

结合充电平台的蜂群无人机多任务调度优化

柯挚捷^{1,2}, 徐国宁^{1,2,*}, 蔡榕^{1,2}, 李永祥¹, 杨燕初^{1,2}

(1. 中国科学院空天信息创新研究院, 北京 100094; 2. 中国科学院大学航空宇航学院, 北京 100049)

摘 要: 蜂群无人机因其数量多、成本低和统一调度等特点, 具有广泛应用前景。统一调度是蜂群无人机研究的热点和难点, 现有研究主要针对小规模、短时间场景, 未考虑充电任务等复杂场景。面向未来多任务和长时间应用, 调度优化需考虑中途充电等因素的影响。提出一种基于统一调度模型和遗传算法改进的蜂群无人机任务调度方法。将无线充电平台资源纳入无人机工作环境中, 并对工作场景进行系统建模; 使用遗传算法对任务和充电平台资源调配进行优化求解。利用仿真实验进行验证, 结果表明: 所提方法可以有效适应任务、环境和资源的变化, 适用于大规模蜂群无人机多任务场景。

关 键 词: 蜂群无人机; 调度优化; 遗传算法; 调度模型; 无人机充电

中图分类号: V219

文献标志码: A

文章编号: 1001-5965(2025)08-2782-10

蜂群无人机是由大量小型无人机组成, 通过相互协作和信息沟通, 以群体形式完成复杂任务的无人机系统^[1]。相比于单个无人机, 蜂群无人机可以更快、更灵活地完成任务, 在动态复杂多任务条件下是具有成本和规模优势, 因而在侦查打击、测控搜索、物流运输等军民领域具有广泛的应用前景^[1-3]。随着蜂群无人机规模的扩大和任务种类的增多, 对无人机任务和资源的合理调配已成为制约蜂群无人机应用的关键因素之一^[2]。

蜂群无人机的任务分配问题是一类非确定性多项式完全问题, 通常不能在多项式时间代价下找到最佳方案^[4]。随着蜂群中无人机和待完成任务数量的增加, 分配计算的代价呈指数增长, 传统的多元方程组优化方法已难以解决多架次多任务的调度优化问题。

蜂群无人机调度中存在多种类型的约束条件, 如无人机资源约束^[5]、任务时效约束^[6]、空间地形约束^[7]和收益约束(任务完成时间、能量消耗)^[8]等。

近年来, 随着计算机算力水平的提升和人工智

能技术的兴起, 越来越多的研究将智能算法引入蜂群无人机任务调度优化问题。Gao 等^[9]基于蚁群算法, 提出一种解决多无人机在对抗环境下在线搜索并完成攻击任务的分布式自组织算法。Wu 等^[10]研究了异质无人机蜂群执行多个任务的调度和轨迹优化问题, 使用分布式遗传算法得到最佳解决方案。Oh 等^[11]基于粒子群算法, 提出一种针对蜂群无人机的最优任务分配算法。这些智能优化算法的使用, 极大提升了该类问题的求解效率, 扩大了可以求解的问题规模。其中, 遗传算法以其良好的适应性、并行性和全局寻优能力, 成为蜂群无人机调度中最常用的方法之一^[3]。

受限于电源技术和无人机承载能力, 现有蜂群无人机普遍续航时间短, 需要经常充电。随着无线充电技术的进步, 尤其是对多旋翼无人机进行自动、非接触式充电方法的研究和应用越来越丰富和成熟, 利用无线输能^[12-13]技术对无人机实现无线充电成为可能, 也增加了充电的便利性。而充电平台数量通常明显少于无人机数量, 因而无人机常常需

收稿日期: 2022-05-26; 录用日期: 2022-11-19; 网络出版时间: 2023-01-11 08:42

网络出版地址: link.cnki.net/urlid/11.2625.V.20230109.1735.008

基金项目: 中国科学院战略性先导科技专项 (XDA17020304)

* 通信作者. E-mail: xugn@aircas.ac.cn

引用格式: 柯挚捷, 徐国宁, 蔡榕, 等. 结合充电平台的蜂群无人机多任务调度优化 [J]. 北京航空航天大学学报, 2025, 51 (8): 2782-2791.

KE Z J, XU G N, CAI R, et al. Optimization of multi-mission scheduling for swarm UAVs with charging platform [J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51 (8): 2782-2791 (in Chinese).

要排队等待充电^[14]。蜂群无人机充电资源分配和充电排队问题同样引起了国内外研究者的广泛关注。Kim 等^[15]研究了基于云的无人机导航系统, 通过对无人机路线的调度降低充电平台拥塞的程度; Shin 等^[16]采用基于拍卖的深度学习框架, 研究了控制移动式充电站对多无人机充电的调度问题; 王云哲等^[14]从排队理论出发, 研究了分布式和集中式充电站的队列长度及等待时间与服务强度(单位时间内需要充电的无人机数量)的关系。

然而, 较少研究将任务调度和充电资源分配结合起来进行协同优化, 同时, 现有研究中的蜂群无人机规模较小, 通常小于 10 个无人机, 而更大机群的实际需求对调度系统提出了新的要求。另外, 缺乏使用统一建模方法和模块化系统设计的研究^[3]。

鉴于此, 本文提出一种改进的蜂群无人机任务调度方法, 将无线充电平台资源纳入无人机工作环境中, 同时分离资源、任务和环境信息的输入与智能算法求解过程, 对工作场景进行统一建模, 使用遗传算法对任务和充电平台资源调配进行优化求解。本文方法将环境因素(风力、高度变化)等引入到工作场景模型中; 同时, 考虑无人机在高度方向飞行的时间, 并根据多旋翼无人机相关研究确定飞行剖面; 允许无人机在任务前后到无线充电平台充电。

1 无人机调度模型设计

1.1 无人机工作场景

无人机的工作场景主要由无人机、目标点(任务)、资源点(充电平台)及工作环境构成。图 1 展示了无人机工作场景的平面示意。工作场景中存在 n 台无人机($U = \{U_1, U_2, \dots, U_n\}$)、 m 个目标点($M = \{M_1, M_2, \dots, M_m\}$)及 p 个资源点($P = \{P_1, P_2, \dots, P_p\}$)。无人机由初始位置出发, 顺序前往一个/多个目标点执行任务后, 前往充电平台(资源点)充电, 或充电后再前往一个/多个目标点执行任务, 最后返回最近

的充电平台。

工作环境包括工作空间中的地形、障碍物、天气及禁飞空域等自然或人为条件, 这些条件限制了无人机从某一地点前往其他地点的路径, 改变无人机飞行消耗的时间及能量资源。出于模型简便和统一的需要, 对工作场景做出如下限制: ①无人机的型号及载荷相同, 即任意一台无人机均可完成所有任务; ②资源点各自具有固定的位置和充电速度; ③无人机执行的任务均设定为单点任务。

对于实际任务中需要巡视、覆盖或搜索一定区域的任务, 假设其出入口位置相同, 具体消耗的时间和能量资源在任务属性中加以明确。同时, 任务可以指定截止时间。

在实际应用场景中, 任务与无人机、无人机与资源点的对应关系随其数量变化而变化。当任务数量 m 大于无人机数量 n 时, 必然存在单台无人机执行多个任务; 反之, 则部分无人机可能无需执行任务。无人机任务分配可以使用二叉决策变量表示:

$$d_{i,j} \in \{0,1\} \quad i \in U, j \in M \tag{1}$$

若由无人机 i 执行任务 j , 则 $d_{i,j} = 1$, 反之 $d_{i,j} = 0$ 。

同理, 充电资源的分配也可以使用二叉决策变量表示:

$$e_{i,k} \in \{0,1\} \quad i \in U, k \in \{P \cup \{0\}\} \tag{2}$$

式中: $k = 0$ 表示无人机直接完成任务而不进行充电。

无人机任务和资源调度的主要工作, 除了确定无人机任务分配, 指定无人机补充能量的资源点, 还包括确定对无人机执行任务的顺序和充电顺序。

通常情况下, 充电平台的数量小于无人机和任务的数量, 因而无人机可能要在充电平台排队等候充电, 对于无人机充电顺序的优化同样是无人机调度中需要考虑的一点。

合理的任务及资源分配可以使各个无人机执行的任务数量较为平均, 任务和资源分配尽可能优化, 从而保证任务尽快完成, 并尽可能避免任务超时。

1.2 无人机任务调度模型

1.1 节所述无人机工作场景可以使用有向图的结构表示。有向图是图结构的一种, 其为由顶点集合和顶点间关系(边)集合组成的一种数据结构, 且其顶点间关系为有序对^[17]。

有向图中的“顶点”可以代表目标点、资源点和无人机初始位置, 而各点间有序对(有向边)及其权值可以代表无人机从一点飞到另一点所需要的时间或能量资源, 图 2 展示了图 1 工作场景中部分点及其相连边。图中: 第 1 行数字为飞行时




图 1 无人机工作场景平面示意图
Fig. 1 UAV working scenario




图2 无人机任务调度的有向图模型

Fig. 2 Directed graph model for UAV mission scheduling

间(单位: s);第2行括号内数字为消耗的能量(单位: Wh)。

无人机往返于两点间的资源消耗可能不同,这是考虑了两点间高度差、风力等环境因素的结果;部分节点间没有边相连,意味着两点间不可通行(存在禁飞区、单程距离超过无人机最大航程等)或无通行意义(各无人机初始点间、充电平台之间)。

无人机、目标点(任务)和资源点(充电平台)构成了模型中的“顶点”。3种不同的顶点具有不同的属性:

1) 无人机: 初始位置坐标、初始电池容量、电池总容量。假定蜂群无人机中各无人机型号相同,因而飞行速度、飞行功率等参数为机群共享。考虑到无人机存在电池损耗现象,各机实际电池容量参数可能不同,因而也将其作为个体参数。

2) 任务(目标): 位置坐标、任务用时、任务耗电量 and 任务截止时间。任务耗电量与任务内容有关,根据具体任务需求确定任务执行耗电量;无人机应在任务截止时间前完成任务。

3) 充电平台(资源): 位置坐标及充电(输出)功率。充电平台是固定放置的无线充电平台,考虑到模型的实际情况,充电平台可能具有不同的输出功率(如由于污染、设备损坏造成输出功率下降等情况)。

1.3 无人机飞行代价计算

建立调度模型的一个重要前提是获得无人机从某一点 A (初始点、目标点或资源点) 飞到另一点 B (目标点或资源点) 预期使用的时间和能量,即图2各边上标注的权值(无人机飞行的时间和能量代价)。

在实际的无人机任务中,无人机的飞行轨迹规划需结合任务和机身特点、障碍物和空中管制等因素确定。而飞行代价的计算,除了要考虑飞行轨迹

规划,还需要考虑风力等天气因素。

参考现有的关于无人机飞行轨迹^[18]、无人机飞行任务剖面^[19]的研究,以及无人机飞行相关的规定,结合实际的无人机设计和控制,确定无人机的飞行剖面如图3所示。无人机从出发点垂直爬升至距离地面 90 m 高度,维持高度平飞至目标点,下降至距离目标位置 10 m 高度,悬停 30 s 调整位置和姿态,最后垂直下降至目标点。平飞阶段规避障碍物、禁飞区的轨迹设计需结合具体场地情况进行确定,在模型和调度系统测试中,采用随机增加的平飞航程代替。




图3 无人机飞行剖面

Fig. 3 UAV flight profile

在飞行轨迹的基础上确定时间和能量消耗。飞行总时间为 $t = t_c + t_s + t_{d1} + t_h + t_{d2}$ 。其中, t_c 、 t_s 、 t_d 和 t_h 分别为爬升、巡航、下降和悬停时间。爬升和下降时间可以根据高度和速度直接确定,悬停时间在前文已经给出。考虑风对飞行的影响,巡航时间的计算如下:

$$t_s(\mathbf{v}_w + \mathbf{v}_s) = \mathbf{x}_B - \mathbf{x}_A \quad (3)$$

式中: $\mathbf{v}_w$ 为风矢量; $\mathbf{v}_s$ 为无人机飞行速度矢量; $\mathbf{x}_B$ 和 $\mathbf{x}_A$ 分别为目标和出发点的位置。

假设工作空间内风场是均匀的,将环境风以风速 $|\mathbf{v}_w|$ 和风向 θ (按一般高空风向表示方法,以北风 N 为 0° ,东风 E 为 90° ,南风 S 为 180° ,西风 W 为 270° ,计算角度) 的形式给出,可以推算出无人机以 $\mathbf{v}_s$ 的速度相对大气运动并在地面坐标系中保持由 A 点飞向 B 点的速度和所需时间。速度合成关系如图4所示,可以得到相对地面速度大小 $|\mathbf{v}_g|$:

$$|\mathbf{v}_g| = |\mathbf{v}_w| \cos \alpha + |\mathbf{v}_s| \sqrt{1 - \left(\frac{|\mathbf{v}_w|}{|\mathbf{v}_s|} \sin \alpha \right)^2} \quad (4)$$

式中: α 为由 A 点指向 B 点的矢量 $(\mathbf{x}_B - \mathbf{x}_A)$ 与风向的夹角。对于图4(a)和图4(b)中的2种情形, α 分别等于 $(\varphi - \theta - \pi)$ 和 $(\varphi - \theta + \pi)$, φ 为由 A 点到 B 点的矢量 $(\mathbf{x}_B - \mathbf{x}_A)$ 与正北方向的夹角。

将式(4)代入式(3),可以得到平飞用时为

$$t_s = \frac{|\mathbf{x}_B - \mathbf{x}_A|}{\sqrt{|\mathbf{v}_s|^2 - |\mathbf{v}_w|^2 \sin^2(\theta - \varphi)}} \quad (5)$$

飞行能量消耗可以用各飞行阶段的功率和用




图 4 无人机在风中飞行的速度合成

Fig. 4 Speed vector synthesis of UAV flying in wind condition

时的乘积进行计算, 无人机不同飞行状态下的消耗功率略有不同, 参考已有的无人机动力系统性能评估模型^[20]和相关实验数据^[21], 结合实际工况, 估计无人机各状态参数, 得到平均速度及平均功率如表 1 所示。

表 1 无人机不同飞行状态下的平均速度及平均功率

Table 1 Average speed and average power consumption of UAV in different flight conditions

状态	平均速度/(m·s ⁻¹)	平均功率/W
悬停		160.8
爬升	3	320.0
巡航	14	185.0
下降	3	128.0

至此, 建立了无人机调度系统模型, 并对模型中参数进行了确定。给定一组任务及资源分配计划, 利用该模型可模拟任务执行过程, 并给出预期的任务执行结果, 如蜂群无人机群完成全部任务所需的时间、消耗的总能量以及是否存在任务超时、超时的时长等, 以得到优化算法所需的适应度数据。

2 基于遗传算法的无人机调度优化

遗传算法是一种模拟自然界生物进化过程与机制进行问题求解的自组织、自适应的随机搜索算法, 其基本思想是从初始种群出发, 采用优胜劣汰、适者生存的自然法则选择个体, 并通过交叉、变异产生新一代种群, 如此逐代进化, 直到满足目标。本文采取的遗传算法流程如图 5 所示。

2.1 编码方式

本文将个体的编码分为 3 段染色体: 第 1 段为任务分配, 共有 m (任务总量) 位, 其取值为 $1 \sim n$ (无人机总量) 之间的整数, 数值表示对应编号的任务由相应编号的无人机完成; 第 2 段为任务优先度, 同样有 m 位, 其取值范围为 $0 \sim 1$ 之间的浮点数, 表示对应编号任务的执行优先度, 同一架无人机执行多个任务时按照优先度由大到小执行; 第 3 段为资源分配, 共有 n 位, 取值为 $0 \sim p$ (充电平台总量) 之间的整数, 表示对应编号的无人机前往相应充电平




图 5 遗传算法流程

Fig. 5 Flow chart of genetic algorithm

台充电, 其中, 0 表示无人机直接执行任务, 不进行充电。

图 6 展示了一个完整的编码示例。按照上述规则, 其表示: 无人机 1 依次执行任务 5 和任务 1, 并前往充电平台 1 充电; 无人机 2 依次执行任务 3 和任务 4, 并前往充电平台 3 充电; 无人机 3 直接执行任务 2 而不前往充电平台充电。




图 6 染色体编码方式

Fig. 6 Encoding of chromosome

2.2 适应度函数和选择算子

对于按照编码方式编码的一个个体 (即一套任务分配方案), 利用第 1 节介绍的无人机调度模型计算出单架无人机完成全部任务所需的时间 T_i 、单架无人机能量消耗 E_i 及各任务超时量 τ_i 。在任务分配的优化中, 需要使完成全部任务的时间最短, 同时减少任务执行的超时量和蜂群总的能量消耗。问题的约束条件主要有: ①每个任务均由恰好一个无人机完成; ②无人机在过程中不因电量耗尽坠毁。因此, 调度优化问题可以表示为

$$\min_{x,y} \left(\max(T_i), \sum E_i, \sum \tau_i \right)$$
$$\text{s.t.} \begin{cases} X = \{d_{i,j} \in \{0,1\} | i \in U, j \in M\} \\ Y = \{e_{i,k} \in \{0,1\} | i \in U, k \in P \cup \{0\}\} \\ \sum_{i=1}^n x_{i,j} = 1 \quad \forall j \in M \\ \text{Batt}_i(t) \geq 0 \quad \forall t \in [0, T_i], \forall i \in U \end{cases} \quad (6)$$

式中: X 和 Y 分别为任务和充电平台分配的二叉决

策变量的集合; $Batt_i(t)$ 为无人机*i*在*t*时刻的电池剩余电量。

针对上述多目标优化问题,通常很难使每个目标都取到最优解^[22],通常会结合对目标的已知信息和实际应用场景需求对多个优化目标进行组合转变为单目标优化^[23],常用的形式包括线性加权和、基于相互关系的评价公式和 ε -约束方法3种^[24]。在实际的蜂群无人机工作场景中,通常这3个目标的优先度依次是减少任务超时、减少最大用时和减少能耗。此外,对于同一个无人机,时间的减少通常与能耗降低正相关,而无人机群规模较大时总能耗 $\sum_n E_i$ 为一个很大的正数,需要加以限制以避免影响整体优化,对数函数可以有效降低其增长速度。综上,选定适应度函数为

$$\min(f) = \max(T_i) + K \sum_m \tau_i + \lg \left(\sum_n E_i \right) \quad (7)$$

式中: K 为系数,以调节不同参数的显著度,本文取 $K=10$ 。

优化目标为适应度函数的最小值,故设定终止条件为:连续5次迭代中种群的平均适应度相比上一代无减小,或达到最大迭代次数。

在选择环节,采用排序选择和最佳个体保存^[25]相结合的方法。首先,对种群按照适应度函数值由小到大排序,将最小的个体直接保留下来,其他个体则根据给定的概率值随机选择,概率值由式(8)确定:

$$H(i) = e^{-i/\sqrt{N}} - e^{-(i+1)/\sqrt{N}} \quad (8)$$

式中: N 为总个体数; i 为排序后该个体所处的位置。该函数为单调递减函数,当 N 较大时, $\sum_{i=1}^N H(i) \approx 1$,满足选择的需要。

2.3 变异与交叉

通过选择的个体,还需要经过变异和交叉操作才能形成新的种群。变异和交叉可以增强种群多样性,遗传算法中的遗传和交叉操作可以增加算法的局部随机搜索能力,避免提前收敛到局部最优。

针对本文使用的编码方式,变异操作均采用简单变异,对于染色体编码中的每一位,先根据预先设定的变异概率 Q_m 判断是否发生变异,若该位发生变异,则在取值范围内随机选取一个值作为变异结果。

交叉操作采用相邻的一对个体*C*和*D*进行(由于选择操作的随机性,此处相邻两个个体完全是随机的),对于任务分配和资源分配采用两点交叉,对于任务优先度采用实值交叉法。具体操作如下:

- 1) 根据预先设定的交叉概率 Q_c 判断该段染色体是否发生交叉。
 - 2) 随机确定交叉起始位置*g*和结束位置*h*。
 - 3) 对于任务分配段,将*C*的0~(*g*-1)位、*D*的*g*~*h*位、*C*的(*h*+1)~*n*位连接形成第1个子代;将*D*的0~(*h*-1)位、*C*的*g*~*h*位、*D*的(*h*+1)~*n*位连接形成第2个子代。
 - 4) 对于任务优先级段,取一个0~1之间的随机数*a*,对于第*g*~*h*位中的某一位*z*,第1个子代取 $aC_z + (1-a)D_z$,第2个子代取 $aC_z + (1-a)D_z$ 。
- 经过选择、变异与交叉操作,得到新一代种群,根据算法流程,再对这代种群计算适应度函数。如此反复迭代,直到满足终止条件。

3 仿真实验结果与分析

对第1节和第2节所述的模型和算法,采用若干组特别选取或随机生成的工作场景进行仿真实验,测试方法的效果和适用性。使用Python语言实现上述模型和算法,并进行仿真实验。实验分为2个部分:

- 1) 采用一组小规模(任务数 ≤ 10)样本验证任务分配结果的有效性,测试不同任务及环境参数(目标高度、任务截止时间及环境风力)的区别。
- 2) 采用不同规模(任务数 > 10)的多个样本及中等规模的大量随机样本,测试方法的适应性、稳定性和计算效率。

3.1 任务及环境参数测试

测试样本的平面图如图1所示,任务*M*₁、*M*₂和*M*₃聚集在任务空间东南部,*M*₄和*M*₅位于西北侧,无人机和充电平台居于中央。本节采用5个测试样本进行环境比较,样本设置如表2所示,其中,除基准样本外,只标注了不同于基准样本的参数。

任务均设定为访问型任务(任务执行时间为30 s,耗电量等于悬停30 s所需电量)。对于5个样

Table 2 Test case environment and mission parameters	
样本	特征
1(基准)	风力: 无风 目标点高度: 均为0 m 任务截止时间: 均为1 h 充电平台功率: 120 W 无人机初始电量: U_1 、 U_2 为30 Wh, U_3 为40 Wh
2(有风)	风力: 东风 8 m/s(约5级风)
3(高度)	目标点高度: M_1 为30 m; M_2 为90 m; M_4 为500 m
4(截止时间)	任务截止时间: M_2 为15 min; M_3 为20 min; M_5 为10 min
5(充电平台)	充电平台功率: P_1 为120 W; P_2 为60 W

本, 分别计算得到任务调度模型, 并使用遗传算法进行调度优化。各样本采用的遗传算法参数相同, 种群个体总数 $N = 128$, 交叉概率 $Q_C = 0.8$, 变异概率 $Q_M = 0.1$, 最大迭代次数 $G_{\max} = 100$ 。

5 个测试样本的分配结果如图 7 所示。对于基

准样本, 如图 7(a) 所示, 其优化结果主要反映了执行任务时间的最小化: 由无人机 U_2 就近前往 P_2 充电, 随后执行 M_2 、 M_3 和 M_1 任务; 由无人机 U_1 前往 P_1 平台充电, 之后执行 M_4 任务; 由无人机 U_3 直接执行任务 M_5 。




图 7 遗传算法优化后的任务及资源分配

Fig. 7 Mission and resource allocation optimized by genetic algorithm

样本 2 环境中的东风使向西飞行更节约时间和燃料, 而向东飞行更困难。图 8 对比了采用基准样本结果和针对样本 2 优化后结果的无人机执行时间序列。可以看到, 针对样本 2 的环境因素优化后, 无人机 U_3 长距离向西飞行经平台 P_1 充电后执行任务 M_5 和 M_4 , 在场地东部的任务 $M_1 \sim M_3$ 由 2 架无人机共同完成, 实际上节省了执行时间。从结果上看, 针对该场景的优化完成最后一个任务(无人机 2 完成任务 1)的时间开始后为 1 943.4 s, 相比针对基准样本优化的分配(在该场景下为 2 099.4 s)提前了 156 s, 但总耗能略有增加(约 6.5%), 体现了适应度函数对降低耗时的优先性。

如图 7(c) 所示, 由于 M_4 具有较高的高度, 飞向它需要更长的时间, 因而使用初始电量较多的无人机 U_3 执行, 并相应调整了其他无人机的任务分配情况。针对该场景的优化结果相比基准样本结果最大用时减少了 50.4 s, 同时, 能量消耗增加了 13.6%。

样本 4 中, 截止时间的加入造成任务 M_2 和 M_3 的尽快执行具有更高优先级, 因而算法选择让无人




图 8 样本 2 用时对比

Fig. 8 Comparison of time consumption for case 2

机 U_2 在充电平台 P_2 短暂充电后执行这 2 个任务以保证及时性, 如图 7(d) 所示。针对该场景的优化结果相比基准样本结果最大用时增加了 850.9 s, 能量消耗减少 2.4%, 但总超时从 565.2 s 减少到 0。

样本 5 中, 充电平台 P_2 充电功率下降, 因而将 $M_1 \sim M_3$ 分给 2 架无人机完成。图 9 对比了使用基准任务分配和针对样本 5 优化后结果在样本 5 上执行的区别。该场景下, 针对性优化结果相比基准样本结果最大用时减少了 558.9 s, 能量消耗增加 2.5%。

在样本 2~5 场景下, 使用基准样本结果和针对性优化结果的测试结果(最大用时、总能耗及总超时)对比如表 3 所示。

对于该组样本的任务及资源数量, 可能存在的任务及资源分配方式(考虑任务执行顺序)共有

$$\begin{aligned} & (A_5^5C_3^1 + A_5^4A_5^3 + A_5^3A_2^2A_3^3 + A_5^3A_3^3 + A_5^2A_3^2C_3^1) \times \\ & (1+2)^3 = 61\,560 \end{aligned}$$

(9)




图 9 样本 5 用时对比
Fig. 9 Comparison of time consumption for case 5

表 3 基准与针对性优化对比												
Table 3 Comparison between benchmark and case-by-case optimization												
样本	最大用时 $\max(T_i)/s$				总能耗 $\sum_n E_i/J$				总超时 $\sum_m \tau_i/s$			
	基准	优化	差值	变化幅度/%	基准	优化	差值	变化幅度/%	基准	优化	差值	变化幅度/%
2	2 099.4	1 943.4	-156.0	-7.4	593 073	631 580	38 507	6.5				
3	2 459.0	2 408.6	-50.4	-2.0	649 034	737 293	88 259	13.6				
4	1 736.0	2 586.9	850.9	49	556 448	543 233	-13 215	-2.4	565.2	0	-565.2	-100
5	2 605.6	2 046.7	-558.9	-21	556 447	570 351	13 904	2.5				

注: 差值负数表示针对性优化减小。

显然, 其中包含了很多无效分配(如让一台无人机执行所有任务、所有无人机均不充电的分配等), 但依然从侧面说明了任务分配问题在计算上的困难性。当然, 由于较小的任务规模, 其总量依然是可以遍历的。采用遍历的方法对结果的有效性进行验证, 结果表明, 对于上述 5 种样本, 遗传算法得出了最优解。

3.2 场景规模测试

设置工作场景为 10 km×10 km 的矩形区域, 共放置 6 个充电平台。充电平台位置如表 4 所示。充电平台均匀分布放置, 对于场景内无人机较多的情况, 可以有效减小充电队列长度, 缩短充电等待时间^[14]。

目标点和无人机在工作场景范围内随机生成, 各样本任务和无人机数量如表 5 所示。

对每个样本使用遗传算法进行 3 次计算, 以验证计算结果的稳定性, 记录每次计算的结果、适应度函数值变化及算法执行所需时间, 如表 6 所示。由于样本中任务和无人机数量的不同对算法需要

搜索的空间影响极大, 进而对遗传算法合理的种群数量产生影响, 故对不同任务采用不同的种群规模。

由表 6 可知, 随着任务和无人机数量的增加,

表 4 大规模测试充电平台位置

Table 4 Charging platform location in large-scale tests			
样本	平面位置/km	高度/m	充电功率/W
1	(5.000, 2.000)	0	120
2	(7.598, 3.500)	25	120
3	(7.598, 6.500)	0	90
4	(5.000, 8.000)	0	120
5	(2.401, 6.500)	25	80
6	(2.401, 3.500)	0	120

表 5 测试样本任务及无人机数量

Table 5 Number of missions and UAVs in test cases		
样本	任务数	无人机数
1	10	10
2	20	16
3	32	24
4	48	32
5	64	48

表 6 不同任务规模样本测试结果

Table 6 Test results for samples with different mission scales

样本	种群规模 N	最大迭代数	$\max(T_i)/s$	$\sum_m \tau_i/s$	$\min(f)$	计算用时/s
1	256	100	3 130	0	4.5×10^4	7.2
	256	100	3 136	0	4.5×10^4	7.3
	256	100	3 014	0	4.5×10^4	7.3
2	512	100	7 803	361.9	1.7×10^5	19.8
	512	100	7 249	2 850	5.4×10^5	20.5
	256	200	6 683	2 435	4.7×10^5	19.7
3	512	200	6 644	31 803	5.0×10^6	56.4
	1 024	100	7 164	32 238	5.1×10^6	57.3
	1024	200	6 320	23 506	3.7×10^6	112.3
4	1 024	200	9 177	89 641	1.4×10^7	149.5
	2048	200	11 888	145 724	2.3×10^7	303.9
	2048	200	11 889	145 723	2.3×10^7	304.2
5	2048	200	7 057	64 259	1.0×10^7	432.2
	2048	200	7 976	67 623	1.1×10^7	442.4
	2048	400	7 334	59 060	9.6×10^6	879.9

为得到较好的计算结果,所需要付出的计算代价成倍增加。对于任务数 $m \leq 32$ 的样本,采用的遗传算法还较易得出优化结果,对于更大规模的问题,优化的时间和空间代价快速增加,后续研究将对大规模任务问题进行拆分处理。此外,充电平台数量相对无人机总量过少、充电速度较慢、无人机续航较短等原因加剧了调度面临的困难。

在对算法应对不同蜂群规模和任务数进行测试的基础上,使用中等规模(任务数 10~32)的大量随机样本,进一步测试算法的适应能力和稳定性。采取与表 5 中样本 1~3 相同的任务数和无人机数组合,对每种组合随机生成 50 个样本,并对每个样本使用遗传算法进行 3 次优化,得出 3 次优化结果适应度函数变异系数(标准差除以平均值)和平均运行时间,再对相同组合的 50 个样本取平均,结果如表 7 所示。

由表 7 可知,本文方法对于中等规模的样本具有较好的分配效果,多次优化的结果虽然不完全一致,但用时和资源消耗十分接近;同时,计算用时随

表 7 大规模随机样本测试结果

Table 7 Test results of large-scale random samples

样本	(任务数, 无人机数)	平均适应度函数 变异系数	平均运行 时间/s
1	(10,10)	0.07	7.91
2	(20,16)	0.01	19.47
3	(32,24)	0.03	112.75

着任务规模的增大快速增加。

4 结 论

1) 介绍了一种考虑无人机充电的蜂群无人机任务调度模型,其考虑了无人机中途充电、任务截止时间和优先度、目标点海拔与无人机飞行剖面等实际工况,并根据多旋翼无人机的飞行特性优化。

2) 设计了一种无人机任务及资源调度方法,探索遗传算法对于大规模无人机任务调度的实际效果。测试结果表明,本文方法实现了蜂群无人机执行不同环境的工作场景的调度优化;且基于遗传算法的调度优化对于较大规模的蜂群无人机任务和资源调度能够取得较好的效果。

3) 任务调度模型提供了一种有效将无人机工作场景中的各种任务及环境要素抽象出来的方法,可以有效提高后续各种调度优化算法的开发和测试效果,为研究更高效的优化算法提供依据。

参考文献 (References)

[1] 杨健,程程,谢旭,等. 无人机蜂群对面攻击任务规划能力需求研究[C]//第九届中国指挥控制大会. 北京: 中国指挥与控制学会, 2021: 252-258.

YANG J, CHENG C, XIE X, et al. Study on the mission planning requirements in the UAV swarms air to surface attack operations[C]//Proceedings of the 9th China Command and Control Conference. Beijing: Chinese Institute of Command and Control, 2021: 252-258(in Chinese).

[2] 焦士俊,王冰切,刘剑豪,等. 国内外无人机蜂群研究现状综述[J]. 航天电子对抗, 2019, 35(1): 61-64.

JIAO S J, WANG B Q, LIU J H, et al. Review of drone swarm research at home and abroad[J]. Aerospace Electronic Warfare, 2019, 35(1): 61-64(in Chinese).

[3] 杜永浩,邢立宁,蔡昭权. 无人飞行器集群智能调度技术综述[J]. 自动化学报, 2020, 46(2): 222-241.

DU Y H, XING L N, CAI Z Q. Survey on intelligent scheduling technologies for unmanned flying craft clusters[J]. Acta Automatica Sinica, 2020, 46(2): 222-241(in Chinese).

[4] CHEN G S, CRUZ J B. Genetic algorithm for task allocation in UAV cooperative control[C]//AIAA Guidance, Navigation, and Control Conference and Exhibit. Reston: AIAA, 2003: 5582.

[5] DI FRANCO C, BUTTAZZO G. Coverage path planning for UAVs photogrammetry with energy and resolution constraints[J]. Journal of Intelligent & Robotic Systems, 2016, 83(3): 445-462.

[6] AHMADZADEH A, SAYYAR-ROUDSARI B, HOMAIFAR A. A hybrid projected gradient-evolutionary search algorithm for capacitated multi-source multiuavs scheduling with time windows[M]// BUTENKO S, MURPHEY R, PARDALOS P M. Recent developments in cooperative control and optimization. Berlin: Springer, 2004: 1-21.

[7] 赵明,苏小红,马培军,等. 复杂多约束 UAVs 协同目标分配的一种统一建模方法[J]. 自动化学报, 2012, 38(12): 2038-2048.

ZHAO M, SU X H, MA P J, et al. A unified modeling method of UAVs cooperative target assignment by complex multi-constraint conditions[J]. *Acta Automatica Sinica*, 2012, 38(12): 2038-2048(in Chinese).

[8] RAMIREZ-ATENCIA C, BELLO-ORGAZ G, R-MORENO M D, et al. A hybrid MOGA-CSP for multi-UAV mission planning[C]// Proceedings of the Companion Publication of the 2015 Annual Conference on Genetic and Evolutionary Computation. New York: ACM, 2015: 1205-1208.

[9] GAO C, ZHEN Z Y, GONG H J. A self-organized search and attack algorithm for multiple unmanned aerial vehicles[J]. *Aerospace Science and Technology*, 2016, 54: 229-240.

[10] WU W N, WANG X G, CUI N G. Fast and coupled solution for cooperative mission planning of multiple heterogeneous unmanned aerial vehicles[J]. *Aerospace Science and Technology*, 2018, 79: 131-144.

[11] OH G, KIM Y, AHN J, et al. PSO-based optimal task allocation for cooperative timing missions[J]. *IFAC-PapersOnLine*, 2016, 49(17): 314-319.

[12] SONG Y Q, SUN X Y, WANG H X, et al. Design of charging coil for unmanned aerial vehicle-enabled wireless power transfer[C]// Proceedings of the 8th International Conference on Power and Energy Systems. Piscataway: IEEE Press, 2018: 268-272.

[13] JEONG S, BITO J, TENTZERIS M M. Design of a novel wireless power system using machine learning techniques for drone applications[C]//Proceedings of the IEEE Wireless Power Transfer Conference. Piscataway: IEEE Press, 2017: 1-4.

[14] 王云哲, 徐国宁, 王生, 等. 蜂群无人机充电排队优化方法[J]. *航空学报*, 2020, 41(10): 323928.

WANG Y Z, XU G N, WANG S, et al. Optimization of charging queuing of UAV swarming[J]. *Acta Aeronautica et Astronautica Sinica*, 2020, 41(10): 323928(in Chinese).

[15] KIM J, KIM S, JEONG J, et al. CBDN: cloud-based drone navigation for efficient battery charging in drone networks[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 20(11): 4174-4191.

[16] SHIN M, KIM J, LEVORATO M. Auction-based charging scheduling with deep learning framework for multi-drone networks[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(5): 4235-4248.

[17] 殷人昆. 数据结构: 用面向对象方法与 C++语言描述[M]. 2 版. 北京: 清华大学出版社, 2007.

YIN R K. Data structure: described by object-oriented method and C++ language[M]. 2nd ed. Beijing: Tsinghua University Press, 2007(in Chinese).

[18] 张启瑞, 魏瑞轩, 何仁珂, 等. 城市密集不规则障碍空间无人机航路规划[J]. *控制理论与应用*, 2015, 32(10): 1407-1413.

ZHANG Q R, WEI R X, HE R K, et al. Path planning for unmanned aerial vehicle in urban space crowded with irregular obstacles[J]. *Control Theory & Applications*, 2015, 32(10): 1407-1413(in Chinese).

[19] 赵焱飞, 郑雨欣. 城市物流无人机飞行任务剖面构建与优化[J]. *飞行力学*, 2021, 39(3): 54-59.

ZHAO Y F, ZHENG Y X. Construction and optimization of flight mission profile of urban logistics UAV[J]. *Flight Dynamics*, 2021, 39(3): 54-59(in Chinese).

[20] SHI D J, DAI X H, ZHANG X W, et al. A practical performance evaluation method for electric multicopters[J]. *IEEE/ASME Transactions on Mechatronics*, 2017, 22(3): 1337-1348.

[21] DIETRICH T, KRUG S, ZIMMERMANN A. An empirical study on generic multicopter energy consumption profiles[C]//Proceedings of the Annual IEEE International Systems Conference. Piscataway: IEEE Press, 2017: 1-6.

[22] KADDANI S, VANDERPOOTEN D, VANPEPERSTRAETE J M, et al. Weighted sum model with partial preference information: application to multi-objective optimization[J]. *European Journal of Operational Research*, 2017, 260(2): 665-679.

[23] YU Y, TANG J, HUANG J Y, et al. Multi-objective optimization for UAV-assisted wireless powered IoT networks based on extended DDPG algorithm[J]. *IEEE Transactions on Communications*, 2021, 69(9): 6361-6374.

[24] GIAGKIOZIS I, FLEMING P J. Methods for multi-objective optimization: an analysis[J]. *Information Sciences*, 2015, 293: 338-350.

[25] KATOCH S, CHAUHAN S S, KUMAR V. A review on genetic algorithm: past, present, and future[J]. *Multimedia Tools and Applications*, 2021, 80(5): 8091-8126.

Optimization of multi-mission scheduling for swarm UAVs with charging platform

KE Zhijie^{1, 2}, XU Guoning^{1, 2, *}, CAI Rong^{1, 2}, LI Yongxiang¹, YANG Yanchu^{1, 2}

(1. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China;

2. School of Aeronautics and Astronautics, University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: The swarm unmanned aerial vehicles (UAVs), characterized by their large quantity, low cost, and unified scheduling, have broad application prospects. Unified scheduling is a focal point and challenge in swarm UAVs research, aiming to the optimal allocation of tasks and resources. Current scheduling research primarily focuses on small-scale, short-term scenarios without considering complex scenarios such as mid-operation charging. However, for future multi-task and long-term applications, scheduling optimization must account for such factors. An improved mission scheduling method for swarm UAVs based on a unified scheduling model and an improved genetic algorithm was proposed. First, the wireless charging platform resources were incorporated into the UAV working environment, and the working scenario was modeled systematically. Then, the genetic algorithm was used to optimize the mission and charging platform resource allocation. Finally, the proposed method was tested for validation using simulated scenarios. Test results show that the method proposed can better adapt to changes in missions, environment, and resources, showing good performance even for large-scale swarm UAVs.

Keywords: swarm UAV; scheduling optimization; genetic algorithm; scheduling model; UAV charging

Received: 2022-05-26; **Accepted:** 2022-11-19; **Published Online:** 2023-01-11 08:42

URL: link.cnki.net/urlid/11.2625.V.20230109.1735.008

Foundation item: Strategic Priority Research Program of the Chinese Academy of the Sciences (XDA17020304)

*** Corresponding author.** E-mail: xugn@aircas.ac.cn