

控制与决策

Control and Decision

融合多策略的改进秃鹰搜索算法

郭云川, 张长胜, 段青娜, 罗运河, 程倩, 钱斌, 胡蓉

引用本文:

郭云川,张长胜,段青娜,罗运河,程倩,钱斌,胡蓉. 融合多策略的改进秃鹰搜索算法[J]. *控制与决策*, 2024, 39(1): 69–77.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0211>

您可能感兴趣的其他文章

Articles you may be interested in

[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>

[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>

[基于自适应正态云模型的灰狼优化算法](#)

Grey wolf optimization algorithm based on adaptive normal cloud model
控制与决策. 2021, 36(10): 2562–2568 <https://doi.org/10.13195/j.kzyjc.2020.0233>

[基于解空间反向跳跃和信息交互强化的新型混合蛙跳算法](#)

A new shuffled frog leaping algorithm based on reverse leaping in solution space and information interaction enhancement
控制与决策. 2021, 36(1): 105–114 <https://doi.org/10.13195/j.kzyjc.2019.0719>

[求解约束优化问题的改进果蝇优化算法及其工程应用](#)

Improved fruit fly optimization algorithm for solving constrained optimization problems and engineering applications
控制与决策. 2021, 36(2): 314–324 <https://doi.org/10.13195/j.kzyjc.2019.0557>

融合多策略的改进秃鹰搜索算法

郭云川¹, 张长胜^{1†}, 段青娜², 罗运河², 程倩², 钱斌¹, 胡蓉¹

(1. 昆明理工大学信息工程与自动化学院, 昆明 650500;

2. 红云红河烟草(集团)有限责任公司, 昆明 650202)

摘要: 针对秃鹰搜索算法(BES)存在全局搜索性能与局部开发能力不协调、易陷入局部最优等缺陷, 提出一种融合多策略的改进秃鹰搜索算法(IBES). 采用凸型自适应控制因子使算法在迭代寻优过程中可根据搜索进程动态调整位置更新方程以修正模型, 实现自适应寻优, 有效平衡算法的全局搜索性能和局部开发能力; 引入折射反向学习机制可对问题当前解在其解空间内进行折射反向学习找到与之对应的折射反向解, 增加寻到最优解的概率, 提升算法求解精度和收敛速度; 同时, 利用定向重组与诱导突变策略实现种群个体多维信息的重组和突变, 提升个体质量和种群多样性, 增加算法跳出局部最优的机率, 提高搜索精度. 以最优值、平均值、标准差和平均收敛代数作为算法性能的评价指标, 对 10 个不同基准测试函数进行数值仿真实验, 实验结果验证了所提改进方法的有效性及其 IBES 算法的优越性. 此外, 经 IBES 算法优化后的 PID 神经网络控制器响应速度快、超调量小、调节时间短, 进一步验证了算法的实用性.

关键词: 秃鹰搜索算法; 凸型自适应控制因子; 折射反向学习机制; 定向重组与诱导突变策略; PID 神经网络控制器

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0211

引用格式: 郭云川, 张长胜, 段青娜, 等. 融合多策略的改进秃鹰搜索算法[J]. 控制与决策, 2024, 39(1): 69-77.

Improved bald eagle search algorithm fused with multiple strategies

GUO Yun-chuan¹, ZHANG Chang-sheng^{1†}, DUAN Qing-na², LUO Yun-he², CHENG Qian², QIAN Bin¹, HU Rong¹

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China; 2. Hongyun Honghe Tobacco (Group) Co., Ltd., Kunming 650202, China)

Abstract: An improved bald eagle search algorithm fused with multiple strategies (IBES) is proposed to address the shortcomings of the bald eagle search algorithm (BES), such as the global search performance is not coordinated with the local exploitation capability and it is easy to fall into local optimum. The use of convex adaptive control factors enables the algorithm to dynamically adjust the position update equations to modify the model according to the search process during the iterative optimization, thus achieving adaptive optimization and effectively balancing the global search performance and local exploitation capability of the algorithm. The refracted opposition-based learning mechanism is used to discover the corresponding solution by refracting the current solution of the problem in its solution space, which increases the probability of finding the optimal solution and improves the solution accuracy and convergence speed of the algorithm. At the same time, the directional recombination and induced mutation strategy is used to achieve the recombination and mutation of the multi-dimensional information of population individuals, improve the individual quality and population diversity, increase the probability of the algorithm escaping from local optimum, and raise the searching precision. The optimal value, mean value, standard deviation and average convergence algebra are used as evaluation indexes of the algorithm performance, and numerical simulation experiments are conducted for 10 different benchmark test functions. The experimental results verify the effectiveness of the proposed improved method and the superiority of the IBES. In addition, the PID neural network controller optimized by the IBES has a fast response, small overshoot, and short regulation time, which further verifies the practicality of the algorithm.

Keywords: bald eagle search algorithm; convex adaptive control factors; refracted opposition-based learning mechanism; directional recombination and induced mutation strategy; PID neural network controller

收稿日期: 2022-01-30; 录用日期: 2022-07-17.

基金项目: 国家自然科学基金项目(51665025, 61963022).

责任编辑: 夏元清.

[†]通讯作者. E-mail: 122832170@qq.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.

0 引言

图像处理、生产与调度、故障诊断、智能控制等多个领域存在一系列的复杂全局优化问题,因其具有多峰值、高维度等特点,利用传统方法难以解决.元启发式算法结合蒙特卡洛式和启发式寻优的优点,兼顾全局探索性能和局部开发能力,一定时间或精度内能实现对复杂问题最优解的搜寻.因此,对该类算法的研究已成为热点,国内外学者们相继提出了遗传算法(genetic algorithm, GA)^[1]、粒子群优化算法(particle swarm optimization, PSO)^[2]、万有引力搜索算法(gravitational search algorithm, GSA)^[3]、灰狼优化算法(grey wolf optimization, GWO)^[4]、鲸鱼优化算法(whale optimization algorithm, WOA)^[5]、正弦余弦算法(sine cosine algorithm, SCA)^[6]、蝴蝶优化算法(butterfly optimization algorithm, BOA)^[7]、麻雀搜索算法(sparrow search algorithm, SSA)^[8]等元启发式算法.根据搜索机理可将其大致归为3类:第1类基于进化机制产生,如GA算法通过模拟生物进化时染色体中遗传物质进行的选择、交叉和变异等操作迭代更新解集合以确定最优解;第2类是基于物理现象或数学模型提出的,如GSA和SCA算法分别根据万有引力定律、正弦余弦函数完成搜索过程摹仿;第3类基于群体智能实现,如PSO、WOA及BOA算法等,其中最具代表性的PSO算法通过模拟鸟群的捕食行为构建迭代寻优机制搜寻问题最优解.寻优过程中,超参数设置不准确或全局探索与局部开发不平衡将导致算法求解精度低、收敛速度慢、易陷入局部最优等问题,因此,学者们提出了诸多改进思想:1)融合不同优化算法:何庆等^[9]将遗传算法的寻优机制融入模拟退火算法中,糅合各自优势,克服了后者收敛速度慢的缺陷;2)调整关键参数:Long等^[10]对灰狼优化算法的控制参数 a 进行对数自适应衰减,有效协调了算法的全局探索与局部开发,使其搜索性能提高,适应性增强;3)重构位置更新公式:龙文等^[11]针对灰狼优化算法中位置更新方程存在搜索能力弱的问题,通过构造新的更新公式直接影响种群位置更新,使问题得到较完美解决;4)引入新算子:张达敏等^[12]在樽海鞘群算法中引入疯狂算子,丰富种群多样性的同时提高了个体质量,保障了算法的全局搜索能力和求解鲁棒性.

秃鹰搜索算法(bald eagle search, BES)是Alsattar等^[13]通过模拟秃鹰捕食过程中的智能行为提出的一种新型元启发式算法.与其他算法相比,其寻优精度高、收敛速度快,但易陷入局部最优、全局搜索与局部开发不协调等问题仍存在,故本文提出一种融合多策略的改进秃鹰搜索算法(IBES),主要研究内容如下:

1)为使算法前期有丰富种群多样性,后期有较强个体集群化能力,能较好兼顾全局搜索性能和局部寻优能力,BES算法的选择搜索空间阶段采用自适应控制因子;

2)将折射反向学习机制融进算法的搜索空间猎物阶段,增加算法找到问题最优解的概率,提升算法收敛精度和速度;

3)在算法的俯冲捕获猎物阶段加入定向重组与诱导突变策略,保留种群最优维度信息的同时丰富种群多样性,增强算法陷入局部最优时的逃逸能力,提高搜索精度;

4)通过不同的仿真实验验证所提改进方法的有效性及IBES算法的优越性和实用性.

1 秃鹰搜索算法

秃鹰以易获得的高蛋白质小型哺乳动物为食,Alsattar通过模拟其在捕猎时的智能社会行为提出BES算法,它包括选择搜索空间、搜索空间猎物和俯冲捕获猎物3个阶段.在算法搜索寻优过程中,每只秃鹰指代问题的一个可行解,通过对各阶段反复迭代更新解集合,直到迭代结束时,从解集合中输出问题的最优解.

选择搜索空间阶段:秃鹰利用种群最优位置、种群平均位置和个体当前位置作为经验信息选定最佳搜索区域,可用以下方程描述:

$$P_{i,\text{new}} = P_{\text{best}} + \alpha \cdot r(P_{\text{mean}} - P_i). \quad (1)$$

其中: P_{best} 为秃鹰种群确定的最优位置, $\alpha \in [1.5, 2]$ 为控制因子, r 为区间(0,1)内产生的随机数, P_{mean} 为所有秃鹰个体位置的平均值, P_i 为第 i 只秃鹰当前所处位置.

搜索空间猎物阶段:秃鹰在所选定的搜索空间内呈螺旋状飞行,以便确定俯冲捕食猎物的最佳位置,其表达式如下:

$$P_{i,\text{new}} = P_i + x(i) \cdot (P_i - P_{\text{mean}}) + y(i) \cdot (P_i - P_{i+1}); \quad (2)$$

$$x(i) = \frac{xr(i)}{\max(|xr|)}, y(i) = \frac{yr(i)}{\max(|yr|)}; \quad (3)$$

$$xr(i) = r(i) \cdot \sin(\theta(i)), yr(i) = r(i) \cdot \cos(\theta(i)); \quad (4)$$

$$\theta(i) = a \cdot \pi \cdot \text{rand}, r(i) = \theta(i) + R \cdot \text{rand}. \quad (5)$$

其中: $a \in [5, 10]$ 为控制螺旋飞行角度参数, $R \in [0.5, 2]$ 为控制螺旋飞行圈数参数, $\theta(i)$ 和 $r(i)$ 分别为螺旋方程的极角和极径, $xr(i) \in (-1, 1)$ 和 $yr(i) \in (-1, 1)$ 为确定秃鹰的极坐标位置, P_{i+1} 为第 $i+1$ 只秃鹰的当前位置.

俯冲捕获猎物阶段:秃鹰从确定的最佳位置俯

冲捕获猎物,其数学描述为

$$P_{i,new} = \text{rand} \cdot P_{\text{best}} + x_1(i) \cdot (P_i - c_1 \cdot P_{\text{mean}}) + y_1(i) \cdot (P_i - c_2 \cdot P_{\text{best}}); \quad (6)$$

$$x_1(i) = \frac{xr(i)}{\max(|xr|)}, \quad y_1(i) = \frac{yr(i)}{\max(|yr|)}; \quad (7)$$

$$xr(i) = r(i) \cdot \sinh(\theta(i)), \quad yr(i) = r(i) \cdot \cosh(\theta(i)); \quad (8)$$

$$\theta(i) = a \cdot \pi \cdot \text{rand}, \quad r(i) = \theta(i). \quad (9)$$

其中: $c_1 \in [1, 2]$ 和 $c_2 \in [1, 2]$ 为秃鹰俯冲时的运动强度控制参数.

2 融合多策略的改进秃鹰搜索算法

2.1 自适应控制因子

由式(1)可知,在算法的选择搜索空间阶段,寻优性能由控制因子 α 决定,其通过与 r 综合作用 ($\alpha \cdot r$) 影响算法性能.若作用后值较大,则秃鹰朝远离群体方向飞行以增加种群多样性,扩宽搜索范围,保持较好的全局搜索性能;若作用后值较小,则秃鹰往群体所在方向聚集,将导致个体集群化现象,能增强算法局部寻优能力,加快收敛速度.为最大化发挥算法的寻优潜能,BES算法模型应满足:迭代前期有较好种群多样性以保证其全局搜索能力,后期有较强个体集群化能力以保证其局部寻优能力.常规BES算法中, α 被设为固定值,其寻优机制的潜能未被充分发掘,故本文提出自适应控制因子,不仅满足算法前期要求,且随着迭代次数的增加,后期需求也逐步得以实现.

根据所提自适应机制,构造 α 的3种递减函数,分别为:线性递减函数 α_{LDF} 、凹型递减函数 α_{CaDF} 和凸型递减函数 α_{CvDF} ,其解析式如下:

$$\alpha_{\text{LDF}}(t) = \alpha_{\text{max}} - t \cdot \left(\frac{\alpha_{\text{max}} - \alpha_{\text{min}}}{T} \right), \quad (10)$$

$$\alpha_{\text{CaDF}}(t) = \alpha_{\text{min}} + (\alpha_{\text{max}} - \alpha_{\text{min}}) \cdot \exp\left(\log 10^{-4} \cdot \frac{t}{T}\right), \quad (11)$$

$$\alpha_{\text{CvDF}}(t) = \alpha_{\text{max}} - (\alpha_{\text{max}} - \alpha_{\text{min}}) \cdot \left(\frac{t}{T}\right)^8. \quad (12)$$

其中: α_{min} 和 α_{max} 分别为 α 在取值区间 $[1.5, 2]$ 内的最小值和最大值, t 为当前迭代次数, T 为最大迭代次数.

2.2 折射反向学习机制

光从一种介质射入另一种介质时,因其在不同介质的传播速度不同,介质的交界面处光的传播方向发生改变,有学者根据此物理现象提出折射反向学习机制,并利用此机制改进樽海鞘算法、灰狼优化算法等群智能优化算法.如图1所示,该机制通过对问题当前解在解空间内进行折射反向学习找到对应的折射

反向解,增加算法找到问题最优解的概率以改善算法寻优性能.




图1 折射反向学习机制

设图1中: x 轴为不同介质交界面, y 轴为交界面法线, a 和 b 为搜索空间边界, l 、 l^* 分别为入射光线和折射光线,与之对应的 β 、 γ 分别为入射角和折射角,点 x 表示问题的当前解, x^* 表示经过折射学习后找到的候选解.根据折射定律定义有 $n = \sin \beta / \sin \gamma$,由图1中线段的几何关系可知

$$\begin{cases} \sin \beta = ((a+b)/2 - x)/l, \\ \sin \gamma = (x^* - (a+b)/2)/l^*. \end{cases} \quad (13)$$

结合折射定律可得

$$n = \frac{l^*((a+b)/2 - x)}{l(x^* - (a+b)/2)}. \quad (14)$$

令缩放因子 $k = l/l^*$,对式(14)变换后可得

$$x^* = \frac{a+b}{2} + \frac{a+b}{2kn} - \frac{x}{kn}. \quad (15)$$

显然,当 n 、 k 为固定常数时, x^* 为固定值,在搜索空间中的覆盖范围较窄,为增加找到问题最优解的概率,可改变缩放因子 k 使候选解范围动态变化.

2.3 定向重组与诱导突变策略

进化增强了个体极具竞争力的特征,消除劣势特征,定向基因重组和诱导基因突变可使目标生物的遗传性状发生定向改变,加快物种进化速度.受此启发,本文提出定向重组与诱导突变策略以改进BES算法性能.

BES算法通过种群内所有个体并行迭代搜索以寻得全局最优值,种群保留着每只秃鹰历史搜索过程中寻到的最优值.个体包含的所有信息中,部分维度可能已经落入全局最优微小邻域,而另一部分距全局最优邻域较远,导致其适应度差.因不同秃鹰个体落入全局最优微小邻域的维度信息存在差异,将不同维度的优良信息整合到同一个体上,既增强其个体质量,也实现了种群优良基因的最大化保留.受诱导突变原理启发,对秃鹰个体的较弱性状基因进行变异,增大其进化概率,丰富种群的多样性.综上所述,定向重组与诱导突变策略可同时增强算法的局部寻优能力和全局搜索性能,提升寻优精度.

基于定向重组与诱导突变策略的秃鹰个体更新机制为:首先,比较相邻个体的所有维度信息,将信息

的绝对差值进行排序;然后,按差异最大优先原则进行重组,若重组后个体比原个体适应度值好,则进行定向重组操作,否则维持原样,秃鹰个体维度信息的诱导突变操作同理.其数学描述为

$$P_{i,\text{new}} = \begin{cases} P_{i,\text{swap}}^{i+1,k}, & f(P_{i,\text{swap}}^{i+1,k}) \text{ is better than } f(P_i); \\ P_i, & \text{otherwise.} \end{cases} \quad (16)$$

$$k = p \times \text{dim}. \quad (17)$$

$$P_{i,\text{new}} = \begin{cases} P_{i,\text{mutate}}^k, & f(P_{i,\text{mutate}}^k) \text{ is better than } f(P_i); \\ P_i, & \text{otherwise.} \end{cases} \quad (18)$$

$$P_{i,\text{mutate}}^k = P_{\text{best}}^k \times \text{rand}. \quad (19)$$

其中: $P_{i,\text{swap}}^{i+1,k}$ 为第*i*只秃鹰和第*i+1*只秃鹰*k*个维度重组后的位置, dim 为搜索空间维度, k 为重组维度个数, p 为重组率(或突变率), $P_{i,\text{mutate}}^k$ 为诱导第*i*只秃鹰*k*个维度信息突变后的位置.

2.4 IBES算法实现步骤

针对BES算法存在的缺点,本文对算法每一阶段的搜索过程实施了改进,提出了IBES算法,其实现全局寻优的具体过程如下.

step 1: 设置算法相关参数,对种群规模*N*、搜索范围[ub, lb]、空间维度*dim*及最大迭代次数*T*等参数赋值;

step 2: 初始化秃鹰个体位置,在搜索范围内,随机生成一个*N*×*dim*维矩阵,储存种群的位置信息;

step 3: 计算秃鹰种群初始适应度值,根据适应度函数计算出每只秃鹰的适应度值,将其排序后,选出种群中适应度最优的个体记为*P*_{best};

step 4: 选择搜索空间,根据式(1)更新秃鹰种群的位置,控制因子α由自适应递减函数计算得出;

step 5: 搜索空间猎物,按照式(15)对(2)更新出的种群位置进行折射反向学习,找出每只秃鹰对应的折射反向解,以此更新种群位置;

step 6: 俯冲捕获猎物,先根据式(6)计算种群位置,然后按差异最大优先原则对相邻秃鹰个体的维度信息进行重组和变异操作,最后完成种群最优位置*P*_{best}的更新;

step 7: 重复step 4~step 6的迭代过程,满足终止条件时,停止搜索,输出全局最优解.

3 仿真实验与结果分析

3.1 不同α递减函数和*p*值对BES算法性能影响

为验证2.1节中提出的3种不同α递减函数对算法性能的影响,在保证其他参数设置均相同的情况

下,选取表1中的基准测试函数*F*₂、*F*₅和*F*₁₀进行寻优性能测试.设秃鹰种群数目为50,迭代次数为100,维度为30,各组实验独立进行30次,以最优值、平均值和标准差作为评价指标,实验结果见表2.

表1 基准测试函数

函数	类型	维度	搜索区间	最优值
<i>F</i> ₁ Sphere	单峰	30	[-100,100]	0
<i>F</i> ₂ Schwefel 2.22	单峰	30	[-10,10]	0
<i>F</i> ₃ Schwefel 1.2	单峰	30	[-100,100]	0
<i>F</i> ₄ Schwefel 2.21	单峰	30	[-100,100]	0
<i>F</i> ₅ Step	单峰	30	[-100,100]	0
<i>F</i> ₆ Quartic	单峰	30	[-1.28,1.28]	0
<i>F</i> ₇ Rastrigin	多峰	30	[-5.12,5.12]	0
<i>F</i> ₈ Ackley	多峰	30	[-32,32]	0
<i>F</i> ₉ Griewank	多峰	30	[-600,600]	0
<i>F</i> ₁₀ Penalized 1	多峰	30	[-50,50]	0

表2 不同α递减函数对BES性能的影响

函数	指标	α	αLDF	αCaDF	αCvDF
<i>F</i> ₂	最优值	8.97e-288	1.04e-282	1.54e-285	5.50e-287
	平均值	3.28e-261	2.20e-262	6.19e-261	4.10e-263
	标准差	0.00e+00	0.00e+00	0.00e+00	0.00e+00
<i>F</i> ₅	最优值	1.16e-04	6.81e-06	1.72e-05	1.44e-07
	平均值	6.39e-02	1.43e-04	1.42e-04	9.19e-05
	标准差	1.27e-01	1.34e-04	1.01e-04	9.49e-05
<i>F</i> ₁₀	最优值	1.58e-05	9.67e-09	7.17e-07	2.22e-09
	平均值	2.56e-03	1.78e-06	6.22e-04	3.15e-07
	标准差	3.60e-03	3.60e-06	2.89e-04	4.49e-07

注:由于求标准差过程中出现的数值超出本文仿真所用计算机精度范围,表2中出现最优值与平均值不相等,标准差为0的情况.

从表2可以看出,采用自适应α对*F*₂的寻优结果无作用,但对*F*₅和*F*₁₀的搜索精度、收敛速度和稳定性均有改善,凸型递减函数效果最明显,线性递减函数效果次之,凹型递减函数最末.

由2.3节可知,重组率(或突变率)*p*值决定了定向重组与诱导突变策略的有效性,直接影响BES算法改进效果.保证相关参数设置均相同的情况下,对*p*在[0.1,0.5]内以0.05间隔取值进行寻优性能测试实验.基准测试函数选取、参数初始化和算法性能评价指标与表2对应实验相同,实验结果记录在表3中.

如表3所示:*p*值从0.10增加到0.25的过程中,算法对函数*F*₂、*F*₅和*F*₁₀寻优的性能随之提升;当*p*取0.25时,各指标均达到最佳;继续增加*p*值,*F*₂的寻优结果不变,*F*₅和*F*₁₀的寻优结果变差.可见,*p*值过小将无法有效对维度信息实现重组与突变,过大将导致种群多样性过于丰富,算法无法快速收敛,其为0.25时,能够最大化挖掘该策略的潜能.综合来看,定向重组与诱导突变策略改善了秃鹰的个体质量与种群多样性,能够增加算法跳出局部最优的机率,提高搜索

表3 不同 p 值对BES性能的影响

p	F_2			F_5			F_{10}		
	最优值	平均值	标准差	最优值	平均值	标准差	最优值	平均值	标准差
0.00	8.97e-288	3.28e-261	0.00e+00	1.61e-05	6.14e-02	9.51e-02	3.55e-06	3.23e-03	5.01e-03
0.10	1.04e-302	7.36e-274	0.00e+00	1.11e-12	5.15e-06	2.65e-05	2.50e-13	3.27e-07	9.98e-07
0.15	1.54e-313	2.23e-293	0.00e+00	8.04e-14	2.24e-07	1.20e-06	4.12e-14	3.35e-10	1.55e-09
0.20	3.05e-320	2.59e-301	0.00e+00	5.24e-14	5.04e-11	8.49e-10	2.70e-15	6.08e-11	1.95e-10
0.25	0.00e+00	0.00e+00	0.00e+00	4.52e-14	4.11e-11	9.13e-11	1.25e-15	3.27e-11	8.19e-11
0.30	0.00e+00	0.00e+00	0.00e+00	8.24e-14	1.60e-10	5.93e-10	9.07e-15	9.56e-11	9.86e-10
0.35	0.00e+00	0.00e+00	0.00e+00	1.92e-13	3.96e-08	2.07e-07	1.91e-13	8.96e-06	4.82e-05
0.40	0.00e+00	0.00e+00	0.00e+00	7.37e-13	3.26e-07	1.75e-06	1.02e-12	2.01e-07	7.72e-07
0.45	0.00e+00	0.00e+00	0.00e+00	2.63e-12	5.46e-06	2.94e-05	1.82e-12	3.06e-06	1.16e-05
0.50	0.00e+00	0.00e+00	0.00e+00	4.48e-12	5.20e-08	2.78e-07	9.25e-12	1.12e-08	6.89e-08

精度,有效改善算法性能.

3.2 不同改进方法有效性验证分析

本文利用自适应控制因子、折射反向学习机制和定向重组与诱导突变策略对BES算法的3个阶段分别实施改进.为验证改进效果,利用表1中的单峰函数测试算法收敛效率和局部寻优性能,利用多峰函数测试其局部极值规避能力和全局搜索性能,从而进行实验.记采用自适应控制因子的秃鹰算法为ABES,引入折射反向学习机制的秃鹰算法为

RBES,引入定向重组与诱导突变策略的秃鹰算法为DIBES,不同方法两两融合后改进的秃鹰算法分别为ARBES、ADIBES和RDIBES,融入3种方法改进的秃鹰算法为IBES.

本节实验中,控制因子 α 和定向重组与诱导突变策略中 p 值均按3.1节优化,折射反向学习机制中的缩放因子 k 设为从0线性递增至200,算法性能评价指标增加平均收敛代数,测试函数取表1中的 $F_1 \sim F_{10}$,其他条件同3.1节,实验结果见表4.

表4 不同改进方法对BES性能的影响

函数	算法	最优值	平均值	标准差	平均收敛代数	函数	算法	最优值	平均值	标准差	平均收敛代数
F_1	IBES	0.00e+00	0.00e+00	0.00e+00	35	F_6	IBES	8.43e-07	3.43e-05	3.12e-05	—
	BES	0.00e+00	0.00e+00	0.00e+00	63		BES	5.13e-06	1.34e-04	8.14e-05	—
	ABES	0.00e+00	0.00e+00	0.00e+00	63		ABES	1.61e-06	9.69e-05	8.11e-05	—
	RBES	0.00e+00	0.00e+00	0.00e+00	42		RBES	1.27e-06	7.04e-05	4.76e-05	—
	DIBES	0.00e+00	0.00e+00	0.00e+00	48		DIBES	5.62e-06	8.39e-05	6.02e-05	—
	ARBES	0.00e+00	0.00e+00	0.00e+00	43		ARBES	1.79e-06	6.21e-05	5.63e-05	—
	ADIBES	0.00e+00	0.00e+00	0.00e+00	49		ADIBES	3.25e-06	5.92e-05	4.35e-05	—
	RDIBES	0.00e+00	0.00e+00	0.00e+00	37		RDIBES	1.56e-06	4.28e-05	3.72e-05	—
F_2	IBES	0.00e+00	0.00e+00	0.00e+00	70	F_7	IBES	0.00e+00	0.00e+00	0.00e+00	1
	BES	3.23e-288	1.69e-273	0.00e+00	—		BES	0.00e+00	0.00e+00	0.00e+00	3
	ABES	2.85e-283	1.29e-260	0.00e+00	—		ABES	0.00e+00	0.00e+00	0.00e+00	1
	RBES	0.00e+00	0.00e+00	0.00e+00	84		RBES	0.00e+00	0.00e+00	0.00e+00	1
	DIBES	0.00e+00	0.00e+00	0.00e+00	94		DIBES	0.00e+00	0.00e+00	0.00e+00	1
	ARBES	0.00e+00	0.00e+00	0.00e+00	83		ARBES	0.00e+00	0.00e+00	0.00e+00	1
	ADIBES	0.00e+00	0.00e+00	0.00e+00	97		ADIBES	0.00e+00	0.00e+00	0.00e+00	1
	RDIBES	0.00e+00	0.00e+00	0.00e+00	72		RDIBES	0.00e+00	0.00e+00	0.00e+00	1
F_3	IBES	0.00e+00	0.00e+00	0.00e+00	37	F_8	IBES	8.88e-16	8.88e-16	0.00e+00	—
	BES	0.00e+00	0.00e+00	0.00e+00	65		BES	8.88e-16	8.88e-16	0.00e+00	—
	ABES	0.00e+00	0.00e+00	0.00e+00	62		ABES	8.88e-16	8.88e-16	0.00e+00	—
	RBES	0.00e+00	0.00e+00	0.00e+00	41		RBES	8.88e-16	8.88e-16	0.00e+00	—
	DIBES	0.00e+00	0.00e+00	0.00e+00	55		DIBES	8.88e-16	8.88e-16	0.00e+00	—
	ARBES	0.00e+00	0.00e+00	0.00e+00	43		ARBES	8.88e-16	8.88e-16	0.00e+00	—
	ADIBES	0.00e+00	0.00e+00	0.00e+00	53		ADIBES	8.88e-16	8.88e-16	0.00e+00	—
	RDIBES	0.00e+00	0.00e+00	0.00e+00	38		RDIBES	8.88e-16	8.88e-16	0.00e+00	—
F_4	IBES	0.00e+00	0.00e+00	0.00e+00	73	F_9	IBES	0.00e+00	0.00e+00	0.00e+00	1
	BES	1.56e-287	1.65e-261	0.00e+00	—		BES	0.00e+00	0.00e+00	0.00e+00	3
	ABES	1.02e-291	1.61e-258	0.00e+00	—		ABES	0.00e+00	0.00e+00	0.00e+00	1
	RBES	0.00e+00	0.00e+00	0.00e+00	88		RBES	0.00e+00	0.00e+00	0.00e+00	1
	DIBES	0.00e+00	0.00e+00	0.00e+00	96		DIBES	0.00e+00	0.00e+00	0.00e+00	1
	ARBES	0.00e+00	0.00e+00	0.00e+00	85		ARBES	0.00e+00	0.00e+00	0.00e+00	1
	ADIBES	0.00e+00	0.00e+00	0.00e+00	98		ADIBES	0.00e+00	0.00e+00	0.00e+00	1
	RDIBES	0.00e+00	0.00e+00	0.00e+00	74		RDIBES	0.00e+00	0.00e+00	0.00e+00	1
F_5	IBES	4.39e-16	1.29e-14	2.35e-14	—	F_{10}	IBES	3.13e-17	2.32e-15	3.80e-15	—
	BES	4.32e-05	7.22e-02	9.79e-02	—		BES	2.18e-06	1.73e-03	3.17e-03	—
	ABES	2.16e-07	1.94e-05	3.57e-05	—		ABES	4.64e-09	3.71e-06	1.84e-05	—
	RBES	1.14e-04	4.46e-02	9.50e-02	—		RBES	1.15e-06	7.99e-04	1.53e-03	—
	DIBES	5.24e-14	1.90e-11	4.07e-11	—		DIBES	1.39e-14	4.02e-10	2.12e-09	—
	ARBES	3.18e-07	2.94e-05	7.97e-05	—		ARBES	4.48e-09	3.65e-07	7.22e-07	—
	ADIBES	1.01e-15	3.03e-14	3.98e-14	—		ADIBES	2.06e-16	2.52e-12	1.35e-11	—
	RDIBES	5.99e-14	1.02e-10	5.05e-10	—		RDIBES	1.40e-14	4.23e-11	1.86e-10	—

表4中:最优值暗含算法在搜索空间内寻到理论最优值的潜力;平均值表明算法整体的寻优性能;标准差表现了最优值的离散程度,体现算法的稳定性和鲁棒性;平均收敛代数指算法搜索到理论最优值时的迭代次数,表征算法收敛速度和精度.

表4中的数据表明: BES第1阶段采用自适应控制因子,即ABES寻优,对 $F_1 \sim F_4$ 的搜索结果无影响;对 F_5 求解的最优值提升2个量级,平均值和标准差均提升3个量级;对 F_6 影响较小,在最优值和平均值上有微小改善;对于 F_7 和 F_9 ,在第1次迭代搜索中便能得到其理论最优值,算法寻优性能已至最佳;对 F_{10} 寻优的改善较为显著,在最优值、平均值和标准差上分别提升了3、3、2个量级.第2阶段引入折射反向学习机制,即RBES寻优,对 $F_1 \sim F_4$ 的搜索结果影响较大,原先对 F_1 和 F_3 平均迭代65次左右找到理论最优值,对 F_2 和 F_4 在100次迭代搜索中寻不到理论最优值,而融入该机制后,算法对 F_1 和 F_3 寻优的平均收敛代数缩小至40代左右,对 F_2 和 F_4 迭代85次左右便能搜索到理论最优值;此机制对其余函数的寻优结果影响较小.第3阶段引入定向重组与诱导突变策略,即DIBES寻优,对 F_1 搜索的平均收敛代数从63缩减为48,对 F_3 从65缩减到55,对 F_2 和 F_4 从100次迭代不收敛优化为94代和96代收敛;对 F_6 、 F_7 和 F_9 的寻优结果也有一定程度改善,在 F_6 上求解到的平均值有微小提升,在 F_7 和 F_9 上,算法寻优性能已至最佳;对 F_5 和 F_{10} 的寻优结果提升显著,其中对 F_5 寻得的最优值、平均值和标准差均提升9个量级, F_{10}

对应的评价指标分别提升8个、7个和6个量级.采用ARBES、ADIBES、RDIBES和IBES寻优,它们融合两种以上单一改进方法优势,寻优效果比ABES、RBES及DIBES更明显.其中IBES最优越,几乎每个指标都好于其他算法.

综上,本文所提3种改进思想对提升BES算法的寻优性能均起到一定作用,各自适用于不同函数.自适应控制因子和折射反向学习机制改善了算法对部分函数的寻优结果,定向重组与诱导突变策略改善了算法对全部函数的寻优结果,利用各改进方法间的耦合作用,可进一步提升算法寻优性能,IBES算法融合了全部改进方法的优势,表现出良好的搜索性能.

3.3 IBES算法优越性验证分析

3.3.1 IBES算法与经典智能优化算法对比

选取PSO、GWO、WOA、SCA、BOA、SSA及BES算法作为参照,对比验证IBES的优越性.实验中各算法的共有参数保持一致,非共有参数按表5设置,基准测试函数的选取及算法性能评价指标同3.2节,实验结果见表6.

表5 各算法非共有参数设置

算法	主要参数		
IBES	α 从2凸型递减至1.5	$p = 0.25$	k 从0线性递增至200
BES	$\alpha = 1.5$	—	—
GWO	a 从2线性递减至0	—	—
SSA	$p_{\text{Num}} = 0.2 \times \text{种群数}$	$R_2 = 0.8$	$s_{\text{Num}} = 0.2 \times \text{种群数}$
PSO	$c_1 = 1.5$	$c_2 = 1.5$	w 从0.9线性递减至0.4
SCA	$a = 2$	—	—
WOA	a 从2线性递减至0	—	—
BOA	$p = 0.8$	$c = 0.01$	$a = 0.1$

表6 IBES与经典智能优化算法寻优结果比较

函数	算法	最优值	平均值	标准差	平均收敛代数	函数	算法	最优值	平均值	标准差	平均收敛代数
F_1	IBES	0.00e+00	0.00e+00	0.00e+00	36	F_6	IBES	2.50e-07	4.72e-05	3.92e-05	—
	BES	0.00e+00	0.00e+00	0.00e+00	61		BES	3.32e-06	1.23e-04	1.25e-04	—
	GWO	2.00e-04	8.54e-04	4.63e-04	—		GWO	3.27e-03	9.40e-03	3.03e-03	—
	SSA	0.00e+00	1.28e-55	6.89e-55	—		SSA	8.81e-05	1.15e-03	1.04e-03	—
	PSO	3.60e-01	7.39e-01	3.42e-01	—		PSO	6.15e-01	3.35e+00	2.19e+00	—
	SCA	1.50e+02	3.11e+03	3.25e+03	—		SCA	4.23e-01	3.76e+00	4.46e+00	—
	WOA	1.14e-17	2.02e-14	4.06e-14	—		WOA	1.30e-05	1.55e-02	1.95e-02	—
	BOA	1.18e-05	1.55e-05	1.93e-06	—		BOA	3.06e-03	5.36e-03	2.22e-03	—
F_2	IBES	0.00e+00	0.00e+00	0.00e+00	72	F_7	IBES	0.00e+00	0.00e+00	0.00e+00	1
	BES	3.19e-294	3.06e-260	0.00e+00	—		BES	0.00e+00	0.00e+00	0.00e+00	3
	GWO	1.29e-03	5.41e-03	2.15e-03	—		GWO	5.82e+00	2.65e+01	2.39e+01	—
	SSA	0.00e+00	2.68e-33	9.99e-33	—		SSA	0.00e+00	0.00e+00	0.00e+00	20
	PSO	3.26e+00	4.87e+00	1.02e+00	—		PSO	4.00e+01	6.59e+01	1.77e+01	—
	SCA	8.41e-01	4.28e+00	2.20e+00	—		SCA	1.49e+01	1.45e+02	5.92e+01	—
	WOA	6.27e-12	4.67e-10	8.61e-10	—		WOA	0.00e+00	4.07e+00	2.19e+01	—
	BOA	2.23e-04	5.60e-04	1.06e-04	—		BOA	1.25e-05	3.14e+00	1.69e+01	—
F_3	IBES	0.00e+00	0.00e+00	0.00e+00	41	F_8	IBES	8.88e-16	8.88e-16	0.00e+00	—
	BES	0.00e+00	0.00e+00	0.00e+00	64		BES	8.88e-16	8.88e-16	0.00e+00	—
	GWO	1.80e+01	1.18e+02	8.67e+01	—		GWO	2.48e-03	6.15e-03	1.84e-03	—
	SSA	0.00e+00	6.72e-40	2.92e-39	—		SSA	8.88e-16	8.88e-16	0.00e+00	—
	PSO	1.47e+00	3.84e+00	1.76e+00	—		PSO	1.07e+00	2.20e+00	4.42e-01	—
	SCA	1.37e+04	2.96e+04	8.56e+03	—		SCA	6.92e+00	1.57e+01	5.18e+00	—
	WOA	4.44e+04	7.76e+04	1.54e+04	—		WOA	2.69e-10	3.77e-08	7.07e-08	—
	BOA	9.99e-06	1.45e-05	1.78e-06	—		BOA	7.26e-04	8.75e-04	6.66e-05	—

表6(序)

函数	算法	最优值	平均值	标准差	平均收敛代数	函数	算法	最优值	平均值	标准差	平均收敛代数
F_4	IBES	0.00e+00	0.00e+00	0.00e+00	75	F_9	IBES	0.00e+00	0.00e+00	0.00e+00	1
	BES	9.69e-284	6.03e-258	0.00e+00	—		BES	0.00e+00	0.00e+00	0.00e+00	3
	GWO	3.32e-01	6.34e-01	2.66e-01	—		GWO	4.16e-04	3.13e-02	3.70e-02	—
	SSA	0.00e+00	3.58e-36	1.93e-35	—		SSA	0.00e+00	0.00e+00	0.00e+00	17
	PSO	3.40e-01	6.09e-01	1.03e-01	—		PSO	1.16e-02	5.49e-02	1.77e-02	—
	SCA	3.31e+01	6.06e+01	1.03e+01	—		SCA	5.57e+00	2.93e+01	1.81e+01	—
	WOA	1.94e-01	5.44e+01	2.63e+01	—		WOA	1.11e-16	2.79e-02	1.50e-01	—
	BOA	9.66e-04	1.10e-03	9.22e-05	—		BOA	3.33e-05	4.79e-05	7.23e-06	—
F_5	IBES	2.75e-16	8.05e-15	1.10e-14	—	F_{10}	IBES	2.96e-17	1.59e-15	2.47e-15	—
	BES	2.58e-04	8.42e-02	1.24e-01	—		BES	4.62e-07	8.99e-04	1.80e-03	—
	GWO	1.01e+00	2.08e+00	5.94e-01	—		GWO	1.73e-02	1.50e-01	1.17e-01	—
	SSA	1.18e-09	6.29e-06	1.27e-05	—		SSA	3.83e-11	5.50e-07	1.08e-06	—
	PSO	2.33e-01	8.20e-01	2.89e-01	—		PSO	1.87e-02	7.22e-02	3.96e-02	—
	SCA	1.92e+02	2.44e+03	2.01e+03	—		SCA	2.90e+04	1.32e+07	1.98e+07	—
	WOA	5.60e-01	1.27e+00	3.75e-01	—		WOA	1.57e-02	7.87e-02	8.74e-02	—
	BOA	4.51e+00	5.60e+00	5.44e-01	—		BOA	3.76e-01	6.28e-01	1.39e-01	—

根据表6可得如下结论:

1) IBES对10个测试函数寻优的结果明显优于其他算法.对函数 $F_1 \sim F_4, F_7$ 和 F_9 ,IBES能够在100次迭代内搜索到理论最优值,且平均值和标准差均为0;对 F_5 和 F_{10} 求解的最优值、平均值和标准差领先SSA算法6~9个量级,优于其余参照算法10个量级以上;对于 F_6 ,各算法寻优表现差距较小,但IBES略胜一筹;对于 F_8 ,IBES、BES和SSA算法寻优的最优值、平均值和标准差均相同且优于其余算法.

2) IBES在6个单峰函数上的寻优表现出色,表明其具有上佳的局部开发能力和收敛精度,能在较短迭代搜索过程中寻到函数较优值;而其对4组多峰函数的寻优结果优良,表明其有着突出的局部最优逃逸

能力和全局搜索性能,陷入局部最优时,能快速逃离,朝全局最优逼近.

总之,与参照算法相比,IBES在相同迭代次数下收敛精度更高,在同一精度下收敛速度更快.

3.3.2 IBES算法与新近改进智能优化算法对比

为进一步分析IBES的优越性,将其与其他新近的改进优化算法(基于非线性收敛因子和局部扰动的鲸鱼算法(NPWOA)^[14]、信息共享的记忆被囊群算法(ISMTSA)^[15]、基于混沌映射的混合粒子群蝴蝶优化算法(HPSOBOA)^[16]、领导者哈里斯鹰优化算法(LHHO)^[17])进行比较.各算法种群规模设为50,最大迭代次数为100,程序独立运行30次,运行结果如表7所示.

表7 新近改进智能优化算法寻优结果

函数	算法	最优值	平均值	标准差	函数	算法	最优值	平均值	标准差
F_1	NPWOA	5.79e-20	1.02e-16	2.16e-16	F_6	NPWOA	1.22e-04	5.00e-03	3.89e-03
	ISMTSA	2.41e-25	4.34e-24	3.76e-24		ISMTSA	7.11e-05	4.26e-04	3.25e-04
	HPSOBOA	1.64e-61	1.35e-59	2.35e-59		HPSOBOA	1.12e-05	3.15e-04	2.77e-04
	LHHO	1.28e-51	7.13e-42	2.12e-41		LHHO	4.94e-06	3.92e-04	4.98e-04
F_2	NPWOA	2.35e-13	8.23e-11	2.65e-10	F_7	NPWOA	0.00e+00	2.68e-06	1.33e-05
	ISMTSA	1.79e-13	5.37e-13	2.06e-13		ISMTSA	0.00e+00	2.08e-14	1.12e-13
	HPSOBOA	1.35e-30	6.02e-30	3.09e-30		HPSOBOA	0.00e+00	2.58e-01	7.47e-01
	LHHO	1.30e-25	2.37e-21	6.44e-21		LHHO	0.00e+00	0.00e+00	0.00e+00
F_3	NPWOA	9.64e+01	3.01e+02	2.03e+02	F_8	NPWOA	2.18e-12	3.34e-09	5.85e-09
	ISMTSA	2.52e-21	6.87e-20	1.06e-19		ISMTSA	1.64e-13	3.53e-13	1.48e-13
	HPSOBOA	1.05e-61	2.85e-59	3.32e-59		HPSOBOA	8.88e-16	8.88e-16	0.00e+00
	LHHO	4.90e-40	6.01e-27	1.79e-26		LHHO	8.88e-16	8.88e-16	0.00e+00
F_4	NPWOA	6.78e-05	9.09e-02	8.34e-02	F_9	NPWOA	0.00e+00	1.73e-12	9.28e-12
	ISMTSA	1.09e-12	2.57e-12	9.66e-13		ISMTSA	0.00e+00	0.00e+00	0.00e+00
	HPSOBOA	1.30e-30	1.26e-29	4.93e-30		HPSOBOA	0.00e+00	0.00e+00	0.00e+00
	LHHO	1.87e-25	3.48e-21	9.83e-21		LHHO	0.00e+00	0.00e+00	0.00e+00
F_5	NPWOA	2.49e-01	6.33e-01	2.56e-01	F_{10}	NPWOA	6.26e-03	3.05e-02	2.01e-02
	ISMTSA	2.16e+00	3.12e+00	5.95e-01		ISMTSA	1.12e-01	3.68e-01	2.41e-01
	HPSOBOA	8.80e-04	7.80e-02	5.76e-02		HPSOBOA	1.65e-04	2.04e-03	1.83e-03
	LHHO	3.68e-06	1.66e-03	1.85e-03		LHHO	1.19e-06	2.11e-04	1.90e-04

对比表6和表7可知:与经典WOA及BOA相比,NPWOA和HPSOBOA在寻优性能上均有一定程度的改善,后者的性能提升较为明显.从各改进优化算法的寻优结果可以看出:IBES在收敛精度和稳定性上的表现最好,HPSOBOA和LHHO稍逊,ISMSTA次之,NPWOA较差.对函数 $F_1 \sim F_5$ 和 F_{10} 寻优时,IBES明显优于其余4种改进算法,其对 $F_1 \sim F_4$ 能够寻到理论最优值,其他算法均未找到;对于 F_5 和 F_{10} ,在各算法求解精度均较低的情况下,IBES能够保证每项指标均优于对比算法10个量级以上;在余下测试函数中,IBES的寻优表现略好或平于其他算法.

综合本节分析可知,IBES算法有较强局部极值规避能力,能较好兼顾全局搜索性能和局部开发能力,故其寻优时收敛速度快、求解精度高、稳定性好,表现出优越的寻优性能.

3.4 IBES算法实用性验证分析

针对复杂、非线性的被控对象,传统的PID控制器难以取得理想控制效果,为了提高控制性能,有学者将其与神经网络结合设计出PID神经网络控制器(PIDNNC).此控制器中,神经网络初始权值的选取直接影响控制的稳定性、准确性和快速性,由于参数较多,人工整定难度大,可利用优化算法的全局寻优技术获得较为理想的初始权值.本文以一种多输入多输出的复杂耦合系统作为被控对象,利用3.3.1节部分算法和3.3.2节全部算法整定初始权值后的PIDNNC对其进行控制,通过比较各算法的适应度值

及其优化后的控制系统的时域性能指标,验证算法的实用性.被控对象的数学模型如下:

$$\begin{cases} y_1(k) = \\ 0.4 \cdot y_1(k-1) + u_1(k-1)/[1 + u_1(k-1)^2] + \\ 0.2 \cdot u_1(k-1)^3 + 0.5 \cdot u_2(k-1) + 0.3 \cdot y_2(k-1), \\ y_2(k) = \\ 0.2 \cdot y_2(k-1) + u_2(k-1)/[1 + u_2(k-1)^2] + \\ 0.4 \cdot u_2(k-1)^3 + 0.2 \cdot u_1(k-1) + 0.3 \cdot y_3(k-1), \\ y_3(k) = \\ 0.3 \cdot y_3(k-1) + u_3(k-1)/[1 + u_3(k-1)^2] + \\ 0.4 \cdot u_3(k-1)^3 + 0.4 \cdot u_2(k-1) + 0.3 \cdot y_1(k-1). \end{cases} \quad (20)$$

其中: $y(k)$ 为系统当前时刻被控量, $y(k-1)$ 为系统上一时刻被控量, $u(k-1)$ 为系统上一时刻控制量.进一步地,给出算法的适应度函数,其计算公式如下:

$$F = \sum_{i=1}^s \sum_{k=1}^n \sqrt{[y_i(k) - r_i(k)]^2}. \quad (21)$$

其中: n 为全部采样点数, s 为被控量个数, $r(k)$ 为被控量期望值.

设输出期望值分别为0.7、0.4、0.6,初始控制量和被控量均为0,采样周期为0.001s,算法寻优的搜索范围为 $[-0.3, 0.3]$,维度为45,每维对应一个权值,其余参数设置同3.3节,各算法的适应度值及其优化后的控制系统的时域性能指标由表8给出.

表8 不同算法的适应度值及其优化后控制系统的时域性能指标

算法	F	被控量1			被控量2			被控量3		
		上升时间/s	超调量/%	调节时间/s	上升时间/s	超调量/%	调节时间/s	上升时间/s	超调量/%	调节时间/s
IBES	6.90	0.008	0.0	0.011	0.009	0.0	0.011	0.008	0.1	0.011
GWO	9.42	0.008	7.1	0.021	0.006	17.2	0.021	0.014	0.4	0.020
SSA	7.90	0.007	8.9	0.020	0.007	5.6	0.020	0.009	4.4	0.019
PSO	10.55	0.012	0.0	0.017	0.009	8.7	0.019	0.011	0.0	0.015
SCA	14.71	0.007	23.5	0.043	0.011	10.0	0.032	0.007	33.1	0.042
NPWOA	12.05	0.015	0.0	0.022	0.015	2.7	0.024	0.015	0.0	0.021
ISMSTA	10.03	0.010	0.5	0.013	0.009	5.0	0.021	0.009	2.7	0.018
HPSOBOA	8.26	0.009	3.6	0.016	0.009	1.8	0.013	0.009	5.6	0.016
LHHO	8.95	0.013	0.0	0.016	0.007	7.2	0.016	0.012	0.0	0.016

分析表8可知,IBES对应的适应度值最小,然后依次是SSA、HPSOBOA、LHHO、GWO、ISMSTA、PSO、NPWOA,而SCA表现最差.对于被控量1而言:SSA和SCA优化后的控制系统上升时间最快,均为0.007s;IBES、PSO、NPWOA和LHHO优化后的控制系统实现了零超调量;IBES优化后的控制系统调节时间最短,仅为0.011s.对于被控量2:IBES表现较优越,经其优化后的控制系统对应超调量最小且调节

时间最短,仅在上升时间上落后GWO、SSA和LHHO作用的结果.而对于被控量3:SCA优化后的控制系统的上升时间最短;PSO、NPWOA和LHHO对应的控制系统超调量为零;IBES对应的控制系统调节时间最短,其另外两个指标也较好.可见,对于给定的三输入三输出的复杂耦合控制系统,经IBES优化后的PIDNNC能保证各控制性能指标均处于较优水平,控制效果显著,反映了该算法具有较强实用性.

4 结论

本文基于自适应控制因子、折射反向学习机制和定向重组与诱导突变策略提出了一种IBES算法. 利用自适应控制因子保证算法在搜索前期具有丰富种群多样性,后期有较强个体集群化能力,有效平衡了算法的全局搜索性能与局部开发能力;其次,通过引入折射反向学习机制找到当前解对应的折射反向解,增加算法搜索到问题最优解的概率,提高其收敛速度和精度;最后,为保留种群的优良基因并加快物种的进化速度,融合了定向重组与诱导突变策略.

通过对10个不同的基准测试函数进行数值仿真实验,剖析了所提3种改进方法对算法性能的影响,验证了IBES算法的优越性.同时,将经不同算法优化的PIDNNC应用到复杂控制系统中,实验结果表明,IBES优化的PIDNNC控制性能优越,体现了IBES算法较好的实用性.综上所述,经多策略叠加效应,改进后的BES算法寻优性能显著提升,优于SSA、HPSOBOA及LHHO等先进优化算法.在下一步研究工作中,考虑将IBES算法契合进更多工程中以解决实际问题.

参考文献(References)

- [1] Galletly J E. An overview of genetic algorithms[J]. *Kybernetes*, 1992, 21(6): 26-30.
- [2] Kennedy J, Eberhart R. Particle swarm optimization[C]. *IEEE International Conference on Neural Networks*. Perth, 1995: 1942-1948.
- [3] Rashedi E, Nezamabadi-pour H, Saryazdi S. GSA: A gravitational search algorithm[J]. *Information Sciences*, 2009, 179(13): 2232-2248.
- [4] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. *Advances in Engineering Software*, 2014, 69: 46-61.
- [5] Mirjalili S, Lewis A. The whale optimization algorithm[J]. *Advances in Engineering Software*, 2016, 95: 51-67.
- [6] Mirjalili S. SCA: A sine cosine algorithm for solving optimization problems[J]. *Knowledge-Based Systems*, 2016, 96: 120-133.
- [7] Arora S, Singh S. Butterfly optimization algorithm: A novel approach for global optimization[J]. *Soft Computing*, 2019, 23(3): 715-734.
- [8] Xue J K, Shen B. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.
- [9] 何庆, 吴意乐, 徐同伟. 改进遗传模拟退火算法在TSP优化中的应用[J]. *控制与决策*, 2018, 33(2): 219-225. (He Q, Wu Y L, Xu T W. Application of improved genetic simulated annealing algorithm in TSP optimization[J]. *Control and Decision*, 2018, 33(2): 219-225.)
- [10] Long W, Jiao J J, Liang X M, et al. Inspired grey wolf optimizer for solving large-scale function optimization problems[J]. *Applied Mathematical Modelling*, 2018, 60: 112-126.
- [11] 龙文, 蔡绍洪, 焦建军, 等. 一种改进的灰狼优化算法[J]. *电子学报*, 2019, 47(1): 169-175. (Long W, Cai S H, Jiao J J, et al. An improved grey wolf optimization algorithm[J]. *Acta Electronica Sinica*, 2019, 47(1): 169-175.)
- [12] 张达敏, 陈忠云, 辛梓芸, 等. 基于疯狂自适应的樽海鞘群算法[J]. *控制与决策*, 2020, 35(9): 2112-2120. (Zhang D M, Chen Z Y, Xin Z Y, et al. Salp swarm algorithm based on craziness and adaptive[J]. *Control and Decision*, 2020, 35(9): 2112-2120.)
- [13] Alsattar H A, Zaidan A A, Zaidan B B. Novel meta-heuristic bald eagle search optimisation algorithm[J]. *Artificial Intelligence Review*, 2020, 53(3): 2237-2264.
- [14] 于俊洋, 高宁杰, 李涵. 基于非线性收敛因子和局部扰动的鲸鱼算法[J]. *计算机工程与设计*, 2019, 40(10): 2861-2866. (Yu J Y, Gao N J, Li H. Whale optimization algorithm based on nonlinear cognitive factor and local disturbance[J]. *Computer Engineering and Design*, 2019, 40(10): 2861-2866.)
- [15] 屈迟文, 彭小宁. 信息共享的记忆被囊群算法[J]. *模式识别与人工智能*, 2021, 34(7): 605-618. (Qu C W, Peng X N. Memory tunicate swarm algorithm with information sharing[J]. *Pattern Recognition and Artificial Intelligence*, 2021, 34(7): 605-618.)
- [16] Zhang M J, Long D Y, Qin T, et al. A chaotic hybrid butterfly optimization algorithm with particle swarm optimization for high-dimensional optimization problems[J]. *Symmetry*, 2020, 12(11): 1800.
- [17] Naik M K, Panda R, Wunnava A, et al. A leader Harris Hawks optimization for 2-D Masi entropy-based multilevel image thresholding[J]. *Multimedia Tools and Applications*, 2021, 80(28/29): 35543-35583.

作者简介

郭云川(1997—),男,硕士生,从事智能优化算法和复杂工业控制的研究, E-mail: 1152418927@qq.com;

张长胜(1970—),男,副教授,从事复杂工业过程建模、智能优化算法等研究, E-mail: 122832170@qq.com;

段青娜(1985—),女,工程师,硕士,从事复杂工业控制的研究, E-mail: 272545192@qq.com;

罗运河(1970—),男,工程师,硕士,从事复杂工业控制的研究, E-mail: 1050152517@qq.com;

程倩(1986—),女,工程师,硕士,从事复杂工业控制的研究, E-mail: cindy86813@qq.com;

钱斌(1976—),男,教授,博士生导师,从事智能优化调度理论与方法、工业过程优化控制等研究, E-mail: bin.qian@vip.163.com;

胡蓉(1974—),女,副教授,博士,从事优化方法与决策支持系统、工业过程优化控制等研究, E-mail: ronghu@vip.163.com.