

基于直觉模糊 Memetic 框架的双粒子群混合优化算法

王 毅¹, 王侃琦¹, 张茂省², 李 静¹

(1. 西北大学信息科学与技术学院, 陕西西安 710127; 2. 西安交通大学, 陕西西安 710049)

摘 要: 为了平衡粒子群算法多样性与收敛速度, 本文在 Memetic 框架下结合多属性决策, 提出基于直觉模糊 Memetic 双种群混合优化算法. 算法采用探索与开发分布式策略, 在探索阶段, 设计了社会强化算子和碰撞反弹算子提升种群多样性与勘探更多新区域; 通过建立直觉模糊多属性决策对探索区域综合评估并生成可能存在的全局最优解区域, 进而指导具有拉马克学习的开发种群进行局部精细搜索, 实现不同策略下种群间的分布式协作与计算资源的合理分配. 通过与其它 5 种新型进化算法在 23 个基准函数测试结果中体现出本算法具有更好的综合优化能力.

关键词: 粒子群; Memetic 框架; 直觉模糊多属性决策; 分布式协作; 拉马克学习

中图分类号: TP182; TP391 **文献标识码:** A **文章编号:** 0372-2112 (2021)06-1041-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20201144

Hybrid Double Particle Swarm Optimization Algorithm Based on Intuitionistic Fuzzy Memetic Framework

WANG Yi¹, WANG Kan-qi¹, ZHANG Mao-sheng², LI Jing¹

(1. School of Information Science and Technology, Northwestern University, Xi'an, Shaanxi 710127, China

2. Xi'an Jiaotong University, Xi'an, Shaanxi 710049, China)

Abstract: In order to mitigate the difficulty of balancing diversity and convergence in heuristic algorithm, this paper proposes an IF-memetic hybrid double particle swarm optimization (IFMHDPSO) based on intuitionistic fuzzy memetic framework and multi-attribute decision. There are two independent exploration and exploitation populations employing distributed strategies in which social reinforcement operator and collision rebound operator are proposed to improve diversity of algorithm and explore new areas in populations of exploration. Moreover, an intuitionistic fuzzy multi-attribute decision making is built up for comprehensively evaluating the solution space to get the potential global optimal solution area, which can guide the PSO (Particle Swarm Optimization) with Lamarckian mechanism to carry out the local search to achieve cooperation between populations under different strategies and reasonable allocation of computational resources. Compared with other 5 new evolutionary algorithms, IFMHDPSO is of better comprehensive optimization in 23 benchmark function test results.

Key words: particle swarm optimization; memetic framework; intuitionistic fuzzy multi-attribute decision making; distributed cooperation; Lamarckian learning

1 引言

自进化算法被提出并用于求解复杂优化问题以来, 各种启发式算法层出不穷. 从经典的粒子群算法 (Particle Swarm Optimization, PSO)、人工蜂群算 (Artificial Ben Colony, ABC), 到近年来备受关注的生物地理

学优化算法^[1] (Biogeography-Based Optimization, BBO). 这些启发式算法各有特点, 所擅长的优化问题也各不相同. 因此将具有不同优势算法相混合已成为解决复杂问题的必然趋势并掀起国内外学者的研究热潮.

Ismail^[2] 将 PSO 与引力搜索算法 (Gravitational Search Algorithm, GSA) 相结合, 在粒子群的速度更新公

收稿日期: 2020-10-18; 修回日期: 2021-01-06; 责任编辑: 梅志强

基金项目: 国家重点研发计划 (No. 2018YFC1504705); 国家重点自然科学基金 (No. 61731015); 国家自然科学基金重大仪器专项 (No. 42027806); 国家自然科学基金 (No. 61402517); 国家重点实验室基金 (No. 2016ADL-DW0302); 陕西省自然科学基金 (No. 2018JM6029)

式的认知部分改为 GSA 加速因子,以期提升全局最优解的分布概率. Si^[3]提出了一种粒子群和基因算法相混合的方法,将其每代粒子群中最优的一部分粒子作为遗传算法的父种群,再把遗传算法形成的新优势粒子替换粒子群中较差的粒子. Şahin^[4]在 Ismai 的基础上研究了带有惯性权重的粒子群模型,分析发现惯性权重对粒子群的探索与开发的平衡至关重要. 众多学者也对该模型进行了不同角度的研究,分析得出较大的惯性权重可以提升粒子的全局勘探能力,而较小的权重拥有较好的局部寻优能力^[5],并相继提出了不同的自适应权重算法以期提升种群的多样性与收敛性之间的平衡^[6]. 这些研究往往聚焦于如何通过已迭代的次数决定种群处于探索阶段还是开发阶段. 因此,这些算法在前期时拥有较好的探索能力,随着迭代的增加探索能力减弱局部开发能力增强;若算法在前期没有发现全局最优解的所在区域,则会导致算法最终会收敛在局部最优.

当前,Memetic 算法被视为一种将全局寻优算法和局部寻优算法相结合的一种框架算法而受到众多学者的关注^[7]. 本文将尝试 Memetic 算法与直觉模糊多属性决策相结合,提出基于直觉模糊 Memetic 框架的双粒子群混合优化模型(IF-Memetic Hybrid Double Particle Swarm Optimization, IFMHDPSO). 在该模型中,采用探索与开发分布式策略并结合 Memetic 框架;通过提出的社会强化算子与碰撞反弹算子构成探索种群,以持续保持种群的多样性,以期探索更多新的区域;通过引入拉马克机制构成局部种群,以实现局部空间精细搜索并提升收敛速度. 此外,为了给探索种群与开发种群提供足够多的环境信息以及更为有效的利用探索种群指导开发种群进行分布式并行操作,引入直觉模糊集理论. 直觉模糊集(Intuitionistic Fuzzy Sets, IFS)相较于 Zadeh 模糊集增加了“非隶属度”概念,进而可以表示“非彼非此”的模糊概念,能够同时表示“支持、反对、中立”三种状态^[8],这使得 IFS 可以更加细腻的刻画每个粒子在运行时所携带的信息,支持模型的高精度系列计算;通过直觉模糊多属性决策可对各阶段的探索种群进行综合评估,在提升全局勘探能力与局部精细搜索的同时,能够更为有效的指导局部种群的寻优效率,调节计算资源的合理分配,实现种群多样性与收敛速度之间的平衡. 为方便起见,下文将全局探索种群称为探索组,局部开发种群称为开发组.

2 IFMHDPSO

图 1 是经直觉模糊多属性决策后转移开发组的过程,本算法将 n 个粒子分配到两组中,探索组和开发组分别有 n_1 和 n_2 个粒子. 图中红色粒子表示探索组成员,

绿色粒子表示开发组成员,黑色粒子表示开发组的生成中心. 探索组在整个决策空间运行,通过直觉模糊多属性决策对所有探索组成员综合评判,选出一个最佳粒子作为开发组的生成中心,即图中的黑色粒子. 再以该粒子为中心生成一个目标区域(绿色框图部分),此即新一阶段的开发组搜索区域. 在经过 G 次迭代后该开发组收敛,当前阶段结束;随后,利用直觉模糊多属性决策重新评估探索组粒子,选择一个新的生成中心,并生成对应的搜索区域. 此时进入下一阶段,开发组粒子在该搜索区域重新生成并继续开发,如此往复直到算法结束.

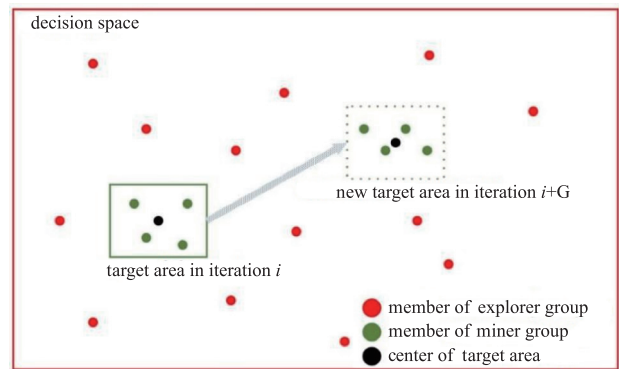


图1 IFMHDPSO开发组转移模型图

2.1 探索种群

2.1.1 社会强化算子

为了提升探索组的全局勘探能力,进而为开发组提供更多可能的潜在全局最优解区域,提高探索组粒子在决策空间的分布性,为探索组设计了社会强化算子,公式如下:

$$\mathbf{x}_i^{t+1} = \mathbf{x}_i^t + \mathbf{v}_i^{t+1} \quad (1)$$

$$\mathbf{v}_i^{t+1} = w_E^{t+1} \mathbf{v}_i^t + C_{E1} r_1 (\mathbf{g}_j^t - \mathbf{x}_i^t) + C_{E2} r_2 (\mathbf{p}_i^t - \mathbf{x}_i^t) \quad (2)$$

式(1)中的 \mathbf{x}_i^t 和 \mathbf{v}_i^t 都是 D 维向量,分别表示探索组在第 t 次迭代时第 i 个粒子位置和速度. 式(2)中的 C_{E1} , C_{E2} 表示探索组中的两个控制常数, $C_{E1}, C_{E2} \in [0, 2]$. w_E^{t+1} 表示第 $t+1$ 次迭代时探索组的随机权重. r_1, r_2 是两个 $[0, 1]$ 上的随机数. \mathbf{g}_j^t 表示在第 t 次迭代时,探索组中第 j 个最优解, $j \in \{1, \dots, E_B\}$, E_B 表示探索组中最优解群的数量; \mathbf{p}_i^t 表示 t 次迭代时粒子 i 自身的历史最优位置. 这里需要指出,社会认知部分不再只受一个最优解影响,而是受探索组中适应度最优的多个粒子影响,本文称这些粒子为最优解群,并在执行时采用精英保留策略.

2.1.2 碰撞反弹算子

由于随着粒子不断迭代,最优解群中的粒子之间也会相互学习,致使粒子最终收敛停止在某一区域. 因此,为了保证探索组在整个迭代过程中保持一定的多样性,需要一种机制在粒子停滞时扰动这些粒子. 本文

根据动量守恒定律设计了碰撞反弹算子. 根据动量守恒定律,当两个运动的物体相碰撞时,每个物体的移动方向和速度可由下式计算得出.

$$\mathbf{v}'_{ij} = \frac{(m_i - m_j)\mathbf{v}_i + 2m_j\mathbf{v}_j}{m_i + m_j} \quad (3)$$

$$m_i = \frac{1}{\text{fit}_i - \min \text{fit} + \Delta} \quad (4)$$

式(3)中 \mathbf{v}'_{ij} 表示粒子 i 和粒子 j 碰撞后,粒子 i 的速度方向向量; \mathbf{v}_i 表示当前粒子的速度方向向量; \mathbf{v}_j 表示与当前粒子发生碰撞的粒子的速度方向向量. m_i 和 m_j 分别表示粒子 i 和 j 的质量;式(4)是粒子质量的计算公式,其中 fit_i 表示粒子 i 的适应度, Δ 是一个防止分母为零的常量,本文设 $\Delta = 0.1$. 若当前粒子和多个粒子碰撞,其最终的移动方向和速度向量由下式计算.

$$\mathbf{u}'_i = \sum_{j=1}^{Z_{\text{coll},i}} \mathbf{v}'_{ij} \quad (5)$$

式(5)中 \mathbf{u}'_i 表示粒子 i 最终的速度方向向量; $Z_{\text{coll},i}$ 是一个与粒子 i 碰撞的粒子所构成的集合.

对于粒子群算法,粒子所聚集的区域往往代表该区域具有开发潜力,而本算子仅为防止粒子早熟停滞. 因此为了不过度干扰粒子导致粒子无法向高适应度区域探索,设置一个参考粒子,当参考粒子邻域内的粒子数量超过预先设定的阈值时就执行反弹算子. 该阈值由 $n_1 \times q$ 得到, $q \in [0, 1]$. 此外,为防止最优信息因碰撞而丢失,碰撞反弹算子执行时保留最优粒子.

2.2 开发种群

开发种群是通过直觉模糊多属性决策对探索组综合评估后所得到的全局最优解集区域位置实现快速局部搜索. 本文采用具有拉马克学习机制的粒子群算法,并执行精英保留策略,其公式如下:

$$\mathbf{v}_i^{t+1} = W_M^{t+1} \mathbf{v}_i^t + C_{M1} r_1 (\mathbf{M}_{\text{best}}^t - \mathbf{x}_i^t) + C_{M2} r_2 (\mathbf{p}_i^{t'} - \mathbf{x}_i^t) \quad (6)$$

位置更新公式仍为式(1). 式(6)中的 $\mathbf{M}_{\text{best}}^t$ 表示第 t 次迭代时开发种群的最优解. W_M^{t+1} 表示第 $t+1$ 次迭代时开发种的随机权重. $\mathbf{p}_i^{t'}$ 表示第 t 次迭代时第 i 个粒子个体历史最优,该个体历史最优通过拉马克机制从开发种群的所有粒子的个体历史最优中选出. C_{M1} 、 C_{M2} 是两个 $[0, 2]$ 上的常数. r_1 、 r_2 为 $[0, 1]$ 上的随机数.

在开发种群中,将拉马克机制^[9]引入 Memetic 模型,使其能快速收敛于局部最优. 具体的做法是为每个粒子的个体历史最优设定一个奖惩因子,随后每个粒子根据奖惩值从整个种群中选择要参考的个体历史最优,奖惩因子的设计如下.

$$\eta_j^t = \frac{\sum_{i \in Z_j} \text{fit}_i^{t-1} - \text{fit}_i^t}{\text{size of } Z_j^{t-1}} \quad (7)$$

式(7)中 η_j^t 表示每个粒子在第 t 次迭代时的奖惩值; Z_j^{t-1} 表示在 $t-1$ 次迭代时将 \mathbf{p}_j^{t-1} 作为自身个体最优的粒子所构成的集合. 本文中采用联赛机制选择个体最优. 即每个粒子在选择个体最优部分时从种群中随机取出两个个体最优,将 η 较大的个体最优作为当前粒子要参考的个体最优. 当 $\eta > 0$ 的粒子个数大于 4 时,对 $\eta > 0$ 的 \mathbf{p}_j 执行以 η 为比较条件的联赛机制(粒子个数设置为 4 作为最小联赛出席粒子数);若粒子个数小于 4 时,对所有的粒子执行以 \mathbf{p}_j 的适应度为比赛条件的联赛机制. 此外,由于 \mathbf{p}_j 会在迭代的过程中不断的更新,而更新后的位置往往会优于之前的位置. 因此,为提高收敛速度,对更新后的 \mathbf{p}_j ,直接令其 η 等于所有大于 0 的 η 的平均值,使其能够参与到联赛机制中. 如上所述,拉马克机制的伪代码如算法 1.

算法 1 拉马克机制伪代码算法

1	FOR 所有探索组成员
2	用式(7)计算每个粒子的 η
3	END
4	FOR 所有探索组成员
5	IF $\text{fit}(\mathbf{p}_j^t) < \text{fit}(\mathbf{p}_j^{t-1})$
6	η_j 等于所有大于 0 的 η 的平均值
7	END
8	END
9	IF $\eta > 0$ 的个数大于 4
10	利用 η 值对大于 0 的 η 执行联赛机制
11	ELSE
12	通过比较各粒子 \mathbf{p}_i^t 的适应度执行联赛机制
13	END

2.3 开发种群的生成

2.3.1 开发种群收敛判定

当前阶段的开发组收敛后,才会生成新的开发组开始下一阶段的局部开发. 在本算法中,若开发组第 t 次迭代的最优解和第 $t-1$ 次迭代的最优解的差值连续 s 次小于预先设定的阈值 ε 则认定已收敛,否则 s 重新开始计数, s 是一个预先设定的迭代次数. 为防止对目标区域重复开发,本文中设立了一个禁止集合. 若该开发组收敛的结果较开发前没有提升,即收敛后的最优适应度值较生成时没有改变,则将该阶段的生成中心记入禁止集合.

2.3.2 挑选目标区域

该部分的作用是利用直觉模糊多属性决策对探索组中所有的粒子进行评估,并从中选出合适的粒子作为开发中心以形成目标区域. 所谓合适粒子是指探索组中所有粒子通过直觉模糊多属性决策综合评估后所得最优的粒子,有极大的概率让开发组以该粒子为中

心,并在经过一定迭代后收敛所得的最优粒子比当前的最优粒子更好. 本文将粒子的适应度以及潜在聚集度作为决策属性,潜在聚集度定义为每个粒子每一维上邻域内粒子数量的平均数. 直觉模糊多属性决策构造过程如下^[10].

Step1:利用高斯型隶属度函数计算出每个粒子对适应度和潜在聚集度的隶属度、非隶属度与犹豫度. 每个粒子的适应度先通过对数归一化再转化为隶属度和非隶属度. 适应度的隶属度函数的均值和方差分别是 0、1/3,非隶属度函数 $\gamma = 1 - \mu$.

每个粒子的潜在聚集度指该粒子每一维上邻域内粒子数量的平均数,计算式如下:

$$n_{\text{con},i} = \frac{\sum_{j=1}^{\text{dim}} \sum_{k=1}^{n_1} l_{i,k,j}}{\text{dim}} \quad (8)$$

$$l_{i,k,j} = \begin{cases} 1, & \text{abs}(x_{i,j} - x_{k,j}) < r_j \\ 0, & \text{otherwise} \end{cases} \quad (9)$$

式(8)中 $n_{\text{con},i}$ 表示粒子 i 的潜在聚集度, $\text{Max } n_{\text{con},i} < n_1$, dim 表示问题维数. 式(9)中 $\text{abs}(\cdot)$ 表示取绝对值, r_j 表示第 j 维上的邻域范围. $x_{i,j}$ 表示第 i 个粒子第 j 维上的值. 潜在适应度的隶属度 μ 的均值和方差分别是 0, $(\text{Max } n_{\text{con},i})/3$, 非隶属度函数 $\gamma = 1 - \mu$.

Step2:确定权重并计算综合评价值. 分别给定两个属性的权重的隶属度 μ 和非隶属度 γ ,且 $\mu + \gamma \leq 1$.

$$\bar{w}(a_j) = \mu_j + \frac{1}{2}\pi_j \quad (10)$$

$$w(a_j) = \frac{\bar{w}(a_j)}{\sum_{j=1}^k \bar{w}(a_j)} \quad (11)$$

$$A_i = \left\{ \langle x_i, \sum_{j=1}^k u_{ij}w(a_j), \sum_{j=1}^k \gamma_{ij}w(a_j) \rangle \right\} \quad (12)$$

本文采用对称权系数合成每个属性,即式(10). 式(10)中 a_j 、 μ_j 、 π_j 分别表示第 j 个属性及其隶属度和犹豫度,犹豫度 $\pi_j = 1 - \mu_j - \gamma_j$. 利用式(11)归一化得出每个属性的权重. 式(11)中的 k 表示属性的数量. 通过式(10)、式(11)就可以分别得到两个属性的权重. 式(12)中 A_i 表示第 i 个粒子的综合评价值.

Step3:利用逼近理想方案的排序方法对当前所用粒子的综合评价值进行排序,计算公式如下:

$$\xi_i = \frac{D(A_i, B)}{D(A_i, B) + D(A_i, G)} \quad (13)$$

$$D(A, B) = \frac{1}{2} \sum_{i=1}^n (|\mu_A(x_i) - (\mu_B x_i)| + |\gamma_A(x_i) - \gamma_B(x_i)| + |\pi_A(x_i) - \pi_B(x_i)|) \quad (14)$$

式(13)中, $D(A, B)$ 用于计算直觉模糊集 A 与 B 的

距离. $B = \{\langle b, 0, 1 \rangle\}$ 表示负理想方案的综合评价. $G = \{\langle g, 1, 0 \rangle\}$ 表示理想方案的综合评价. ξ_i 表示第 i 个粒子测度,从式(13)中可以看出该值越接近 1 表示越接近理想解.

Step4:在排除处于禁止区域中的粒子之后,取 ξ_i 最高的粒子作为新的开发中心.

2.3.3 生成开发组

开发种群各个粒子在开发中心的邻域内随机生成. 具体的做法是每个粒子的第 j 维上的速度和位置分别在 $[-r_j, r_j]$ 和 $[\Theta_j - r_j, \Theta_j + r_j]$ 上随机生成, Θ 和 r 分别为生成中心和邻域的半径.

此外,由于新生成的开发组需要一定的时间适应目标区域. 因此,为加快收敛速度,将探索组中关于目标区域的位置和速度信息提供给开发组,即将处于目标开发区域内的探索组粒子的速度和位置信息复制给开发组中部分新生成的粒子.

2.3.4 IFMHPSO 算法流程

IFMHPSO 算法流程见算法 2. 在 IFMHPSO 算法中采用探索与开发分布式策略,即随机产生 n_1 个粒子作为探索组,以探索组所找到的最优位置作为中心,在邻域半径 r 的范围内产生 n_2 个粒子作为开发组,两组同步更新. 当开发组最优解连续 s 代没有改变时即认为该区域已开发完毕. 若收敛结果未优于该轮开发组初始化时的最优粒子,则将该粒子计入禁止集合.

算法 2 IFMHPSO 算法

```

1  初始化:在搜索空间随机产生探索组,并计算适应度,以探索组最优解为中心产生开发组
2  WHILE(结束控制条件)
3       $n_{\text{pnc}} =$  探索组中任一随机粒子的邻域内其它粒子的个数
4      IF  $n_{\text{pnc}} > n_1 \times q$  //执行碰撞反弹算子
5          FOR  $i = 1$  to 探索组中所有粒子
6              执行式(5)得到  $u'_i$ 
7               $v_i = u'_i; x_i = x_i + v_i$ 
8          END
9      END
10     用式(1)、(2)更新探索组,计算适应度并更新探索组最优粒子
11     执行拉马克学习机制,即算法 1
12     用式(1)、(6)更新开发组,计算适应度并更新开发组最优粒子
13     IF  $M_{\text{best}}^{t-1} - M_{\text{best}}^t \leq \varepsilon$ 
14          $n_s = n_s + 1$ 
15         IF  $n_s > s$  //开发组开发完毕,移至新开发区域
16             用开发组最优解替换探索组最劣解
17             若  $M_{\text{best}}^t$  优于  $\Theta^t$ ,将  $\Theta^t$  计入禁止集合
18             利用直觉模糊多属性决策得出最佳排序,并剔除处于禁止区域中的粒子. 在剩下粒子中,将排在第一的粒子作为新的开发中心  $\Theta^{t+1}$  并以此为中心重新生成开发组

```

19	END
20	ELSE
21	$n_i = 0$
22	END
23	$t = t + 1$
24	END

以禁止集中的每个点为中心,以半径 r 为邻域形成多个禁止区域,每当需要重新生成开发组时先剔除处于禁止区域内的探索组粒子,再通过直觉模糊多属性决策选出最优粒子作为生成中心.如此往复不断循环直至满足结束条件.

3 IFMHDPSO 算法的仿真实验

3.1 实验设计

为体现本算法所具有的全局勘探能力与局部精细搜索能力,将 IFMHDPSO 算法与近年来备受关注的新型进化算法:生物地理学算法^[1] (Biogeography-Based Optimization, BBO)、布谷鸟搜索算法^[11] (Cuckoo Search, CS)、鸡群算法^[12] (Chicken Swarm Optimization, CSO)、灰狼算法^[13] (Grey Wolf Optimization, GWO)以及鲸鱼算法^[14] (Whale Optimization Algorithm, WOA)对 23 个标准测试函数^[14]进行比较,这里选取单峰函数 $f_1 \sim f_7$,多峰函数 $f_8 \sim f_{13}$ 与定维多峰函数 $f_{14} \sim f_{23}$ 来考察各类算法的性能表现.定维多峰是一种维数固定的多峰函数,可以更好的考察算法的综合搜索能力.

本文算法参数设置如下:邻域半径 $r = (\text{ub} + \text{lb}) / 20$, ub , lb 分别表示测试函数的上界和下界;开发组收敛判定次数 $s = 5$; ε 开发组收敛判定精度 $\varepsilon = 0.001$;碰撞反弹算子的执行阈值 $q = 0.6$; n_1, n_2 分别为探索组与开发组初始粒子数量, $n_1 = \text{round}(n * 0.6)$, $n_2 = \text{round}(n * 0.4)$, $\text{round}(\cdot)$ 为一个四舍五入函数;探索组最优解群数量 $E_B = \text{round}(n_1 / 10)$;适应度和潜在聚集度的隶属度和非隶属度分别设为 $\mu_1 = \mu_2 = 0.8$, $\gamma_1 = \gamma_2 = 0.1$; $C_{M1} = C_{M2} = C_{E1} = C_{E2} = 2$. $W_E \in [0.4, 1]$, $W_M \in [0.2, 0.8]$.比较算法中的 BBO、CS、CSO、GWO、WOA 均遵循其文献预先设置,实验中,每个算法在所有测试函数上执行 30 次,测试函数维度 $D = 30$,最大评价次数为 $(\text{FEs}) 5 \times 10^4$,每个算法分配 100 个个体.

3.2 结果分析

3.2.1 求解精度与稳定性

实验过程中,每个对比算法都执行 23 个标准测试函数 30 次,最终结果如表 1 所示.表中的平均值体现求解精度、标准差体现算法稳定性,黑色加粗数值表示相应算法在测试函数上求解结果的均值与标准差最优,最后两行分别表示相应算法在所有测试函数上取得最优均值结果的个数与 Friedman^[15] 秩均值检测结果,秩

均值越小越好.

从表 1 可以看出,IFMHDPSO 在 $f_1 \sim f_{23}$ 的函数测试中取得 11 个最优均值结果,而 BBO、CS、CSO、GWO 和 WOA 分别在 9 个、10 个、4 个、3 个和 5 个函数上取得最优结果,从 Friedman 排名为 2.2609 的检测结果最小,也验证了 IFMHDPSO 算法综合性能优于其它算法,在所有算法排名中第一.

分析表 1 数据,得出以下总体结论:在相同评估次数下,IFMHDPSO 在 $f_1, f_3, f_4, f_6, f_{14}, f_{16}, f_{17}, f_{18}, f_{19}, f_{21}$ 和 f_{23} 上均能求得最优解.相比排名第二的 CS 算法,在 $f_1, f_3, f_4, f_5, f_6, f_9, f_{10}, f_{11}, f_{12}$ 和 f_{13} 上求得更高质量的解;在 $f_{14}, f_{16}, f_{17}, f_{18}, f_{19}, f_{21}, f_{23}$ 函数上性能持平,只有 $f_2, f_7, f_8, f_{15}, f_{20}, f_{22}$ 性能上稍有差距. BBO 在测试函数 $f_5, f_8, f_9, f_{10}, f_{12}, f_{13}, f_{14}, f_{16}, f_{17}$ 共 9 个函数上求得最优解,其余函数上算法性能有待加强. CSO 和 WOA 分别在 4 个和 5 个函数上优势明显,测试其余函数时,算法易陷入局部最优. GWO 在 f_{16}, f_{17}, f_{18} 上同样能求得函数最优解,但在其余函数上的表现性能较弱.

3.2.1.1 单峰函数的求解精度与稳定性分析

进一步分析可以得出,IFMHDPSO 在单峰函数上的优势尤为突出,在 7 个函数上获得 4 个最优结果,而其余的 5 种算法只能获得 1 个或者 0 个最优解.这要归功于 IFMHDPSO 模型可以更加全面的刻画每个粒子在运行时所携带的信息,支持 IFMHDPSO 模型的高精度计算;而结合 Memetic 框架的探索种群与开发种群则采用分布式策略并行工作,参数设置不再需要根据迭代次数自适应调整权重,有效缓解了传统混合粒子群算法中因全局与局部之间的频繁自适应参数调节所带来的计算开销,提高了算法的执行效率.此外,在开发种群中加入了拉马克学习机制,使其粒子个体自身探索获得适应度提升,进而支持算法的局部精细搜索,极大的提升了算法的求解精度并实现了局部快速收敛.

从各类算法得到的标准差所体现出的稳定性上分析得出,在单峰函数中,IFMHDPSO 表现最好, BBO 次之, CS、CSO、GWO、WOA 稳定性相对较弱.与 BBO 相比,除了 f_5 外,IFMHDPSO 在 f_1, f_2, f_4, f_6 上的均值与标准差都优于 BBO,而在 f_3 函数表现上 IFMHDPSO 均值最优,而标准差却劣于 BBO,说明 BBO 在该函数上的稳定性高于 IFMHDPSO,但却得不到最优解,即 BBO 容易陷在目标函数上的某一位置,而不能更进一步的搜索导致其“稳定”在某一非最优解上.而 IFMHDPSO 的平均值更小,标准差更大表明该算法往往能找到比均值更好的解,而出现少部分未找到最优解的情况致使平均值被拉高,这说明拉马克机制能在某一给定范围内搜索到更好解,相比于其它启发式方法具有更好的局部搜索能力.

3.2.1.2 多峰与定维多峰函数的求解精度与稳定性分析

在求解精度的表现上 IFMHDP SO 与排名第二的 CS 算法相比,除了 f_8 、 f_{15} 、 f_{20} 与 f_{22} 的函数测试值略有差距外,在 f_{14} 、 f_{16} 、 f_{17} 、 f_{18} 、 f_{19} 、 f_{21} 、 f_{23} 上两者均能求得最优解,而在 f_9 、 f_{10} 、 f_{11} 、 f_{12} 、 f_{13} 的函数测试中 IFMHDP SO 的所得测试值更优,精度更高。

从稳定性上分析,IFMHDP SO 在 f_{11} 和 f_{13} 的均值和标准差上都优于 CS,在 f_9 、 f_{10} 、 f_{11} 、 f_{12} 函数上平均值都优于 CS,而 CS 的标准差却相对较小,这可以说明 CS 算法较为稳定.但从另一个角度来看,CS 算法往往无法在维数较高的多峰函数找到更好的解,总是容易因为多样性不足而无法对更多的区域进行探索导致其收敛在局部极值,从而使得其方差较小.而 IFMHDP SO 的直觉模糊多属性决策却可以在复杂的多峰环境下综合评估可能存在局部最优区域,从而使算法往往能够拥有更好解。

IFMHDP SO 与 BBO 相较,在 16 个多峰与定维多峰函数中,仅在 f_8 、 f_9 、 f_{10} 、 f_{12} 、 f_{13} 、 f_{20} 的 6 个测试值劣于 BBO.在 f_{14} 、 f_{16} 、 f_{17} 上两者都能获得最优解,但 IFMHDP SO 标准差所表现出的稳定性更高;此外,除 f_{15} 的标准差略差外,IFMHDP SO 在函数 f_{11} 、 f_{18} 、 f_{19} 、 f_{21} 、 f_{22} 、 f_{23} 的平均值和标准差均优于 BBO,寻优速度与稳定性更高,而 f_{15} 的平均值也优于 BBO,这表明 IFMHDP SO 在 10 个多峰与定维多峰函数上综合性能优于 BBO. CS 与 BBO 在单峰函数的表现上却相差甚远,只求得 1 个最优解。

从上述分析可知,由于 IFMHDP SO 算法采用直觉模糊多属性决策对探索种群中所有粒子进行综合评估并生成可能存在的全局最优解区域,进而指导具有拉马克学习机制的粒子群算法作为开发种群对评估后的最优解区域进行高效的局部精细搜索,实现了不同策略下种群间的分布式协作,使其在单峰、多峰与定维多峰函数上,表现出更优的求解精度与较好的稳定性。

表 1 6 种算法在 23 个测试函数上运行结果

函数	最优适应度	评价指标	IFMHDP SO	BBO		CS		CSO		GWO		WOA	
f_1	0	平均值	3.7979	8.6820	+	20.2628	+	5.0382e+03	+	171.3775	+	10.5097	+
		标准差	2.7737	5.7483		28.3399		1.6234e+05		1.4106e+04		45.5012	
f_2	210	平均值	220.2753	238.1158	+	211.0868	-	332.3635	+	219.9749	-	221.3749	+
		标准差	88.2483	4.4202e+03		2.3822		59.3116		52.1266		26.9332	
f_3	0	平均值	168.8087	7.0540e+03	+	3.0801e+03	+	1.2591e+04	+	1.6789e+03	+	5.2434e+04	+
		标准差	6.6496e+03	3.0337		2.4470e+05		2.4610e+06		1.0240e+06		3.0116e+08	
f_4	0	平均值	1.8810	10.9916	+	13.3722	+	22.8414	+	6.7055	+	32.4190	+
		标准差	0.4868	7.2120		3.3997		0.9501		1.4257		301.6344	
f_5	0	平均值	817.6020	308.2816	-	1.7026e+03	+	7.6178e+07	+	2.6015e+05	+	1.9548e+04	+
		标准差	2.6891e+06	9.2602e+03		5.4950e+05		3.5745e+14		8.9459e+10		2.8124e+08	
f_6	0	平均值	3.3114	10.1861	+	21.6253	+	4.9042e+03	+	324.6778	+	11.6446	+
		标准差	2.9019	9.0606		54.9168		7.8800e+11		9.1645e+04		97.6930	
f_7	1.0903e+08	平均值	1.0927e+08	1.0916e+08	-	1.0904e+08	-	1.1331e+08	+	1.0968e+08	+	1.0903e+08	-
		标准差	5.3849e+10	1.4164e+09		1.6387e+07		9.0101e+03		9.9747e+10		1.1861e-06	
f_8	-8.8827e+03	平均值	-1.8890e+03	-8.8611e+03	-	-2.2669e+03	-	430.8539	+	-942.1326	+	-6.3288e+03	-
		标准差	1.6738e+06	41.0067		1.8466e+05		1.3142e+04		2.6108e+05		2.9992e+06	
f_9	5.5151e+03	平均值	5.5615e+03	5.5020e+03	-	5.6106e+03	+	7.1937e+03	+	5.6492e+03	+	5.5248e+03	-
		标准差	6.7906e+03	5.0702		1.4072e+03		1.3142e+04		3.7760e+03		24.1500	
f_{10}	0	平均值	7.1047	1.5171	-	18.2837	+	18.0974	+	5.1244	-	15.8878	+
		标准差	52.9188	0.0763		2.4237		0.1943		3.4493		1.5430	
f_{11}	0	平均值	1.0172	1.0776	+	1.1394	+	1.7260	+	0.9462	-	0.3331	-
		标准差	6.1635e-04	9.3161e-04		0.0012		0.0037		0.0369		0.0295	
f_{12}	0	平均值	21.654	0.0681	-	80.7088	+	145.9965	+	33.2493	+	54.1962	+
		标准差	145.2742	0.0024		67.3648		267.7734		152.0639		1.4073e+03	

续表

函数	最优适应度	评价指标	IFMHDPSO	BBO		CS		CSO		GWO		WOA	
f_{13}	0	平均值	0.5313	0.4674	-	187.9249	+	788.6776	+	100.9944	+	210.2814	+
		标准差	0.0653	0.0205		4.8874e+03		2.5833e+03		3.3958e+03		5.7318e+03	
f_{14}	0.9980	平均值	0.9980	0.9980	=	0.9980	=	1.4306	+	2.8953	+	1.2295	+
		标准差	8.4531e-30	3.3677e-18		1.0107e-31		0.4291		10.2959		0.3730	
f_{15}	0	平均值	0.0011	0.0017	+	0.0004	-	3.1536e-04	-	0.0058	+	6.6221e-04	-
		标准差	1.2902e-05	1.2336e-05		7.3882e-09		4.1861e-10		7.7648e-05		1.632e-07	
f_{16}	-1.0316	平均值	-1.0316	-1.0316	=	-1.0316	=	-1.0316	=	-1.0316	=	-1.0316	=
		标准差	3.5758e-18	1.7933e-09		2.2187e-31		7.4324e-13		3.0806e-17		2.0038e-24	
f_{17}	0.3979	平均值	0.3979	0.3979	=	0.3979	=	0.3979	=	0.3979	=	0.3979	=
		标准差	1.4014e-13	1.0740e-10		4.4339e-28		7.4324e-13		1.5527e-09		3.4247e-13	
f_{18}	3	平均值	3.0000	3.0004	+	3.0000	=	3.0000	=	3.0000	=	3.0000	=
		标准差	5.0605e-21	4.0589e-07		2.5441e-30		1.6581e-14		2.2454e-11		1.8406e-13	
f_{19}	-3.86	平均值	-3.8628	-0.2973	+	-3.8628	=	-3.8627	+	-3.8618	+	-3.8617	+
		标准差	7.1817e-21	5.3936e-06		5.5812e-30		1.1255e-09		5.2092e-06		3.8182e-06	
f_{20}	-3.32	平均值	-3.2903	-3.3061	-	-3.3220	-	-3.2825	+	-3.2238	+	-3.2373	+
		标准差	0.0028	0.0016		4.7604e-14		5.4095e-04		0.0040		0.0046	
f_{21}	-10.1532	平均值	-10.1532	-5.8317	+	-10.1532	=	-9.3270	+	-9.4786	+	-9.6431	+
		标准差	4.4487e-13	13.1555		5.7491e-13		0.5951		2.9498		2.3388	
f_{22}	-10.4030	平均值	-10.4029	-9.0629	+	-10.4030	-	-9.5872	+	-10.4021	+	-8.8800	+
		标准差	4.9295e-14	7.1268		2.1750e-13		0.3564		2.7862e-07		7.8267	
f_{23}	-10.5364	平均值	-10.5364	-9.3000	+	-10.5364	=	-9.8842	+	-10.3555	+	-9.2779	+
		标准差	6.8961e-13	7.5782		1.3835e-10		0.2178		0.9421		6.5293	
最优均值个数			11	9		10		4		3		5	
$t/w/l/(t-w)$			NAN	12/8/3/4		10/6/7/4		19/1/3/15		17/3/3/14		15/5/3/12	
Friedman 排名			2.2609(1)	3.4383(3)		2.6522(2)		4.9130(6)		4(5)		3.7391(4)	

3.2.2 收敛过程

由于篇幅所限,这里选取了各算法在不同类型函数上的收敛速度比较,如图 2 所示,包括单峰函数 f_4 、 f_6 ,多峰函数 f_{12} 、 f_{13} ,定维多峰函数 f_{22} 、 f_{23} ,其中纵轴为平均适应度,横轴为适应度评估次数。

从图 2 可以看出,IFMHDPSO 在单峰函数 f_4 和 f_6 上表现出优秀的收敛性能。具体而言,IFMHDPSO 在 f_4 上相较于其它算法收敛优势显著,可以更快找到全局最优解。在 f_6 上尽管 IFMHDPSO 在算法前期收敛速度略慢于 WOA,但在后期的搜索性能更优,因此取得比 WOA 更高精度的解。对于多峰函数 f_{12} 与 f_{13} ,IFMHDPSO 也表现出了良好的综合性能。因为 IFMHDPSO 不仅在 f_{13} 上表现出更快的收敛速度与收敛精度,而且在 f_{12} 上也表现出较为稳定、持续的收敛过程和较高的求解精度。这是由于 IFMHDPSO 在探索阶段加入了社会增强算子和碰撞反弹算子,增强了种群的多样性进而通过

直觉模糊多属性决策对探索种群进行综合评估后找到了全局最优解区域并指导开发种群在该位置局部寻优并快速收敛。此外,由于定维多峰函数具有函数设计复杂但维数固定且相对较低,易于考察算法的收敛速度。这里通过函数 f_{22} 与 f_{23} 上的各类算法表现可以看出,所有算法都能找到最优解,但 IFMHDPSO 相较于其它算法在寻优速度上能力突出,收敛最快且精度最高。通过上述 6 种算法在单峰、多峰与定维多峰函数上的比较分析可以得出,IFMHDPSO 算法在收敛速度与求解精度上具有更好的综合性能。

3.2.3 显著性检测

这里给出 IFMHDPSO 与其它算法在 23 个测试函数上的符号秩检测^[15],其 t -检测结果如表 1 所示。表中“+”表示 IFMHDPSO 较好,“-”表示 IFMHDPSO 较差,“=”表示两算法性能相当。 $t/w/l$ 分别表示 IFMHDPSO 比相应的对比算法具有显著更优、显著更劣和

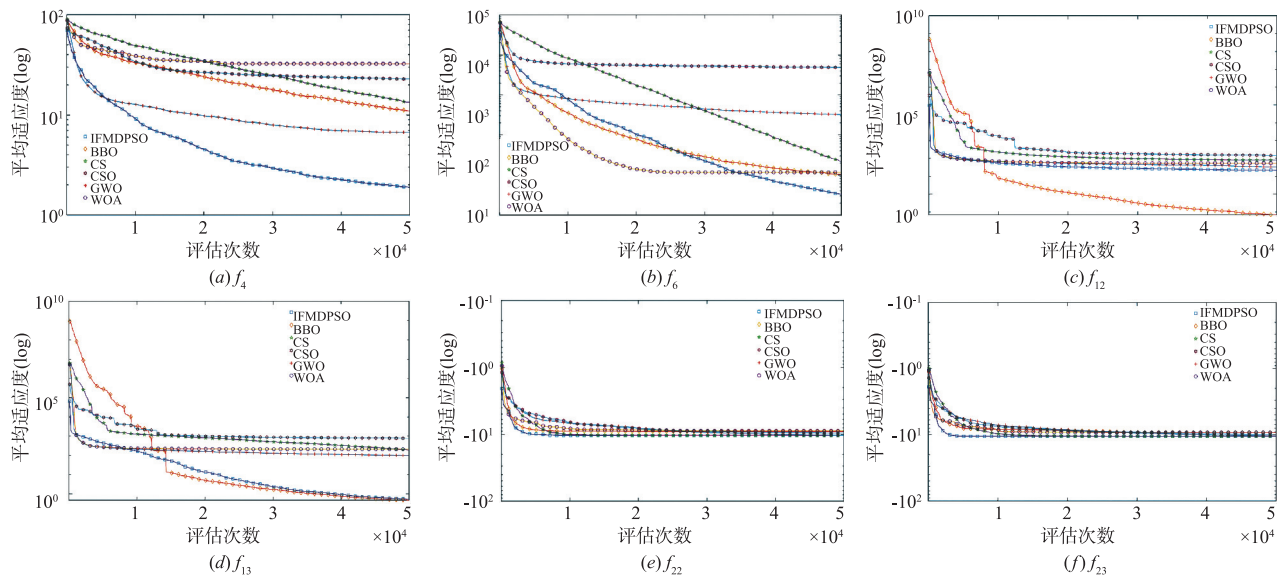


图2 各算法在部分函数上的收敛曲线图

相当的函数个数。 $t-w$ 表示 IFMDPSO 显著性优于对比算法的函数个数与其显著性劣于相应算法的函数个数的差值,该值越大说明相应算法在 t -检测所体现的性能越差。

通过表 1 的 t -检验结果可以得出,IFMDPSO 与 BBO、CS、CSO、GWO、WOA 等 5 种算法相比具有更好的综合性能,因为上述 5 个算法 $t-w$ 的均值都大于 0。在显著性比较时,显著性水平为 0.05,即当 $t = n/2 + \sqrt{n}/2 \times 1.96$, $n = 23$ 可知 $t > 16.1999$ 时,本算法显著优于其它算法(需要说明的是,对于 l 相等问题,将 l 的分值均分给 t 和 w ,即 t 和 w 各分得 l 所得分值的一半,如 WOA 的 $t = 15, l = 3$,则最终显著性 $t = 15 + 1.5$)。因此 IFMDPSO 在 23 个测试函数中显著优于 CSO、GWO 与 WOA;而与 BBO 和 CS 相比,也在 12 个和 10 个标准函数上取得显著性优势,对各类算法进行 Friedman 检测的结果也表明了 IFMDPSO 算法所得秩均值最小,验证本算法的综合优化能力更强。

4 结论

为解决粒子群算法多样性与收敛速度之间的平衡,本文做了三点改进:一是引入 IFS 与 Memetic 框架,在支持 IFMDPSO 模型系列计算提高求解精度的同时,使探索与开发种群在不同的搜索特性下并行工作,既缓解了自适应参数在全局与局部搜索之间频繁调节所带来的计算开销,还提升了算法的执行效率与寻优速度;二是为探索种群设计了社会强化算子与碰撞反弹算子提升种群多样性的同时勘探更多新区域,而开发种群则采用拉马克学习机制实现局部精细搜索;三是建立直觉模糊多属性决策对探索种群综合评估并生

成全局最优解的目标区域,进而有效指导开发种群快速寻优,实现不同策略下种群间的分布式协作与计算资源的合理分配。通过实验分析与验证,结果表明 IFMDPSO 算法在求解精度、稳定性、收敛速度与显著性检测中,具有更强的综合优化能力。

参考文献

- [1] Ma H P, Simon D. Evolutionary Computation With Biogeography-Based Optimization [M]. Hoboken, NJ, USA: John Wiley & Sons, Inc, 2017.
- [2] Ismail A M, Mohamad M S, Abdul Majid H, et al. An improved hybrid of particle swarm optimization and the gravitational search algorithm to produce a kinetic parameter estimation of aspartate biochemical pathways [J]. Biosystems, 2017, 162: 81–89.
- [3] Si W, Qin B Y, Li Q Q, et al. A novel adaptive wavelet threshold estimation based on hybrid particle swarm optimization for partial discharge signal denoising [J]. Optik, 2019, 181: 175–184.
- [4] Şahin M, Kellegöz T. A new mixed-integer linear programming formulation and particle swarm optimization based hybrid heuristic for the problem of resource investment and balancing of the assembly line with multi-manned workstations [J]. Computers & Industrial Engineering, 2019, 133: 107–120.
- [5] 邓先礼,魏波,曾辉,等.基于多种群的自适应迁移 PSO 算法[J].电子学报,2018,46(8):1858–1865.
Deng X L, Wei B, Zeng H, et al. A multi-population based self-adaptive migration PSO [J]. Acta Electronica Sinica, 2018, 46(8): 1858–1865. (in Chinese)
- [6] 孙辉,邓志诚,赵嘉,等.混合均值中心反向学习粒子群

- 优化算法[J]. 电子学报,2019,47(9):1809-1818.
- Sun H,Deng Z C,Zhao J,et al. Hybrid mean center opposition-based learning particle swarm optimization [J]. Acta Electronica Sinica,2019,47(9):1809-1818. (in Chinese)
- [7] García-Ródenas R, Linares L J, López-Gómez J A. A memetic chaotic gravitational search algorithm for unconstrained global optimization problems [J]. Applied Soft Computing,2019,79:14-29.
- [8] Krawczak M, Szkatuła G. On matching of intuitionistic fuzzy sets[J]. Information Sciences,2020,517:254-274.
- [9] Konstantinidis A, Pericleous S, Charalambous C. Meta-Lamarckian learning in multi-objective optimization for mobile social network search[J]. Applied Soft Computing,2018,67:70-93.
- [10] 王毅,刘三阳,张文,等. 属性权重不确定的直觉模糊多属性决策的威胁评估方法[J]. 电子学报,2014,42(12):2509-2514.
- Wang Y, Liu S Y, Zhang W, et al. Threat assessment method with uncertain attribute weight based on intuitionistic fuzzy multi-attribute decision [J]. Acta Electronica Sinica,2014,42(12):2509-2514. (in Chinese)
- [11] Yang X S, Deb S. Cuckoo search via Levy flights [A]. 2009 World Congress on Nature & Biologically Inspired Computing (NaBIC) Computing (NABIC'09) [C]. Coimbatore, India; IEEE,2009. 210-214.
- [12] Meng X B, Liu Y, Gao X Z, et al. A new bio-inspired algorithm: Chicken swarm optimization [A]. Advances in Swarm Intelligence [C]. Hefei, China; Springer,2014. 86-94.
- [13] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer [J]. Advances in Engineering Software,2014,69:46-61.
- [14] Mirjalili S, Lewis A. The whale optimization algorithm [J]. Advances in Engineering Software,2016,95:51-67.
- [15] Derrac J, García S, Molina D, et al. A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms [J]. Swarm and Evolutionary Computation,2011,1(1):3-18.

作者简介



王 毅 男,1979 年 2 月出生,上海人,博士(后)。现为西北大学信息科学与技术学院副教授,主要从事智能信息处理、深度学习与群体智能优化。



王侃琦 男,1994 年出生,浙江杭州人。西北大学信息科学与技术学院硕士研究生,主要研究方向为群体智能优化算法。



张茂省(通信作者) 男,1962 年 12 月出生,陕西省乾县,博士,教授。现任西安交通大学灾害防治与生态修复研究院院长,主要从事智能信息处理与地质灾害防治。
E-mail: xjtzms@xjtu.edu.cn



李 静 女,1997 年 1 月出生,山西晋中人。西北大学信息科学与技术学院硕士研究生,主要研究方向为多目标优化,深度学习。