

求解高维混合指标优化问题的交互式进化计算

郭广颂¹, 陈良骥², 文振华³, 张 勇⁴

(1. 郑州航空工业管理学院智能工程学院, 河南郑州 450046; 2. 天津工业大学机械工程学院, 天津 300387;
3. 郑州航空工业管理学院航空工程学院, 河南郑州 450046; 4. 中国矿业大学信息与控制工程学院, 江苏徐州 221116)

摘 要: 同时存在区间显式指标和模糊隐式指标的高维混合指标优化问题是一类难以求解的不确定多目标优化问题. 针对该问题, 首先, 分别对高维显式指标和隐式指标的主要参数按确定性多目标优化, 根据获得的相关权值, 将高维显式指标和高维隐式指标分别降维成一维等效区间适应值和一维等效模糊适应值, 二者合成个体等效指标体; 然后, 依据等效指标体的占优情况, 通过确定自适应参考点和偏好区域面积选择个体; 最后, 在大规模种群 NSGA-II 范式下, 采用隐式指标估计策略和种群聚类方法实现交互式进化优化算法. 将本文算法应用于 2 种混合性能指标优化问题, 验证所提算法的有效性和泛化性.

关键词: 进化优化; 混合性能指标; 遗传算法; 交互

中图分类号: TP301 **文献标识码:** A **文章编号:** 0372-2112 (2020)07-1361-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.07.015

Solving Multidimensional Optimization Problems with Hybrid Indices by Interactive Evolutionary Computation

GUO Guang-song¹, CHEN Liang-ji², WEN Zhen-hua³, ZHANG Yong⁴

(1. School of Intelligent Engineering, Zhengzhou University of Aeronautics, Zhengzhou, Henan 450046, China;

2. School of Mechanical Engineering, Tianjin Polytechnic University, Tianjin 300387, China;

3. School of Aeronautical Engineering, Zhengzhou University of Aeronautics, Zhengzhou, Henan 450046, China;

4. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China)

Abstract: The multidimensional hybrid indices optimization problem is a kind of uncertainty multi-objective optimization problems that is difficult to solve. First, we can get relevant weights by optimizing the main parameters of explicit and implicit indices. According to these weights, multidimensional explicit indices can be reduced to an equivalent-interval fitness, and multidimensional implicit indices can be reduced to an equivalent-fuzzy fitness. Equivalent-interval fitness and equivalent-fuzzy fitness can be synthesized to an equivalent-index body. Then, we select advantage individual on the basis of equivalent-index bodies dominant situation according to adaptive reference point and preference area size. Finally, we adopt an implicit-indices estimation strategy with cluster method to realize interactive evolutionary algorithm within the framework of NSGA-II. The proposed algorithm is applied to two optimization problems with hybrid indices, and the results validate its efficiency and generalization.

Key words: evolutionary optimization; hybrid indices; genetic algorithms; interaction

1 引言

融入偏好的交互式多目标优化 (Interactive Multiobjective Optimization, IMO) 问题是近年进化优化领域的热点研究方向之一^[1]. 优化问题中能够用明确定义的函数表示的性能指标称为显式指标 (也称为定量指标); 不能用明确定义的函数表示的性能指标称为隐式指标 (也称为定性指标). 优化过程中同时存在显式指

标和隐式指标的 IMO 问题称为混合指标优化问题^[2]. 高维混合指标优化问题的两类性能指标维数多于 3 个, 且指标形式也大多不同, 这是一类复杂的混合指标优化问题, 该问题广泛存在于配电系统^[3]、装配线平衡设计^[4]、设施布局优化^[5]等应用领域.

对于混合指标优化问题的相关研究主要集中于 3 个方面: (1) 融入偏好. 混合指标优化问题采用交互式融入决策者偏好, 可以为决策者提供性能更佳的最

优解. 结合交互式进化计算的可视化技术^[6], 交互式偏好融入方式允许对多个维度的隐式指标直接做出评价. 但受易疲劳性限制, 交互规模不能太大, 这又会影响求解效率和优化解的质量^[7]. 所以, 简便的偏好表达方式和有效的偏好融入策略是提高混合指标优化算法性能的关键技术. (2) 目标缩减. 将不确定性多目标问题转化为确定性多目标或单目标问题是求解混合指标优化问题的基本思想^[2], 但该方法仅针对一维混合指标采用单目标线性规划求取目标权值, 并未考虑高维混合指标的降维情况. 所以, 开发合理的多目标缩减与降维策略是提高优化解质量的关键技术. (3) 个体比较. 确定合理的个体占优关系, 能加强算法对知识的挖掘能力. IMO 问题的个体比较主要有分类比较^[7]、成对比较^[8]和最满意解选择^[9]3 种. LopezJaimes 等根据给定的参考点, 基于成就标量函数确定偏好区域, 并利用该区域确定个体之间的占优关系^[10]. 文献[11]使用偏好锥消除非首选候选解, 同时推进算法逼近最大梯度方向, 增加进化搜索能力. 但文献[10, 11]均针对于确定性一维 IMO 问题, 对于高维混合指标优化问题并不适用. 有研究认为, 混合指标交互式进化优化问题的研究趋势是在遵循审慎原则的同时, 优化中应包含所有可兼容的偏好模型^[12].

综上, 本文以高维区间显式指标和模糊隐式指标的混合指标优化问题为研究对象, 开发其交互式进化求解方法. 本文的创新之处是: (1) 提出了新的指标降维策略; (2) 提出了新的基于自适应参考点的个体比较方法; (3) 提出了新的指标占优准则. 另外, 相比一维混合指标优化问题, 本文研究的高维混合指标优化问题更为复杂, 至今还没有交互式进化求解方法.

2 高维混合性能指标优化问题模型

考虑如下—类混合性能指标优化问题:

$$\begin{aligned} \min: & f_1(x, c_1), f_2(x, c_2), \dots, f_p(x, c_p) \\ \max: & \tilde{f}_{p+1}(x), \tilde{f}_{p+2}(x), \dots, \tilde{f}_{p+q}(x) \\ \text{s. t.} & x \in S \subseteq \mathbb{R}^n \\ & c_i = (c_{i1}, c_{i2}, \dots, c_{il})^T, c_{ik} = [\underline{c}_{ik}, \bar{c}_{ik}], k = 1, 2, \dots, l \end{aligned} \quad (1)$$

式中: x 为 n 维决策变量; S 为 x 的可行域; $f_i(x, c_i)$ ($i = 1, 2, \dots, p$) 为含区间参数的显式性能指标对应的目标函数, c_i 为区间向量参数, 其中, c_{ik} 为 c_i 的第 k 个分量; $\tilde{f}_j(x)$ ($j = p+1, p+2, \dots, p+q$) 为隐式性能指标, 是用户对进化个体满足程度的定性评价, 其值为模糊数, 其中心值为 $f_j(x)$, 模糊支集下限为 $\underline{f}_j(x)$, 上限为 $\bar{f}_j(x)$. 为简化计算, 本文采用线性函数描述模糊数 $\tilde{f}_j(x)$, 记为 $(\underline{f}_j(x), f_j(x), \bar{f}_j(x))$. $f_i(x, c_i)$ 和 $\tilde{f}_j(x)$ 在目标空间构成指标超体, 图 1 表示了个体 x 的显式指标与隐式指标各

为 1 个时的指标超体情况.




图1 目标空间性能指标超体

3 算法总体框架

本文算法基于 NSGA-II 框架实现, 如算法 1 所示. 首先, 通过个体相似性对种群聚类; 其次, 在各聚类子集内计算/估计显式指标和隐式指标; 然后, 将混合指标降维至 2 维等效指标体, 通过等效指标体占优选择个体; 最后, 基于序值对种群个体排序, 生成新种群. 可以看出, 本文方法有 3 个关键技术: 个体隐式指标估计 (第 13 行); 种群个体混合指标降维 (第 15 行), 以及基于等效指标体的个体占优选择 (第 18 行). 下面对此做详细介绍.

算法1 本文算法框架

```

01 Data:  $P, N, p, c, p_m, T$ 
02 Result: 本文算法
03 Step1 初始化种群  $p(t)$ 
04  $t \leftarrow 0$ ;
05 while  $t < T$  do
06 Step2 用户评价个体
07   for  $i \leftarrow 1$  to  $Ac$  do
08      $p(t) \leftarrow f_i(x_i(t))$ ;
09   end
10 Step3 种群聚类, 生成聚类子集  $Ar$ 
11    $p(t) \leftarrow Ar$ ;
12 Step4 计算聚类子集内剩余个体显式与隐式指标
13    $p(t) \leftarrow \text{explicit-tacit-indices}(Ar)$ ;
14 Step5 对种群个体混合指标降维, 生成等效指标体
15    $p(t) \leftarrow \text{reduce-indices-dimension-pop}(p(t))$ ;
16 Step6 按等效指标体占优选择个体, 生成临时种群  $p'(t)$ ,
    合并种群, 获得非支配序值
17   for  $i \leftarrow 1$  to  $N$  do
18      $p'(t) \leftarrow \text{selection-crossover-mutation-pop}(p(t))$ ;
19      $Q(t) = p(t) \cup p'(t)$ ;
20      $F \leftarrow \text{fast-non-dominated-sort}(Q(t))$ ;
21   end
22 Step7 计算  $F_i$  个体拥挤距离,
23   repeat
24      $F_i \leftarrow \text{crowding-distance-assignment}(F_i)$ 
25   until  $|p^{(t+1)}| + |F_i| \leq N$ 
26 Step8 选择  $p^{(t+1)}$  的前  $Ac$  个个体推荐给用户评价
27    $Ac(t+1) \leftarrow p^{(t+1)}[1:Ac]$ ;
28 end while

```

4 隐式指标估计

4.1 隐式指标意义的个体相似度

针对优化目标的复杂性,采用大规模种群进化策略会更有利于获得高质量优化解.在大规模种群进化中,个体 x_i 与参照个体 x_j 的第 $q', p+1 < q' \leq p+q$ 维隐式指标意义相似度记为 $\mu^{q'}(x_i, x_j)$,具体计算方法可见文献[13]. $\mu^{q'}(x_i, x_j)$ 中参照个体 x_j 的 q' 维模糊适应值支集宽度 $\delta^{q'}(x_j)$ 的计算是关键.菲茨定律阐明,用户指向目标所需时间越短,用户对目标就越感兴趣^[14].所以,评价时间与模糊适应值之间存在密切联系.设 $\delta^{q'}(x_j)$ 取值范围为 $[\delta_{\min}, \delta_{\max}]$, $T^{q'}(x_j)$ 为个体 x_j 的 q' 维隐式指标评价时间.则 $\delta^{q'}(x_j)$ 可以用 Tan 函数表示为:

$$\delta^{q'}(x_j) = \delta_{\min} + \frac{e^{T^{q'}(x_j)} - e^{-T^{q'}(x_j)}}{e^{T^{q'}(x_j)} + e^{-T^{q'}(x_j)}} \cdot (\delta_{\max} - \delta_{\min}) \quad (2)$$

由式(2)可见, $T^{q'}(x_j)$ 越大,即用户对个体评价时间越长,评价结果模糊程度越高, $\delta^{q'}(x_j)$ 越大;反之, $T^{q'}(x_j)$ 越小,评价结果模糊程度越小, $\delta^{q'}(x_j)$ 就越小.

4.2 模糊适应值估计

受人的疲劳性限制,种群所有个体的隐式指标不可能完全由用户评价.所以,需要估计聚类子集的剩余个体隐式指标.设 x_{Ar} 是聚类子集 $Ar(t)$ 的聚类中心个体,其 q' 维模糊适应值 $\tilde{f}_{q'}(x_{Ar})$ 由用户评价. $x_i, i = 1, 2, \dots, |Ar(t)| - 1$ 是 $Ar(t)$ 内剩余个体.假设 $\hat{\Delta}_{q'}(x_i)$ 是 x_i 的 q' 维隐式指标估计值,显然, x_i 和 x_{Ar} 的相似程度越低,则 $\hat{\Delta}_{q'}(x_i)$ 与 $\tilde{f}_{q'}(x_{Ar})$ 的差异就越大.根据模糊适应值特点, $\hat{\Delta}_{q'}(x_i)$ 估计应包含模糊中心值和模糊支集宽度 2 部分. $\hat{\Delta}_{q'}(x_i)$ 的模糊中心值 $f_{q'}(x_i)$ 和模糊支集宽度 $\delta^{q'}(x_i)$ 计算方法可参阅文献[13].

5 混合指标的降维

记 x_i 的第 j 个显式指标值为 $f_j(x_i, c_j)$, $f_j(x_i, c_j)$ 归一化后的下限与上限值为 $\underline{f}_j'(x_i, c_j)$ 和 $\bar{f}_j'(x_i, c_j)$. 由于问题(1)要求显式指标最小,同时考虑优化结果应具备最小的不确定性,因此,显式指标的降维问题可以转化为如下约束优化问题:

$$\begin{aligned} \min f 1 &= \sum_{i=1}^{|Ar(t)|} \sum_{j=1}^p \text{mid}([f_j'(x_i, c_j), \bar{f}_j'(x_i, c_j)]) w_j^1 \\ f 2 &= \sum_{i=1}^{|Ar(t)|} \sum_{j=1}^p R([f_j'(x_i, c_j), \bar{f}_j'(x_i, c_j)]) w_j^1 \\ \text{s. t.} \quad & \underline{w}_j^1 \leq w_j^1 \leq \bar{w}_j^1 \\ & \sum_{j=1}^p w_j^1 = 1 \end{aligned} \quad (3)$$

式中, $\text{mid}([f_j'(x_i, c_j), \bar{f}_j'(x_i, c_j)])$ 为区间数 $[f_j'(x_i, c_j), \bar{f}_j'(x_i, c_j)]$ 的中点值, $R([f_j'(x_i, c_j), \bar{f}_j'(x_i, c_j)])$ 为区间数 $[f_j'(x_i, c_j), \bar{f}_j'(x_i, c_j)]$ 的半径. 求解上式,可以得到一组优化后的权值 $w_1^1, w_2^1, \dots, w_p^1$, 对于 x_i 的所有显式指标 $f_j(x_i, c_j)$ ($j = 1, 2, \dots, p$) 可以加权为一个区间数 $[\sum_{j=1}^p f_j'(x_i, c_j) w_j^1, \sum_{j=1}^p \bar{f}_j'(x_i, c_j) w_j^1]$, 称为等效显式区间适应值,记为 $f(x_i, c_j)$. 类似地,记 x_i 的第 j 个隐式指标值 $\tilde{f}_j(x_i)$ 的中心值为 $f_j(x_i)$, $f_j(x_i)$ 归一化后的值为 $\underline{f}_j'(x_i)$; $\tilde{f}_j(x_i)$ 的支集下限和上限为 $\underline{f}_j'(x_i)$ 和 $\bar{f}_j'(x_i)$, 其归一化后的值为 $\underline{f}_j'(x_i)$ 和 $\bar{f}_j'(x_i)$. 由于问题(1)要求隐式指标最大,同时考虑优化结果应具备最小的不确定性,因此,隐式指标的降维问题可以转化为如下约束优化问题:

$$\begin{aligned} \max f 3 &= \sum_{i=1}^{|Ar(t)|} \sum_{j=p+1}^{p+q} f_j'(x_i) w_j^2 \\ f 4 &= - \sum_{i=1}^{|Ar(t)|} \sum_{j=p+1}^{p+q} \delta \tilde{f}_j'(x_i) w_j^2 \\ \text{s. t.} \quad & \underline{w}_j^2 \leq w_j^2 \leq \bar{w}_j^2 \\ & \sum_{j=p+1}^{p+q} w_j^2 = 1 \end{aligned} \quad (4)$$

式中, $f_j'(x_i)$ 为模糊数 $\tilde{f}_j'(x_i)$ 的中心值, $\delta \tilde{f}_j'(x_i)$ 为模糊数 $\tilde{f}_j'(x_i)$ 的模糊支集宽度. 求解上式,可以得到一组优化后的权值 $w_{p+1}^2, w_{p+2}^2, \dots, w_{p+q}^2$, 对于 x_i 的所有隐式指标 $\tilde{f}_j(x_i)$ ($j = p+1, p+2, \dots, p+q$), 可以加权近似为一个三角形模糊数 $(\sum_{j=p+1}^{p+q} \underline{f}_j'(x_i) w_j^2, \frac{1}{q} \sum_{j=p+1}^{p+q} f_j'(x_i) w_j^2, \sum_{j=p+1}^{p+q} \bar{f}_j'(x_i) w_j^2)$, 称为等效隐式模糊适应值,记为 $\tilde{f}(x_i)$. 这样, $f(x_i, c_j)$ 和 $\tilde{f}(x_i)$ 就构成个体 2 维等效指标体. 由于用户评价的适应值分布特征不可能事先知道,所以,采用本文方法对个体的隐式指标降维后,子集内个体一般具有不同的模糊中心值和不同的模糊支集.

6 个体选择策略

6.1 混合性能指标个体占优情况

本节基于指标占优关系选择个体.采用文献[15]的“区间可能度”刻画显式指标为区间数的占优关系,定义如下:

定义 1 对于问题(1)的 2 个解 x_1 和 x_2 , 其对应的显式指标为区间数 $f_i(x_1, c_i) = [f_i(x_1, \underline{c}_i), f_i(x_1, \bar{c}_i)]$ 和 $f_i(x_2, c_i) = [f_i(x_2, \underline{c}_i), f_i(x_2, \bar{c}_i)]$, $i = 1, 2, \dots, p$, 其中 $f_i(x_1, \underline{c}_i)$, $f_i(x_2, \underline{c}_i)$ 和 $f_i(x_1, \bar{c}_i)$, $f_i(x_2, \bar{c}_i)$ 分别为 $f_i(x_1, c_i)$ 和 $f_i(x_2, c_i)$ 的下限和上限. 记 $f_i(x_1, c_i)$ 小于 $f_i(x_2, c_i)$ 的可能度为 $\sigma(x_1, x_2, i)$, 则

$$\sigma(x_1, x_2, i) = p(f_i(x_1, c_i) < f_i(x_2, c_i)) \quad (5)$$

类似地, $f_i(x_1, c_i)$ 大于 $f_i(x_2, c_i)$ 的可能度为 $\sigma(x_2, x_1, i)$

$$\sigma(x_2, x_1, i) = p(f_i(x_2, c_i) < f_i(x_1, c_i)) \quad (6)$$

容易验证, $\sigma(x_1, x_2, i) + \sigma(x_2, x_1, i) = 1$.

采用“模糊数贴近度”刻画隐式指标为模糊数的占优关系, 定义如下:

定义 2 对于问题(1)的 2 个解 x_1 和 x_2 , 其对应的隐式指标为模糊数 $\tilde{f}_j(x_1)$ 和 $\tilde{f}_j(x_2)$. 确定模糊数 c , 记 c 与 $\tilde{f}_j(x_1)$ 和 $\tilde{f}_j(x_2)$ 的贴近度为 $d_1(c, x_1)$ 和 $d_1(c, x_2)$, 如果 $d_1(c, x_1) \geq d_1(c, x_2)$, 则 $\tilde{f}_j(x_1) \leq \tilde{f}_j(x_2)$; 反之, 则

$$\tilde{f}_j(x_1) \geq \tilde{f}_j(x_2).$$

根据 5 节, 问题(1)的 2 个解 x_1 和 x_2 的指标超体可以降低构成 2 维等效指标体. 基于定义 1 和定义 2 确定混合性能指标个体占优情况, 如图 2 所示. 图 2(a) 所示占优情况为当 $f(x_1, c_j) \leq f(x_2, c_j)$, 且 $\tilde{f}(x_1) > \tilde{f}(x_2)$, 则 x_1 占优 x_2 , 记为 $x_1 \succ x_2$; 图 2(c) 所示占优情况为当 $f(x_1, c_j) < f(x_2, c_j)$, 且 $\tilde{f}(x_1) < \tilde{f}(x_2)$, 则 x_1, x_2 互不占优, 记为 $x_1 \parallel x_2$, 其余类推.

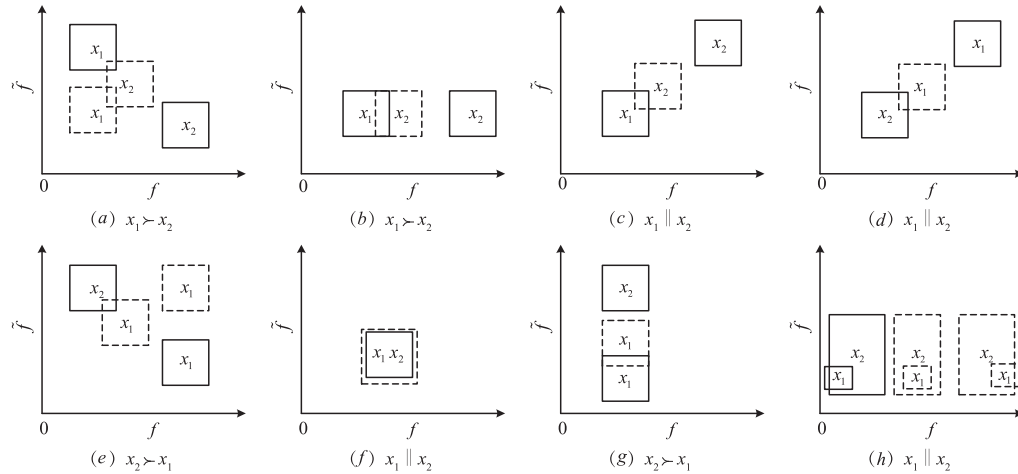


图 2 个体占优情况

6.2 基于自适应参考点的互不占优个体比较策略

由图 2 可知, 当个体可以根据性能指标比较优劣时, 可以直接选择优势个体 (图 2(a)、(b)、(e) 和 (g)). 对于个体互不占优情况 (图 2(c)、(d)、(f) 和 (h)), 本节提出基于自适应参考点的个体比较策略. 即对于问题(1)的 2 个相等序值解 x_1 和 x_2 , 其降维后的显式指标为 $f(x_1, c_j)$ 和 $f(x_2, c_j)$, 隐式指标为 $\tilde{f}(x_1)$ 和 $\tilde{f}(x_2)$, 则 2 个个体的参考点为局部理想点:

$$r_l = \left(\begin{array}{l} |\min\{m(f(x_1, c_j)), m(f(x_2, c_j))\} - \varepsilon(x_1, x_2)|, \\ |\max\{f(x_1), f(x_2)\} + \varepsilon(x_1, x_2)| \end{array} \right) \quad (7)$$

式中, $m(f(x_1, c_j))$ 和 $m(f(x_2, c_j))$ 是 $f(x_1, c_j)$ 和 $f(x_2, c_j)$ 的区间中点值; $f(x_1)$ 和 $f(x_2)$ 是 $\tilde{f}(x_1)$ 和 $\tilde{f}(x_2)$ 的模糊中心值; $\varepsilon(x_1, x_2)$ 为个体 x_1 和 x_2 的距离, 并用于计算个体拥挤距离^[2].

基于自适应参考点的互不占优个体比较方法如图 3 所示. 图中 r_l 是根据式(7)确定的参考点, g_1, g_2 分别是 x_1, x_2 等效指标体的几何中心 (重心). 直角三角形 $\triangle g_1 r_l d_1$ 面积 S_1 和直角三角形 $\triangle g_2 r_l d_2$ 面积 S_2 , 分别构成 x_1, x_2 在目标空间内的偏好区域. 如果 $S_1 > S_2$, 则 $x_1 \succ x_2$; 反之, 则 $x_1 \prec x_2$; 特别地, 当隐式指标无法比较时 (图 2(h)), 可以选择原点为参考点; 如果 $S_1 = S_2$ (图 2(f)), 则任选其中一个个体做为优势个体.




图 3 基于自适应参考点的个体选择

7 性能分析

本文方法主要分三个部分: 种群聚类、聚类子集并行求解和最优个体选择. 在种群聚类时, 需求个体隐式指标的相似性, 计算复杂度为 $O((p+q)Ac)$. 在聚类子集并行求解时, 个体显式指标计算复杂度为 $O(pAc)$, 隐式指标估计的计算复杂度为 $O((p+q)Ac)$, 混合指标降维的计算复杂度为 $O(p(p+q)Ac)$, 具有相同 Pareto 序值个体的自适应参考点计算复杂度为 $O(2Ac \log 2Ac)$. 在最优个体选择时, 指标规模降至 2 维, 则合并种群 $p(t)$ 和 $p'(t)$ 的非被占优解排序时间复杂度为 $O(2N^2)$. 所以, 本文方法的计算复杂度为 $O(2N^2)$. 如果不采用指标降维策略, 直接采用 NSGA-II 时, 每进化一代的计算复杂度为 $O((p+q)N^2)$, $O((p+q)N^2) > O(2N^2)$, 这表明, 本文方法每进化一代, 需要的总的计算复杂度小于 NSGA-II.

8 实验与结果分析

本文采用高维混合指标优化和 1 维混合指标优化等 2 个应用问题,验证所提算法的性能.其中,高维混合指标优化采用室内布局优化问题验证算法的有效性,1 维混合指标优化采用室内挂件外观设计问题验证算法的泛化性.

8.1 在室内布局优化问题中的应用

8.1.1 优化问题与参数设置

本文以室内布局优化问题验证算法的有效性^[2],其中居室的开间 W 和进深 L 已知,取 $W = 12.5\text{m}$, $L = 10\text{m}$.优化目标是:合理计算居室每一部分的开间和进深,布局设计满足用户审美需求,同时要求居室总造价最低,且公摊面积最小.该问题包含 2 个显式指标 $f_1(x, c)$, $f_2(x, c)$ 和 2 个隐式指标 $\tilde{f}_3(x)$, $\tilde{f}_4(x)$.其中, $f_1(x, c)$ 是室内面积造价之和,该指标函数包含 7 个决策变量 $x_1, x_2, x_3, x_4, x_5, x_6, x_7$,每一决策变量的参数是单位面积造价 $c_1 \sim c_7$,受市场因素影响, $c_1 \sim c_7$ 在某一范围内波动. $f_2(x, c)$ 是公摊面积,该指标函数包含 2 个决策变量 x_8, x_9 ,其参数是分摊系数 c_8 和墙体系数 c_9 , $c_8 \in [0.12, 0.16]$, $c_9 \in [0.02, 0.05]$.所以, $f_1(x, c)$, $f_2(x, c)$ 均为区间数. $\tilde{f}_3(x)$, $\tilde{f}_4(x)$ 是用户对室内布局方案的主观评价价值,采用模糊数表示,分别反映用户对“布局尺度最大”和“布局功能最好”两个方面的审美评价.

采用 VB6.0 开发进化优化系统.进化个体采用实数编码.个体表现型属性与基因型属性相同,即 $x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9$ 为个体的 9 个属性, $N_g = 9$.种群规模 $N = 200$,用户评价个体数 $Ac = 12$,交叉概率 $p_c = 0.95$,变异概率 $p_m = 0.01$,最大进化代数 $T = 10$,用户评价模糊适应值中心值范围为 1~99 整数, $\delta_{\min} = 1$, $\delta_{\max} = 99$.进化优化系统人机交互界面如图 4 所示.用户通过样本下方滑动条对个体评价,同时系统通过滑动条下方滑动块记录用户对每个个体的评价时间,该评价时间与用户评价在系统后台用于估计个体模糊适应值.个体显示指标在个体右侧图框中显示.通过进化,系统不断生成新的室内布局方案,直至用户满意.

8.1.2 实验结果分析

为验证算法有效性,基于本文降维策略,采用文献[2]开发的混合指标优化算法(记为方法 1)和基于本文方法,采用小种群的混合指标优化算法(记为方法 2)等 2 种相关算法作为比较算法,分别按上述 3 种方法开发相应系统.其中,方法 1 采用区间适应值表示隐式指标和显式指标.选择年龄 22~25 岁的男女各 5 名在校大学生做为体验用户,分别记为用户 1~10.用户熟悉系统后,每种方法独立运行 20 次.通过分析各方法在算法效率、算法收敛性和 pareto 最优解集 3 个方面的效

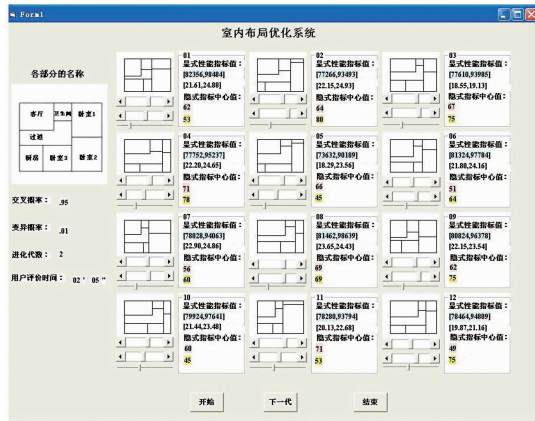


图4 人机交互界面

果,验证本文方法的有效性.

(1) 算法效率

算法效率统计结果如表 1 所示.可以看出,3 种方法的计算机耗时差异不大,但本文方法的计算机耗时与用户耗时大致相同,这说明本文方法能明显提高算法效率.原因在于,一方面本文方法基于高维混合指标优化,搜索信息更为丰富;另一方面本文方法采用 NS-GA-II 做为算法引擎,算法求解能力更强.另外,本文方法的进化代数少于对比方法,表明本文方法收敛速度更快,这既提高了搜索效率,又能减少用户耗时.算法平均成功率采用“二分式”方法计算,可以看到,本文算法的平均成功率最高.

(2) 算法收敛性

算法的收敛性主要通过进化个体适应值体现,图 5 显示了 3 种算法的适应值统计结果.可以看到,3 种算法均能成功收敛.从第 3 代开始,本文方法的显式指标中点值和宽度值变化至 3 种算法的最小值;从第 2 代开始,本文方法的模糊适应值中心值变化至 3 种算法的最大值.模糊适应值支集宽度变化至 3 种算法的最小值.这表明本文方法的优化结果更符合问题(1)的优化要求,优化结果质量更高.与对比方法 2 将所有指标加权为单一指标相比,本文方法的个体选择结果更准确,算法收敛性更好.另外,对 3 种算法性能指标进行显著性水平为 0.05 的 Mann-Whitney U 检验(p 值),结果显示本文方法与对比方法的性能指标差异显著.

(3) pareto 最优解集

表 2 给出了 3 种算法的 pareto 最优解集测度.可以看出,本文方法的最优解数目最多,这说明本文方法能够为用户提供更多的选择样本;本文方法 bH 测度最大,这说明本文方法得到的 pareto 前沿更接近真实 pareto 前沿;本文方法 I 测度最小,说明本文方法得到的 pareto 最优解集不确定性小于对比方法;本文方法 D 测度最小,这意味着本文方法得到的 pareto 最优解集分布

更为均匀. 图 6(a) 给出了本文方法与方法 1 获得的 pareto 前沿, 图 6(b) 给出了本文方法与方法 2 获得的 pareto 前沿. 由图可知, 本文方法求得的 pareto 前沿占优区域大于对比方法, 所以更接近真实的 pareto 前沿; 本

文方法求得的 pareto 前沿面积小于对比方法, 反映出 pareto 前沿不确定度最小; 相比对比方法, 本文方法求得的 pareto 前沿分布更均匀, 延展性更好. 所以, 在 pareto 最优解集方面, 本文方法优于对比方法.

表 1 算法效率

| 算法 | 计算机耗时 | 用户耗时 | 进化代数 | 用户评价个体数 | 搜索的个体数 | 成功率 |
|------|--------|--------|------|---------|--------|-----|
| 本文方法 | 12'23" | 12'49" | 9.4 | 113 | 1880 | 82% |
| 方法 1 | 12'36" | 14'21" | 10 | 120 | 2000 | 76% |
| 方法 2 | 12'45" | 15'36" | 10 | 120 | 2000 | 63% |




图 5 个体性能指标变化

表 2 pareto 最优解集测度

| 算法 | 最优解数 | bH 测度 | I 测度 | D 测度 |
|------|------|----------------------|-------|--------|
| 本文方法 | 10.4 | 4.5257×10^6 | 10398 | 198.35 |
| 方法 1 | 9.2 | 4.3645×10^6 | 12676 | 217.64 |
| 方法 2 | 7.5 | 4.2483×10^6 | 13520 | 268.52 |

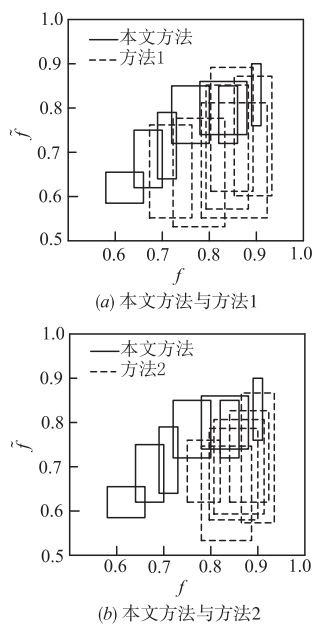


图 6 优化 pareto 前沿

8.2 在室内挂钟外观设计问题中的应用

8.2.1 优化问题与参数设置

本文以室内挂钟设计问题验证算法的泛化性^[13], 该问题包含 1 个“挂钟外观评价”隐式指标和 1 个“挂钟价格”显式指标. 采用基于文献[13]的混合指标优化方法(记为方法 3)和文献[2]的方法(记为方法 4)等 2 种相关算法作为比较算法. 其中, 方法 3 采用模糊适应值表示隐式指标. 分别按上述 3 种方法开发相应系统, 算法参数设置与测试用户情况同 8.1.

8.2.2 实验结果分析

对于混合指标优化问题, 隐式指标估计最能体现算法的适应能力, 所以, 采用隐式指标测试误差验证本文算法的泛化性:

$$\sigma = \sqrt{\frac{1}{T'} \sum_{t=1}^{T'} (\bar{f}(t) - \bar{f}^1(t))^2} \quad (8)$$

式中, $\bar{f}(t)$ 为 8.1 实验第 t 代种群隐式指标均值, $\bar{f}^1(t)$ 为本节实验第 t 代种群平均隐式指标均值, T' 为设定进化代数, 取 $T' = 10$. 该式体现了算法在相同进化代内对不同优化对象隐式指标的估计能力, σ 越小, 算法对新对象的适应能力越强, 泛化性越好.

3 种算法优化结果统计如表 3 所示. 可以看到, 对于不同优化对象, 本文方法隐式指标的模糊中点值和模糊宽度 2 项测试误差均较小, 这表明本文方法具有良好的泛化性. 原因在于, 本文的混合指标优化策略具

有良好的普适性,基于 NSGA-II 引擎对不同多目标优化对象均具有良好的适应性.在算法效率方面,本文方法用户耗时和进化代数仍然最少,成功率最高.由于优化对象相对简单,对比表 1 可见,本节 3 种算法的用户耗时均减少近一半时间,3 种算法成功率均有提高.在 pa-

reto 最优解集测度方面,本文方法 bH 测度最大、I 测度和 D 测度最小,表明 pareto 最优解集分布最均匀.

综合上述,对于高维混合指标和 1 维混合指标 2 种应用对象,本文方法均表现出良好的有效性和泛化性,所以,本文方法可以有效求解高维混合指标优化问题.

表 3 算法优化结果

| 算法 | 隐式指标测试误差 | | 算法效率 | | | pareto 最优解集测度 | | | |
|------|----------|-------|-------|------|-----|---------------|----------------------|-------|--------|
| | 模糊中点值 | 模糊宽度 | 用户耗时 | 进化代数 | 成功率 | 最优解数 | bH 测度 | I 测度 | D 测度 |
| 本文方法 | 3.627 | 3.258 | 6'42" | 8.2 | 87% | 11.2 | 4.9403×10^6 | 11274 | 184.26 |
| 方法 3 | - | - | 7'53" | 10.7 | 86% | 10.5 | 4.2186×10^6 | 13438 | 231.43 |
| 方法 4 | - | - | 8'21" | 11.4 | 85% | 9.5 | 4.1725×10^6 | 14859 | 253.87 |

9 结论

本文针对高维混合指标优化问题提出交互式进化求解方法.进化个体显式指标用区间数表示,隐式指标用模糊数表示.对显式指标和隐式指标分别采取降维策略,构成个体 2 维等效指标体,并按等效指标体占优选择个体.对于序值相同个体,采用基于自适应参考点的偏好区域比较,进一步区分个体优劣.最后,在 2 个应用问题上验证了算法性能.本文研究的混合指标类型只有 2 类,更多类型混合性能指标优化问题的交互式进化求解方法是下一步要研究的问题.

参考文献

- [1] XIN Bin, CHEN Lu, CHEN Jie, et al. Interactive multiobjective optimization: a review of the state-of-the-art [J]. IEEE Access, 2018, 6: 41256 - 41279.
- [2] GONG Dun-wei, LIU Yi-ping, JI Xinfang, et al. Evolutionary algorithms with user's preferences for solving hybrid interval multi-objective optimization problems [J]. Applied Intelligence, 2015, 3: 676 - 694.
- [3] KURODA Ken, MAGORI Hideki, et al. A hybrid multi-objective optimization method considering optimization problems in power distribution systems [J]. Journal of Modern Power Systems and Clean Energy, 2015, 3(1): 41 - 50.
- [4] JONATHAN Oesterle, THOMAS Bauernhansl, LIONEL Amodeo. Hybrid multi-objective optimization method for solving simultaneously the line balancing, equipment and buffer sizing problems for hybrid assembly systems [J]. Procedia Cirp, 2016, 55: 416 - 421.
- [5] FREDERICO Galaxe Paes, ARTUR Alves Pessoa, THIBAUT Vidal. a hybrid genetic algorithm with decomposition phases for the unequal area facility layout problem [J]. European Journal of Operational Research, 2017, 256(3): 742 - 756.
- [6] YAN Pei, HIDEYUKI Takagi. Research progress survey on interactive evolutionary computation [J]. Journal of Ambient Intelligence and Humanized Computing, 2018, 1 - 14.
- [7] 孙靖, 巩敦卫. 进化高维多目标优化研究进展 [J]. 控制理论与应用, 2018, 35(7): 928 - 938.
- [8] SUN Jing, GONG Dun-wei. Recent advances in evolutionary many-objective optimization [J]. Control Theory & Applications, 2018, 35(7): 928 - 938. (in Chinese)
- [8] BRANKE J, GRECO S, SLOWINSKI R, et al. Learning value functions in interactive evolutionary multiobjective optimization [J]. IEEE Transactions on Evolutionary Computation, 2015, 19(1): 88 - 102.
- [9] SINHA A, KORHONEN P, WALLENIUS J, et al. An interactive evolutionary multi-objective optimization method based on polyhedral cones [A]. International Conference on Learning and Intelligent Optimization [C]. Berlin: Springer, 2010. 318 - 332.
- [10] LOPEZ-JAIMES A, COELLO CAC. Including preferences into a multiobjective evolutionary algorithm to deal with many-objective engineering optimization problems [J]. Information Sciences, 2014, 277: 1 - 20.
- [11] SINHA A, MALO P, KALLIO M. Convex preference cone-based approach for many objective optimization problems [J]. Computers & Operations Research, 2018, 95: 1 - 11.
- [12] BRANKE J, CORRENTE S, GRECO S, et al. Using Choquet integral as preference model in interactive evolutionary multiobjective optimization [J]. European Journal of Operational Research, 2016, 250(3): 884 - 901.
- [13] 郭广颂, 陈良骥, 文振华, 等. 基于进化个体模糊适应值估计的交互式遗传算法 [J]. 控制与决策, 2018, 33(9): 1559 - 1546.
- [13] GUO Guang-song, CHEN Liang-ji, WEN Zhen-hua, et al. Interactive genetic algorithms based on estimation of individuals' fuzzy fitness [J]. Control and Decision, 2018, 33(9): 1559 - 1546. (in Chinese)
- [14] Fitts P M. The information capacity of the human motor system in controlling the amplitude of movement [J].

Journal of Experimental Psychology, 1954, 47 (6): 381 - 391.

- [15] 高德宝,于辉. 一种新的区间数的比较与排序方法[J]. 统计与决策,2017,(17):39-41.

GAO De-bao, YU Hui. New comparison and ranking method of interval numbers [J]. Statistics & Decision, 2017,(17):39-41. (in Chinese)

作者简介



郭广颂 男,1978 年 9 月生,吉林集安人,副教授、硕导,主要研究方向为进化优化与智能控制.
E-mail: guogs78@126.com



陈良骥(通信作者) 男,1978 年 6 月生,四川邻水人,教授、博士、硕导,主要研究方向为先进制造与智能控制.
E-mail: chenliangji@tjpu.edu.cn