

控制与决策

Control and Decision

求解高维优化问题的ITCSO算法

张伟, 魏万峰, 黄卫民

引用本文:

张伟, 魏万峰, 黄卫民. 求解高维优化问题的ITCSO算法[J]. 控制与决策, 2024, 39(2): 449–457.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0327>

您可能感兴趣的其他文章

Articles you may be interested in

基于局部搜索的反向学习竞争粒子群优化算法

Opposition-based learning competitive particle swarm optimizer with local search

控制与决策. 2021, 36(4): 779–789 <https://doi.org/10.13195/j.kzyjc.2019.1150>

具有重组学习和混合变异的动态多种群粒子群优化算法

Dynamic multi-population particle swarm optimization algorithm with recombined learning and hybrid mutation

控制与决策. 2021, 36(12): 2871–2880 <https://doi.org/10.13195/j.kzyjc.2020.0898>

基于R2指标和目标空间分解的高维多目标粒子群优化算法

R2 indicator and objective space partition based many-objective particle swarm optimizer

控制与决策. 2021, 36(9): 2085–2094 <https://doi.org/10.13195/j.kzyjc.2020.0113>

嵌入Circle映射和逐维小孔成像反向学习的鲸鱼优化算法

Whale optimization algorithm for embedded Circle mapping and one-dimensional oppositional learning based small hole imaging

控制与决策. 2021, 36(5): 1173–1180 <https://doi.org/10.13195/j.kzyjc.2019.1362>

一种自适应拟牛顿-状态转移混合智能优化算法及应用

A hybrid state transition optimization algorithm based on adaptive quasi-newton method and its application

控制与决策. 2021, 36(10): 2451–2458 <https://doi.org/10.13195/j.kzyjc.2020.0214>

求解高维优化问题的ITCSO算法

张伟[†], 魏万峰, 黄卫民

(河南理工大学 电气工程与自动化学院, 河南 焦作 454003)

摘要: 为提高竞争群优化(competitive swarm optimization, CSO)算法求解高维优化问题的寻优效率, 提出一种改进的3重竞争群优化(improved triple competitive swarm optimization, ITCSO)算法. 首先, 采用3重竞争机制提高算法的寻优效率, 同时, 获胜粒子较好的收敛基础可以提高失败粒子的个体认知, 明确粒子更新方向以提高粒子探索能力; 然后, 提出优胜粒子向获胜子群学习的策略, 增强算法的社会认知能力, 减少算法评估次数, 从而提高算法全局搜索能力; 最后, 提出优胜子群自竞争和劣败粒子基于优胜者变异的操作, 增强粒子局部开发能力, 避免算法陷入局部最优. 为验证所提出算法的可行性, 通过计算系统状态转移矩阵特征值和使用极限分析方法, 给出稳定性和收敛性理论证明. 采用几种基准测试函数验证所提出算法求解高维问题时的性能, 并与其他算法进行对比. 实验结果表明, ITCSO算法不仅有较高的寻优效率, 且全局搜索和局部开发能力突出, 更适用于高维问题的求解.

关键词: 粒子群优化算法; 竞争群优化算法; 高维优化; 3重竞争机制; 局部开发; 收敛性分析

中图分类号: TP183

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0327

开放科学(资源服务)标识码(OSID):



引用格式: 张伟, 魏万峰, 黄卫民. 求解高维优化问题的ITCSO算法[J]. 控制与决策, 2024, 39(2): 449-457.

ITCSO algorithm for solving high dimensional optimization problem

ZHANG Wei[†], WEI Wan-feng, HUANG Wei-min

(College of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China)

Abstract: In order to improve the optimization efficiency of a competitive swarm optimization (CSO) algorithm, an improved triple competitive swarm optimization (ITCSO) algorithm is proposed for solving high-dimensional optimization problems. Firstly, a triple competition mechanism is used to improve the optimization efficiency of the algorithm. Simultaneously, the better convergence basis of the winners can improve the cognitive ability of the losers, and can guide the adaption direction of particles to improve the exploration ability. Secondly, the strategy that the losers with superiority fitness can learn from the winning subgroup is proposed, which can enhance the social cognition ability and reduce the number of evaluations, and can greatly improve the global search ability. Finally, the winning subgroup self-competition and the variation of losers with inferior fitness based on winners is proposed to enhance the local explore ability, which can avoid the algorithm falling into local optimum. In order to demonstrate the feasibility of the ITCSO algorithm, the stability and the convergence are proved by calculating the eigenvalues of the state transition matrix and using the limit analysis method. Several benchmark test functions are adopted to verify the performance of the proposed ITCSO. The experimental results show that, compared with other algorithms, the ITCSO not only has high optimization efficiency, but also has outstanding global search and local explore ability, which is more suitable for solving the high-dimensional problems.

Keywords: particle swarm optimization; competitive swarm optimization; high dimensional optimization; triple competition mechanism; local explore; convergence analysis

0 引言

粒子群优化(particle swarm optimization, PSO)算法^[1]概念简单且搜索效率高, 近几十年来迅速发展并

广泛应用于各领域^[2-5]. 然而, PSO在解决高维、不可分离和多峰问题时易出现过早收敛, 导致算法寻优效果不佳^[6-7]. 为改善PSO解决高维优化问题时的性

收稿日期: 2022-03-02; 录用日期: 2022-09-20.

基金项目: 国家自然科学基金项目(61703145); 河南省科技攻关项目(222102210213); 河南省高校科技创新团队项目(20IRTSTHN019).

责任编辑: 巩敦卫.

[†]通讯作者. E-mail: zwei1563@126.com.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

能,学者们提出不同的改进方案,主要包括参数动态调整、改进种群拓扑结构、融合其他智能算法和改进进化策略^[8-11].文献[12]给出了新个体维度互相学习策略,虽然没有降低维数,但是涉及基于维度层面的经验学习;文献[13]将多因素降维策略引入PSO,多角度对算法进行降维优化,提高了算法性能;文献[14]将PSO与GA算法相融合来解决高维问题,通过在PSO中引入遗传算法,进一步提高了算法的优化效果;Ghasemi等^[15]基于DE和PSO提出了一种高效的启发式混合算法,获得了较优的效果.然而,大多数PSO改进方法引入新的寻优机制和额外操作,搜索性能的提高往往是以增加计算复杂度为代价,且由于PSO中全局最优粒子对种群进化的强烈影响,过早收敛仍然是大多数现有PSO变体的一个主要问题.

针对上述问题,最有效的解决方法是完全摆脱全局最优粒子和个体最优粒子对种群收敛的影响.因此,Cheng等^[16]提出了竞争粒子群优化(competitive swarm optimization, CSO)算法,采用两两竞争机制确定失败者和获胜者,通过失败者向获胜者学习的过程更新种群,由于CSO突出的性能表现,现已成为解决高维优化问题的有效选择之一.然而,CSO每次迭代只有一半粒子参与寻优,且种群更新仅依赖于获胜者的位置,导致算法开发能力不够.

为进一步提高CSO算法的寻优效率,Mohapatra等^[17]提出了一种改进的竞争群优化(modified competitive swarm optimizer, MCSO)算法,该方法采用3重竞争机制使得算法每次迭代更新更多的粒子.Nayak等^[18]提出了遗传竞争群优化(inherited competitive swarm optimization, ICSOA)算法,父代粒子更新策略与基本CSO相同,子代粒子通过向父代以及获胜者学习更新自身位置,由于父代粒子对于提高子代粒子社会认知程度的作用较低,使得算法在解决一些实际问题时收敛性不足.这2种改进策略均不同程度地提高了算法的性能,但是粒子的更新依旧靠获胜者提供的信息驱动,导致种群开发程度不高.

为提高种群的多样性,章强等^[19]提出了一种柯西和高斯变异的竞争粒子群优化(competitive swarm optimizer integrated with cauchy and gaussian mutation, CGCSO)算法,通过柯西和高斯变异提高算法的开发能力,利用环形拓扑结构增强种群多样性,但是,该方法中获胜者变异对粒子引导的效果不强,且环形拓扑结构的使用抑制了算法的寻优效率.Xiong等^[20]提出了具有动态高斯变异的获胜者领先竞争群优化(winner-leading competitive swarm optimizer with

dynamic gaussian mutation, WLCSODGM)算法,利用获胜者领先的搜索策略和动态高斯突变算子,提高了种群多样性,但是该方法会导致粒子有可能错过获胜者与失败者间潜在的最优解,且随机突变算子需要额外评估,增加了计算复杂度.Chen等^[21]提出了一种改进的竞争群优化(improved competitive swarm optimizer, ImCSO)算法,首先采用排序配对学习策略来提高失败粒子的学习能力,然后采用差分进化策略对获胜粒子进行改进,提高了算法的搜索能力,具有较高的寻优效率和计算精度.钱晓宇等^[22]提出了基于局部搜索的反向学习竞争粒子群优化算法(solis and wets-opposition based learning competitive particle swarm optimizer with local search, SW-OBLCSO),采用竞争机制和反向学习机制,该方法在收敛速度和全局搜索能力上表现突出.上述各改进策略为解决高维复杂问题提供了可行性,但是,由于竞争机制弱化了PSO算法局部开发的能力,同时PSO中的最优粒子也限制了竞争机制带来的全局探索性能,仍然需要更有效的控制策略提高算法的寻优效率和求解精度.

综上所述,本文通过探索粒子内在行为,挖掘种群内在信息,提出一种改进的3重竞争群优化算法.本文对算法改进以及创新内容在于:1)根据种群分组的思想,采用3重竞争机制使得更多粒子参与寻优,在探索与开发间保持相对平衡;2)为提高算法求解效率,提出优败粒子向获胜子群学习的寻优机制,提高算法探索优解空间的能力并细化搜索阶段产生的解;3)为提高种群的多样性和局部空间的开发能力,提出获胜子群自竞争和劣败粒子基于获胜者位置局部开发的操作;4)给出所提出算法的稳定性和收敛性证明,确保算法的理论可行性.最后,通过仿真实验进一步验证所提出算法性能.

1 基本CSO算法

1.1 CSO算法基本原理

基本CSO算法依赖于粒子间成对的竞争机制,算法每次迭代将所有粒子随机分为 $m/2$ 组,每组粒子通过竞争确定获胜者和失败者,获胜者不参与更新直接进入下一次迭代,失败者通过向获胜者学习更新自身速度和位置.假设第 t 次迭代第 k 轮竞争中获胜者和失败者的位置和速度分别为 $X_{w,k}(t)$ 、 $V_{w,k}(t)$ 、 $X_{l,k}(t)$ 、 $V_{l,k}(t)$,则失败粒子进行如下更新:

$$\begin{aligned} V_{l,k}(t+1) = & \\ & R_1(k,t)V_{l,k}(t) + R_2(k,t)(X_{w,k}(t) - X_{l,k}(t)) + \\ & \varphi R_3(k,t)(\bar{X}_k(t) - X_{l,k}(t)), \end{aligned} \quad (1)$$

$$X_{l,k}(t+1) = X_{l,k}(t) + V_{l,k}(t+1). \quad (2)$$

其中: $R_1(k, t)$ 、 $R_2(k, t)$ 、 $R_3(k, t)$ 为(0, 1)内均匀分布的随机数; $\bar{X}_k(t)$ 为第 t 次迭代后种群的平均位置, $k=1, 2, \dots, m/2$, m 为粒子个数; φ 为控制 $\bar{X}_k(t)$ 影响的非负实数. 与PSO类似: 式(1)的第1项为记忆部分, 第2项为个体认知部分, 第3项为社会认知部分.

1.2 CSO算法分析

CSO算法概念简洁, 主要包括竞争机制和更新策略. 算法只有一个参数 φ 需要人为确定, 因此, 相比于其他元启发式算法具有更强的泛化能力. 此外, 对控制参数 φ 的改进也是提高算法性能的关键, 而目前对CSO的研究还处于初级阶段, 故对参数 φ 的优化鲜有有效的指导方案. 由于其他元启发式算法已对相关工作进行了广泛研究, 并引入一些有效的策略来提高算法的整体性能^[23], 为CSO算法的参数研究提供了一定的参考价值.

由于CSO算法采用随机竞争机制, 具有十分出色的全局搜索能力, 作为一种收敛策略, 弱解有机会从强解中学习, 所有获胜粒子均可作为粒子更新方向的指导, 更新信息从一半的粒子中获得而非从个体最优位置和全局最优位置中获得, 在探索与开发间取得良好的平衡. 一些研究表明, 没有突变算子的CSO算法可成功解决大规模多峰问题. 另外, 将竞争机制应用于多目标问题时, 也可提高算法的全局探索能力. 因此, 采用竞争机制的多目标优化算法的基本突变算子可进一步省略^[24], 不仅使得算法更加简洁, 且保留了CSO算法的进化组织.

2 ITCSO算法

由于基本CSO算法特殊的搜索机制导致算法寻优效率低, 需要对CSO的竞争机制、获胜粒子选取、种群平均位置选取以及粒子变异操作等制定相应的策略引导粒子搜索. 通过对粒子行为分析, 本文采用3重竞争机制确定粒子特性, 并对不同粒子制定不同的更新策略, 提高算法的寻优效率. 所提出ITCSO算法的整体结构如图1所示.

2.1 粒子特性分析

CSO算法中, 失败粒子速度 $V_i(t)$ 与获胜者位置 $X_w(t)$ 共同作用使得粒子向适应度较好的方向移动, 合成后速度为 $V_i'(t+1)$, 如图2所示. 由于粒子分组的随机性, 有很大概率2个适应度较好的粒子分为1组, 而种群进化前期阶段粒子分布较分散且平均适应度较差, 会导致粒子社会认知部分过低, 从而抑制粒子向适应度较好的方向探索, 最终粒子速度合成为 $V_i''(t+1)$.

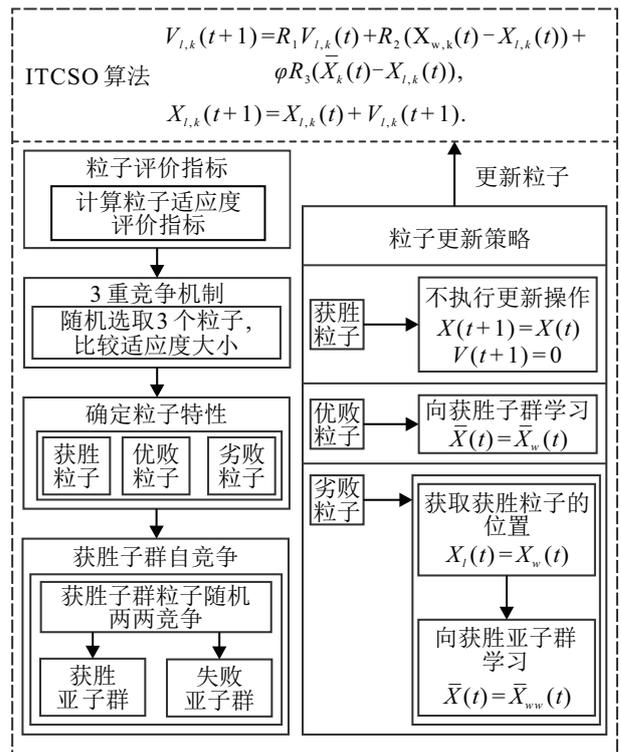


图1 ITCSO算法的整体框架

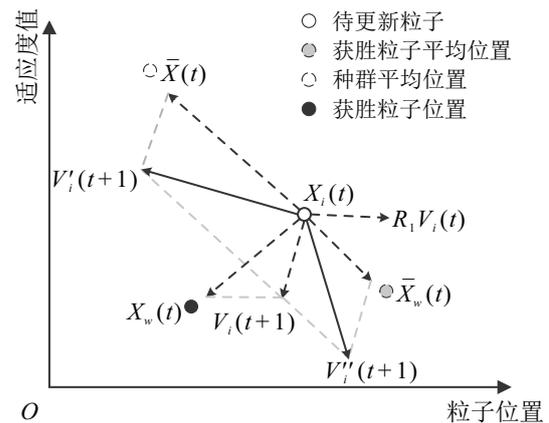


图2 粒子向不同获胜种群学习更新方向

为减少上述问题的出现, 探索简单有效的更新策略, 本文从种群内部出发分析粒子行为. 对粒子社会认知部分进行改进, 即粒子向获胜子群 $\bar{X}_w(t)$ 学习. 粒子速度 $V_i(t)$ 和获胜者 $X_w(t)$ 对粒子的作用合成后, 再向获胜子群学习, 粒子最终速度为 $V_i''(t+1)$, 该操作缓解了种群对适应度较优粒子的抑制作用, 降低了粒子向适应度差的方向移动的可能性. 另外, 适应度较好的子群在迭代后期依旧对粒子保持较强的指导作用, 避免粒子在劣解空间探索, 从而能够有效提高算法的寻优效率.

2.2 3重竞争机制

PSO中若粒子前后两时刻个体最优不变, 则此时粒子个体认知为0, 所有粒子均会向全局最优移动, 导致粒子对搜索空间探索不充分, 易陷入局部最

优. CSO 由于粒子分组的随机性,使得算法个体认知几乎不为0,能够有效避免算法陷入局部最优.但是,CSO在搜索前期阶段获胜者的适应度参差不齐,且只有一半粒子参与更新,必然导致算法寻优效率慢.

综上,本文采用3重竞争机制确定粒子特性. t 时刻,在种群 $P(t)$ 中随机选取3个粒子,根据适应度值大小产生获胜者、优败粒子和劣败粒子,并采用不同的更新策略,更新后的粒子存放于 $P(t+1)$ 中.当 $P(t)$ 中粒子数为0时,进入 $t+1$ 次迭代,如图3所示.

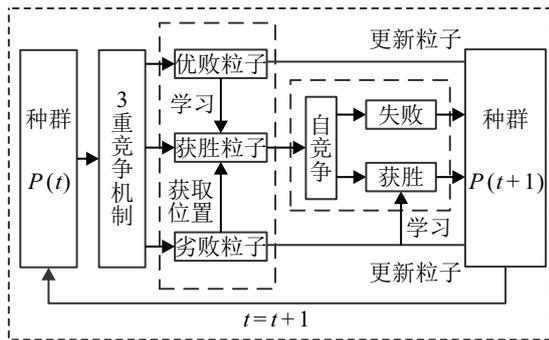


图3 3重竞争机制粒子学习方式

与CSO算法相比:1)3重竞争的获胜者具有更好的适应度,可有效提高粒子的个体认知.对于优败粒子而言,其收敛性优于劣败粒子,选择3重竞争的获胜粒子作为失败粒子学习目标,能够有效避免搜索前期粒子状态变差的可能性,使得优败粒子更偏向于优解空间搜索;对于劣败粒子而言,更新迭代所需评价次数多,而3重竞争中获胜者比CSO更具收敛性,因此,对于突变后的劣败粒子更具指导意义,能够有效提高劣败粒子个体认知部分.2)每次迭代2/3的粒子参与寻优,能够有效提高算法的寻优效率.3)在不增加算法复杂度的前提下,3重竞争机制在探索与开发间保持了相对平衡.

2.3 优败粒子更新策略

标准CSO算法存在的主要问题在于寻优效率低.种群平均位置 $\bar{X}(t)$ 是算法迭代过程中所有粒子位置的集中体现,虽然能够代表种群的整体进化水平,但是不能提供有效的搜索动力,特别是在求解复杂优化问题时,难以达到预期的寻优效果.

CSO算法搜索环境的改变必然会引起粒子行为的变化,从而对解的质量产生较大影响.而粒子所面临的环境是其他粒子传递给自身的信息,集中体现在种群平均位值 $\bar{X}(t)$,即算法的社会认知部分.粒子根据传递给自身信息的不同产生不同的响应.在进化过程中,粒子信息来源主要由获胜者位置 $X_w(t)$ 和种群平均位置 $\bar{X}(t)$ 提供.为提高粒子社会认知部分对

进化的作用,提出优败粒子向获胜子群 $\bar{X}_w(t)$ 学习的操作,优败粒子 $X_i(t)$ 按照下式更新:

$$V_i(t+1) = R_1(t)V_i(t) + R_2(t)(X_w(t) - X_i(t)) + \varphi R_3(t)(\bar{X}_w(t) - X_i(t)), \quad (3)$$

$$X_i(t+1) = X_i(t) + V_i(t+1). \quad (4)$$

其中: $X_i(t)$ 为优败粒子的位置向量, $V_i(t)$ 为速度向量, $X_w(t)$ 为获胜者的位置, $\bar{X}_w(t)$ 为获胜子群的平均位置, t 为迭代次数.

上述更新策略的优点在于:1)保留了CSO原有的迭代方法,没有增加任何额外参数,维持了算法的简洁性;2)由于粒子是随机分组的,所选获胜者能够代表整个种群的整体水平;3)获胜子群的适应度更好,对于提高种群的社会认知部分有很大的帮助,提高算法寻优效率的同时细化搜索阶段发现的解.

2.4 劣败粒子变异策略

在算法寻优过程中,采用单一搜索策略的行为虽然可维持算法稳定,但是会造成算法后期阶段局部开发能力不足的情况.当粒子陷入局部最优采用原定搜索策略不足以跳出该区域时,对粒子实施变异是最简单有效的方法.

劣败粒子更新所需要的迭代次数较多,且向获胜者学习的目标导向操作会使得算法迅速丧失多样性,因此,将劣败粒子位置替换为获胜者的位置,利用获胜子群自竞争产生适应度更好的子群指导劣败粒子更新,在减少计算评估次数的同时能够有效提高算法局部开发的能力,维持种群的多样性.

本文对劣败粒子变异操作可描述为:1)劣败粒子通常在收敛性方面表现不佳,将其位置替换为具有较好收敛基础的获胜者以减少劣败粒子的评价次数;2)为提供更有效的变异信息,提出获胜子群自竞争产生适应度更优子群指导劣败粒子变异,提高算法局部开发的能力.劣败粒子 $X_j(t)$ 变异策略如下:

$$V_j(t+1) = R_4(t)V_j(t) + R_5(t)(X_w(t) - X_j(t)) + \varphi R_6(t)(\bar{X}_{ww}(t) - X_j(t)), \quad (5)$$

$$X_j(t+1) = X_w(t) + \alpha V_j(t+1). \quad (6)$$

其中: $X_j(t)$ 和 $V_j(t)$ 分别为劣败粒子的位置向量和速度向量, $\bar{X}_{ww}(t)$ 为获胜子群自竞争中获胜粒子的平均位置, α 为控制粒子变异大小的非负实数.上述变异操作只针对劣败粒子,并不影响当前种群其他粒子,作为一种辅助手段提高种群的多样性,避免算法陷入局部最优.本文提高了算法的个体认知和社会认知,在进化前期阶段粒子变异范围较大,保证算法

的探索能力,后期由于粒子间差异性减小,使得变异范围缩小,因此,变异行为更具收敛性.

3 稳定性和收敛性分析

稳定性是系统收敛的前提,本文采用动力系统稳定性理论,验证所提出ITCSO算法的稳定性,并采用极限分析方法验证算法的收敛性.粒子在竞争结束后有2种结果:一种为获胜者,而获胜粒子不参与更新;另一种为失败者,失败粒子需要更新自身状态.因此,只需对随机选取的粒子为失败者的情况进行稳定性和收敛性分析.

首先,根据粒子更新公式得到状态转移矩阵,通过计算状态转移矩阵的特征值得到算法稳定的充要条件,即特征根满足 $|\lambda| < 1$;然后,采用极限分析方法验证所提出算法中粒子始终收敛于解空间的最优点.

4 实验研究

为便于粒子分组,本文选取粒子个数为 $n = 120$,控制因子 $\varphi = 1$,算法最大评价次数为2000,每种算法在同一测试函数上均独立运行30次.算法运行环境均为AMD Ryzen5 4600H 3.00 GHz CPU, 16 GB内存, Windows 10操作系统, Matlab 2019b.

4.1 测试函数

为验证所提出ITCSO算法的寻优效率和收敛能力,选用9个常用的基准测试函数作为算法的测试函数.测试函数表达式如下:

$$f_1 = \sum_{i=1}^n x_i^2, \quad -100 \leq x \leq 100; \quad (7)$$

$$f_2 = \sum_{i=1}^n ([x_i + 0.5]), \quad -100 \leq x \leq 100; \quad (8)$$

$$f_3 = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 - (x_i - 1)^2], \quad -30 \leq x \leq 30; \quad (9)$$

$$f_4 = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i)] + 10n, \quad -5.12 \leq x \leq 5.12; \quad (10)$$

$$f_5 = 20 + \exp(1) - 20 \exp\left[-\frac{1}{5} \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right] - \exp\left[\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right], \quad -32 \leq x \leq 32; \quad (11)$$

$$f_6 = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1, \quad -600 \leq x \leq 600; \quad (12)$$

$$f_7 = \sum_{i=1}^n |x_i \sin(x_i) + 0.1x_i|, \quad -100 \leq x \leq 100; \quad (13)$$

$$f_8 = \sum_{i=1}^n \left(\sum_{j=1}^i x_j\right)^2, \quad -65.536 \leq x \leq 65.536; \quad (14)$$

$$f_9 = \sin^2(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_i + 1)] + (y_n - 1)^2 [1 + \sin^2(2\pi y_n)],$$

$$y_i = 1 + \frac{(x_i - 1)}{4}, \quad -50 \leq x \leq 50. \quad (15)$$

其中: f_1 为一种单峰、完全可分函数; f_2 为step函数,由一系列水平线组成,该函数在定义域内以一定的间隔出现阶跃现象,在每个阶跃间会产生大量局部极值;函数 f_3 为典型病态香蕉型的单峰函数,一般算法在此函数下找到全局最优的概率很小,优化难度较大; f_4 为Rastrigin函数,是一种多峰不对称函数; f_5 和 f_9 是较为复杂的不可分多峰函数,且局部最优与全局最优相距很远,导致算法难以获得全局最优; f_6 为多峰、不可分的可旋转函数,函数曲面存在大量的波峰波谷,在通往全局最优的路径上优化算法易陷入局部最优点; f_7 为一种震荡函数,在定义域内,函数取值波动较大且具有多个极值,距原点越远波动越大,优化难度较大; f_8 为Schwefel问题,特征为单峰不可分.上述测试函数在群智能优化算法性能检测中广泛应用.

4.2 不同分组竞争对算法性能的影响

为验证不同分组对算法性能的影响,分别设计4重竞争实验(quadruple competitive optimization, QCSO),并与CSO(两两竞争)以及MCSO(3重竞争)算法进行对比.选用本文采用的部分测试函数验证算法性能,实验结果如图4所示.

由图4可见:基本CSO算法只有一半粒子参与更新,因此,在求解高维复杂优化问题时寻优效率较低,但是,两两竞争机制能够有效维持种群多样性,避免算法陷入局部最优,因此求解精度较高;MCSO采用3重竞争机制,每次迭代更新2/3的粒子,能够有效提高算法的寻优效率,但是,多数粒子向少数粒子学习会使得多样性丧失,导致算法最终求解精度有所降低;4重竞争实验每次迭代更新3/4的粒子,虽然能够进一步提高算法的收敛速度,但是,种群中指导失败粒子更新的获胜粒子数量将大大减少,使得算法在搜索前期多样性迅速丧失而陷入局部最优,这种以提高寻优速率而牺牲算法求解精度的方式在很大程度上限制了算法的整体性能.

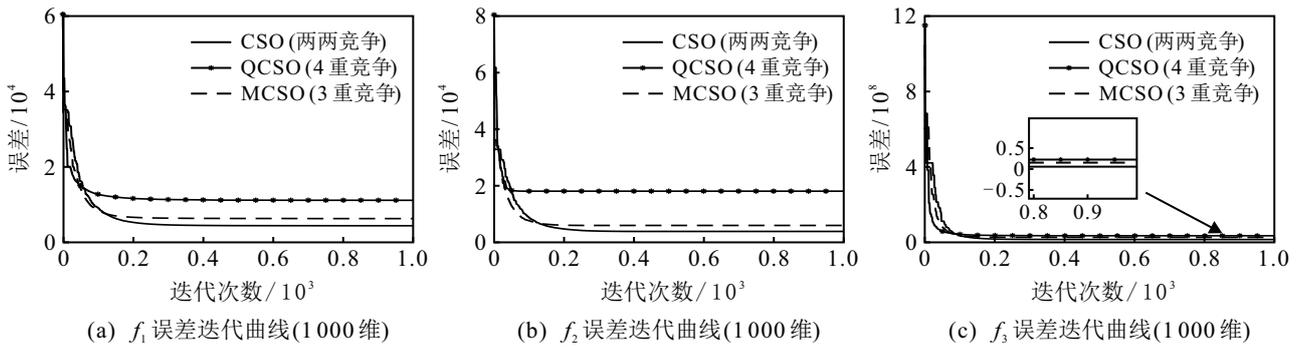


图4 不同分组算法最优适应度迭代曲线

4.3 实验结果和分析

本文将所提出算法与CSO^[16]、MCSO^[17]、PSO^[1]、ICSOA^[18]以及ImCSO^[21]进行性能对比,将测试函数维度设置为1000,各算法参数设置均与原文献一致.所提出算法与其他算法在9个测试函数上的实验数据如表1所示.每个测试函数的实验数据由4行数据构成,分别为最优值、最差值、均值和方差,粗体为算

法在优化当前测试函数时性能最优.图5为各算法在9个测试函数上的误差收敛曲线.对于适应度值变化较大的测试函数,纵坐标取自然对数.

由图5可见,ITCSO算法的寻优效率明显优于其他算法.在优化前期,粒子向适应度更好的种群学习,能够以更大可能探索优解空间,避免对劣解空间过度探索,因此能够快速探索到全局最优.而劣败粒子

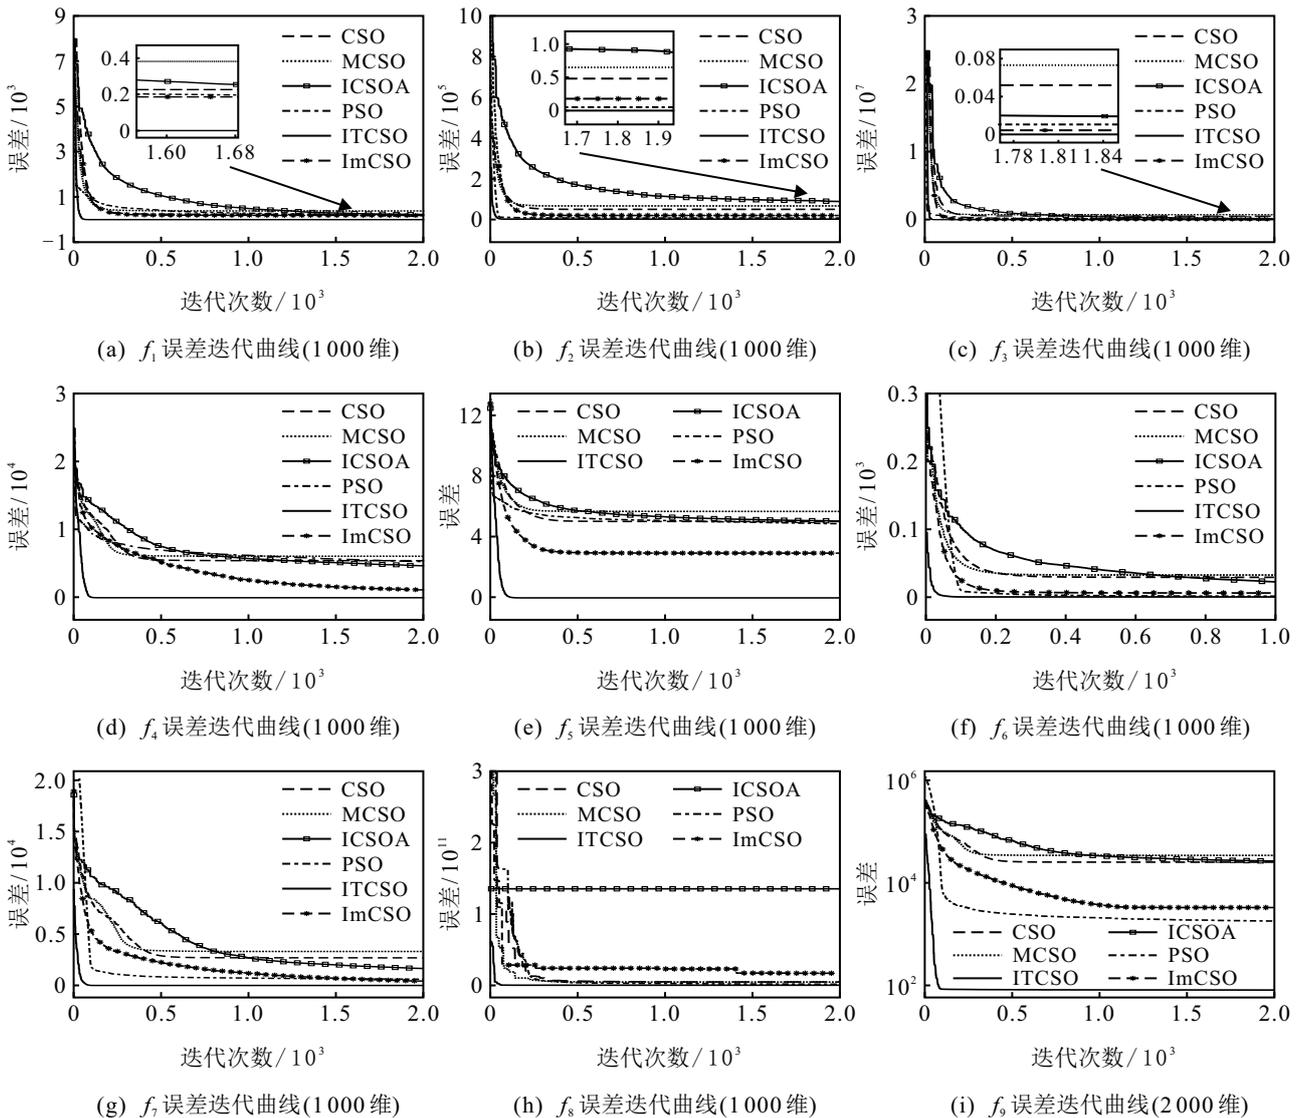


图5 各测试函数最优适应度迭代曲线

表1 各对比算法在9个标准测试函数上的实验结果(1 000维)

函数	指标	CSO	MCSO	PSO	ICSOA	ImCSO	ITCSO
f_1	best	2.44e+02	3.14e+02	1.60e+02	1.08e+02	2.31e+02	1.57e-107
	worst	2.82e+02	3.57e+02	3.21e+02	1.49e+02	2.56e+02	3.08e-104
	mean	2.60e+02	3.24e+02	2.12e+02	1.24e+02	2.43e+02	6.65e-105
	var	2.11e+02	2.24e+02	2.73e+03	2.12e+02	7.73e+01	1.18e-208
f_2	best	9.26e+04	1.12e+05	6.00e+03	5.61e+04	1.78e+04	0.00e+00
	worst	1.05e+05	1.31e+05	1.20e+04	7.78e+04	2.27e+04	0.00e+00
	mean	9.91e+04	1.22e+05	9.00e+03	6.69e+04	1.99e+04	0.00e+00
	var	2.74e+07	4.62e+07	4.85e+05	6.01e+07	2.53e+06	0.00e+00
f_3	best	5.02e+05	7.00e+05	1.94e+04	1.50e+05	3.90e+04	9.97e+02
	worst	6.85e+05	9.61e+05	2.45e+04	2.90e+05	5.72e+04	9.97e+02
	mean	5.70e+05	8.06e+05	2.20e+04	2.16e+05	4.81e+04	9.97e+02
	var	4.20e+09	6.41e+09	2.87e+06	2.60e+09	3.77e+07	4.00e-03
f_4	best	5.28e+03	5.95e+03	5.10e+03	4.32e+03	1.03e+03	0.00e+00
	worst	5.68e+03	6.18e+03	6.81e+03	5.34e+03	1.18e+03	0.00e+00
	mean	5.44e+03	6.06e+03	6.35e+03	4.66e+03	1.10e+03	0.00e+00
	var	1.85e+04	5.33e+03	3.56e+05	1.14e+05	2.56e+03	0.00e+00
f_5	best	4.88e+00	5.25e+00	2.97e+00	5.74e+00	2.90e+00	8.88e-16
	worst	5.31e+00	5.75e+00	3.58e+00	5.35e+00	3.05e+00	8.88e-16
	mean	5.11e+00	5.47e+00	3.26e+00	5.57e+00	3.00e+00	8.88e-16
	var	1.84e-02	2.47e-02	3.46e-02	1.57e-02	6.20e-03	0.00e+00
f_6	best	1.01e+00	1.29e+00	2.14e-01	5.00e-01	2.89e-01	0.00e+00
	worst	1.17e+00	1.16e+00	4.42e-01	7.76e-01	3.89e-01	0.00e+00
	mean	1.11e+00	1.23e+00	2.85e-01	6.22e-01	3.16e-01	0.00e+00
	var	3.00e-03	1.80e-03	5.00e-03	7.10e-03	1.20e-03	0.00e+00
f_7	best	3.24e+02	3.71e+02	2.19e+02	1.40e+02	8.20e+01	3.55e-56
	worst	3.77e+02	4.24e+02	4.90e+02	1.67e+02	9.61e+01	6.09e-54
	mean	3.50e+02	3.95e+02	2.79e+02	1.55e+02	8.86e+01	2.62e-54
	var	3.46e+02	4.70e+02	9.08e+03	8.96e+01	2.57e+01	4.30e-108
f_8	best	2.89e+07	2.57e+07	6.91e+06	3.24e+09	1.02e+08	6.46e-75
	worst	6.22e+07	8.08e+07	1.56e+07	8.79e+09	1.50e+08	1.70e-31
	mean	4.80e+07	4.97e+07	1.14e+07	5.38e+09	1.24e+08	3.41e-32
	var	1.33e+14	3.75e+14	1.14e+13	4.29e+18	4.72e+14	4.66e-63
f_9	best	2.94e+02	3.38e+02	1.36e+02	2.59e+02	6.98e+01	8.62e+01
	worst	3.21e+02	4.20e+02	1.89e+02	3.38e+02	8.08e+01	8.80e+01
	mean	3.07e+02	3.86e+02	1.58e+02	2.99e+02	7.46e+01	8.71e+01
	var	8.28e+01	7.98e+02	3.26e+02	6.78e+02	1.91e+01	5.14e-01
统计	sum	0/9	0/9	0/9	0/9	1/9	8/9
	rank	5	6	3	4	2	1

突变策略能够有效避免算法寻优过程陷入局部最优. 所提出算法的进化策略可指导粒子向优解空间更新自身状态, 避免粒子在搜索空间滞留, 减少算法评估次数, 因此具有较大的优势.

由表1的实验数据可见, 在解决1000维优化问题时所提出算法性能表现突出, 在寻优效率和求解精度方面均有很大提升, 仅在求解函数 f_9 时性能略低于ImCSO算法, 但是二者相差无几. 这是由于ImCSO算法采用排序配对策略, 使得粒子间的距离不会太大或太小, 粒子搜索行为更加稳定, 性能表现良好. 然而, 所提出算法在求解函数 f_9 时方差较小, 因此, 在高维优化问题的求解中性能表现更为稳定. 当维数增加至2000维时, 优化函数 f_9 时的收敛曲线如图5(i)所示, 相比其他对比算法有更好的寻优结果.

由最优值、最大值、平均值和方差可见, ITCSO算法在求解高维问题时性能明显优于其他对比算法, 综合排名第1. 通过实验结果分析可见, 所提出算法有较高的稳定性和鲁棒性, 各对比算法在求解高维问题时稳定性较差, 求解精度较低. 所提出算法稳定的主要原因是ITCSO中待更新的粒子均会获得更好的先验知识, 指导不同粒子的搜索行为, 算法可充分利用种群内部信息指导粒子的进化, 劣败粒子突变策略的引入可有效避免陷入局部最优, 有利于全局搜索和局部开发, 在搜索的后期阶段依然能够保持较高的搜索动力, 在处理高维优化问题时具有更大的优势.

5 结论

本文通过对粒子行为分析, 提出了一种改进的3重竞争群优化算法, 该方法可有效提高粒子寻优效率, 并在高维复杂优化问题的求解中表现出色. 算法在随机选取的3个粒子间进行竞争操作, 通过比较同一组粒子的适应度值采取不同的粒子更新方式, 获胜粒子向获胜子群学习. 劣败粒子获取获胜者位置后, 向获胜子群自竞争产生的获胜亚子群学习. 这些策略共同作用, 提高了算法的全局搜索能力和局部开发能力, 能够有效解决高维优化问题. 通过对几个常用的测试函数进行优化表明, 所提出ITCSO算法性能明显优于其他对比算法, 收敛性和求解精度均有很大提高, 因此, 在解决高维优化问题时表现出更好的适用性. 然而, 本文引入控制劣败粒子变异大小的参数 α 是通过多次实验得到的, 更适用于高维问题的求解, 当维度较低时 α 的控制作用会降低, 在求解部分函数时算法收敛精度较低, 但是, 总体优于其余对比算法. 因此, 后续的研究工作将通过引入自适应策略来调整粒子变异大小, 提高算法求解高维和低维问题

的适用性.

参考文献(References)

- [1] Kennedy J, Eberhart R. Particle swarm optimization[C]. Proceedings of ICNN'95-International Conference on Neural Networks. Perth, 1995: 1942-1948.
- [2] Ali N, Ayaz Y, Iqbal J. Collaborative position control of pantograph robot using particle swarm optimization[J]. International Journal of Control, Automation and Systems, 2022, 20(1): 198-207.
- [3] Nimmanterdwong P, Chalermssinsuwan B, Piumsomboon P. Application of neural network modeling and constrained particle swarm optimization of steam production from biomass power plant[J]. Energy Reports, 2022, 8: 1066-1072.
- [4] Jiang Y, Li X Y, Qin C W, et al. Improved particle swarm optimization based selective harmonic elimination and neutral point balance control for three-level inverter in low-voltage ride-through operation[J]. IEEE Transactions on Industrial Informatics, 2022, 18(1): 642-652.
- [5] Ho S D, Palacky P, Kuchar M, et al. Particle swarm optimization-based stator resistance observer for speed sensorless induction motor drive[J]. International Journal of Electrical and Computer Engineering, 2021, 11(1): 815-826.
- [6] Seo J H, Im C H, Heo C G, et al. Multimodal function optimization based on particle swarm optimization[J]. IEEE Transactions on Magnetics, 2006, 42(4): 1095-1098.
- [7] Chen W N, Zhang J, Lin Y, et al. Particle swarm optimization with an aging leader and challengers[J]. IEEE Transactions on Evolutionary Computation, 2013, 17(2): 241-258.
- [8] Hu M Q, Wu T, Weir J D. An adaptive particle swarm optimization with multiple adaptive methods[J]. IEEE Transactions on Evolutionary Computation, 2013, 17(5): 705-720.
- [9] Qu B Y, Suganthan P N, Das S. A distance-based locally informed particle swarm model for multimodal optimization[J]. IEEE Transactions on Evolutionary Computation, 2013, 17(3): 387-402.
- [10] Juang C F. A hybrid of genetic algorithm and particle swarm optimization for recurrent network design[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2004, 34(2): 997-1006.
- [11] Pehlivanoglu Y V. A new particle swarm optimization method enhanced with a periodic mutation strategy and neural networks[J]. IEEE Transactions on Evolutionary Computation, 2013, 17(3): 436-452.

- [12] Xu G P, Cui Q L, Shi X H, et al. Particle swarm optimization based on dimensional learning strategy[J]. *Swarm and Evolutionary Computation*, 2019, 45: 33-51.
- [13] Yang C H, Yang H S, Chuang L Y. PBMDR: A particle swarm optimization-based multifactor dimensionality reduction for the detection of multilocus interactions[J]. *Journal of Theoretical Biology*, 2019, 461: 68-75.
- [14] Garg H. A hybrid GSA-GA algorithm for constrained optimization problems[J]. *Information Sciences*, 2019, 478: 499-523.
- [15] Ghasemi M, Aghaei J, Akbari E, et al. A differential evolution particle swarm optimizer for various types of multi-area economic dispatch problems[J]. *Energy*, 2016, 107: 182-195.
- [16] Cheng R, Jin Y C. A competitive swarm optimizer for large scale optimization[J]. *IEEE Transactions on Cybernetics*, 2015, 45(2): 191-204.
- [17] Mohapatra P, Nath Das K, Roy S. A modified competitive swarm optimizer for large scale optimization problems[J]. *Applied Soft Computing*, 2017, 59: 340-362.
- [18] Nayak M R, Behura D, Nayak S. Performance analysis of unbalanced radial feeder for integrating energy storage system with wind generator using inherited competitive swarm optimization algorithm[J]. *Journal of Energy Storage*, 2021, 38: 102574.
- [19] 章强, 程辉, 叶贞成, 等. 改进竞争粒子群算法及其应用[J]. *计算机工程与设计*, 2019, 40(2): 376-383.
(Zhang Q, Cheng H, Ye Z C, et al. Improved competitive swarm optimizer and its applications[J]. *Computer Engineering and Design*, 2019, 40(2): 376-383.)
- [20] Xiong G J, Zhang J, Shi D Y, et al. Winner-leading competitive swarm optimizer with dynamic Gaussian mutation for parameter extraction of solar photovoltaic models[J]. *Energy Conversion and Management*, 2020, 206: 112450.
- [21] Chen X, Tang G W. Solving static and dynamic multi-area economic dispatch problems using an improved competitive swarm optimization algorithm[J]. *Energy*, 2022, 238: 122035.
- [22] 钱晓宇, 方伟. 基于局部搜索的反向学习竞争粒子群优化算法[J]. *控制与决策*, 2021, 36(4): 779-789.
(Qian X Y, Fang W. Opposition-based learning competitive particle swarm optimizer with local search[J]. *Control and Decision*, 2021, 36(4): 779-789.)
- [23] Rajani, Kumar D, Kumar V. Impact of controlling parameters on the performance of MOPSO algorithm[J]. *Procedia Computer Science*, 2020, 167: 2132-2139.
- [24] Wei B, Xia X W, Yu F, et al. Multiple adaptive strategies based particle swarm optimization algorithm[J]. *Swarm and Evolutionary Computation*, 2020, 57: 100731.

作者简介

张伟(1978—),女,教授,博士,从事智能特征建模、神经网络结构优化、污水处理过程优化控制等研究, E-mail: zwei1563@126.com;

魏万峰(1997—),男,硕士生,从事智能优化算法、智能特征建模、污水处理过程优化控制等研究, E-mail: 809019541@qq.com;

黄卫民(1997—),男,硕士生,从事神经网络结构优化和算法设计等研究, E-mail: hweimin97520@163.com.