏好高维目标优化算法[J]. 计算机学报,2018,41(1):236-253.

[5] 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, 2013, 18(4): 577-601.

[6] YUAN Y, XU H, WANG B, et al. A new dominance relation-based evolutionary algorithm for many-objective optimization [J]. IEEE Transactions on Evolutionary Computation, 2015, 20(1): 16-37.

[7] JIANG Shouyong, YANG Shengxiang. A Strength Pareto Evolutionary Algorithm Based on Reference Direction for Multi-objective and Many-objective Optimization [J]. IEEE Transactions on Evolutionary Computation, 2017, 21(3): 329-346.

[8] LI Ke, DEB Kalyanmoy, ZHANG Qingfu, et al. An Evolutionary Many-Objective Optimization Algorithm Based on Dominance and Decomposition [J]. IEEE Transactions on Evolutionary Computation, 2015, 19(5): 694-716.

[9] 李明峰,王胜正,谢宗轩. 恶劣气象海况下船舶航线的多变量多目标优化建模[J]. 中国航海,2020,43(2):14-19,30.

[10] LI X, MA S. Multiobjective discrete artificial bee colony algorithm for multiobjective permutation flow shop scheduling problem with sequence dependent setup times [J]. IEEE Transactions on Engineering Management, 2017, 64(2): 149-165.

[11] 王原,马力,王凌,等. 智能机器人可变参数群体控制模型的多目标优化方法[J]. 中国科学:技术科学,2020,50(5):526-537.

[12] 董骏峰,王祥,梁昌勇. 基于个体邻域的改进 NSGA-II 算法 [J]. 计算机工程与应用,2019,55(5):166-174.

[13] ELARBI M, BECHIKH S, GUPTA A, et al. A new decomposition-based NSGA-II for many-objective optimization [J]. IEEE transactions on systems, man, and cybernetics: systems, 2017, 48(7): 1191-1210.

[14] LU Z, WHALEN I, BODDETI V, et al. Nsga-net: neural architecture search using multi-objective genetic algorithm [C]// Proceedings of the Genetic and Evolutionary Computation Conference. 2019: 419-427.

[15] Indraneel Das, DENNIS J E. Normal-Boundary Intersection: A New Method for Generating the Pareto Surface in Nonlinear Multicriteria Optimization Problems [J]. Siam Journal on Optimization, 1998, 8(3): 631-657.

[16] TIAN Y, CHENG R, ZHANG X, et al. An Indicator Based Multi-Objective Evolutionary Algorithm with Reference Point Adaptation for Better Versatility [J]. IEEE Transactions on Evolutionary Computation, 2017, PP(99): 1-1.

[17] 金飞飞,倪志伟. 基于犹豫模糊偏好关系的雾霾影响因素评价 [J]. 模式识别与人工智能,2015,28(9):839-847.

[18] HALIM Z. Optimizing the minimum spanning tree-based extracted clusters using evolution strategy [J]. Cluster Computing, 2018, 21(1): 377-391.