

基于直觉模糊支配的混合多目标粒子群算法

梅海涛 华继学 王毅 文童

(空军工程大学防空反导学院 西安 710051)

摘要 为提高求解多目标优化问题的精确性和解集分布的均匀性,提出了一种基于直觉模糊支配的混合粒子群算法。通过引入种群全局目标值标量参数、直觉模糊隶属度和排序方法,定义一种新的最优解支配关系;采用基于模拟退火的 Meta-Lamarckian 局部学习策略,结合粒子群算法,以避免算法陷入局部最优和早熟;此外,定义种群同构因子来衡量种群多样性,以自适应调节惯性权重和加速因子;提出一种递减扰动策略对粒子飞行速度进行扰动;最后,与多种经典多目标优化算法进行仿真测试比较,结果表明该算法在求解精度、解集分布均匀性上具有明显优势。

关键词 直觉模糊支配,混合粒子群优化,模拟退火,拉马克学习,同构因子

中图分类号 TP18 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.01.047

Hybrid Multi-objective Particle Swarm Optimization Based on Intuitionistic Fuzzy Dominance

MEI Hai-tao HUA Ji-xue WANG Yi WEN Tong

(Air and Missile Defense College, Air Force Engineering University, Xi'an 710051, China)

Abstract To improve the precision and distribute uniformity of multi-objective optimization problem, a hybrid multi-objective particle swarm optimization based on intuitionistic fuzzy dominance (IFDHP SO) was proposed. By introducing the scalar factor, this paper utilized intuitionistic fuzzy membership and rank method to define a new dominance strategy. Then, we proposed a meta-lamarckian local learning strategy to reduce the probability of being trapped into the local optima and premature convergence, which is based on simulated annealing algorithm. Then, the PSO identical factor was defined to adjust inertia weight and acceleration operator adaptively. Furthermore, a decline disturbance strategy was proposed to disturb particle's velocity. Finally, the simulation results comparing with other typical optimization algorithm shows that the proposed algorithm performs better in solution precision, uniformity and convergence.

Keywords Intuitionistic fuzzy dominance, Hybrid particle swarm optimization, Simulated annealing, Meta-lamarckian learning, Identical factor

1 引言

生活中的许多优化问题由于各目标相互冲突,需同时考虑各变量之间的约束关系,称其为多目标优化问题(Multi-objective Optimization Problem, MOP)。由于 MOP 的自身特性,很难找出一个能使所有目标同时达到最优的解,需要在各目标函数间折衷选出具有代表性的 Pareto 最优解集^[1]。传统解决 MOP 的方法利用加权法将多目标转化为单目标,但其依赖于问题的先验知识,对高维、复杂 MOP 问题的求解效率很低。基于群体行为的启发式智能算法一次迭代便可得到一组 Pareto 最优解,为解决 MOP 提供了一种新思路,自 Schaffer 首次采用进化算法解决 MOP 问题(VEGA)以来,多种群体智能算法被用于解决 MOP 问题。Srinivas 等提出了非支配排序的遗传算法 NSGA^[2]; Deb 等^[3]对 NSGA 进行了改进,提出了 NSGAI; Zitzler 和 Thiele 提出了强 Pareto 关系的进化算法 SPEA 及增强型的 SPEAII^[4]; Deb 等^[5]提出了基于 ϵ -支配关系的 EPSMOEA; Coello 等^[6]提出了多目标粒子群优化算法; 公茂果等^[7]在克隆选择的基础上提出了非支配

领域选择的多目标优化算法 NNIA 及 NNIA2^[8]。

粒子群优化算法^[9](Particle Swarm Optimization, PSO)是 Kennedy 和 Eberhart 于 1995 年受鸟群捕食过程飞行规律的启发而提出的。相比其他群体智能算法, PSO 算法实现简单、快速收敛、求解效率高,在求解 MOP 上具有很大的优势。文献^[10]运用 PSO 算法解决预警作战资源调度问题,并与领域搜索相结合,结果表明该方法能快速有效地调度资源;文献^[11]将其用于项目选址问题,依据实际问题设计了目标函数、编码机制、状态更新机制,选址方案更加科学有效。但 PSO 也存在依赖参数初始值、易早熟收敛、精度低等缺陷。为此,文献^[12]提出了一种基于模糊支配的多目标粒子群算法,采用模糊隶属度对种群的支配关系进行改进,明确了个体间的支配能力。文献^[13]提出基于信息共享和速度扰动因子的 PSO 算法,采用信息共享函数以避免算法陷入早熟收敛,采用扰动因子以帮助 PSO 跳出局部最优。

本文在对 PSO 和 MOP 问题已有研究成果的基础上提出了直觉模糊支配的混合粒子群优化算法,直觉模糊支配重新定义了粒子支配关系,可精确描述多决策变量解的优劣性,更

到稿日期:2015-12-11 返修日期:2016-03-04 本文受国家自然科学基金(61402517),中国博士后基金(2013M542331),陕西省自然科学基金(2013JQ8035)资助。

梅海涛(1993-),男,硕士,主要研究方向为智能信息处理与智能决策, E-mail: meihai14@163.com; 华继学(1966-),男,副教授,硕士生导师,主要研究方向为分布式软件与网络信息系统等; 王毅(1979-),男,博士后,硕士生导师,主要研究方向为智能信息处理与智能决策等; 文童(1993-),男,硕士,主要研究方向为智能信息处理与智能决策。

符合原始支配解的概念;引入基于模拟退火的 Meta-Lamarckian 局部学习策略来平衡 PSO 的收敛速度与求解精度,增强算法的局部逃逸能力;定义一种种群同构因子来衡量种群多样性,运用同构因子函数来自适应调节惯性权重和加速因子,此外,提出一种速度扰动策略以提高算法的全局收敛能力。多组实验结果表明了 IFDHPSO 的可行性和有效性。

2 多目标优化问题的数学描述

不失一般性, MOP 的数学形式可描述^[7]为:

$$\begin{aligned} \min y &= f(x) = (f_1(x), f_2(x), \dots, f_m(x)) \\ x &= (x_1, x_2, \dots, x_n) \in X \subset \mathbb{R}^n \\ y &= (y_1, y_2, \dots, y_m) \in Y \subset \mathbb{R}^m \end{aligned} \quad (1)$$

其中, x 为决策变量; X 为 n 维决策空间; y 表示目标函数; Y 表示 m 维目标空间。

定义 1 (Pareto 支配关系) 设 s 和 t 为 n 维粒子群中的任意两个不同个体, 称 s Pareto 支配 t , 记为 $s > t$, 若满足:

- (1) $f_i(s) \leq f_i(t) (i=1, 2, \dots, n)$;
- (2) $\exists l \in \{i=1, 2, \dots, n\}$, 满足 $f_l(s) < f_l(t)$ 。

定义 2 (Pareto 最优解, 非劣最优解) 设 $x^* \in R$ 为决策空间的一点, 则称 x^* 为 Pareto 最优解, 当且仅当对于 $x \in R$ 满足:

- (1) $\bigwedge_{k \in K} (f_k(x) = f_k(x^*))$, 或者
- (2) $\exists j \in K(1, 2, \dots, n)$, s. t. $f_j(x) > f_j(x^*)$ 。

定义 3 (Pareto 最优前端) 目标函数 $\min y = f(x)$ 和它的 Pareto 最优解集为 $\{x^*\}$, y 的 Pareto 最优前端为:

$$PF^* = \{f_1(x), f_2(x), \dots, f_m(x) | x \in x^*\} \quad (2)$$

3 直觉模糊支配的混合粒子群算法

3.1 直觉模糊支配关系

求解多维复杂 MOP 问题时, 随着目标维数和迭代次数的增加, 种群中同构个体不断增多, 算法难以收敛到全局最优, 使寻优结果偏离真实 Pareto 前端。基于此, Drechsler 等提出了目标优胜关系的宽松 Pareto 支配关系^[14], 但该关系易受目标函数数量纲差别的影响; M. Farina 等^[15]将模糊理论引入到多目标优化问题中, 基于个体间目标优劣个数衡量支配关系, 提出了 $(1-k_F)$ 支配, 但种群个体易陷入循环支配, 无法择出最优支配解; Hernandez-diaz 等于 2007 年通过引入评判目标间优劣关系的阈值提出了 ϵ -占优策略^[16], 但该策略依赖阈值的选取方法。

鉴于以上支配策略存在的不足, 本文提出了一种直觉模糊支配关系, 利用目标函数值对应的优劣个体数量确定相应支配解的隶属度和非隶属度, 引入直觉模糊得分函数和精确函数对个体进行支配关系排序。设 $L(x_1, x_2)$ 表示个体 x_1 比个体 x_2 表现更优的目标函数值的个数, $M(x_1, x_2)$ 表示个体 x_1 与个体 x_2 表现一致的目标函数值的个数, $N(x_1, x_2)$ 表示个体 x_1 比个体 x_2 表现更差的目标函数值的个数, 相应的隶属度函数和非隶属度函数为:

$$\mu_{x_1 \succ x_2} = \frac{L(x_1, x_2)}{L(x_1, x_2) + M(x_1, x_2) + N(x_1, x_2)} \quad (3)$$

$$\gamma_{x_1 \succ x_2} = \frac{N(x_1, x_2)}{L(x_1, x_2) + M(x_1, x_2) + N(x_1, x_2)} \quad (4)$$

当隶属度大小相同时, 引入得分函数和精确函数, 分别记为 S 和 H :

$$S(x_1) = \mu_{x_1 \succ x_2} - \gamma_{x_1 \succ x_2}, \quad H(x_1) = \mu_{x_1 \succ x_2} + \gamma_{x_1 \succ x_2} \quad (5)$$

定义 4 设 $\alpha = (\mu_1, \gamma_1), \beta = (\mu_2, \gamma_2)$ 为两个直觉模糊数:

- (1) 若 $S(\alpha) < S(\beta)$, 或 $S(\alpha) = S(\beta)$ 且 $H(\alpha) < H(\beta)$, 规定 α 小于 β , 记为 $\alpha < \beta$;
- (2) 若 $S(\alpha) = S(\beta)$ 且 $H(\alpha) = H(\beta)$, 规定 α 等于 β , 记为 $\alpha = \beta$ 。

此外, 定义一个只有值大小的标量参数 P_s , P_s 具有传递性, 作为从全局衡量个体目标函数值大小的标准, 若 $P_s(x_1) < P_s(x_2)$ 且 $P_s(x_2) < P_s(x_3)$, 可得 $P_s(x_1) < P_s(x_3)$, 可防止个体陷入循环支配。

$$P_s(x) = \sqrt{\sum_{i=1}^n (f_i(x) - Q)^2} \quad (6)$$

$$\mu_{x_1 \succ x_2} = \begin{cases} \mu_{x_1 \succ x_2}, & P_s(x_1) < P_s(x_2) \\ -\mu_{x_1 \succ x_2}, & P_s(x_1) \geq P_s(x_2) \end{cases} \quad (7)$$

其中, $Q = \min(f(x_i))$ 为粒子群目标函数值的参考值。当 $S(\alpha) = S(\beta)$ 且 $H(\alpha) = H(\beta)$ 时, 无法对 α 和 β 的直觉模糊支配度进行排序(结果相同), 认为 α 和 β 不能以绝对优势支配另一个非劣解, 采用式(7)对直觉模糊支配度进行更新, 选出最优非劣解, 更新外部档案。

定义 5 (直觉模糊支配) 设 x_1, x_2 为决策变量空间中的任意两点, 若满足 $\mu_{x_1 \succ x_2} \geq C (C \in (0.5, 1])$, 则称 x_1 直觉模糊支配 x_2 , 记为 $\mu_{x_1 \succ x_2}$ 。

其中, C 用来调节支配宽松度。随着迭代次数的增加, 个体的非劣解数目急剧增多, 需不断放松支配条件, 从而增加选择压力, 避免非支配解数量超过种群规模。若 $C=1$, 要使 x_1 支配 x_2 , 需满足 $N(x_1, x_2) = 0$ 且 $L(x_1, x_2) > 0$, 此时直觉模糊支配等同于 Pareto 支配; $C=0.5$ 时, 要使 x_1 支配 x_2 , 需满足 $L(x_1, x_2) > N(x_1, x_2)$; 当 $C \in (0.5, 1)$ 时, 直觉模糊支配关系等同于宽松 Pareto 支配, 故需自适应调整 C 值, 使其从 1 逐渐向 0 靠拢, 如式(8)所示:

$$C = 0.5 + 0.5 \times \exp(-2t/T) \quad (8)$$

其中, t 为算法当前迭代数, T 为最大迭代次数。

3.2 模拟退火的 Meta-Lamarckian 学习策略

虽然 PSO 实现简单、求解速度快, 但存在易早熟收敛的缺陷^[9], PSO 前期收敛速度快, 极值更新机制易使算法陷入早熟收敛, 降低了算法的全局搜索能力; 在后期, 大量同构粒子充斥着整个空间, 使种群多样性降低, 导致收敛速度很慢, 甚至无法寻优到全局最优解。鉴于此, 提出一种基于模拟退火算法的 Meta-Lamarckian 学习策略, 并与 PSO 算法进行结合, 以增强局部逃逸能力和全局搜索能力。

模拟退火算法是一种启发式算法, 概率跳出原则可以有效地避免算法陷入局部最优^[17], 根据目标函数值变化量 ΔE , 决定粒子被选择接受的概率。在迭代搜索过程中, 除接受优化解外, 还可以按照随机接受准则(Metropolis 准则)概率接受劣质解, 且接受概率随着搜索进程逐渐降低, 最终趋于零, 这有利于 PSO 从局部最优区域中跳出来。随着温度的下降, 粒子逐渐变成低能量的状态, 收敛至全局最优。

模拟退火 Meta-Lamarckian 学习策略从多领域结构中选择最适于当前搜索的结构进行局部搜索, 借鉴文献[18]中的自适应 Meta-Lamarckian 学习策略, 选择领域结构用来进行局部搜索, 其步骤如下。

Step1 生成 n 种不同的领域结构, 对群体最佳位置 g_{best} 按模拟退火策略在初始温度下同时进行 $n(n-1)$ 步局部搜索;

Step2 按式(9)计算每个领域的奖励值:

$$\Delta E = |pf - cf_i|, \eta_i = \Delta E / (n(n-1)) \quad (9)$$

其中, pf 为局部搜索前 g_{best} 的函数值, cf_i 为在第 i ($i=1, 2, \dots, n$) 种领域结构进行局部搜索后所获得的最佳目标函数值, ΔE 表示目标函数值的变化量;

Step3 根据 Step2 中所获得每个领域相应的奖励值 η_i , 计算每个领域被选择的概率:

$$p_{\alpha, i} = \frac{\eta_i}{\sum_{j=1}^n \eta_j} \quad (10)$$

Step4 采用轮盘赌方法, 根据 Step3 中的选择概率确定一个领域结构对种群的最佳位置, 在当前温度下进行局部搜索;

Step5 更新奖励值 η_i , 当第 i 个领域结构在 Step4 中被选择时, 使 $\eta_i = \eta_i + \Delta\eta_i$ 进行更新, $\Delta\eta_i$ 由式(8)计算得到。

模拟退火算法的初始温度过高会引起多余搜索, 为使所有状态都有被选择的概率, 设 $t_k = \lambda t_{k-1}$ ($0 < \lambda < 1$), 平衡计算速度和降温速度, 使算法的求解质量与搜索效率都得到满足, 模拟退火局部搜索策略只作用在目前搜索到的最优解上, 在发现较优解后应更新全局最优解 g_{best} 。

3.3 参数自适应调整的 PSO 算法

惯性权重 ω 的大小可影响算法的收敛速度和求解质量, 加速因子 c_1, c_2 分别为粒子的个体和社会认知能力, 引导粒子向个体历史最优和全局历史最优的位置飞行。在 PSO 初期, 应取较大的惯性权重, 在前期应设置较大的 c_1 和较小的 c_2 , 个体主要参考本身信息, 增强种群多样性; 在后期, 应降低惯性权重, 增大 c_2 并减小 c_1 , 加强粒子的社会认知能力, 加快算法收敛速度。

在算法迭代前期, 种群中同构个体较少, 适应度差别较大, 而在后期粒子适应度差别很小, 同构个体增多, 定义同构因子 s_v 来反映粒子种群多样性, 自适应地调整惯性权重值。

$$s_v = \frac{1}{(1 + \frac{a}{N} \sqrt{\sum_{i=1}^N f_i^t - f_{avg}^t})} \quad (11)$$

其中, N 为粒子种群规模; f_i 和 f_{avg} 分别为在算法第 t 次迭代过程中第 i 个粒子的适应度值和全局平均适应度值; $a=0.1 \times N$ 为调整系数, 显然 $s_v \in (0, 1)$ 。定义同构因子函数 θ_{s_v} :

$$\theta_{s_v} = 1 - \cos(\frac{\pi}{2} s_v) \quad (12)$$

则自适应的 ω, c_1, c_2 为:

$$\omega^{t+1} = \omega_{max} - (\omega_{max} - \omega_{min}) \cdot \theta_{s_v} \quad (13)$$

$$c_1^{t+1} = c_1^{max} - (c_1^{max} - c_1^{min}) \cdot \theta_{s_v} \quad (14)$$

$$c_2^{t+1} = c_2^{min} - (c_2^{max} - c_2^{min}) \cdot \theta_{s_v} \quad (15)$$

其中, $\omega \in [0.4, 0.9]$, $c \in [0.5, 2.5]$ 。

3.4 递减扰动策略

通过增加一项递减扰动, 对 PSO 算法的速度更新公式进行改进, 如下:

$$\begin{cases} v_{id}^{t+1} = \omega v_{id} + c_1 r_1 (p_{id} - x_{id}^t) + c_2 r_2 (p_{gd} - x_{id}^t) + l r_3 \\ x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1} \end{cases} \quad (16)$$

其中, $l = -d_1(x - d_2)$ 是由参数 d_1 和 d_2 控制的线性递减函数; r_3 服从 $[0, 1]$ 分布; $x = t \Delta x$, d_1 和 d_2 是可被动态设定的固定参数, t 为当前迭代次数, Δx 为迭代前后的位置变化。

在算法前期, 粒子以较快速度飞行到个体极值, 且具有较强的全局搜索能力, 因此递减扰动效果几乎可以忽略不计。随着迭代的进行, 大量粒子聚集在一起易使算法停滞不前, 式(16)通过改进粒子的速度更新公式, 扰动索引按一固定速率

下降, 最终会对寻优粒子产生一个小幅度的扰动, 帮助粒子跳出局部最优解, 收敛至全局最优解。

本文 IFDHPSO 算法流程描述如下:

Step1 初始化算法参数, 设置种群规模 N , 加速因子 c_1 和 c_2 , 惯性权重 ω , 起始、停止温度, 退火速度 K , 最大迭代次数 T , 外部存储档案大小;

Step2 随机生成种群规模为 N 的粒子种群, 确定每个粒子的初始位置 x_i , 初始速度 v_i 及粒子自身最好位置 p_{best} ;

Step3 计算每个粒子的适应度值, 与 p_{best} 和 g_{best} 比较, 择优进行更新;

Step4 根据直觉模糊支配关系计算粒子个体直觉模糊支配隶属度, 并进行排序, 将得到的非劣解存储到外部存储器中;

Step5 计算当代种群同构因子函数 s_v , 自适应调节惯性权重 ω 及加速因子 c_1 和 c_2 ;

Step6 将 Step5 中自适应权重和加速因子按式(16)更新粒子飞行的速度和位置;

Step7 生成 n 种不同的领域结构, 按 2.2 节中的模拟退火的 Meta-Lamarckian 学习策略计算目标函数变化量 ΔE , 得出每个领域的奖励值 η_i , 按 Metropolis 准则随机确定一领域进行局部搜索;

Step8 计算每个粒子的适应度值, 与 p_{best} 和 g_{best} 比较, 择优进行更新;

Step9 计算粒子直觉模糊隶属度, 进行直觉模糊支配排序, 更新外部存储档案;

Step10 判断是否寻优到最优解或达到最大迭代次数(停机准则), 若是, 则停止; 否则, 转 Step3。

4 实验仿真与结果分析

为验证本文算法求解 MOP 问题的性能, 对 SCH^[7], ZDT1, ZDT2, ZDT3, ZDT4, ZDT6, DTLZ1, DTLZ2^[2] 进行测试, 并与经典算法 NSGAI, MOPSO, NNIA2 就 GD 值和 SP 值进行对比。设置 NSGAI 算法种群规模为 100, 交叉率为 0.8, 变异率为 0.02; MOPSO 算法种群规模为 100, $c_1 = c_2 = 2$, $\omega \in [0.4, 0.9]$; 设置 NNIA2 免疫优势抗体规模为 100, 活性种群规模为 30, 克隆种群大小为 100。

4.1 算法性能评价标准

(1) 收敛性 (Generational Distance, GD), 表示所求非劣解逼近真实 Pareto 解的程度:

$$GD = \frac{1}{n} \sqrt{\sum_{i=1}^n d_i^2} \quad (17)$$

其中, n 为外部档案中非劣解个数, d_i 为第 i 个非劣解与真实 Pareto 解的最小距离, 若 GD 为零, 表明所求非劣解与真实 Pareto 解吻合, GD 越小则算法性能越好。

(2) 均匀性 (Spacing, SP), 非劣解集中每个体与其邻居之间的距离变化情况衡量解集在目标空间的分布情况:

$$SP = \sqrt{\sum_{i=1}^n (\bar{D} - d_i)^2 / (n-1)} \quad (18)$$

其中, $d_i = \min(|f_i^j(x) - f_i^j(x)| + |f_i^j(x) - f_i^j(x)|)$, $i, j = 1, 2, \dots, n$, n 为非劣解的个数, SP 为零, 说明所求的非劣解前端分布均匀, SP 值越小, 非劣解前端分布越均匀, 算法性能越好。

4.2 算法复杂度分析

设 IFDHPSO 算法中最大迭代次数为 T , N 为粒子种群规模, D 表示变量的维数。故可得 IFDHPSO 算法的时间复杂度, 如表 1 所列。

表 1

IFHDPSO 流程	时间复杂度
1 基本粒子群算法	$O(NDT)$
2 适应度排序	$O(ND)$
3 计算 s_v	$O(ND)$
4 调整 ω, c_1, c_2	$O(3NT)$
5 更新速度、位置	$O(2ND)$
6 退火策略	$O(T)$
7 计算适应度、更新	$O(3ND)$
8 更新存储档案	$O(2ND)$
9 终止条件判断	$O(ND)$

参照表 1 可得 IFHDPSO 算法的时间复杂度为:

$$T(N) = O(NDT) + O(ND) + O(ND) + O(3NT) + O(2ND) + O(T) + O(3ND) + O(2ND) + O(ND)$$

$$= O(NDT) + O(NDK) + O(T) \quad (19)$$

由此可知,相比基本 PSO 算法,IFHDPSO 算法确实增加了时间复杂度,而当变量维数很小时,IFHDPSOS 算法不会显著增加时间复杂度;相反,在迭代次数很大时,则 IFDHP SO 算法与基本 PSO 算法的时间复杂度相差无异,因此可以认为它是一种可取的算法。

4.3 算法性能比较分析

IFDHP SO 算法与 NSGA-II, MOPSO, NNIA2 对测试函数分别进行 2000, 500, 2000 次函数评价后所得的最优前端与真实 Pareto 前端之间的对比如图 1 所示,表 2 为 4 种算法求解性能比较。

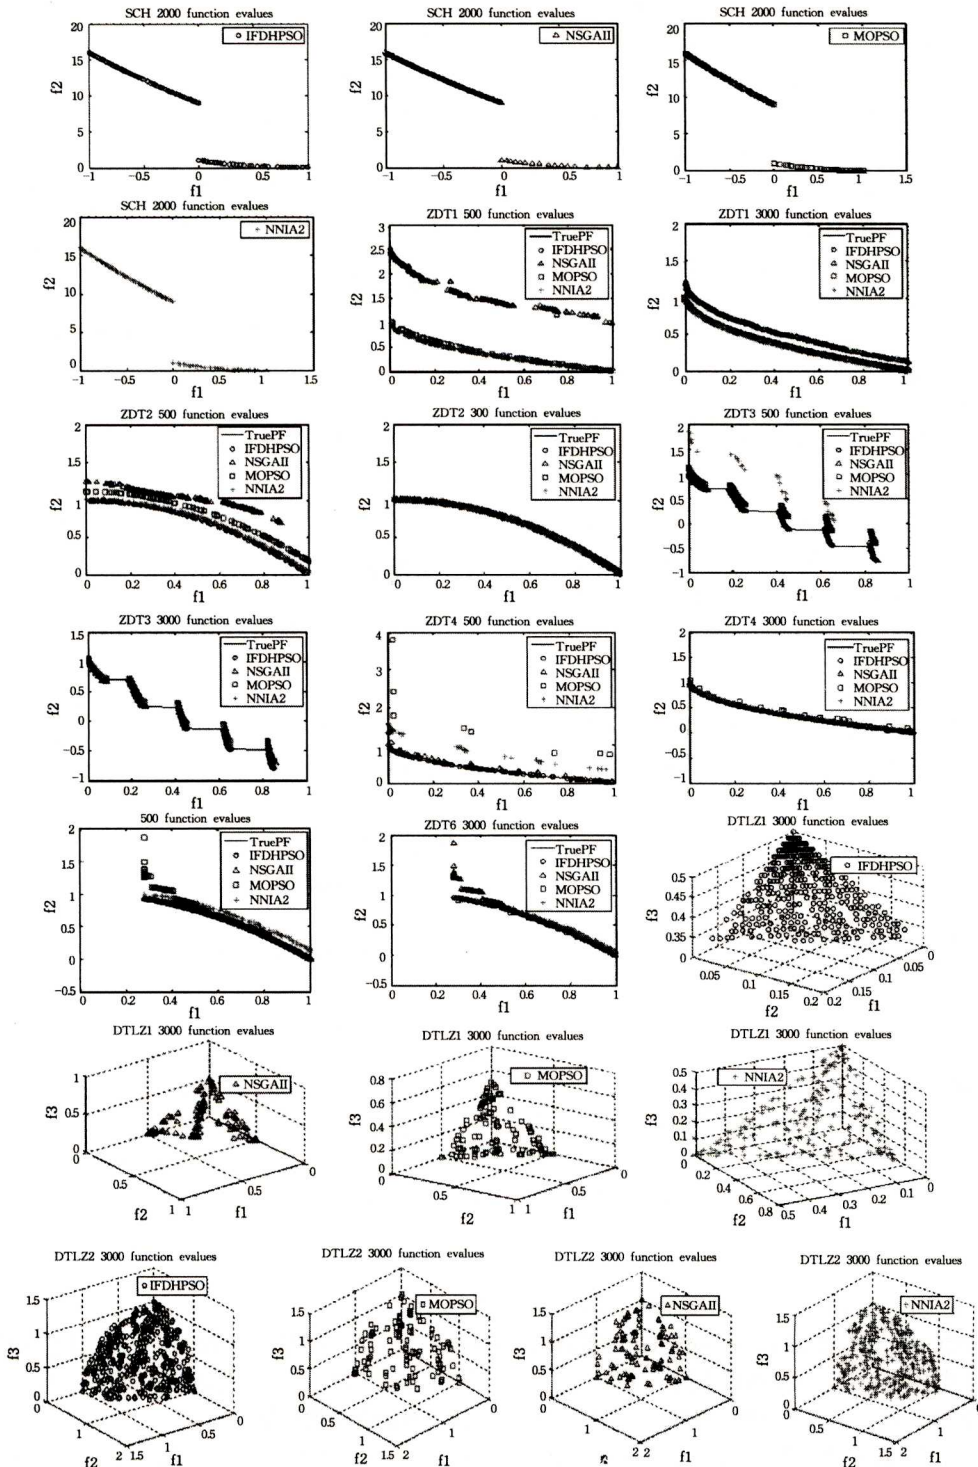


图 1 4 种算法在 2000, 500, 2000 次函数评价的最优前端

表 2 4 种算法求解的 GD 和 SP 值的比较结果

测试函数	算法	GD 值			SP 值			时间 (s)
		Best	Average	Worst	Best	Average	Worst	
SCH	IFDHPSO	0.002117	0.002345	0.002842	0.3649	0.4215	0.5873	10.354
	NSGAI	0.003089	0.003382	0.003554	0.4256	0.5726	0.7687	23.625
	MOPSO	0.002941	0.003242	0.003799	0.3847	0.4524	0.5319	7.889
	NNIA2	0.002963	0.003237	0.003506	0.4319	0.5692	0.6691	11.671
ZDT1	IFDHPSO	0.002654	0.015960	0.027769	0.0029	0.0061	0.0203	12.263
	NSGAI	0.046512	0.075551	0.122316	0.4340	0.7901	0.5375	21.648
	MOPSO	0.063836	0.081128	0.124011	0.5534	0.5915	0.6528	13.987
	NNIA2	0.075705	0.016844	0.126365	0.0138	0.0157	0.0854	15.369
ZDT2	IFDHPSO	0.006248	0.008156	0.013260	0.2306	0.3517	0.4572	8.412
	NSGAI	0.095841	0.152121	0.251330	0.5495	0.8819	1.0800	17.864
	MOPSO	0.103316	0.244976	0.484534	0.5780	0.9287	1.0964	10.668
	NNIA2	0.046923	0.071523	0.126482	0.4633	0.6648	0.7814	16.067
ZDT3	IFDHPSO	0.024435	0.056783	0.067754	0.0654	0.1640	0.1886	25.765
	NSGAI	0.600920	0.645840	0.712746	0.6621	0.7963	0.8448	37.621
	MOPSO	0.113631	0.157366	0.227841	0.5348	0.6076	0.6621	28.364
	NNIA2	0.246637	0.319562	0.694855	0.7956	0.8812	0.9364	42.693
ZDT4	IFDHPSO	1.2185E-4	3.7295E-4	4.3326E-4	0.0043	0.0052	0.5469	12.635
	NSGAI	0.000482	0.002176	0.004297	0.5236	2.7659	3.4006	31.410
	MOPSO	0.000736	0.001245	0.000763	0.3012	1.1347	1.7712	18.347
	NNIA2	0.000664	0.004751	0.005960	0.9653	1.8464	2.3684	26.594
ZDT6	IFDHPSO	0.036225	0.253844	0.658459	0.0649	0.0901	0.1721	14.365
	NSGAI	2.498493	3.073925	3.707603	0.9343	0.9549	0.9832	22.241
	MOPSO	0.523178	1.029723	1.667019	0.7882	0.9276	1.0161	13.472
	NNIA2	1.049562	2.937410	4.958647	0.7257	0.9745	1.2036	21.269
DTLZ1	IFDHPSO	1.6245E-4	3.1564E-4	4.5169E-4	0.00236	0.0065	0.0094	36.354
	NSGAI	0.020413	0.091249	0.143371	0.0314	0.1034	0.2191	20.632
	MOPSO	0.081076	0.286970	0.634154	0.0148	0.0638	0.1425	35.86
	NNIA2	0.065262	0.178251	0.356142	0.0276	0.0850	0.2599	43.427
DTLZ2	IFDHPSO	2.1526E-4	4.1623E-4	5.1547E-4	0.0298	0.0356	0.0536	30.362
	NSGAI	5.3293E-4	6.1871E-4	8.4146E-4	0.3171	0.3761	0.4088	47.349
	MOPSO	3.5062E-4	4.8022E-4	7.3600E-3	0.0125	0.0458	0.0790	23.374
	NNIA2	4.2615E-4	7.2315E-4	8.3251E-3	0.2135	0.2496	0.3742	41.541

从图 1 可得, IFDHPSO 算法对测试函数所求最优 Pareto 解的数目、分布情况以及与真实 Pareto 前端的逼近程度, 相比其他 3 种算法均有明显优势。对于 ZDT1 函数, 加入模拟退火的 Meta-Lamarckian 局部学习策略, 算法可以跳出局部最优, 避免早熟收敛, IFDHPSO 算法在 500 次迭代时曲线光滑, Pareto 解均匀且密集地靠近真实 Pareto 前端, 而 NSGAI 因易陷入局部最优, 难以收敛到全局最优; 对于 ZDT4 函数, IFDHPSO 算法引入参数控制和直觉模糊支配关系, 在保证算法快速收敛到全局最优解的同时, 优化了解集间的支配关系, 在函数评价 3000 次时所得最优 Pareto 解逼近理想 Pareto 前端且各最优解之间的距离较小, 分布均匀, 说明递减扰动策略可以有效地使 IFDHPSO 算法跳出局部最优解, 其他算法只能部分收敛到全局最优, 且解间跳跃性很大; 从 DTLZ1 和 DTLZ2 函数的优化结果可得, IFDHPSO 在求解 Pareto 数目和分布情况上有很大优势, 说明 IFDHPSO 算法的改进和引入策略的正确性和有效性。

从表 2 可得, DEB, ZDT2, ZDT3 的 GD 值指标相比其他 3 种算法均少一个数量级, 随着变量维数从 2 增至 30, 直觉模糊支配可更好地更新最优 Pareto 解集外部档案, 维护解集的数目和逼近真实 Pareto 前端的能力; 从 SCH 函数求解结果可得, 4 种算法求解结果相差很小, 说明其求解低维函数的能力与 IFDHPSO 算法基本相同, 直觉模糊支配关系并没有发挥其优势。随着目标维数的增多, 特别地, 对于 ZDT6 和 DTLZ1 函数, IFDHPSO 所求的 GD 值为其他算法的 0.01 倍, 这说明本文算法的收敛能力明显优于其他算法。在 SP

指标方面, 自适应粒子群参数调整策略以及递减扰动策略的作用可指导粒子的飞行方向和速度, 除 SCH 和 ZDT2 相差很小之外, 还可以从表 2 以及图 1 看出, 其余函数的 SP 最优值以及平均值均接近于 0, 且比其他算法约小 10 倍, 其中, ZDT4 函数的最好、平均 SP 值为 0.004267 和 0.005182, DTLZ1 函数的最好、平均 SP 值为 0.002361 和 0.006487, 这明显优于其他函数的优化结果, 模拟退火 Meta-Lamarckian 局部学习策略在领域中根据函数值变化量计算奖励值, 从而在领域中进行局部搜索, 使 IFDHPSO 算法跳出局部最优, 最优 Pareto 解集分布更加均匀且宽广。此外, 在时间复杂度方面, 对于一般简单的 MOP 问题, 由于维数较小, IFDHPSO 并没有很大地增加其时间开销; 对于复杂 MOP 问题, 如 ZDT3, ZDT4, ZDT6, DTLZ1, DTLZ2, 需要多次迭代搜索, 由于可以跳出局部最优, 相比其他算法, IFDHPSO 可以很快地搜索到最优解。综上可得, 本文所提 IFDHPSO 算法具有较强的局部寻优能力和全局寻优能力, 分布性和收敛性较优, 提高了多目标优化问题的求解性能。

结束语 针对经典多目标优化问题, 提出一种基于直觉模糊支配的混合多目标粒子群优化算法。1) 直觉模糊支配精确地刻画了最优解间支配关系, 可保证外部存储档案非劣解的更新; 2) 模拟退火的 Meta-Lamarckian 局部学习策略、递减扰动策略引导粒子跳出局部最优, 防止陷入早熟收敛; 3) 同构因子函数可增强种群多样性, 增强算法的全局搜索能力。实验结果表明, IFDHPSO 算法能够快速、有效地收敛至真实 Pareto 前端, 且在解集分布均匀性和宽广性方面有明显优势。

参考文献

- [1] ZENG Jie, NIE Wei. Novel multi-objective optimization algorithm[J]. Journal of Systems Engineering and Electronics, 2014, 25(4): 697-710.
- [2] QI Yu-tao, LIU Fang, CHANG Wei-yuan, et al. Memetic Immune Algorithm for Multiobjective Optimization[J]. Journal of Software, 2013, 24(7): 1529-1544. (in Chinese)
戚玉涛, 刘芳, 常伟远, 等. 求解多目标问题的 Memetic 免疫优化算法[J]. 软件学报, 2013, 24(7): 1529-1544.
- [3] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm: NSGAII[J]. IEEE Transaction on Evolutionary Computation, 2002, 6(2): 182-197.
- [4] ZITZLER E, LAUMANN S, THIELE L. SPEA2: Improving the strength Pareto evolutionary algorithm for multiobjective optimization[R]. TIK-Report, 103, Swiss Federal Institute of Technology, 2001: 1-21.
- [5] DEB K, MOHAN M, MISHRA S. Evaluating the epsilon-dominance based multi-objective evolutionary algorithm for a quick computation of Pareto-optimal solutions[J]. Evolutionary Computation, 2005, 13(4): 501-525.
- [6] COELLO C A C, PULIDO G T, LECHUGA M S. Handling multiple objectives with particle swarm optimization [J]. IEEE Trans on Evolutionary Computation, 2004, 8(3): 256-279.
- [7] GONG M G, JIAO L C, DU H F, et al. Multi-Objective immune algorithm with nondominated neighbor-based selection[J]. Evolutionary Computation, 2008, 16(2): 225-255.
- [8] YANG D D, JIAO L C, GONG M G, et al. Adaptive ranks and K-nearest neighbor list based multiobjective immune algorithm [J]. Computational Intelligence, 2010, 26(4): 359-385.
- [9] ZHANG Shi-hai, Ou Jin-ping. BP-PSO-based intelligent case retrieval method for high-rise structural form selection[J]. Science China Technological Sciences, 2013, 56(4): 940-944.
- [10] ZHAO Xin-shuang, WANG Hou-xiang, CAI Yi-chao. Resource scheduling method in antimissile early warning campaign[J]. System Engineering and Electronics, 2015, 37(6): 1300-1305. (in Chinese)
- [11] WANG Hua, ZHU Fu-bao. Site selection model of land consolidation projects based on multi-objective optimization PSO[J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(14): 255-263. (in Chinese)
王华, 朱付保. 基于多目标粒子群的土地整理项目选址模型[J]. 农业工程学报, 2015, 31(14): 255-263.
- [12] ZHANG En-ze, WU Yi-fei, CHEN Qing-wei. Particle swarm optimization algorithms for interval multi-objective optimization problems[J]. Control and Decision, 2014, 29(12): 2171-2176. (in Chinese)
章恩泽, 吴益飞, 陈庆伟. 一类区间多目标粒子群优化算法[J]. 控制与决策, 2014, 29(12): 2171-2176.
- [13] GAN Xu-sheng, DUANMU Jing-shun, MENG Yue-bo, et al. Wavelet neural network aerodynamic modeling from flight data based on pso algorithm with information sharing and velocity disturbance[J]. Journal of Central South University, 2013, 20(6): 1592-1601.
- [14] DRECHSLER N, DRECHSLER R, BECKER B. Multi-objective Optimization based on Relation favor[M]// Evolutionary multi-criterion optimization. Springer Berlin Heidelberg, 2001: 154-166.
- [15] FARIAN M, AMATO P. A fuzzy definition of "optimality" for many-criteria optimization problems[J]. IEEE Transactions on Systems, Man, and Cybernetics, 2004, 34(3): 315-326.
- [16] HERNANDEZ-DIAZ A G, SANTANA-QUINTERO L V, COELLO C A C, et al. Pareto-adaptive ϵ -dominance[J]. Evolutionary Computation, 2007, 15(4): 493-517.
- [17] GAO Hong-min, ZHOU Hui, XU Li-zhong, et al. Classification of hyperspectral remote sensing images based on simulated annealing genetic algorithm and multiple instance learning [J]. Journal of Central South University, 2014, 21(1): 262-271.
- [18] LIU Bo, WANG Ling, JIN Yi-hui. An effective hybrid PSO-based algorithm for flow shop scheduling with limited buffers [J]. Computers & Operations Research, 2008, 35(9): 2791-2806.
- [19] 赵新爽, 汪厚祥, 蔡益朝. 反导预警作战资源调度方法[J]. 系统工程与电子技术, 2015, 37(6): 1300-1305.
- [20] 葛浩, 杨传健, 李龙澍. 一种高效的核属性求解算法[J]. 计算机工程与应用, 2010, 46(26): 138-141.
- [21] ZHAO Jie, LIANG Jun-jie, DONG Zhen-ning, et al. Global positive region inconsistency based Attributes Core computation [J]. Computer Science, 2015, 42(8): 259-264. (in Chinese)
赵洁, 梁俊杰, 董振宁, 等. 基于全局正域不一致性的快速求核算法[J]. 计算机科学, 2015, 42(8): 259-264.
- [22] YANG M. An Incremental Updating Algorithm of the Computation of a Core Based on the Improved Discernibility Matrix[J]. Chinese Journal of Computers, 2006, 29(3): 407-413. (in Chinese)
杨明. 一种基于改进差别矩阵的核增量式更新算法[J]. 计算机学报, 2006, 29(3): 407-413.
- [23] GE H, LI L S, YANG C J. Quick algorithm for computing core attribute[J]. Control and Decision, 2009, 24(5): 738-742. (in Chinese)
葛浩, 李龙澍, 杨传健. 一种核属性快速求解算法[J]. 控制与决策, 2009, 24(5): 738-742.
- [24] GE H, LI L S, YANG C J. Efficient algorithm for computing core attributes [J]. Computer Engineering and Applications, 2010, 46(26): 138-141. (in Chinese)
- [25] ZHAO Jie, DONG Zheng-yu, ZHANG Kan-hang. Rough equivalence Class Based Attribute Reduction Algorithm with Bilateral-pruning strategies and Multiple Hashing[J]. Control and Decision, 2016, 3(11): 1921-1934 (in Chinese)
赵洁, 董振宇, 张恺航. 粗等价类双边剪枝策略下多次 Hash 的约简算法[J]. 控制与决策, 2016, 3(11): 1921-1934.
- [26] HU F, WANG G, XIA Y. Attribute core computation based on divide and conquer method[M]. Rough Sets and Intelligent Systems Paradigms, Springer, 2007: 310-319.

(上接第 234 页)