

融合多策略改进的克隆选择算法

张文豪¹, 杨超^{2,3}, 彭旭¹, 王道维¹, 范波⁴

1. 湖北大学 网络空间安全学院, 湖北 武汉 430062;
2. 湖北大学 计算机与信息工程学院, 湖北 武汉 430062;
3. 智慧政务与人工智能应用湖北省工程研究中心, 湖北 武汉 430062;
4. 武汉大学 科学技术发展研究院, 湖北 武汉 430072)

摘要:针对克隆选择算法(CSA)解决复杂优化问题时存在的效率低下、收敛速度慢以及容易陷入局部最优等不足,提出了一种融合多策略改进的克隆选择算法(MSICSA)。首先,引入Sobol序列初始化种群,丰富种群多样性,并提高算法整体稳定性;其次,引入正余弦优化策略加强算法全局搜索能力,避免陷入局部最优而导致算法停滞;最后,引入动态浓度调节策略,调节算法在不同时期搜索空间内的抗体浓度,控制算法加强前期全局搜索以及后期局部寻优能力,并提高算法收敛速度。文中利用12种CEC测试函数及4种算法对MSICSA进行测试及对比,消融实验证明了改进策略的有效性,扰动实验验证了文中算法的稳定性与鲁棒性,对比仿真以及几项实验均表明MSICSA能够有效提升收敛速度和寻优精度,并提高跳出局部最优的能力。

关键词:克隆选择算法;正余弦优化策略;浓度调节策略;Sobol序列;抗体变异

中图分类号:TP18

文献标识码:A

文章编号:1673-629X(2024)06-0140-08

doi:10.20165/j.cnki.ISSN1673-629X.2024.0080

Improved Clonal Selection Algorithm Fusing Multiple Strategies

ZHANG Wen-hao¹, YANG Chao^{2,3}, PENG Xu¹, WANG Dao-wei¹, FAN Bo⁴

1. School of Cyber Science and Technology, Hubei University, Wuhan 430062, China;
2. School of Computer and Information Engineering, Hubei University, Wuhan 430062, China;
3. Engineering Research Center of Hubei Province in Intelligent Government Affairs and Application of Artificial Intelligence, Wuhan 430062, China;
4. School of Science and Technology Development, Wuhan University, Wuhan 430072, China)

Abstract: Aiming at the shortcomings of clonal selection algorithm (CSA) in solving complex optimization problems, such as low efficiency, slow convergence speed and easy to fall into local optimum, an improved clonal selection algorithm based on multi-strategy (MSICSA) was proposed. Firstly, the Sobol sequence was introduced to initialize the population, which enriched the diversity of the population and improved the overall stability of the algorithm. Secondly, the sine cosine optimization strategy was introduced to enhance the global search ability of the algorithm to avoid falling into local optimum and causing the stagnation of the algorithm. Finally, a dynamic adaptive concentration adjustment strategy was introduced to adjust the antibody concentration in the search space at different periods of the algorithm, which strengthened the global search ability in the early stage and the local optimization ability in the later stage, and improved the convergence speed of the algorithm. The ablation experiment shows the effectiveness of the improved strategy, and the perturbation experiment verifies the stability and robustness of the proposed algorithm. The comparative simulation show that MSICSA can effectively improve the convergence speed and optimization accuracy, and improve the ability to jump out of local optimum.

Key words: clonal selection algorithm; sine cosine optimization strategy; concentration regulation strategy; Sobol sequence; antibody variation

0 引言

高级生物体在免疫应答时,免疫系统控制着各种

免疫功能抵御“非我”的侵害^[1]。其具有自学习、记忆机制、模式识别、动态适应等特质,为解决实际复杂优

收稿日期:2023-07-05

修回日期:2023-11-08

基金项目:国家自然科学基金(61977021);湖北省重点研发计划项目(2021BAA184)

作者简介:张文豪(1997-),男,硕士研究生,研究方向为信息安全、计算机免疫学;杨超(1982-),男,博士,副教授,硕导,CCF高级会员(94791M),研究方向为信息安全、计算机免疫学;通讯作者:范波(1985-),男,硕士,高级工程师,研究方向为算法分析、软件工程。

化问题提供了大量的仿生灵感。人工免疫算法借鉴生物免疫系统,结合细胞进化机理构造而出。克隆选择算法(CSA)是人工免疫算法的重要分支^[2],通过模拟生物体内B细胞的选择、克隆、变异、更新等行为,利用高突变操作完成全局最优解搜索;具有出色的自学习和自适应能力,以及较强的鲁棒性、群体多样化等特点^[3];适合求解TSP和复杂函数优化问题,在智能寻优算法中拥有显著优势,多应用于调度^[4]、故障诊断^[5]、入侵检测^[6]、参数识别^[7]等方面。

但CSA也在收敛速度、寻优精度、跳出局部最优等方面存在不足,国内外学者针对上述问题提出众多改进。为提高算法收敛速度,2016年,谢新林等人提出CA-CSA,利用核值构造稳定区,只对可变区进行变异操作,加快算法的收敛速度,但是易陷入局部最优^[8];2022年,Liu等人使用亲和力和约束设施索引组成的序列双索引进行抗体选择,提高了准确性和收敛速度,但是易陷入局部最优^[9]。为提高算法寻优精度,2019年,Zhou等人建立双目标函数模型、引入精英策略,提高算法的寻优精度,但收敛速度和全局搜索能力较差^[10];2021年,王丽丽等人引入云变异因子进行变异并用反向学习策略进行抗体种群选择,提高寻优精度及稳定性,但是降低了局部寻优能力^[11]。为提高算法跳出局部最优的能力,2018年,Xi采用CA双层进化框架引导交叉和混沌突变操作,提高跳出局部最优能力,但忽视了种群多样性^[12];2020年,Yang等人利用生物遗忘机制消除低频突变抗体,提高抗体多样性、易陷入局部最优能力,但寻优精度较低^[13]。

众多学者将改进重点放在变异操作,以此提高算法抗体多样性和寻优精度,但是算法不同时期的全局搜索和局部寻优能力稍显不足,部分学者也忽视了初始种群位置对算法稳定性的影响。该文首先引入Sobol序列拟随机初始种群位置,丰富种群多样性,加强整体稳定性;其次引入正余弦优化策略,确定抗体搜索空间并引导抗体变异方向,提高算法寻优精度;最后引入动态浓度调节策略,利用非线性曲线控制搜索空间及其抗体浓度,加强算法前期全局搜索以及后期局部寻优能力,提高算法的收敛速度。文中的数值实验与结果分析验证算法达到了预期效果。

1 基础理论

1.1 Sobol序列初始化种群

元启发式搜索算法中^[14],对于初始种群的位置极其敏感,散乱分布会降低种群多样性,影响算法收敛性能及整体稳定性,故初始种群更应均匀分布,以保证较高的遍历性和多样性。Sobol序列是采用确定性拟随机数产生的低差异化序列,通过选择合理的采样方向,

将尽可能均匀的点填充至搜索空间中,具有计算周期短、采样速度快以及高效处理高维序列等特点。Sobol序列生成的初始种群个体位置表示如式1:

$$X_i = R_u + K_i \cdot (R_u - R_l) \quad (1)$$

其中, X_i 为生成抗体的位置坐标, $[R_u, R_l]$ 为测试函数的取值范围, $K_i \in [0, 1]$ 为Sobol序列产生的随机数。假设二维搜索空间,取值范围为 $[-1, 1]$,采用两种方式分别初始化500个个体,个体位置分布如图1所示。可以看出,Sobol序列相较于伪随机初始化的个体分布更加均匀,遍历性更广。

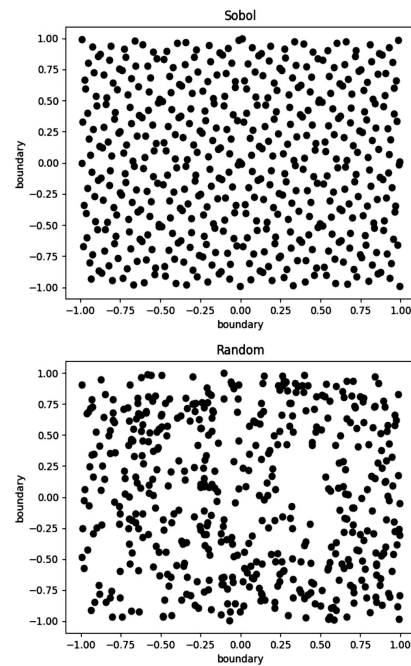


图1 Sobol序列与伪随机初始化种群对比

1.2 正余弦优化策略

正余弦优化策略利用正、余弦函数的数学性质更新抗体位置,该策略可以通过自适应改变函数的振幅来平衡算法在搜索过程中的全局搜索和局部寻优能力,并且还具备结构简单、参数少等特点。正余弦优化策略在探索过程中,将寻找搜索空间内最适合抗体更新的区域,开发过程中,将随机采用正弦或余弦函数在搜索空间内更新抗体位置。具体公式如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t + r_1 \sin r_2 \cdot |r_3 X_{per}^t - X_{i,j}^t|, & r_4 < 0.5 \\ X_{i,j}^t + r_1 \cos r_2 \cdot |r_3 X_{per}^t - X_{i,j}^t|, & r_4 \geq 0.5 \end{cases} \quad (2)$$

$$r_1 = a \cdot \left(1 - \frac{t}{T}\right) \quad (3)$$

式中, $X_{i,j}^t$ 表示在 t 次迭代中第 i 个抗体在第 j 维的位置, $j \in \{1, 2, \dots, N\}$; X_{per}^t 为第 t 次迭代中最优抗体的位置; r_1 作为控制参数,主要控制正余弦函数的振幅,即控制抗体的搜索空间(见式3),其中 $a = 2$; r_2, r_3, r_4 为服从均匀分布的随机数,其中 $r_2 \in [0, 2\pi]$,控制每

轮迭代抗体更新位置时移动的方向,影响新生成的抗体是位于当前抗体与最优抗体之间还是之外; $r_3 \in [0, 2]$,作用是给最优抗体设置随机权重,控制最优抗体在生成最新抗体时的影响效果; $r_4 \in [0, 1]$,控制算法在正弦和余弦更新之间的随机性。以上参数均参考文献[15]设定,为文献作者经过多次实验后确定的最优值。以二维随机变量为例,图2为范围处于 $[-2, 2]$ 的正余弦优化策略概念模型,该图说明了如何改变正余弦函数的范围及抗体更新时如何确定搜索空间和生成方向。 $r_1 \sin r_2$ 和 $r_1 \cos r_2$ 的波动幅度随着迭代次数的增加而逐渐衰减。当其值处于 $(-1, 1)$ 时,采用局部开发策略,下一轮抗体会在当前抗体与最优抗体之间的区域生成;当其值处于 $(-2, -1]$ 和 $[1, 2)$ 时,采用全局搜索策略,抗体会在当前抗体与最优抗体之外的区域生成。




图2 正余弦优化策略概念模型

1.3 动态浓度调节策略

抗体在更新时,随着迭代次数增加,搜索空间会逐渐缩减,种群多样性随之降低,此时算法易陷入局部最优。引入正余弦优化策略虽然可以使算法加强全局搜索能力,但是算法难以在不同时期控制搜索空间。考虑到算法前期需要加强全局搜索能力,使算法跳出局部最优解,所以需要降低搜索空间减小的速率;而算法后期更应加强局部寻优能力,使算法更快收敛,该文将引入动态浓度调节策略。正余弦优化策略中的参数 r_1 决定算法的搜索空间,考虑到 r_1 受线性控制(见式3),致使抗体的搜索空间随迭代次数线性缩减,故该文选用非线性曲线 ω 替代 r_1 ,从而动态调节搜索空间内的抗体浓度,以此控制算法在不同时期的全局搜索以及局部寻优能力,具体的调节公式如下:

$$\omega = 2 \cdot [1 - \sin((\frac{t}{T})^2 \cdot \frac{\pi}{2})] \quad (4)$$

如图3所示,相比于线性曲线 r_1 , ω 在迭代前期较为平缓,可以使搜索空间递减速度放缓,降低搜索空间内的抗体浓度,使生成的抗体覆盖区域更加宽泛,以此来增强算法前期的全局搜索能力,使其更易跳出局部最优;在迭代中期, ω 变化速率增快,此时搜索空间内的抗体浓度也急剧变化,提高了算法中期的寻优效率;在迭代后期,搜索空间急剧减少, ω 的变化速率相应放缓,此时搜索空间内的抗体浓度上升,提升了算法的

局部寻优能力,使算法更快地确定最优抗体。




图3 动态浓度调节曲线

2 改进的克隆选择算法

2.1 算法描述

在CSA中,初始种群的生成采用伪随机方式,这种方式生成的抗体种群分布较为散乱,降低了抗体种群的多样性和算法整体稳定性;变异操作可以改变抗体基因来丰富抗体种群,在局部寻优时,加快算法收敛速度,但随着迭代次数的增加,变异抗体的生成空间逐渐减小,易使算法陷入局部最优;且CSA不能动态控制搜索空间,导致算法寻优精度降低。针对上述问题,该文提出一种融合多策略改进的克隆选择算法(MSICSA)。首先,利用Sobol序列初始化抗体种群,使抗体均匀分布在搜索空间内,丰富种群多样性,并提高算法整体稳定性;其次,引入正余弦优化策略引导抗体变异,减少抗体变异的随机性,加强算法寻优精度;最后,引入动态浓度调节策略,利用非线性曲线控制搜索空间,加强算法前期的全局搜索能力以及后期的局部寻优能力,提高算法寻优精度以及收敛速度。

2.2 算法流程

MSICSA流程如图4所示。

定义:种群规模 I ,优秀抗体规模 D_{per} ,克隆抗体规模 C ,维度 \dim ,抗体值的上下边界 R_u 和 R_l ,最大迭代次数 T ,变异概率 m ,参数 $a = 2$,算法具体步骤如下:

- (1) 设定目标函数 $f(x)$ 以及算法的基本参数。
- (2) Sobol序列初始化抗体种群 $P = \{x_1, x_2, \dots, x_i\}$ 。
- (3) 计算本轮抗体与抗原的亲合度 $A(X_i)$,并按照亲合度降序排序。
- (4) 根据亲合度排序选择前 D 个抗体,进行克隆生成新的 C 个抗体。
- (5) 利用动态浓度调节策略计算调节因子 ω ,调节搜索空间及其内的抗体浓度。
- (6) 利用正余弦优化策略对克隆后的 C 个抗体进行变异操作。
- (7) 再次计算抗体亲合度,选择亲合度最高的 D 个抗体,并删除其余抗体。

- (8) 随机补入 $I - D$ 个抗体,组成新的种群 P' 。
- (9) 满足终止条件,结果输出,否则重复步骤 3 ~ 8。

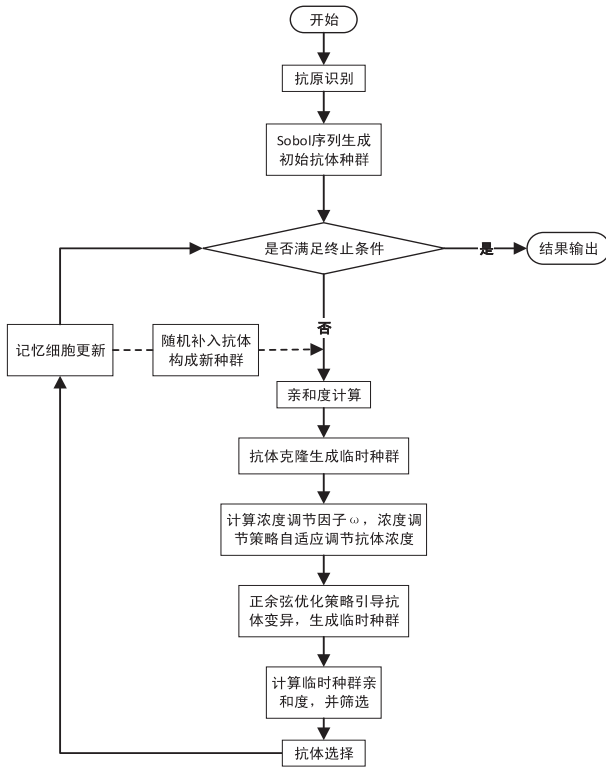


图 4 MSICSA 流程

2.3 时间复杂度分析

为预测算法所需资源及运行时间,对算法进行复杂度分析。算法包含种群规模 I 、维度 dim 、克隆规模 C 、优秀抗体规模 D 等参数。算法主要包括以下 5 个步骤:(1) 计算亲和度;(2) 克隆操作;(3) 变异操作;(4) 选择操作;(5) 种群更新操作。操作 1 执行依据种群规模大小决定,次数为 I ;操作 2、操作 3 对抗体种群进行克隆、变异操作,需要执行次数为 $2C$;操作 4,根据亲和度对种群进行排序,选择出前 D 个优秀抗体,使用时间复杂度最小的快速排序算法,所需的计算量

为 $D \log_2 D$;操作 5 根据亲和力排序,将除优秀抗体之外的抗体进行替换,最少需要执行 $I - D$ 次。已知 $I > 2C > C \geq D$,第 t 次迭代过程中 MSICSA 算法执行的总次数 S_t 应符合以下条件:

$$S_t \leq I + 2C + D \log_2 D + (I - D) \leq 3I \quad (5)$$

由于 MSICSA 相较于 CSA 增加的时间复杂度是线性级的,因此 MSICSA 的计算量最高级为 $O(I)$,与 CSA 的时间复杂度一致。因此,改进策略并未增加算法时间复杂度。

3 数值实验与结果分析

该文采用 12 种测试函数分别对 MSICSA 及 4 种对比算法进行测试,并进行收敛精度分析、稳定性分析、Wilcoxon 秩和检验、收敛曲线分析、扰动实验及消融实验。测试函数均为 CEC2022 函数集中具有代表性的测试函数,较为复杂且具有边界约束,能够充分检验算法的综合性能;对比算法采用融合云模型和反向学习的克隆选择算法 (CRCSA)、粘液霉菌算法 (SMA)^[16]、黄金正弦搜索算法 (GSA)^[17]、基于 Sobol 序列和纵横交叉策略的麻雀搜索算法 (SSASC);其中 SMA、SSASC 及 GSA 均为近几年提出的智能搜索算法,具有较好的寻优性能,而 CRCSA 提高了 CSA 的寻优精度及稳定性。与以上算法比较,更能检验文中算法的改进效果。设定文中算法的默认参数:种群规模 $I = 1000$,优秀抗体规模 $P_{\text{per}} = 300$,维度 $\text{dim} = 10$,最大迭代次数 $T = 500$,抗体值的上下边界 R_u 和 R_l 由测试函数确定;除默认参数外,其他对比算法内部的参数均按照参考文献设定。

3.1 测试函数

为验证 MSICSA 的实用性与有效性,实验选取的测试函数涵盖了多峰、高维、非线性以及线性与非线性混合等特点(见表 1)。其中, $f_6 \sim f_{12}$ 为多峰测试函

表 1 CEC2022 测试函数

functions	expression	scope	optimal
Bent Cigar Function	$f_1(x) = x_1^2 + 10^6 \sum_{i=2}^D x_i^2$	$[-10, 10]$	0
Different Power Function	$f_2(x) = \sum_{i=1}^D x_i ^{i+1}$	$[-100, 100]$	0
Rosenbrock's Function	$f_3(x) = \sum_{i=1}^{D-1} [100(x_i^2 - x_{i+1}) + (x_i - 1)^2]$	$[-10, 10]$	0
Discus Function	$f_4(x) = 10^6 x_1^2 + \sum_{i=2}^D x_i^2$	$[-10, 10]$	0
Rotated Elliptic Function	$f_5(x) = \sum_{i=1}^D (10^6)^{\frac{i-1}{D-1}} \cdot x_i^2$	$[-100, 100]$	0
Ackley Function	$f_6(x) = -20 \exp(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2}) - \exp(\frac{1}{D} \sum_{i=1}^D \cos(2\pi x_i)) + 20 + e$	$[-32, 32]$	0
Rastrigin Function	$f_7(x) = \sum_{i=1}^D [x_i^2 - 10 \cos(2\pi x_i) + 10]$	$[-5.12, 5.12]$	0

续表 1

functions	expression	scope	optimal
Zakharov Function	$f_8(x) = \sum x_i^2 + (\sum 0.5x_i)^2 + (\sum 0.5x_i)^2$	[-5,10]	0
Katsuura Function	$f_9(x) = \frac{10}{D^2} \prod (1 - i \sum \frac{ 2^j x_i - \text{round}(2^j x_i) }{2^j})^{\frac{10}{D^2}} - \frac{10}{D^2}$	[-10,10]	0
Schwefel's Problem 2.21 Function	$f_{10}(x) = \max(x_1 , x_2) + 0.3 \sin(10\pi x_1) \cdot \sin(10\pi x_2)$	[-100,100]	0
Schaffer's F7 Function	$f_{11}(x) = 0.5 + \frac{\sin^2(\sqrt{x_1^2 + x_2^2}) - 0.5}{(1 + 0.001 \cdot (x_1^2 + x_2^2))^2}$	[-100,100]	0
Expanded Sums Function	$f_{12}(x) = \sum (\sum x_j)^2$	[-10,10]	0

数,共同特点是具有多个全局最优解以及多个局部最优解,函数图像复杂,适用于检测算法在高维复杂问题下的寻优性能和稳定性;另外, $f_1 \sim f_{10}$ 以及 f_{12} 为高维测试函数,具有可视化困难、计算过程复杂和局部最优解稀疏的特点;另外, $f_1 \sim f_{11}$ 为非线性测试函数,它们包含多个极值点,具有形式复杂、计算复杂且易陷入局部最优等特点; f_{11} 为线性与非线性混合测试函数,该测试函数由线性与非线性两部分组成,不同部分具有不同的优化难度,且具有调和特性。

3.2 收敛精度及稳定性分析

收敛精度决定算法能否有效找到全局最优解,稳定性会影响算法在面对复杂问题时的搜索偏差。该文采用最优抗体的平均值和标准差评估不同算法的收敛

性能,其中平均值可以反映出算法的搜索精度,标准差可以反映出算法的稳定性。

对于单峰测试函数,记录 MSICSA、CRCSA、SSASC、SMA 以及 GSA 在相同测试环境中各执行 50 次后的平均值以及标准差,实验结果如表 2 所示,其中最优结果用粗体显示。在 f_2 的测试结果中,MSICSA 的平均值和标准差与 SMA 和 SSASC 持平且低于其他对比算法;在 f_4 的测试结果中,MSICSA 的平均值和标准差与 SSASC 持平且低于其他对比算法;而在 f_1, f_3 的测试结果中,MSICSA 的平均值与标准差均低于其他四种算法,即 MSICSA 在单峰函数的测试中相较于其他对比算法具有较高的收敛精度和稳定性。

表 2 单峰测试函数寻优性能比较

algorithm	mean				std			
	f_1	f_2	f_3	f_4	f_1	f_2	f_3	f_4
MSICSA	5.362 18e-190	0.000 00e+00	0.000 00e+00	0.000 00e+00	2.860 81e-189	0.000 00e+00	0.000 00e+00	0.000 00e+00
CRCSA	1.671 20e-121	7.283 56e-120	3.208 65e-122	1.124 16e-120	7.186 40e-121	3.156 85e-119	1.089 53e-121	3.989 69e-120
SSASC	1.983 51e-184	0.000 00e+00	7.254 84e-366	0.000 00e+00	2.235 49e-183	0.000 00e+00	3.235 27e-365	0.000 00e+00
SMA	1.264 24e-155	0.000 00e+00	3.137 31e-321	3.325 55e-319	3.397 29e-155	0.000 00e+00	6.486 73e-320	3.318 78e-318
GSA	6.462 57e-29	2.486 42e-47	1.092 87e-55	8.453 44e-37	1.053 52e-28	2.326 95e-45	3.237 57e-54	4.305 38e-38

对于多峰测试函数,记录 MSICSA、CRCSA、SSASC、SMA 分别在 $\text{dim} = 10, \text{dim} = 20, \text{dim} = 50$, 以及其他相同测试环境中各执行 50 次后的平均值及标准差,实验结果如表 3 所示,其中最优结果用粗体显示。分析可知,在 f_6 的测试结果中,SSASC 在不同维度下的平均值和标准差均优于其他对比算法,且相对稳定,而 MSICSA 在此测试函数中表现不佳;在 f_7, f_9 的测试

结果中,MSICSA 在不同维度下的平均值和标准差均与 SMA 或 SSASC 持平且低于 CRCSA;在 f_8, f_{12} 的测试结果中,MSICSA 在不同维度下的平均值与标准差均低于其他对比算法,即 MSICSA 在多峰问题中具有较高寻优精度与较强的收敛稳定性,且寻优性能受维度影响的程度较小。

表 3 多峰测试函数寻优性能比较

function	algorithm	dim = 10		dim = 50		dim = 100	
		mean	std	mean	std	mean	std
f_6	MSICSA	4.440 892e-22	4.013 639e-21	2.721 135e-19	6.076 169e-18	5.678 174e-16	1.267 918e-15
	CRCSA	7.964 763e-124	1.757 303e-123	9.387 739e-114	2.894 709e-113	1.363 755e-111	3.605 465e-111
	SSASC	2.070 554e-159	4.620 335e-158	3.719 755e-147	8.306 786e-145	7.101 581e-138	1.488 836e-137
	SMA	1.566 338e-146	2.843 715e-145	2.202 888e-136	2.510 545e-135	1.566 338e-133	2.843 715e-132

续表 3

function	algorithm	dim=10		dim=50		dim=100	
		mean	std	mean	std	mean	std
f_7	MSICSA	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00
	CRCSA	1.025 152e-120	4.155 315e-120	1.125 387e-110	4.782 725e-110	1.055 352e-108	4.594 642e-108
	SSASC	1.962 867e-193	3.737 738e-192	1.704 252e-187	3.352 752e-186	2.815 295e-168	6.256 115e-167
	SMA	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00
f_8	MSICSA	8.895 899e-319	2.349 244e-318	1.856 998e-136	6.037 605e-136	2.411 517e-117	1.051 067e-116
	CRCSA	4.630 610e-120	1.515 337e-119	5.466 304e-113	1.289 704e-112	3.994 063e-111	1.481 124e-110
	SSASC	2.124 534e-312	4.506 284e-311	1.353 059e-135	3.022 274e-134	1.390 529e-102	3.106 205e-101
	SMA	3.263 786e-304	4.434 885e-303	6.153 886e-132	2.682 402e-131	2.322 881e-50	1.012 520e-49
f_9	MSICSA	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00
	CRCSA	1.550 765e-122	1.592 311e-121	2.119 267e-111	4.302 694e-110	7.687 168e-106	1.368 276e-105
	SSASC	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00
	SMA	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00
f_{12}	MSICSA	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00	0.000 000e+00
	CRCSA	2.167 458e-244	1.567 947e-243	2.044 989e-169	1.743 888e-167	7.834 587e-86	5.155 457e-85
	SSASC	3.133 564e-315	3.332 447e-314	2.101 929e-283	3.554 882e-282	3.312 897e-226	7.763 706e-225
	SMA	1.573 650e-266	2.079 775e-267	2.950 384e-206	6.355 729e-204	1.498 043e-155	1.632 583e-154

综上所述, MSICSA 对比 CRCSA、SSASC、SMA、GSA, 收敛更加稳定可靠, 寻优精度均高于对比算法; 对于多峰、高维、非线性等问题, 文中算法在寻优精度和整体稳定性上有较好的效果, 说明改进策略是有效的。

3.3 收敛曲线分析

通过收敛曲线图可以更加直观地反映算法的收敛速度和寻优精度。图 5 为 MSICSA 与四种对比算法关于测试函数的收敛曲线。

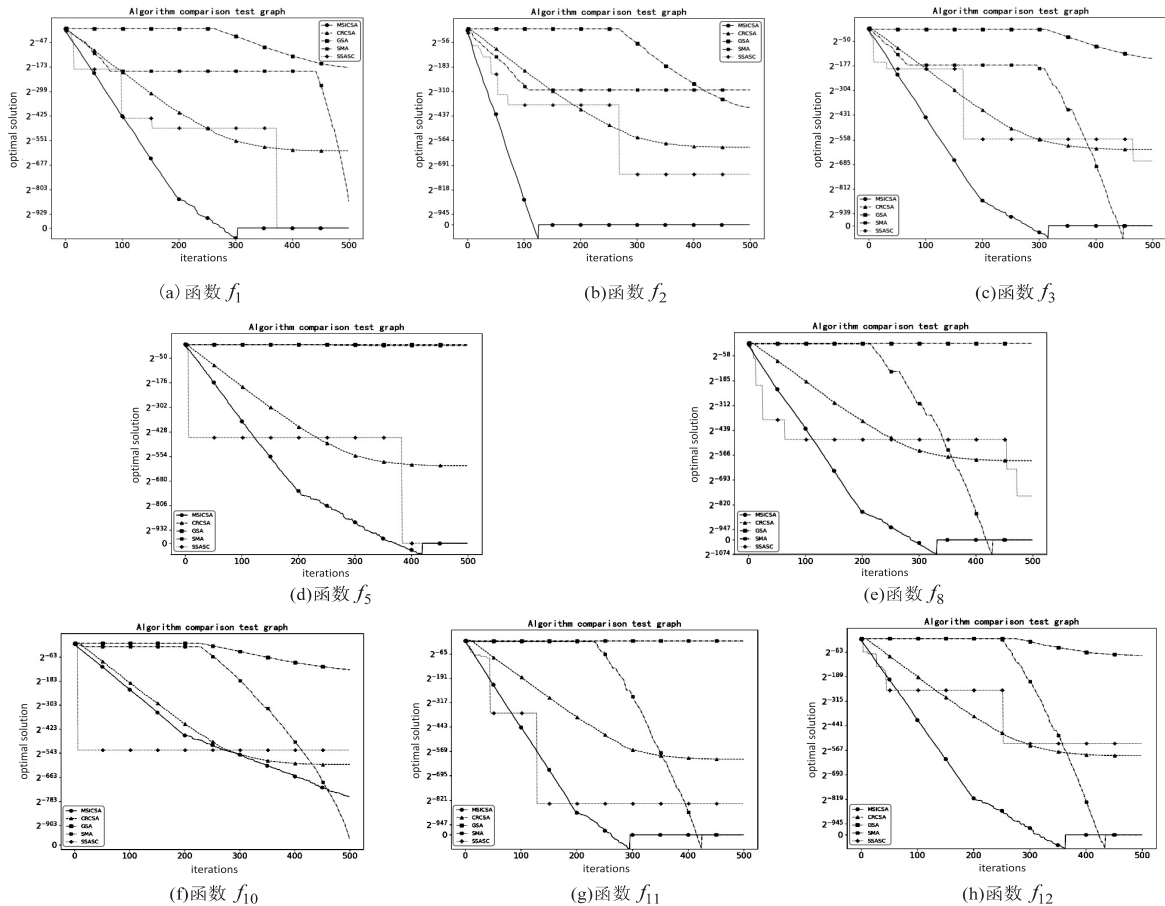


图 5 收敛曲线对比

在关于 $f_1 \sim f_3, f_5$ 四个单峰函数测试中, MSICSA 与 SSASC 的收敛精度最优, 且 MSICSA 的收敛速度更快; SMA 在迭代后期成功跳出局部最优, 但收敛速度较慢; CRCSA 在前期可以稳定寻优, 但在迭代后期陷入局部最优; 而 GSA 在迭代前期陷入局部最优。在关于 $f_8, f_{10} \sim f_{12}$ 在四个多峰函数测试中, 关于 f_8 与 f_{12} , MSICSA、SSASC、SMA 的寻优精度均为最优, 但 SSASC、SMA 收敛速度低于 MSICSA 算法; CRCSA 在迭代后期易陷入局部最优; 而 GSA 在迭代前期陷入局部最优。关于 f_{10} , CRCSA 在迭代前期稳定寻优, 但在迭代后期易陷入局部最优, 而其他算法均未能达到最优。关于 f_{11} , MSICSA 与 SSASC 均能达到最优, 但 SSASC 收敛速度稍快; CRCSA 在迭代后期陷入局部最优; SMA 在迭代前期陷入局部最优。

综上所述, MSICSA 对比 CRCSA、SSASC、SMA、GSA, 在寻优精度、收敛速度以及跳出局部最优的能力

上均取得了较好的效果, 说明了改进策略是有效的。

3.4 扰动实验

扰动实验将进一步验证 MSICSA 的稳定性与鲁棒性。本文的扰动实验将随机补入抗体阶段更改为随机补入部分抗体以及离群抗体(离群抗体产生在搜索空间边缘), 以此来扰动下一轮抗体的克隆和变异。共进行 4 次实验, 每次实验各执行算法 100 次, 分别设定离群抗体的规模占随机补入抗体的 0%、5%、10%、20%, 设定算法的最优解达成率阈值 $K = 0.95$, 当实验结果的最优解达成率高于阈值时, 则证明改进算法在该扰动条件下具有较强的稳定性与鲁棒性。

实验结果如表 4 所示, 在四种扰动环境下本文算法最优解达成率均达到阈值以上, 证明本文算法在标准环境以及离群抗体的扰动下有关多峰、高维、非线性、非线性与线性混合等特性的测试函数寻优上具有较好的稳定性与鲁棒性。

表 4 扰动实验及最优解达成率

function	0% disturbance	5% disturbance	10% disturbance	20% disturbance
f_1	1.00	1.00	1.00	1.00
f_2	1.00	1.00	0.99	0.98
f_3	1.00	1.00	0.99	0.98
f_6	1.00	1.00	0.98	0.98
f_7	1.00	1.00	0.99	0.99
f_9	1.00	1.00	1.00	0.98
f_{11}	1.00	1.00	0.99	0.98
f_{12}	1.00	1.00	0.99	0.97

3.5 消融实验结果及分析

对 MSICSA 进行消融实验并与其他对比算法在寻优性能上进行对比, 设置 MSICSA1 不含 Sobol 序列映射、MSICSA2 不含正余弦优化策略、MSICSA3 不含

动态浓度调节策略。对不同函数的寻优结果如表 5 所示, 其中最优结果用粗体显示。分析可知, 文中的改进策略相较于部分改进以及其他对算法在寻优性能上具有较大的提升。

表 5 消融实验性能比较

Function	Indicator	MSICSA	MSICSA1	MSICSA2	MSICSA3	CRCSA	SMA
f_1	mean	5.362 181e-190	3.156 781e-101	4.787 653e-64	7.126 630e-90	1.671 203e-121	1.295 695e-155
	std	2.860 812e-189	5.454 651e-100	5.456 878e-63	1.456 428e-89	7.186 409e-121	3.397 292e-155
f_2	mean	0.000 000e+00	4.452 752e-103	8.689 687e-66	2.043 570e-92	7.283 566e-120	0.000 000e+00
	std	0.000 000e+00	1.125 615e-102	1.545 786e-65	4.786 766e-91	3.156 859e-119	0.000 000e+00
f_3	Mean	0.000 000e+00	5.342 583e-98	3.348 415e-59	1.395 469e-86	3.208 651e-122	3.137 317e-321
	std	0.000 000e+00	3.537 275e-97	5.789 713e-58	6.765 173e-85	1.089 537e-121	6.486 731e-320
f_4	mean	0.000 000e+00	4.174 859e-109	2.364 315e-70	3.378 522e-98	1.124 166e-120	3.325 556e-319
	std	0.000 000e+00	7.523 757e-108	5.576 533e-69	7.863 164e-97	3.989 693e-120	3.318 783e-318
f_6	mean	4.440 892e-22	8.236 883e-111	7.088 006e-72	8.891 609e-101	7.964 763e-124	1.566 338e-146
	std	4.013 639e-21	3.574 275e-110	2.856 786e-71	4.876 711e-100	1.757 303e-123	2.843 715e-145
f_7	mean	0.000 000e+00	1.365 439e-104	4.314 437e-66	4.616 843e-94	1.025 152e-120	0.000 000e+00
	std	0.000 000e+00	8.156 468e-103	2.567 841e-65	6.494 136e-93	4.155 315e-120	0.000 000e+00

续表 5

Function	Indicator	MSICSA	MSICSA1	MSICSA2	MSICSA3	CRCSA	SMA
f_8	mean	8.895 899e-319	9.376 994e-99	3.744 337e-64	4.417 346e-92	4.630 610e-120	3.263 786e-304
	std	2.349 244e-318	3.587 933e-98	3.457 671e-63	5.143 182e-91	1.515 337e-119	4.434 885e-303
f_9	mean	0.000 000e+00	5.397 842e-116	4.586 543e-71	4.722 079e-98	1.550 765e-122	0.000 000e+00
	std	0.000 000e+00	2.656 787e-115	1.546 781e-70	2.916 675e-97	1.592 311e-121	0.000 000e+00

4 结束语

针对 CSA 随机性初始化生成的种群多样性不足而导致算法寻优精度以及整体稳定性差的问题, 该文采用 Sobol 序列来伪随机初始化种群, 使生成的抗体可以均匀分布在整个解空间中, 丰富了种群多样性、加强了算法整体稳定性; 针对算法容易陷入局部最优的问题, 采用正余弦优化策略引导抗体变异, 利用正余弦函数的数学性质加强算法全局搜索能力和寻优精度; 针对算法搜索空间难以控制的问题, 引入动态浓度调节策略, 利用非线性曲线控制搜索空间缩减, 动态调节搜索空间内的抗体浓度, 在迭代前期扩大全局搜索, 在迭代中期加快寻优效率, 在迭代后期加强局部寻优, 增强了算法整体的寻优精度和收敛速度。

通过 12 种测试函数对比其他 4 种优秀的智能算法, 进行了对比实验、消融实验以及扰动实验, 并且根据实验结果对文中算法的寻优精度、收敛速度以及稳定性和鲁棒性进行了分析, 验证了改进策略的有效性。

目前各种改进的克隆选择算法已多次应用于实际复杂的优化问题, 且在各工程领域取得了一定的成效。文中算法经实验验证已达到预期效果, 故将其应用在实际复杂的优化问题上也较易实现, 笔者未来会在利用该算法解决实际复杂优化问题上做进一步研究。

参考文献:

- [1] 蒋亚平, 张安康, 黎 星. 人工免疫系统的研究进展与展望 [J]. 信息安全与通信保密, 2021(2): 83-92.
- [2] LI L J, LIN Q Z, MING Z. A survey of artificial immune algorithms for multi-objective optimization [J]. Neurocomputing, 2022, 489: 211-229.
- [3] ZHANG W W, GAO K, ZHANG W Z, et al. A hybrid clonal selection algorithm with modified combinatorial recombination and success-history based adaptive mutation for numerical optimization [J]. Applied Intelligence, 2019, 49(2): 819-836.
- [4] KASHAV A, TRIBHUWAN K T. VMS-MCSA: virtual machine scheduling using modified clonal selection algorithm [J]. Cluster Computing, 2021, 24(4): 1-19.
- [5] SANTOSHINEE M, PABITRA M K, RAKESH R S W. Fault diagnosis in wireless sensor network using clonal selection

principle and probabilistic neural network approach [J]. International Journal of Communication Systems, 2019, 32(16): e4138.1-e4138.20.

- [6] 张 玲, 张建伟, 桑永宣, 等. 基于随机森林与人工免疫的入侵检测算法 [J]. 计算机工程, 2020, 46(8): 146-152.
- [7] CHEN Q, FU Y, CAI Q P. Parameter identification of permanent magnet synchronous motor based on clone-selective differential evolutionary algorithm [J]. Sensors and Microsystems, 2022, 41(1): 135-137.
- [8] 谢新林, 续欣莹, 谢 珺, 等. 一种基于粗糙集核值的克隆选择算法 [J]. 小型微型计算机系统, 2016, 37(5): 992-996.
- [9] LIU J Q, ZHANG Z Q, GONG J H, et al. A novel hybrid clonal selection algorithm for the corridor allocation problem with irregular material handling positions [J]. Computers & Industrial Engineering, 2022, 168: 953-972.
- [10] ZHOU B H, WU Q. An improved immune clonal selection algorithm for bi-objective robotic assemble line balancing problems considering time and space constraints [J]. Engineering Computations, 2019, 36(6): 1868-1892.
- [11] 王丽丽, 申 燚, 徐玉松, 等. 融合云模型和反向学习的克隆选择算法 [J]. 计算机工程与应用, 2021, 57(17): 68-74.
- [12] XI L, YAO Z, ZHAO Y, et al. CC-CSA: a culture & chaos inspired clonal selection algorithm for abnormal detection [J]. Journal of Intelligent & Fuzzy Systems, 2020, 39(1): 1-13.
- [13] CHAO Y, QIU B C, LIN J, et al. Improved clonal selection algorithm based on biological forgetting mechanism [J]. Complexity, 2020, 2020: 1-10.
- [14] 段玉先, 刘昌云. 基于 Sobol 序列和纵横交叉策略的麻雀搜索算法 [J]. 计算机应用, 2022, 42(1): 36-43.
- [15] SEYEDALI M. SCA: a sine cosine algorithm for solving optimization problems [J]. Knowledge-Based Systems, 2016, 96: 120-133.
- [16] LI S M, CH N H L, WANG M J, et al. Slime mould algorithm: a new method for stochastic optimization [J]. Future Generation Computer Systems, 2020, 111: 300-323.
- [17] TANYILDIZI E, DEMIR G. Golden sine algorithm: a novel math-inspired algorithm [J]. Advances in Electrical and Computer Engineering, 2017, 17(2): 71-78.