

基于改进鸽群优化和马尔可夫链的多无人机协同搜索方法

王 瑞, 肖冰松[✉]

空军工程大学航空工程学院, 西安 710038

✉通信作者, E-mail: 58818252@qq.com

摘 要 针对多无人机在协同搜索过程中存在重复搜索、目标静止、搜索效率低的问题, 提出基于改进鸽群优化和马尔可夫链的多无人机协同搜索方法。首先, 建立类似传感器探测范围的蜂窝状环境模型, 降低对搜索区域的重复搜索; 其次, 建立满足高斯分布的马尔可夫链动态目标运动模型; 然后, 将柯西扰动引入基本鸽群优化算法的地图和指南针算子, 高斯扰动引入地标算子, 同时利用模拟退火机制保留次优个体, 进而有效缓减基本鸽群优化算法易陷入局部最优的问题。最后, 通过仿真实验将本文算法与其他群体智能算法进行比较, 结果表明新型算法的合理性和有效性。

关键词 多无人机; 协同搜索; 蜂窝状模型; 马尔可夫链; 柯西扰动; 高斯扰动; 鸽群优化

分类号 V249.1

Cooperative search for multi-UAVs *via* an improved pigeon-inspired optimization and Markov chain approach

WANG Rui, XIAO Bing-song[✉]

Aeronautics Engineering College, Air Force Engineering University, Xi'an 710038, China

✉Corresponding author, E-mail: 58818252@qq.com

ABSTRACT Compared with manned aircraft, unmanned aerial vehicles (UAVs) are affordable and convenient for high-risk missions. Therefore, UAVs are increasingly playing an important role in military and civilian fields. Today, UAVs have been exploited to perform special missions carrying some important equipment. However, influenced by the constraints of single UAV's performance and load, it has become a research hotspot that multi-UAVs perform search cooperatively. The process is to minimize the uncertainty of the unknown area and to find the target as much as possible. In terms of cooperation among UAVs, the more effective method based on search map is used. And search process optimization on the basis of distributed model predictive control (DMPC) or traditional swarm intelligence algorithms are adopted, but these methods have some limitations. Due to the behavior of swarm intelligent individual have the characteristics of the decentralization, distribution, and overall self-organization, which match with the requirements of the localization, distribution and robustness of the UAV cooperate search. Nevertheless, the traditional swarm intelligence algorithms have low search efficiency and are easy to fall into local optimum. To solve the problem of repeated search, static targets and low efficiency in cooperative search for multi-UAVs, a method based on improved pigeon-inspired optimization (PIO) and Markov chain was proposed. Firstly, a honeycomb environmental model similar to the sensor detect region was established to reduce repeated search for the area. Secondly, Markov chain with the Gaussian distribution was used to represent dynamic movement of targets. Thirdly, Cauchy mutation and Gaussian mutation were introduced into the map and compass operator and the landmark operator of PIO, respectively. Meanwhile,

收稿日期: 2018-09-02

基金项目: 空军工程大学航空工程学院科研创新基金资助项目(CXJJ201809)

simulated annealing (SA) mechanism was exploited to reserve the worse individual, which effectively reduced the problem that PIO was easy to fall into local optimum. Finally, the algorithm was compared with other swarm intelligence algorithms through simulation experiments. The results show that the new method is effective and available.

KEY WORDS multi-UAVs; cooperative search; honeycomb model; Markov chain; Cauchy mutation; Gaussian mutation; pigeon-inspired optimization

军事领域的智能无人化发展,是“加快军事智能化发展”的重要内容,也是军事智能“由人向物”迁移的关键领域。无人机具有持续工作能力强、全寿命周期成本低等特点,在尺寸、速度和机动性等方面具有独特的优势^[1],成为影响未来信息化战争的时代力量。由于单架无人机所能携带的任务载荷相对单一,执行任务能力有限,而通过多无人机的能力互补和行动协调,可实现整个系统效能的提升。因此,无人机的应用样式逐步从单平台向群体智能的多平台发展。

多无人机协同搜索,即多架无人机按照一定的搜索规则,在未知区域中最大限度地降低环境的不确定性,且尽可能地发现目标的过程。Peng等^[2]对几种典型协同目标搜索策略进行仿真分析。如,随机搜索、贪婪搜索、滚动时域控制(receding horizon control, RHC)搜索等。由于群体智能个体行为的去中心化、交互合作分布式、整体自组织等特点与无人机协同搜索的局部性、分布式和鲁棒性等要求存在契合之处^[3]。因此,研究群体智能的多无人机协同搜索成为热点话题。文献[4]基于搜索图建立环境模型,采用局部粒子群实时构建无人机子群,实现分布式搜索多个静态目标。Yang等^[5]提出基于不确定环境的改进蚁群多无人机协同搜索方法,该方法使用改进蚁群算法的行为规则决定航路点的转移,并基于信息素图进行更新。但是基于群体智能的蚁群优化算法、粒子群优化算法、人工蜂群优化算法存在搜索效率低、收敛速度慢等问题,段海滨等^[6]提出的鸽群优化(pigeon-inspired optimization, PIO)算法能够有效克服以上问题,并已在很多方面取得研究成果^[7]。Li等^[8]提出边缘势函数和改进鸽群优化的图像目标检测方法。但以上算法在两方面存在局限性:(1)针对静态目标完成协同搜索;(2)群体智能算法容易陷入局部最优。因此,本文提出运动目标模型和扰动模拟退火鸽群优化(mutations simulated annealing pigeon-inspired optimization, MSAPIO)算法完成多无人机协同搜索。

1 系统建模

多无人机协同搜索是一个复杂的动态过程,影

响其性能的主要因素有搜索环境、无人机自身特性、目标运动等。

1.1 环境信息图

环境信息图,是无人机在搜索过程中对环境不确定性的反应。文献[4]和[9]均采用矩形栅格离散化搜索区域,但是传感器对周围环境的探测更接近于圆形域,所以本文采用六边形构建蜂窝状的搜索环境,这样可以减少重复区域的搜索,进而提高搜索效率。将搜索区域 L 离散化为 $L_x \times L_y$ 的栅格,每架无人机看作栅格中的一个质点,这样多无人机协同搜索问题就可以转化成无人机之间栅格位置的协同。构建环境信息模型如图1所示。




图1 环境信息模型

Fig.1 Environmental information model

图1中,灰色阴影部分为搜索区域。假设该区域用二维坐标 (x, y) 表示,传感器的探测半径为 r ,横坐标 x 的增幅 Δx 为 $\sqrt{3}r$,纵坐标 y 的增幅 Δy 为 $3r/2$ 。

假设 $p(x, y, t)$ 是 t 时刻目标在栅格 (x, y) 内存在的概率, $p(x, y, t) \in [0, 1]$ 。 $ud(x, y, t)$ 是环境信息的不确定度,可用目标存在概率 $p(x, y, t)$ 的熵描述,定义为:

$$ud(x, y, t) = \begin{cases} 0 & p(x, y, t) = 0 \text{ 或者 } 1 \\ H[p(x, y, t)] & \text{其他} \end{cases} \quad (1)$$

$$H[p(x, y, t)] = -p(x, y, t) \log_2 p(x, y, t) - (1 - p(x, y, t)) \log_2 (1 - p(x, y, t)) \quad (2)$$

1.2 无人机运动模型

假设所有无人机处于相同飞行高度。UAV_{*i*}在 t 时刻的状态信息 $x_i(t)$ 为:

$$x_i(t) = [\text{pos}_i(t) \text{ 且 } O_i(t)] \quad (3)$$

式中, $\text{pos}_i(t) = (x_i(t), y_i(t)) \in \{1, 2, \dots, L_x\} \times \{1, 2, \dots, L_y\}$ 为UAV_{*i*}的空间位置;方向 $O_i(t) \in \{0,$

1 2 3 4 5 6 7} ,如图2所示 8个数字代表8个方向. UAV在飞行过程中由于受到最小转弯变径的限制,只能到达相邻的三个位置,即直行、左拐和右拐. 即:

$$O_i(t+1) \in \{O_i(t) - 1, O_i(t), O_i(t) + 1\} \bmod 8 \quad (4)$$




图2 UAVs可选航向图

Fig.2 UAVs optional heading diagram

1.3 目标信息图

目标信息图,反应特定栅格目标存在的概率,其先验信息由情报和监视平台提供.随着搜索的进行,目标信息图在不断更新.假设在 t 时刻,栅格 (x, y) 的目标存在概率为 $p(x, y, t)$,其更新方法为:

$$p(x, y, t+1) = \begin{cases} \frac{p_d p(x, y, t)}{p_f + (p_d - p_f) p(x, y, t)}, & \delta(t) = 1 \\ \frac{(1 - p_d) p(x, y, t)}{1 + p_d p(x, y, t) - p_f (1 - p(x, y, t))}, & \delta(t) = 0 \end{cases} \quad (5)$$

式中 $\delta(t) = 1$ 表示栅格 (x, y) 中的目标被发现; $\delta(t) = 0$ 表示未被发现. p_d 和 p_f 分别表示检测率和误报率.

1.4 数字信息素图

通过人工势函数实现无人机之间位置的协同,可以有效形成多机空间结构,但是存在任务协调性不好,资源浪费的问题.而基于数字信息素的多无人机协同机制能够解决该问题^[10].数字信息素图(digital pheromone map)^[11],本质上是一种具有隐性协调机制的扩展势场方法.本文定义引力信息素和斥力信息素两种基本信息素,实现无人机的动态协作行为.

首先,定义表示相应栅格信息素浓度的参数:

(1) $d_A(x, y, t)$ 和 $d_R(x, y, t)$ 是常量,表示 t 时刻栅格 (x, y) 释放的引力信息素和斥力信息素的数量;

(2) $g_A(x, y, t)$ 和 $g_R(x, y, t)$ 表示 $(t-1, t]$ 时间内从相邻栅格传入栅格 (x, y) 的引力信息素和斥力

信息素的数量;

(3) E_A 和 E_R 表示引力信息素和斥力信息素的蒸发系数;

(4) P_A 和 P_R 表示引力信息素和斥力信息素的传播系数.

假设数字信息素按照先传播后蒸发的原则进行计算.那么 t 时刻栅格 (x, y) 的引力信息素 s_A 定义为:

$$s_A(x, y, t) = (1 - E_A) [(1 - P_A) (s_A(x, y, t-1) + \lambda^{\frac{1}{f(x, y)}} d_A(x, y, t) + g_A(x, y, t))] \quad (6)$$

式中 $\lambda \in (0, 1)$ 是调节因子; $f(x, y)$ 是最后一次访问栅格 (x, y) 到当前的时间周期数,定义为:

$$f(x, y) = \frac{t(x, y)}{T_c}$$

$$g_A(x, y, t) =$$

$$\sum_{(x', y') \in \text{Nei}(x, y)} \frac{P_A}{N(x', y')} (s_A(x', y', t-1) + d_A(x', y', t)) \quad (7)$$

式中 $t(x, y)$ 是最后一次访问栅格 (x, y) 到当前的时间; T_c 是信息素更新周期,通常设置为无人机运动周期的10倍; $\text{Nei}(x, y)$ 是 (x, y) 的相邻栅格; $N(x', y')$ 是相邻栅格总数. $g_A(x, y, t)$ 定义表明,传播到栅格 (x, y) 的引力信息素量是所有相邻栅格对外传播总量的加权和.

与引力信息素类似, t 时刻栅格 (x, y) 的斥力信息素 s_R 定义为:

$$s_R(x, y, t) = (1 - E_R) [(1 - P_R) (s_R(x, y, t-1) + \lambda^{f(x, y)} d_R(x, y, t) + g_R(x, y, t))] \quad (8)$$

$g_R(x, y, t)$ 的更新方法为:

$$g_R(x, y, t) =$$

$$\sum_{(x', y') \in \text{Nei}(x, y)} \frac{P_R}{N(x', y')} (s_R(x', y', t-1) + d_R(x', y', t)) \quad (9)$$

因此, t 时刻栅格 (x, y) 的信息素浓度定义为引力信息素与斥力信息素的差.

$$s(x, y, t) = s_A(x, y, t) - s_R(x, y, t) \quad (10)$$

2 目标运动模型和适应度函数

2.1 目标运动模型

马尔可夫链是时间和状态均离散的特殊马尔可夫过程,它不具有后验特征,相关定义如下:

定义1: 马尔可夫链. 假定状态空间的离散随机序列 $\{S(i) \mid i=0, 1, 2, \dots, n\}$ 为 $1, m$ 个非负整数 $n_1, n_2, \dots, n_m (0 \leq n_1 < n_2 < \dots < n_m)$ 以及所有 $t > 0, i_1, i_2, \dots, i_m, i_{m+t} \in I$. 有:

$$P\{S(n_{m+i}) = i_{m+i} | S(n_1) = i_1, S(n_2) = i_2, \dots, S(n_m) = i_m\} = P\{S(n_{m+i}) = i_{m+i} | S(n_m) = i_m\} \quad (11)$$

式中 $\{S(i) \mid i=0, 1, 2, \dots, n\}$ 是马尔可夫链, 它的一步转移概率为 $P\{S(n+1) = j | S(n) = i\}$, 可缩写为 p_{ij} .

在多无人机协同搜索过程中, 由于目标未来的运动状态仅仅与当前状态有关, 而与过去的运动状态无关, 因此, 无人机的运动状态可构成典型的马尔可夫链. 当时间离散时, 目标下一时刻是运动到它的相邻栅格或静止在当前栅格, 由其运动状态转移矩阵决定.

目标运动的状态转移概率依赖于目标运动的特征. 根据经验, 目标通常运动到无人机对环境不确定性高的栅格, 且一步状态转移概率定义为:

$$p_{ii} = \frac{ud(x_i, y_i)}{\sum_{j \in L} ud(x_j, y_j) + ud(x_i, y_i)} \quad (12-1)$$

$$p_{ij} = \begin{cases} \frac{ud(x_j, y_j)}{ud(x_j, y_j) + ud(x_i, y_i)}, & j \in L \\ 0, & j \notin L \end{cases} \quad (12-2)$$

式中 L 是目标运动区域; $ud(x_i, y_i)$ 和 $ud(x_j, y_j)$ 分别是栅格 (x_i, y_i) 和 (x_j, y_j) 的不确定性; p_{ii} 是保持静止的概率; p_{ij} 是运动到相邻栅格的概率.

另外, 目标运动预测的准确与否, 很大程度上依赖于目标初始位置的估计. 从统计学角度考虑, 目标运动通常假定遵循一定分布, 如: 正态分布或 Beta 分布^[12]. 由于 Beta 分布存在预测步的开销, 本文采用两维正态分布表示目标的初始位置, 如果目标的初始中心位置是 (x_0, y_0) , (x, y) 是相邻位置, 方差是 σ_0^2 , 目标位置的联合概率密度为:

$$f(x, y) = \frac{1}{2\pi\sigma_0^2} e^{-\frac{(x-x_0)^2 + (y-y_0)^2}{2\sigma_0^2}} \quad (13)$$

所以, 初始时刻目标位置分布可定义为:

$$p_0(x, y, \theta) = \int_{x-x_0-\frac{1}{2}}^{x-x_0+\frac{1}{2}} \int_{y-y_0-\frac{1}{2}}^{y-y_0+\frac{1}{2}} f(x, y) dx dy \quad (14)$$

2.2 适应度函数设计

多无人机协同搜索主要考虑三个因素: 尽可能降低环境的不确定度; 尽可能多的发现目标; 尽可能提高搜索效率. 因此, 适应度函数中应包含环境不确定收益、目标发现收益和协同收益三项.

(1) 环境不确定收益.

$$f_e(x, y, t+1) = ud(x, y, t+1) - ud(x, y, t)$$

(2) 目标发现收益.

根据式(5)和式(14)得到目标在时刻 t 的位置分布, 这里定义目标发现收益为目标位置的分布概率:

$$f_i(x, y, t+1) = p(x, y, t+1) \quad (3) \text{ 协同收益.}$$

$$f_c(x, y, t+1) = s(x, y, t+1)$$

线性整合以上三个收益, 生成协作搜索的适应度函数:

$$\text{fitness}(t) = \omega_1 f_e(x, y, t) + \omega_2 f_i(x, y, t) + \omega_3 f_c(x, y, t) \quad (15)$$

式中 ω_1 、 ω_2 和 ω_3 分别反应环境不确定收益、目标发现收益和协同收益的重要程度, 且 $\omega_1 + \omega_2 + \omega_3 = 1$.

3 鸽群优化算法及改进模型

3.1 鸽群优化算法思想

鸽群优化算法是受鸽子归巢行为启发设计的一种新型群体智能算法. 针对鸽子在寻找目标的不同阶段使用不同导航工具这一机制, 使用 2 种不同算子模型: 地图和指南针算子、地标算子.

在多维搜索空间中初始化鸽子的位置 X_i 和速度 V_i :

$$X_i = [x_{i1}, x_{i2}, \dots, x_{iD}]$$

$$V_i = [v_{i1}, v_{i2}, \dots, v_{iD}]$$

其中: i 是第 i 只鸽子, $i \in \{1, 2, \dots, N\}$, N 是鸽子总数; D 是问题求解维度. 每只鸽子根据式(16)更新位置和速度:

$$\begin{cases} V_i(t) = V_i(t-1) e^{-R \times t} + \text{rand} \cdot (X_{\text{gbest}} - X_i(t-1)) \\ X_i(t) = X_i(t-1) + V_i(t) \end{cases} \quad (16)$$

其中: R 是地图和指南针因子, 随着迭代的进行能降低鸽子的速度; 随机数 $\text{rand} \in [0, 1]$; t 是当前迭代次数; X_{gbest} 是 $t-1$ 次迭代得到的全局最优位置. 假设地图和指南针算子的最大迭代次数是 NC_1 , 当 $t > \text{NC}_1$ 时, 停止地图和指南针算子, 进入地标算子.

地标算子中, 每次迭代鸽子的数量减半, 剩余鸽子的中心位置 X_c 被当作地标, 即飞行的参考方向. X_c 和剩余鸽子的位置更新, 如式(17)所示:

$$\begin{cases} X_c(t-1) = \frac{\sum_{i=1}^{N_p} X_i(t-1) \cdot \text{fitness}(X_i(t-1))}{N_p \sum \text{fitness}(X_i(t-1))} \\ X_i(t) = X_i(t-1) + \text{rand} \cdot (X_c(t-1) - X_i(t-1)) \end{cases} \quad (17)$$

式中 N_p 是 $t-1$ 次迭代减半的鸽子数; $\text{fitness}(\cdot)$ 是每只鸽子的适应度函数. 针对求解的最值不同, 定义也不同. 如式(18)所示:

$$\text{fitness}(X_i(t-1)) =$$

$$\begin{cases} \frac{1}{\text{fitness}(X_i(t-1)) + \varepsilon}, & \text{最小值} \\ \text{fitness}(X_i(t-1)), & \text{最大值} \end{cases} \quad (18)$$

假设地标算子的最大迭代次数是 NC_2 , 当 $t > NC_2$ 时, 停止地标算子. 记录每次迭代的最优位置, 并用 X_p 表示:

$$X_p = \max (X_g(1), X_g(2), \dots, X_g(t))$$

3.2 鸽群优化算法的改进模型

基本鸽群优化算法的每一次迭代均在寻找全局最优, 虽然具有收敛速度快、搜索效率高的优势, 但该思想在求解多最值问题时极易陷入局部最优.

为了最大限度地避免算法模型陷入局部最优, 本文将柯西因子、高斯因子和模拟退火^[13] (simulated annealing, SA) 机制引入基本鸽群优化算法模型中, 从而提高算法性能. 在进化计算理论中, 高斯扰动和柯西扰动是两种流行的扰动技术. 柯西扰动在跳出局部最优方面具有优势, 而高斯扰动在局部收敛方面表现较好^[14]. 因此, 可将柯西扰动引入基本鸽群优化算法的地图和指南针算子, 高斯扰动引入地标算子, 这样既可以避免过早收敛陷入局部最优问题, 又可以确保地标算子找到全局最优解.

便于扰动机制的描述, 在搜索目标函数最大值时, 将每一维位置 \bar{x}_i 看成 1, 即 $\bar{x}_i = x_i$, 则扰动后的位置 $\bar{x}'_i = x'_i = x_i + \Delta r \cdot X$; Δr 是扰动步长, X 是随机变量. 若采用高斯扰动, 则 X 是满足高斯分布的一个随机变量 $X = N(\mu, \sigma^2)$, 其概率密度函数如式 (19) 所示:

$$f_N(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad x \in (-\infty, +\infty) \quad (19)$$

若采用柯西扰动, 则 X 是满足柯西分布的随机变量 $X = C$, 其概率密度函数如式 (20) 所示:

$$f_c(x) = \frac{1}{\pi} \left(\frac{a}{a^2 + x^2} \right) \quad x \in (-\infty, +\infty) \quad (20)$$

因此, 在地图和指南针算子中引入柯西扰动的新一代鸽子的位置、速度更新如式 (21) 所示^[15]. 扰动时机为全局最优的适应度函数值在最近 K_1 次迭代内, 如果变化大小的绝对值小于阈值 e_1 ; 那么, 对全局最优位置执行柯西扰动操作.

$$\begin{cases} V_i(t) = V_i(t-1) e^{-R \times t} + \left\{ X_{g\text{best}} + \right. \\ \left. a \times \tan \left[\pi \left(\text{rand} - \frac{1}{2} \right) \right] - X_i(t-1) \right\} \\ X_i(t) = X_i(t-1) + V_i(t) \end{cases} \quad (21)$$

由于地标算子是对目标的精细搜索, 在初始扰动时的步长可以稍大一些, 但随着迭代的进行扰动步长应逐渐减小. 而 $\text{logsig}(\cdot)$ 函数恰好具有从 1 到 0 的非线性下降特性. 所以, 本文引入 $\text{logsig}(\cdot)$ 函数表示扰动步长, 其位置更新如式 (22) 所示. 扰动时机为中心位置 X_c 在最近的 K_2 次迭代内, 如果每一维变化大小的绝对值小于阈值 e_2 , 那么, 对中心位置 X_c 执行高斯扰动操作.

$$\begin{cases} X_c(t-1) = X_c(t-1) + \text{log sig} \left(\frac{NC_2/2 - t}{k} \right) N(\mu, \sigma) \\ X_i(t) = X_i(t-1) + \text{rand} \cdot (X_c(t-1) - X_i(t-1)) \end{cases} \quad (22)$$

另外, 基本鸽群优化算法在搜索过程中, 始终寻找全局最优解, 极易陷入局部最优. 因此, 应以一定概率保留次优个体. 20 世纪 80 年代提出的模拟退火算法可以解决这一问题. 假定, 次优个体以概率 P_r 保留, 添加高斯扰动后的个体 X_{ig} 与扰动前的个体 X 之间适应度值的差为 Δf , 概率 P_r 定义为:

$$P_r = \exp(-\Delta f/T) \quad (23)$$

式中, T 是退火温度, 随着迭代的进行该值逐渐下降. 而且, 如果初始退火温度较高, 退火率较低, 改进模型将更有助于跳出局部最优.

将上述思想融入基本鸽群优化算法, 得到扰动模拟退火鸽群优化 (MSAPIO) 算法模型. 算法实现过程描述如下.

第一步: 建立搜索图. 根据式 (5) 和式 (14) 构建目标信息图, 根据式 (1) 构建环境信息图;

第二步: 初始化参数. 初始化扰动模拟退火鸽群优化算法参数. 如: 鸽子总数 N ; 两个算子的最大迭代次数 NC_1 、 NC_2 (具体如表 1 所示), 以及鸽群中每只鸽子的初始位置和初始速度等;

第三步: 估计鸽子的适应度值. 利用式 (15) 的适应度函数评价每只鸽子的位置;

第四步: 地图和指南针算子更新. 利用式 (16) 基本鸽群优化算法的地图和指南针算子更新位置和速度, 每次迭代, 若有鸽子的适应度值优于 $X_{g\text{best}}$, 则利用该鸽子的位置替换 $X_{g\text{best}}$; 若满足柯西扰动条件, 利用式 (21) 跳出局部最优, 继续执行本步操作, 直至迭代次数达到 NC_1 ;

第五步: 地标算子更新. 利用式 (17) 基本鸽群优化算法的地标算子更新中心位置和每只鸽子位置, 每次迭代, 若新一代 $X_c(t)$ 优于上一代 $X_c(t-1)$, 则利用新一代 $X_c(t)$ 替换上一代 $X_c(t-1)$; 若满足高斯扰动条件, 利用式 (22) 局部调整, 若高斯扰

动后的中心位置次于扰动前的位置,计算二者的差,利用式(23)确定 P_r .然后,用随机数 $\text{rand} \in (0, 1)$ 与 P_r 比较,若 $\text{rand} < P_r$,保留次优位置,否则,退回扰动前状态,继续执行本步操作,直至迭代次数达到 NC_2 ,算法收敛.

基本鸽群优化算法的时间复杂度为 $O(N + NC_1 * N * D + NC_2 * N^2 + N * D)$,模拟退火算法的时间复

杂度是 $O((T_0 - T_{\min})/c)$.其中, T_0 是初始退火温度; T_{\min} 是最低温度; c 是降温速率.由于模拟退火算法只在地标算子寻优中加入,所以扰动模拟退火鸽群优化算法的时间复杂度为 $O(N + NC_1 * N * D + NC_2 * N^2 + N * (D + (T_0 - T_{\min})/c))$.

基本鸽群优化(PIO)算法和扰动模拟退火鸽群优化(MSAPIO)算法的参数选择如表1所示:

表1 PIO和MSAPIO参数表
Table 1 Parameters of PIO and MSAPIO

参数	参数定义	数值	应用
NC_1	地图和指南针算子迭代次数	15	
NC_2	地标算子迭代次数	5	鸽群优化
N	鸽子总数	50	扰动模拟退火鸽群优化
R	地图和指南针因子	0.3	
a	柯西分布概率密度参数	1	
μ	高斯分布率密度函数参数(均值)	0	
σ	高斯分布概率密度函数参数(方差)	1	
K_1	地图和指南针算子的柯西扰动条件	3	扰动模拟鸽群优化
K_2	地标算子的高斯扰动条件	2	
e_1	地图和指南针算子扰动阈值	0.1	
e_2	地标算子扰动阈值	0.01	
T_0	初始退火温度	100	

4 实验结果和分析

首先,使用经典适应度函数验证本文算法相对基本鸽群优化算法的优越性.然后从搜索覆盖范围和发现目标数目两个方面衡量多无人机协同搜索的性能.

4.1 算法性能比较

本文算法采用扰动和模拟退火机制,相对基本鸽群优化算法易跳出局部最优.使用多峰适应度评价函数进行测试,图3(a)使用Rastrigrin函数,其在 $x = (0, 0, \dots, 0)$ 处取得极小值0,为了便于观察对函数取反,即这里取极大值0;图3(b)使用Schaffer函数,其在 $x = (0, 0, \dots, 0)$ 处取得极大值1.每个函数的前两幅图是基本鸽群优化算法随机一次运行和10次迭代取最大值、最小值和均值的收敛情况;后两幅图是扰动模拟退火鸽群优化算法随机一次运行和10次迭代取最大值、最小值和均值的收敛情况.从图中不难发现,本文算法能够有效避免陷入局部最优.

4.2 搜索范围覆盖率

假设搜索区域 L 为 10×10 的栅格.图4(a)中,

红色“×”是随机产生的目标初始位置,数字“1, 2, 3, 4, 5, 6”是中间被包围目标下一时刻可能的运动位置.图4(b)是随机产生的初始环境不确定度,且绿色阴影部分正比于不确定度.

为了验证本文算法的优越性,图5是4架无人机在不同仿真步数下的运动轨迹和搜索范围覆盖率,便于观察运动情况.图5(a)和图5(b)仅给出无人机和目标1在30步和60步的运动轨迹,图5(c)是不同算法的搜索范围随着搜索步数的变化情况.将 $20 \text{ km} \times 20 \text{ km}$ 的搜索区域划分为 20×20 的栅格,4架无人机的初始位置用“▷”表示,“×”是随机产生的动态目标,“ s_i ”是第 i 个目标的起始位置,“ e_i ”是经马尔可夫链运动后的终止位置.由图分析可知,无人机能够用最小步数,实现尽可能多的目标搜索,而且随着搜索步数的增加搜索覆盖范围不断扩大.

4.3 搜索目标有效性

图6从搜索目标的有效性对基本鸽群优化算法、蚁群算法以及扰动模拟退火鸽群优化算法这3种算法做仿真分析比较,且图6(a)和图6(b)分别表示搜索目标平均数和搜索策略有效性.使用4

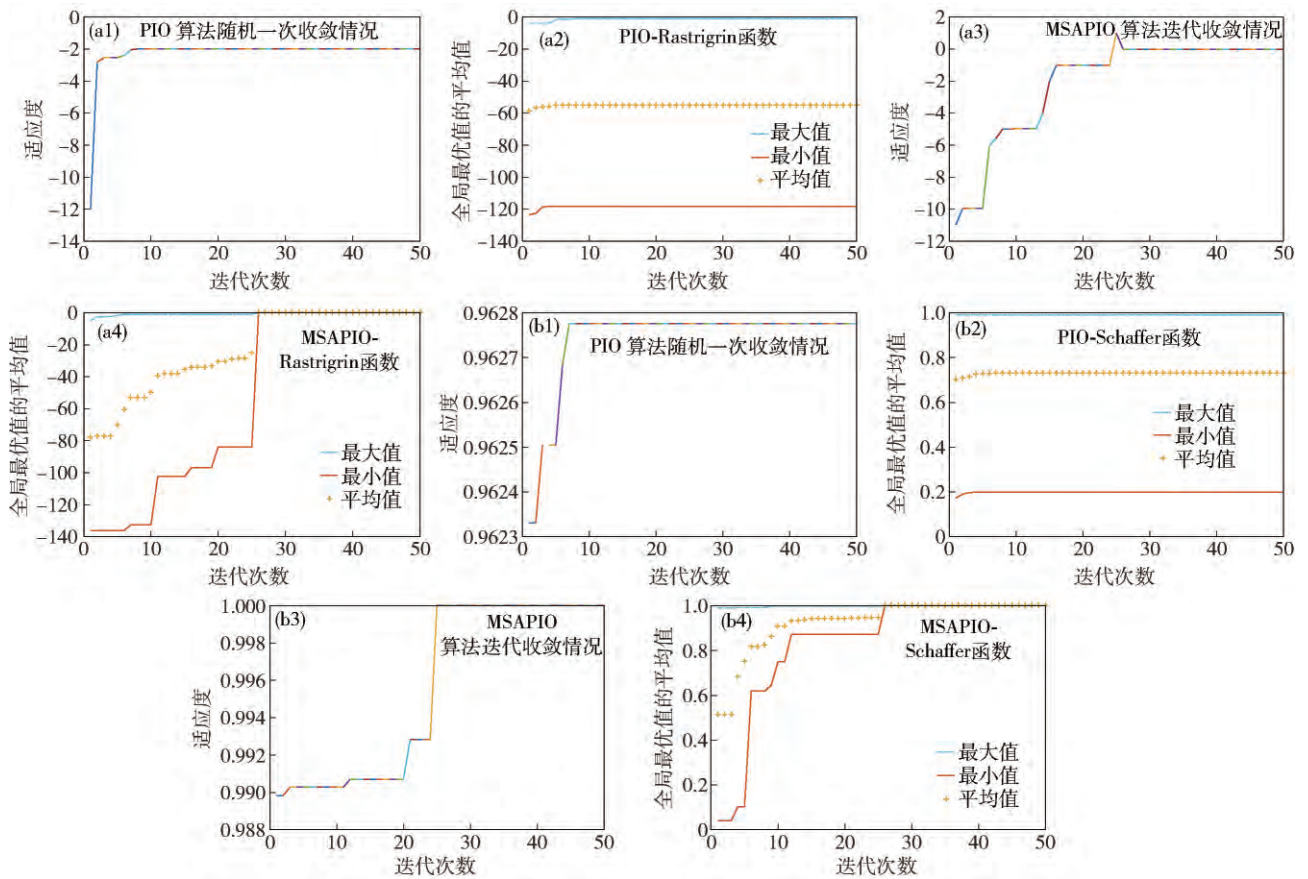


图3 不同函数随机一次和10次迭代最优值收敛情况. (a) Rastrigrin; (b) Schaffer

Fig.3 Optimal value convergence of different functions at random times and 10 times of iteration: (a) Rastrigrin; (b) Schaffer

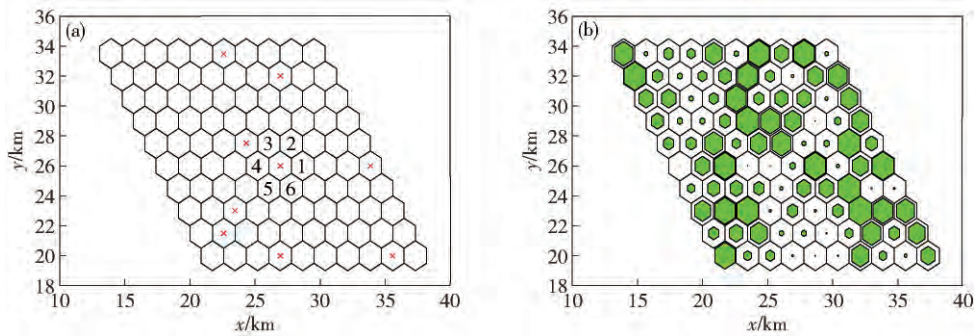


图4 目标和环境的初始状态. (a) 目标初始位置; (b) 初始环境不确定图

Fig.4 Initial state of target and environment: (a) initial position of the target; (b) initial environment uncertainty

架无人机对不同仿真步数分别做10次搜索并计算发现目标平均数,搜索步数分别是30、60、90、120和150.搜索策略有效性,即在相同搜索时间内,发现目标数越多,搜索策略越好,算法性能也越好.因此,搜索策略有效性=发现目标平均数/目标总数.仿真结果表明,由于本文算法使用数字信息素完成无人机之间的协同,因此,相对另外两种算法能够发现更多的目标且大大提高了搜索的有效性.

5 结论

基于改进鸽群优化和动态目标运动模型提出一种多无人机协同搜索方法.首先,构建环境信息图、目标信息图、信息素图等,并建立符合马尔可夫链的目标运动模型,实现多无人机协同搜索建模.然后,采用改进鸽群优化算法完成优化求解.鸽群优化算法虽然具有收敛速度快、搜索效率高等优势,但容易陷入局部最优.因此,本文将柯西、高斯扰动分别加

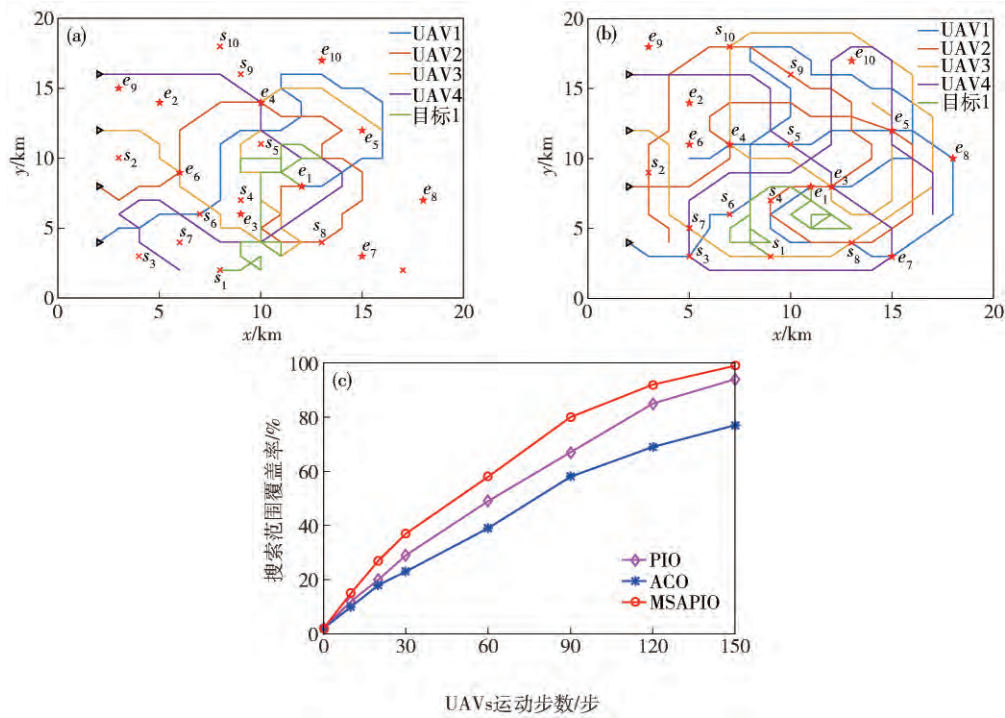


图5 无人机的运动轨迹和覆盖率。(a) 30步的运动轨迹; (b) 60步的运动轨迹; (c) 搜索范围覆盖率

Fig. 5 The movement trajectories of unmanned aerial vehicle: (a) the movement trajectory of 30 steps; (b) the movement trajectory of 60 steps; (c) search coverage

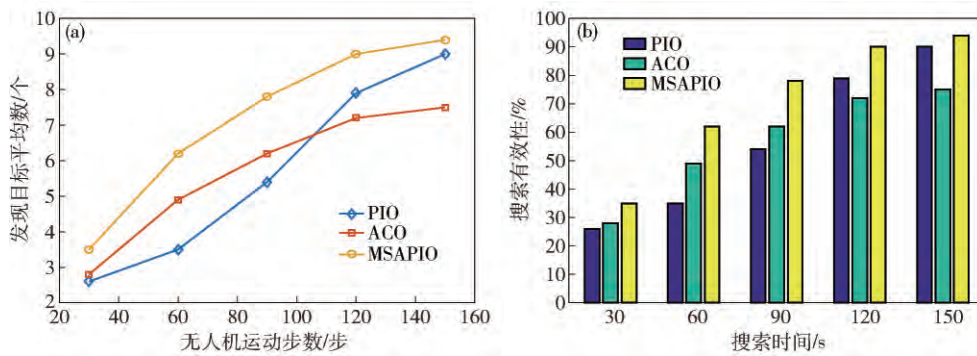


图6 协同搜索目标数和有效性评估。(a) 搜索目标平均数; (b) 有效性评估

Fig. 6 Effectiveness evaluation of collaborative search: (a) the average target number; (b) effectiveness assessment

入鸽群优化算法的两个算子中,并使用模拟退火机制保留次优个体,避免陷入局部最优。

参 考 文 献

[1] Qiu H X, Wei C, Dou R, et al. Fully autonomous flying: from collective motion in bird flocks to unmanned aerial vehicle autonomous swarms. *Sci China Inf Sci*, 2015, 58(12): 128201

[2] Peng H, Huo M L, Liu Z Z, et al. Simulation analysis of cooperative target search strategies for multiple UAVs // *The 27th Chinese Control and Decision Conference*. Qingdao, 2015: 4855

[3] Qiu H X, Duan H B. From collective flight in bird flocks to unmanned aerial vehicle autonomous swarm formation. *Chin J Eng*, 2017, 39(3): 317

(邱华鑫,段海滨. 从鸟群群集飞行到无人机自主集群编队. *工程科学学报*, 2017, 39(3): 317)

[4] Saadaoui H, El Bouanani F. Information sharing based on local PSO for UAVs cooperative search of unmoved targets // *2018 International Conference on Advanced Communication Technologies and Networking (CommNet)*. Marrakech, Morocco, 2018: 1

[5] Yang F, Ji X L, Yang C W, et al. Cooperative search of UAV swarm based on improved ant colony algorithm in uncertain environment // *2017 IEEE International Conference on Unmanned Systems*. Beijing, 2017: 231

[6] Duan H B, Qiao P X. Pigeon-inspired optimization: a new swarm intelligence optimizer for air robot path planning. *Int J Intell Comput Cybern*, 2014, 7(1): 24

[7] Duan H B, Ye F. Progresses in pigeon-inspired optimization algo-

- rithms. *J Beijing Univ Technol*, 2017, 43(1): 1
(段海滨, 叶飞. 鸽群优化算法研究进展. 北京工业大学学报, 2017, 43(1): 1)
- [8] Li C, Duan H B. Target detection approach for UAVs via improved pigeon-inspired optimization and edge potential function. *Aerosp Sci Technol*, 2014, 39: 352
- [9] Zhong Y, Yao P Y, Sun Y, et al. Method of multi-UAVs cooperative search for Markov moving targets // 2017 29th Chinese Control And Decision Conference (CCDC). Chongqing, China, 2017: 6783
- [10] Shen D, Wei R X, Ru C J. Digital-pheromone-based control method for UAV swarm search. *Syst Eng Electron*, 2013, 35(3): 591
(沈东, 魏瑞轩, 茹常剑. 基于数字信息素的无人机集群搜索控制方法. 系统工程与电子技术, 2013, 35(3): 591)
- [11] Kalivarapu V, Winer E. Digital pheromone implementation of PSO with velocity vector accelerated by commodity graphics hardware // *Proceedings of the 50th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference*. Palm Springs California, 2009: 1017
- [12] Bertuccelli L F, How J P. Search for dynamic targets with uncertain probability maps // 2006 American Control Conference. Minneapolis, MN, USA, 2006: 737
- [13] Kirkpatrick S, Gelatt C D, Vecchi M P. Optimization by simulated annealing. *Science*, 1983, 220(4598): 671
- [14] Lan K T, Lan C H. Notes on the distinction of Gaussian and Cauchy mutations // 2008 Eighth International Conference on Intelligent Systems Design and Applications. Kaohsiung, Taiwan, 2008: 272
- [15] Duan H B, Yang Z Y. Large civil aircraft receding horizon control based on Cauchy mutation pigeon inspired optimization. *Sci Sin Technol*, 2018, 48(3): 277
(段海滨, 杨之元. 基于柯西变异鸽群优化的大型民用飞机滚动时域控制. 中国科学: 技术科学, 2018, 48(3): 277)