

控制与决策

Control and Decision

基于改进图神经网络算法的异构多智能体动态任务分配

马梓元, 冯鹏宇, 龚华军, 王新华

引用本文:

马梓元, 冯鹏宇, 龚华军, 等. 基于改进图神经网络算法的异构多智能体动态任务分配[J]. *控制与决策*, 2026, 41(4): 1014-1023.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0887>

您可能感兴趣的其他文章

Articles you may be interested in

基于深度学习的仿生集群运动智能控制

Intelligent control of bionic collective motion based on deep learning

控制与决策. 2021, 36(9): 2195-2202 <https://doi.org/10.13195/j.kzyjc.2020.0071>

一种结合内在动机理论的移动机器人环境认知模型

An environment cognition model combined with intrinsic motivation for mobile robots

控制与决策. 2021, 36(9): 2211-2217 <https://doi.org/10.13195/j.kzyjc.2019.1744>

基于影响度介数中心性的多智能体牵制控制算法

Multi-agent pinning control algorithm based on betweenness centrality with influence degree

控制与决策. 2021, 36(6): 1442-1448 <https://doi.org/10.13195/j.kzyjc.2019.1106>

基于生物启发神经网络和DMPC的多机器人协同搜索算法

Multi-robot cooperative search algorithm based on bio-inspired neural network and DMPC

控制与决策. 2021, 36(11): 2699-2706 <https://doi.org/10.13195/j.kzyjc.2020.0959>

脉冲神经网络研究进展综述

Spiking neural networks A survey on recent advances and new directions

控制与决策. 2021, 36(1): 1-26 <https://doi.org/10.13195/j.kzyjc.2020.1006>

基于改进图神经网络算法的异构多智能体动态任务分配

马梓元[†], 冯鹏宇, 龚华军, 王新华

(南京航空航天大学 自动化学院, 南京 211106)

摘要: 针对复杂任务环境下异构多智能体的多目标优化调度中存在的动态不确定性等问题, 提出一种自适应深度图神经网络 (AD-GNN) 与仿生算法融合的任务分配方法. 首先, 通过构建自适应深度图神经网络, 根据任务图复杂度动态调整网络结构, 实现对异构多智能体与任务节点间复杂关系的高效建模; 然后, 引入仿生优化机制, 模拟自然进化和群体协作过程, 增强系统在动态干扰下的鲁棒性和全局寻优能力, 从而形成具备环境自适应的智能决策框架; 最后, 通过仿真实验结果表明: 在动态环境下, 所提出方法在任务完成时间、系统能耗、动态任务覆盖率上均表现优异, 能够有效应对动态不确定环境下的异构智能体任务分配问题, 显著提升系统在实时决策、协同效率以及环境适应性方面的综合性能.

关键词: 复杂环境; 异构多智能体; 任务分配; 自适应动态机制; 图神经网络; 仿生机制

中图分类号: V279 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0887

引用格式: 马梓元, 冯鹏宇, 龚华军, 等. 基于改进图神经网络算法的异构多智能体动态任务分配 [J]. 控制与决策, 2026, 41(4): 1014-1023.

Dynamic task allocation for heterogeneous multi-agent systems based on improved graph neural network algorithm

MA Zi-yuan[†], FENG Peng-yu, GONG Hua-jun, WANG Xin-hua

(School of Automation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: To address multi-objective optimization scheduling and dynamic uncertainty issues for heterogeneous multi-agent systems in complex task environments, this paper proposes a dynamic task allocation method integrating adaptive dynamic graph neural networks (AD-GNN) with bio-inspired algorithms. First, by constructing an adaptive deep graph neural network, the network structure is dynamically adjusted based on task graph complexity to efficiently model intricate relationships between heterogeneous agents and task nodes. Then, a biomimetic optimization mechanism is introduced to simulate natural evolution and collective collaboration processes, enhancing the system's robustness and global optimization capability under dynamic disturbances. This forms an intelligent decision-making framework with environmental adaptability. Finally, simulation results demonstrate that under dynamic conditions, the proposed method exhibits superior performance in task completion time, system energy consumption, and dynamic task coverage. It effectively addresses multi-agent task allocation challenges in dynamically uncertain environments, significantly enhancing the system's overall capabilities in real-time decision-making, collaborative efficiency, and environmental adaptability.

Keywords: complex environments; heterogeneous multi-agent systems; task allocation; adaptive dynamic mechanism; graph neural networks; biomimetic mechanism

0 引言

随着人工智能时代的到来, 在深度学习等新方法的赋能下, 智能优化与调度正迈向知识与群智协同、数据与模型融合的新范式. 社会和城市的发展变得愈加引人注目和复杂, 特别是在复杂环境下的应急响应、大规模物流配送等实际场景中, 任务需求呈

现出高度动态、不确定的特点, 对异构多智能体系统的协同决策能力提出了更高要求. 无人机等智能体的出现极大地拓展了其在各类高难度任务中的应用范围, 如环境监测、灾害评估以及精准农业等^[1]; 与此同时, 在复杂的环境中, 通过人工智能技术互联的自主车辆已经实现了高度自动化的驾驶能力, 显著

收稿日期: 2025-08-28; 录用日期: 2025-12-11.

基金项目: 国家自然科学基金项目 (62350048).

责任编辑: 王凌.

[†]通信作者. E-mail: mazyuan@nuaa.edu.cn.

提升了交通管理和物流配送的效率^[2]。这些智能系统在复杂环境中动态且高效地执行任务,尤其是在空中与地面资源高度集成的情况下,能够有效应对复杂环境固有的复杂性和不可预测性^[3-4]。深度学习、机器学习、自然语言处理、计算机视觉等这些人工智能技术在复杂环境中愈发重要,这些环境以其复杂性和动态变化的特性为特点^[5-6]。多智能体能够高效地在这些环境中导航,对于执行监视、运输和紧急任务等复杂动态环境中异构多智能体的多目标调度动态不确定性问题至关重要^[7]。然而,当面对突发任务、设备故障或通信中断等现实情况时,现有的任务分配方法往往难以保持系统的协同效率和稳定性。这种协作对于高效执行需要在不可预测和复杂环境中导航的任务至关重要^[8]。

目前研究的任务分配算法有自适应遗传学习粒子群算法、顺序扩展一致性包算法等^[9-10]。这些动态任务分配算法对于多智能体而言,涉及一种复杂的协调机制,使得这些自主系统能够在复杂环境中灵活、高效地响应多样化的作业需求^[11]。其主要目标是通过基于实时数据分析和不断演变的情境背景动态分配职责,以优化任务执行,确保多智能体在最需要的地方得到充分利用^[12]。但是,在实际应用中,由于环境变化的突发性和任务需求的实时演进,这些算法在动态重规划效率和系统协同性方面仍然存在明显不足。多智能体的动态任务分配在执行需要高度精准和适应性的各类操作中至关重要^[13]。通常被分配的任务包括监视、侦察、物流支持,以及更复杂的操作,如搜索与救援、灾害响应以及环境监测^[14]。这些复杂的环境以其不可预测性、密集的基础设施和不断变化的特性为特点,给独立操作的自主系统带来了巨大挑战^[15]。同样,被指派执行搜索与救援任务的多智能体可能会遇到被阻塞的路线或受损的基础设施,需要立即重新分配到新条件下更可行的任务。这类实际应用场景迫切需求能够快速响应环境变化,保持系统整体协同的任务分配机制。其次,这些环境需要强大的通信和数据共享框架,以同步多智能体的活动^[16]。这种同步措施可确保空中和地面单位能够适配彼此的探测结果及任务环境的变化,优化整体战略响应^[17]。

多智能体任务分配的传统方法在复杂的环境中常常面临诸多限制^[18]。这些传统方法通常依赖于预定义,且缺乏灵活性的静态任务分配,不考虑作业的动态特性^[19]。因此,它们难以有效应对这些环境中常见的突发变化或新出现的状况。特别是在协同作业方面,传统方法缺乏系统级的优化视角,无法在保持个体性能的同时实现整体系统效能的最大化。此外,

这些传统模型通常未设计用于应对复杂环境中固有的复杂性和不确定性^[20]。传统任务分配方法由于其刚性、缺乏实时适应性、多智能体能力整合不足以及无法充分应对复杂环境的复杂性和不确定性而面临挑战^[21]。这些缺陷凸显了采用更复杂和动态的方法的必要性,如利用先进的计算模型和实时数据整合的方法。在多智能体协作中的动态任务分配的传统方法主要集中于静态和预定义的任务分配。这些方法通常涉及层级化或集中式的决策结构,任务分配基于固定的算法,不考虑作业环境的变化^[22]。如:在监视应用中,无人机可能会根据其初始位置和电池寿命被分配监控特定区域,而无人地面车辆则根据预定路线执行地面分析或障碍清除任务^[23]。

为解决上述问题,学者们引入深度图神经网络(D-GNNs)融合先进的机器学习技术,该方法显著改进了传统的DTA方法,实现了更为动态和响应迅速的任务分配^[24]。D-GNNs是一种图神经网络,能够动态调整其深度,以更好地处理和理解数据中的复杂关系,特别适用于多智能体作业中常见的互联和多模态数据。在动态任务分配中使用D-GNNs的主要优势之一在于其能够适应不同的数据深度和复杂性,从而对作业环境有更细致的理解^[25]。

然而,当前研究仍然存在明显不足:一方面,多数现有方法是基于静态场景设计的,难以匹配复杂环境中任务的动态变化特性,如:救援中新增被困人员点位,物流中临时出现大额紧急订单,现有方法往往需要重新计算全局分配策略,存在明显的响应延迟^[26];而在动态资源调度场景中,如部分智能体突发故障、道路临时管制导致资源可达性变化,缺乏快速调整局部任务分工的自适应能力。另一方面,现有研究多将优化焦点集中于单个智能体的执行效率,却忽视了不同智能体间协同求解动态任务分配问题的需求,如:物流配送中多台机器人同时争抢同一配送区域导致路径重叠,巡检任务中多设备遗漏交叉区域或重复覆盖^[27]。这些协同求解动态任务分配问题直接制约了系统在复杂环境中的作业稳定性、覆盖完整性和整体响应速度。针对上述关键挑战,本文对现有方法中异构多智能体在动态环境适应性与系统协同优化方面的不足,在D-GNNs的基础上引入自适应机制,构建自适应深度图神经网络与仿生算法融合的动态任务分配方法,结合图注意力机制对关键节点进行重加权,完成动态重规划并生成新任务分配方案。旨在提升多智能体在复杂环境下的动态任务分配能力和整体协同效率。

1 问题描述与定义

考虑到复杂任务环境中异构多智能体的多目标

调度存在动态不确定性的问题,任务分配必须应对作业规模和多样性的增加.根据不同多智能体的作业角色和能力进行不同任务的分工和调度,下文将分别对场景动态问题、任务分配模型、约束条件、目标函数以及通信信道模型进行分析.

1.1 场景动态问题描述

本文所设计的任务场景多为任务点分布较为分散,动态性强的作业场景,具体存在如下3个问题.

问题1 任务点动态变化导致响应不足.

本文所测试的江南大学校园场景中存在固定任务点和动态任务点.令任务集合表示为 $T = T_f \cup T_d$.其中: $T_f = t_1, t_2, \dots, t_{10}$ 为10个固定任务点, $T_d = t_{11}, t_{12}, t_{13}$ 为3个动态任务点.令 $P(t_i)$ 表示任务点 t_i 的位置状态集合,随时间 t 变化.动态任务点 T_d 的变化频率为每10 min新增或移动1个任务点,导致任务分配需要频繁调整.

问题2 任务规模增加导致局部最优.

本文所测试的桤溪农场场景中存在固定稻田和动态除草点.令任务集合 $T = T_f \cup T_d$.其中: $T_f = t_1, t_2, \dots, t_8$ 为8个固定任务点, $T_d = t_9, t_{10}, t_{11}, t_{12}$ 为4个动态任务点.令 $R(t_i, t_j)$ 表示任务点 t_i 与 t_j 间的路径状态集合,路径距离 $d_{\{ij\}}$ 随动态任务点变化而调整.当任务点数量增至12时,路径优化复杂度从 $O(|T|^2)$ 升至更高,导致优化算法易陷入局部最优.

问题3 多样化需求与资源限制的矛盾.

本文所测试的局部战场场景中存在固定哨站和动态移动目标.令任务集合 $T = T_f \cup T_d$.其中: $T_f = t_1, t_2, \dots, t_9$ 为9个固定任务点, $T_d = t_{10}, t_{11}, \dots, t_{14}$ 为5个动态任务点.令 $D(t_i)$ 表示任务点 t_i 的需求状态集合.UAV载重上限 $C_u = 20$ kg,UGV载重上限 $C_g = 200$ kg,任务需求 $\sum_{i \in T} D(t_i)$ 可能超出单设备容量,导致资源分配矛盾.

1.2 任务分配模型

本文主要探讨动态任务环境下UAV和UGV这种异构多智能体协同任务分配,任务点集合用符号 T 表示.

UAV集合用符号 U_v 表示,定义为 $U_v = u_1, u_2, \dots, u_k (k \in [2, 4])$,每台UAV的属性为四元组 v_u, f_u, r_u, t_u .UGV集合用符号 G_v 表示,定义为 $G_v = g_1, g_2, \dots, g_l$,每台UGV的属性为四元组 v_g, f_g, r_g, t_g .其中四元组分别表示速度、执行功能、续航能量、最大飞行时间.

任务集合定义为 $T = T_f \cup T_d$.其中:固定任务点集合 T_f 数量为5~10,动态任务点集合 T_d 数量为

3~5,总任务数不超过15.每个任务 $t_i \in T$ 具有需求载重 d_i (单位:kg).

能耗参数:UAV单位距离能耗 $e_u = 10$ kJ/km,续航上限 $R_u = 600$ kJ;UGV单位距离能耗 $e_g = 5$ kJ/km,续航上限 $R_g = 1200$ kJ.

通信参数:任务期间的通信延迟 $D(t)$ 和通信成功率 $P_{s(t)}$.

任务分配和路径变量: $y_{\{ik\}}$ 表示任务 t_i 是否分配给设备 k , $x_{\{ijk\}}$ 为路径选择变量, η_i 为任务 t_i 的成功率, θ 为执行时间占比, ε 为任务执行效率.

1.3 约束条件

任务分配唯一性和载重限制如下所示:

$$\sum_{\{k \in U \cup G\}} y_{\{ik\}} = 1, \quad \sum_{\{i \in T\}} y_{\{ik\}} d_i \leq C_k. \quad (1)$$

式(1)表示每个任务只能分配给一台智能体.智能体携带的任务总重量不能超过其最大载重.

时间约束如下所示:

$$\begin{aligned} s_i &\geq a_{\{ik\}}; \\ e_i &= s_i + \tau_i; \\ a_{\{ij\}} &= a_{\{ik\}} + \frac{d_{\{ij\}}}{v_k} \times x_{\{ijk\}}; \\ s_i - a_{\{ik\}} &\leq 300, \quad t_i \in T_d; \\ T_{\text{total}} &= \max_{\{i \in T\}} e_i. \end{aligned} \quad (2)$$

其中:任务开始时间不能早于设备到达时间,任务结束时间是开始时间加上执行时间,设备从一个任务点到下一个任务点的时间取决于两点间的距离和智能体速度,动态任务从设备到达至开始不能超过300 s,总调度时间是所有任务中最晚的结束时间.

能耗约束如下所示:

$$E_k = \sum_{\{i, j \in T\} e_k} d_{\{ij\}} \times x_{\{ijk\}} \leq R_k. \quad (3)$$

智能体耗能基于其走过的距离,设备的总耗能不能超过其电池容量.

通信和任务成功率为

$$D(t) < 2, \quad p_{s(t)} > 0.9, \quad \eta_i \geq 0.95 \times P_{s(t)}. \quad (4)$$

通信延迟必须低于2 s,通信成功率要高于90%,每个任务的成功率至少达到通信成功率的95%.

路径连通性和任务执行效率如下所示:

$$\begin{aligned} \varepsilon &= \sum_{\{i \in T\} \eta_i} T_{\text{total}} \geq 0.25, \quad \forall t_i, t_j \in T, \quad \forall k \in U \cup G; \\ \sum_{\{j \in T\}} x_{\{ijk\}} &= y_{\{ik\}}; \\ \theta &= \sum_{\{i \in T\} \tau_i} T_{\text{total}} \leq 1, \end{aligned} \quad (5)$$

若任务分配给某个智能体,则智能体必须有对应的

路径执行. 所有任务的执行时间总和不能超过总调度时间. 任务的平均成功率至少达到 0.25, 以确保整体效率. 这些规则适用于所有任务和设备. 该综合约束公式 (1) ~ (5) 系统性地描述了动态任务环境下 UAV 与 UGV 协作执行的关键限制条件, 唯一性和资源合理分配, 确保每个任务只被一个智能体执行, 且不超过其载重.

1.4 目标函数

在动态任务环境下, UAV 和 UGV 组成的异构多智能体协同任务分配需要综合考虑任务完成时间、能耗、任务成功率、任务覆盖率以及任务优先级等多个目标, 以实现高效、可靠的分配方案. 本文设计一个多目标优化函数, 旨在最小化任务完成时间和能耗, 同时, 最大化任务成功率和动态任务覆盖率, 并在任务优先级和执行效率的约束下优化分配. 目标函数基于统一的约束条件, 通过加权方式平衡各目标, 下文通过公式表达目标函数, 并详细解释其参数含义.

目标函数综合任务完成时间、能耗和任务成功率如下所示:

$$\min_z = w_1 \cdot T_{\text{total}} + w_2 \cdot E_{\text{total}} - w_3 \cdot \sum_{(i \in T_{\eta_i})} \pi_i. \quad (6)$$

其中: 任务完成时间为 $T_{\text{total}} = \max_{i \in T} (s_i + \tau_i)$, s_i 为任务的开始时间, τ_i 为任务的执行时间; 总能耗为 $E_{\text{total}} = \sum_{k \in U \cup G} \sum_{i, j \in T} e_k \cdot d_{ij} \cdot x_{ijk}$; w_1 、 w_2 和 w_3 为权重系数, 表示时间、能耗、成功率的重要性. 该目标函数通过最小化时间、能耗、成功率以及覆盖率, 结合任务

优先级, 全面优化 UAV 和 UGV 的任务分配. 相比于上一研究仅关注时间和能耗的双目标, 目标函数 (6) 增加了任务成功率和优先级权重, 动态调整权重以适应不同场景, 并在多维约束下保证分配方案的高效性和鲁棒性, 为 AD-GNN 算法提供了坚实的理论支持.

1.5 通信信道模型建模

通过通信信道模型的建立, 所提出算法能够动态调整任务分配策略, 适应动态环境下的通信波动, 确保 UAV 与 UGV 的高效协同. 通信信道动态模型的建立考虑以下要素: 带宽设定为中等水平, 如 10 Mbps, 足以支持任务点位置和需求的实时传输, 但是波动时可能会降至 8 Mbps; 延迟通常在 1 ~ 2 s 之间, 但是在通信波动 25% 的战场场景中, 可能会增至 3 s; 通信成功率要求大于 90%, 但是在中密度环境中, 因轻度干扰可能会降至 85% ~ 90%. 这种通信信道模型为 AD-GNN 算法提供了实时数据支持, 确保任务分配的鲁棒性.

图 1 为通信信道模型建立流程. 如图 1 所示: 首先, 算法初始化任务图, 基于输入的任务点集合、设备集合、初始通信状态以及节点属性, 生成一个包含节点和边的初始任务图, 其中边权重初始为 1; 然后, 系统实时监测通信状态, 通过传感器数据输出通信参数集合 $C(t)$, 用于反映环境变化; 接着, 算法更新任务图, 根据动态任务点和通信状态调整节点数量和边权重, 以适配实时变化; 最后, 基于更新后的任务图和设备属性, 输出动态分配方案 S .

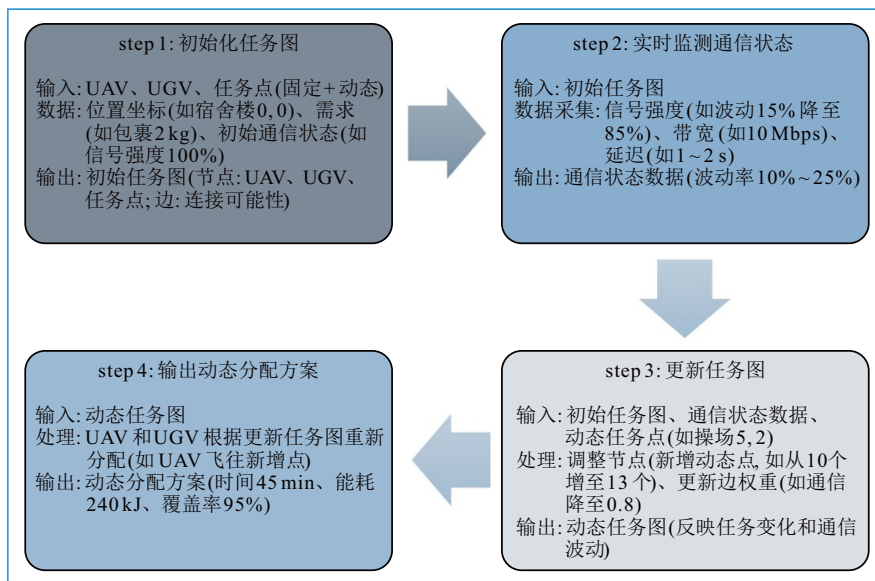


图1 通信信道模型建立流程

2 任务分配算法设计

任务分配策略主要是构建基于自适应深度图神

经网络, 将仿生算法融入的动态任务分配方法, 优化异构多智能体多样化且可扩展的作业. 这种混合方

法能够实现自适应且高效的动态任务分配。

2.1 算法结构数学描述

将仿生算法融入 AD-GNN, AD-GNN 旨在根据任务复杂性的拓扑结构动态调整其深度或层数. 这种适应性使得网络能够高效处理大规模、高维度的数据, 这些数据涉及多智能体作业场景的典型特征.

在数学上, AD-GNN 可表示为一个函数 $G = (V, E, W)$. 其中: V 为多智能体的节点集合, E 为它们之间交互和通信的边集合, W 为网络的权重或参数. 网络的深度记为 D , 根据输入图的复杂性进行调整, 以优化学习和决策过程, 如下所示:

$$D = \delta(C, S, T). \quad (7)$$

这里: δ 为一个自适应函数; 根据情景深度 D 、空间约束 S 和时间约束 T , 调整复杂度 C .

为解决环境动态和部分可观测性的挑战, 所提出的框架构建了感知-决策-执行闭环自适应机制. AD-GNN 通过自适应函数 δ 根据实时场景复杂度 C 动态调整网络深度 D . 当环境波动时, 自动加深网络以提取复杂特征; 当环境稳定时, 则切换浅层网络提升响应速度, 实现精度与效率的平衡.

令 $G = (V, E)$ 表示作业网络的图. 其中: (V) 为节点集合 (无人机和无人地面车辆), (E) 为它们之间连接的边集合.

对于节点 $(v \in V)$, 边 (i, j) 的局部注意力系数 (α_{ij}) 可使用一个 softmax 函数计算. 该函数考虑了节点 (i) 和 (j) 的特征以及边的属性 (e_{ij}) , 即

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(a^T [Wh_i | Wh_j + W_e e_{ij}]))}{\sum_{k \in \mathcal{N}(i)} \exp(\text{LeakyReLU}(a^T [Wh_i | Wh_k + W_e e_{ik}]))}. \quad (8)$$

其中: h_i 和 h_j 为节点 i 和节点 j 的特征向量, W 和 W_e 分别为节点和边特征的权重矩阵, α 为注意力机制中的权重向量, $|$ 表示连接, $\mathcal{N}(i)$ 为节点 i 的领域.

全局注意力机制评估网络中每个节点 v , 在整个网络上下文中的重要性记为 β_v , 如下所示:

$$\beta_v = \frac{\exp(\text{LeakyReLU}(a_g^T W_g h_v))}{\sum_{u \in V} \exp(\text{LeakyReLU}(a_g^T W_g h_u))}. \quad (9)$$

其中: W_g 为全局注意力的权重矩阵, a_g 为全局注意力权重向量, (h_v) 为节点 (v) 的特征向量.

对于系统异构性建模方法, 该算法框架的核心在于结合自适应深度图卷积网络, 引入局部和全局双重关联建模, 精准刻画异构智能体 i 与任务 j 间的关键协作关联, 进而聚焦核心协作关系以提升协同

效率. 全局注意力 β_v 评估节点全局重要性, 优化关键资源分配. 二者协同实现复杂异构依赖的精准建模.

全局注意力机制通过计算每个节点在整个图中的重要性权重, 能够更全面地捕捉节点间的全局关系. 这种机制不仅考虑了节点自身的特征, 还结合了其在网络中的位置和连接情况, 从而提升了模型对于整体网络结构的理解和任务分配的精准性.

仿生算法受自然过程和行为的启发, 被集成至 AD-GNN, 以增强其决策和优化能力. 这种集成借鉴了进化算法、蚁群优化和群体智能等原理, 模仿自然界中观察到的集体和适应性行为, 从而提升任务分配的效率 and 鲁棒性. 所提出仿生算法模块深度融合了蚁群优化与粒子群优化的协同机制, 通过将任务分配方案映射为路径优化问题, 利用 ACO 的信息素正反馈机制强化优质解、PSO 的全局搜索能力, 扩大探索空间, 有效弥补了纯 GNN 模型在全局寻优上的不足; 该模块通过自适应调整信息素挥发因子和启发式权重, 实现对动态环境特性的实时响应, 并与 AD-GNN 层形成双向协同, 共同构建一个兼具全局优化能力与动态适应性的高效决策系统.

仿生方法体现在优化函数 Ω 上. 该函数通过模拟自然选择和适应过程, 寻求最优的任务分配策略 Θ , 即

$$\Theta = \Omega(G, \Phi, \Lambda). \quad (10)$$

其中: Φ 为任务及其需求的集合, Λ 为作业约束和环境因素, 函数 Ω 通过迭代调整图 G 和任务分配策略 Θ 来最大化作业效率和任务成功率.

面向 NP-Hard 及多目标优化难题, 仿生层采用自适应蚁群机制, 设计两类核心算子: 状态转移规则基于信息素与启发信息平衡探索利用; 自适应信息素更新规则通过动态调整挥发系数 ρ , 强化高效路径, 快速淘汰过时信息, 引导搜索逼近帕累托最优解.

所提出算法中关键可调参数包括自适应深度函数 δ 中的环境复杂度权重 Ω_c , 空间约束权重 Ω_s 和时间约束权重 Ω_t , 注意力机制中的温度参数 τ , 以及仿生优化中蚁群算法的信息素挥发系数 ρ . 这些参数共同影响算法的收敛速度、解的质量以及对动态环境的适应性.

2.2 算法设计框架

AD-GNN 与仿生算法集成的架构蓝图结构如图 2 所示.

输入层: 接收初始数据, 包括作业情景的具体细节、多智能体的特性以及环境参数.

自适应深度层: 由 GNNs 组成, 这些层根据输入数据的复杂性动态调整深度, 处理异构多智能体网

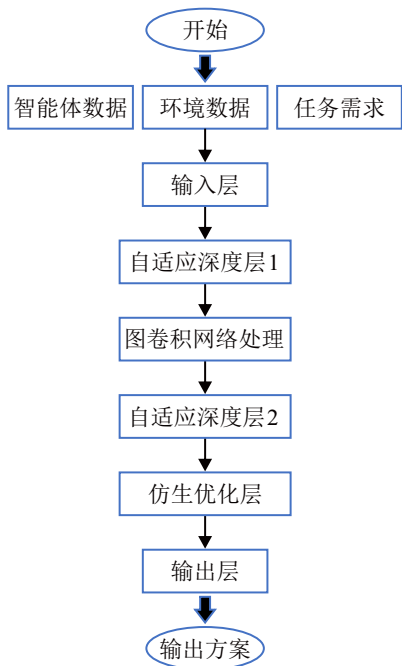


图2 AD-GNN 与仿生优化的架构

网络中的交互和依赖关系。

仿生优化层: 应用基于自然过程的算法, 优化任务分配策略, 确保在动态环境中的适应性和鲁棒性。

输出层: 生成优化的任务分配计划, 详细说明网络中每个智能体的角色、职责以及作业路径。

为进一步说明算法在每层架构中的任务分配, 图3使用矩阵表示法来说明 AD-GNN 架构中每层




图3 AD-GNN 架构连接结构

任务分配通过图 $G = (V, E)$ 来建模。其中: V 为节点集合, E 为通信连接或作业依赖关系的边集合。图神经网络处理该图以优化任务分配, 利用节点特征 X 和边特征 Y 计算任务分配策略。多智能体及其环境之间的交互可通过仿生算法建模, 该算法模拟自然过程以实现优化。如: 若 $\phi(u_i)$ 为无人机 u_i 的任务分配函数, 则优化过程旨在最大化整体任务效率 η , 表达式为

$$\eta = \max \left\{ \sum_{i=1}^n \phi(u_i) + \sum_{j=1}^m \phi(g_j) \right\}. \quad (11)$$

在满足多智能体的作业约束和能力的前提下, 这种数学模型能够定量评估任务分配策略的效果, 确保

的连接性和结构。图3中, 使用二进制值 (0 和 1) 表示各层内部元素间是否存在连接, 这有助于直观地展示模型不同组件间的相互作用。

输入层矩阵: 矩阵中的每列表示一种数据类型。“1”的存在表示输入层与该特定数据类型间有直接连接, 表明输入层处理并整合这些多样化的数据流, 以促进后续层的操作。

自适应深度层矩阵: 对角线元素为“0”, 表示没有自连接; 而非对角线的“1”表示图神经网络处理与深度调整间的双向互动, 展示了该层内部的动态性和反馈机制。

仿生优化层矩阵: 非对角线的“1”反映了这些组件间的互动和协作性质, 强调了该层通过仿生原理优化任务分配的作用。

输出层矩阵: 表明过程的最终阶段将计算和决策过程整合为一个连贯的输出, 指导不同智能体执行各自的任務。

所提出框架通过集成 AD-GNN 和仿生算法机制, 构建一个多层智能任务分配系统: 输入层负责数据汇集, 自适应深度层解析任务与环境间的复杂关系, 仿生优化层进一步提升分配效率, 输出层则生成最终作业方案。该架构实现了在复杂动态环境下异构多智能体的高效协同和动态决策, 显著提升了任务执行效率和系统适应性, 为智能自主作业提供了可靠的技术基础。

在复杂环境中多智能体的协同作业达到最佳状态。

该算法框架的核心在于构建自适应深度图神经网络与仿生算法融合的动态任务分配方法, 实现对复杂多变的作业环境的动态适应和优化。自适应深度图卷积网络能够根据任务的复杂性和环境的变化, 实时调整其网络结构和深度, 以更高效地处理和来自无人机以及无人地面车辆的多源、多模态数据。与此同时, 仿生算法通过模拟自然界中的优化机制, 如蚁群算法和粒子群算法, 进一步提升任务分配的适应性和鲁棒性, 使得系统能够在面对突发事件和环境变化时, 迅速做出响应和调整。

通过这种结合, 算法框架不仅能够实现实时的数据整合和任务优化, 还能在动态环境中高效地协

调无人机和无人地面车辆的作业,提高整体作业效率和任务完成率.此外,该框架还考虑了能源消耗和环境因素,如风速和温度,确保无人机和无人地面车辆在不同物理条件下的高效运行.这一综合性的算法框架为复杂环境中无人系统的动态任务分配提供了一个稳健且高效的解决方案,显著提升了自主系统在多变和不确定环境中的作业能力和响应速度.

3 仿真分析

为保障 AD-GNN 模型在动态环境中能够快速、稳定地生成高效任务分配方案,首先对其进行离线的初始化训练.该训练基于历史和仿真数据,构建涵盖各种初始任务图及其在通信波动、动态任务出现下演变序列的样本集.每个样本均包含初始任务图和动态环境的模拟变化.

参数初始值通过网格搜索在预实验场景中确定,搜索范围基于参数理论取值范围设定,最终取值通过对比实验,AD-GNN 参数按照上述优化策略设置,对比实验中的其他算法均采用其最优参数配置,保证对比公平性.

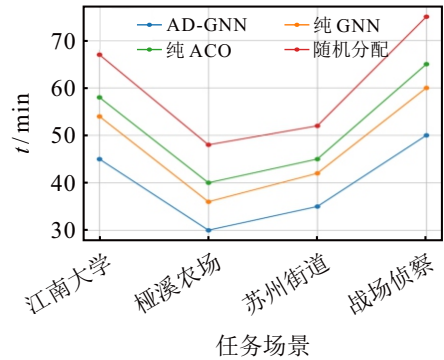
对改进 AD-GNN 进行综合仿真分析,分别通过 4 大场景进行测试.然后,与几种现有的主流方法进行比较实验.不同智能体总数控制在 20 个以内,任务点包括固定点和动态点,通信存在偶发波动.目标约束为场景中需要完成的任务点数量.空间约束为智能体的作业区域范围、障碍物分布、禁飞区设置以及通信基站的覆盖范围.时间约束为任务的最长完成时限、智能体的最大续航时间以及任务间的时序依赖关系.动态不确定性来源为通信链路质量的实时波动、环境要素的干扰、智能体突发状况以及随机插入动态任务.发生时机为随机动态插入.4 大仿真场景设置如表 1 所示.

表1 4大仿真场景设置


场景参数项	江南大学 校园配送	樾溪街道 家庭农场	苏州科技大学 周边街道	局部战场 侦察
面积/km ²	2	2	1	3
固定任务点/个	10	18	7	9
动态任务点/个	3	4	3	5
多智能体数量/台	7	6	5	14
环境干扰波动/%	15	20	15	25
信号强度	100 ~ 85	100 ~ 80	100 ~ 85	100 ~ 75
信号延迟/s	1 ~ 2	2.5	2	3

实验对比 4 种算法: AD-GNN (所提出算法)、纯 GNN (静态特征提取)、纯 ACO (传统蚁群优化)、随机分配.评估指标包括任务完成时间、能耗、资源利用率、协同效率、动态任务覆盖率.仿真结果见图 4.


如图 4 所示,AD-GNN 在动态响应、路径优化 (10 次迭代覆盖 95%) 和通信适应性 (波动 25% 仍然高效) 上优于其他算法.如:在江南大学场景中,AD-GNN 以 45 min 完成 13 个任务点的配送,较 GNN




(a) 任务完成时间



(b) 能耗



(c) 资源利用率



(d) 协同效率

图4 4大任务场景实验分析对比

的 54 min 缩短约 16%, 能耗从 264 kJ 降至 240 kJ, 动态任务覆盖率达 95%; 在榷溪农场场景中, 12 个任务点实现 30 min 全覆盖, 资源利用率高达 90%; 在局部战场场景中, 5 个动态目标的侦察任务在通信波动 25% 下仍然保持 95% 覆盖率. 具体仿真结果数据如表 2 所示.

表2 4大仿真结果分析

评估指标及方法	江南大学 校园配送	榷溪街道 家庭农场	苏州科技大学 周边街道	局部战场 侦察
耗时(AD-GNN)/min	45	30	35	50
能耗(AD-GNN)/kJ	240	200	180	300
覆盖率(AD-GNN)/%	95	90	95	88
耗时(GNN)/min	54	36	42	60
能耗(GNN)/kJ	264	220	198	330
覆盖率(GNN)/%	80	85	80	80
耗时(ACO)/min	58	40	45	65
能耗(ACO)/kJ	288	240	210	360
覆盖率(ACO)/%	75	80	75	70
耗时(随机)/min	67	48	52	75
能耗(随机)/kJ	312	260	228	390
覆盖率(随机)/%	60	70	65	60

为验证不同算法在发生动态变化后任务重规划场景下的时间效率, 本文针对 AD-GNN、纯 GNN、纯 ACO 以及随机分配 4 种算法, 开展任务变化数量与重分配时间的对比实验, 仿真结果如图 5 所示.






图5 任务变化数量与重规划时间关系对比

由图 5 可知, 4 种算法的重规划耗时均随任务变化数量增大而上升, 但是性能层级差异显著: AD-GNN 重规划时间增长最为平缓, 始终控制在 2 ~ 3 s 内, 时间效率最优; 纯 GNN、纯 ACO 时间增长速率依次加快; 随机分配时间增长最显著, 从约 8.5 s 快速攀升至 13 s 以上, 性能在 4 种算法中最差. 这表明 AD-GNN 因高效的图表示和分配策略, 在任务重分配的时间效率上优势明显, 更适合实时性要求高的场景.


为验证 AD-GNN 在动态任务环境下的优越性, 开展在 4 大任务场景下的收敛曲线分析, 仿真结果见图 6.




(a) 江南大学校园配送收敛曲线



(b) 榷溪街道家庭农场收敛曲线



(c) 苏州科技大学周边街道收敛曲线



(d) 局部战场侦察收敛曲线

图6 收敛曲线仿真

如图 6 所示, 在动态任务分配问题的研究中, AD-GNN 算法在复杂动态任务环境下展现出显著优势, 其在任务完成时间、收敛速度以及动态任务覆盖率等方面均优于纯 GNN、纯 ACO 与随机分配方法. 尽管该算法在超高动态性或高延迟场景中存在局限, 其整体性能仍然验证了自适应图神经网络与仿生机制协同策略的有效性和鲁棒性.

为验证所提出 AD-GNN 模型在复杂环境下进行动态任务分配的性能, 将其与传统的图神经网络、仿生算法、标准 GNN、深度神经网络、卷积神经网络

络、递归神经网络和混合算法进行比较, 仿真结果如图7所示。

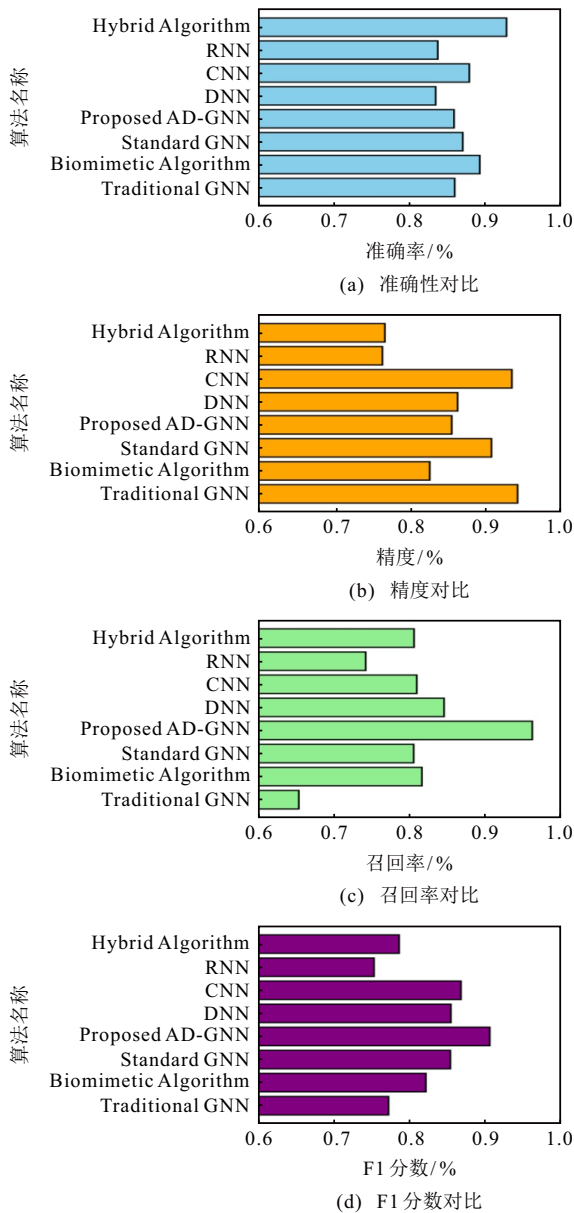


图7 多智能体作业中的任务分配算法比较性能分析

如图7所示, 通过视觉对比, 既突出了所提出AD-GNN在定量上的优越性, 还进一步凸显了其定性性能特征, 如适应性、可靠性和整体操作效能. 具体仿真结果数据如表3所示。

表3 不同算法比较性能分析

算法	准确度	精确度	召回率	F1分数
传统GNN	0.85	0.86	0.84	0.85
仿生算法	0.82	0.80	0.79	0.79
标准GNN	0.81	0.79	0.78	0.78
改进AD-GNN	0.97	0.97	0.97	0.97
DNN	0.78	0.75	0.76	0.75
CNN	0.80	0.81	0.79	0.80
RNN	0.77	0.76	0.74	0.75
混合算法	0.83	0.84	0.82	0.83

由表3可见, 所提出AD-GNN在准确度、精确度、召回率和F1分数方面均显著超越了其他算法. 这些结果表明, AD-GNN在复杂场景中的动态任务分配方面表现出色, 展示了其在处理复杂任务需求方面的卓越表现. 仿真结果验证了所提出模型的有效性。

4 结论

本文探讨了在复杂环境中异构智能体动态任务分配, 提出了仿生机制下自适应深度图神经网络模型, 基于真实世界的GIS数据模拟了实际不同任务场景优化任务分配的决策过程. 图注意力机制通过对受环境变化影响的节点和边进行动态重加权, 实现了决策焦点的精准调整和快速重规划. 仿生算法的集成机制使得系统能够响应环境条件和操作需求的变化进行适应和进化, 模拟自然过程的高效性. 具备在动态且不可预测的复杂环境中高效管理和分配任务的能力。

尽管所提出AD-GNN框架在异构多智能体的动态任务分配中表现出显著优势, 但是为推进实际应用, 未来研究将聚焦于轻量化模型设计、高效训练算法开发、增强系统容错能力, 并通过扩展多样化场景数据库和跨领域合作, 提升模型的可扩展性、适应性和部署可行性。

参考文献 (References)

- [1] Han Z M, Guo K X, Xie L H, et al. Integrated relative localization and leader-follower formation control[J]. *IEEE Transactions on Automatic Control*, 2019, 64(1): 20-34.
- [2] Choudhury S, Gupta J K, Kochenderfer M J, et al. Dynamic multi-robot task allocation under uncertainty and temporal constraints[J]. *Autonomous Robots*, 2022, 46(1): 231-247.
- [3] Chen G D, Yao D Y, Li H Y, et al. Saturated threshold event-triggered control for multiagent systems under sensor attacks and its application to UAVs[J]. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2022, 69(2): 884-895.
- [4] Chen P P, Luo L L, Guo D K, et al. Secure task offloading for rural area surveillance based on UAV-UGV collaborations[J]. *IEEE Transactions on Vehicular Technology*, 2024, 73(1): 923-937.
- [5] 纪苗苗, 吴志彬. 考虑工人路径的多智能体强化学习空间众包任务分配方法[J]. *控制与决策*, 2024, 39(1): 319-326.
(Ji M M, Wu Z B. A multi-agent reinforcement learning algorithm for spatial crowdsourcing task assignments considering workers' path[J]. *Control and Decision*, 2024, 39(1): 319-326.)
- [6] Zhang Z, Chen C, Wang L D, et al. A two-phase planner for messenger routing problem in UAV-UGV coordination systems[J]. *IEEE Transactions on*

- Automation Science and Engineering*, 2025, 22: 16948-16963.
- [7] Chen H, Wang X B, Yang Z X. Semi-supervised self-correcting graph neural network for intelligent fault diagnosis of rotating machinery[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3536611.
- [8] Zhao L Z, Zhang X C, Fu X W, et al. Efficient distributed 4D spatiotemporal path planning for multi-UAV systems in dynamic environments[J]. *IEEE Transactions on Vehicular Technology*, 2025, PP(99): 1-16.
- [9] 张祥银, 夏爽, 张天. 基于自适应遗传学习粒子群算法的多无人机协同任务分配[J]. *控制与决策*, 2023, 38(11): 3103-3111.
(Zhang X Y, Xia S, Zhang T. Adaptive genetic learning particle swarm optimization based cooperative task allocation for multi-UAVs[J]. *Control and Decision*, 2023, 38(11): 3103-3111.)
- [10] 高程, 都延丽, 步雨浓, 等. 基于顺序扩展一致性包算法的多无人机分布式任务分配[J]. *控制与决策*, 2023, 38(11): 3242-3250.
(Gao C, Du Y L, Bu Y N, et al. Distributed task allocation of multiple UAVs based on sequential extended consensus based bundle algorithm[J]. *Control and Decision*, 2023, 38(11): 3242-3250.)
- [11] Sawalmeh A H, Othman N S, Shakhathreh H, et al. Wireless coverage for mobile users in dynamic environments using UAV[J]. *IEEE Access*, 2019, 7: 126376-126390.
- [12] Bai X S, Jiang H Y, Li C, et al. Efficient hybrid multi-population genetic algorithm for multi-UAV task assignment in consumer electronics applications[J]. *IEEE Transactions on Consumer Electronics*, 2025, 71(2): 2395-2406.
- [13] Guo J C, Wan Y T, Ma A L, et al. A global-local collaborative and decomposition-based multiobjective evolutionary optimization method for UAV 3-D path planning[J]. *IEEE Internet of Things Journal*, 2025, 12(18): 38338-38351.
- [14] Jiang F B, Wang K Z, Dong L, et al. AI driven heterogeneous MEC system with UAV assistance for dynamic environment: Challenges and solutions[J]. *IEEE Network*, 2020, 35(1): 400-408.
- [15] Zammit C, van Kampen E J. Real-time 3D UAV path planning in dynamic environments with uncertainty[J]. *Unmanned Systems*, 2023, 11(3): 203-219.
- [16] Wan K F, Gao X G, Hu Z J, et al. Robust motion control for UAV in dynamic uncertain environments using deep reinforcement learning[J]. *Remote Sensing*, 2020, 12(4): 640.
- [17] Jang G, Lee K. Joint optimization of path planning and cooperative strategy for UAV-UGV delivery[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2025, 26(11): 20176-20186.
- [18] 李海峰, 杨宏安, 盛梓茂, 等. 基于 MAPPO 的多无人机协同分布式动态任务分配[J]. *控制与决策*, 2025, 40(5): 1429-1437.
(Li H F, Yang H A, Sheng Z M, et al. Multi-UAV collaborative distributed dynamic task allocation based on MAPPO[J]. *Control and Decision*, 2025, 40(5): 1429-1437.)
- [19] de Petrillo M, Beard J, Gu Y, et al. Search planning of a UAV/UGV team with localization uncertainty in a subterranean environment[J]. *IEEE Aerospace and Electronic Systems Magazine*, 2021, 36(6): 6-16.
- [20] Almayyahi A, Wang W J, Hussein A A, et al. Motion control design for unmanned ground vehicle in dynamic environment using intelligent controller[J]. *International Journal of Intelligent Computing and Cybernetics*, 2017, 10(4): 530-548.
- [21] 黄亭飞, 程光权, 黄魁华, 等. 基于 DQN 的多类型拦截装备复合式反无人机任务分配方法[J]. *控制与决策*, 2022, 37(1): 142-150.
(Huang T F, Cheng G Q, Huang K H, et al. Task assignment method of compound anti-drone based on DQN for multi type interception equipment[J]. *Control and Decision*, 2022, 37(1): 142-150.)
- [22] Tagarakis A C, Filippou E, Kalaitzidis D, et al. Proposing UGV and UAV systems for 3D mapping of orchard environments[J]. *Sensors*, 2022, 22(4): 1571.
- [23] Oubbati O S, Alotaibi J, Alromithy F, et al. A UAV-UGV cooperative system: Patrolling and energy management for urban monitoring[J]. *IEEE Transactions on Vehicular Technology*, 2025, 74(9): 13521-13536.
- [24] Wang C, Wang J Q, Ma Z W, et al. Integrated learning-based framework for autonomous quadrotor UAV landing on a collaborative moving UGV[J]. *IEEE Transactions on Vehicular Technology*, 2024, 73(11): 16092-16107.
- [25] Arbanas B, Ivanovic A, Car M, et al. Decentralized planning and control for UAV-UGV cooperative teams[J]. *Autonomous Robots*, 2018, 42(8): 1601-1618.
- [26] Thelasingha N, Julius A A, Humann J, et al. Iterative planning for multi-agent systems: An application in energy-aware UAV-UGV cooperative task site assignments[J]. *IEEE Transactions on Automation Science and Engineering*, 2024, 22: 3685-3703.
- [27] Liang H J, Yang S F, Li T S, et al. Distributed adaptive cooperative control for human-in-the-loop heterogeneous UAV-UGV systems with prescribed performance[J]. *IEEE Transactions on Intelligent Vehicles*, 2024, 9(11): 6912-6925.

作者简介

马梓元 (1992-), 男, 博士, 主要研究方向为多智能体任务规划与飞行控制技术、无人机仿生集群自主控制, E-mail: mazyuan@nuaa.edu.cn;

冯鹏宇 (2000-), 男, 硕士生, 主要研究方向为先进飞行器控制, E-mail: pyf333@nuaa.edu.cn;

龚华军 (1964-), 男, 教授, 博士, 博士生导师, 主要研究方向为编队控制与多智能体任务决策、舰载机着舰引导与控制, E-mail: ghj301@nuaa.edu.cn;

王新华 (1977-), 男, 副教授, 博士, 主要研究方向为先进飞行器控制、无人机路径规划, E-mail: xhwang@nuaa.edu.cn.