

基于变因子加权学习与邻代维度交叉策略的改进 CSA 算法

赵世杰,高雷阜,于冬梅,徒 君
(辽宁工程技术大学优化与决策研究所,辽宁阜新 123000)

摘 要: 针对乌鸦搜索算法(CSA)优化高维问题时存在寻优精度低、局部极值逃逸能力弱等问题,提出一种耦合多个体变因子加权学习机制与最优个体邻代维度交叉策略的改进乌鸦搜索算法(ICSA)。该算法随迭代进程动态修正模型控制参数(感知概率和飞行长度),利用多个体的变因子加权学习机制保证子代个体同时继承跟随乌鸦与上代最优个体的位置信息以避免单个体继承的过快种群同化并减小陷入局部极值的风险;同时构建历史最优个体的邻代维度交叉策略,并按维度绝对差异大的优先替换原则更新最优个体位置,以保留历代最优维度信息并提高算法的局部极值逃逸能力。数值实验结果分别验证了模型参数对 CSA 算法性能的一定影响,加权学习因子不同递变形式对 ICSA 算法性能改善的有效性与其差异性以及改进算法的优越寻优性能。

关键词: 智能优化算法;乌鸦搜索算法;变因子加权学习机制;邻代维度交叉策略;基准测试函数

中图分类号: TP18 **文献标识码:** A **文章编号:** 0372-2112 (2019)01-0040-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.01.006

Improved Crow Search Algorithm Based on Variable-Factor Weighted Learning and Adjacent-Generations Dimension Crossover Strategy

ZHAO Shi-jie, GAO Lei-fu, YU Dong-mei, TU Jun

(*Institute of Optimization and Decision, Liaoning Technical University, Fuxin, Liaoning 123000, China*)

Abstract: Considering that crow search algorithm (CSA) has low optimization accuracy and weak local-optimum escape ability in optimizing high-dimensional problems, an improved crow search algorithm (ICSA) is proposed by coupling the variable-factors' weighted learning mechanism of multiple individuals (Mi-VWL) and the adjacent-generations dimension crossover strategy of the best individual (Bi-ADC). In the proposed algorithm, the model parameters, i. e. awareness probability and flight length, are firstly modified dynamically with increasing number of iterations. Meanwhile, the Mi-VWL is introduced to guarantee that offspring individuals of crow population can inherit position information from the followed crow and the best individual of the last generation simultaneously, which is advantageous to avoid the over-rapid population intensification of single-individual learning and reduce the algorithm's risk on dropping into local optimum. Furthermore, Bi-ADC is constructed and the priority replacement principle of larger absolute value difference of dimensions between two-generations is adopted to update position of the best individual, which is beneficial to retain the optimal dimension information of historical best crows and enhance the local extreme escape ability of algorithms. Experimental results verify the influence of modal parameters on CSA's performance, the effectiveness and differences of different-type weighted learning factor on improving ICSA's capability and the superior optimization ability of the proposed algorithm, respectively.

Key words: intelligent optimization algorithm; crow search algorithm; variable-factor weighted learning mechanism; adjacent-generations dimension crossover strategy; benchmark function

收稿日期:2017-05-02;修回日期:2018-01-26;责任编辑:孙瑶

基金项目:辽宁省博士启动基金(No. 20170520075);国家自然科学基金青年基金(No. 51704140);辽宁省教育厅基金(No. LJ2017QL031, No. LJYL043);辽宁省社科规划基金(No. L17BGL004)

1 引言

智能优化算法是受特定自然现象启发而提出的一类基于群体的随机优化方法,其以初值不敏感、易于理解、操作简单等优点而被看作是确定性优化算法的一种拓展,目前已在供应链网络结构优化^[1]、系统级故障诊断^[2]、生产制造与调度^[3]等领域得到成功应用.智能算法根据其启发式机理不同大致可分为3类:第一类是基于自然进化、遗传等生物进化机制的随机搜索算法,发展较早且较为成熟,主要包括遗传算法^[4](Genetic Algorithms, GA)、进化规划^[5]和进化策略等,其中以 GA 最具代表性,它通过模拟基因操作中的选择、交叉和突变等算子以实现解集的迭代更新并最终寻得问题最优解;第二类是基于生物群体间的组织、协作等个体或群间行为的随机优化方法,发展较为迅速且灵感启发涵盖微生物、植物和动物等多种物种,其中以粒子群优化算法^[6](Particle Swarm Optimization, PSO)较为经典,它通过模拟鸟群捕食行为构建迭代寻优机理并利用多个体的并行搜索而确定问题最优解,蚁群算法^[7]则是求解离散型优化问题的代表——通过模型化自然界蚂蚁觅食过程中的路径寻优行为寻得问题最优解;第三类是启发于特定物理现象/规律并数学化重建建模以赋予其随机寻优性能的一类启发式算法,其中最基本的是源于固体退火原理的模拟退火算法^[8](Simulated Annealing),它通过模拟固体由高温串行冷却过程中粒子渐趋于有序平衡态并融入概率性突跳以最终收敛于问题最优解.鉴于智能优化算法的较好迭代寻优性能以及人们对自然启发式机制的不断探索与挖掘,基于新启发思想的智能算法也不断被提出,如源于多元宇宙理论中虫洞、黑洞和白洞等概念机理的多元宇宙优化算法^[9](Multi Verse Optimizer, MVO)、基于平衡域探索与开采性能的搜索群组算法^[10](Search Group Algorithm, SGA)、模仿自然界蚁狮狩猎机制的蚁狮优化算法^[11](Ant Lion Optimizer, ALO)等等.

乌鸦搜索算法^[12](Crow Search Algorithm, CSA)是通过模拟乌鸦隐藏和回取食物过程中的智能行为而提出的一种新的随机优化算法,通过对多组工程优化问题和基准测试函数的实验有效验证了其较好的寻优性能;得益于其简单易理解的启发机制、较少调节参数和较强优化性能等优势,目前已成功应用于桁架、焊接梁和弹簧等工程设计问题^[12]、极限学习机参数优化^[13]、核磁共振图像分割^[14]等多个领域.

CSA 算法中感知概率 AP 和飞行长度 fl 作为两个关键模型参数影响着其迭代寻优性能,但传统 CSA 算法将二者均设为固定常数并不利于算法寻优性能的充分发挥;同时乌鸦种群的子代个体只通过随机跟随单

只乌鸦更新自身位置信息并生成子代新种群,但个体学习方式并不一定能够保证算法较好的全局搜索性能且极易造成乌鸦群体的过快同化而不利于种群多样性保持.针对上述问题,提出一种改进 CSA 算法(Improved CSA, IC-SA)以针对性改善算法的特定性能.模型参数 AP 和 fl 随迭代进程自适应动态改变以调控算法的全局搜索性能和局部开采能力;通过引入随迭代稳定性改变的加权学习因子以实现子代乌鸦同时向多个体(即被跟随乌鸦和当前最优乌鸦)选择性继承位置信息并生成新子代种群,有利于保证较好的新群体多样性和算法迭代搜索性能.鉴于历代最优解的不同变量维度可能差异较大且往往逼近于全局最优解邻域的不同分量,提出一种基于邻代最优解维度交叉策略思想的最优个体位置更新策略以概率性保留不同维度的历史最优信息并增强算法的局部极值逃逸能力,实验结果分别从不同角度验证了改进策略的有效性和 IC-SA 算法的优越寻优性能.

2 乌鸦搜索算法(CSA)

CSA 算法^[12]是学者 Askarzadeh 启发于乌鸦食物寻觅行为而提出的一种基于群体的智能优化算法,其中每只乌鸦均代表问题可行解,通过乌鸦群体在解空间中的并行迭代搜索实现问题的优化求解.

假定 d 维优化问题中乌鸦个体数目为 N ,乌鸦 i 在第 t 次迭代时的位置为 $x^{i,t} = [x_1^{i,t}, x_2^{i,t}, \dots, x_d^{i,t}]$,其中 $i = 1, 2, \dots, N; t = 1, 2, \dots, t_{\max}$ 且 t_{\max} 为最大迭代次数.每只乌鸦均有记忆且能记住当前最优食物源(即食物隐藏地),假设第 t 次迭代时乌鸦 i 的食物源为 $m^{i,t}$.

CSA 算法迭代寻优时,首先在 d 维解空间内随机初始化 N 只乌鸦的初始位置,相应种群可表示为

$$Crows = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_d^1 \\ x_1^2 & x_2^2 & \dots & x_d^2 \\ \vdots & \vdots & \vdots & \vdots \\ x_1^N & x_2^N & \dots & x_d^N \end{bmatrix} \quad (1)$$

由于初始种群没有先验知识,故以 $Crows$ 初始化其记忆 $Memory$.乌鸦通过观察并跟随其他个体更新自身位置.假定第 t 次迭代时乌鸦 j 飞向食物源 $m^{j,t}$,乌鸦 i 跟随之并以概率逼近 $m^{j,t}$,则根据乌鸦 j 是否察觉到被跟踪将有以下两种情形.

情形 1 乌鸦 j 未察觉被跟踪并继续飞向 $m^{j,t}$,则乌鸦 i 将逼近 $m^{j,t}$,故其在 $t+1$ 次迭代时的新位置为

$$x^{i,t+1} = x^{i,t} + r_i \times fl^{i,t} \times (m^{j,t} - x^{i,t}) \quad (2)$$

其中, r_i 为 $[0, 1]$ 区间内的一个随机数, $fl^{i,t}$ 为乌鸦 i 在第 t 次迭代时的飞行长度.

情形 2 乌鸦 j 察觉到被跟踪,则其为保证食物不

被盗取而在搜索空间中随意飞行以诱骗乌鸦 i 飞向解空间中的任意位置。

根据上述描述可知乌鸦 i 的子代新位置为

$$x^{i,t+1} = \begin{cases} x^{i,t} + r_i \times fl^{i,t} \times (m^{i,t} - x^{i,t}), & r_j \geq AP^{i,t} \\ \text{a random position,} & \text{otherwise} \end{cases} \quad (3)$$

其中, $AP^{i,t}$ 为乌鸦 j 第 t 次迭代时的被跟随感知概率。

在乌鸦个体位置更新后,需要检验解的有效性:若新位置位于有效区间内则更新位置,反之则继承父代位置。随后计算子代乌鸦种群中各个体的适应度值(目标函数值) $f(\cdot)$ 并按最小/大优化原则更新记忆:

$$m^{i,t+1} = \begin{cases} x^{i,t+1}, & f(x^{i,t+1}) \text{ is better than } f(m^{i,t}) \\ m^{i,t}, & \text{otherwise} \end{cases} \quad (4)$$

CSA 算法通过两个模型参数—感知概率 AP 和飞行长度 fl 控制算法的全局和局部搜索进程,利用 N 只乌鸦经 t_{\max} 次并行迭代搜索并最终寻得问题最优解。

3 改进乌鸦搜索算法 (ICSA)

3.1 模型参数动态递变规则

由 CSA 算法基本理论可知,CSA 算法的寻优性能是受感知概率 AP 和飞行长度 fl 所控制。由式(3)可知,感知概率 AP 影响乌鸦种群多样性和个体集群化,通过 AP 与随机数 r_j 的比较判断使乌鸦 i 选择性跟随乌鸦 j 向其食物源而导致种群同化或在整个解空间内随机觅食以增强种群多样性;飞行长度 fl 则影响算法的局部与全局搜索性能,通过与 r_i 的综合作用($r_i \times fl$)并与 1 比以逼近或远离乌鸦 j 的食物源而选择性实现算法的全局或局部寻优进程。因此,根据式(3)和概率知识可知:感知概率 AP 值越大,乌鸦 i 将以较大概率进行随机觅食以保证种群多样性,反之则跟随乌鸦 j 促使种群集化和算法收敛;而参数 fl 越大,则乌鸦 i 则以较大概率远离乌鸦 i 食物源以增强算法全局搜索性能,反之则进行局部邻域搜索。

但在传统 CSA 算法中两个模型控制参数 AP 和 fl 均被设定为固定常数,并不利于算法性能的充分发挥。因此,为保证算法优化进程的前期具有较好种群多样性与全局搜索性能以及后期较强局部寻优能力与算法收敛性,模型参数均应遵循的递变规则是:在迭代初期参数值应保持一个相对较大的初值,并随迭代进程趋减小,直到后期逼近于预设最小值。

根据上述递变规则,构造参数 AP 随迭代 t 动态改变的 3 种递变函数分别为

$$\begin{aligned} \text{(i)} \quad AP_{LDF} &= AP_{\max} - t \times \left(\frac{AP_{\max} - AP_{\min}}{t_{\max}} \right) \\ \text{(ii)} \quad AP_{CaDF} &= (AP_{\max} - AP_{\min}) \times \left(1 - \left(\frac{t}{t_{\max}} \right)^\alpha \right)^{1/\alpha} + AP_{\min} \\ \text{(iii)} \quad AP_{CvDF} &= AP_{\max} \times \exp \left(\log \left(\frac{AP_{\min}}{AP_{\max}} \right) \times \frac{t}{t_{\max}} \right) \end{aligned} \quad (5)$$

其中, AP_{\max} 和 AP_{\min} 分别为参数 AP 值的最大和最小值,常数 $\alpha > 1$ 。根据式(5)中参数 AP 的 3 种递减曲线形态,可依次命名为线性下降型 (Linear Descending Form, LDF)、凹形下降型 (Concave Descending Form, CaDF) 和凸形下降型 (Convex Descending Form, CvDF)。参数 fl 也遵循相同递变规则,类比式(5)可定义 3 种 fl 递变函数并简记为 fl^{LDF} 、 fl^{CaDF} 和 fl^{CvDF} 。

3.2 基于多个体的变因子加权学习策略

传统 CSA 算法中,乌鸦种群迭代更新过程是以较大期望向单个体(跟随乌鸦)学习(窃取食物)并更新自身食物位置以实现算法优化寻优性能。单个体学习方式受随机选择个体的质量影响显著同时也会无形中加快乌鸦种群集群化,在一定程度上弱化种群多样性和增加算法陷入局部极值的概率。因此,为保证乌鸦群体较好的种群多样性和算法全局搜索性能,通过引入变因子加权学习机制以保证子代个体同时向多个乌鸦个体学习并更新位置以提高乌鸦群体的个体差异性(即保证种群多样性)。

假定乌鸦在群体交流过程中,能够通过信息交流与共享方式感知上代乌鸦群体的最优位置(食物源);子代乌鸦 i 在跟随乌鸦 j 学习的同时可根据感知的上代最优位置进行潜在食物源的再寻觅并探索发现新食物源。该方式的个体更新策略能够保证子代同时向多乌鸦个体继承位置信息而有利于拓广潜在食物位置的探寻并改善群体多样性,相应数学表达为

$$x^{i,t+1} = \begin{cases} x^{i,t} + r_i(1, d) \times fl^{i,t} \times \delta, & r_j \geq AP^{i,t} \\ \text{a random position,} & \text{otherwise} \end{cases} \quad (6)$$

$$\delta = (\lambda^t m^{i,t} + (1 - \lambda^t) b^{t-1} - x^{i,t})$$

其中, b^{t-1} 为第 $t-1$ 代种群中被感知的最优食物位置, λ^t 为第 t 次迭代时加权学习因子, $r_i(1, d)$ 为 $[0, 1]$ 区间内的 d 维随机向量。图 1 为基于多个体加权学习机制的子代更新示意(以维度 $d=2$ 为例)。

由图 1 可知:加权学习因子 λ 可有效拓展子代群体潜在食物源的搜索域而有利于改善子代种群多样性。为保证乌鸦群体较强的搜索性能, λ 应随迭代进程动态改变:在 t 较小时 λ 值较大以保证子代多向跟随乌鸦继承位置信息,在达到一定迭代次数后 λ 越趋减小以保证子代更多地继承上代最优乌鸦位置。根据 λ 的该递变特性,亦可参照式(5)定义 3 种递减函数,分别记为 λ^{LDF} 、 λ^{CaDF} 和 λ^{CvDF} 。

3.3 基于邻位维度交叉策略的最优个体更新机制

最优乌鸦个体的食物源表示乌鸦群体所寻得的当前最优解,CSA 算法通过 N 只乌鸦并行迭代搜索并最终得到全局最优解。在 CSA 算法迭代寻优过程中,当代最优解(乌鸦)可能只因为某些变量维度离真实最优解相对较远而外显出较差的适应度值,但其他维度却早

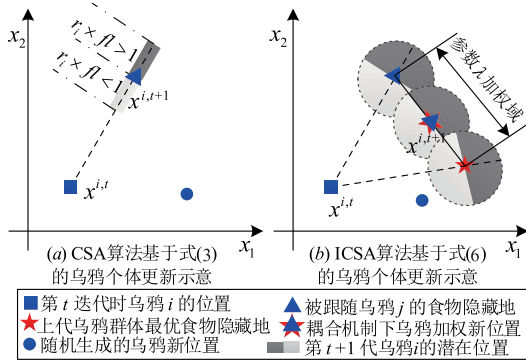


图1 基于多个体加权学习机制的子代更新示意

已落入全局最优解的微小邻域,同时鉴于相邻两代最优解的不同维度分量间可能差异较大且分别落入相应分量的微小邻域.因此,可通过综合历代最优解的不同维度信息来动态改善最优乌鸦的个体质量以增强算法的局部开采性能.

为融合历代最优解的不同维度信息并实现较优分量的最大化有效保留,提出一种基于邻代维度交叉策略的最优个体更新机制,通过邻代最优个体的维度差异性比对并按绝对差异最大优先交叉原则交叉邻代最优解分量,若交叉后其适应度值更优则执行交叉,反之则不交叉.该更新策略的数学化表达为

$$m_{k,h}^{i,t+1} = \begin{cases} m_k^{j,t}, & f(m_{j,Cross}^{i,t}) \text{ is better than } f(m^{i,t}) \\ m_k^{i,iter}, & \text{otherwise} \end{cases} \quad (7)$$

其中, $m_{k,h}^{i,t+1}$ 为 $t+1$ 次迭代时乌鸦 i 的维度 k 交叉 h 次后的位置, $m_{j,Cross}^{i,t}$ 为乌鸦 i 与乌鸦 j 交叉维度 k 后的位置, k 为邻代最优解的维度绝对差异序列中排序 h 大的维度角标(维度差异计算公式为 $\Delta_k = ||m_k^{j,t}| - |m_k^{i,t}||$), $h = 1, 2, \dots, \lfloor R_{Cross} \times d \rfloor$ 为乌鸦 i 执行交叉操作的次数($\lfloor R_{Cross} \times d \rfloor$ 为最大交叉次数, R_{Cross} 为维度交叉比例).图2为邻代最优个体的维度交叉示意(以 $h=4$ 为例).




图2 邻代最优个体的变量维度交叉示意

由图2可知:在邻代最优个体的维度交叉操作时,若维度差异大且交叉后能改善算法优化性能时该维度将被执行交叉并保留(如第5维),反之差异小或交叉后性能未显著改善的维度将被遗弃;而当交叉比例 $R_{Cross} = 1$ 时,历代最优维度均将被保留并蕴含于子代种

群.在一定程度上,该更新策略可有效增强算法的维度纵深挖掘性能和局部极值逃逸能力.

3.4 ICOSA 算法的优化实现

ICOSA 算法优化过程的执行伪码如算法1所示.

算法1 ICOSA 算法优化过程的执行伪码

Algorithm: Improved Crow Search algorithm (ICOSA)

Parameters: N — the number of crows in population;

t_{max} — the maximum number of iterations;

R_{Cross} — the crossover rate of variable dimension;

$\lambda_{max} (\lambda_{min})$ — the maximum (minimum) value of λ ;

$AP_{max} (AP_{min})$ — the maximum (minimum) value of AP ;

$f_{l_{max}} (f_{l_{min}})$ — the maximum (minimum) value of f_l ;

Output: X^* — optima for minimum problems with d -dimension in $[a, b]$.

1: Set $N, t_{max}, R_{Cross}, \lambda_{max}, \lambda_{min}, AP_{max}, AP_{min}, f_{l_{max}}, f_{l_{min}}$

2: //Initialize N initial solutions (position of crows) randomly

3: $x = lb - (lb - ub) \times rand(N, d)$

4: //Calculate fitness of initial crows population and save best position

5: $fit_x = f(x); X_1^* = \arg \min(fit_x)$

6: //Initialize memory and fitness of crows population

7: $m = x; fit_m = fit_x$

8: $t = 1$

9: Repeat

10: //Update parameters AP, f_l, λ iteratively

11: $AP_t = f^{AP}(t); f_{l_t} = f^l(t); \lambda_t = f^\lambda(t)$;

12: //Choose randomly one of crows population to follow (for example j)

13: For $i = 1: N$

14: //Compare AP_t with random number r_j and generate next position of i crow

15: If $r_j \geq AP_t$

16: $x_{new}^{i,t+1} = x^{i,t} + f_{l_t} \times rand(1, d) \times [\lambda_t \times m^{i,t} + (1 - \lambda_t) \times X_t^* - x^{i,t}]$

17: Else

18: $x_{new}^{i,t+1} = lb - (lb - ub) \times rand(1, d)$

19: End If

20: //Calculate fitness of current crows population

21: $fit_{x_{new}^{i,t+1}} = f(x_{new}^{i,t+1})$

22: //Check the feasibility of new positions and update memory of crows

23: If $x_{new,k}^{i,t+1} \in [1, 2, \dots, d] \geq lb$ & $x_{new,k}^{i,t+1} \in [1, 2, \dots, d] \leq ub$

24: $x^{i,t+1} = x_{new}^{i,t+1}$

25: If $fit_{x_{new}^{i,t+1}} < fit_{m^i}$

26: $fit_{m^i} = fit_{x_{new}^{i,t+1}}; m^i = x_{new}^{i,t+1}$;

27: End If

28: End If

29: End For

30: //Update the best solution of current iteration t

31: $X_{t+1}^* = \arg \min(fit_m)$

32: //Crossover variable dimension based on neighbouring two-iteration bests

33: //Calculate and sort dimension absolute difference between solutions

34: $Dif_{k=1,2,\dots,d} = ||X_{k,t+1}^* - X_{k,t}^*||$; $[S_{Dif}, S_{Ind}] = \text{sort}(Dif, 'descend')$;

35: For $Cha_i = 1: \lfloor d \times R_{Cross} \rfloor$

```

36:   termX* = Xt+1*; termX* (SIndChat) ← Xt* (SInd(Chat)); fitterm =
f(termX*);
37:   If fitterm < fit(Xt+1*)
38:     Xt+1* = termX*
39:   End If
40: End For
41: t = t + 1
42: Until t = tmax
43: Return X*

```

4 数值实验

为探究和验证 ICSA 算法的优越寻优性能,共设计 3 组实验:第 1 组实验以 4 组基准测试函数测试参数 AP 和 f_l 的不同函数形式对 CSA 算法的性能影响;第 2 组实验测试不同形式的加权学习因子 λ 对 ICSA 算法的优化性能影响;第 3 组实验以 8 组测试函数和 4 种对比算法来验证改进算法的较好优化性能。

4.1 不同 $AP(f_l)$ 函数对 CSA 性能影响实验

为验证不同 AP 递变函数和 f_l 递变函数对 CSA 算法的优化性能影响,以表 1 中前 4 组基准测试函数进行实验(其中 F1、F2 和 F4 均选自文献[12]),表中 F1 ~ F2 和 F5 ~ F6 为单峰函数以测试算法的局部开采性能和收敛效率等;F3 ~ F4 和 F7 ~ F8 为多峰函数以测验算法的全局探索性能和局部极值规避性等。

在测验不同 AP 函数对 CSA 算法的性能影响时,参数 f_l 设为 2, AP 递变区间为 $[0.05, 0.15]$;在测验 f_l 函数的性能影响时,参数 AP 设为 0.1, f_l 递变区间为 $[1.5, 2.5]$ 。按文献[12]设乌鸦数目 N 和最大迭代次数 t_{\max} 为 20 和 2000、函数维度 d 为 10,各实验组均独立进行 30 次,以 30 次实验统计结果的最优值(Best)、平均值(Mean)和标准差(Std)为评价指标,具体实验统计结果见表 2。

表 1 基准测试函数

函数名	表达式	区间	单 / 多峰	最优值
Sphere	$F_1(x) = \sum_{i=1}^d x_i^2$	$[-100, 100]$	单峰	0
Schwefel	$F_2(x) = \sum_{i=1}^d x_i + \prod_{i=1}^d x_i $	$[-10, 10]$	单峰	0
Alpine	$F_3(x) = \sum_{i=1}^d x_i \sin(x_i) + 0.1x_i $	$[-10, 10]$	多峰	0
Ackley	$F_4(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{30} \sum_{i=1}^d x_i^2}\right) - \exp\left(\frac{1}{30} \sum_{i=1}^d \cos 2\pi x_i\right) + 20 + e$	$[-32, 32]$	多峰	0
Step	$F_5(x) = \sum_{i=1}^d (x_i + 0.5)^2$	$[-100, 100]$	单峰	0
HCE	$F_6(x) = \sum_{i=1}^d (10^6)^{\frac{i-1}{d-1}} x_i^2$	$[-100, 100]$	单峰	0
Penalized1	$F_7(x) = \frac{\pi}{d} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^{d-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_d - 1)^2 \right\}$ $+ \sum_{i=1}^d \mu(x_i, 10, 100, 4), y_i = 1 + \frac{x_i + 1}{4}, \mu(x_i, a, k, m) = \begin{cases} k(x_i - a)^m, & x_i > a \\ 0, & -a < x_i < a \\ k(-x_i - a)^m, & x_i < -a \end{cases}$	$[-50, 50]$	多峰	0
Penalized2	$F_8(x) = 0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^d (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] \right.$ $\left. + (x_d - 1)^2 [1 + \sin^2(2\pi x_N)] \right\} + \sum_{i=1}^d \mu(x_i, 5, 100, 4)$	$[-50, 50]$	多峰	0

注:HCE表示 High Conditioned Elliptic 函数。

表 2 模型参数(AP 和 f_l)对 CSA 算法的性能影响

F	Index	(a) 参数 AP 的影响效果				(b) 参数 f_l 的影响效果			
		CSA	AP^{LDF}	AP^{CaDF}	AP^{CuDF}	CSA	f_l^{LDF}	f_l^{CaDF}	f_l^{CuDF}
F1	Best	<u>9.54E-13</u>	1.90E-14	1.18E-11	2.80E-15	<u>9.54E-13</u>	7.36E-13	8.01E-12	2.07E-13
	Mean	<u>4.09E-11</u>	9.20E-12	1.47E-10	7.60E-13	<u>4.09E-11</u>	1.80E-11	1.74E-10	9.61E-12
	Std	<u>6.17E-11</u>	3.13E-11	1.43E-10	1.03E-12	<u>6.17E-11</u>	2.53E-11	2.13E-10	8.88E-12
F2	Best	<u>9.37E-6</u>	2.92E-6	8.68E-6	6.19E-7	<u>9.37E-6</u>	2.83E-6	5.51E-6	2.00E-6
	Mean	<u>6.27E-3</u>	2.73E-2	1.97E-2	1.64E-2	<u>6.27E-3</u>	1.03E-2	3.47E-3	8.22E-3
	Std	<u>1.99E-2</u>	7.65E-2	6.88E-2	4.87E-2	<u>1.99E-2</u>	3.25E-2	1.78E-2	2.24E-2
F3	Best	<u>3.10E-6</u>	2.03E-7	6.38E-7	5.00E-8	3.10E-6	6.38E-7	2.94E-6	7.51E-8
	Mean	<u>3.56E-2</u>	1.56E-2	3.49E-2	1.46E-2	3.56E-2	3.30E-2	3.18E-2	3.72E-2
	Std	<u>6.40E-2</u>	3.00E-2	6.92E-2	2.64E-2	6.40E-2	6.00E-2	8.59E-2	1.16E-1
F4	Best	<u>1.02E-6</u>	3.64E-7	1.51E-6	1.44E-7	<u>1.02E-6</u>	6.34E-7	2.25E-6	2.29E-7
	Mean	<u>1.90</u>	1.84	1.77	1.66	<u>1.9</u>	1.42	1.49	1.38
	Std	<u>7.90E-1</u>	9.23E-1	9.34E-1	8.06E-1	<u>7.90E-01</u>	1.22	9.81E-01	8.94E-1

注:以“下划线”表示的结果直接引自文献[12].

由表 2(a) 分析可知:在相同 AP 递变区间和 f_l 值设定情形下,不同 AP 递变形式对 CSA 算法的性能影响有所差异,其中以 AP^{CuDF} 型对 CSA 算法性能改善相对优异,在 9/12 性能指标上优于传统 CSA 算法和其他函数形式,在一定程度上表明参数 AP 随迭代步 t 的动态迭代能改善 CSA 算法优化性能.由表 2(b) 可得类似结论,在相同 f_l 递变区间和 AP 值设定情形下,不同 f_l 函数对 CSA 算法寻优性能亦不同,以 f_l^{CuDF} 型较优 f_l^{LDF} 型次之, f_l^{CaDF} 型的 CSA 算法性能提高最小但在绝大多数指标上仍略优于传统 CSA 算法.

综合分析可知:模型参数 AP 和 f_l 对 CSA 算法有一定的性能影响,适当参数修正可在一定程度上改善算法的优化性能,且参数 AP 的性能改善效果略优于 f_l ,表明感知概率 AP 较 f_l 对 CSA 算法具有相对显著的性能影响.

4.2 不同 λ 递变函数对 ICESA 性能影响实验

为验证不同 λ 递变函数对 ICESA 算法的性能影响,以 4.1 节 4 组测试函数进行实验,相关参数设置和评价指标同 4.1 节,其中参数 AP 和 f_l 均采用 $CuDF$ 型, λ 有效区间为 $[0.05, 0.95]$, 维度交叉比例 R_{Cross} 为 0.3. 各实验组均独立运行 30 次,统计结果见表 3.

由表 3 分析可知,在相同 λ 区间和其他参数设置条件下,不同 λ 递变形式影响 ICESA 算法的优化性能: λ^{CuDF} 型 ICESA 算法性能显著优于 CSA 算法数个甚至至十多个数量级,表明该型改进算法具有较强的寻优性能; 3 种基于加权学习因子 λ 的 ICESA 算法在 Mean 指标与 Best 指标间数量级跨度较小,证明 ICESA 算法在 30 次独立实验中性能表现均较为优异且稳定,有利于在未知

先验知识情境下对工程优化问题的可靠解决,避免反复实验并筛选最优解过程中所造成的时间和人力物力资源浪费等,较小 Std 指标则更进一步有效佐证了改进算法的较好稳健性.上述分析充分证明了基于变因子加权学习与邻代维度交叉耦合策略对 CSA 算法性能改善的有效性和可行性.

表 3 加权学习因子 λ 对 ICESA 算法的性能影响

F	Index	CSA	λ^{LDF}	λ^{CaDF}	λ^{CuDF}
F1	Best	<u>9.54E-13</u>	2.77E-25	7.96E-22	1.27E-28
	Mean	<u>4.09E-11</u>	1.46E-21	9.86E-19	5.64E-23
	Std	<u>6.17E-11</u>	3.31E-21	3.84E-18	1.80E-22
F2	Best	<u>9.37E-6</u>	6.36E-14	1.90E-12	7.72E-15
	Mean	<u>6.27E-3</u>	6.95E-12	7.49E-11	1.24E-12
	Std	<u>1.99E-2</u>	1.57E-11	1.17E-10	2.03E-12
F3	Best	3.10E-6	1.54E-14	3.82E-13	3.23E-15
	Mean	3.56E-2	5.32E-8	2.56E-5	1.91E-9
	Std	6.40E-2	2.91E-7	1.40E-4	1.04E-8
F4	Best	<u>1.02E-6</u>	1.29E-13	4.51E-12	3.64E-14
	Mean	<u>1.9</u>	7.14E-12	1.46E-10	8.84E-13
	Std	<u>7.90E-1</u>	1.20E-11	2.43E-10	1.03E-12

注:以“下划线”表示的结果直接引自文献[12].

4.3 不同智能算法的对比实验

为验证 ICESA 算法的优越寻优性能,以 MVO 算法^[9]、SGA 算法^[10]、ALO 算法^[11] 和传统 CSA 算法^[12] 作为对比算法,以表 1 中 8 组函数作为实验函数.鉴于 4.1 节和 4.2 节中的分析结果,ICESA 算法的参数 AP 、 f_l 和 λ 均采用 $CuDF$ 型,故简记该改进算法为 C^4SA .

实验中各算法的群体规模 N 和最大迭代次数 t_{\max} 均设为 50 和 5000, MVO 算法^[9] 的虫洞存在概率 $WEP \in [0.2, 1]$, SGA 算法^[10] 的 α 初始值 α_0 和最小值 α_{\min} 分别为 2 和 0.01、群组突变个体数 $n_{mut} = 5$ 、搜索群组比为 0.1、全局搜索占比为 0.3, C^4SA 的其他相关参数设置同 4.1 节和 4.2 节, 8 组测试函数的维度 d 均为 30. 各实验组均独立运行 30 次并记录其最优目标值, 以统计结果的 Best、Mean、Std、Worst (最差值) 为评价指标, 具体实验统计结果见表 4.

由表 4 分析可知:

(1) C^4SA 算法对 8 组测试函数的统计结果明显优越于其他 4 种对比算法, 在相同寻优条件下, C^4SA 的 4 项评价指标均优于其他算法数个甚至数十个数量级, 证明改进算法具有较强的优化性能; 最优 Best 指标表明改进算法能有效探索搜索空间并保证较强的全局寻优性能, 最优 Mean 指标说明 C^4SA 算法在 30 独立实验中保持较高的整体寻优水平并隐含着算法拥有较好的单次寻优精度, 最优 Std 指标证明了改进算法的较强寻优稳定性和鲁棒性且 Best 与 Worst 指标间的较小数值差异亦进一步证实了该结论, 最小 Worst 指标则验证了 C^4SA 算法即使在最差寻优情形下也保持较高的优化精度且显著优于其他对比算法的 Best 值, 有利于其对未知最优解的工程优化问题实现较好寻优并能寻得相对更优解.

(2) 在相同测试约束条件下, 改进算法在单/多峰函数寻优过程中均表现出较高优化精度, 表明 C^4SA 算法具有较强的局部开采性能和较好收敛精度, 特别是对 4 组多峰函数仍保持较高优化目标值, 验证了算法的较好全局探索性能和较强局部极值规避能力.

(3) 算法若以目标值寻优精度为评价指标, 则该预设精度阈值可高达 $1.0E-12$ 并在 7/8 测试函数 (除 F3) 中实现 100% 的成功寻优, 特别是函数 F1、F5、F7 和 F8 的阈值甚至可在保证寻优成功率的前提下松弛到 $1.0E-25$, 而该精度能有效满足工程问题的误差容许范围, 更进一步佐证 C^4SA 算法在工程优化问题中的较好应用潜能.

为进一步直观描绘 5 种算法的迭代进程差异, 以各实验组在 30 次实验 5000 次迭代的逐代平均精度绘制平均迭代寻优对比曲线见图 3.

由图 3 分析可知, 不同算法对 8 组测试函数的平均迭代优化进程各不相同且寻优态势也各有差异. 在平均迭代寻优前期, C^4SA 算法梯度下降较为缓慢以保证其较好的全局探索能力, 并在一定程度上减小陷入局部极值的可能性. 在一定迭代步后, 改进算法捕获并落入最优解的微小邻域且寻优速率显著加快, 对局部邻域进行纵深挖掘并越趋逼近于全局最优解. 在最大迭

表 4 5 种算法对 8 组测试函数的统计结果对比

F		Best	Mean	Std	Worst
F1	MVO	3.30E-03	6.65E-03	1.96E-03	1.06E-02
	SGA	1.05E-04	1.76E-04	5.57E-05	3.76E-04
	ALO	8.53E-09	1.25E-08	2.06E-09	1.62E-08
	CSA	6.30E-12	2.70E-11	1.77E-11	8.54E-11
	C^4SA	2.45E-31	1.26E-27	4.67E-27	2.58E-26
F2	MVO	2.76E-02	5.58E-02	1.76E-02	9.90E-02
	SGA	4.55E-03	7.09E-03	1.49E-03	1.10E-02
	ALO	4.12E-04	3.95	3	1.09E+01
	CSA	6.27E-02	4.99E-01	2.84E-01	1.14
	C^4SA	2.39E-15	4.19E-14	5.90E-14	2.88E-13
F3	MVO	3.66E-03	7.32E-03	1.79E-03	1.19E-02
	SGA	8.88E-05	1.77E-04	6.47E-05	3.63E-04
	ALO	8.95E-09	1.18E-08	2.57E-09	1.67E-08
	CSA	6.68E-12	2.86E-11	1.35E-11	5.95E-11
	C^4SA	6.70E-30	2.76E-27	7.47E-27	3.05E-26
F4	MVO	7.86E+05	1.87E+06	7.29E+05	3.81E+06
	SGA	7.36E+04	2.80E+05	1.11E+05	5.08E+05
	ALO	2.51E+05	5.31E+05	1.98E+05	9.55E+05
	CSA	7.92E+03	2.86E+04	1.36E+04	6.47E+04
	C^4SA	2.13E-26	1.47E-21	5.13E-21	2.77E-20
F5	MVO	2.89E-01	1.64	1.1	3.72
	SGA	2.05E-02	6.02E-02	2.57E-02	1.27E-01
	ALO	9.91E-01	3.62	2.54	1.05E+01
	CSA	2.96E-03	2.43E-02	3.08E-02	1.16E-01
	C^4SA	7.46E-15	1.58E-08	5.73E-08	2.77E-07
F6	MVO	1.55E-02	1.45E-01	3.86E-01	1.5
	SGA	2.30E-03	3.19E-03	5.78E-04	4.67E-03
	ALO	2.73E-05	1.82	8.74E-01	2.96
	CSA	2.96E-06	3.19	1.08	5.19
	C^4SA	5.06E-14	9.69E-14	2.97E-14	1.86E-13
F7	MVO	2.14E-05	2.29E-01	5.18E-01	2.2
	SGA	8.37E-07	3.46E-02	9.96E-02	5.19E-01
	ALO	5.42E-01	4.83	3.34	1.41E+01
	CSA	1.51E-09	8.22E-01	1.06	3.38
	C^4SA	2.65E-32	2.47E-30	6.29E-30	3.50E-29
F8	MVO	2.84E-04	3.75E-03	4.97E-03	1.26E-02
	SGA	1.14E-05	1.13E-03	3.36E-03	1.10E-02
	ALO	4.11E-10	4.39E-03	5.47E-03	1.10E-02
	CSA	9.63E-11	2.28E-02	4.30E-02	1.95E-01
	C^4SA	9.98E-32	4.25E-29	7.84E-29	3.29E-28

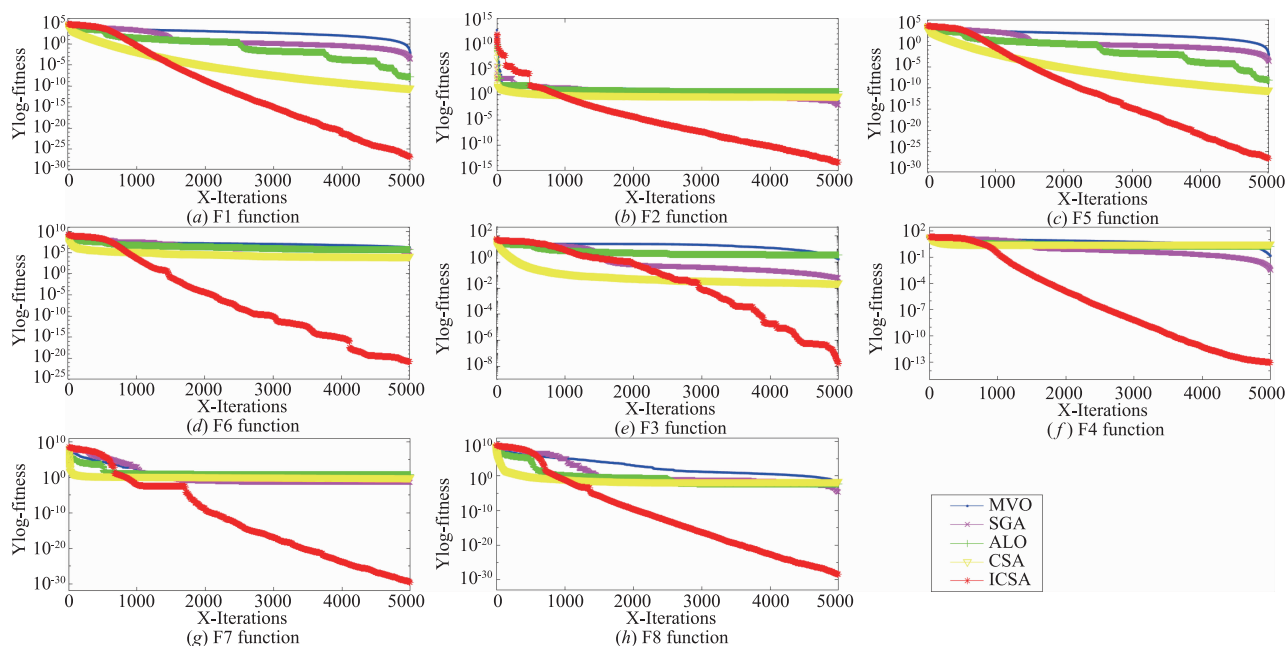


图3 5种算法的平均迭代寻优对比曲线

代次数 t_{\max} 处, C^4SA 算法的寻优精度明显优于其他 4 种对比算法并保有持续梯度寻优趋势, 而对比算法则表象性地趋于收敛但实际已陷入“伪全局最优解”邻域而丧失逃逸能力, 特别是对函数 F2、F6、F4 和 F7, 4 种对比算法在 $0.2t_{\max}$ 后几乎均陷入了局部极值邻域而无法逃逸. 改进算法则以“间断跳跃”式(即曲线波折点处)在 30 次独立实验中表现出较好的整体协同性并跳出局部极值邻域以继续迭代寻优, C^4SA 算法较对比算法有更多寻优断点表明改进算法具有更好的局部极值逃逸性能、跳跃式快速搜索能力和整体寻优同步性.

综上所述:改进 CSA 算法具有较强的迭代优化性能并可有效改善对高维函数的寻优精度和算法稳健性, 实验测试中其表现出较强的全局探索与局部搜索能力、较好的局部极值逃逸性能和整体寻优协同性, 验证了改进 CSA 算法的优越寻优性能.

5 结论

为提高 CSA 算法的全局寻优精度和算法稳定性, 动态修正模型参数感知概率 AP 和飞行长度 fl , 通过耦合多个体变因子加权学习机制与最优个体邻代维度交叉策略提出一种改进 CSA 算法(ICSA). 实验结果表明: 适应模型参数对 CSA 性能改善有一定影响且以感知概率 AP 的影响效果更显著、不同形式的加权因子对 ICSA 算法的性能改善有所差异且以 C^4DF 型改进算法表现最优异, ICSA 算法相较于 4 种对比算法在寻优精度、局部极值逃逸性和算法稳定性等方面均有显著提高且有效验证了改进算法的优越寻优性能和耦合策略


的有效性和可行性. 下一步研究重点是 CSA 算法对多目标、离散多约束工程优化问题的拓展应用或融入其他智能算法的特定算子以构造新的优化算法.

参考文献

- [1] ZHANG Y, LIU S, ZHANG X. An optimized supply chain network model based on modified genetic algorithm [J]. Chinese Journal of Electronics, 2017, 26(3): 468–476.
- [2] XUAN H, ZHANG R, SHI S. An efficient cuckoo search algorithm for system-level fault diagnosis [J]. Chinese Journal of Electronics, 2016, 25(6): 999–1004.
- [3] ZHANG L, LIU M, HAO J, et al. Scheduling semiconductor wafer fabrication using a new harmony search algorithm based on receipt priority interval [J]. Chinese Journal of Electronics, 2016, 25(5): 866–872.
- [4] HOLLAND J. Genetic algorithms [J]. Scientific American, 1992, 267: 66–72.
- [5] FOGEL D. Artificial intelligence through simulated evolution [A]. Proceedings of National Conference on Emerging Trends & Applications in Computer Science [C]. USA: Wiley-IEEE Press, 1966. 227–296.
- [6] KENNEDY J, EBERHART R. Particle swarm optimization [A]. Proceedings of IEEE International Conference on Neural Networks (Vol. 4) [C]. USA: IEEE, 1995. 1942–1948.
- [7] DORIGO M. Ant Colony Optimization for Vehicle Routing Problem [D]. PhD thesis, Politecnico di Milano, Milan, Italy, 1992.
- [8] KIRKPATRICK S, GELATT C D, VECCHI M P. Optimi-

- zation by simulated annealing [J]. Science, 1983, 220 (4598) :671 – 680.
- [9] MIRJALILI S, MIRJALILI S M, HATAMLOU A. Multi-verse optimizer: A nature-inspired algorithm for global optimization [J]. Neural Computing and Applications, 2016, 27(2) :495 – 513.
- [10] GONCALVES M S, LOPEZ R H, MIGUEL L F F. Search group algorithm: a new metaheuristic method for the optimization of truss structures [J]. Computers & Structures, 2015, 153:165 – 184.
- [11] MIRJALILI S. The ant lion optimizer [J]. Advances in Engineering Software, 2015, 83:80 – 98.
- [12] ASKRZAADEH A. A novel metaheuristic method for solving constrained engineering optimization problems: Crow search algorithm [J]. Computers & Structures, 2016, 169:1 – 12.
- [13] LIU D, LIU C, FU Q, et al. ELM evaluation model of regional groundwater quality based on the crow search algorithm [J]. Ecological Indicators, 2017, 81:302 – 314.
- [14] OLIVA D, HINOJOSA S, CUEVAS E, et al. Cross entropy based thresholding for magnetic resonance brain images using crow search algorithm [J]. Expert Systems with Applications, 2017, 79:164 – 180.

作者简介



赵世杰 男, 1987 年出生, 山东五莲人. 博士, 辽宁工程技术大学讲师. 主要研究领域为人工智能与数据挖掘、优化与管理决策等.
E-mail: zhao2008shijie@126.com

高雷阜 男, 1963 年出生, 辽宁阜新人. 辽宁工程技术大学教授、博士生导师. 主要研究领域为最优化理论与应用、非线性动力系统 etc.
E-mail: gaoleifu@163.com

于冬梅 女, 1986 年出生, 辽宁鞍山人. 博士, 辽宁工程技术大学讲师. 主要研究领域为最优化理论与应用.

徒君 男, 1982 年出生, 安徽全椒人. 博士, 辽宁工程技术大学讲师. 主要研究领域为智能算法、供应链管理等.