融合多策略的蜣螂算法的三维无人机航迹规划

李尧,黄大庆*,徐文校,赵喆
(南京航空航天大学 电子信息工程学院,江苏 南京 210016)

摘 要 针对蜣螂算法在无人机航迹规划中存在的种群多样性匮乏、收敛迟缓和全局探索力不足等问题,提出了一种融合多策略的更优蜣螂优化算法(BDBO).该算法将动态学习的佳点集初始化、基于时间选择的主动并行双边搜索、自然衰减种群机制及融合Sigmoid的边界收敛策略嵌入航迹规划全过程:在全局阶段迅速扩大可行航迹空间,在局部阶段精细调整航迹最优点,从而同步提升收敛速度与求解精度.以航迹长度、飞行安全、平滑度及高度代价的加权和为目标函数,在CEC2017及三维山地环境进行验证.结果表明:BDBO所得航迹的适应度值较对比的四种算法平均降低19.47%、25.51%、20.85%和3.97%,充分证明了BDBO在无人机三维航迹规划中的有效性与优越性.

关键词 蜣螂算法;主动并行双边搜索;自然衰减种群优化法;选择边界收敛策略
中图分类号 TP18;V279;V249 **文献标志码** A **文章编号** 1672-4321(2026)04-0540-08
doi:10.20056/j.cnki.ZNMDZK.20250853

Three-dimensional UAV path planning based on Dung Beetle Algorithm fused with multiple strategies

Li Yao, Huang Daqing*, Xu Wenxiao, Zhao Zhe
(School of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, Jiangsu China)

Abstract To address the deficiencies of the Dung Beetle Optimizer (DBO) in UAV path planning—namely, insufficient population diversity, slow convergence, and weak global exploration, a multi-strategy-enhanced variant termed BDBO is proposed . The algorithm seamlessly integrates four synergistic components throughout the entire planning process: dynamic-learning-based good-point set initialization, time-triggered active parallel bilateral search, a natural population-decay mechanism, and a boundary convergence strategy fused with a Sigmoid function. Collectively, these strategies rapidly expand the feasible flight-corridor during the global phase and refine waypoint positions in the local phase, thereby accelerating convergence and improving solution accuracy simultaneously. A composite objective function aggregating path length, flight safety, trajectory smoothness, and altitude cost is minimized on both CEC2017 benchmarks and a realistic 3-D mountainous scenario. Experimental results reveal that BDBO reduces the best fitness value by 19.47 %, 25.51 %, 20.85 %, and 3.97 % compared with four state-of-the-art counterparts, unequivocally demonstrating its effectiveness and superiority for three-dimensional UAV path planning.

Keywords Dung Beetle algorithm; active parallel bilateral search; natural decay population optimization; selected boundary convergence strategy

自动化技术趋于成熟,无人机的运用领域日益宽广,如在植保[1]、防灾[2]、物流[3]等方面,无人机都发挥了显著的作用.航迹规划是无人机的相关运用中的关键技术之一,先进的航迹规划技术可以实现快速精准打击目标、节约成本.众多学者对航迹规划算法进行了研究,目前可将其分为传统算法和智能优化算法.传统算法有A*算法[4]、快速探索随机树算法(Rapidly-Exploring Random Tree Algorithm,

收稿日期 2025-05-27
* **通信作者** 黄大庆(1964-),男,研究员,研究方向:遥测遥感,E-mail: radiouav@nuaa.edu.cn
基金项目 中国高校产学研创新基金资助项目(2021ZYA04004)

RRT)[5]等.A*算法对启发式函数的依赖性强,搜索效率低下;RRT算法随机性高,航迹结果不够平滑且在狭窄区域搜索速度慢.因此智能算法逐渐成为了优化问题的主流.智能算法种类繁杂,有灰狼算法(Grey Wolf Optimizer, GWO)[6]、蚁群算法(Ant Colony Algorithm, ACA)[7]等.但GWO存在收敛速率低下、局部最优解的困扰、参数选择难度大;ACA计算复杂度高,收敛速度慢,在高维空间中计算量指数级增长.因此寻找收敛速度快、精度高、环境适应性强的智能算法是航迹规划问题中研究的主要目标.

蜣螂算法(Dung Beetle Optimizer, DBO)[8]是依靠模拟蜣螂不同行为的分布式智能算法,其特点在于寻优能力强、收敛速度快,能够有效探索问题空间,近来年被广泛使用于航迹规划领域中[9].DBO算法在初期种群分布过于随机,使得算法搜索效率遭受影响,且算法收敛边界采用线性收敛,易导致算法收敛速率过快,陷于局部最优.针对上述困扰,研究人员们提出了很多改进措施,文献[10]将DBO与GWO融合,提高收敛速率和航迹质量,但未解决收敛精度低的问题;文献[11]引入了莱维飞行和纵横交叉策略,提高收敛速率,但是并未改善算法易陷入局部最优解的风险,不适用于山地环境下的航迹规划问题.

为了更好解决DBO的收敛速度慢、收敛精度低、可能陷入局部最优解的局限性,本文建立了一种结合动态学习的佳点集初始化、基于时间选择的主动并行双边搜索、自然衰减种群优化法和融合Sigmoid函数选择边界收敛的融合多策略的更优蜣螂算法(Better Dung Beetle Optimizer, BDBO).该算法能够有效降低航迹成本、提升航迹平滑度以及收敛精度.将BDBO与DBO、GWO等在CEC2017函数上进行仿真对比.在山地仿真环境下,将BDBO与DBO、狐猴算法(Lemurs Optimizer, LO)[12]、开普勒算法(Kepler Optimization Algorithm, KOA)[13]、蜘蛛胡蜂算法(Spider Wasp Optimizer, SWO)[14]进行仿真对比.

1　无人机航迹规划问题建模

1.1　飞行航迹长度函数

无人机的飞行航迹是由许多航迹点拟合构成.采用欧氏距离方法构建飞行航迹长度函数.设三维空间中,某一航迹点o的坐标为$p_o=(x_o,y_o,z_o)$,则无人机飞行的航迹函数f_L,如公式(1)所示:

$$\begin{cases} f_L=\sum_{o=1}^{n}L_o \\ L_o=\sqrt{(x_{o+1}-x_o)^2+(y_{o+1}-y_o)^2+(z_{o+1}-z_o)^2} \end{cases},(1)$$

式中:L_o表征的是第o段航迹的欧氏长度.

1.2　飞行安全代价函数

无人机易受到来自外部威胁的干扰,导致飞行任务失败,致使无人机坠毁.因此应当确保无人机在飞行过程中的安全,如公式(2)所示:

$$\begin{cases} f_S=\sum_{o=1}^{n}f_o \\ f_o=\begin{cases} 0 & d_o<M \\ M-d_o & R_i<d_o<M \\ \infty & d_o<R_i \end{cases} \end{cases},(2)$$

式中:R_i为空间中第i个障碍物的半径大小,d_o为航迹L_o到与其相距最近的障碍物中心点的距离,M为安全阈值.威胁区域俯视平面图如图1所示:

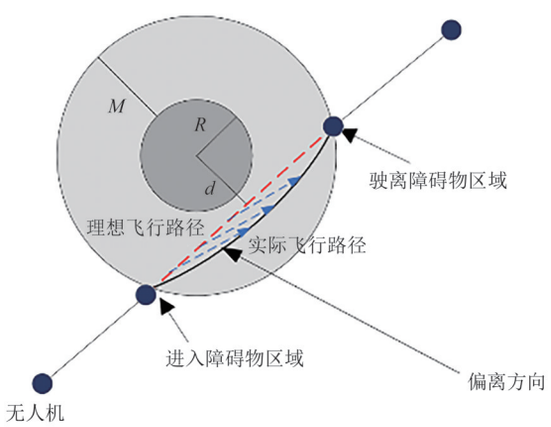


图1　威胁区域模型俯视平面图

Fig. 1　Threat zone model diagram

1.3　航迹平滑成本函数

无人机在执行任务过程中,应当避免转向角度或升降幅度过大的情况.因此,其俯仰角和偏转角必须满足相关约束限制,否则航迹是不满足飞行性的.数学模型如公式(3)、公式(4)所示:

$$\phi_o=\arctan\left(\frac{\|L_oL_{o+1}\|}{L_oL_{o+1}}\right),(3)$$

$$\varphi_o=\arctan\left(\frac{z_{o+1}-z_o}{\sqrt{(x_{o+1}-x_o)^2+(y_{o+1}-y_o)^2}}\right),(4)$$

每一段航迹的偏转角度和俯仰角度之和可求得航迹平滑程度函数f_E,如公式(5)所示:

$$f_E=\sum_{o=1}^{n-2}\phi_o+\sum_{o=1}^{n-1}(\varphi_o-\varphi_{o-1}),(5)$$

式中:ϕ_o、φ_o为无人机飞行过程中处于第o段航迹所

对应的偏转角度和俯仰角度.

1.4 高度代价成本函数

无人机飞行高度应当处在一个合理的区间内,低于区间会提高飞行风险,高过区间会增加飞行成本,高度代价成本函数f_H如公式(6)所示:

$$f_H=\sum_{o=1}^{n}H_o$$
$$H_o=\begin{cases}\left|2h_o-\left(h_{\max}+h_{\min}\right)\right| & h_{\min}<h_o<h_{\max}\\ \infty & else\end{cases},(6)$$

式中:h_o为第o段航迹对应无人机飞行高度,$h_{\min}$和$h_{\max}$为可飞行的最小和最大高度.

1.5 总目标函数

对其上所有函数进行权重综合,构建无人机航迹规划问题目标函数F_C,如公式(7)所示:

$$F_C=f_L+f_S+f_E+f_H \quad ,(7)$$

当F_C取得最小值时,即可得最优航迹.

2 BDBO算法

2.1 DBO算法的基本理论

DBO通过模拟滚球(跳舞)、繁殖、觅食以及偷窃的不同行为来模拟迭代进行位置更新.蜣螂通过滚动粪球进行全局搜索,当前方未出现阻碍物时,其位置更新如公式(8)所示:

$$x_i(t+1)=x_i(t)+\alpha\times k\times x_i(t-1)+b\times\left|x_i(t)-X^{\omega}\right| \quad ,(8)$$

前方出现阻碍物时,其位置更新如公式(9)所示:

$$x_i(t+1)=x_i(t)+\tan(\theta)\times\left|x_i(t)-x_i(t-1)\right| \quad ,(9)$$

式中,$x_i(t)$代表第i只蜣螂在第t迭代时的位置,k是一个0到0.2间的常量.b是0到1之间的常量,α取值为1或-1,X^{ω}为全局最差解,$\theta\in(0,\pi)$.

蜣螂会在一个逐渐收敛的边界区间中进行产卵,产卵边界范围的数学模型如公式(10)所示:

$$\begin{cases}L_b^*=\max(X^*\times(1-R),L_b)\\ U_b^*=\min(X^*\times(1+R),U_b)\end{cases} \quad ,(10)$$

边界收敛因子R的数学模型如公式(11)所示:

$$R=\frac{1-t}{M_t} \quad ,(11)$$

繁殖蜣螂的位置更新如公式(12)所示:

$$x_i(t+1)=X^*+b_1\times(x_i(t)-L_b^*)+b_2\times(x_i(t)-U_b^*) \quad ,(12)$$

式中:L_b^*、U_b^*代表产卵区域的上下界,L_b、U_b表示待求解问题的上下边界,M_t表示最大迭代次数,X^*表示当前局部最优解,b_1、b_2是2个独立的随机向量,大小为$1\times D$,D代表待求解问题的维度.

蜣螂会进行觅食行为,觅食边界的数学模型如公式(13)所示:

$$\begin{cases}L_b^b=\max(X^b\times(1-R),L_b)\\ U_b^b=\min(X^b\times(1+R),U_b)\end{cases} \quad ,(13)$$

蜣螂觅食行为位置更新如公式(14)所示:

$$x_i(t+1)=x_i(t)+C_1\times(x_i(t)-L_b^b)+C_2\times(x_i(t)-U_b^b) \quad ,(14)$$

式中:L_b^b、U_b^b代表觅食区域的上下界,C_1是满足正态分布的随机数,C_2是0到1的随机向量.

部分蜣螂会选择偷盗其他蜣螂的粪球,偷盗行为的位置更新如公式(15)所示:

$$x_i(t+1)=X^b+S\times g\times\left(\left|x_i(t)-X^*\right|+\left|x_i(t)-X^b\right|\right) \quad ,(15)$$

式中:S为常数,g是满足正态分布的随机数,大小为$1\times D$.

2.2 BDBO算法改进策略

2.2.1 结合动态学习的佳点集初始化

DBO采用伪随机数的方法生成初始种群的位置,但此方法全局遍历性差,寻优效率低下.因此,本文提出结合动态学习的佳点集方法[15]进行种群初始化,丰富种群层次、使得全局遍历区域更广,能够有效提高全局搜索效率,两者对比如图2所示:

由图2可以看出,结合动态学习的佳点集初始化时序散点分布更加均匀,面对高维问题时具备更好的稳定性.

结合动态学习的佳点集方法的数学模型如公式(16)、(17)所示:

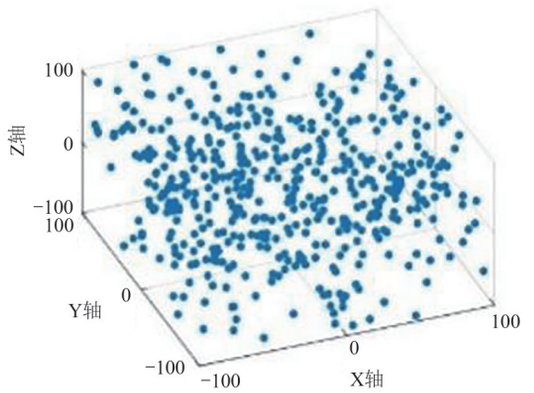
$$x_i(t)=(U_b-L_b)g\left\{r_j^{(i)}\times k\right\}+L_b \quad ,(16)$$

$$x_{i+1}(t)=x_i(t)+m_1\times(m_2(L_b+U_b)-x_i(t))-x_i(t) \quad ,(17)$$

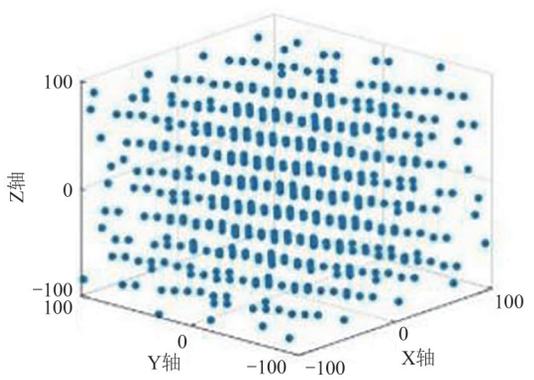
式中:$r_j^{(i)}$表示第j维度下所对应的佳点,m_1和m_2是两个独立随机值,$k\in(1,n)$.

2.2.2 基于时间选择的主动并行双边搜索

DBO中,觅食行为依赖于全局最佳位置进行搜寻,其局部开发能力不足,收敛精度低,易陷入局部最优解.在此提出一种新的搜索思想——主动并行双边搜索策略.该策略不再单一的依靠全局最优位置,而是将另外的蜣螂信息和当前种群的最佳位置联立,引导整个蜣螂种群朝着最佳食物源进行位置更新.首先,选择适应度值最高的4只觅食蜣螂作为一个种群集,计算当前离食物源最近的觅食蜣螂同另外3只觅食蜣螂的距离,然后随机从中选择1-2个



(a) 未使用佳点集初始化种群时序图



(b) 结合动态学习的佳点集时序图

图2　不同方式初始化种群时序对比图

Fig. 2　Comparison chart of time series for population initialization with different methods

位置作为权重参数,引导整个蜣螂群体向最佳位置靠拢.距离l_d表示如公式(18)所示:

$$l_d = (X^* - X_{if}^T) \quad i = 1, 2\cdots n \qquad (18)$$

式中:X_{if}^T表示第T次迭代时,第i只觅食蜣螂的位置.

为了强化种群中各蜣螂间的相互交流,引入时间选择策略.选择任意两只觅食蜣螂,比较二者距全局最佳位置的距离,由比较结果设置权重参数,其数学模型如公式(19)、公式(20)所示:

$$\omega_D = \left| X_{if}^T - X_{jf}^T \right| \qquad (19)$$

$$\omega_S = J \times \omega_D \qquad (20)$$

式中:J为随机常量,ω_D为两只蜣螂间距离,ω_S代表权重参量.

采用时间选择机制,能够提高种群的多样性.当迭代次数满足一定条件时采用双边搜索策略进行位置更新;若不满足则按照主动选择策略进行位置更新.设置时间参量$T(t)$和时间常量$T(0)$,如公式(21)所示,本文中$T(0)$取值为0.5.

$$T(t) = \left| \left(1 - (1 - t/M_t)\right) \times J \right| \qquad (21)$$

优化后的觅食行为位置更新策略如公式(22)所示:

$$X_{(i+1)f}^T = \begin{cases} X_{if}^T + \alpha l_{d1} + \beta l_{d1} & T(t) < T(0) \\ \omega_D\left(X_{if}^T + C_1(X_{if}^T - L_b^b) + C_2(X_{if}^T - U_b^b)\right) & T(t) > T(0) \end{cases} \qquad (22)$$

2.2.3　自然衰减种群优化法

DBO中,种群中各蜣螂比重是不变的,导致种群的多样性差.受自然选择思想[16]的启发,种群最开始在整个空间中广泛寻找合适的居住地和食物源,此时滚球蜣螂的数量占比较大.当多数滚球蜣螂找到了优质食物源后便会在此繁衍后代.小部分滚球蜣螂因未找到合适的区域会逐渐死亡,通过自然选择行为实现种群结构的动态调整.

在迭代前期让滚球蜣螂占有较大比重,使得前期全局搜索能力强;后期提高繁殖蜣螂和觅食蜣螂的比重,使得后期局部寻优能力高.自然衰减种群优化法的数学模型如公式(23)所示:

$$rNum = \begin{cases} N_{\mathrm{Pop}} 2 r_{\mathrm{Percent}} & 0 < t < \dfrac{M_t}{4} \\ N_{\mathrm{Pop}} r_{\mathrm{Percent}} \cos v_1 \cos\left(\dfrac{\pi}{4M_t}\right) & \dfrac{M_t}{4} < t < \dfrac{M_t}{2} \\ N_{\mathrm{Pop}} r_{\mathrm{Percent}} v_2 \cos\left(\dfrac{\pi}{2M_t}\right) & \dfrac{M_t}{2} < t < \dfrac{3M_t}{4} \\ N_{\mathrm{Pop}} r_{\mathrm{Percent}} v_3 \cos\left(\dfrac{3\pi}{4M_t}\right) & \dfrac{3M_t}{4} < t < M_t \end{cases} \qquad (23)$$

式中:rNum代表滚球蜣螂的数量,r_{Percent}代表滚球蜣螂在整个蜣螂种群中的比重,N_{Pop}代表总体蜣螂的数量,v_1、v_2、v_3表示与迭代次数相关的权重常量.

2.2.4　融合Sigmoid函数选择边界收敛策略

在DBO中,繁殖和觅食蜣螂的搜索边界都是一条线性的直线.R的大小对应了搜索区域的范围,通过调整R来平衡算法的全局搜索和局部搜索能力.但DBO算法采用线性衰减,存在收敛速度过快的问题,易使算法陷入局部最优解.如图3所示,实线代表融合Sigmoid函数收敛条件,虚线代表线性收敛条件.对比线性收敛的方式,融合Sigmoid函数[17]选择边界收敛策略.在迭代前期,较高R的值能够提高全局搜索能力;在迭代后期,较低R的值在能够提高局部寻优精度,便于在二者之间达到平衡.

改进后的边界收敛曲线R_Δ的数学模型如公式(24)所示:

$$R_\Delta = \begin{cases} 1 + \dfrac{1}{1 + \mathrm{e}^{-t/M_t}} & 0 < t < 2/M_t \\ \dfrac{1}{2}\cos\left(\dfrac{t}{M_t}\right) + 1/2 & 2/M_t < t < M_t \end{cases} \qquad (24)$$

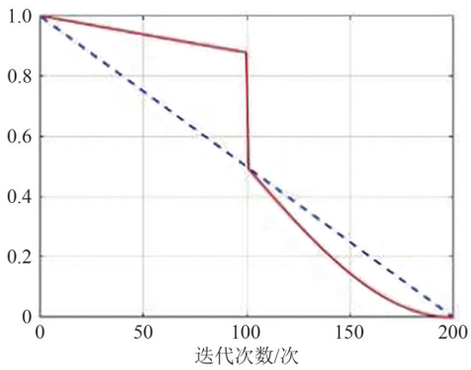


图3 不同边界收敛条件曲线对比图

Fig. 3 Comparison of convergence curves under different boundary conditions

2.3 BDBO算法流程图

本文BDBO算法流程图如图4所示:

3 仿真实验及结果分析

实验语言采用matlabR2023a,仿真环境为windows11(64位),处理器为AMD Ryzen5 7600 6-CoreProcessor,3.8GHz,16.0GB.

3.1 标准算法在测试函数中的仿真比较

为了论证本文提出的算法性能,本文采用CEC2017测试函数[18]进行基础实验对比,CEC2017函数集如表1所示.

本文将BDBO同DBO、GWO、WOA[19]和PSO算法[20]与本文提出的BDBO算法进行对比实验,统一设置5种算法的参数,种群大小为30,最大迭代次数为500,基础参数设置如表2所示.

为降低单次实验的偶然性,每个算法独立重复运行30次.计算求得最优值、平均值和标准差记录

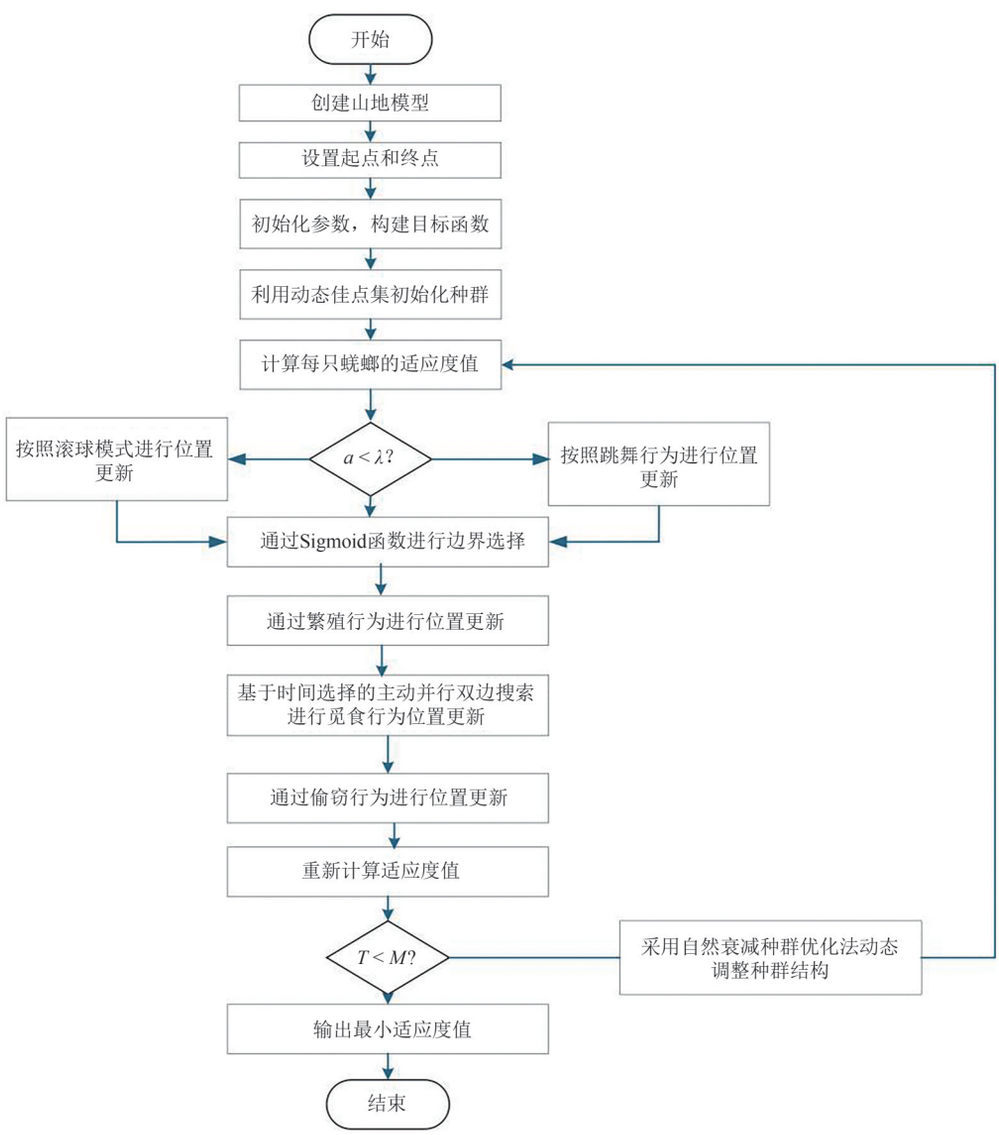


图4 BDBO算法流程图

Fig. 4 Flowchart of the BDBO algorithm

表1　CEC2017测试函数

Tab. 1　CEC2017 test functions

公式	维度	上下界	最优值
F1	30	[-100,100]	0
F2	30	[-10,10]	0
F3	30	[-100,100]	0
F4	30	[-500,500]	-418.9829n
F5	30	[-5.12,5.12]	0
F6	4	[-5,5]	0.000307
F7	3	[0,1]	-3.86

表2　相关算法参数设置表

Tab. 2　Parameter settings for the investigated algorithms

算法	关键参数	取值
BDBO	λ	0.9
	k	0.1
	b	0.3
	S	0.5
	α	±1
	g	rand(1)
DBO[8]	同DBO	
GWO[6]	α	2-0递减
	A	A = 2α·r1-α
	C	C = 2·r2
	r1	rand(1)
	r2	rand(1)
WOA[19]	A	A = 2α·r1-α
	C	C = 2·r2
	r1	rand(1)
	r2	rand(1)
	p	0.5
	b	1
PSO[20]	w	0.9→0.2
	c1	2
	c2	2
	Vmax	0.2*(ub-lb)

于表3.其中最优值可以反映算法的优化能力,平均值反映算法的平均性能,标准差表征算法的稳定程度.

图5给出了测试函数的收敛曲线.

从表3和图5可以看出,在面对高维单峰函数F1、F2、F3时,仅有BDBO能够找到最优的解;对于高维多峰函数F4、F5,BDBO能够寻找到更精确解;对于低维多峰函数F6,仅有BDBO可以得到最优解;对于低维多峰函数F7,BDBO的性能也是排在前列的.因此BDBO不仅在面对简单问题求解时能够有着较快的收敛速率,其在面对复杂问题时,求解能力更强,具备更好的稳定性.由此可以证明BDBO克服了DBO收敛速度慢、收敛精度低的缺陷,可适用于复杂环境下无人机航迹规划问题.

3.2　三维山地环境无人机航迹仿真实验

为了进一步论证BDBO在无人机最优航迹规划问题中的有效性,将其与DBO、LO、KOA、SWO算法在山地场景中进行仿真对比实验.所有算法的种群数量设置为30,迭代次数上限为500.

5种算法的航迹图和适应度收敛曲线如图6-图7所示:

通过图6可知,BDBO所生成的航迹平滑程度均高于其他算法;由图7可知,BDBO所求得的适应度值更低,收敛速度更快.为减少单次实验所带来的偶然性,重复实验30次,并将结果记录在表4中.

从表4可知,BDBO的平均路径分别降低了19.47%、25.51%、20.85% 和 3.97%.综上,无论是在航迹和飞行成本还是响应速度上,BDBO在无人机三维航迹规划问题上都展现出优越的性能.

4　结论

本文提出一种融合多策略的更优蜣螂算法(BDBO),通过引入动态学习的佳点集初始化、基于时间选择的主动并行双边搜索、自然选择种群优化法以及融合Sigmoid函数选择边界收敛策略,解决了DBO算法存在的搜索实时性低下、遍历性不充分、局部开发能力不足、种群结构单一等问题,有效降低航迹成本,提高收敛速度,减少陷入局部最优解的风险,经CEC2017测试函数集以及三维地图仿真实验验证,其性能优于DBO和其他算法的.但该算法也存在不足,如加入的额外参数提高了对参数的敏感度,运行时间还需进行后续优化.

表4　山地环境下各算法的仿真结果

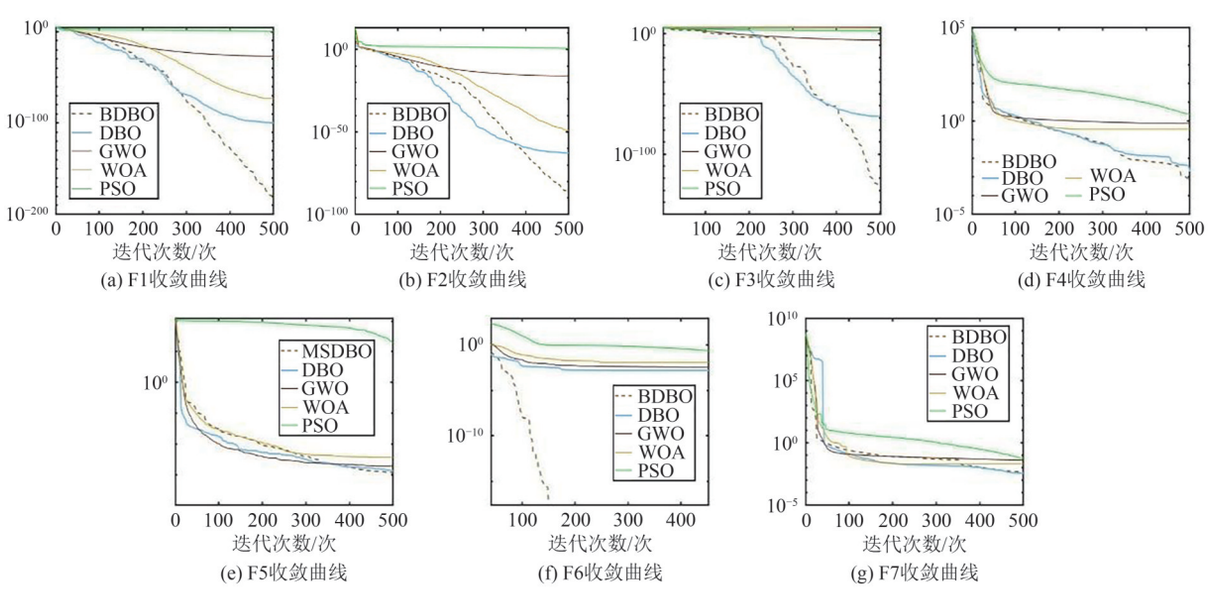
Tab. 4　Simulation results of various algorithms in mountainous environments

算法	最短路径	最长路径	平均路径	标准差
BDBO	171.0599	300.2150	191.6414	37.1858
DBO	181.4258	390.0401	238.1111	47.1658
LO[12]	187.5674	326.1422	257.2676	42.8128
KOA[13]	183.0011	391.1866	242.1111	47.1658
SWO[14]	172.5117	300.2150	199.5556	42.8128

表3 不同优化算法CEC2017测试函数计算结果

Tab. 3 Calculation results of different optimization algorithms on CEC2017 test functions

算法	F1			F2		
	最优值	平均值	标准差	最优值	平均值	标准差
BDBO	0.000E+00	0.000E+00	0.000E+00	0.000E+00	0.000E+00	0.000E+00
DBO	1.654E−152	4.628E−94	3.210E−89	1.263E−85	1.785E−54	1.785E−54
GWO	1.265E−29	1.171E−27	1.155E−27	1.202E−17	8.037E−17	6.082E−17
WOA[	9.482E−84	2.027E−72	7.389E−72	1.342E−56	1.537E−50	7.600E−49
PSO	8.868E−00	2.303E+00	1.196E+00	2.808E+00	4.107E+00	1.108E+00
算法	F3			F4		
	最优值	平均值	标准差	最优值	平均值	标准差
BDBO	0.000E+00	4.820E−158	0.000E+00	−1.128E+23	−1.017E+15	−1.026E+06
DBO	5.237E−134	8.506E−56	5.332E−55	−1.127E+05	−8.428E+03	1.947E+03
GWO	3.072E−10	9.870E−17	2.583E−14	−7.981E+02	−6.016E+04	9.378E+02
WOA	1.630E+15	4.363E+05	1.203E+13	−1.166E+04	−1.056E+04	1.841E+03
PSO	8.427E+02	1.976E+00	6.481E+01	−7.568E+03	−5.687E+03	1.271E+03
算法	F5			F6		
	最优值	平均值	标准差	最优值	平均值	标准差
BDBO	0.000E+00	0.000E+00	0.000E+00	3.028E−03	3.174E−03	3.268E−03
DBO	0.000E+00	8.847E−01	3.435E+00	3.067E−04	8.392E−04	3.696E−04
GWO	0.000E+00	2.481E+00	3.497E+00	3.103E−04	5.022E−03	8.448E−03
WOA	0.000E+00	2.734E−15	1.688E−14	3.223E−04	7.119E−04	4.433E−04
PSO	9.016E+01	1.608E+02	3.732E+01	6.614E−04	9.185E−04	1.212E−04
算法	F7					
	最优值	平均值	标准差			
BDBO	−3.752E+00	−3.759E+00	2.488E−03			
DBO	−3.763E+00	−3.883E+00	3.423E−03			
GWO	−3.822E+00	−3.862E+00	2.173E−03			
WOA	−3.863E+00	−3.860E+00	1.742E−02			
PSO	−3.847E+00	−3.863E+00	2.120E−15			



(a) F1收敛曲线 (b) F2收敛曲线 (c) F3收敛曲线 (d) F4收敛曲线

(e) F5收敛曲线 (f) F6收敛曲线 (g) F7收敛曲线

图5 不同测试函数收敛曲线图

Fig. 5 Convergence curves of different test functions

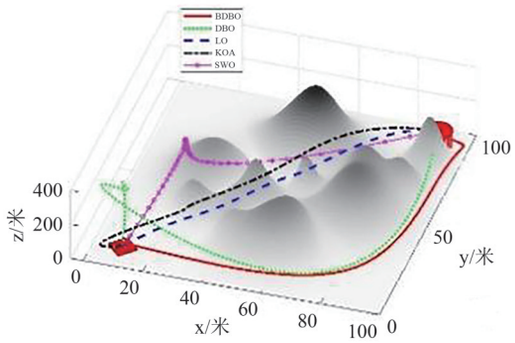


图6　5种算法仿真航迹图

Fig. 6　Five types of algorithm simulation trajectory diagrams

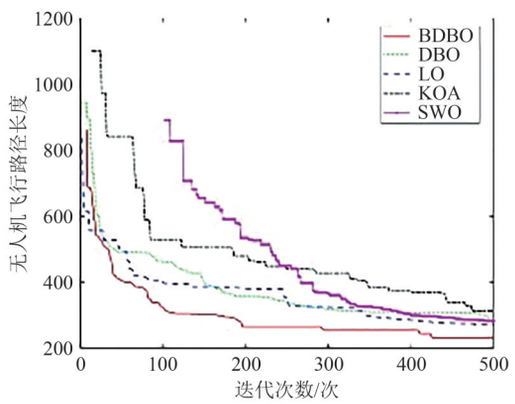


图7　5种算法无人机飞行路径长度收敛曲线图

Fig. 7　Convergence curves of flight path lengths for five algorithms of unmanned aerial vehicles

参　考　文　献

[1]　于少猛，闫铭，王鹏飞，等. 丘陵山地果园植保无人机三维路径规划[J]. 浙江大学学报(工学版)，2025，59(3)：635-642.

[2]　唐东旭. 无人机技术在森林生态遥感监测中的应用与探讨[J]. 智慧中国，2024(12)：80-81.

[3]　王芸. 基于模拟退火算法的末端车载无人机物流配送路径规划研究[J]. 自动化与仪器仪表，2025(2)：247-251.

[4]　汪国安，王红军，马宁，等. 复合作业模式下基于A*-PPO算法的AGV调度[J/OL]. 计算机集成制造系统，2025：1-24.（2025-04-17）. https://link.cnki.net/doi/10.13196/j.cims.2024.0496.

[5]　宋俊辉，刘宇庭，郭世杰. 动态环境下AIP-RRT*与DGF-APF融合的机器人路径规划[J]. 仪器仪表学报，2025，46(3)：51-64.

[6]　孙波，周健康，赵玉清，等. 基于改进灰狼优化算法的机器人全局路径规划[J]. 科学技术与工程，2024，24(33)：14287-14297.

[7]　毛文平，李帅永，谢现乐，等. 基于自适应机制改进蚁群算法的移动机器人全局路径规划[J]. 控制与决策，2023，38(9)：2520-2528.

[8]　Xue J，Shen B. Dung beetle optimizer：A new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing，2023，79(7)：7305-7336.

[9]　蒋翱徽，刘文红. 基于改进蜣螂优化算法的无人机三维路径规划[J]. 电子测量技术，2024，47(13)：128-135.

[10]　陈琦，王亚杰，孙云飞，等. 基于蜣螂和灰狼复合算法的无人机三维路径规划[J]. 电光与控制，2025，32(6)：8-15.

[11]　李为瀚，刘媛华. 融合多策略改进的蜣螂优化算法[J/OL]. 重庆工商大学学报(自然科学版)，2025：1-10.（2025-02-24）. https://kns.cnki.net/KCMS/detail/detail.aspx? filename=YZZK20250221003&dbname=CJFD&dbcode=CJFQ.

[12]　Abasi A K，Makhadmeh S N，Al-Betar M A，et al. Lemurs optimizer：A new metaheuristic algorithm for global optimization[J]. Applied Sciences，2022，12(19)：10057.

[13]　Abdel-Basset M，Mohamed R，Abdel Azeem S A，et al. Kepler optimization algorithm：A new metaheuristic algorithm inspired by Kepler's laws of planetary motion[J]. Knowledge-Based Systems，2023，268：110454.

[14]　Abdel-Basset M，Mohamed R，Jameel M，et al. Spider wasp optimizer：A novel meta-heuristic optimization algorithm[J]. Artificial Intelligence Review，2023，56(10)：11675-11738.

[15]　李书群，陈钰，杨雨婷，等. 基于佳点集人工鱼群的点云配准算法[J]. 合肥工业大学学报(自然科学版)，2023，46(9)：1203-1209.

[16]　郝武帮，施磊. 融合自然选择机理和遗传算法的多峰MPPT优化控制[J]. 舰船电子工程，2024，44(11)：186-191，203.

[17]　李俊毅，邓志祥. 双曲正切函数的新型变步长LMS算法[J]. 计算机与数字工程，2024，52(8)：2272-2278.

[18]　毛清华，赵冰，李阳. 融合多项式差分学习与逐维变异的混沌蜉蝣算法[J/OL]. 北京航空航天大学学报，2024：1-15.（2024-06-28）. https://link. cnki. net/doi/10.13700/j.bh.1001-5965.2023.0698.

[19]　杨桂芹，刘志琦，张国庆，等. 基于鲸鱼优化算法改进的SDN网络流量预测模型[J]. 兰州交通大学学报，2025，44(2)：19-29.

[20]　朱凯鹏，王全政，杨文政，等. 基于改进粒子群优化算法的船舶避碰研究[J]. 传感器与微系统，2025，44(4)：40-43，47.

（责编&校对　雷建云）