

DOI:10.19651/j.cnki.emt.2108509

基于新型灰狼优化算法的无人机航迹规划*

许乐 赵文龙

(南昌航空大学信息工程学院 南昌 330063)

摘要:为解决灰狼优化算法存在寻优性能差、收敛性差等问题,提出了一种新型灰狼优化算法。该算法在初始化部分使用反向学习策略生成了有序的个体,有效改善了算法的收敛速度;设计新型的非线性收敛因子和优化个体位置更新策略来协调算法的搜索能力,降低陷入局部最优的概率;引进精英选择保留策略,促使种群进化加速,提高算法收敛速度。基本函数测试和航迹规划仿真实验两者的结果表明新型灰狼优化算法具有较强的收敛性和寻优能力,并且该算法规划航迹所花费的平均航迹代价值比灰狼优化算法少19.9%。

关键词: 无人机;灰狼优化;反向学习;精英保留;航迹规划

中图分类号: TP301.6 **文献标识码:** A **国家标准学科分类代码:** 520.1040

UAV track planning based on new gray wolf optimization algorithm

Xu Le Zhao Wenlong

(School of Information Engineering, Nanchang Hangkong University, Nanchang 330063, China)

Abstract: For the sake of settle the disputes of algorithm poor optimization performance and slow training speed of gray wolf optimization algorithm, a new gray wolf optimization algorithm is proposed. In the initialization part of the algorithm, the reverse learning strategy is used to generate ordered gray wolf individuals, which validly ameliorates the convergence speed of the algorithm. The search ability of the algorithm is coordinated by designing a new nonlinear convergence factor and optimizing the individual location update strategy to reduce the probability of falling into local optimization. The elite selection retention strategy and tournament selection strategy are introduced to accelerate the population evolution and improve the convergence speed of the algorithm. The basic function test results and track planning simulation experiment verify that the new gray wolf optimization algorithm has strong astringency and high optimization accuracy, and the average track generation value spent by the algorithm is 19.9% less than that of gray wolf optimization algorithm.

Keywords: UAV; gray wolf optimization; reverse learning; elite selection retention; track planning

0 引言

随着各种新兴技术的发展,无人机在灾后救援、物资运输、环境监测、军事作战等多个领域起着广泛的应用^[1]。航迹规划是无人机执行任务中最重要的部分之一,是指在一定的约束条件下,找到一条能从起点抵达终点且安全、快速、消耗代价小的路线^[2]。因此,航迹规划问题经常被当作优化问题来处理,但传统的优化方法无法得到较为精确的解。近年来,受到自然界现象的启发,国内外学者提出了许多生物智能算法如人工蜂群算法、蚁群算法(ant colony optimization algorithm, ACO)、天牛须搜索算法(bettle antennae search algorithm, BAS)等^[3]。它们具有原理简单、易收敛到最优解、参数设置简单等优点,因此在优化问

题中有着广泛的应用。

灰狼优化算法(gray wolf optimization algorithm, GWO)是一种群体智能搜索算法,借鉴了灰狼群体中的社会等级制度和捕食行为模式,具有较强的收敛性能和探索能力^[4]。但是随着维度和复杂性的增加,GWO算法会出现收敛速度慢、易陷入局部最优、寻优效果较差等问题,于是一些改进的算法被相继提出,一定程度上解决了上述问题。

为了降低GWO算法陷入局部最优的概率,王敏等^[5]设计了一种多样性变异算子,用于解决高维度函数优化问题,实验结果表明变异算子的引入能减少算法过早收敛,陷入局部最优。为了提高路径规划的收敛速度,曹建秋等^[6]

收稿日期:2021-12-04

* 基金项目:南昌航空大学研究生创新专项资金(YC2020-045)项目资助

提出了一种新型的修正变异方法,能起到优化路径与提升搜索质量的效果。柳长安等^[7]为提高算法搜索能力的问题,引进了一种非线性收敛因子和动静结合的位置更新策略,能得到质量较好的航迹。

为解决三维环境中GWO算法存在收敛速度慢和寻优性能不足的问题,本文提出了一种新型的灰狼优化算法(new gray wolf optimization algorithm,NGWO),首先通过基本函数测试证明了NGWO算法具有更快的收敛速度和更强的寻优能力,其次将该算法用来处理三维规划空间的航迹规划问题,通过航迹规划仿真实验证明了NGWO算法相对于其他算法能规划出收敛更快、消耗航迹代价更小的航迹。

1 无人机航迹规划建模

在无人机航迹规划问题中,建立无人机的规划空间环境和航迹评价指标是进行航迹规划的前提准备。

1.1 规划空间模型

不同的环境信息能够直接影响航迹规划的结果,也会影响执行任务的效果,因此对规划空间环境进行精准建模是十分重要的。考虑到数据存储和计算量的问题,本文采用栅格法来建立规划空间环境模型。

如图1所示,把三维直角坐标系O-XYZ中的空间区域OBCD-EFGH作为无人机航迹规划的整个空间,其中平面OBCD在平面XOZ上;然后沿着Y轴方向将整个空间分割成*l*个平面*s_j*(*j* = 1, 2, ..., *l*),再将平面进行*m* × *n*栅格等分,平面就变成了*m* × *n*个栅格,所以三维空间区域OBCD-EFGH可以用*l* × *m* × *n*个栅格来表示。无人机航迹规划过程中的所有节点均可用栅格坐标来*P*(*x_i*, *y_j*, *z_k*)表示,且位于平面*s_j*上^[8]。因此,无人机在三维空间OBCD-EFGH中的航迹规划可以表示为从起点开始,然后到达平面*s₁*上的*p₁*,再飞向平面*s₂*上的*p₂*,直到*s_l*平面的终点。




图 1 规划空间模型图

1.2 航迹评价指标

评价航迹规划算法的好坏的前提是建立航迹评价指标。航迹规划指标中包含了无人机自身的性能约束、算法

性能以及航迹代价。

1)性能约束

航迹质量和规划的可行性都受无人机自身的性能影响,无人机自身的性能约束主要考虑如下几个方面。

(1)最远航程约束

最远航程是由无人机的油耗和任务共同决定的。无人机执行飞行任务前首先需要考虑无人机的最远航程。假设无人机的最远航程为*l_{max}*,那么其约束条件如式(1)所示。

$$\sum_{i=1}^{l-1} \|P_i P_{i+1}\| \leq l_{max} \tag{1}$$

式中: $\|P_i P_{i+1}\|$ 表示航迹节点*i*与航迹节点*i+1*之间的距离,*P_i*为无人机的任务终点。

(2)角度约束

角度约束包含偏航角约束和俯仰角约束两部分。偏航角约束是指无人机在两个相邻航迹节点间飞行时转弯的角度是被限制的。与偏航角约束类似,俯仰角约束是指无人机在两个相邻航迹节点间飞行时垂直方向的角度只能在范围内变化,如果角度超出这个范围容易出现坠毁的危险。

如图2所示,将相邻节点间的航迹段投影到XOY平面,航迹段*i*是航迹节点*i-1*与航迹节点*i*之间的航迹,其水平投影*l_i* = (*x_i* - *x_{i-1}*, *y_i* - *y_{i-1}*),并且这两个航迹节点的纵向高度差为|*z_i* - *z_{i-1}*|,航迹段*i+1*的水平投影*l_{i+1}* = (*x_{i+1}* - *x_i*, *y_{i+1}* - *y_i*)。假设偏航角和俯仰角的最大值分别为*θ*、*φ*,那么偏航角约束和俯仰角约束可以分别用式(2)、(3)表示。

$$\cos\theta \leq \frac{a^2 + b^2 + c^2}{2ab} \tag{2}$$

$$\tan\varphi \geq \frac{|z_i - z_{i-1}|}{a} \tag{3}$$

其中,*a*是*l_i*的模长,*b*是*l_{i+1}*的模长。




图 2 角度约束示意图

(3)飞行高度约束

在规划空间中无人机的飞行高度应不低于最低飞行高度,使其不会因为过低飞行而撞击地面坠毁^[9]。其次,无人机航迹节点应该处于规划空间中,所以飞行高度应保持在最高飞行高度之下,该约束可用式(4)表示。

$$h_{min} \leq h_i \leq h_{max} \tag{4}$$

式中:*h_{min}*表示飞行高度最小值,*h_{max}*表示飞行高度最大值,*h_i*表示第*i*个航迹节点的飞行高度。

2)航迹代价函数

航迹代价函数是用于计算航迹总代价,从而评价改进算法性能的优劣的^[10]。无人机进行航迹规划的目的就是为了获得最小代价航迹。本文在航迹规划时考虑的综合代价函数如式(5)所示。

$$J_{\text{cost}} = \omega_1 J_1 + \omega_2 J_2 + \omega_3 J_3 \quad (5)$$

式中: J_{cost} 、 J_1 、 J_2 、 J_3 分别为航迹总代价、油耗代价、高度代价、威胁代价,其权重参数分别为 ω_1 、 ω_2 、 ω_3 , 且它们之和为 1。

(1)油耗代价

耗油量间接反映了无人机航程的长短,而航迹规划的目的之一就是节省油耗^[11]。为计算油耗代价,假定无人机在航迹规划的过程中保持匀速运动,那么油耗代价与航迹距离成正比。假设航迹是由 l 个节点组成的,则可以根据式(6)计算得到油耗代价 J_1 。

$$J_1 = k_1 \sum_{i=1}^{l-1} L_i \quad (6)$$

其中, k_1 为油耗系数, L_i 表示航迹节点 i 与航迹节点 $i+1$ 之间航迹段的长度。

(2)高度代价

当无人机的飞行高度超出规划空间时,可以用式(7)来计算高度代价 J_2 。

$$J_2 = \begin{cases} p_1(h_{\min} - h), & h \leq h_{\min} \\ 0, & h_{\min} < h < h_{\max} \\ p_2(h - h_{\max}), & h \geq h_{\max} \end{cases} \quad (7)$$

其中, p_1 和 p_2 均是比例系数。

(3)威胁代价

障碍物是无人机航迹规划不得不考虑的因素,如果障碍物距离无人机过近,会直接影响到航迹规划的可行性,所以在计算航迹代价时必须考虑障碍物产生的威胁代价。威胁代价 J_3 可以用式(8)表示。

$$J_3 = \sum_{i=1}^{l-1} L_i W_i \quad (8)$$

式中: W_i 表示航迹段 i 的威胁代价。

W_i 的表达式如式(9)所示。

$$W_i = \begin{cases} p_3 \sum_{j=1}^m \frac{1}{3} \left(\frac{1}{D_{m,i}} + \frac{1}{d_{m,i}} + \frac{1}{D_{m,i+1}} \right), & d_m \leq r \\ 0, & d_m > r \end{cases} \quad (9)$$

其中, p_3 是比例系数, $D_{m,i}$ 和 $D_{m,i+1}$ 分别表示航迹节点 i 、航迹节点 $i+1$ 与第 m 个障碍物之间的距离, $d_{m,i}$ 表示航迹段 i 的中点坐标与第 m 个障碍物之间的距离, d_m 表示航迹段 i 上的点与第 m 个障碍物之间的最小距离, r 表示障碍物威胁半径。

2 算法原理与分析

2.1 GWO 算法

GWO 算法是一种优化搜索方法,它借鉴了灰狼群体中的社会等级制度和捕食行为模式^[12]。在 GWO 算法中,狼群

被分为 α 、 β 、 δ 、 ω 四个等级,其中 α 狼负责做出决策, β 狼协助 α 狼做出决策并服从于它, δ 狼遵守 α 和 β 狼的指令,可以管理 ω 狼。灰狼在捕食时,是通过猎物的气味锁定猎物的,灰狼群体包围猎物后会逐渐靠近猎物,最终攻击猎物。

在使用灰狼优化算法求解寻优问题时,首先假设在 G 维空间中存在 N 只灰狼,其中第 i 只灰狼的坐标可以表示为 $\mathbf{X}_i = (\mathbf{X}_{i1}, \mathbf{X}_{i2}, \dots, \mathbf{X}_{iG})$, 它在包围猎物时的位置更新公式如式(10)所示。

$$\mathbf{X}_i(t+1) = \mathbf{X}_p(t) - \mathbf{A}_i \cdot |\mathbf{C}_i \mathbf{X}_p(t) - \mathbf{X}_i(t)| \quad (10)$$

式中: $\mathbf{X}_p(t)$ 表示猎物在第 t 代时的位置, $\mathbf{X}_i(t)$ 表示第 i 只灰狼在第 t 代时的位置。

协同系数 \mathbf{A}_i 和 \mathbf{C}_i 分别为:

$$\mathbf{A}_i = 2ar_1 - a \quad (11)$$

$$\mathbf{C}_i = 2r_2 \quad (12)$$

其中, r_1 和 r_2 是 $[0,1]$ 中的随机变量, a 是收敛因子,其表达式如式(13)所示。

$$a = 2 - \frac{t}{t_{\max}} \quad (13)$$

式中: t 和 t_{\max} 分别表示当前和最大迭代次数。

灰狼群体是根据 α 、 β 、 δ 的位置 \mathbf{X}_α 、 \mathbf{X}_β 和 \mathbf{X}_δ 来更新所有个体的位置,其更新公式如式(14)所示。

$$\begin{cases} \mathbf{X}_1(t) = \mathbf{X}_\alpha - \mathbf{A}_1 \cdot |\mathbf{C}_1 \mathbf{X}_\alpha - \mathbf{X}(t)| \\ \mathbf{X}_2(t) = \mathbf{X}_\beta - \mathbf{A}_2 \cdot |\mathbf{C}_2 \mathbf{X}_\beta - \mathbf{X}(t)| \\ \mathbf{X}_3(t) = \mathbf{X}_\delta - \mathbf{A}_3 \cdot |\mathbf{C}_3 \mathbf{X}_\delta - \mathbf{X}(t)| \\ \mathbf{X}(t+1) = (\mathbf{X}_1(t) + \mathbf{X}_2(t) + \mathbf{X}_3(t))/3 \end{cases} \quad (14)$$

2.2 NGWO 算法

虽然 GWO 算法具有强收敛性、参数少等优点,但是 GWO 算法应用于三维航迹规划时会产生一系列问题^[13]。当 GWO 算法初始化种群时,无序的种群个体会减慢算法的收敛速度;其次,收敛因子 a 是线性变化的,与算法的收敛趋势不一致,会导致算法的开发能力不足。此外,由于 GWO 算法的位置更新策略不灵活,有时无法摆脱局部最优解。针对上述问题,本文对 GWO 算法进行了如下改进。

1)反向学习策略

由文献[14]可知,算法的收敛性能与初始种群的多样性之间为正相关。因此,本文通过反向学习策略来得到一个多样性较好的初始化种群。

定义 1 假设 y 是区间 $[a, b]$ 中的一个实数,那么它的反解为:

$$y' = a + b - y \quad (15)$$

根据定义 1,利用反向学习初始化种群的步骤如下:

(1)在规划空间中随机选取 N 个点,作为初始种群中所有灰狼的位置坐标;

(2)对初始种群中的所有位置坐标均进行反解,得到反向种群;

(3)合并两个种群,所有灰狼中适应度值较小的前 N 个个体将作为最终初始种群的成员。

2) 新型非线性收敛因子

GWO 算法协调好全局搜索和局部搜索能力有利于更好的寻优。由文献 [15] 可知, A 值的大小间接影响着 GWO 算法的寻优性能。在迭代过程中, 算法是非线性变化的, 但是由式 (11) 可知 A 是随收敛因子 a 线性变化的, 无法满足实际情况。因此, 本文引进了一种新型非线性收敛因子, 表达式为式 (16) 所示。

$$a = \begin{cases} 1 + \cos \frac{2(t-1)\pi}{t_{\max} - 1}, & 1 \leq t \leq \frac{t_{\max}}{4} \\ 0.0002t^2 - \frac{11}{300}t + 2.4, & \frac{t_{\max}}{4} < t \leq t_{\max} \end{cases} \quad (16)$$

3) 位置更新策略的优化

在 GWO 算法迭代的后半部分过程中, 种群的所有个体都会向最优解区域移动, 多样性也会随之减少。如果最优解只是局部最优, 那么所有个体将陷入局部最优。为了降低算法出现局部最优的风险, 本文对位置更新策略进行了调整, 增加了种群的多样性, 其公式如式 (17) 所示。

$$\mathbf{X}_i(t+1) = \begin{cases} \sum_{i=\alpha, \beta, \delta} \frac{f(\mathbf{X}_i(t))\mathbf{X}_i(t)}{\mathbf{F}(t)}, & \Delta\mathbf{X}_i(t) > u \\ \mathbf{X}_i(t) + r_3\Delta\mathbf{X}_j(t), & \Delta\mathbf{X}_i(t) \leq u \end{cases} \quad (17)$$

其中, $f(\mathbf{X}_i(t))$ 是指第 t 代时第 i 只灰狼的适应度值, u 是位置阈值, r_3 是区间 $[0, 1]$ 中的随机变量, $\Delta\mathbf{X}_j(t)$ 的表达式如式 (18) 所示; $\mathbf{F}(t)$ 表示第 t 代时 α, β, δ 的适应度值之和, 如式 (19) 所示; $\Delta\mathbf{X}_i(t)$ 表示 α 和 δ 的适应度值差的绝对值, 如式 (20) 所示。

$$\Delta\mathbf{X}_j(t) = \sum_{j=1}^3 (\mathbf{X}_j(t+1) - \mathbf{X}_j(t)) / 3 \quad (18)$$

$$\mathbf{F}(t) = f(\mathbf{X}_\alpha(t)) + f(\mathbf{X}_\beta(t)) + f(\mathbf{X}_\delta(t)) \quad (19)$$

$$\Delta\mathbf{X}_i(t) = |f(\mathbf{X}_\alpha(t)) - f(\mathbf{X}_\delta(t))| \quad (20)$$

4) 精英选择保留策略

结合遗传算法中的精英保留策略和锦标赛选择策略, 以适应度值大小实行优胜劣汰规则, 在按照式 (16) 更新完所有灰狼个体的位置后, 从更新后的种群中选择一定数量

的个体, 计算选择个体的适应度值, 如果上一代对应个体的适应值小于更新之后该个体的适应度值, 则保留上一代的精英个体, 采用这种策略方法会促使种群朝着最优解进化。

2.3 算法分析

本文为证实改进之处可以加快 GWO 算法的收敛速度和增强 GWO 算法的寻优能力, 采用基础函数 Rastrigin、Quartic 进行相关测试。

测试函数 Rastrigin 和 Quartic 的全局最优值均为 0, 它们的表达式如式 (21)、(22) 所示。

$$f_1(x, y) = 20 + x^2 + y^2 - 10(\cos(2\pi x) + \cos(2\pi y)) \quad (21)$$

$$f_2(x) = \sum_{i=1}^n ix_i^4 + rand() \quad (22)$$

为验证 NGWO 算法的寻优效果, 分别利用 NGWO、GWO、ACO 和 BAS 算法在维数 Dim 为 2、30、50 时对 Rastrigin 和 Quartic 函数进行了 30 次寻优仿真实验。表 1 和 2 分别表示 4 种算法对测试函数 Rastrigin、Quartic 的寻优结果。

表 1 4 种算法对测试函数 Rastrigin 的寻优结果

维数	算法	平均值	最优值	最差值	标准差	时长
Dim=2	NGWO	0	0	0	0	0.04
	GWO	0	0	0	0	0.05
	ACO	0	0	0	0	0.06
	BAS	19.0	1.99	51.7	16.2	0.02
Dim=30	NGWO	0	0	0	0	0.09
	GWO	12.5	7.43	19	4.04	0.21
	ACO	125.3	71.6	137	34.2	0.42
	BAS	396.3	312.7	446.9	38.5	0.06
Dim=50	NGWO	0	0	0	0	0.36
	GWO	29	14.8	42.7	9.49	0.55
	ACO	273.2	226.7	351.5	36.6	0.67
	BAS	759	734.2	825.2	27	0.21

表 2 4 种算法对测试函数 Quartic 的寻优结果

维数	算法	平均值	最优值	最差值	标准差	时长
Dim=2	NGWO	1.50×10^{-4}	1.97×10^{-5}	7.31×10^{-4}	2.02×10^{-4}	0.01
	GWO	4.10×10^{-4}	1.30×10^{-4}	1.44×10^{-3}	3.81×10^{-4}	0.13
	ACO	8.82×10^{-4}	7.09×10^{-5}	2.52×10^{-3}	6.94×10^{-4}	0.14
	BAS	0.081	5.51×10^{-3}	0.43	0.12	0.05
Dim=30	NGWO	2.34×10^{-4}	2.38×10^{-5}	6.50×10^{-4}	1.81×10^{-4}	0.16
	GWO	7.90×10^{-3}	2.67×10^{-3}	1.58×10^{-2}	3.76×10^{-3}	0.19
	ACO	0.92	0.27	1.60	0.4	0.23
	BAS	104.4	60.9	188.4	37.1	0.12
Dim=50	NGWO	1.06×10^{-4}	1.20×10^{-6}	3.59×10^{-4}	1.09×10^{-4}	0.40
	GWO	1.24×10^{-2}	7.29×10^{-3}	2.04×10^{-2}	4.34×10^{-3}	0.45
	ACO	135.1	32.9	303.5	69.7	0.51
	BAS	427	284.8	544.4	74.6	0.24

由表1测试数据可知,当测试函数为 Rastrigin 时, GWO 算法只能在维数为 2 时才能收敛到最优解,而 NGWO 算法在不同维数下均收敛到最优解且收敛速度是这 4 种算法中最快的。

由表 2 测试数据可知,当测试函数为 Quartic 时, NGWO 算法在 3 种维数中的收敛速度均比 GWO 算法更快,而且 NGWO 算法的寻优结果是 4 种算法中最好的,能得到质量较高的解,也是最接近最优解的。

在进行收敛性测试时,选择维度 $Dim = 30$, 根据寻优测试的结果,计算获得每种算法在每个迭代次数的 20 次平均适应度值。NGWO、GWO、ACO 和 BAS 算法在 Rastrigin 和 Quartic 函数中的平均适应度值对比分别如图 3、4 所示。

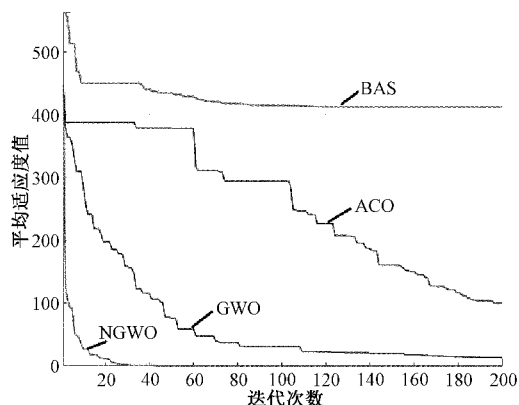


图 3 4 种算法在 Rastrigin 函数中的平均适应度值对比图




图 4 4 种算法在 Quartic 函数中的平均适应度值对比图

2.4 NGWO 用于航迹规划的优化

NGWO 算法可用于解决复杂三维环境下无人机的航迹规划问题,可以寻找到一条满足各种约束条件且飞行代价最小的航迹,具体流程如图 5 所示。

NGWO 算法进行航迹规划的过程如下。

步骤 1: 设置算法的最大迭代次数 t_{max} 、种群规模 N 、收敛因子 a 初始值、位置阈值 u 等参数以及初始化三维空间模型。

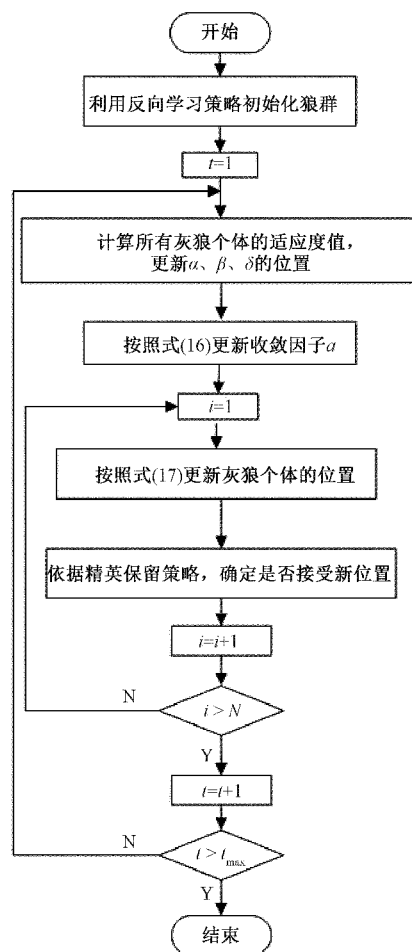


图 5 NGWO 算法用于优化航迹规划的流程

步骤 2: 在规划空间中,首先利用反向学习初始化灰狼群体,此时迭代次数 t 记为 1。

步骤 3: 计算所有灰狼的适应度值,并将前 3 的个体记为 α, β, δ 。

步骤 4: 按照式(16)更新收敛因子 a , 再通过式(11)计算出 A 。

步骤 5: 按照式(17)计算出下一代所有灰狼个体的新位置。

步骤 6: 依据精英保留策略,确定是否要保留精英灰狼个体。

步骤 7: 令 $t = t + 1$, 判断 t 是否大于 t_{max} , 若是则算法结束并输出规划航迹; 否则返回步骤 3。

3 仿真实验

在规划空间中进行航迹规划仿真实验,设置任务的起点为 $S(1, 15, 3)$, 终点为 $T(21, 9, 6)$, 最远航程 $l_{max} = 200$, 最大俯仰角 $\varphi = 45^\circ$, 最大偏航角 $\theta = 60^\circ$, 3 种代价占航迹总代价的权重参数分别为 $\omega_1 = 0.6, \omega_2 = 0.2, \omega_3 = 0.2$, 油耗系数 $k_1 = 1.0$, 高度代价中的比例系数 $p_1 = p_2 = 0.5$,

威胁代价中的比例系数 $p_3 = 1$, 灰狼种群数量 $N = 15$, 最大迭代次数 $l_{max} = 200$, 位置更新策略中的位置阈值 $u = 5$ 。

将 NGWO、GWO、ACO、BAS 算法基于上述环境进行航迹规划, 规划结果的侧视图和俯视图分别如图 6 和 7 所示, 4 种算法规划的这些航路均成功地避开了障碍物, 但相比于其他算法规划的航路, NGWO 算法规划的航程更短, 对应的油耗代价也会较低, 转弯次数也是最少的, 航路质量明显更优。

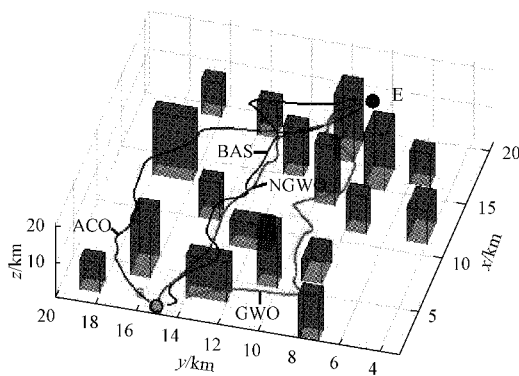


图 6 三维航迹规划侧视图

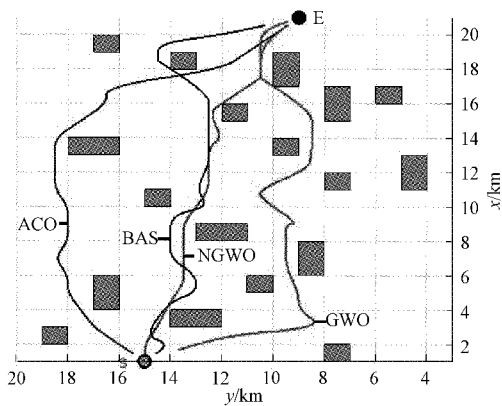


图 7 三维航迹规划俯视图

在航迹规划仿真实验中, 为了比较验证算法的收敛速度和航迹代价函数值, 通过多次仿真实验的数据结果求取各算法代价函数值, 得到航迹代价对比曲线, 如图 8 所示。由图 8 可知, NGWO 算法在航迹代价和收敛速度方面明显优于其他 3 种算法, 并且算法的稳定性更好。

此外, 将这 4 种算法分别执行 20 次, 选取最优解中的最小值、最大值并计算平均值和标准差。由表 3 可知, NGWO 算法的最小最优解和最大最优解均小于其他算法, 并且根据表 3 可以计算出 NGWO 算法规划航迹所需的平均代价值比 GWO 算法少 19.9%, 说明 NGWO 算法在寻优性能方面比其他算法更好; 而平均最优解和标准差的对比说明 NGWO 在稳定性方面有较大的优势。




图 8 航迹代价变化曲线对比图

表 3 算法统计结果对比

算法	最大最优值	最小最优值	平均最优值	标准差
NGWO	17.2	16.4	16.9	0.32
GWO	21.8	20.4	21.1	0.62
ACO	49.5	46.5	48.5	1.08
BAS	87.4	72.3	79.1	5.55

4 结 论

本文提出了一种新型灰狼优化算法, 并应用于复杂环境中的无人机航迹规划问题。该算法为生成有序的灰狼个体, 在初始化部分使用了反向学习策略, 从而增强算法的收敛速度和寻优能力; 同时改进收敛因子和个体位置的更新公式, 提高了算法的探索能力, 有效防止局部最优; 融合精英保留策略和锦标赛选择法, 促使所有种群个体均加速朝着全局最优解靠近。在算法分析部分, 通过基础测试函数验证了算法改进之处有助于提高收敛速度和寻优性能。航迹规划仿真实验结果表明, 在 4 种算法中新型灰狼优化算法能规划出收敛速度更快、总代价更小的航迹路线。

参考文献

- [1] 赵丽华, 万晓冬. 基于改进 A 算法的多无人机协同路径规划[J]. 电子测量技术, 2020, 43(7): 72-75, 166.
- [2] 王宁, 代冀阳, 应进, 等. 基于自适应扩展势场的多无人机航迹规划仿真[J]. 系统仿真学报, 2021, 33(9): 2147-2156.
- [3] 刘耀, 毛剑琳. 动态环境下基于改进蚁群算法的路径规划研究[J]. 电子测量技术, 2020, 43(7): 82-87.
- [4] 李全耀, 沈艳霞. 一种基于教与学的混合灰狼优化算法[J/OL]. 控制与决策, 2021: 1-7[2021-11-27].
- [5] 王敏, 唐明珠. 一种新型非线性收敛因子的灰狼优化算法[J]. 计算机应用研究, 2016, 33(12): 3648-3653.
- [6] 曹建秋, 张广言, 徐鹏. A^{*} 初始化的变异灰狼优化的无人机路径规划[J/OL]. 计算机工程与应用, 2021: 1-12[2021-11-27].

- [7] 柳长安,王晓鹏,刘春阳,等. 基于改进灰狼优化算法的无人机三维航迹规划[J]. 华中科技大学学报(自然科学版),2017,45(10):38-42.
- [8] 张宏宏,甘旭升,李双峰,等. 复杂低空环境下考虑区域风险评估的无人机航路规划[J]. 仪器仪表学报,2021,42(1):257-266.
- [9] 李银通,韩统,聂光戌,等. 多UCAV协同打击多目标实时三维航迹规划[J]. 哈尔滨工业大学学报,2021,53(6):128-137.
- [10] 吴文海,郭晓峰,周思羽. 基于改进约束差分进化算法的动态航迹规划[J]. 控制与决策,2020,35(10):2381-2390.
- [11] 李志锃,黄宜庆,徐玉琼. 改进变步长蚁群算法的移动机器人路径规划[J]. 电子测量与仪器学报,2020,34(8):15-21.
- [12] 张新明,杨方圆,刘国奇. 多策略的郊狼优化算法[J/OL]. 计算机应用研究,2021:1-8[2021-11-27].
- [13] 郝芑斐,池瑞,屈志坚,等. 求解铁路物流配送中心选址问题的改进灰狼优化算法[J]. 计算机应用,2021,41(10):2905-2911.
- [14] 王刚,张方,严大亮,等. 基于改进蚁群算法的机器人三维路径规划[J]. 国外电子测量技术,2020,39(11):1-6.
- [15] 刘宁宁,王宏伟. 基于改进灰狼优化算法的移动机器人路径规划[J]. 电测与仪表,2020,57(1):76-83,98.

作者简介

许乐,硕士研究生,主要研究方向为无人机航迹规划算法、智能控制与应用等。

E-mail:2871185406@qq.com

赵文龙,硕士,教授,主要研究方向为嵌入式技术及应用、智能控制与应用等。

E-mail:3347841990@qq.com