

非线性多目标概率优化问题的 自适应采样免疫优化算法

张仁崇¹, 潘春燕², 武 星³, 杨 坤¹

(1. 贵州商学院计算机与信息工程学院, 贵州贵阳 550014; 2. 黔南民族师范学院数学与统计学院, 贵州都匀 558000;
3. 贵州商学院管理学院, 贵州贵阳 550014)

摘 要: 针对噪声环境下非线性多目标概率优化问题, 提出问题求解的自适应采样免疫优化算法. 在算法设计中, 基于克隆选择原理, 设计小种群的算法进化框架; 提出目标值估计法自适应确定个体的样本大小并估算其目标值; 借助传统快速非支配排序法, 种群被分割成多级非支配子群协同进化; 设计动态交叉分布指数的模拟二进制交叉加强各子群之间的信息交流; 设计动态变异分布指数的多项式变异、均匀变异, 以及自适应变异概率平衡全局、局部探索. 最后, 借助3个理论测试问题、海铁联运能耗优化问题以及9个代表性的比较算法, 数值实验结果表明, 此算法寻优效率优势显著、搜索效果优越、稳定性好.

关键词: 多目标概率优化; 免疫优化; 随机模拟; 自适应采样; 海铁联运

中图分类号: TP301.6 **文献标识码:** A **文章编号:** 0372-2112 (2021)04-0647-14

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20200171

Adaptive Sampling Immune Optimization Algorithm for Nonlinear Multi-Objective Probabilistic Optimization Problems

ZHANG Ren-chong¹, PAN Chun-yan², WU Xing³, YANG Kun¹

(1. Computer and Information Engineering College, Guizhou University of Commerce, Guiyang, Guizhou 550014, China;
2. School of Mathematics and Statistics, Qiannan Normal University for Nationalities, Duyun, Guizhou 558000, China;
3. College of Management, Guizhou University of Commerce, Guiyang, Guizhou 550014, China)

Abstract: In this paper, an adaptive sampling immune optimization algorithm is proposed to solve the nonlinear multi-objective probabilistic optimization problem in noisy environments. In the whole design of the algorithm, we develop an evolutionary framework with small population inspired by the clonal selection principle. The approach for estimating objective value is designed by adaptively determining the sample size of an individual. The population is divided into multi-level non-dominated sub-populations for co-evolution by the traditional fast non-dominated sorting approach. The simulation binary crossover with dynamic crossover distribution index is designed to enhance the information exchanges among all sub-populations. Polynomial mutation and uniform mutation with dynamic mutation distribution index, and adaptive mutation probability are designed to enhance the capability of global and local exploration. Finally, based on three theoretical test questions, energy consumption optimization of sea-rail intermodal transportation and nine representative comparison algorithms, the numerical experiment results show that the algorithm has significant search efficiency, superior search effect and good stability.

Key words: multi-objective probabilistic optimization; immune optimization; stochastic simulation; adaptive sampling; sea-rail intermodal transportation

1 引言

多目标概率优化问题 (Multi-Objective Probabilistic Optimization Problem, MOPOP) 是指多个相互冲突的性能指标满足概率约束限制的随机规划问题. MOPOP 频繁出现在许多工程优化设计中, 例如水资源调度^[1,2]、空降作战^[3]、电网电力协调调度^[4,5]、电动汽车充电站^[6]、服务资源协同调度^[7]等问题. 解决此类问题的主要难点包括三个方面: (1) 随机变量(噪声)一般具有复杂或未知分布, 模型不能转化为解析模型; (2) 目标函数由概率不等式而非确定性函数确定; (3) 随机函数通常是非线性、多模态或非凸. 若已知随机变量的概率分布, MOPOP 在特定条件下可转化为确定性多目标优化模型, 借助静态多目标智能优化算法或传统的规划方法^[8]求解.

然而, 在实际工程优化问题中, 经常出现上述难点 (1) 的情况, 此时传统的规划方法是无效的, 而蒙特卡罗 (Monte Carlo, MC) 随机模拟正是处理此种情况问题的有效工具; 当随机变量的样本大小一旦给定时, 经由 MC 随机模拟可获取 MOPOP 目标函数的估计值, 然后通过智能优化算法求解. MC 随机模拟因其计算程序简单且不受限于随机变量的分布类型的优点而被广泛应用于求解单、多目标随机规划问题; 基于此, 静态采样、动态采样^[9]、自适应采样^[10-17]成为 MC 随机模拟三种具有代表性的样本采样方法. 静态采样要求随机变量的样本大小固定不变, 方法简单易行, 但计算资源消耗大, 运行效率低; 动态采样依据迭代次数动态确定个体的样本大小, 样本总量小、运算效率高, 但设计困难; 自适应采样依据个体的优劣程度自适应确定样本大小, 使得优质个体样本数量多于劣质个体, 与静态采样、动态采样相比具有计算复杂度低、样本分配灵活等优点, 但其较难辨析相似个体的优劣程度. 目前为止, 设计具有动态采样或自适应采样的智能优化算法求解 MOPOP 的研究成果极为匮乏, 其主要挑战有四点: (1) 低计算复杂度的动态或自适应样本分配方案; (2) 噪声环境下有效辨析个体质量; (3) 小样本容量下快速有效估计目标函数值; (4) 设计可兼容模块的、快速收敛的、多样性好的、稳定性强的进化框架.

从智能优化的角度而言, 针对性研究一般类型 MOPOP 的成果很少, 仅有张仁崇等^[17]针对机会约束条件下的 MOPOP, 基于 MC 随机模拟, 设计具有自适应样本分配策略的多目标免疫优化算法 (MOIOA), 其效率优势明显, 进化能力、降噪效果有待提高. 实际上, MOPOP 在特定的工程优化设计中已得到广泛应用, 主要侧重于在静态采样中使用智能优化算法解决, 但效率低, 计算开销大, 不能满足工程应用的实际需求, 较难

推广. 例如, 关于单目标智能优化算法求解 MOPOP 的研究, 文献[1,3,18~20]针对空降突破点决策、水库资源调度等问题, 建立 MOPOP 模型, 加权目标函数转化为单目标概率优化模型, 继而借助神经网络、随机(或模糊)模拟、妥协算法获得单目标改进型遗传算法求解; 文献[5,6,21]针对汽车充电站规划等工程优化的 MOPOP 模型, 借助隶属函数, 经加权形式获得单目标规划模型, 利用改进型单目标蝙蝠算法、离散(或连续)粒子群算法求解. 其次, 对于多目标智能优化算法求解 MOPOP 的研究, 文献[22,23]利用模糊模拟或随机模拟、拉丁超立方抽样抑制噪声, 进而使用传统的快速非支配排序遗传算法 (NSGA-II) 求解含不确定参数的工业磨削加工、电网最优负荷削减问题; 文献[7,24]针对服务资源协同调度等问题, 借助随机模拟、BP 神经网络抑制噪声, 利用多目标粒子群算法或多目标差分算法求解. 再次, 在确定性转化模型求解方面的研究, 文献[2,25]针对多水源联合调度等问题, 建立不确定多目标规划模型, 通过复杂转换、线性加权将模型转化为具有解析式的单目标优化模型. 最后, 针对描述为 MOPOP 的风火联合调度优化等问题, 文献[4,26]利用对偶内点法、法线边界交叉法、混合交互模糊规划方法求解, 通过顺序偏好近似理想解技术选取折衷解.

综上所述, 鉴于智能优化技术和工程设计优化问题的迫切需求, 设计一种具有优异的运算效率、搜索效果、抑噪能力和应用潜力的新型高性能多目标智能优化算法已成为求解 MOPOP 问题的关键. 免疫优化是人工免疫系统中一个极其重要的研究分支^[27], 在人工智能、信息科学、生物科学等学科受到高度关注; 与经典智能优化算法相比, 具有多样性丰富、收敛速度快、模块设计灵活、学习能力强等优点, 使其求解动态或静态多目标规划模型取得一系列研究成果^[28-31], 与自适应采样求解多目标规划的期望值或概率优化模型在效率、降噪等方面呈现一定的优势^[10,26,32,33], 并获证其求解非线性、多模态随机规划模型有较好潜力. 为此, 本文针对一般类型的 MOPOP, 从免疫系统的克隆选择应答机理出发, 提出一种自适应采样的多目标免疫优化算法 (Adaptive Sampling Multi-Objective Immune Optimization Algorithm, ASMOIOA). 该算法具有种群规模小、适应性强、收敛快等优点. 具体如下: 提出目标值估计法能自适应分配样本大小并辨析非支配个体; 采用快速非支配排序法可有效规避群体分割的困难; 设计分布指数动态变化的模拟二进制交叉能促进各子群协同进化; 设计动态变异分布指数和自适应变异概率能平衡群体局部和全局探索能力、增强群体多样性; 设计的记忆集更新, 可逐渐突显非支配个体.

2 问题描述与目标值估计

2.1 问题描述

一般类型的多目标概率优化问题 (MOPOP)^[34]:

$$\min \bar{f}(\mathbf{x}) = [\bar{f}_1(\mathbf{x}), \bar{f}_2(\mathbf{x}), \dots, \bar{f}_l(\mathbf{x})]$$

$$\text{s. t. } \begin{cases} \Pr\{f_i(\mathbf{x}, \boldsymbol{\xi}) \leq \bar{f}_i(\mathbf{x})\} \geq \alpha_i, 1 \leq i \leq l, \\ \mathbf{x} \in D = \mathbf{R}^p, \boldsymbol{\xi} \in \mathbf{R}^q. \end{cases}$$

在此, \mathbf{x} 为 p 维决策向量, $D \in \mathbf{R}^p$ 为 p 维决策空间, $\boldsymbol{\xi} \in \mathbf{R}^q$ 为 q 维随机向量, $\Pr\{\cdot\}$ 为概率算子, $\alpha_i \in [0, 1]$ 为置信水平; $\bar{f}(\mathbf{x}): D \rightarrow \mathbf{R}^l$ 为含 l 个待优化的、相互冲突的目标函数, $\bar{f}_i(\mathbf{x})$ 为 $\bar{f}(\mathbf{x})$ 的子目标函数, $f_i(\mathbf{x}, \boldsymbol{\xi})$ 为关于 \mathbf{x} 的非线性、多模态或非凸的随机函数; 在点 \mathbf{x} 处, 一旦给定 $\boldsymbol{\xi}$ 的样本容量 $n(\mathbf{x})$, 经 MC 随机模拟, 获得 $\bar{f}_i(\mathbf{x})$ 满足概率不等式的估计值 $\hat{f}_i(\mathbf{x})$ ^[34], $\hat{f}_i(\mathbf{x})$ 为第 $\lfloor \alpha_i n(\mathbf{x}) \rfloor$ 个最小观测值, 其估计质量与样本容量紧密联系。

引入支配及非支配最优解 (即 Pareto 最优解) 的概念^[33] 比较候选解。

定义 1 $\forall \mathbf{x}, \mathbf{y} \in D$, 称 \mathbf{x} 支配 \mathbf{y} (即 $\mathbf{x} < \mathbf{y}$), 若

$$\hat{f}_i(\mathbf{x}) \leq \hat{f}_i(\mathbf{y}), 1 \leq i \leq l, \exists j$$

$$\text{s. t. } \hat{f}_j(\mathbf{x}) < \hat{f}_j(\mathbf{y}), 1 \leq j \leq l$$

(1)

定义 2 $\mathbf{x}^* \in D$ 是 MOPOP 的非支配最优解, 若不存在候选解 $\mathbf{x} \in D$, 使得 $\mathbf{x} < \mathbf{x}^*$ 。

2.2 目标值估计

针对目标函数随机变量, 设计具有自适应样本大小分配的目标值估计法处理。目标值估计法是借助样本容量上限 M_n , 依据个体的优劣程度自适应确定其样本大小; 利用 MC 随机模拟、继承方式、加权思想获取目标函数的估计值。

算法 1 目标值估计法

- 步骤 1** 输入参数: 群体 E , 样本容量 m , 样本容量上限 $M_n (m \leq M_n)$, 置信水平 α_i 。
- 步骤 2** 置 $s \leftarrow m$; 非支配集 $E_1 = \phi$, 受支配集 $E_2 = \phi$ 。
- 步骤 3** 依据 s , 利用 MC 随机模拟估计 E 中全体 B 细胞 \mathbf{x} 的目标值 $\hat{f}^s(\mathbf{x}) = [\hat{f}_1^s(\mathbf{x}), \hat{f}_2^s(\mathbf{x}), \dots, \hat{f}_l^s(\mathbf{x})]$, $\hat{f}_i^s(\mathbf{x})$ 表达式如下:
- $$\hat{f}_i^s(\mathbf{x}) = \hat{f}_i(\mathbf{x}, \boldsymbol{\xi}^v) + (\alpha_i s - \lfloor \alpha_i s \rfloor) \times [\hat{f}_i(\mathbf{x}, \boldsymbol{\xi}^{v+1}) - \hat{f}_i(\mathbf{x}, \boldsymbol{\xi}^v)]$$
- (2)
- 其中, v 在 $\alpha_i > 0.5$ 下取 $\lfloor \alpha_i s \rfloor$, 反之取 $\lceil \alpha_i s \rceil$; $\hat{f}_i(\mathbf{x}, \boldsymbol{\xi}^v)$ 是 $f_i(\mathbf{x}, \boldsymbol{\xi})$ 在样本容量为 s 下的第 v 个最小观测值。
- 步骤 4** 更新 E 中全体 B 细胞 \mathbf{x} 的目标值; 若 $s = m$, 则 $\hat{f}(\mathbf{x}) = \hat{f}^s(\mathbf{x})$; 否则, $\hat{f}(\mathbf{x})$ 依下式更新:
- $$\hat{f}(\mathbf{x}) = \frac{s-m}{s-m+2} \hat{f}(\mathbf{x}) + \frac{2}{s-m+2} \hat{f}^s(\mathbf{x})$$
- (3)
- 步骤 5** 若 $M_1 \leq s$, E 中非支配 B 细胞构成集合 E_1 , 受支配 B 细胞加入 E_2 , 且 $E = E_1$ 。
- 步骤 6** 置 $s \leftarrow s + 1$, 若 $s \leq M_n$, 转步骤 3; 否则, $E = E_1 \cup E_2$, 输出群体 E 、非支配集 E_1 和受支配集 E_2 。

经由以上描述过程获知, 步骤 3、4 的计算复杂度为 $O(|E| |I| s^3)$, 结合 $s \leq M_n$ 可知, 在最坏情况下算法 1 的计算复杂度为 $O(|E| |I| M_n^3)$ 。算法设计中, 个体在样本大小 s 下, 借助 MC 随机模拟获得观测值, 经改进型公式 (2) 线性化抑制噪声, 再通过式 (3) 的继承和加权方式更新目标函数的估计值, 进一步提高噪声抑制效果。此外, 循环步骤 3 ~ 步骤 6 的设计使算法 1 自适应分配样本容量, 提升样本的有效利用及算法运算速度; 个体的样本容量依赖于其优劣程度, 越优质的个体被赋予的样本容量越大; 当 M_n 随迭代次数 n 增大时, $\hat{f}(\mathbf{x})$ 逐渐逼近真实值。

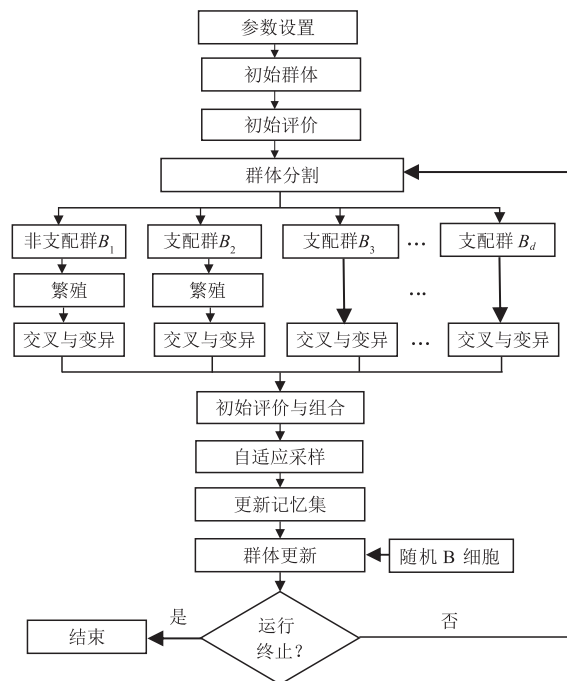


图1 ASMOIOA 的流程图

3 克隆选择原理与算法设计

3.1 克隆选择原理

克隆选择原理^[35] 描述免疫细胞识别、清除入侵抗原的过程, 为求解 MOPOP 提供算法设计灵感、思路。在胚胎期, 免疫细胞在遗传、增殖过程中发生基因突变, 产生多样的免疫细胞; 免疫细胞经分化后, 部分高亲和力的免疫细胞变为记忆细胞, 存储在免疫系统中, 并更新低亲和力的记忆细胞; 一些免疫细胞依据其对抗原的反应能力不断增殖生成无性克隆系。当抗原入侵机体时, 激活免疫系统中相应的免疫细胞, 使之不断分化、增殖, 产生大量具有特异性的免疫细胞, 最终中立或清除抗原。

3.2 算法设计

结合以上问题 (MOPOP), 借助克隆选择原理, 设计

ASMOIOA 进行求解,抗原被视为问题 MOPOP 本身, B 细胞被视为候选解 \mathbf{x} , 运行机制如图 1. 图中, 初始评价是在小采样规模下, 经算法 1 估算个体的目标值. 群体分割是借助传统快速非支配排序法, 将种群分割成多级别的非支配子群. 各子群经克隆、交叉、变异产生新个体, 经初始评价后组合成变异群. 在较大采样规模下, 借助算法 1 重新估算变异群与进化群经验非支配个体的目标值, 并更新记忆集; 最后, 选择一定比例的经验非支配或支配个体与随机生成的新成员产生下一代进化群. ASMOIOA 描述如下:

算法 2 ASMOIOA

- 步骤 1** 输入参数: 群体规模 N , 记忆规模 m_0 , 样本容量 m 和 M , 最大迭代数 G_{\max} , 募集新成员比例 λ , 交叉概率 p_c , 参数 $\eta, N \leq m_0, m \leq M$.
- 步骤 2** 置 $n \leftarrow 1$, 记忆集 $M_{\text{set}} = \phi$; 随机产生规模为 N 的初始 B 细胞群 $A = \{x_1, x_2, \dots, x_N\}$.
- 步骤 3** $M_n \leftarrow (M+1)[2 - \cos(\pi n/G_{\max})]$; 经由算法 1 估计种群 A 中每个 B 细胞 \mathbf{x} 的目标值 $\hat{f}(\mathbf{x})$; $M_{\text{set}} = A$, M_{set} 中经验非支配 B 细胞构成非支配集 P_F .
- 步骤 4** 群体分割: 借助传统快速非支配排序法, 将种群 A 分割为 d 个等级的非支配子群 B_1, B_2, \dots, B_d , 其中, B_i 的 B 细胞互不支配, 但受 B_{i-1} 的 B 细胞支配; B_i 级数 i 越低, B 细胞越优质.
- 步骤 5** B_1, B_2 的 B 细胞分别繁殖 3, 2 个克隆;
- 步骤 6** 交叉与变异:

步骤 6.1 B_i 中 B 细胞 \mathbf{x} 的变异概率设计如下:

$$p_i(\mathbf{x}) = \frac{1}{p} + (1 - \frac{1}{p}) \frac{i}{d} \Delta_n^2, \quad 1 \leq i \leq d \quad (4)$$

式中 $\Delta_n = 1/(1 + \exp(10(n/G_{\max} - 0.4)))$.

步骤 6.2 子群 B_1, B_2 中 B 细胞的克隆 x_i 分别与 P_F, B_1 中随机选取的 B 细胞执行模拟二进制交叉(SBX); B_i 的 B 细胞 x_i 与 $B_1 \cup \dots \cup B_{i-1}$ 中随机选取的 B 细胞执行 SBX, $i = 3, \dots, d$; x_i 经 SBX 获得 x'_i . 若 x'_i 的分量越界, 执行如下越界处理:

$$x'_{ij} = \begin{cases} a_j + (x_{ij} - a_j)(1 - 2u), & \text{if } u < 0.5 \\ x_{ij} + (b_j - x_{ij})(2 - 2u), & \text{else} \end{cases} \quad (5)$$

u 服从 $[0, 1]$ 上的均匀分布, x_{ij} 为 x_i 的第 j 个分量;

步骤 6.3 B_1, B_2 中 B 细胞生成的 x'_i 依据变异概率 $p(x'_i)$ 执行多项式变异^[36]; B_3, \dots, B_d 中 B 细胞生成的 x'_i 依据 $p(x'_i)$ 执行如下非均匀变异:

$$x''_{ij} = \begin{cases} x'_{ij} - (x'_{ij} - a_j) \cdot \Delta(n), & \text{if } u < 0.5 \\ x'_{ij} + (b_j - x'_{ij}) \cdot \Delta(n), & \text{else} \end{cases} \quad (6)$$

其中, $\Delta(n) = 1 - r^{(1-n/G_{\max})^2}$, r 服从 $(0, 1)$ 上的均匀分布. x'_i 经变异获得 x''_i , 若 x''_i 的分量越界, 则按式(5)执行越界处理. B_1, B_2, \dots, B_d 经 SBX、变异获得对应子群 B'_1, B'_2, \dots, B'_d .

步骤 7 评价:

步骤 7.1 依据 M_1 , 经算法 1 评价 $B'_1 \cup \dots \cup B'_d$ 的 B 细胞, 并获得经验非支配子群 C_1 和经验支配子群 C_2 .

步骤 7.2 依据 M_n 及算法 1 重新评价 C_1 中 B 细胞; B_i 的全体 B 细胞均依据 M_n 重新评价.

步骤 8 借助 $<$, $B_1 \cup C_1$ 分为经验非支配子群 C'_1 和经验支配子群 C'_2 ; $B_2 \cup B_3 \cup \dots \cup B_d \cup C_2$ 中 B 细胞送入 C'_2 .

步骤 9 更新记忆集 M_{set} :

步骤 9.1 用 B_1 更新 M_{set} 中 B 细胞的样本容量、目标值.

步骤 9.2 将 C'_1 的 B 细胞送入 M_{set} , 删除相似 B 细胞.

步骤 9.3 若 $|M_{\text{set}}| \leq m_0$, 转步骤 10; 否则, M_{set} 经步骤 4 分割为 L 个等级的非支配子群 $D_1, D_2, \dots, D_L, M_{\text{set}} = \phi$.

步骤 9.4 令 $M_{\text{set}} = D_1 \cup \dots \cup D_{L-1}$, 且 $|M_{\text{set}}| \leq m_0 < |M_{\text{set}} \cup D_L|$.

步骤 9.5 若 $|M_{\text{set}}| = m_0$, 则转步骤 10; 否则计算 D_i 的拥挤距离^[37], 并依据拥挤距离降幂排序.

步骤 9.6 删除 D_i 中样本容量最小、拥挤距离较小的 B 细胞, 循环此过程直至 D_i 只有 $m_0 - |M_{\text{set}}|$ 个 B 细胞; 令 $M_{\text{set}} = M_{\text{set}} \cup D_i$.

步骤 10 将 M_{set} 中经验非支配 B 细胞构成非支配集 P_F .

步骤 11 产生下一代细胞群:

步骤 11.1 置 $A = \phi$; 若 $(1 - \lambda)N \leq |P_F|$, 计算 P_F 的拥挤距离; 基于拥挤距离, 采用比例选择法(即轮盘赌选择法)从 P_F 中随机选出 $(1 - \lambda)N$ 个相异的 B 细胞加入群体 A .

步骤 11.2 若 $|P_F| < (1 - \lambda)N$, 则 $A = A \cup P_F$; 基于样本容量, 采用比例选择法从 C'_2 中随机选出选择 $\min\{(1 - \lambda)N - |P_F|, |C'_2|\}$ 个相异的 B 细胞加入群体 A .

步骤 11.3 随机生成 $N - |A|$ 个新的 B 细胞加入群体 A .

步骤 12 若满足终止条件, 则 P_F 的 B 细胞均依据 M_n 重新评价, 输出 P_F 经验非支配 B 细胞, 算法终止运行; 否则, 置 $n \leftarrow n + 1$, 转步骤 4.

注: 上述的 SBX、多项式变异的分布指数均设计为 $\eta(1 - \Delta_n) + 1$.

以上算法描述中, 结合 MOPOP 的特点和求解难点, 设计步骤 3 ~ 步骤 12, 具体说明如下:

(1) 样本大小控制和目标值估计: 步骤 3 设计样本上限 M_n 随迭代数 n 按三角函数方式递增, 通过提出的目标值估计法依据 B 细胞的优劣程度自适应分配样本容量抑制噪声, 获取概率不等式下目标函数的估计值; 算法运行前期, M_n 较小, 运算速度快; 算法运行后期, M_n 较大, 噪声抑制能力增强, 估计质量提高, 优质 B 细胞逐渐突显.

(2) 群体分割: 为提高搜索质量, 设计步骤 4 基于协同进化的思想, 采用传统快速非支配排序法将种群按等级分割, 级数越小子群的 B 细胞解质量越高, 利于 B 细胞展开多策略进化及信息交流.

(3) 克隆数量限制: 依据亲和力克隆, 亲和力(即解质量)越高的 B 细胞克隆数越多. 为提高效率, 设计步骤 5 仅对子群 B_1, B_2 中 B 细胞实施克隆; B_1 的 B 细胞亲和力最高, 繁殖 3 个克隆, B_2 次之; B_2 克隆有助于协同 B_1 开采高亲和力 B 细胞.

(4) 自适应交叉与变异: 为提高全局、局部搜索能力, 步骤 6 设计变异概率与子群 B_i 的级数 i 成正比, 使优质 B 细胞低概率变异寻优, 劣质 B 细胞高概率在决策空间内探索; 同时, 设计变异概率、交叉变异幅度随迭代数 n 递减. 算法运行初期, 全局探索能力强, 快速定位优质 B 细胞的大致范围; 随着算法运行, 局部搜索能力

增强,产出优质 B 细胞.此外,利用 SBX 促使各子群间信息充分交流,优质 B 细胞指导进化.

(5) 个体评价:为提高效率和目标值估计质量,设计步骤 7 在小样本容量下快速评价新 B 细胞,并筛选经验非支配 B 细胞构成子群 C_1 ,与含优质 B 细胞的子群 B_1 在较大采样规模下经算法 1 重新估算目标值,使其逼近真实值;经步骤 8 从 $B_1 \cup C_1$ 中筛选经验非支配 B 细胞组成子群 C_1 .

(6) 记忆集更新:设计步骤 9 借助快速非支配排序法、样本容量、拥挤距离,使记忆集保留解质量高、多样性好、样本容量大的 B 细胞.

(7) 新进化群体更新:设计步骤 11 借助比例选择法、拥挤距离、样本容量,选择多样性的优质 B 细胞与随机生成的新成员构成下一代进化群体.

当终止运行条件满足时,步骤 12 重新评价 P_f 的 B 细胞,确保输出的 B 细胞解质量高.

4 计算复杂度分析

由上述算法描述获知,ASMOIOA 的计算复杂度由步骤 4 ~ 步骤 7、步骤 9 确定.步骤 4 中快速非支配排序法的计算复杂度为 $O(IN^2)$;步骤 5 ~ 步骤 6 中 B 细胞分化增殖的计算复杂度为 $O(pN)$;步骤 7.1 和步骤 7.2 评价 B 细胞的计算复杂度分别为 $O(N(IM^3))$ 、 $O(N(IM_n^3))$;步骤 9 删除、更新记忆集 M_{set} 的计算复杂度依次为 $O(Nm_0)$ 、 $O(I(4N + m_0)^2)$.概括起来,在最坏情况下 ASMOIOA 的计算复杂度如下:

$$\begin{aligned} O_n &= O(IN^2) + O(pN) + O(N(IM^3)) \\ &\quad + O(N(IM_n^3)) + O(Nm_0) + O(I(4N + m_0)^2) \\ &= O(N(IN + p + IM_n^3 + Im_0) + Im_0^2) \end{aligned} \quad (7)$$

经由以上计算复杂度分析可知,ASMOIOA 的计算复杂度由 N 、 I 、 p 、 m_0 、 M_n 确定,主要取决于 N 、 M_n .其中, M_n 随迭代数 n 逐代增大,所以 M_n 、 N 被限定取较小值.

5 评价准则与数值实验

5.1 评价准则

在此,引入 4 个评价准则^[10,32]比较各算法的搜索性能.设算法 A' 和 A'' 分别求解问题 MOPOP 一次获得经验非支配解集 X 和 Y .

(1) 平均覆盖率:此比较 A' 和 A'' 所获解质量的优劣关系,其设计如下:

$$CR(A', A'') = \frac{|\{y \in Y \mid \exists x \in X, s.t., x < y\}|}{|Y|} \quad (8)$$

此式表明, $0 \leq CR(A', A'') \leq 1$, 如果 $CR(A', A'') > CR(A'', A')$, 则 A' 获得的解质量优于 A'' ; 若 $CR(A', A'') = 1$, A' 获得的解质量绝对优于 A'' .

(2) 覆盖密度:此度量 X 在非支配面上的分布性,

其设计如下:

$$CD = \sqrt{\frac{1}{|X| - 1} \sum_{1 \leq i \leq |X|} (d_i - \bar{d})^2} \quad (9)$$

式中:

$$d_i = \min \{ \|\hat{f}(x_i) - \hat{f}(x_j)\|_1, x_i, x_j \in X, 1 \leq i, j \leq |X| \wedge i \neq j \}, \bar{d} = \frac{1}{|X|} \sum_{i=1}^{|X|} d_i$$

式(9)表明,若 CD 越小,则 X 在非支配面上分布越均匀;若 CD=0,则 X 均匀分布于非支配面.

(3) 覆盖范围:此度量 X 在非支配面上的覆盖宽度,其设计如下:

$$CS = \max \{ \|\hat{f}(x_i) - \hat{f}(x_j)\|_1, x_i, x_j \in X, 1 \leq i, j \leq |X| \} \quad (10)$$

此式表明,若 CS 越大,则覆盖范围越宽.

(4) 收敛性度量:此度量 X 在目标空间中逼近理论非支配最优解集 X^* 的程度,其设计如下:

$$CM(X, X^*) = \frac{1}{|X|} \sum_{x \in X} d(x, X^*) \quad (11)$$

在此, $d(x, X^*)$ 是 x 与 X^* 在目标空间中的 Hausdorff 距离.此式表明,若 $CM(X, X^*)$ 越小,则算法 A' 的收敛性越好.

5.2 数值实验

所有实验均在 Windows 10、配置为 CPU/1.8GHz、RAM/8.00GB 的 Visual C++ 平台上展开.为充分测试具有自适应采样能力的 ASMOIOA 算法的性能,选取 1 个具有自适应采样能力的多目标免疫优化算法 MOIOA^[17] 以及 8 个具有代表性的静态多目标智能优化算法在静态采样下参与比较:多目标粒子群算法 AgMOPSO^[38]、MOPSO^[39],基于分解的多目标进化算法 MOEA/DD^[40]、MOEA/D^[41],多目标免疫优化算法 CMIGA^[42]、NNIA^[29],多目标遗传算法 NSGA-II^[37]、SPEA-II^[43].测试算例包含 3 个理论测试问题以及 1 个工程优化问题.算法终止的最大评价次数均设置为 2×10^4 .经调试,为兼顾各算法的运算效率和搜索效果等因素,静态多目标智能优化算法个体的样本容量固定设置为 300 ^[44],其他参数的设置与原文献一致.对每个测试算例,各算法均独立运行 100 次,获得的非支配解集被用于统计比较分析;为使解集的目标值逼近真实值,均需重新估计,样本容量固定设置为 10^4 .

ASMOIOA 含 4 个主要可调参数: M 、 N 、 η 、 λ . M 是样本大小调控参数,取值在 5 ~ 10 之间,若偏小,降噪能力弱;反之,运行效率低. N 是群体规模,取值在记忆集规模 m_0 的 0.1 ~ 0.15 之间,若偏小,搜索效果不理想;若偏大,运算速度慢. η 是 SBX、多项式变异的分布指数的调控参数,取值在 20 ~ 25 之间,若偏大,算法的全局勘探能力不足,易陷入局部搜索;反之,局部搜索能力弱. λ 是募集新成员的比例,取值一般在 0.05 ~ 0.08 之间^[45,46],防止算法陷入局部搜索.经调试后,ASMOIOA

的参数设置为 $N = 10, m = 2, M = 10, \eta = 23, p_c = 0.9, \lambda = 0.1, m_0 = 100$.

5.2.1 理论实验

问题 1 KUR 问题

$$\begin{aligned} \min & [\bar{f}_1(\mathbf{x}), \bar{f}_2(\mathbf{x})] \\ \text{s. t.} & \begin{cases} \Pr\{g(\mathbf{x}) + \xi_1 \leq \bar{f}_1(\mathbf{x})\} \geq \alpha, \\ \Pr\{h(\mathbf{x}) + \xi_2 \leq \bar{f}_2(\mathbf{x})\} \geq \alpha, \\ g(\mathbf{x}) = \sum_{i=1}^2 [-10 \exp(-0.2 \sqrt{x_i^2 + x_{i+1}^2})], \\ h(\mathbf{x}) = \sum_{i=1}^3 [|x_i|^{0.8} + 5 \sin(x_i^3)], \\ \xi_1, \xi_2 \sim N(0, 1), -5 \leq x_1, x_2, x_3 \leq 5. \end{cases} \end{aligned}$$

式中, $N(\cdot, \cdot)$ 为正态分布. 标准 KUR 问题^[47,48] 已被许多研究者用于测试、分析算法性能^[37,49], 问题 1 是由标准 KUR 问题扩展获之, 含 3 个决策变量、2 个随机变量; 目标函数是非线性的, 理论非支配最优解集和非支配面都是分段连续、非对称的, 候选解的支配关系复杂. 取 $\alpha = 0.9$, 10 种算法求解 100 次后得到的统计结果如表 1 所示, 表中 TS、AR 分别表示样本总量平均值、平均执行时间; 图 2(a) ~ 2(e) 为各算法求解一次获得的非支配面, 图中 PFtrue 为理论非支配面; 图 2(f) ~ 2(h) 为所有

算法求解 100 次后分别获得的 CD、CS、CM 值的箱线图.

经由表 1 的 CD、CS 均值及图 2(f) ~ 2(g) 可知, 以上 10 种算法获得的覆盖密度、覆盖范围的差值较小, 说明各算法获得的解的分布、覆盖宽度的差异不明显, 其中 NNIA 获得的解分布最好, ASMOIOA、AgMOPSO、NSGA-II、SPEA-II 次之. 观察 CR、CM 均值及图 2(h) 可知, 所有算法均收敛于理论非支配面, 且解质量相近, 其中 ASMOIOA 获得的解质量最好, NSGA-II、SPEA-II 次之. 10 种不同算法均能有效抑制噪声对寻优的干扰, 主要原因归结为以下两点: (1) ASMOIOA 和 MOIOA 均设计目标值估计法经线性、继承、加权方式抑制噪声, 自适应辨析个体的优劣程度, 合理分配样本容量, 使优质个体获得的样本容量多于劣质个体, 提高噪声抑制效果和运算效率, 且 ASMOIOA 噪声抑制效果明显优于 MOIOA; (2) 其他算法采用静态采样策略抑制噪声, 在较大的固定样本容量 (300) 下使个体的目标函数的估计值贴近真实值.

由 TS、AR 均值可知, ASMOIOA 和 MOIOA 的样本总量仅是其他算法的 4%; 同时, 它们的运行效率最高, 至少是 CMIGA、NNIA、MOEA/D、MOPSO、NSGA-II 的 2 倍, AgMOPSO、SPEA-II 的 4 倍, MOEA/DD 的 12 倍.

表 1 算法在 $\alpha = 0.9$ 下求解问题 1 获得的统计结果比较

Algor.	CR(.,.)/%										CD/ 10 ⁻¹	CS	CM/ 10 ⁻³	TS	AR/s
	AgMOPSO	MOEA/DD	CMIGA	NNIA	MOEA/D	MOPSO	NSGA-II	SPEA-II	MOIOA	ASMOIOA					
AgMOPSO	0	25.64	34.67	20.74	22.02	31.96	18.62	17.38	21.23	17.15	1.55	17.17	4.57	6 × 10 ⁶	20.52
MOEA/DD	16.63	0	26.23	14.77	18.13	24.47	12.93	12.92	14.39	12.48	2.42	17.11	4.89	6 × 10 ⁶	49.19
CMIGA	10.90	12.06	0	9.86	11.56	16.76	8.53	8.20	9.42	7.29	3.21	17.07	6.60	6 × 10 ⁶	13.78
NNIA	26.02	27.93	36.33	0	25.89	34.82	20.69	20.00	24.36	19.72	1.36	17.16	4.35	6 × 10 ⁶	13.99
MOEA/D	17.53	19.78	27.24	16.39	0	25.57	14.11	14.86	16.65	13.57	2.39	17.07	4.39	6 × 10 ⁶	13.06
MOPSO	15.47	16.69	25.93	14.03	16.47	0	12.35	12.59	14.68	11.50	1.72	17.07	6.65	6 × 10 ⁶	13.81
NSGA-II	25.50	29.57	37.52	24.15	26.49	35.96	0	21.20	24.85	19.71	1.53	17.15	3.91	6 × 10 ⁶	14.51
SPEA-II	25.54	28.28	37.86	23.45	24.99	34.27	20.98	0	24.54	19.69	1.60	17.15	3.90	6 × 10 ⁶	21.97
MOIOA	23.35	25.58	34.90	20.50	21.86	33.25	17.74	17.90	0	17.83	1.69	17.13	4.41	219645	3.48
ASMOIOA	26.82	29.49	39.28	24.94	26.57	37.73	22.27	23.11	25.22	0	1.53	17.13	3.73	243133	3.67

问题 2 DEB 问题

$$\begin{aligned} \min & [\bar{f}_1(\mathbf{x}), \bar{f}_2(\mathbf{x})] \\ \text{s.} & \begin{cases} \Pr\{x_1 + \xi_1 \leq \bar{f}_1(\mathbf{x})\} \geq \alpha, \Pr\{h(\mathbf{x}) + \xi_2 \leq \bar{f}_2(\mathbf{x})\} \geq \alpha, \\ h(\mathbf{x}) = (1 + 10x_2) \left(1 - \left(\frac{x_1}{1 + 10x_2} \right)^2 - \frac{x_1 \sin(8\pi x_1)}{1 + 10x_2} \right) \\ \xi_1, \xi_2 \sim N(0, 1), 0 \leq x_1, x_2 \leq 1. \end{cases} \end{aligned}$$

此问题是经由标准 DEB 问题^[47,50] 扩展而得, 目标函数是非线性的, 非支配面为 4 段连续且单调递减的曲线, 在噪声环境下求解极为困难. 取 $\alpha = 0.9$, 各算法

求解 100 次后得到的统计结果如表 2, 箱线图和一次求解获得的非支配面如图 3.

由表 2 的 CD、CS 均值及图 3(f) ~ 3(g) 可知, ASMOIOA 与比较算法所获解的分布性、覆盖宽度相近, 其中 CMIGA 获得的解分布略差. 由 CM 均值和图 3(h) 可知, 所有算法均能有效收敛, 其中 ASMOIOA 的收敛性和稳定性最好, CMIGA 较差. 综合 CM、CR 均值及图 3(h) 可知, ASMOIOA 的 CM 均值最小, 但 CR 均值略小于 MOIOA、AgMOPSO、MOEA/DD、NNIA、MOEA/D、NSGA-II 及 SPEA-II, 出现此种矛盾现象是因为这些比较

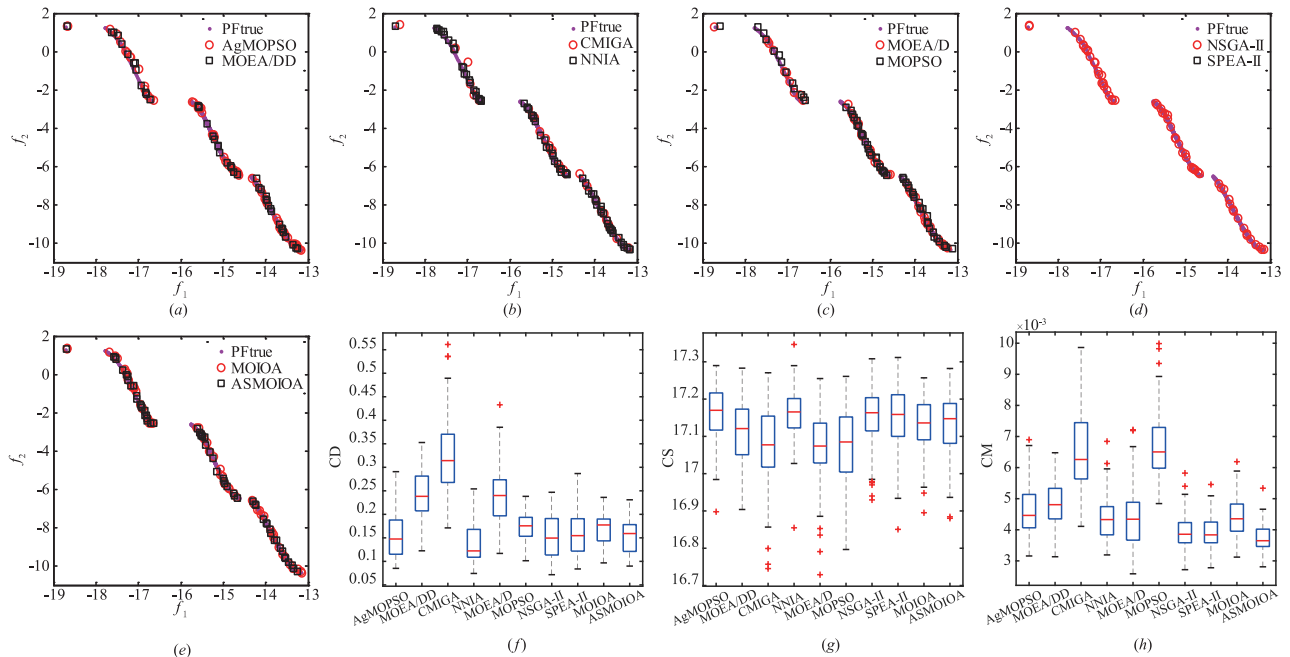


图2 问题1的CD、CS、CM值的箱线图比较与非支配面比较

算法在噪声环境下搜索效果不稳定,导致 CM 均值高于 ASMOIOA;以上分析表明 ASMOIOA 的噪声抑制效果好、解质量高、稳定性强.进一步,由 TS 均值可知,AS-

MOIOA 和 MOIOA 的样本总量最小.就运行效率而言,ASMOIOA 和 MOIOA 的效率最高,是其他算法的 3 倍以上,MOEA/DD 的效率最低.

表 2 算法在 $\alpha = 0.9$ 下求解问题 2 获得的统计结果比较

Algor.	CR(·,·)/%										CD/ 10 ⁻²	CS	CM/ 10 ⁻²	TS	AR/s
	AgMOPSO	MOEA/DD	CMIGA	NNIA	MOEA/D	MOPSO	NSGA-II	SPEA-II	MOIOA	ASMOIOA					
AgMOPSO	0	32.39	43.97	30.20	31.03	43.16	31.82	32.93	32.53	33.78	11.28	2.33	1.72	6 × 10 ⁶	15.35
MOEA/DD	27.92	0	46.08	29.99	31.52	43.14	32.74	30.56	30.78	34.24	10.60	2.31	1.63	6 × 10 ⁶	51.02
CMIGA	14.37	16.03	0	13.76	14.60	23.47	15.90	15.25	17.79	17.30	26.05	2.61	4.12	6 × 10 ⁶	13.98
NNIA	29.12	30.67	43.35	0	30.58	41.45	33.50	31.65	30.86	32.20	13.21	2.44	2.35	6 × 10 ⁶	13.20
MOEA/D	37.73	26.77	30.39	26.80	0	38.26	28.94	28.74	29.58	31.89	11.01	2.16	1.75	6 × 10 ⁶	13.18
MOPSO	19.90	20.07	30.22	17.94	20.75	0	19.83	18.74	21.39	21.68	14.21	2.46	2.81	6 × 10 ⁶	13.19
NSGA-II	29.35	33.47	43.59	29.45	31.09	41.68	0	32.00	32.83	33.22	8.72	2.35	1.69	6 × 10 ⁶	15.82
SPEA-II	32.57	33.43	41.97	29.88	31.76	41.42	32.40	0	35.12	34.07	11.62	2.31	1.60	6 × 10 ⁶	21.15
MOIOA	27.51	31.20	43.70	28.04	28.84	40.46	31.33	29.06	0	31.30	15.13	2.47	2.72	215996	2.56
ASMOIOA	23.97	26.27	39.34	24.31	27.24	38.09	30.10	27.48	26.81	0	9.45	2.31	1.45	219211	2.34

问题 3 多模态多目标问题

$$\begin{aligned}
 & \min [\bar{f}_1(\mathbf{x}), \bar{f}_2(\mathbf{x})] \\
 & \text{s. t. } \begin{cases} \Pr\{x_1 + \xi_1 \leq \bar{f}_1(\mathbf{x})\} \geq \alpha, \\ \Pr\{g(x_2)/x_1 + \xi_2 \leq \bar{f}_2(\mathbf{x})\} \geq \alpha, \\ g(x_2) = 2 - \exp\left\{-\left(\frac{x_2 - 0.2}{0.004}\right)^2\right\} \\ \quad - 0.8 \exp\left\{-\left(\frac{x_2 - 0.6}{0.4}\right)^2\right\}, \\ \xi_1, \xi_2 \sim N(0,1), 0.1 \leq x_1, x_2 \leq 1. \end{cases}
 \end{aligned}$$

此问题是经文献[50]的多模态多目标优化问题扩展而得.该问题是多模态的,理论最优非支配面是连续的;但在 $x_2 = 0.6$ 处存在局部非支配面,在 $x_2 = 0.2$ 处有全局非支配面,且 $g(x_2)$ 在 $x_2 = 0.2$ 处为倒立的锐利尖峰;加之随机变量影响算法寻优,致使问题求解难度极高.取 $\alpha = 0.9$,依据以上评价准则,各算法求解 100 次后得到的统计结果如表 3 所示;同时,图 4(a)~4(e)给出一次运行中所获的非支配面,图 4(f)~4(h)给出不同算法的 CD、CS 值及 CM 值的箱线图.

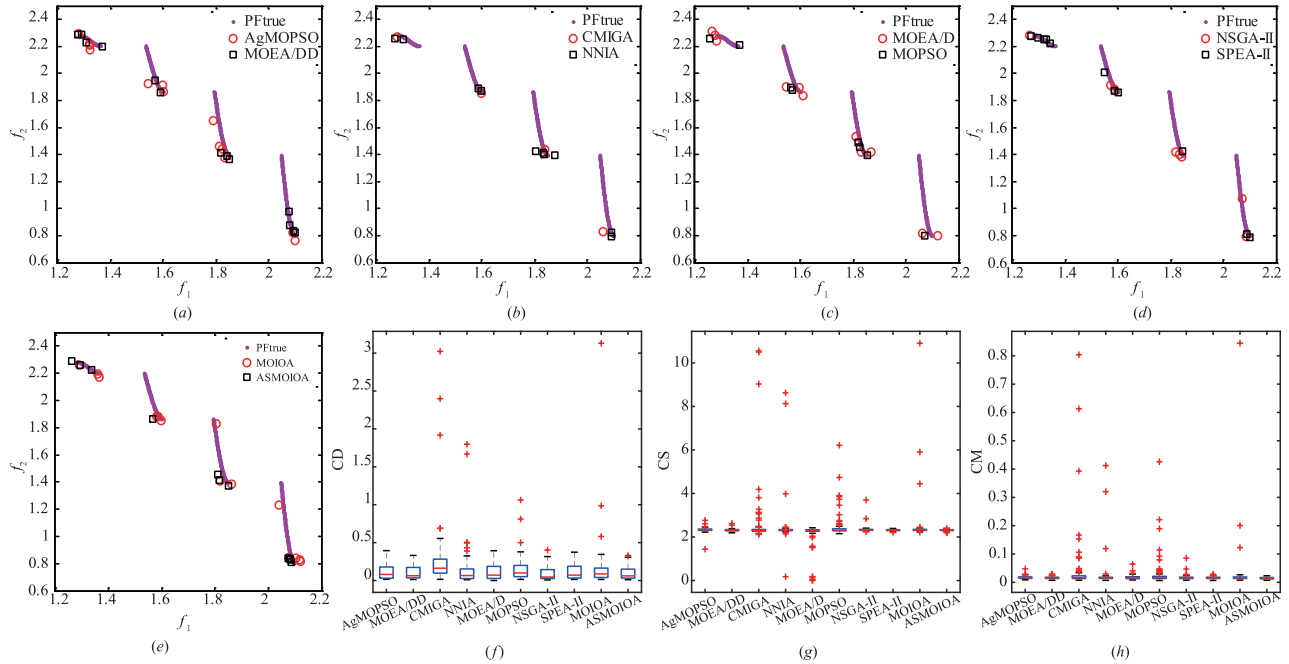


图3 问题2的CD、CS、CM值的箱线图比较与非支配面比较

表3 算法在 $\alpha=0.9$ 下求解问题3获得的统计结果比较

Algor.	CR(·, ·)/%										CD/ 10^{-1}	CS	CM/ 10^{-3}	TS	AR/s
	AgMOPSO	MOEA/DD	CMIGA	NNIA	MOEA/D	MOPSO	NSGA-II	SPEA-II	MOIOA	ASMOIOA					
AgMOPSO	0	37.64	24.02	46.62	86.55	64.55	25.38	40.13	18.69	15.16	5.49	9.68	6.40	6×10^6	15.07
MOEA/DD	26.52	0	20.71	40.69	70.21	56.71	22.61	33.17	16.83	14.31	5.15	6.53	4.58	6×10^6	48.99
CMIGA	25.35	35.31	0	46.27	87.95	67.01	23.14	37.48	12.44	8.97	15.22	11.09	7.71	6×10^6	13.31
NNIA	23.49	25.76	16.87	0	57.19	49.38	17.95	31.31	12.99	9.89	5.67	8.54	7.88	6×10^6	12.76
MOEA/D	3.14	8.89	2.22	9.38	0	9.97	5.42	7.80	1.80	1.20	1.03	1.92	9.65	6×10^6	12.44
MOPSO	10.66	21.00	5.82	27.51	63.02	0	12.24	20.57	4.25	2.97	7.61	8.97	12.00	6×10^6	12.64
NSGA-II	34.14	39.17	26.35	49.76	79.79	70.00	0	42.00	21.35	17.64	6.68	9.11	4.92	6×10^6	15.02
SPEA-II	25.90	28.88	18.84	41.41	64.84	56.68	21.82	0	14.60	12.25	7.23	8.84	6.66	6×10^6	20.48
MOIOA	38.39	44.18	28.13	55.04	89.66	77.03	33.00	46.62	0	18.93	8.64	9.85	3.85	215189	2.75
ASMOIOA	39.55	45.02	31.13	57.66	91.07	79.08	33.27	46.73	25.53	0	7.04	8.22	2.49	220446	2.55

经由表3的CR、CM均值及图4(h)可知,ASMOIOA的收敛性、稳定性和解质量远优于比较算法;MOEA/D和MOPSO的解质量相对较低,易陷入局部非支配面.表中的CD、CS均值及图4(f)~4(g)看出,MOEA/D与CMIGA获得解的分布情况都相对较差,其中MOEA/D极易陷入局部非支配面的右半面,致使CD、CS均值较小;ASMOIOA和其他算法所获解的分布、覆盖宽度较好且差异较小.因此,综合算法获得的解的分布性、覆盖范围及解质量,ASMOIOA求解问题3优势明显,MOEA/D求解此问题的能力较弱.

由TS、AR均值可知,ASMOIOA和MOIOA的样本总量最小、运行效率最高,效率至少是其他算法的3

倍,MOEA/DD的效率最低.

5.2.2 工程应用

问题4 海铁联运能耗优化问题

在国际贸易运输中,为达到控制成本、减少污染物排放、缩短运输时间的目的,海铁联运已成为重要的运输方式;而且,为保护环境,船舶在硫排放控制区需要使用低硫燃料.基于此,文献[51]以能源消耗 $E(\text{kg})$ 和运输时间 $T(\text{h})$ 作为优化目标,构建海铁联运能耗的多目标优化问题.然而,在实际运输过程中,船舶的航运速度、火车的行驶速度常因环境干扰、系统不稳定等因素呈现不确定性,海铁联运能耗优化问题在此种环境下可描述为MOPOP加以求解,表达式如下:

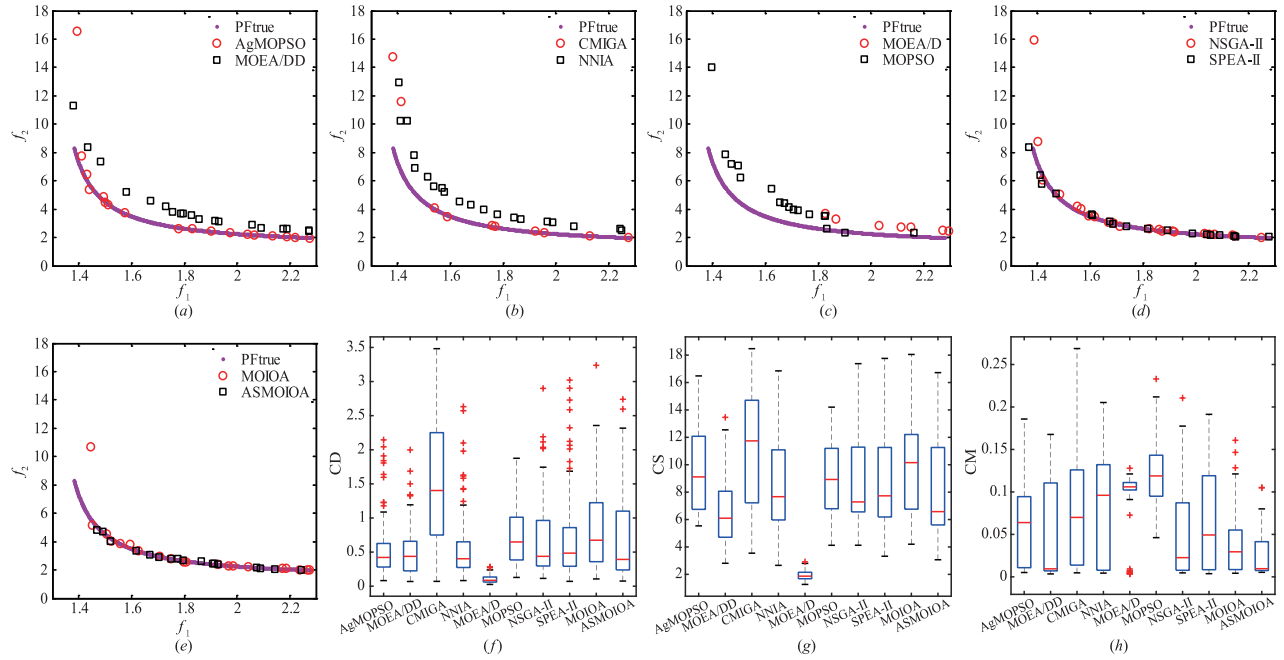


图4 问题3的CD、CS、CM值的箱线图比较与非支配面比较

$$\min [f_1(\mathbf{v}), f_2(\mathbf{v})]$$

$$\text{s. t. } \begin{cases} \Pr \{ E_{\text{ship}}^{\text{SECA}} + E_{\text{ship}}^{\text{S}} + E_{\text{train}}^{\text{rail}} \leq \bar{f}_1(\mathbf{v}) \} \geq \alpha, \\ \Pr \{ T_{\text{ship}}^{\text{SECA}} + T_{\text{ship}}^{\text{S}} + T_{\text{train}}^{\text{rail}} + 2 \times t_{\text{transit}} \leq \bar{f}_2(\mathbf{v}) \} \geq \alpha, \end{cases}$$

$$E_{\text{ship}}^{\text{SECA}} = \sum_{k=1}^2 \frac{0.0043 \times (v_{\text{ship}}^{\text{SECA}_k})^{3.358} \times S_{\text{ship}}^{\text{SECA}_k} \times 1000 \times 1.5}{24 \times v_{\text{ship}}^{\text{SECA}_k}}$$

$$E_{\text{ship}}^{\text{S}} = \sum_{k=1}^3 \frac{0.0043 \times (v_{\text{ship}}^{\text{S}_k})^{3.358} \times S_{\text{ship}}^{\text{S}_k} \times 1000}{24 \times v_{\text{ship}}^{\text{S}_k}}$$

$$E_{\text{train}}^{\text{rail}} = \sum_{k=1}^2 \frac{\rho_{\text{train}}^{\text{rail}_k} \times P_{\text{train}}^{\text{rail}_k} \times S_{\text{train}}^{\text{rail}_k} \times 20}{1000 \times v_{\text{train}}^{\text{rail}_k}}$$

$$T_{\text{ship}}^{\text{SECA}} = \sum_{k=1}^2 \frac{S_{\text{ship}}^{\text{SECA}_k}}{v_{\text{ship}}^{\text{SECA}_k}}, T_{\text{ship}}^{\text{S}} = \sum_{k=1}^3 \frac{S_{\text{ship}}^{\text{S}_k}}{v_{\text{ship}}^{\text{S}_k}}, T_{\text{train}}^{\text{rail}} = \sum_{k=1}^2 \frac{S_{\text{train}}^{\text{rail}_k}}{v_{\text{train}}^{\text{rail}_k}}$$

$$\rho_{\text{train}}^{\text{rail}_k} = 0.004 \times (v_{\text{train}}^{\text{rail}_k})^2 - 0.8245 \times v_{\text{train}}^{\text{rail}_k} + 271.4, k=1, 2,$$

$$P_{\text{train}}^{\text{rail}_k} = -0.004285 \times (v_{\text{train}}^{\text{rail}_k})^3 + 0.917 \times (v_{\text{train}}^{\text{rail}_k})^2 - 35.78 \times v_{\text{train}}^{\text{rail}_k} + 817.1, k=1, 2,$$

$$v_{\text{ship}}^{\text{SECA}_k} = \hat{v}_{\text{ship}}^{\text{SECA}_k} + \xi_{\text{ship}}^{\text{SECA}_k}, v_{\text{ship}}^{\text{S}_k} = \hat{v}_{\text{ship}}^{\text{S}_k} + \xi_{\text{ship}}^{\text{S}_k},$$

$$v_{\text{train}}^{\text{rail}_k} = \hat{v}_{\text{train}}^{\text{rail}_k} + \xi_{\text{train}}^{\text{rail}_k},$$

$$4 \text{ knot/h} \leq \hat{v}_{\text{ship}}^{\text{SECA}_k}, \hat{v}_{\text{ship}}^{\text{SECA}_k} \leq 8 \text{ knot/h},$$

$$8 \text{ knot/h} \leq \hat{v}_{\text{ship}}^{\text{S}_k}, \hat{v}_{\text{ship}}^{\text{S}_k} \leq 15 \text{ knot/h},$$

$$15 \text{ knot/h} \leq \hat{v}_{\text{ship}}^{\text{S}_k} \leq 20 \text{ knot/h},$$

$$30 \text{ km/h} \leq \hat{v}_{\text{train}}^{\text{rail}_k}, \hat{v}_{\text{train}}^{\text{rail}_k} \leq 100 \text{ km/h},$$

$$t_{\text{transit}} = 14 \text{ h}, S_{\text{train}}^{\text{rail}_k} = S_{\text{train}}^{\text{rail}_k} = 1200 \text{ km},$$

$$S_{\text{ship}}^{\text{SECA}_k} = S_{\text{ship}}^{\text{SECA}_k} = 150 \text{ knot},$$

$$S_{\text{ship}}^{\text{S}_k} = S_{\text{ship}}^{\text{S}_k} = 300 \text{ knot}, S_{\text{ship}}^{\text{S}_k} = 700 \text{ knot},$$

$$\xi_{\text{ship}}^{\text{SECA}_k}, \xi_{\text{ship}}^{\text{SECA}_k}, \xi_{\text{ship}}^{\text{S}_k}, \xi_{\text{ship}}^{\text{S}_k}, \xi_{\text{ship}}^{\text{S}_k}, \xi_{\text{train}}^{\text{rail}_k}, \xi_{\text{train}}^{\text{rail}_k} \sim N(0, 1).$$

此问题包含 7 个决策变量,模型结构复杂,在噪声环境下求解问题的难度较大.取 $\alpha = 0.9$,各算法求解 100 次后得到的统计结果如表 4 所示,给出 CD、CS 值的箱线图如图 5(f) ~ 5(g) 所示;在一次运行中所获的非支配面如图 5(a) ~ 5(e) 所示.

表 4 算法在 $\alpha = 0.9$ 下求解海铁联运能耗优化问题获得的统计结果比较

Algor.	CR(·, ·, ·)/%										CD	CS	CM	TS	AR/s
	AgMOPSO	MOEA/DD	CMIGA	NNIA	MOEA/D	MOPSO	NSGA-II	SPEA-II	MOIOA	ASMOIOA					
AgMOPSO	0	11.26	12.23	18.03	16.77	41.84	10.90	16.06	6.91	6.66	1186	197827	6×10^6	33.73	0
MOEA/DD	3.49	0	0.34	1.61	22.75	0.39	1.03	0.79	1.99	1.60	1026	11692	6×10^6	57.90	3.49
CMIGA	25.52	5.16	0	23.10	0	53.36	14.74	22.12	8.16	9.45	1421	180809	6×10^6	23.57	25.52
NNIA	24.33	7.18	14.22	0	1.33	47.65	12.56	18.45	6.47	6.84	1051	187522	6×10^6	24.79	24.33
MOEA/D	0.37	1.81	0	0.09	0	0	0.03	0	0.11	0.11	92	579	6×10^6	22.45	0.37
MOPSO	10.88	0.86	4.50	9.58	0	0	3.50	5.42	1.90	2.50	1110	119437	6×10^6	25.63	10.88
NSGA-II	31.77	6.96	20.31	27.40	0.50	57.63	0	26.42	9.62	11.09	1007	181902	6×10^6	23.91	31.77
SPEA-II	25.94	3.96	15.22	22.76	0	60.21	12.90	0	7.71	8.56	1394	150599	6×10^6	38.73	25.94
MOIOA	43.22	8.87	30.20	39.67	1.67	66.75	28.10	34.27	0	18.95	1037	194104	224576	8.76	43.22
ASMOIOA	39.77	8.88	26.91	37.34	1.00	65.84	25.26	32.24	14.88	0	1030	190322	279491	10.05	39.77

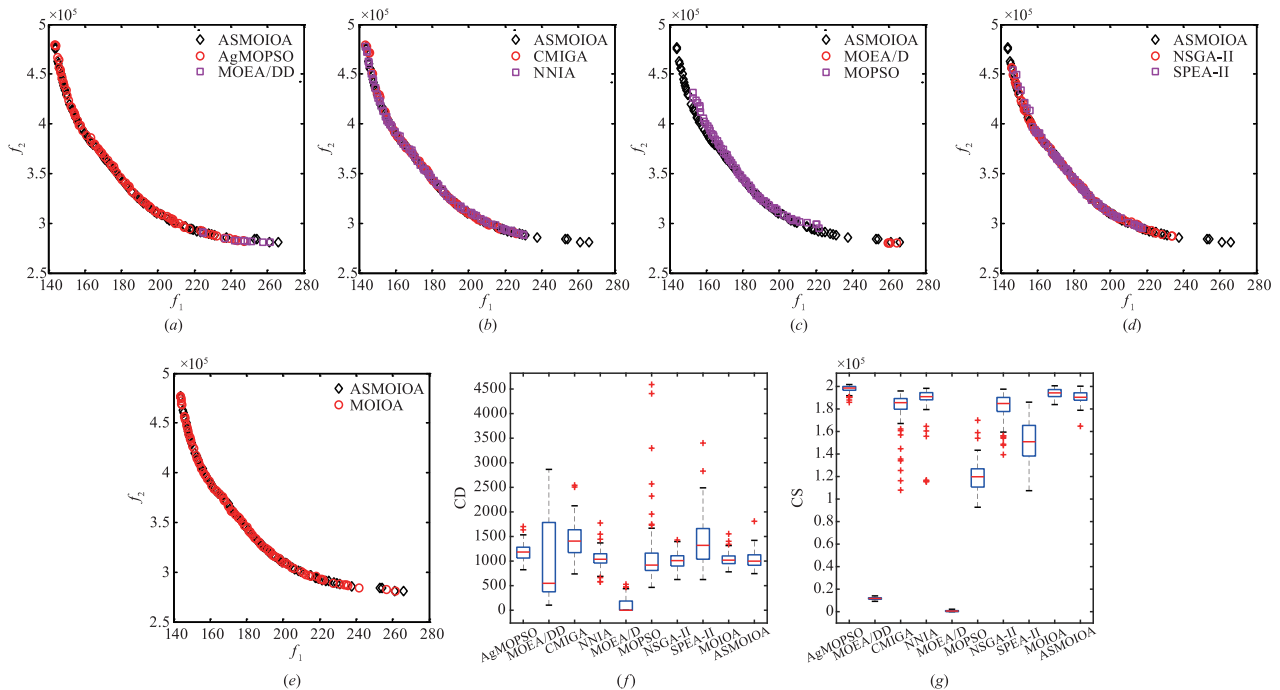


图5 问题4的CD、CS值的箱线图比较与非支配面比较

经由表 4 的 CR 均值获知, ASMOIOA 的解质量高且略低于 MOIOA, CMIGA、NSGA-II 和 SPEA-II 次之. 由 CD、CS 均值及图 5(f) ~ 5(g) 可知, ASMOIOA、MOIOA、AgMOPSO 及 NNIA 所获解的分布性较好、覆盖宽度较宽; 而 MOEA/DD、MOEA/D 获得的解分布较差, 主要原因是它们在噪声环境下仅获得少量的非支配解, 特别是 MOEA/D. 以上分析表明, ASMOIOA 和 MOIOA 所获解的分布好、质量高.

由 TS、AR 均值可知, ASMOIOA 和 MOIOA 的样本总量最小、运行效率最高; 同时, 它们的效率至少是其他算法的 1 倍, AgMOPSO 和 SPEA-II 的 2 倍, MOEA/DD 的 4 倍.

6 灵敏度分析

ASMOIOA 的主要可调参数包括 N 、 M 、 η 及 λ . 选取

多模态多目标优化问题 3 测试该算法的搜索性能是否在很大程度上依赖于参数设置. 就此, 给定 $\alpha = 0.9$, 选取 N 、 M 、 η 、 λ 、 p_c 及 m_0 构成 13 种参数组合如图 6(a), 充分测试算法对参数设置的灵敏度, 算法终止的最大评价次数设置为 2×10^4 ; 在每种参数组合下均独立运行 100 次, 所获统计结果的折线图如图 6(b) ~ 6(c).

经由图 6 的 CM、CD、CS 均值获知, ASMOIOA 算法对参数设置的敏感度较低, 在不同参数组合下均获得较为满意的结果, 且解质量差异较小. 在相同评价次数下, 当群体规模 N 增大时, 算法效率越高; 然而, 当样本大小 M 、记忆集规模 m_0 增大时, 算法效率递减. 另外, 在 11 种参数组合中, 最佳参数组合为: $N = 10$, $M = 10$, $\lambda = 0.1$, $p_c = 0.9$, $\eta = 23$.

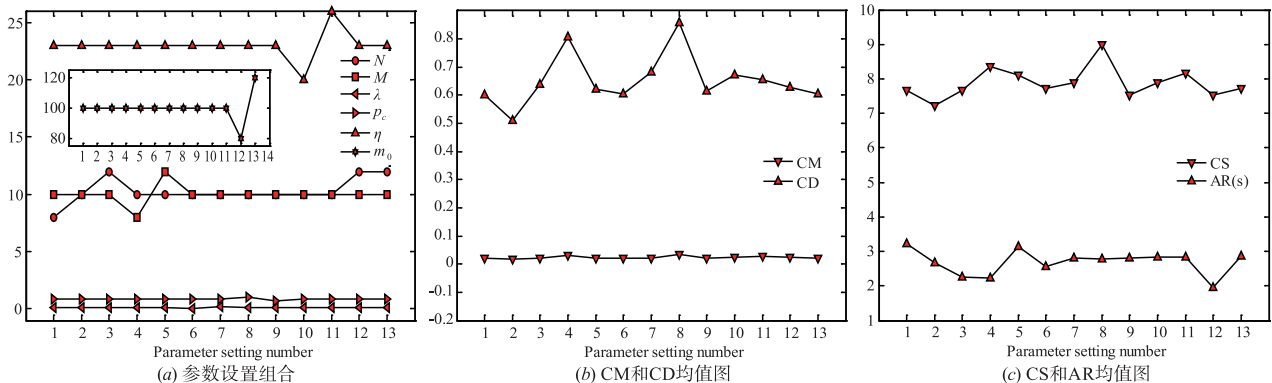


图6 ASMOIOA的不同的参数设置及统计结果比较

7 结论

(1) 多目标概率优化问题广泛出现在工程优化、生命科学、经济金融、社会科学等领域,且探讨问题求解的新型高性能智能优化算法是极具挑战性的课题,也是优化领域研究的难点.因此,从免疫优化的角度出发,基于免疫系统的克隆选择原理,设计该问题求解的自适应采样多目标免疫优化算法(ASMOIOA).

(2) 在此算法中,设计目标值估计法经线性、继承、加权形式抑制目标函数的噪声,自适应辨析个体的优劣关系并分配样本容量;基于克隆选择原理的应答机理,设计算法进化框架;通过 SBX、多项式变异、非均匀变异、自适应变异概率、动态交叉变异分布指数指导种群展开多渠道进化,产生多样的、质量高的解.

(3) 经计算复杂度及算法 2 可知,算法运行前期,样本容量小,搜索速度快,全局探索能力强;算法运行后期,样本容量增大,抑制噪声能力、局部开采能力增强,解质量提高,利于获取非支配最优解.

(4) 借助 9 个代表性的算法、3 个理论测试问题、海铁联运能耗优化问题及灵敏度分析,说明了该算法是求解 MOPOP 的极具竞争力和应用潜力的优化方法,在搜索效果、寻优效率上优势明显,特别是寻优效率.

(5) 尽管 ASMOIOA 表现出较高的优越性,但仍需进行一些改进.例如,优化算法结构和去噪方法,提高记忆集更新的效率,缩减样本总量,并对工程应用做进一步的研究.此外,该算法在自适应采样下尚不能有效求解超多目标概率优化问题.未来研究方向:探讨低计算复杂度、结构简单、参数少、降噪能力强的小种群免疫优化算法求解超多目标概率优化问题.

参考文献

- [1] 纪昌明,李克飞,张验科,等.基于机会约束的水库调度随机多目标决策模型[J].电力系统保护与控制,2012(19):36-40.
JI Chang-ming, LI Ke-fei, ZHANG Yan-ke, et al. Stochastic multi-objective decision-making model of the reservoir operation based on chance-constrained programming[J]. Power System Protection and Control, 2012(19):36-40. (in Chinese)
- [2] 李晓娜.不确定环境下城市需水量预测及多水源联合供水调度研究[D].邯郸:河北工程大学,2018.
LI Xiao-na. Study on urban water demand forecast and multiple water sources optimization allocation under uncertainty [D]. Handan: Hebei University of Engineering, 2018. (in Chinese)
- [3] 张国新,王瑜,沈田双.空降地面作战突破点决策模型[J].火力与指挥控制,2010,35(11):54-57.
ZHANG Guo-xin, WANG Yu, SHEN Tian-shuang. A study on breakthrough point decision model of airborne ground operation[J]. Fire Control & Command Control, 2010, 35(11):54-57. (in Chinese)
- [4] 李卓环,陈艺璇,余涛,等.考虑大气污染时空分布的风火联合系统多目标优化调度[J].电力系统自动化,2019,43(14):126-139.
LI Zhuo-huan, CHEN Yi-xuan, YU Tao, et al. Multi-objective optimization dispatching for wind-thermal power joint system considering temporal and spatial distribution of air pollutants[J]. Automation of Electric Power Systems, 2019, 43(14):126-139. (in Chinese)
- [5] 吕凯,唐昊,王珂,等.计及源荷双侧不确定性的跨区互联电网网荷协同调度[J].电力系统自动化,2019,43(22):38-51,150.
LÜ Kai, TANG Hao, WANG Ke, et al. Coordinated dispatching of source-grid-load for inter-regional power grid considering uncertainties of both source and load sides[J]. Automation of Electric Power Systems, 2019, 43(22):38-51, 150. (in Chinese)
- [6] 裴文杰,汪泓,谭阳红,等.含光伏分布式电源配电网的电动汽车充电机会约束规划[J].电力系统及其自动化学报,2017,29(6):45-52.
PEI Wen-jie, WANG Hong, TAN Yang-hong, et al. Chance-constrained programming for electric vehicle charging stations in distribution network containing photovoltaic distributed generations[J]. Proceedings of the CSU-EPSA, 2017, 29(6):45-52. (in Chinese)
- [7] 杨新宇,胡业发.不确定环境下复杂产品维护、维修和大修服务资源调度优化[J].浙江大学学报(工学版),2019,53(05):852-861.
YANG Xin-yu, HU Ye-fa. Maintenance, repair and overhaul/operations service resource scheduling optimization for complex products in uncertain environment[J]. Journal of Zhejiang University (Engineering Science), 2019, 53(05):852-861. (in Chinese)
- [8] 李整.基于粒子群优化算法的机组组合问题的研究[D].北京:华北电力大学(北京),2016.
LI Zheng. Unit commitment via particle swarm optimization algorithm[D]. Beijing:North China Electric Power University(Beijing),2016. (in Chinese)
- [9] ZHANG Z H. Noisy immune optimization for chance-constrained programming problems[J]. Applied Mechanics and Materials, 2011, 48:740-744.
- [10] YANG K, ZHANG Z H, LU J X. Adaptive racing rank-

- ing-based immune optimization approach solving multi-objective expected value programming [J]. *Soft Computing*, 2017, 1 – 20.
- [11] 杨凯,张著洪. 基于免疫优化的单目标多模态期望值规划[J]. *西南交通大学学报*, 2014, 49(6): 1061 – 1067.
YANG Kai, ZHANG Zhu-hong. A single-objective multimodal expected value programming based on immune optimization [J]. *Journal of Southwest Jiaotong University*, 2014, 49(6): 1061 – 1067. (in Chinese)
- [12] ZHANG Z H, WANG L, LIAO M. Adaptive sampling immune algorithm solving joint chance-constrained programming [J]. *Journal of Control Theory and Applications*, 2013, 11(2): 237 – 246.
- [13] YANG K, ZHANG Z H. Adaptive sampling detection based immune optimization approach and its application to chance constrained programming [A]. *Genetic and Evolutionary Computing [C]*. Berlin: Springer, 2015. 19 – 28.
- [14] ZHANG Z H, YANG K, ZHANG D M. Sample bound estimate based chance-constrained immune optimization and its applications [J]. *International Journal of Automation and Computing*, 2016, 13(5): 468 – 479.
- [15] ZHANG Z H, ZHANG R C. Danger theory inspired micro-population immune optimization for probabilistic constrained programming [J]. *Evolving Systems*, 2019. 1 – 16.
- [16] 张著洪,张仁崇. 求解概率优化问题的微种群免疫优化算法[J]. *北京航空航天大学学报*, 2016, 42(09): 1785 – 1794.
ZHANG Zhu-hong, ZHANG Ren-chong. Micro immune optimization algorithm for solving probabilistic optimization problems [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2016, 42(09): 1785 – 1794. (in Chinese)
- [17] 张仁崇,张著洪. 非线性多目标概率约束规划免疫优化算法[J]. *北京航空航天大学学报*, 2020, 46(05): 900 – 914.
ZHANG Ren-chong, ZHANG Zhu-hong. Immune optimization algorithm for nonlinear multi-objective probabilistic constrained programming [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2020, 46(05): 900 – 914. (in Chinese)
- [18] 张铭鑫,张玺,彭建刚,等. 不确定环境下再制造加工车间多目标调度优化方法[J]. *合肥工业大学学报(自然科学版)*, 2016, 39(4): 433 – 439.
ZHANG Ming-xin, ZHANG Xi, PENG Jian-gang, et al. Multi-objective optimization method of remanufacturing processing workshop scheduling under uncertain conditions [J]. *Journal of Hefei University of Technology (Natural Science)*, 2016, 39(4): 433 – 439. (in Chinese)
- [19] XU J P, DING C. A class of chance constrained multiobjective linear programming with birandom coefficients and its application to vendors selection [J]. *International Journal of Production Economics*, 2011, 131(2): 709 – 720.
- [20] 白牧可,唐巍,张璐,等. 基于机会约束规划的 DG 与配电网架多目标协调规划 [J]. *电工技术学报*, 2013, 28(10): 346 – 354.
BAI Mu-ke, TANG Wei, ZHANG Lu, et al. Multi-objective coordinated planning of distribution network incorporating distributed generation based on chance constrained programming [J]. *Transactions of China Electrotechnical Society*, 2013, 28(10): 346 – 354. (in Chinese)
- [21] 刘文学,梁军,负志皓,等. 基于可信理论的多目标模糊机会约束无功优化 [J]. *电工技术学报*, 2015, 30(21): 82 – 89.
LIU Wen-xue, LIANG Jun, FU Zhi-hao, et al. Multi-objective chance constrained optimal reactive power flow based on credibility theory [J]. *Transactions of China Electrotechnical Society*, 2015, 30(21): 82 – 89. (in Chinese)
- [22] VIRIVINTI N, MITRA K. Intuitionistic fuzzy chance constrained programming for handling parametric uncertainty: an industrial grinding case study [J]. *Industrial & Engineering Chemistry Research*, 2015, 54(24): 6291 – 6304.
- [23] 谢仕炜,胡志坚,宁月. 考虑最优负荷削减方向的电网多目标分层随机机会约束规划 [J]. *电力自动化设备*, 2017, 37(8): 35 – 42.
XIE S W, HU Z J, NING Y. Multi-objective hierarchical stochastic chance-constrained programming considering optimal load-shedding direction [J]. *Electric Power Automation Equipment*, 2017, 37(8): 35 – 42. (in Chinese)
- [24] 徐斌,俞静. 基于期权视角的海外市场拓展的双目标多项目多期优化随机机会约束模型 [J]. *中国管理科学*, 2010, 18(04): 14 – 20.
XU Bin, YU Jing. The bi-objective stochastic chance-constrained combination optimization model of multi-project and multi-item market development based on the perspective of real options [J]. *Chinese Journal of Management Science*, 2010, 18(04): 14 – 20. (in Chinese)
- [25] WU J K, TANG L. Multi-objective stochastic scheduling models for hydrothermal plants based on fuzzy chance constrained programming [J]. *Proceedings of the CSEE*, 2011, 31(25): 26 – 34.
- [26] MEHLAWAT M K, GUPTA P. COTS products selection using fuzzy chance-constrained multiobjective programming [J]. *Applied Intelligence*, 2015, 43(4): 732 – 751.
- [27] TIMMIS J, HONE, STIBOR T, et al. Theoretical advances in artificial immune systems [J]. *Theoretical Computer Science*, 2008, 403(1): 11 – 32.

- [28] 马元锋,李昂儒,余慧敏,等. 基于动态拥挤距离的混合多目标免疫优化算法[J]. 计算机科学,2018,45(S1):63-68.
MA Yuan-feng, LI Ang-ru, YU Hui-min, et al. Dynamic crowding distance-based hybrid immune algorithm for multi-objective optimization problem[J]. Computer Science,2018,45(S1):63-68. (in Chinese)
- [29] GONG M G, JIAO L C, DU H F, et al. Multiobjective immune algorithm with nondominated neighbor-based selection[J]. Evolutionary Computation, 2008, 16(2):225-255.
- [30] MARTINEZ-PENALOZA M, MEZURA-MONTES E. Immune generalized differential evolution for dynamic multi-objective environments; an empirical study[J]. Knowledge-Based Systems,2018,142:192-219.
- [31] XIA X, ZHOU Y. On the effectiveness of immune inspired mutation operators in some discrete optimization problems[J]. Information Sciences,2018,426:87-100.
- [32] ZHANG Z H, WANG L, LONG F. Immune optimization approach solving multi-objective chance-constrained programming[J]. Evolving Systems,2013,6(1):41-53.
- [33] ZHANG Z H, TU X. Probabilistic dominance-based multi-objective immune optimization algorithm in noisy environments[J]. Journal of Computational and Theoretical Nanoscience,2007,4(7):1380-1387.
- [34] LIU B D. Theory and Practice of Uncertain Programming (2nd ed) [M]. Berlin:Springer-Varlag,2009. 50-53.
- [35] 黄席樾,张著洪,何传江,等. 现代智能优化算法理论与应用[M]. 北京:科学出版社,2005. 18-21.
HUANG Xi-yue, ZHANG Zhu-hong, HE Chuan-jiang, et al. Modern Intelligence Algorithms: Theory and Application[M]. Beijing, China: Science Press,2005. 18-21. (in Chinese)
- [36] LIN Q, CHEN J, ZHAN Z H, et al. A hybrid evolutionary immune algorithm for multiobjective optimization problems[J]. IEEE Transactions on Evolutionary Computation,2016,20(5):711-729.
- [37] 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.
- [38] ZHU Q L, LIN Q Z, CHEN W N, et al. An external archive-guided multiobjective particle swarm optimization algorithm[J]. IEEE Transactions on Cybernetics,2017,47(9):2794-2808.
- [39] 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.
- [40] LI K, DEB K, ZHANG Q F, et al. An evolutionary many-objective optimization algorithm based on dominance and decomposition[J]. IEEE Transactions on Evolutionary Computation,2015,19(5):694-716.
- [41] ZHANG Q F, LI H. MOEA/D: a multiobjective evolutionary algorithm based on decomposition[J]. IEEE Transactions on Evolutionary Computation, 2008, 11(6):712-731.
- [42] QIAN S Q, YE Y Q, JIANG B, et al. Constrained multiobjective optimization algorithm based on immune system model[J]. IEEE Transactions on Cybernetics,2015,46(9):2056-2069.
- [43] ZITZLER E, LAUMANN S M, THIELE L. SPEA2: Improving the strength Pareto evolutionary algorithm[A]. Evolutionary Methods for Design, Optimization and Control with Applications To Industrial Problems[C]. Berlin: Springer-Verlag,2002. 95-100.
- [44] POOJARI C A, VARGHESE B. Genetic algorithm based technique for solving chance constrained problems[J]. European Journal of Operational Research,2008,185(3):1128-1154.
- [45] 张著洪,黄席樾. 一种新的免疫算法及其在多模态函数优化中的应用[J]. 控制理论与应用,2004,(01):17-21.
ZHANG Zhu-hong, HUANG Xi-yue. Novel immune algorithm and its application to multi-modal function optimization[J]. Control Theory & Applications,2004,(01):17-21. (in Chinese)
- [46] DE CASTRO L N, VON ZUBEN F J. The clonal selection algorithm with engineering applications[A]. Proceedings of Genetic and Evolutionary Computation Conference[C]. CA, USA: Morgan Kaufman Publisher,2000. 36-37.
- [47] VELDHUIZEN D A V. Multiobjective evolutionary algorithms: classifications, analyses, and new innovations[J]. Evolutionary Computation,1999,8(2):125-147.
- [48] DEB K. Advances in evolutionary multi-objective optimization[A]. Symposium on Search Based Software Engineering[C]. Berlin: Springer,2012. 1-26.
- [49] LIM W J, JAMBEEK A B, NEOH S C, et al. Kursawe and ZDT functions optimization using hybrid micro genetic algorithm (HMGA)[J]. Soft Computing, 2015, 19(12):3571-3580.
- [50] DEB K. Multi-objective genetic algorithms: Problem difficulties and construction of test problems[J]. Evolutionary Computation,1999,7(3):205-230.
- [51] 毕超超,范勤勤,王维莉. 基于策略自适应的多目标差分进化算法及其应用[J]. 计算机应用研究,2019,37(7):1-7.
BI Chao-chao, FAN Qin-qin, WANG Wei-li. Multi-objective

tive differential evolution algorithm based on self-adaptive strategy and its application[J]. Application Research of


Computers,2019,37(7):1-7. (in Chinese)

作者简介



张仁崇(通信作者) 男,1988年4月出生,贵州三都人.2016年在贵州大学获理学硕士学位.现为贵州商学院计算机与信息工程学院助教,CAAI会员,主要研究方向为智能优化算法.

E-mail:zhangrenchong1990@163.com




潘春燕 女,1990年10月出生,贵州三都人.2017年在贵州民族大学获理学硕士学位.现为黔南民族师范学院数学与统计学院讲师,主要研究方向为数据挖掘.

E-mail:chunyanpan666@163.com



武星 男,1988年7月出生,安徽来安人.2014年在贵州大学获工程硕士学位.现为贵州商学院管理学院讲师,主要研究方向为物流与供应链管理.

E-mail:wuxingjobmail@163.com



杨坤 男,1987年11月出生,贵州织金人.2017年在贵州民族大学获理学硕士学位.现为贵州商学院计算机与信息工程学院讲师,主要研究方向为模式识别与图像处理.

E-mail:kunflv@126.com