

控制与决策

Control and Decision

无人机监控巡检路径规划及ACO-AVNS求解算法

陈群, 孙乐天, 余帆

引用本文:

陈群, 孙乐天, 余帆. 无人机监控巡检路径规划及ACO-AVNS求解算法[J]. *控制与决策*, 2025, 40(11): 3253-3262.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.1459>

您可能感兴趣的其他文章

Articles you may be interested in

[基于粒子群算法的满载需求可拆分车辆路径规划](#)

Split vehicle route planning with full load demand based on particle swarm optimization

控制与决策. 2021, 36(6): 1397-1406 <https://doi.org/10.13195/j.kzyjc.2019.1323>

[面向多目标侦察任务的无人机航线规划](#)

UAV trajectory planning for multi-target reconnaissance missions

控制与决策. 2021, 36(5): 1191-1198 <https://doi.org/10.13195/j.kzyjc.2019.1284>

[基于16方向24邻域改进蚁群算法的机器人路径规划](#)

Mobile robots path planning based on 16-directions 24-neighborhoods improved ant colony algorithm

控制与决策. 2021, 36(5): 1137-1146 <https://doi.org/10.13195/j.kzyjc.2019.0600>

[城市低空环境中多旋翼无人机在线航线规划方法](#)

An online route planning method for multi-rotor drone in urban environments

控制与决策. 2021, 36(12): 2851-2860 <https://doi.org/10.13195/j.kzyjc.2020.0557>

[基于2D-OTSU图像边缘检测的回转窑工况识别方法](#)

Condition recognition method of rotary kiln based on 2D-OTSU image edge detection

控制与决策. 2021, 36(10): 2427-2434 <https://doi.org/10.13195/j.kzyjc.2020.0348>

无人机监控巡检路径规划及 ACO-AVNS 求解算法

陈群[†], 孙乐天, 余帆

(中南大学 交通运输工程学院, 长沙 410075)

摘要: 无人机作为一种新兴的数据采集工具, 正在治安巡逻、森林防火和设施检查等监控巡检领域迅速普及. 针对此类问题, 提出一个混合整数规划模型, 通过将监控资源的分配类比为库存管理问题, 量化因过度频繁地监控而产生的成本, 以优化资源分配. 所提出模型考虑无人机的续航限制以及监控需求拆分机制, 综合优化巡检点的分配、无人机的服务路径以及每条路径的巡检周期, 以最小化系统的总运营成本. 为求解该模型, 提出一种基于蚁群优化算法 (ACO) 和自适应变邻域搜索 (AVNS) 的混合启发式算法. 在算法的每次迭代中, 首先由 ACO 构建初始解, 然后基于 AVNS 的 6 种邻域结构持续优化解的质量. 在 23 个小规模实例中, 该算法均可获得与求解器质量相当的解. 对于采集自长沙市的 121 节点大规模实例, 求解器在 10 h 内无法找到任何可行解, 而所提出算法在较短时间内可得出质量较高的解决方案, 并通过消融实验验证了所提出算法的有效性和良好的求解稳定性.

关键词: 监控巡检; 无人机; 路径规划; 需求拆分; 蚁群优化算法; 变邻域搜索

中图分类号: U491

文献标志码: A

DOI: 10.13195/j.kzyjc.2024.1459

引用格式: 陈群, 孙乐天, 余帆. 无人机监控巡检路径规划及 ACO-AVNS 求解算法 [J]. 控制与决策, 2025, 40(11): 3253-3262.

Unmanned aerial vehicle monitoring patrol path planning and ACO-AVNS solution algorithm

CHEN Qun[†], SUN Le-tian, YU Fan

(School of Traffic and Transportation Engineering, Central South University, Changsha 410075, China)

Abstract: Unmanned aerial vehicles (UAVs), as an emerging tool for data collection, are rapidly gaining popularity in monitoring patrol fields such as public security patrols, forest fire prevention, and facility inspections. To address these issues, this paper proposes a mixed-integer programming model that analogizes the allocation of monitoring resources to inventory management problems, quantifying costs due to excessive and frequent monitoring to optimize resource allocation. The model takes into account the endurance limitations of UAVs and the mechanism for splitting monitoring demands, comprehensively optimizing the allocation of inspection points, the service paths of UAVs, and the inspection cycles of each path to minimize the total operational costs of the system. To solve this model, a hybrid heuristic algorithm based on ant colony optimization (ACO) and adaptive variable neighborhood search (AVNS) is proposed. In each iteration of the algorithm, the ACO algorithm first constructs an initial solution, which is then continuously optimized in quality by the AVNS through alternate searches across six neighborhood structures. The algorithm achieves solutions comparable in quality to those of solvers in 23 small-scale instances. For a large-scale 121-node instance collected from Changsha City, the solver fails to find any feasible solution within 10 hours, while the proposed algorithm generates high-quality solutions in a short time. The effectiveness of the proposed algorithm and its excellent solution stability are validated through ablation studies.

Keywords: monitoring patrol; unmanned aerial vehicle; path planning; split demand; ant colony optimization algorithm; variable neighborhood search

0 引言

近年来, 无人机以其成本低廉、机动性强和扩展

性高等特点, 在监控巡检领域展现出巨大潜力和应用价值^[1]. 通过搭载轻量化相机、热像仪等设备, 无

收稿日期: 2024-12-17; 录用日期: 2025-05-21.

基金项目: 湖南省教育厅科学研究重点项目 (23A0010).

责任编辑: 刘宝碁.

[†]通信作者. E-mail: chenqun631@csu.edu.cn.

本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

人机可在复杂或危险环境中自主完成高精度的监控任务^[2]. 如: 在公共安全领域, 其快速部署能力和三维视角可高效处理突发事件并疏导交通, 突破传统地面巡逻限制^[3]; 在基础设施检测中, 通过搭载传感器对桥梁、输电杆塔等关键设施进行检查, 能够及时发现裂缝、损坏或其他潜在问题^[4].

与配送问题类似, 监控任务中, 无人机需要抵达特定位置进行数据采集. 现有研究从不同角度扩展了无人机监控场景下的路径规划问题: Zhen 等^[5]将飞行高度作为影响监控精度的变量引入了模型, 并设计了禁忌搜索算法来平衡任务时效与精度要求; Wei 等^[6]提出了一种自约束粒子群算法, 以解决拓扑优化问题, 提升了无人机在多干扰源场景下的监控覆盖率; Zeng 等^[7]将无人机-卡车协同监控问题构建为混合整数二次约束规划模型, 并通过线性化改进和邻域搜索算法进行了求解; 夏丹等^[8]等则引入了基尼不纯度指标, 通过蚁群算法优化监测路径的随机性来降低规律性监测的隐私泄露风险. 然而, 这些研究大多将监控任务简化为单次或离散的观测行为, 未充分考虑监控服务的重复性、连续性和长期性等特征.

监控巡检任务的本质是无人机周期性飞往指定巡检点收集信息. 如 Nigam^[9]指出, 持续监控的关键在于通过连续或重复访问来维持信息的时效性; Brown 等^[10]针对海上持续监视任务, 采用多目标粒子群算法实现了检测概率、重访问间隔与燃料消耗的协同优化; 秦文龙等^[11]等针对多无人机电力应急巡检场景, 提出了一种 SAC-GA 混合算法, 并利用强化学习自适应调整遗传算法参数; Zhou 等^[12]围绕城市无人机监控的选址-路径规划问题, 设计了嵌入频率-时间-频率策略的自适应大邻域算法以最小化运营成本.

现有研究主要局限于航迹规划或站点部署层面, 忽视了监控需求差异引发的成本冗余, 如对低优先级区域过度监控而造成的资源浪费和设备损耗. 这一挑战与库存路径问题 (inventory routing problem, IRP) 的优化目标高度契合. IRP 作为一类 NP-hard 问题, 需要通过库存管理与路径规划的协同决策来实现成本最小化^[13], 其复杂性催生了启发式算法, 如蚁群算法 (ACO) 和变邻域搜索 (VNS) 的广泛应用: 刘志硕等^[14]设计了融合模拟退火的混合变邻域搜索算法求解了小容销比客户的 IRP; Huang 等^[15]针对多物品 IRP 中的需求不确定性, 采用了改进 ACO 算法, 定义特定的信息素更新规则来优化补货量和车辆调度方案; Liu 等^[16]等针对允许拆分交货和可变

时间窗的 IRP, 开发了 ACO-VNS 混合算法以优化运输成本和缺货成本. 通过借鉴 IRP 的理论框架, 本文将监控资源的分配类比为库存管理问题, 以量化监控巡检中存在的资源冗余.

基于上述讨论, 本文的内容包括以下 3 方面: 1) 结合 IRP 框架中库存的概念, 将过度监控导致的资源浪费量化为可优化的成本项; 2) 构建混合整数规划模型, 实现巡检点、无人机基地、巡逻路径以及巡检周期的联合优化, 并引入需求拆分机制, 允许高监控需求的巡检点被多条路径协同服务; 3) 针对该 NP-hard 问题, 设计并实现蚁群优化与自适应邻域搜索的混合算法 (ACO-AVNS), 并通过不同规模实例的数值分析和消融实验来验证其有效性.

1 问题分析与建模

1.1 问题描述与方法

研究聚焦于无人机监控巡检网络的设计和无人机调度策略的优化, 目标是实现运营成本最小化. 以城市监控为例, 无人机监控巡检可应用于治安巡逻: 警察局等治安基地因其战略位置和应急响应能力, 是理想的无人机基地; 而城市中的繁忙商圈、交通枢纽等安全隐患区域则作为巡检点.

本文将巡检点的监控需求视为在达到临界条件前必须进行“补货”的行为, 而无人机监控服务则为周期性补给的“货物”. 基于此框架, 引入“监控缺口增量”来衡量巡检点的监控需求. 巡检点 i 的监控缺口每分钟按照缺口增量 C_i 累积, 且在达到临界值 C_m 前必须提供监控服务. 完成监控后, 监控缺口将重置为 0, 标志需求得以满足. C_i 的取值根据巡检点的特性确定, 包括人口流动性、区域重要性等因素.

当巡检点 i 由单个路径 r 服务时, 其可容忍的最长服务间隔 $T_i = C_m / C_i$, 巡检周期 F_r 必须小于 T_i , 否则监控缺口将超出 C_m . 而路径上的 F_r 往往由最高监控需求点强制约束, 致使低需求点被动接受冗余的监控服务, 造成资源浪费. 为此, 本文引入了监控需求拆分机制, 允许高需求点由多条路径协同服务.

与可拆分车辆路径问题 (split delivery vehicle routing problem, SDVRP) 的货物拆分相似, 本文引入了决策变量 C_{ir} 将原始监控缺口增量 C_i 与具体的路径 r 关联起来, 以精确刻画多路径协同下的监控需求拆分机制. 当实施需求拆分时, 原始监控缺口增量 C_i 被分解为若干子增量 C_{ir} , 并由不同路径分担. 由于单一路径承担的监控缺口增量减少, 其对应的巡检周期将得以延长.

在 IRP 的理想实施中, 最优的巡检周期 F_r 应使

得路径上各巡检点的监控缺口到达临界值时恰好获得监控服务. 然而, 由于巡检点间的需求差异, 所有巡检点难以同步满足该条件, 导致部分巡检点被迫在监控缺口未达到临界值时接受服务. 这种监控服务的提前性会强制清零尚可继续累积的监控缺口, 由此产生的成本冗余即为本文定义的“监控库存成本”. 在进行建模前, 本文提出了以下假设:

- 1) 所有无人机是同构的, 且速度是恒定的;
- 2) 所有无人机基地中配备足够数量的无人机;
- 3) 所有巡检点的监控需求是已知且恒定的.

1.2 模型建立

1.2.1 符号

表1为所提出数学模型中所涉及的符号及其定义.

表1 模型符号及定义

索引/集合	定义
i, j	巡检点的索引
d	单个无人机基地的索引
r	单个路径的索引
I	所有巡检点的集合
D	所有无人机基地的集合
R	所有路径的集合
模型参数	定义
T_m	无人机受电池续航限制的最大飞行时间
C_m	巡检点的监控缺口临界值
C_i	巡检点 <i>i</i> 每分钟的原始监控缺口增量
e_{ij}	无人机从巡检点 <i>i</i> 到巡检点 <i>j</i> 所需要的飞行时间
δ	无人机每分钟的作业成本
ψ	路径的固定运营成本(按照一周计算)
h	巡检点的单位监控缺口持有成本
λ	周成本转换系数
M	一个足够大的正数
决策变量	定义
F_r	路径 <i>r</i> 上无人机的巡检周期
C_{ir}	路径 <i>r</i> 上巡检点 <i>i</i> 每分钟的实时监控缺口增量
E_{ir}	路径 <i>r</i> 上无人机从基地离开后到达巡检点 <i>i</i> 的累计飞行时间
z_r	二元变量, 若路径 <i>r</i> 被使用, 则为1
y_{ir}	二元变量, 若巡检点 <i>i</i> 在路径 <i>r</i> 上被服务, 则为1
x_{ijr}	二元变量, 若路径 <i>r</i> 上的无人机在巡检点 <i>i</i> 后访问巡检点 <i>j</i> , 则为1

1.2.2 模型

所提出模型的目标函数和约束条件如下所示:

$$\min Z = \sum_{r \in R} \psi z_r + \lambda \left[\sum_{r \in R} \sum_{i \in I} h(y_{ir} C_m - F_r C_{ir}) + \sum_{r \in R} \sum_{i \in I \cup D} \sum_{j \in I \cup D} \delta F_r^{-1} e_{ij} x_{ijr} \right]. \quad (1)$$

$$\sum_{r \in R} y_{ir} \geq 1, \quad \forall i \in I; \quad (2)$$

$$\sum_{d \in D} \sum_{j \in I} x_{djr} = z_r, \quad \forall r \in R; \quad (3)$$

$$\sum_{i \in I} \sum_{d \in D} x_{idr} = z_r, \quad \forall r \in R; \quad (4)$$

$$\sum_{j \in I} x_{jdr} - \sum_{i \in I} x_{dir} = 0, \quad \forall d \in D, \forall r \in R; \quad (5)$$

$$\sum_{\substack{j \in I \cup D \\ j \neq i}} x_{ijr} + \sum_{\substack{j \in I \cup D \\ j \neq i}} x_{jir} = 2y_{ir}, \\ \forall i \in I, \forall r \in R; \quad (6)$$

$$F_r C_{ir} \leq C_m, \quad \forall i \in I, \forall r \in R; \quad (7)$$

$$y_{ir} F_r \leq \frac{C_m}{C_i} \sum_{r \in R} y_{ir}, \quad \forall i \in I, \forall r \in R; \quad (8)$$

$$C_{ir} \leq y_{ir} C_i, \quad \forall i \in I, \forall r \in R; \quad (9)$$

$$\sum_{r \in R} C_{ir} \geq C_i, \quad \forall i \in I; \quad (10)$$

$$E_{ir} \leq T_m, \quad \forall i \in I, \forall r \in R; \quad (11)$$

$$E_{jr} \geq E_{ir} + e_{ij} + (x_{ijr} - 1)M, \quad \forall i \in I, \\ \forall j \in I \cup D, i \neq j, \forall r \in R; \quad (12)$$

$$E_{jr} \geq e_{dj} + (x_{djr} - 1)M, \quad \forall d \in D, \\ \forall j \in I \cup D, d \neq j, \forall r \in R; \quad (13)$$

$$F_r \leq M z_r, \quad \forall r \in R; \quad (14)$$

$$y_{ir} \leq z_r, \quad \forall i \in I, \forall r \in R; \quad (15)$$

$$F_r \geq 0, \quad \forall r \in R; \quad (16)$$

$$E_{ir} \geq 0, \quad \forall i \in I \cup D, \forall r \in R; \quad (17)$$

$$C_{ir} \geq 0, \quad \forall i \in I, \forall r \in R; \quad (18)$$

$$z_r \in \{0, 1\}, \quad \forall r \in R; \quad (19)$$

$$y_{ir} \in \{0, 1\}, \quad \forall i \in I \cup D, \forall r \in R; \quad (20)$$

$$x_{ijr} \in \{0, 1\}, \quad \forall i, j \in I \cup D, \\ i \neq j, \forall r \in R. \quad (21)$$

其中: 目标函数(1)旨在最小化无人机监控巡检系统的总运营成本, 包含3部分: 1) 路径运维成本: 即保障路径稳定运行的系统性成本, 反映维持基础运营能力的必要投入; 2) 监控库存持有成本: 因监控服务提前性产生的冗余成本, 用于表示因过度频繁监控导致的资源浪费; 3) 无人机作业成本: 由总飞行时间和巡检周期的倒数决定, 巡检周期越长, 单位时间内的巡检频次越低, 资源消耗越少. 考虑到运维成本的计算周期设定为一周, 故引入周成本转换系数 λ , 将其余两项成本转化为等效周成本. 所提出模型受到

4 组约束条件的限制: 第 1 组约束 (2) ~ (6) 描述了无人机巡检路径的基本特征: 约束 (2) 要求巡检点至少被一条路径服务; 约束 (3) 和 (4) 要求路径必须从无人机基地出发, 并满足无人机基地结束; 约束 (5) 确保每条路径的起点和终点必须为同一个无人机基地; 约束 (6) 则保证流量守恒. 第 2 组约束 (7) ~ (10) 参考 SDVRP 问题定义了监控需求拆分机制的核心规则和可行性边界, 直接支撑后续算法中邻域算子的设计逻辑: 约束 (7) 限定任意巡检点累积的监控缺口不得超过其临界阈值; 约束 (8) 设定巡检周期动态上限规则: 非分访点的周期上限维持可容忍的最长服务间隔为 T_i , 而分访点上限放宽为 T_i 与协同服务路径数的乘积; 约束 (9) 强制单条路径上的监控缺口增量 C_{ir} 不大于原始增量 C_i , 以确保拆分后单条路径的巡检周期能够有效延长; 约束 (10) 则规定所有协同路径对分访点 i 的监控缺口增量的和不少于原始增量 C_i , 避免需求拆分后分访点的监控需求无法得到满足. 第 3 组约束 (11) ~ (13) 用于约束无人机的电池续航: 约束 (11) 规定无人机从基地出发后到达任意巡检点 i 时的累积飞行时间均不应超过最大飞行时间; 约束 (12) 和 (13) 则确保电池续航能够满足路径上相邻两点间的可达性, 并采用经典的 MTZ 约束的形式消除子回路. 最后一组约束用于规范各决策变量的取值逻辑和可行域: 约束 (14) 和 (15) 确保无人机的巡检和巡检点的服务仅发生在被使用的路径上; 约束 (16) ~ (21) 定义了决策变量的取值范围和非负性.

所提出模型的目标函数以及约束 (7) 中均存在两个连续变量的乘积项 $F_r C_{ir}$, 此类双线性项导致模型呈现非凸性, 其可行解空间被分割为多个非连通的子区域, 导致计算复杂度呈指数级增长^[17].

2 求解算法

现有商业求解器难以在多项式时间内求得该 NP-hard 问题的最优解. 本文提出了一种融合自适应邻域搜索的改进蚁群优化算法 (ACO-AVNS), 其详细的伪代码如表 2 所示.

2.1 改进的蚁群优化算法

2.1.1 信息素矩阵初始化

本文设计了一种贪婪方法来生成初始可行解, 从而构建具有梯度差异的信息素浓度矩阵, 加速算法收敛, 其具体步骤如下.

step 1: 以 [无人机最大续航时间/2] 为覆盖半径, 优先激活范围内未服务巡检点数量最多的基地.

step 2: 从激活的无人机基地出发, 插入距离当前路径末端最近且满足续航返航的未服务巡检点,

表2 ACO-AVNS 算法伪代码

算法1 ACO-AVNS算法.
输入: 问题数据, 算法参数;
输出: 最终解决方案.
贪婪算法获取初始解: $S^*(ACO)$ // 初始化信息素浓度矩阵
do while (迭代次数 \leq MaxIter)
for Ant = 1 to MaxAnt
while (未服务的巡检点集合 $\neq \emptyset$)
基于概率选择巡检点
将巡检点插入当前路径
// 若不满足续航限制, 则选择新的无人机基地
// 开始构造新路径
end while
计算目标函数值: $S(ACO)$
比较并保留最佳解: $S^*(ACO) \rightarrow \min\{S^*(ACO), S(ACO)\}$
end for
// AVNS 算法
do while (未改进的迭代次数 $\leq \nu$)
轮盘赌选择邻域结构
基于 $S^*(ACO)$ 生成邻域解
保留最佳解或接受次优解: $S^*(AVNS)$
// 每 γ 次迭代更新各邻域的权重
// 连续 ν_0 次迭代未改进则重置温度
end while
基于 $S^*(AVNS)$ 进行全局信息素更新
end while

重复此过程, 直至无法扩展.

step 3: 若无法继续扩展路径, 则返回至 step 1; 否则, 重复此过程, 直至所有巡检点均被服务.

2.1.2 蚂蚁移动与解的构造

本文将巡检点和无人机基地分别设定为蚂蚁旅行的目的地和起点, 以下统称为节点. 蚂蚁在节点 i 处的移动遵循以下概率公式:

$$S_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha \cdot [\eta_{ij}(t)]^\beta}{\sum_{l \in N_i^k} [\tau_{il}(t)]^\alpha \cdot [\eta_{il}(t)]^\beta}, & j \in N_i^k; \\ 0, & \text{otherwise.} \end{cases} \quad (22)$$

其中: $S_{ij}^k(t)$ 为蚂蚁 k 在第 t 次迭代中从节点 i 出发且选择节点 j 的概率; N_i^k 为未被分配节点的集合; α 和 β 分别为信息素因子和启发式因子; $\tau_{ij}(t)$ 为边 (i, j) 上的信息素浓度值; $\eta_{ij}(t)$ 为启发式信息, 启发式函数 $\eta_{ij}(t)$ 并非经典 ACO 所采用的距离倒数形式, 而是在优化飞行时间的基础上引入了监控需求差异因子, 如下所示:

$$\eta_{ij} = \frac{1}{e_{ij}} \times \frac{1}{1 + \Delta C_{ij}}. \quad (23)$$

这里: e_{ij} 为节点 i 与节点 j 间的飞行时间, 即距离; $\Delta C_{ij} = |C_i - C_j|$ 为两点间监控需求的差值, 其值越小, η_{ij} 越大, 引导算法优先聚合需求相近的节点, 降低需求差异过大导致的监控库存成本。

计算完各点间的概率后, 蚂蚁基于如下伪随机比例规则选择下一节点:

$$P_{ij}^k(t) = \begin{cases} \arg \max_{j \in N_i^k} \{[\tau_{ij}(t)]^\alpha, [\eta_{ij}(t)]^\beta\}, \\ q \geq q_0; \\ S_{ij}^k(t), \text{ otherwise.} \end{cases} \quad (24)$$

根据此规则, 节点被逐步选择并插入至已构建的路径中, 直至达到无人机的续航限制。然后, 蚂蚁基于第 2.1.1 节中的 step 1 选择下一个无人机基地。重复此过程, 直至所有巡检点被分配到对应路径。

在每轮迭代中, 当预定数量的蚂蚁完成路径构建后, 需要完成信息素水平的更新, 即根据下文式 (25) 在至今最优路径的边上完成信息素的释放和蒸发, 式 (26) 为信息素增量的计算公式:

$$\tau_{ij}(t+1) = (1 - \rho) \cdot \tau_{ij}(t) + \rho \cdot \Delta\tau_{ij}^k; \quad (25)$$

$$\Delta\tau_{ij}^k = \begin{cases} \frac{Q}{L_{\text{best}}}, \text{ ant } k \text{ uses edge}(i, j); \\ 0, \text{ otherwise.} \end{cases} \quad (26)$$

其中: $\Delta\tau_{ij}^k$ 为蚂蚁 k 在边 (i, j) 释放的信息素的值, Q 为信息素强度, L_{best} 为全局最优解。该过程会重复进行, 直至达到预定的迭代次数为止。

2.2 自适应邻域搜索

为降低陷入局部最优的风险并提升搜索多样性, 本文在每只蚂蚁生成初始解后, 利用 AVNS 的自适应机制选择邻域算子优化当前解, 并将改进后的解反馈至 ACO 的信息素更新流程, 从而引导后续蚂蚁的探索方向。

2.2.1 自适应机制

研究表明, 引入自适应机制可动态分配计算资源至高效的邻域结构从而提升算法效率^[18]。本文在 Stenger 等^[19]研究的基础上, 采用动态权重轮盘赌机制来实现邻域算子的自适应调用。各邻域初始权重相同, 并在搜索过程中根据其表现动态调整: 若应用某邻域后获得全局最优解, 则其得分加 9 分; 若改进当前解, 则加 3 分; 若解虽然差, 但是被模拟退火准则接受, 则加 1 分。邻域 k 的权重更新遵循

$$\omega_k^{n+1} = (1 - \mu)\omega_k^n + \mu \frac{\eta_k}{\chi_k}. \quad (27)$$

其中: η_k 为邻域 k 当前的分数, χ_k 为邻域 k 自上次权重更新以来被调用的次数, μ 为 $(0, 1)$ 间的常数。每次经 γ 次 AVNS 迭代后更新各邻域的权重, 并将 η_k 和

χ_k 重置为 0。此外, 模拟退火算法中的温度通常会以固定的速率 θ 逐代衰减, 而本文还引入了温度重启机制: 当连续 ν_θ 次迭代解未得到改进时, 温度将恢复至初始值 θ_0 , 以增加全局搜索能力。

2.2.2 邻域算子

本文设计了 6 种邻域算子来探索解空间, 其中所有插入操作均为将节点插入路径中距离成本最低的位置, 并满足续航约束。算子的定义如下。

1) Random_Swap: 随机选择位于不同路径中的两个巡检点, 并互换其位置。

2) Random_Relocate: 随机移除一条路径中的一个巡检点, 将其插入至另一条路径中。

3) Worst_Relocate: 移除当前方案中具有最大成本节省的巡检点, 并将其重新插入至能够获得最大收益的其他路径中, 其中节点 i 成本节省值的计算公式为 $\Delta\text{COST}_i = \text{当前成本} - \text{除去 } i \text{ 点后的成本}$ 。

4) 2-opt: 将为 TSP 开发的 2-opt 算法应用于每条路径中。选取一条路径中两个非连续的巡检点, 断开原连接并反转中间段。

5) Depot_Relocate: 移除一条路径中的无人机基地并替换为其他基地, 将巡检点插入至新基地之间。

6) Demand_Split: 识别路径中满足需求拆分的巡检点集合 (分访点), 并匹配可行的潜在合作路径集合, 将监控需求分配至合作路径, 实现多路径协同服务。

2.2.3 需求拆分算子

与传统独立交付的货物拆分模式不同, 无人机监控需求拆分的核心在于分访点由多条路径在不同时间点交替服务, 其实际巡检周期由各合作路径的服务时序共同决定。基于此, Demand_Split 算子的关键在于: 1) 确定路径实施需求拆分的可行巡检周期区间; 2) 识别路径上可行的分访点集合; 3) 针对路径上可能存在的多个分访点, 设计分访点组合策略。为便于表述, 令 r 为待优化的目标路径, 而 r^* 为潜在的合作路径。其具体实施步骤如下。

step 1: 识别可行的巡检周期区间 $F_{(r, r^*)}$ 。

由约束 (7) 和 (8), 若单个巡检点实施需求拆分, 则其所在路径 r 的巡检周期可行区间为 $\left[\frac{C_m}{C_{ir}}, \frac{C_m}{C_i} \sum_{r \in R} y_{ir} \right]$ 。当路径 r 上的最需点 (监控需求最高的点) 为分访点时, 路径 r 的巡检周期仅需满足次需点的监控需求即可覆盖所有点的需求。基于此, 初始可行区间 $F_{(r, r^*)}$ 的计算方式为

$$F_{(r,r)} = [F_r^{\min}, F_r^{\max}] = \left[F_r^{(1)}, \min \left\{ F_r^{(2)}, F_r^{(1)} \sum_{r \in R} y_{ir} \right\} \right] = \left[\frac{C_m}{C_r^{(1)}}, \min \left\{ \frac{C_m}{C_r^{(2)}}, \frac{2C_m}{C_r^{(1)}} \right\} \right], \quad (28)$$

其中 $C_r^{(1)}$ 和 $C_r^{(2)}$ 分别为路径 r 上巡检点 C_{ir} 的最高值和次高值. 假设由两条路径服务, 故 $\sum_{r \in R} y_{ir} = 2$.

确定 $F_{(r,r)}$ 后, 需要结合合作路径 r^* 的巡检周期 $F_{r^*}^{\min}$ 进行调整, 得到最终可行区间 $F_{(r,r^*)}$: 若 $F_{r^*}^{\min} < F_r^{\min}$, 则表明路径 r^* 上存在监控需求更高的巡检点, 继续在路径 r^* 上添加分访点将导致成本无效增加; 若 $F_{r^*}^{\min} \in [F_r^{\min}, F_r^{\max}]$, 则 $F_{(r,r^*)}$ 的上限则调整为 $F_{r^*}^{\min}$, 以确保满足合作路径 r^* 上巡检点的监控需求; 否则, $F_{(r,r^*)}$ 维持 $F_{(r,r)}$ 不变. 如下所示:

$$F_{(r,r^*)} = \begin{cases} \emptyset, & F_{r^*}^{\min} < F_r^{\min}; \\ [F_r^{\min}, F_{r^*}^{\min}], & F_r^{\max} \geq F_{r^*}^{\min} \geq F_r^{\min}; \\ [F_r^{\min}, F_r^{\max}], & \text{otherwise.} \end{cases} \quad (29)$$

其中: $F_{r^*}^{\min} = C_m / C_{r^*}^{(1)}$, 表示合作路径 r^* 的巡检周期. 若 $F_{(r,r^*)} \neq \emptyset$, 则路径 r^* 是一个可行的合作路径.

step 2: 确定可行的分访点集合 $I_{(r,r^*)}$.

基于可行的巡检周期区间 $F_{(r,r^*)}$, 通过下式确定目标路径 r 上的分访点集合 $I_{(r,r^*)}$:

$$I_{(r,r^*)} = \{i | C_m - C_{ir} \cdot \max(F_{(r,r^*)}) \leq 0\}, \quad (30)$$

即当路径 r 上的巡检周期为 $F_{(r,r^*)}$ 的上限时, 其中仍然能够满足监控需求的巡检点均可作为分访点.

step 3: 实施分访点组合策略.

针对路径上存在多个分访点的情况, 本文提出了两类组合策略以全面探索解空间. 对于监控需求不同的分访点集合 $I_{(r,r^*)}$, 采用渐近式分访策略: 首先选取监控需求最高的节点进行分访操作, 如图 1(b) 所示; 然后按照监控需求降序逐步纳入其他分访点, 如图 1(c) 所示, 直至穷尽所有可能的分访点组合.

第 2 种策略为合作路径重构策略, 主要应对分访点集合 $I_{(r,r^*)}$ 中各分访点的监控需求相同, 或整条路径全为分访点的特殊场景. 该策略的核心思想是通过路径的打断和重构来扩展解空间, 即对合作路径 r^* 分段拆分, 再与目标路径 r 进行组合重构, 从而生成新的可行解, 如图 1(e) 和图 1(f) 所示.




图1 渐近式分访策略和合作路径重构策略

3 数值实验

本文通过对不同规模数据集进行数值实验, 并

使用商业求解器 Gurobi 在预设时间内获得最佳解, 以此作为基准来衡量所提出 ACO-AVNS 算法所得

到的解的质量. 同时, 进行了消融实验来验证其有效性, 并通过敏感性测试分析不同参数对于系统的影响.

3.1 参数设置

参考大疆无人机官方参数, 考虑悬停和监控所需额外电量, 设置无人机最大飞行时间 $T_m = 30 \text{ min}$. 由于空气阻力和路径非直线性, 无人机飞行速度设定为 10 km/h . 单条路径运维成本 $\psi = 1.2 \times 10^4 \text{ 元}$, 无人机每分钟的作业成本 $\delta = 0.15 \text{ 元}$, 单位监控缺口持有成本 $h = 0.15 \text{ 元}$. 考虑到一周大约有 10^4 min , 设置每周成本转换系数 $\lambda = 10^4$.

上述参数作为基准参数 *A*. 在后续实验中, 参照基准参数, 引入两组不同配置: 参数 *B* 将无人机最大飞行时间增至 60 min ; 参数 *C* 仅将库存持有成本提高至初始值的 6 倍; 其余参数则与参数 *A* 一致.

ACO-AVNS 算法的性能对于参数较为敏感. 本文基于 AVNS 的终止条件 ν 以及 ACO 的 5 个核心参数 $\{\alpha, \beta, \rho, \text{MaxAnt}, \text{MaxIter}\}$, 构建了 6 因素 5 水平的正交实验以优化参数配置. AVNS 的其他参数

则沿用 Stenger 等^[19] 的稳定配置. 最终确定参数组合如下: $\{\gamma = 30, \theta_0 = 20, \theta^- = 0.95, v_\theta = 50, \mu = 0.3, \nu = 300\}$, $\{\alpha = 3, \beta = 4, \rho = 0.01, \text{MaxAnt} = 40, \text{MaxIter} = 10\}$.

3.2 数值计算

3.2.1 小规模实例分析

数据实例基于长沙市人流密集区域的实际地理位置和监控需求生成. 地点的经纬度信息从高德地图获取并转换为笛卡尔坐标系, 共得到 6 个小规模实例. 因缺乏真实数据集, 在不同大小的矩形区域内随机生成巡检点和基地坐标, 以扩充实验数据. 对于总点数不超过 11 个的实例, 采用第 3.1 节中的 3 种不同参数设置进行测试. 最终得到 23 个小规模实例, 命名为 “*N-DxIy*”. 其中: *N* 为实例索引, *x* 为无人机基地数量, *y* 为巡检点数量.

表 3 分别展示了基于 ACO-AVNS 的混合启发式算法和使用 Gurobi 两种方法求解后的各实例的总成本、CPU 时间、最终解决方案中的路径数量以

表3 小规模实例的结果比较

实例编号	参数设置	ACO-AVNS 成本/ 10^2	ACO-AVNS CPU时间/s	Gurobi 成本/ 10^2	Gurobi CPU时间	路径数量	两者成本Gap ^d /%
1-D215 ^a	A	302.52	4.11	302.52	5.89 s	2	0.00
	B	217.63	2.75	217.63	0.36 s	1	0.00
	C	355.02	3.21	355.02	7.41 s	2	0.00
2-D215	A	290.21	3.14	290.21	3.94 s	2	0.00
	B	220.06	2.39	220.06	0.42 s	1	0.00
	C	355.21	3.12	355.21	2.32 s	2	0.00
3-D217 ^a	A	412.09	7.09	412.09	9.97 h	3	0.00
	B	193.90	3.43	193.90	24.56 s	1	0.00
	C	412.77	6.20	412.77 ^b	10 h	3	0.00
4-D217	A	443.37	5.29	443.37	1036.33 s	3	0.00
	B	319.80	4.96	319.80	2691.93 s	2	0.00
	C	508.37	5.96	508.37	829.53 s	3	0.00
5-D318 ^a	A	281.93	4.68	281.93 ^b	10 h	2	0.00
	B	179.53	3.64	179.53	38.36 s	1	0.00
	C	311.93	4.48	311.93 ^b	10 h	2	0.00
6-D318	A	573.82	5.94	573.82	2.82 h	4	0.00
	B	337.48	4.56	337.48 ^b	10 h	2	0.00
	C	611.32	5.52	611.32	6898.65 s	4	0.00
7-D417 ^a	A	426.80	4.50	426.80	3.88 h	3	0.00
	B	301.00	4.46	301.00	3.12 h	2	0.00
	C	471.80	4.59	471.80	8580.58 s	3	0.00
8-D518 ^a	A	579.34	6.86	579.34 ^b	10 h	4	0.00
9-D619 ^a	A	462.07	5.90	462.07 ^b	10 h	3	0.00
a	根据长沙实际城市市场所生成的实例						
b	求解器运行10 h结束时的求解结果						
c	启发式算法的CPU时间为运行10次算法的总时间						
d	$\text{Gap}(\%) = \frac{\text{Cost}(\text{ACO} - \text{AVNS}) - \text{Cost}(\text{Gurobi})}{\text{Cost}(\text{Gurobi})} \times 100\%$						


及两者成本的差距. 启发式算法在搜索的过程中存在一定随机性, 因此, 对每个实例均使用所提出算法进行了 10 次求解.

在测试的 23 个实例中, Gurobi 未能在给定的 10 h 内找到其中 6 个实例的最佳解, 而所提出算法在所有实例中始终提供了与其质量相同的解. 此外, 对于不同规模和参数配置的实例, Gurobi 的计算时间呈现出显著的波动性, 其时间跨度从几秒钟延伸至数小时不等, 这种时间维度上的不确定性可能会对依赖快速响应的应用场景造成制约. 相比之下, 所提出 ACO-AVNS 算法在所有测试实例中均表现出高效且稳定的性能, 运行时间始终控制在 8 s 以内.

图 2 为实例 7-D4I7-参数 C 的求解结果, 其中监控需求最高的巡检点同时被路径 2 和路径 3 共同服务. 通过实施需求拆分策略, 将原本不分访情况下路径 1 和路径 2 的库存水平从 {0.6, 0.0} 优化至 {0.2, 0.0}, 从而有效利用监控资源.

3.2.2 大规模实例分析

为评估算法在实际场景中的适用性, 本文选择长沙市的橘子洲头景区及其周边地区作为研究对象, 包含众多交通枢纽、桥梁以及地铁线路. 从高德地图采集了该区域中 121 个关键节点的经纬度坐标, 包



路径	服务顺序	监控库存	路径长度
1	D3-I7-I3-I5-D3	0.2	24.36
2	D4-I7-I6-D4	0	24.62
3	D1-I2-I1-I4-D1	0.4	28.08

— 路径1 — 路径2 ... 路径3
 ◻ 巡检点 ● 分访点 ☆ 无人机基地

图2 小规模实例 7-D4I7-参数 C 的结果示意图

括 92 个巡检点和 29 个无人机基地.

对于该大规模实例, 精确求解器 Gurobi 在预设的 10 h 内未能获得任何可行解. 为验证所提出算法的性能, 本文对 ACO-AVNS 算法进行了消融实验, 分别与 ACO 和 AVNS 单独求解的结果对比. 实验采用 3 种参数配置, 均独立运行 20 次, 结果如表 4 所示. 其中: 成本单位为万元, 时间单位为 s.

表4 消融实验的结果比较

算法配置	参数 A			参数 B			参数 C		
	最佳成本/万元	平均成本/万元	平均运行时间/s	最佳成本/万元	平均成本/万元	平均运行时间/s	最佳成本/万元	平均成本/万元	平均运行时间/s
ACO	37.07	37.42	3.53	24.13	24.35	3.52	51.95	53.51	3.66
AVNS	36.77	38.1	12.92	21.61	22.39	11.5	46.62	49.03	18.19
ACO-AVNS	30.76	32.16	28.61	21.04	21.62	29.72	40.75	42.03	30.46

表 4 结果表明: ACO-AVNS 在最佳成本和平均成本方面均优于 ACO 与 AVNS 单独求解的结果, 尤其是在参数 C 中, 其最佳成本和平均成本较 ACO 分别降低了 21.6% 和 21.5%. 尽管 ACO-AVNS 平均运行时间约为 30 s, 较其他算法略长, 但是其解的质量和稳定性优势显著. 这种优势源于 ACO 与 AVNS 的协同作用: ACO 通过全局信息素引导, 抑制了 AVNS 因初始解质量导致的波动; 而 AVNS 通过自适应的邻域切换, 帮助 ACO 跳出解空间中的局部最优.

3.3 灵敏度分析

3.3.1 电池续航时间与单位监控缺口持有成本


本节进行灵敏度分析, 以评估无人机电池续航时间和单位监控缺口持有成本对于系统性能的影响. 首先, 评估无人机电池续航时间 T_m 的长短对于系统的影响. 通过表 3 中小规模实例的计算结果可见, 参数 B 中将 T_m 增加了 1 倍, 总成本降低显著, 节省幅

度达 24.19% ~ 52.95%. 图 3 为 T_m 从 30 min 递增至 60 min 时, 总成本和路径数量的变化趋势. 实验基于大规模实例, 在参数 A 的设置下进行 20 次的独立运算. 实验结果表明, 随着续航时间的增加, 总成本和路径数量均呈现下降趋势.


此外, 为分析单位监控缺口持有成本 h 对于系统成本的影响, 参数 C 将该成本增加至初始值的 6 倍. 表 3 结果显示, 小规模实例的总成本增幅范围为 0.16% ~ 22.40%. 值得注意的是, 实例 3-D2I7 仅出现了 0.16% 的微小涨幅, 这主要得益于算法通过需求拆分策略优化了监控资源的分配, 有效抑制了系统总库存成本的上升. 图 4 直观地反映了系统总成本和路径数量对于不同 h 取值的敏感程度.

3.3.2 需求拆分机制

本节通过对比允许与禁止需求拆分的场景, 评估其对于系统成本的影响. 实验使用参数 C 测试, 每




(a) 总成本箱线图




(b) 路径总数箱线图

图3 不同电池续航时间下的总成本和路径总数




(a) 总成本箱线图




(b) 路径总数箱线图

图5 是否实施需求拆分策略下的总成本和路径总数



(a) 总成本箱线图



(b) 路径总数箱线图

图4 不同单位监控缺口持有成本的总成本和路径总数

个实例运行 20 次, 结果如图 5 所示. 实施需求拆分策略可使得平均成本降低 4.04%, 最优成本下节省 5.42%, 在规模化运营中具有相当经济价值. 然而, 需求拆分策略下成本的标准差略高于禁止拆分的情况, 路径数量的起伏较大. 这一现象可归因于需求拆分显著扩大了解空间: 虽然获得了更优解的概率增加, 但是也易陷入局部最优.

从整体角度来看, 无人机监控巡检系统的总运营成本主要受制于无人机电池续航等硬件条件以及新增路径带来的运维成本. 因此, 优化路径规划以减

少路线总数量和飞行时间是降低成本的主要途径. 虽然需求拆分策略并非成本优化的决定性因素, 但是作为路径规划的补充机制, 通过优化监控需求分配, 能够为系统提供额外的改善空间. 特别是在资源受限时, 通过合理的需求拆分调整服务策略, 在不增加投入的前提下满足监控需求, 能够实现更高的经济效益.

4 结论

本文针对无人机监控巡检问题, 构建了一个通用的混合整数规划模型, 考虑了各巡检点间监控需求的差异, 并将过度监控造成的资源浪费以库存成本的形式量化, 与路径运维成本和无人机作业成本一同纳入总成本的计算. 同时, 所提出模型还允许监控需求的可拆分性, 可为需要监控巡检的各类场景提供灵活的解决方案. 为求解该模型, 本文开发了一种结合蚁群优化和自适应变邻域搜索的混合启发式算法, 并设计了特定邻域搜索算子来实现监控需求的拆分. 通过不同规模实例的计算实验以及消融实验验证了所提出算法的有效性和适用性. 进一步通过灵敏度分析, 分析了电池续航、成本参数以及需求拆分机制对于系统的影响.

未来研究可拓展动态的多周期规划, 以适应需求波动和环境变化, 进一步提升无人机巡检系统的灵活性和成本效益, 如时变需求下的弹性调度策略. 此外, 可将研究范围扩展至无人机与其他监控设备(如地面车辆或固定监控设施)的协同调度问题, 构建多层次的综合监控网络. 同时, 将能耗模型、天气

条件等实际因素纳入考虑,使得解决方案更具实用价值.这些研究方向有助于提升无人机监控系统在复杂环境中的运营效率,并为实际应用提供更全面的理论支撑.

参考文献 (References)

- [1] Barmponakis E N, Vlahogianni E I, Golias J C. Unmanned aerial aircraft systems for transportation engineering: Current practice and future challenges[J]. *International Journal of Transportation Science and Technology*, 2016, 5(3): 111-122.
- [2] Sony S, Laventure S, Sadhu A. A literature review of next-generation smart sensing technology in structural health monitoring[J]. *Structural Control and Health Monitoring*, 2019, 26(3): e2321.
- [3] 柳长源, 郭鹏岗, 兰朝凤. 注意力置换与通道重建的无人机城市街景实时语义分割[J]. *控制与决策*, 2025, 40(4): 1198-1206.
(Liu C Y, Guo P G, Lan C F. Real-time semantic segmentation of UAV urban street scenes with attention permutation and channel reconstruction[J]. *Control and Decision*, 2025, 40(4): 1198-1206.)
- [4] 毛建旭, 贺振宇, 王耀南, 等. 电力巡检机器人路径规划技术及应用综述[J]. *控制与决策*, 2023, 38(11): 3009-3024.
(Mao J X, He Z Y, Wang Y N, et al. Review of research and applications on path planning technology for power inspection robots[J]. *Control and Decision*, 2023, 38(11): 3009-3024.)
- [5] Zhen L, Li M, Laporte G, et al. A vehicle routing problem arising in unmanned aerial monitoring[J]. *Computers & Operations Research*, 2019, 105: 1-11.
- [6] Wei J W, Yang C X, Yuan Y, et al. Topology optimization of UAV network for target surveillance task with support jamming[J]. *Signal Processing*, 2024, 224: 109583.
- [7] Zeng F, Chen Z W, Clarke J P, et al. Nested vehicle routing problem: Optimizing drone-truck surveillance operations[J]. *Transportation Research — Part C: Emerging Technologies*, 2022, 139: 103645.
- [8] 夏丹, 陈洋, 陈志环, 等. 基于高基尼不纯度的 UAV & UGV 协作监测系统路径规划[J]. *控制与决策*, 2024, 39(3): 804-812.
(Xia D, Chen Y, Chen Z H, et al. Path planning of unmanned aerial vehicle & unmanned ground vehicle collaborative monitoring system based on high Gini impurity[J]. *Control and Decision*, 2024, 39(3): 804-812.)
- [9] Nigam N. The multiple unmanned air vehicle persistent surveillance problem: A review[J]. *Machines*, 2014, 2(1): 13-72.
- [10] Brown A, Anderson D. Trajectory optimization for high-altitude long-endurance UAV maritime radar surveillance[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2020, 56(3): 2406-2421.
- [11] 秦文龙, 罗贺, 王国强, 等. 考虑多换电站的多无人机应急电力巡检路径规划方法[J]. *控制与决策*, 2025, 40(8): 2391-2399.
(Qin W L, Luo H, Wang G Q, et al. Multi-UAV emergency power inspection path planning method considering multiple charging stations[J]. *Control and Decision*, 2025, 40(8): 2391-2399.)
- [12] Zhou B L, Liu W, Yang H. Unmanned aerial vehicle service network design for urban monitoring[J]. *Transportation Research — Part C: Emerging Technologies*, 2023, 157: 104406.
- [13] Coelho L C, Cordeau J F, Laporte G. Thirty years of inventory routing[J]. *Transportation Science*, 2014, 48(1): 1-19.
- [14] 刘志硕, 左兴权, 吴建军. 面向小容销比客户的库存路径问题模型与算法[J]. *系统工程理论与实践*, 2024, 44(6): 2018-2032.
(Liu Z S, Zuo X Q, Wu J J. Model and algorithm of the inventory routing problem for customers with small capacity sales ratio[J]. *Systems Engineering — Theory & Practice*, 2024, 44(6): 2018-2032.)
- [15] Huang S H, Lin P C. A modified ant colony optimization algorithm for multi-item inventory routing problems with demand uncertainty[J]. *Transportation Research — Part E: Logistics and Transportation Review*, 2010, 46(5): 598-611.
- [16] Liu Z S, Zuo X Q. Inventory routing problem with split delivery and variable time windows for customers with small capacity and large sales[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(8): 10375-10388.
- [17] Floudas C A. *Nonlinear and mixed-integer optimization: Fundamentals and applications*[M]. New York: Oxford University Press, 1995.
- [18] Brimberg J, Salhi S, Todosijević R, et al. Variable neighborhood search: The power of change and simplicity[J]. *Computers & Operations Research*, 2023, 155: 106221.
- [19] Stenger A, Vigo D, Enz S, et al. An adaptive variable neighborhood search algorithm for a vehicle routing problem arising in small package shipping[J]. *Transportation Science*, 2013, 47(1): 64-80.

作者简介

陈群 (1977-), 男, 教授, 博士, 博士生导师, 主要研究方向为运输系统优化、交通运输规划与管理, E-mail: chenqun631@csu.edu.cn;

孙乐天 (2001-), 男, 硕士生, 主要研究方向为无人机巡检路径规划问题, E-mail: 224211027@csu.edu.cn;

余帆 (1997-), 男, 博士生, 主要研究方向为无人车辆协同路径规划问题、交通运输规划与管理, E-mail: yufan0519@gmail.com.