

DOI:10.19651/j.cnki.emt.2417117

基于多策略改进灰狼算法的无人机路径规划^{*}

宋宇 高岗 梁超 徐军生

(长春工业大学计算机科学与工程学院 长春 130012)

摘要: 针对传统的灰狼算法在三维路径规划中容易陷入局部最优等问题,本文提出了一种改进的灰狼算法。首先,对三维威胁区域进行环境建模,对约束条件规定无人机飞行的总成本函数;其次,在灰狼种群初始化中加入了混沌序列和准反向学习策略,增加了种群多样性以及未知领域的搜索范围,通过对自适应权重因子的改进来更新个体位置,从而加快收敛速度;最后,为了避免陷入局部最优,引入了粒子群算法从而平衡全局开发与局部收敛。通过实验结果表明,相较于另外3种典型路径规划算法,改进灰狼算法可以寻找出一条安全可行的路径,并且有着较稳定的寻优能力。

关键词: 无人机;三维路径规划;混沌序列;准反向学习;灰狼算法;粒子群算法

中图分类号: TP301.6;TN911.7 **文献标识码:** A **国家标准学科分类代码:** 510.1050

UAV path planning based on multi-strategy improved gray wolf algorithm

Song Yu Gao Gang Liang Chao Xu Junsheng

(School of Computer Science and Engineering, Changchun University of Technology, Changchun 130012, China)

Abstract: Aiming at the problem that traditional grey wolf algorithm is prone to local optimality in 3D path planning, an improved grey wolf algorithm is proposed in this paper. Firstly, the environment of the three-dimensional threat region is modeled, and the total cost function of UAV flight is specified under the constraint conditions. Secondly, chaotic sequences and quasi-reverse learning strategies were added to the initialization of grey wolf population, which increased the diversity of species and the search scope of unknown domain, and improved the adaptive weight factors to update individual positions, thus speeding up the convergence speed. Finally, in order to avoid falling into local optimization, particle swarm optimization algorithm is introduced to balance global development and local convergence. The experimental results show that compared with the other three typical path planning algorithms, the improved gray wolf algorithm can find a safe and feasible path, and has a stable optimization ability.

Keywords: UAV; three-dimensional path planning; chaotic sequence; quasi-reverse learning; grey wolf algorithm; article swarm optimization

0 引言

随着科技的不断进步,无人机因为可以执行一些高风险的任务而备受关注,如情报、监视、侦察、救援等^[1]。在无人机任务规划系统中,路径规划是一项至关重要的任务,主要目的是根据任务要求和飞行约束,自主搜索从初始目标点到最终目标点的最优路径^[2]。在过去几年中,为了解决这一问题,研究者已经提出了多种方法。如人工势场算法^[3]、A*算法^[4]、快速探索随机树^[5]等一些传统算法,但这些算法都有本身的局限性,对复杂的地形应用不能很好的解决。相反,元启发式算法擅长解决这些问题^[6],因为它们简单、灵活、无需推导。目前已经开发了大量的元启发算

法,如文献[7]中提出了改进的蜚螂优化算法,加入Bernoulli混沌映射策略增加蜚螂种群的多样性,使其收敛速度更快。文献[8]中提出了一种改进麻雀搜索算法,采用柯西-高斯突变策略,增强算法摆脱停滞的能力。以上算法在应用于无人机路径规划方面的效果比改进之前效果更好,但不能证明这些算法的寻优稳定性和路径质量都是最好的。其寻优稳定性和在不同环境模型下路径规划质量有待提高,不同策略在不同环境模型下改进算法仍然具有研究意义。

灰狼优化算法(grey wolf optimizer, GWO)模仿灰狼的狩猎行为和社会领导能力,具有很强的探索能力。与传统算法相比,启发式算法具有结构简单、参数少和易于实现

收稿日期:2024-10-15

^{*} 基金项目:吉林省科技发展计划项目(20220201030GX)资助

的优点^[9]。Yu等^[10]中提出一种灰狼算法和差分进化相结合方法,对其中变异算子的改进,使赋予排名靠前的狼群更高的选择概率,使算法能够更好地跳出局部最优解,但并没有考虑种群多样性问题,使得全局搜索能力较差;Zhang等^[11]设计一种改进自适应的GWO,通过动态调整非线性收敛因子,使有效避免算法在后期陷入局部最优;卢颖等^[12]引入了莱维飞行来优化灰狼算法,提高了灰狼的全局探索和局部开发能力,但在算法的收敛能力上有待改进;Qu等^[13]把MOSS算法结合到了GWO算法当中,从而增强了局部开发能力,能够更好地利用搜索空间中的信息;陈福金^[14]加入了反向学习策略改进灰狼优化算法,优化了物种搜索速度较慢问题,但环境设置不够理想。以上文献对GWO算法进行了不同程度的改进,但仍存在种群多样性差、复杂度高、和收敛慢等问题。

在已有研究成果的基础上,如何进一步加快收敛速度,提高解的最优性是本文研究的主要动机。所以,本文提出了一种改进的灰狼算法,首先将混沌序列和准反向学习的方法引入到灰狼种群初始化中,增加了种群的多样性,使算法增大了对解空间的搜索范围;其次通过对自适应权重因子来改进更新个体位置,从而加快收敛速度并提升了全局寻优能力;最后为了避免陷入局部最优,引入了PSO算法,从而平衡全局开发和局部收敛能力。

1 路径规划模型和适应度函数

1.1 数学建模

在模型中,无人机的起始点和目标点用 $S(x_s, y_s, z_s)$ 和 $T(x_T, y_T, z_T)$ 表示,飞行环境中的威胁源表示为圆形区域,每个圆的半径为该威胁源的最大影响距离,如果路径在威胁区域经过,无人机将受到不同程度的损坏^[15],如图1所示。

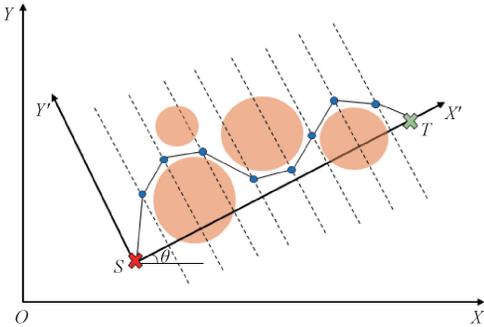


图1 路径规划示意图

Fig.1 Path planning diagram

起始点和目标点分别用 S 和 T 表示,连接线段定义为 ST 。线段 ST 被 n 个点平均分成 $n+1$ 等分。在 n 点处绘制通过 ST 线的垂直线,垂直线定义为 $L_1, L_2, \dots, L_k, \dots, L_D (k=1, 2, \dots, D)$,在每条垂直线上取点 $p_k: (x_k, y_k, z_k)^T, k=1, 2, \dots, D$,并将这些点连接起来,形成一条从 S

到 T 的可行路径。为了计算方便,通过平移和旋转表示为 XOY 的坐标系,得到新的坐标系,表示为 $X'S'Y'$,其横坐标与 ST 重合。 XOY 到 $X'S'Y'$ 的旋转角度为 θ ,可表示为:

$$\theta = \arctan\left(\frac{y_T - y_S}{x_T - x_S}\right) \quad (1)$$

因此,路径规划问题被视为坐标优化问题,以获得更优的飞行路径。将线段 ST 作为新的 x 轴,每个路径点 p_k 需要根据式(1)进行坐标变换:

$$\begin{bmatrix} x'_k \\ y'_k \\ z'_k \end{bmatrix} = \begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \\ 0 & 0 \end{bmatrix} \begin{bmatrix} x_k - x_S \\ y_k - y_S \\ z_k - z_S \end{bmatrix} \quad (2)$$

其中, θ 表示旋转的角度, $[x'_k, y'_k, z'_k]^T$ 表示旋转坐标后的路径。

然后,设置搜索空间用来限制下界和上界。这些界限由距离线段 ST 最大威胁决定,无人机飞行时不能超出所设置界限。 P_{\min} 和 P_{\max} 定义如下:

$$P_{\min} = \min\{\min\{y_{i,i}^* - R_i\}, 0\} - \Delta d \quad (3)$$

$$P_{\max} = \max\{\max\{y_{i,i}^* + R_i\}, 0\} + \Delta d \quad (4)$$

其中, R_i 是第 i 个威胁的半径; $y_{i,i}^*$ 是坐标变换后第 i 个威胁点的纵坐标; Δd 是可定义距离。

1.2 适应度函数

无人机路径规划的约束条件主要包括威胁成本和能源消耗,飞行成本适应度函数定义为^[16]:

$$J_{\text{cost}} = \lambda \cdot J_i + (1 - \lambda) \cdot J_f \quad (5)$$

其中, J_{cost} 为飞行路径上的加权总成本; $\lambda \in (0, 1)$ 是一个权重参数,用于调整威胁成本与能源消耗之间的比例。当 λ 接近于0时,在路径规划过程中更注重考虑能源消耗,使无人机获得尽可能短的路径,当 λ 接近1时,在路径规划过程中更注重威胁成本,使无人机获得尽可能安全的路径。

J_f 为能源 J_i 为威胁成本之如下:

$$J_i = \int_0^{\text{length}} W_i dl \quad (6)$$

$$J_f = \int_0^{\text{length}} W_f dl \quad (7)$$

$$W_{i,k} = \frac{l_k}{5} \cdot \sum_{i=1}^m \frac{r_i}{10} \cdot \left(\frac{1}{d_{0,i}^k} + \frac{1}{d_{0.25,i}^k} + \frac{1}{d_{0.5,i}^k} + \frac{1}{d_{0.75,i}^k} + \frac{1}{d_{1,i}^k} \right) \quad (8)$$

其中, length 表示所创建路径的长度,即能源成本; m 是威胁圆的个数; r_i 是第 i 个威胁的半径; $d_{0.25,i}^k$ 表示第 i 条子路径0.25处和第 k 个威胁中心的欧式距离。

2 算法描述

2.1 PSO算法

粒子群算法(particle swarm optimization, PSO)是一种基于群体智能的优化方法,它模仿自然界中鸟群、鱼群等

生物群体的觅食行为来寻找全局最优解。其基本原理是通过群体中个体之间的协作和信息共享来寻找最优解。 $X_i(t)$ 和 $V_i(t)$ 表示在第 t 次迭代时第 i 个粒子的位置向量和速度向量,更新公式如下:

$$V_i(t+1) = \omega V_i(t) + c_1 r_1 (Pbest_i(t) - X_i(t)) + c_2 r_2 (Gbest(t) - X_i(t)) \quad (9)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (10)$$

其中, $Pbest_i(t)$ 和 $Gbest(t)$ 表示在第 t 次迭代时第 i 个粒子的个体最佳位置和群体的全局最佳位置; ω 是惯性权重; c_1 和 c_2 表示认知学习因子和社会学习因子; r_1 和 r_2 表示在 $[0, 1]$ 内均匀分布的随机数。

2.2 GWO 算法

灰狼优化算法通过模拟灰狼种群的性质、内部机制和狩猎行为,构建了严格的灰狼种群分层任务体系。在灰狼优化算法中,灰狼种群按类别分为 α, β, δ 和 ω 四类, α 狼的位置被定义为最优解, β 狼的位置被定义为次优解。 δ 狼的位置是第三优解,其他候选解则是剩余 ω 狼。灰狼在群体狩猎时,主要行为包括包围、捕猎和攻击猎物。灰狼种群在猎物周围的行为可以用以下公式来描述:

$$D = |C \times X_p(t) - X_i(t)| \quad (11)$$

$$X_i(t+1) = X_p(t) - A \times D \quad (12)$$

其中, D 表示个体与目标之间的距离; t 是当前迭代次数; $X_p(t)$ 是猎物第 t 次迭代的位置坐标; $X_i(t+1)$ 是位置向量迭代之后的第 i 个狼; A 和 C 为系数向量,表示如下:

$$A = 2a \times rand_1 - a \quad (13)$$

$$C = 2 \times rand_2 \quad (14)$$

$$a = 2 - \frac{2t}{t_{\max}} \quad (15)$$

其中, $rand_1$ 和 $rand_2$ 是 $[0, 1]$ 范围内的随机数; a 是收敛因子; t_{\max} 为最大迭代次数。

在随机寻找猎物的过程中,种群中的灰狼个体会根据离猎物最近的个体位置实时调整自己的位置,然后逐渐向猎物位置靠近。灰狼种群位置的更新过程可描述为:

$$\begin{cases} D_\alpha = |C_1 \times X_\alpha(t) - X_i(t)| \\ D_\beta = |C_2 \times X_\beta(t) - X_i(t)| \\ D_\delta = |C_3 \times X_\delta(t) - X_i(t)| \end{cases} \quad (16)$$

$$\begin{cases} X_{i,\alpha}(t+1) = X_\alpha(t) - A_1 \times D_\alpha \\ X_{i,\beta}(t+1) = X_\beta(t) - A_2 \times D_\beta \\ X_{i,\delta}(t+1) = X_\delta(t) - A_3 \times D_\delta \end{cases} \quad (17)$$

$$X_i(t+1) = \frac{X_{i,\alpha} + X_{i,\beta} + X_{i,\delta}}{3} \quad (18)$$

其中, C_1, C_2, C_3 和 A_1, A_2, A_3 是随机向量; $X_i(t)$ 是当前位置向量中的第 i 只狼; $X_\alpha(t)$ 表示 α 狼的当前位置; $X_\beta(t)$ 表示 β 狼的当前位置; $X_\delta(t)$ 表示 δ 狼的当前位置; 式(17)描述了 α 狼, β 狼和 δ 狼之间的距离; 式(18)定义了灰狼个体的最终位置。

3 改进灰狼优化算法

当面对多维复杂优化问题时,灰狼优化算法容易出现早熟并且容易陷入局部最优。为了克服这些问题,本文将改进 GWO 进行改进,通过 3 种方式来进一步优化算法在实际应用中的性能。

3.1 混沌序列和准反向学习初始化种群策略

1) 本文借助混沌序列对种群进行初始化,在提升种群的多样性及个体间的随机分布特性。这一策略有助于更全面地探索未知区域,增加问题的解空间,进而强化算法的全局搜索效能,提高发现更优解的概率。此外,混沌序列赋予的随机性还能有效降低算法陷入局部最优解的风险。基于上述分析,本文在初始化阶段加入了 Tent 混沌序列,表达式如下:

$$Z_{k+1} = \begin{cases} Z_k/\beta, & Z_k \in (0, \beta] \\ (1-Z_k)/(1-\beta), & Z_k \in (\beta, 1] \end{cases} \quad (19)$$

其中, Z_k 为第 k 代混沌序列产生的值; β 为参数范围,本文设置 $\beta = 0.5$ 。

如图 2 所示,通过 Tent 混沌映射后产生的随机数在 $[0, 1]$ 区间更加均匀。

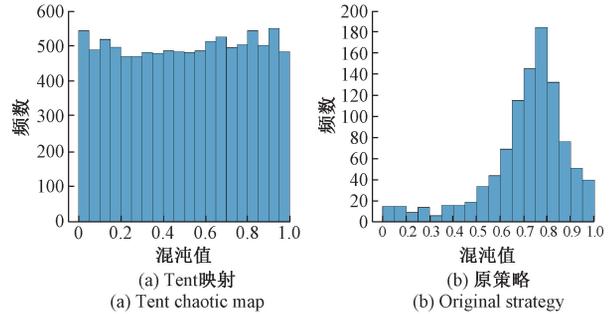


图 2 混沌值分布图

Fig. 2 Chaotic value distribution diagram

2) 为了更好的提高初始种群的质量,本文在 Tent 混沌映射的基础上加入准反向学习,初始种群 $X_i = \{x_{i1}, x_{i2}, \dots, x_{id}\}$, ($i = 1, 2, \dots, NP$) 是在搜索空间中随机生成的,其中 D 是解决问题的维度, NP 是种群大小,这个种群被用来繁衍后代^[17]。这里介绍的准反向学习策略公式如下:

$$X_{oi}(t) = rand \left\{ \frac{L_b + U_b}{2}, X_i(t) \right\} \quad (20)$$

$$X_i(t) = L_b + U_b - X(t) \quad (21)$$

其中, U_b 和 L_b 分别是第 b 维的上界和下界; $X(t)$ 为原始值; $X_i(t)$ 为反向学习的解; $X_{oi}(t)$ 为准反向学习解。如图 3 所示,可以看出准反向学习是对反向学习进行进一步的随机化运算,与其每一次生成的映射都是一个给定的数值相比,准反向学习生成的映射 $X_{oi}(t)$ 在解空间上、下限与反向学习映射 $X_i(t)$ 间随机分配。

3.2 自适应权重因子更新位置策略

根据式(18),狼的最终位置是由 α, β 和 δ 狼的平均步

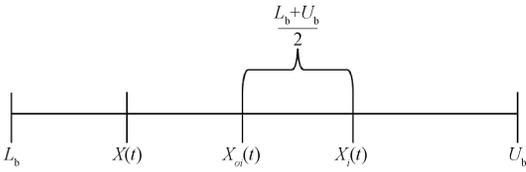


图 3 准反向学习示意图

Fig. 3 Quasi-reverse learning diagram

长和方向决定的。但在实际环境中,由于灰狼种群具有严格的等级机制, α 、 β 和 δ 狼对灰狼种群的影响是不同的。因此,在算法的位置更新公式中引入了自适应权重因子策略。在此策略中,提出了离心距离变化率的概念。从平均离心距离和最大离心距离可以计算出每个个体当前离心距离的变化率。离心距离实际上是种群中个体与历史最优位置之间的空间距离。并且可以有效地反映候选解的动态分布,并利用离心距离变化率设计自适应权重因子。这样,在迭代过程中,个体灰狼的位置可以随着种群的整体收敛程度而动态更新,从而有效地提高了算法的优化性能。

在实际环境的复杂性导致 α 狼不一定是全局最优解。所以,还需要知道每个个体与 β 狼和 δ 狼的距离有多近。计算每个个体到 α 、 β 和 δ 的离心距离的公式如下:

$$dist_{x_{ave}} = \frac{\sum_{i=1}^N \sqrt{\sum_{d=1}^D (X_i^d - X_x^d)^2}}{N} \quad (22)$$

$$dist_{x_{max}} = \max_{i=1,2,\dots,N} \left(\sqrt{\sum_{d=1}^D (X_i^d - X_x^d)^2} \right) \quad (23)$$

其中, $x = \alpha, \beta, \delta$; X_i^d 是个体 i 的 D 维位置向量; X_x^d 是个体 X 的 D 维位置向量;这是历史最优的位置向量。每个个体的当前离心距离相对于 α 、 β 和 δ 的变化率可以表示为:

$$\lambda_\alpha = \frac{dist_{\alpha_{max}} - dist_{\alpha_{ave}}}{dist_{\alpha_{max}}} \quad (24)$$

$$\lambda_\beta = \frac{dist_{\beta_{max}} - dist_{\beta_{ave}}}{dist_{\beta_{max}}} \quad (25)$$

$$\lambda_\delta = \frac{dist_{\delta_{max}} - dist_{\delta_{ave}}}{dist_{\delta_{max}}} \quad (26)$$

其中, λ_α 表示灰狼个体相对于 α 狼的离心距离的变化; λ_β 表示灰狼个体相对于 β 狼的离心距离的变化; λ_δ 表示灰狼个体相对于 δ 狼的离心距离的变化。然后,可以根据当前每个个体相对于 α 、 β 和 δ 的离心距离变化率设计以下自适应权重因子:

$$\omega_1 = \frac{\lambda_\alpha}{\lambda_\alpha + \lambda_\beta + \lambda_\delta} \quad (27)$$

$$\omega_2 = \frac{\lambda_\beta}{\lambda_\alpha + \lambda_\beta + \lambda_\delta} \quad (28)$$

$$\omega_3 = \frac{\lambda_\delta}{\lambda_\alpha + \lambda_\beta + \lambda_\delta} \quad (29)$$

其中, ω_1 表示 α 狼对其他狼的影响程度; ω_2 表示 β 狼对其他狼的影响程度; ω_3 表示 δ 狼对其他狼的影响程度。

结合所设计的自适应权重因子,得到新的位置更新公式如下:

$$X_{i_G}(t+1) = \frac{\omega_1 X_{i,\alpha} + \omega_2 X_{i,\beta} + \omega_3 X_{i,\delta}}{3} \quad (30)$$

其中, $X_{i,\alpha}$ 是个体 i 与狼 α 之间的距离; $X_{i,\beta}$ 是个体 i 与狼 β 之间的距离; $X_{i,\delta}$ 是个体 i 与狼 δ 之间的距离。

3.3 引入粒子搜索策略

在 GWO 算法中,当 $|A| > 1$ 时,灰狼种群倾向于扩大全局搜索范围以寻找更合适的猎物,当 $|A| < 1$ 时,灰狼种群倾向于缩小局部搜索范围,从各个方向包围猎物并发起攻击。由式(15)可知,参数 a 随着迭代次数的增加而线性减小到 0,但由于 GWO 算法是一个非线性优化过程,线性减小的 a 并不能符合实际要求因此,为了避免过早的陷入局部最优,本篇文章将 PSO 算法与 GWO 算法相结合并采用自适应度系数来优化算法的搜索能力,新的更新公式如下:

$$V_i(t+1) = \omega V_i(t) + b_1 r_1 (X_1 - X_i(t)) + b_2 r_2 (X_2 - X_i(t)) + b_3 r_3 (X_3 - X_i(t)) \quad (31)$$

$$X_{i_P}(t+1) = X_i(t) + V_i(t+1)$$

其中, r_1, r_2, r_3 是 $[0, 1]$ 之间的随机向量系数; b_1, b_2, b_3 是自适应度向量系数,具体公式如下:

$$b_1 = \frac{1}{2} \times \left(1 - \frac{F(\alpha)}{F(\alpha) + F(\beta) + F(\delta)} \right)$$

$$b_2 = \frac{1}{2} \times \left(1 - \frac{F(\beta)}{F(\alpha) + F(\beta) + F(\delta)} \right) \quad (32)$$

$$b_3 = \frac{1}{2} \times \left(1 - \frac{F(\delta)}{F(\alpha) + F(\beta) + F(\delta)} \right)$$

其中, $F(\alpha), F(\beta), F(\delta)$ 分别是 α, β, δ 狼的适应度值。

最终,进入择优更新替换阶段,通过比较式(30)和式(31)的适应度值,最后确认物种个体的最新位置,表示如下:

$$X_i(t+1) = \begin{cases} X_{i_G}(t+1), & F(X_{i_G}) < F(X_{i_P}) \\ X_{i_P}(t+1), & F(X_{i_G}) \geq F(X_{i_P}) \end{cases} \quad (33)$$

3.4 优化灰狼算法实现流程

在这一节中,给出了改进优化灰狼算法(以下简称 PSO-LGWO)流程图和具体步骤,如下:

图 4 所示为 PSO-LGWO 算法流程图。

步骤 1) 初始化参数。主要包括参数有种群规模 N 、迭代次数 t_{max} 、维数 D 、适应度函数涉及等,并定义无人机起始点坐标以及威胁区域大小。

步骤 2) 在搜索空间中利用混沌序列(19)和准反向学习式(20)~(21)随机生成初始种群。

步骤 3) 计算出每个单独个体的适应度值,并根据排出的适应度值的前 3 个定义为 α, β, δ 。

步骤 4) 根据式(13)~(15)计算参数 A, C, a , 然后根

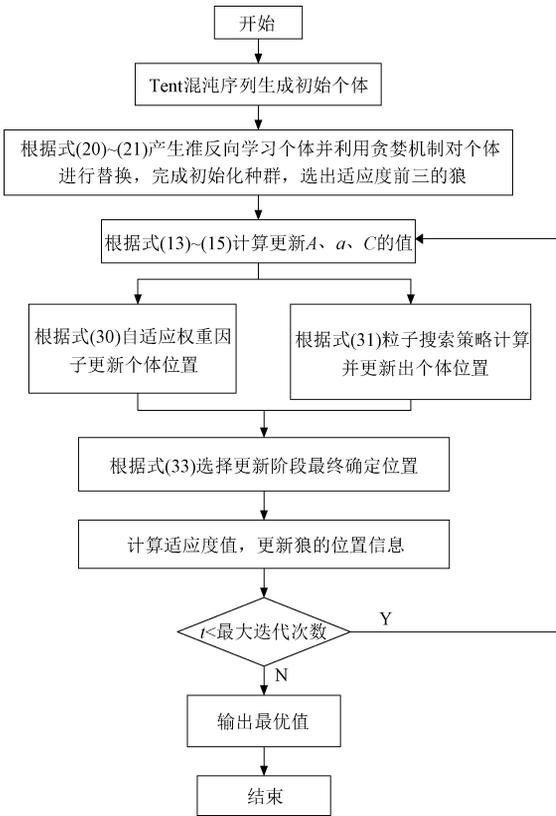


图 4 PSO-LGWO 算法流程图

Fig. 4 PSO-LGWO algorithm flow chart

据式(30)自适应权重因子更新个体位置 $X_{i,G}(t+1)$ 。

步骤 5) 根据式(31)策略计算并更新出个体位置 $X_{i,P}(t+1)$ 。

步骤 6) 进行选择比较阶段, 最后确定个体的位置, 并且重新计算出新的适应度值, 更新 a, β 和 δ 。

步骤 7) 最终判断算法是否达到最大迭代次数, 若到达, 则返回最优值; 否则, 返回步骤 4), 继续进行。

4 实验结果与分析

本文在 windows 11 操作系统中使用 MATLAB2023b 设计了 3 个三维的仿真场景, 并将 PSO-LGWO 算法在威胁环境下得到路径规划与 GWO 算法, AGWO 算法^[11], HSGWO-MOSS 算法^[13]进行比较, 证明 PSO-LGWO 算法的有效性和可行性。威胁区域位置信息设置如表 1 所示。

本章实验仿真设置如下: 无人机飞行起始点定义为 (0 cm, 0 cm, 0 cm), 最终点设置为 (1 000 m, 1 000 m, 1 000 m), 目标函数的成本系数 λ 为 0.4, 最大迭代次数 t_{max} 为 500, 维度 D 为 10, 种群规模 N 为 50, 其中 PSO 惯性权重 ω 为 0.9, 认知学习因子和社会学习因子 C_1, C_2 为 2。每组实验各运行 30 次, 并将这 4 个算法实验结果记入在表 2 中, 分别记入最大适应度值、最小适应度值、标准差、运行时间进行比较, 以便更有利地证明分析算法的性能。

表 1 威胁区域位置信息

Table 1 Threat area location information

案例	危险中心/m	危险半径/m	危险高度/m
案例 1	(170,250)	90	600
	(310,670)	120	800
	(450,150)	105	900
	(600,750)	100	800
	(650,450)	85	800
案例 2	(150,270)	100	500
	(360,470)	100	850
	(550,150)	100	750
	(250,750)	100	800
	(850,550)	100	650
	(800,250)	100	700
	(500,700)	100	600
	(800,880)	100	800
案例 3	(200,210)	95	1 000
	(360,460)	150	800
	(550,150)	100	1 000
	(250,750)	150	800
	(750,450)	100	1 000
	(800,250)	150	800
	(500,700)	150	600
(800,860)	80	800	

图 5~7 表示了 4 种算法在案例 1 中的路径规划实验结果和对比的收敛曲线, 从图 5 的 3D 路径图和图 6 路径俯视图中可以看出 4 种算法都可以避开障碍物到达目标点, 但是相对于 PSO-LGWO 而言, 其他 3 种算法所生成的路径并不平滑和稳定, 这会使得无人机在到达目标点会产生更多的能源消耗。通过表 2 中案例 1 的统计结果数据可以看出, PSO-LGWO 都优于其他 3 种算法, 说明 PSO-LGWO 算法可以更好的获得最优路径。

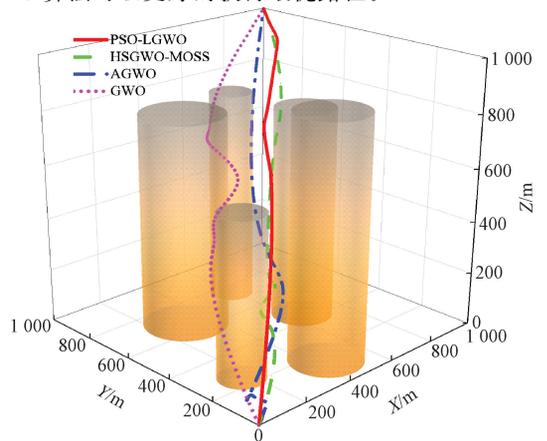


图 5 无人机路径 3D 图对比

Fig. 5 UAV path 3D results comparison

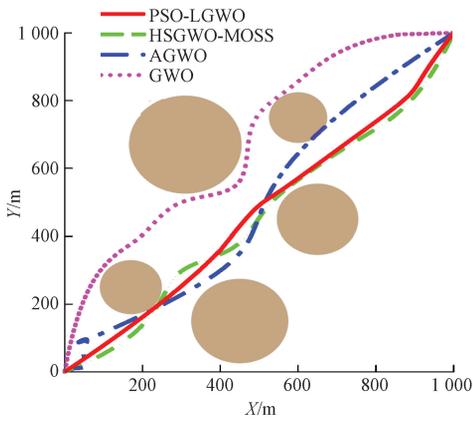


图 6 无人机路径俯视图对比

Fig. 6 UAV path top view comparison

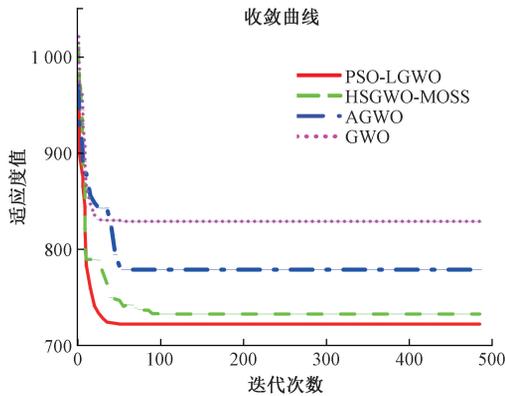


图 7 目标函数收敛曲线对比

Fig. 7 Objective function convergence curve comparison

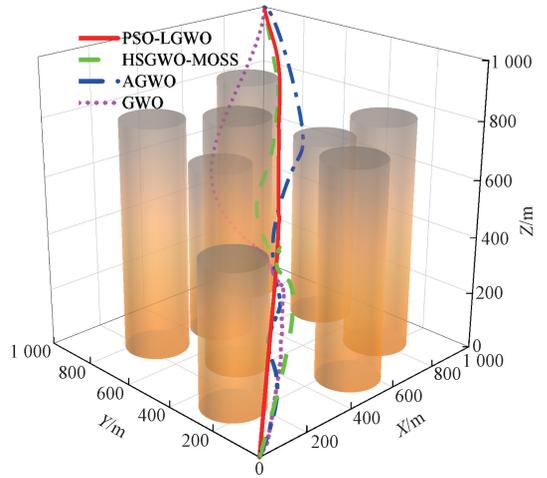


图 8 无人机路径 3D 图对比

Fig. 8 UAV path 3D results comparison

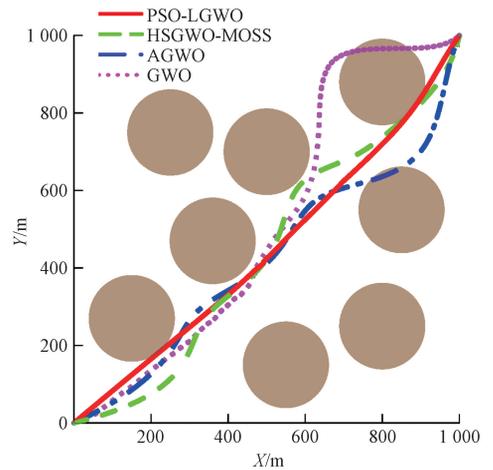


图 9 无人机路径俯视图对比

Fig. 9 UAV path top view comparison

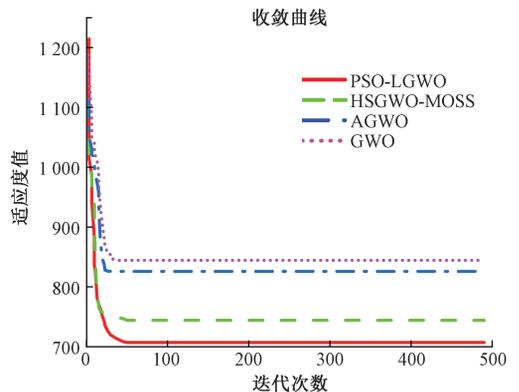


图 10 目标函数收敛曲线对比

Fig. 10 Objective function convergence curve comparison

图 8~10 表示了 4 种算法在案例 2 中的路径规划实验结果和对比的收敛曲线,GWO 算法和 3 种改进 GWO 算法表现出不同的性能。其中由图 10 可以看出 GWO 算法和 AGWO 算法的性能不理想,因为算法在迭代后期种群多样性减少,使得算法不能继续探究搜索解空间的未知区域,从而快速陷入局部最优、收敛效果差。其次是 HSGWO-MOSS 算法,虽然在实验结果和收敛曲线上要比前两种算法要强,但是通过图 8 和图 9 相比于 PSO-LGWO 算法而言,HSGWO-MOSS 算法在生成的路径上较为曲折,这大大增加了无人机在行驶过程中的能耗,不能很好的获得路径规划的结果。通过表 2 的实验结果的各项数据可以看到 PSO-LGWO 算法相比较其他 3 种算法来说是最优的,证明 PSO-LGWO 算法是可以在实验过程中得到一条最优路径。

案例 3 继续增加了无人机在更加复杂的环境下的飞行能力,方便做更好的算法对比。图 11~13 检验了实验结果和各自的收敛曲线,从图 13 目标函数收敛曲线对比中可以看出 GWO 和 AGWO 由于地图的复杂程度增加,从而早早的陷入了局部最优,并且在飞行过程中还碰撞到了危险区

域,导致无人机不同程度的损坏,加大了运输成本。在图 11 路径 3D 图和图 12 路径俯视图中可以看出 HSGWO-MOSS 算法和 PSO-LGWO 算法在路径上比较相近,但通

表 2 路径规划实验数据统计结果

Table 2 Statistical results of path planning experiment data

案例	实验结果	GWO	AGWO	HSGWO-MOSS	PSO-LGWO
案例 1	最大适应度值	973.632	923.364	843.236	798.346
	最小适应度值	780.041	772.451	753.521	689.532
	标准差	50.34	47.25	39.52	29.41
	运行时间/s	32	30	26	17
案例 2	最大适应度值	946.262	905.623	873.521	801.421
	最小适应度值	770.041	752.451	743.521	701.532
	标准差	50.34	47.25	39.52	29.41
	运行时间/s	39	35	31	28
案例 3	最大适应度值	905.422	895.624	849.462	799.425
	最小适应度值	803.425	784.582	765.582	744.521
	标准差	47.3	34.5	38.3	26.42
	运行时间/s	64	59	47	38

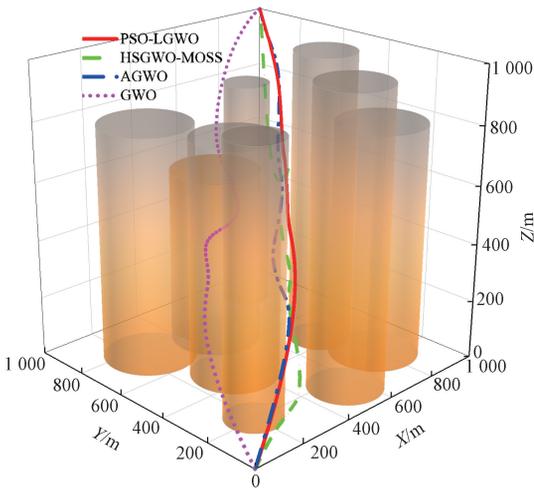


图 11 路径规划结果对比

Fig. 11 UAV path 3D results comparison

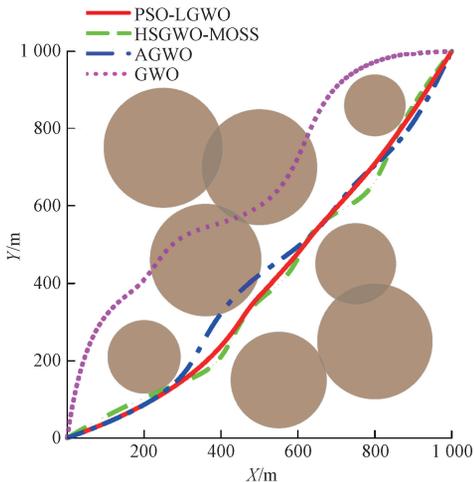


图 12 无人机路径俯视图对比

Fig. 12 UAV path top view comparison

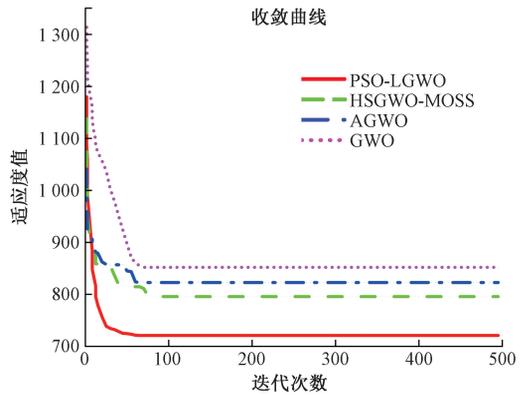


图 13 目标函数收敛曲线对比

Fig. 13 UAV path top view comparison

过表 2 可以看出 PSO-LGWO 算法的标准差和运行时间都比 HSGWO-MOSS 算法低很多。进一步证明了 PSO-LGWO 算法能够在全局与局部寻优之间取得较好的平衡,在保证收敛速率的前提下,达到优化效果。

综上所述,从以上 3 个案例可以看出 4 种元启发式算法均能到达指定的目标点,说明了元启发式算法的价值和实用性。但是从得到的实验结果中可以看出由于 GWO 算法和 AGWO 算法本身的缺陷,并不能很好的得到让人满意的实验结果,HSGWO-MOSS 算法相对于 PSO-LGWO 算法而言还是有一定差距的,所以实验验证了 PSO-LGWO 算法有着较好的能力并且在不同的案例中都可以寻找出最优路径。

5 结 论

本文通过改进灰狼算法,解决了无人机在复杂威胁区域不同环境下路径的避障和稳定性的问题。首先,为了模拟真实环境,对威胁区域和约束条件进行环境建模;其次,

在种群初始化中加入了混合策略,扩大了种群的多样性,在此基础上,通过自适应权重因子对自身的位置进行更新;最后,为了避免陷入局部最优,利用粒子群算法平衡了全局开发和局部收敛。通过 matlab 进行仿真,对4种算法进行对比,验证了改进灰狼算法能更好的解决无人机在三维环境下路径规划问题。在接下来的工作中,要解决多无人机协同问题以及在动态障碍环境下无人机路径问题。

参考文献

- [1] 王博文,郑建,孙彦景,等. 应急场景无人机自组网部分重叠信道动态分配方法[J]. 电子与信息学报, 2024, 47(3):1-10.
WANG B W, ZHENG J, SUN Y J, et al. Dynamic allocation method of partially overlapped channels for AD hoc networks of unmanned aerial vehicles in emergency scenarios[J]. Journal of Electronics and Information Technology, 2024, 47(3):1-10.
- [2] 俞成,陈谋,雍可南. 基于改进 RRT* 算法的无人机往返航迹规划[J]. 中国科学:技术科学, 2023, 53(11): 1911-1921.
YU CH, CHEN M, YONG K N. Return flight trajectory planning for unmanned aerial vehicle based on improved RRT* algorithm[J]. Science China: Technological Sciences, 2023, 53(11): 1911-1921.
- [3] 陈佳,张珂,杜英森,等. 基于改进势场法的多无人机避碰控制方法[J]. 探测与控制学报, 2024, 46(4): 93-100.
CHEN J, ZHANG K, DU Y S, et al. Multi-UAV collision avoidance control method based on improved potential field method[J]. Journal of Detection and Control, 2024, 46(4):93-100.
- [4] 袁新亚,戴娟,孙胜强,等. 融合 A* 和 DWA 算法的移动机器人路径规划方法[J]. 电子测量技术, 2024, 47(4):95-103.
YUAN X Y, DAI J, SUN SH Q, et al. Mobile robot path planning method integrating A* and DWA algorithms[J]. Electronic Measurement Technology, 2024, 47(4): 95-103.
- [5] 喻九阳,张德安,戴耀南,等. 基于改进 B-GRRT* 算法的移动机器人路径规划[J]. 计算机科学, 2023, 50(S1):105-111.
YU J Y, ZHANG D AN, DAI Y N, et al. Path planning of mobile robot based on improved B-GRRT* algorithm[J]. Computer Science, 2023, 50(S1): 105-111.
- [6] 黄鹤,温夏露,王会峰,等. 基于 IBES 优化的三维无人机自主避障[J]. 复旦学报(自然科学版), 2023, 62(5): 615-626.
HUANG H, WEN X L, WANG H F, et al. Autonomous obstacle avoidance for 3D UAV based on IBES optimization[J]. Fudan Journal (Natural Science), 2023, 62(5):615-626.
- [7] 蒋翱翱,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.
JIANG AO H, LIU W H. Uav 3D path planning based on improved dung beetle optimization algorithm[J]. Electronic Measurement Technology, 2024, 47(13): 128-135.
- [8] LIU G Y, SHU C, LIANG ZH W, et al. A modified sparrow search algorithm with application in 3d route planning for UAV[J]. Sensors, 2021, 21(4):1224.
- [9] 张颖,姜文刚,陈一鸣,等. 基于改进蜘蛛蜂算法的无人机三维路径规划[J]. 电子测量技术, 2024, 47(11): 101-111.
ZHANG Y, JIANG W G, CHEN Y M, et al. UAV 3D path planning based on improved spider bee algorithm[J]. Electronic Measurement Technology, 2024, 47(11): 101-111.
- [10] YU X B, JIANG N J, WANG X M, et al. A hybrid algorithm based on grey wolf optimizer and differential evolution for UAV path planning[J]. Expert Systems With Applications, 2023, 215:119327.
- [11] ZHANG W, ZHANG S, WU F, et al. Path planning of UAV based on improved adaptive grey wolf optimization algorithm[J]. IEEE Access, 2021, 9: 89400-89411.
- [12] 卢颖,庞黎晨,陈雨思,等. 一种面向城市战的无人机路径规划群智能算法[J]. 兵工学报, 2023, 44(S2): 146-156.
LU Y, PANG L CH, CHEN Y S, et al. A swarm intelligent algorithm for UAV path planning for urban warfare[J]. Acta Ordnance Engineering, 2023, 44(S2):146-156.
- [13] QU CH, GAI W, ZHANG J, et al. A novel hybrid grey wolf optimizer algorithm for unmanned aerial vehicle(UAV) path planning[J]. Knowledge-Based Systems, 2020, 194: 105530.
- [14] 陈福金. 基于 CLGWO 的无人机三维路径规划研究[J]. 经纬天地, 2024(3):77-82.
CHEN F J. Research on 3D path planning of UAV based on CLGWO[J]. Jingwei World, 2024(3): 77-82.
- [15] JIA Y J, QU L D, LI X Q. A double-layer coding model with a rotation-based particle swarm algorithm for unmanned combat aerial vehicle path planning[J]. Engineering Applications of Artificial Intelligence, 2022, 116:105410.
- [16] ZHANG CH Q, ZHOU W J, QIN W D, et al. A novel UAV path planning approach: Heuristic crossing search and rescue optimization algorithm[J]. Expert Systems with Applications, 2023, 215: 119243.
- [17] 许子俊,胡涛,刘凯越,等. 基于多策略改进灰狼算法的多无人机三维路径规划[J/OL]. 航空器, 1-10[2024-10-15]. <http://kns.cnki.net/kcms/detail/41.1228.TJ.20240815.1604.003.html>.
XU Z L, HU T, LIU K Y, et al. 3D path planning of multi-UAV based on multi-strategy improved grey wolf algorithm[J/OL]. Aviation Weapons, 1-10[2024-10-15]. <http://kns.cnki.net/kcms/detail/41.1228.TJ.20240815.1604.003.html>.

作者简介

宋宇, 硕士, 教授, 主要研究方向为嵌入式系统及小型无人机系统与航迹规划。

E-mail: songyu@ccut.edu.cn

高岗(通信作者), 硕士研究生, 主要研究方向为嵌入式系统及小型无人机系统与航迹规划。

E-mail: 784322931@qq.com

梁超, 硕士, 讲师, 主要研究方向为数字图像处理。

E-mail: liangchao@ccut.edu.cn

徐军生, 实验师, 主要研究方向为嵌入式系统及小型无人机系统与航迹规划。

E-mail: xjs@ccut.edu.cn