动态环境下基于时空高斯过程预测的多智能体覆盖控制

石 磊†，吕建鹏，麻壮壮

(河南大学 人工智能学院，郑州 450046)

摘 要: 针对多智能体覆盖控制中环境状态动态变化、先验信息不足导致系统难以及时跟踪重要覆盖区域的问题, 提出一种基于时空高斯过程预测的多智能体覆盖控制方法, 以提高动态场景中的前瞻响应能力与协同覆盖效率. 传统覆盖控制方法依赖当前观测或静态环境假设, 难以反映环境热点的时空演化, 且仅依据实时局部信息的协同决策易在多热点场景下出现重复覆盖与分工失衡. 为此, 首先利用多智能体带噪局部观测建立环境敏感度场的在线时空高斯过程回归模型, 获得未来短时域内的预测均值及不确定性估计; 然后, 构造融合预测均值与不确定性的区域重要度函数, 据此设计基于梯度的覆盖控制策略, 引导智能体向潜在高价值区域前瞻部署; 最后, 结合预测加权的区域划分与任务分配机制, 实现多热点场景下的动态分工与协同覆盖. 仿真结果表明, 所提出方法在重点覆盖区域发生结构突变时能够快速优化智能体分工, 有效提升动态场景下的覆盖性能; 半实物平台实验进一步验证了所提出方法的可行性.

关键词: 多智能体系统；覆盖控制；动态环境；时空高斯过程；任务分配；环境状态预测

中图分类号: TP273 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2026.0399

引用格式: 石磊, 吕建鹏, 麻壮壮. 动态环境下基于时空高斯过程预测的多智能体覆盖控制 [J]. 控制与决策.

Multi-agent coverage control in dynamic environments based on spatiotemporal gaussian process prediction

SHI Lei†，*LV Jian-peng*，*MA Zhuang-zhuang*

(School of Artificial Intelligence，Henan University，Zhengzhou 450046，China)

Abstract: Dynamically changing environmental states and insufficient prior information in multi-agent coverage control make it difficult for the system to track important coverage regions in a timely manner. To address this issue, this paper proposes a multi-agent coverage control method based on spatiotemporal Gaussian process prediction to improve the anticipatory response capability and cooperative coverage efficiency of the system in dynamic environments. Traditional coverage control methods rely on current observations or static environmental assumptions and thus fail to capture the spatiotemporal evolution of environmental hotspots in time, while cooperative decisions based solely on real-time local information tend to cause repeated coverage and unbalanced division of labor in multi-hotspot scenarios. To this end, an online spatiotemporal Gaussian process regression model of the environmental sensitivity field is first established using noisy local observations collected by multiple agents to obtain the predicted mean and uncertainty estimates over a short future horizon. Then, a regional importance function integrating the predicted mean and uncertainty is constructed, and a gradient-based coverage control strategy is designed accordingly to guide the agents to proactively deploy toward potentially high-value regions. Finally, a prediction-weighted region partitioning and task allocation mechanism is developed to achieve dynamic division of labor and cooperative coverage in multi-hotspot scenarios. Simulation results demonstrate that the proposed method can rapidly optimize the task allocation among agents when structural changes occur in key coverage regions, thereby effectively improving the coverage performance of the multi-agent system in dynamic environments. Semi-physical platform experiments further verify the feasibility of the proposed method in real-world scenarios.

Keywords: multi-agent systems；coverage control；dynamic environments；spatiotemporal Gaussian process；task allocation；environmental state prediction

收稿日期: 2026-05-01；**录用日期:** 2026-09-23.

基金项目: 国家自然科学基金项目 (62673181)；河南省高等学校重点科研项目 (27BQ413001).

责任编委: 张海涛.

†通信作者. E-mail: shilei910918@126.com.

0 引 言

近年来, 随着无人系统、移动机器人网络和智能感知网络的快速发展, 多智能体协同控制因能够通过多个具备感知、通信与决策能力的智能体实现局部信息交互与分布式协作, 逐渐成为协同控制领域的重要研究方向[1-2]. 覆盖控制作为多智能体协同控制中的重要研究方向, 其核心目标是通过合理设计智能体的运动策略, 使其实现最优空间部署, 从而完成对任务区域的高效感知与监测. 相较于单智能体系统, 多智能体协同覆盖控制具有分布式实现、良好可扩展性和鲁棒性强等优势, 因此在环境监测、灾害搜救、目标搜索、农业巡检以及无人系统协同作业等领域具有广泛的应用前景[3-6]. 随着任务需求日益复杂, 实际环境往往呈现出动态变化、热点迁移和局部突发等特征, 对多智能体系统的覆盖效率与实时响应能力提出了更高要求.

在多智能体覆盖控制问题中, 覆盖性能在很大程度上受到任务区域内环境信息分布的影响. 由于不同空间位置对整体覆盖任务目标的重要程度通常并不一致, 智能体需要依据覆盖目标的空间分布特征调整其部署位置与协同策略, 从而提高覆盖效率与感知质量. 为此, 研究者通常引入环境敏感度函数(密度函数), 对环境状态在空间上的分布特性进行刻画, 并以此作为覆盖控制策略设计的重要依据[7].

在环境敏感度函数已知且保持静态的条件下, 覆盖控制问题已受到许多研究者的关注. 例如, Cortés 等[7] 提出了基于质心 Voronoi 分区的 Lloyd 算法, 通过密度函数构造覆盖性能函数, 并由此导出基于梯度下降的控制策略, 从而实现对任务区域的最优监视. Pimenta 等[8] 研究了异构机器人网络中的传感覆盖问题, 将经典位置优化覆盖框架扩展到异构机器人网络. Breitenmoser 等[9] 将 Voronoi 覆盖方法扩展到非凸环境, 并给出了可收敛到局部最优的算法. 然而, 这些方法以环境分布信息固定且已知为前提, 而受外部扰动、任务演化等因素影响, 实际环境敏感度分布通常具有明显的时变性与未知性, 例如污染源在风场作用下迁移扩散、高风险区域随外界条件持续演化等. 对于此类任务环境, 依赖固定敏感度地图的静态覆盖控制方法难以维持持续有效的覆盖性能.

围绕动态环境下的覆盖需求, 研究者针对移动目标或动态热点场景开展了大量研究. 现有工作主要从覆盖控制律设计与协同机制构建等角度展开, 其中 Pimenta 等[10] 提出了一种同时覆盖与跟踪方法, 将入侵者或移动目标的跟踪问题建模为时变密度函数下的覆盖优化问题, 从而在统一框架内实现任务分配、区域覆盖与目标跟踪的耦合. 在此基础上, Lee 等[11] 进一步研究了基于时变密度函数的多机器人控制问题, 将动态密度函数视为对机器人群体空间分布的粗略期望以引导机器人随密度函数演化而重新部署. 此外, 也有研究进一步关注覆盖过程中的瞬态性能、覆盖效率以及安全约束等问题. Zhang 等[12] 针对未知密度函数下的多智能体覆盖问题, 指出已有方法通常更关注目标位置处的覆盖收益, 而忽略智能体移动过程中的瞬态损失, 因此提出了考虑瞬态行为的多智能体覆盖控制算法, 以提升智能体在边学习边覆盖过程中的动态响应效率. Liu 等[13] 则将安全覆盖控制扩展到三维空间, 结合控制障碍函数实现了无碰撞的动态覆盖. 总体来看, 上述方法在静态或弱时变环境中效果较好, 但当环境敏感度分布快速变化或热点迁移时, 因缺乏对环境演化趋势的前瞻刻画, 难以及时引导智能体有效重部署.

为提升系统对动态环境的适应能力, 研究者开始从环境变化建模与趋势预测的角度改进覆盖控制策略. 相比仅依据当前观测进行调整的方法, 预测驱动的覆盖控制能够提供环境未来演化趋势的前瞻信息, 从而引导智能体提前重部署, 并提升动态环境下的持续覆盖性能. 现有相关研究主要包括两类: 一类基于物理机理模型, 利用对流–扩散方程或其他演化规律描述环境场的时空变化, 并结合滤波或估计方法进行状态更新[14]; 另一类采用贝叶斯方法、时序模型或数据驱动策略, 对时变环境中的覆盖需求进行预测[15]. 然而, 前者通常依赖较强的先验动力学假设和模型参数设置, 后者则往往难以同时充分刻画环境状态在时间与空间上的相关性, 且对预测不确定性的利用仍不充分. 近年来, 数据驱动的时空场预测方法发展迅速. 刘金培等[16] 将多尺度三维卷积与注意力机制相结合实现了空气质量指数的时空预测, 验证了时空耦合建模对多步预测精度的作用. 这类方法进一步印证了前瞻信息对动态任务的价值, 不过它们以集中式离线训练的确定性预测为主, 没有给出可供覆盖控制律直接调用的预测方差, 因而难以直接支撑动态环境下的在线覆盖决策.

针对此问题, 时空高斯过程作为一种兼具非参数建模能力与不确定性量化能力的概率模型, 正被广泛用于时间变化空间过程的在线估计与覆盖耦合问题. Mantovani 等[17] 通过在线时变空间场估计和时间衰减机制实现探索与持续覆盖之间的动态权衡. Wei 等[18] 则利用多任务高斯过程学习未知感知需求函数, 并将其嵌入联邦式多任务覆盖算法中. Nanavati 等[19] 融合分布式贝叶斯滤波、覆盖控制和信息论采样机制, 实现多机器人对未知化学释放源的协同估

计与搜索. 上述研究表明, 概率建模能够有效刻画未知空间场的相关性与不确定性, 但现有方法多侧重于当前状态估计与反应式覆盖调整, 对未来敏感度分布的前瞻预测利用仍不充分.

如何在有限智能体资源条件下实现不同目标区域的高效协同覆盖, 仍是多智能体系统面临的重要难题. 相较于单一目标覆盖任务, 多目标覆盖通常具有目标数量多、空间分布不均、优先级差异明显和任务需求动态变化等特点. 若仅依赖覆盖控制律引导智能体向局部高价值区域移动, 容易导致智能体聚集、重复覆盖以及关键区域响应不足, 从而降低整体覆盖效率. 因此, 任务分配、优先级规划与协同搜索等机制成为提升多智能体覆盖性能的重要手段. 为此, Liu 等[20] 针对异构无人机系统, 考虑灾害侦察、物资投送和效果评估等任务之间的时序依赖关系, 建立了面向时序任务链的异构无人机任务分配模型, 并通过动态联盟形成机制提升复杂灾害环境下的连续决策能力. Cao 等[21] 通过多无人机任务分配与路径规划的联合优化方法, 解决了应急救援场景中任务需求不确定的问题. 同时, Cao 等[22] 还提出了基于区域动态感知的多无人机自适应协同覆盖搜索方法, 使无人机能够根据局部感知信息实时调整搜索与覆盖策略. 围绕集群覆盖搜索与任务分配, 王宁等[23] 提出带宏观引导收益的分层池化方法, 通过宏观引导与微观航迹规划的结合提升无人机集群区域覆盖搜索的效率. 此类方法为多智能体协同覆盖与任务分配提供了有效手段, 但其任务集合与任务收益大多依据当前时刻的感知结果或预设优先级确定, 尚未把环境敏感度的未来演化趋势纳入任务生成与分配环节, 因而在热点持续迁移的动态环境中前瞻调度能力有限.

尽管时空高斯过程在动态环境建模中具有良好适用性, 但如何将其敏感度估计与实时多智能体覆盖控制有效融合[24], 以及如何统一分析移动智能体在时空变化环境中的探索、利用与控制性能[25], 仍是当前研究的重要问题. 与此同时, 现有分配方法尚未与基于敏感度预测的动态覆盖控制机制形成紧密耦合.

基于上述研究背景, 本文聚焦动态环境下的多智能体覆盖控制问题, 提出一种基于时空高斯过程预测与任务分配协同的覆盖控制方法. 该方法在线建模并预测动态环境敏感度场, 将预测结果同时引入覆盖控制与任务分配机制, 以提高系统的协同覆盖效率. 主要贡献包括以下三个方面.

(1) 提出面向动态环境敏感度场的在线时空高斯过程建模与预测方法, 并在此基础上构建融合预测信息的多智能体覆盖控制策略.

(2) 设计结合预测加权区域划分的任务分配机制, 以提高多智能体系统在动态环境中的协同覆盖效率.

(3) 通过数值仿真与半实物平台实验验证所提方法在动态热点场景下的有效性与实际部署可行性.

1　问题表述

本节给出多智能体协同覆盖任务的基本假设与数学模型. 考虑未知且时变的环境敏感度场, 多智能体系统需基于有限观测对高敏感区域实现持续高效覆盖, 并在热点迁移、分裂或合并时保持良好的动态响应. 图 1 给出了覆盖任务场景示意图, 其中高敏感度区域被抽象为需要优先覆盖的环境热点.

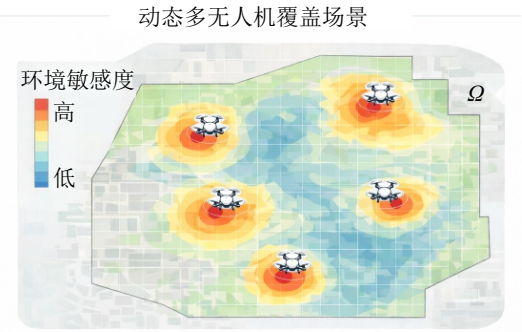

图 1　动态环境下覆盖任务场景示意图

1.1　多智能体动力学模型

考虑在有界任务区域$\Omega \subset \mathbb{R}^2$内部署$N$个智能体执行覆盖与环境感知任务. 假设智能体$i \in \{1, \ldots, N\}$在时刻$t$的位置和速度分别为$\mathbf{p}_i(t) \in \mathbb{R}^2$和$\mathbf{v}_i(t) \in \mathbb{R}^2$. 为描述智能体的基本运动特性, 本文将其动力学建模为如下二阶积分器形式:

$$\begin{cases} \dot{\mathbf{p}}_i(t) = \mathbf{v}_i(t), \\ \dot{\mathbf{v}}_i(t) = \mathbf{u}_i(t), \end{cases} \tag{1}$$

其中, $\mathbf{u}_i(t) \in \mathbb{R}^2$表示智能体的加速度控制输入.

由于本文主要关注动态环境下智能体的上层覆盖控制与协同决策机制, 而非底层执行器控制问题, 故采用两层控制结构进行设计, 其中, 上层控制器根据环境敏感度预测结果及覆盖任务需求生成智能体的期望速度$\mathbf{v}_i^{\mathrm{des}}(t)$; 下层速度跟踪控制器则将该期望速度进一步转换为可执行的加速度输入. 采用如下速度跟踪控制律:

$$\mathbf{u}_i(t) = k_v(\mathbf{v}_i^{\mathrm{des}}(t) - \mathbf{v}_i(t)), \tag{2}$$

其中, $k_v > 0$为速度跟踪增益. 后续所设计的覆盖控制律均为智能体的期望速度输入, 实际加速度输入由式 (2) 给出. 仿真中, 式 (1) 以步长Δt数值离散化, 并假设底层速度跟踪响应足够快.

1.2 动态环境敏感度场与观测模型

在上述多智能体动力学模型基础上, 进一步考虑任务区域内环境状态演化. 为表征任务区域中不同位置对覆盖任务的重要程度, 定义如下环境敏感度函数:

$$\phi(\mathbf{x},t):\Omega\times\mathbb{R}_{+}\to\mathbb{R}_{\geqslant 0}, \tag{3}$$

其中, $\phi(\mathbf{x},t)$表示位置$\mathbf{x}\in\Omega$在时刻t的环境敏感度, 其值越大, 该位置对当前覆盖任务越重要. 在污染监测、灾害搜救与目标搜索等任务中, $\phi(\mathbf{x},t)$可分别表示污染风险水平、搜救需求强度或目标出现概率, 这些量通常随时间变化, 故采用时空函数刻画.

在未知环境中, 敏感度场无法被完整获取, 智能体仅能获得当前位置处的局部带噪观测, 即

$$y_i(t)=\phi(\mathbf{p}_i(t),t)+\varepsilon_i(t), \tag{4}$$

其中, $y_i(t)$为智能体i在位置$\mathbf{p}_i(t)$处的观测值, $\varepsilon_i(t)\sim\mathcal{N}(0,\sigma_n^2)$为方差为$\sigma_n^2$的加性高斯白噪声, 对不同智能体及不同时刻独立同分布, 且与智能体位置及真实敏感度场相互独立, 该假设与后续时空高斯过程回归的高斯似然相容.

1.3 覆盖模型与覆盖性能指标

令$\mathbf{p}(t)=[\mathbf{p}_1^{\top}(t),\dots,\mathbf{p}_N^{\top}(t)]^{\top}$表示$t$时刻全体智能体的位置向量, 并定义覆盖函数$\mathcal{C}(\mathbf{x},\mathbf{p}(t))\in[0,1]$刻画位置$\mathbf{x}\in\Omega$在时刻$t$被智能体集合感知的程度. 假设每个智能体配备以自身位置为圆心、感知半径为r_s的圆形传感器, 定义智能体i对位置$\mathbf{x}$的单体覆盖贡献为

$$c_i(\mathbf{x},t)=\frac{1}{1+\exp(\kappa(\|\mathbf{x}-\mathbf{p}_i(t)\|-r_s))}, \tag{5}$$

其中, $\kappa>0$为边界平滑参数, $\kappa\to\infty$时该函数趋近于硬阈值圆盘感知模型. $c_i(\mathbf{x},t)\in(0,1)$关于$\mathbf{x}$和$\mathbf{p}_i(t)$连续可导, 且随$\|\mathbf{x}-\mathbf{p}_i(t)\|$的增大而单调减小.

为避免多个智能体对同一区域的重复覆盖被简单累加, 系统总体覆盖函数定义为

$$\mathcal{C}(\mathbf{x},\mathbf{p}(t))=1-\prod_{i=1}^{N}(1-c_i(\mathbf{x},t)). \tag{6}$$

由此, $\mathcal{C}(\mathbf{x},\mathbf{p}(t))\in[0,1]$关于智能体位置连续可导, 未被任何智能体感知的位置取值接近0, 被充分感知的位置接近1, 且总体覆盖水平不会因重复覆盖而被无界放大, 符合重复观测收益递减的特点.

覆盖函数尚未反映各位置在任务中的重要性差异, 为此进一步引入环境敏感度, 定义环境加权覆盖效能函数

$$\eta(t)=\int_{\Omega}\phi(\mathbf{x},t)\,\mathcal{C}(\mathbf{x},\mathbf{p}(t))\,d\mathbf{x}. \tag{7}$$

其中, $\eta(t)$表征t时刻系统对敏感度场的加权覆盖水平, 其值越大说明对高敏感区域的覆盖越充分. 由$\phi(\mathbf{x},t)\geqslant 0$且 $\mathcal{C}(\mathbf{x},\mathbf{p}(t))\in[0,1]$可 知 $0\leqslant\eta(t)\leqslant\int_{\Omega}\phi(\mathbf{x},t)\,d\mathbf{x}$, 即$\eta(t)$始终有界. 需要说明的是, 式(7)中的$\phi(\mathbf{x},t)$为真实环境状态, 仅用于离线性能评估与方法对比, 在线决策时智能体只能基于历史观测对其进行估计与预测.

1.4 任务目标

考虑离散决策时刻$t_k=k\Delta t$, $k=0,1,2,\dots$, $\Delta t>0$为决策步长. 记时刻t_k的可用信息集为$\mathcal{I}_{\|}=\{(\mathbf{p}_i(t_\ell),y_i(t_\ell))\mid i=1,\dots,N,\ \ell=0,1,\dots,k\}$.

智能体在t_k的决策仅依赖当前及历史信息, 即上层期望速度与任务分配结果满足$\mathbf{v}_i^{\mathrm{des}}(t_k)=\pi_i(\mathcal{I}_{\|})$, $\mathbf{a}(t_k)=\Pi(\mathcal{I}_{\|})$, 其中$\pi_i(\cdot)$为智能体$i$的在线覆盖控制策略, $\Pi(\cdot)$为任务分配机制, $\mathbf{a}(t_k)$为任务分配结果.

本文的目标是在动力学约束下设计敏感度场在线预测、覆盖控制与任务分配策略, 使系统获得尽可能高的长期覆盖效能, 即

$$\max_{\{\pi_i\},\Pi}\ \int_{\Omega}\phi(\mathbf{x},t_k)\,\mathcal{C}(\mathbf{x},\mathbf{p}(t_k))\,d\mathbf{x}. \tag{8}$$

为此, 本文通过在线估计与预测敏感度场引导智能体提前向潜在高价值区域部署, 并结合任务分配机制提升多热点场景下的协同覆盖能力.

2 方 法

本节提出一种“预测–分配–执行”的闭环方法框架. 首先利用滑动时间窗口构建时空高斯过程(ST-GP)模型, 对环境敏感度场进行短时前瞻预测; 其次据此构造可在线求解的覆盖目标并生成覆盖控制输入; 最后通过任务提取与分配机制引导多智能体协同分工, 以减少多热点场景下的重复覆盖.

2.1 方法流程框架

如图 2 所示, 本文提出了一种基于时空高斯过程预测的多智能体自适应覆盖控制框架, 用于应对环境敏感度随时间变化的动态覆盖任务. 其中: 箭头标注模块间传递的物理量, 区域重要度$w_{t_k}(\mathbf{x})$经右侧总线同时驱动任务提取与分配 (模块 4) 和预测驱动的覆盖控制 (模块 5), 两支输出融合后得到期望速度并由模块 6 执行, 从而构成感知、预测、分配与执行的闭环.

图 2 说明预测结果被同时贯通到覆盖控制与任务分配两个环节并由此形成闭环. 模块 1 为多智能体局部感知, 各智能体在当前位置按 1.2 节的观测模型 (4) 获取带噪观测. 模块 2 为时空高斯过程预测, 以最近若干时刻的观测构成滑动窗口数据集, 输出

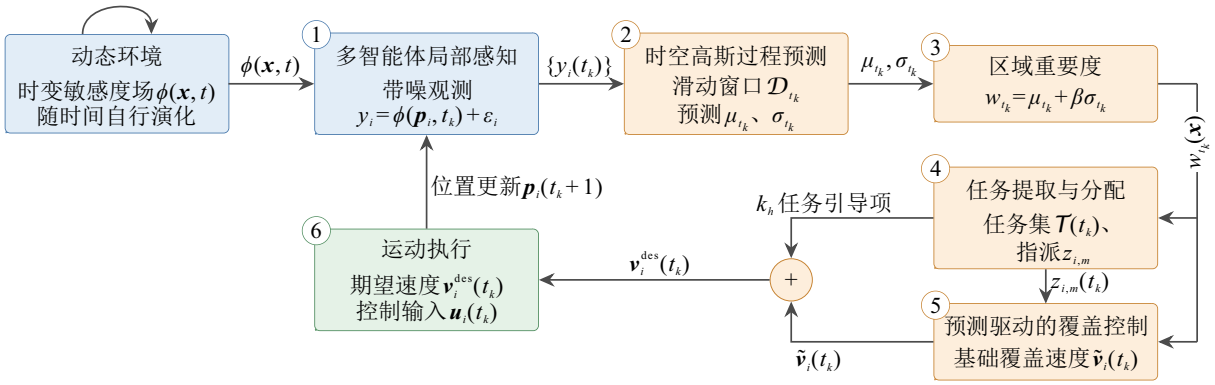

图 2　基于时空高斯过程预测的多智能体覆盖控制整体框架

敏感度场的预测均值与预测方差, 具体见 2.2 节. 模块 3 将预测均值与预测标准差合成区域重要度 $w_{t_k}(\mathbf{x})$, 它是连接预测环节与决策环节的唯一接口. 模块 4 和模块 5 均以$w_{t_k}(\mathbf{x})$为输入, 前者从中提取任务集并完成分配优化 (2.4 节), 后者据此构造覆盖目标并生成基础覆盖速度 (2.3 节). 两支输出经加权融合得到期望速度, 再由模块 6 按 1.1 节的速度跟踪律 (2) 执行. 智能体位置更新后在新位置重新采集观测并回到模块 1, 而环境敏感度场按自身规律随时间演化, 不受执行动作影响, 图中以动态环境模块上方的自环表示.

通过上述闭环的持续更新与滚动优化, 所提方法能够跟踪环境敏感度场的动态变化, 并在热点迁移、分裂与合并等场景下保持较高的覆盖性能. 此外, 可在控制输入执行前加入安全过滤环节, 以避免智能体之间及其与障碍物之间的潜在碰撞. 下面分别对环境敏感度场预测、覆盖控制策略设计以及任务提取与分配机制进行详细阐述.

2.2　时空高斯过程预测

为对动态环境中的敏感度场进行在线建模与短时预测, 本文采用时空高斯过程对环境敏感度函数进行概率建模. 令时空输入表示为$\boldsymbol{\xi}=[\mathbf{x}^\top,t]^\top$. 假设环境敏感度场满足如下时空高斯过程先验:

$$\phi(\mathbf{x},t)\sim\mathcal{GP}(0,\ k((\mathbf{x},t),(\mathbf{x}',t'))). \tag{9}$$

为同时刻画环境敏感度在空间和时间上的相关性, 本文采用可分离核函数

$$k((\mathbf{x},t),(\mathbf{x}',t'))=k_s(\mathbf{x},\mathbf{x}')\,k_t(t,t'), \tag{10}$$

其中, $k_s(\mathbf{x},\mathbf{x}')$和$k_t(t,t')$分别为空间核函数和时间核函数. 采用平方指数核形式, 即

$$\begin{aligned}k_s(\mathbf{x},\mathbf{x}')&=\sigma_s^2\exp\Big(-\frac{\|\mathbf{x}-\mathbf{x}'\|^2}{2\ell_s^2}\Big),\\ k_t(t,t')&=\exp\Big(-\frac{(t-t')^2}{2\ell_t^2}\Big),\end{aligned} \tag{11}$$

其中, σ_s^2为信号方差, $\ell_s>0$和$\ell_t>0$分别为空间和时间长度尺度.

在决策时刻t_k, 为兼顾在线更新效率与对近期环境变化的敏感性, 采用长度为W的滑动时间窗口维护观测数据集

$$\mathcal{D}_{t_k}=\{(\mathbf{p}_i(t_j),t_j,y_i(t_j))\mid t_k-W<t_j\leqslant t_k,\ \forall i\}. \tag{12}$$

记窗口内训练输入集合为$\mathcal{X}_{\|}=\{\boldsymbol{\xi}_n\}_{n=1}^{M_k}$, 对应观测向量为$\mathbf{y}_k=[y(\boldsymbol{\xi}_1),\dots,y(\boldsymbol{\xi}_{M_k})]^\top$, 其中$M_k$为窗口内样本总数.

由时空高斯过程先验及高斯噪声观测模型可知, 训练输出与测试输出满足联合高斯分布. 对任意测试输入$\boldsymbol{\xi}_*=[\mathbf{x}_*^\top,t_k+\tau]^\top$, 有

$$\begin{bmatrix}\mathbf{y}_k\\ \phi(\mathbf{x}_*,t_k+\tau)\end{bmatrix}\sim\mathcal{N}\Bigg(\mathbf{0},\ \begin{bmatrix}\mathbf{K}_k+\sigma_n^2\mathbf{I} & \mathbf{k}_*\\ \mathbf{k}_*^\top & k_{**}\end{bmatrix}\Bigg), \tag{13}$$

其中, $[\mathbf{K}_k]_{mn}=k(\boldsymbol{\xi}_m,\boldsymbol{\xi}_n)$为训练核矩阵, $[\mathbf{k}_*]_n=k(\boldsymbol{\xi}_n,\boldsymbol{\xi}_*)$为测试输入与训练输入之间的协方差向量, $k_{**}=k(\boldsymbol{\xi}_*,\boldsymbol{\xi}_*)$为测试输入的自协方差. 本文统一规定标量核函数采用小写k, 测试输入与训练输入之间的协方差向量采用粗体小写$\mathbf{k}_*$, 训练核矩阵采用粗体大写$\mathbf{K}_k$, 测试输入的自协方差采用标量k_{**}. 进一步利用条件高斯分布公式, 可得

$$\phi(\mathbf{x}_*,t_k+\tau)\mid\mathcal{D}_{t_k}\sim\mathcal{N}(\mu_{t_k}(\mathbf{x}_*,\tau),\ \sigma_{t_k}^2(\mathbf{x}_*,\tau)),$$

其中, 预测均值与预测方差分别为

$$\mu_{t_k}(\mathbf{x}_*,\tau)=\mathbf{k}_*^\top(\mathbf{K}_k+\sigma_n^2\mathbf{I})^{-1}\mathbf{y}_k, \tag{14}$$

$$\sigma_{t_k}^2(\mathbf{x}_*,\tau)=k_{**}-\mathbf{k}_*^\top(\mathbf{K}_k+\sigma_n^2\mathbf{I})^{-1}\mathbf{k}_*. \tag{15}$$

本文引入预测视野H表征前瞻决策考虑的最远预测时长, 考虑到视野过大将显著增加外推误差与不确定性, 后续主要采用短时预测结果指导覆盖控制与任务分配.

2.3　预测驱动的覆盖控制

在每个决策时刻t_k, 选取短时预测步长$\tau_0\in(0,H]$, 并基于时空高斯过程的预测结果构造区域重要度函数

$$w_{t_k}(\mathbf{x}) = \mu_{t_k}(\mathbf{x},\tau_0) + \beta\,\sigma_{t_k}(\mathbf{x},\tau_0), \tag{16}$$

其中, 预测标准差$\sigma_{t_k}(\mathbf{x},\tau_0) = \sqrt{\sigma^2_{t_k}(\mathbf{x},\tau_0)} \geqslant 0$, $\beta \geqslant 0$为不确定性权衡系数. 该函数同时考虑区域在未来时刻的预期敏感度与预测不确定性, 有助于在优先覆盖高价值区域和主动探索高不确定区域之间实现平衡.

命题 1 对任意固定的$\beta \geqslant 0$, 区域重要度函数$w_{t_k}(\mathbf{x})$关于预测均值$\mu_{t_k}(\mathbf{x},\tau_0)$和预测标准差$\sigma_{t_k}(\mathbf{x},\tau_0)$分别单调不减.

证明 由式 (16) 直接得$\partial w_{t_k}/\partial\mu_{t_k} = 1 > 0$, $\partial w_{t_k}/\partial\sigma_{t_k} = \beta \geqslant 0$, 故结论成立. □

命题 1 表明, 区域重要度函数对预测均值和预测不确定性的响应方向一致, 为后续在线代理覆盖目标函数的构造提供了依据.

基于预测的区域重要度函数, 定义智能体覆盖目标函数为

$$\hat{J}(t_k) = \int_{\Omega} w_{t_k}(\mathbf{x})\,\mathcal{C}(\mathbf{x},\mathbf{p}(t_k))\,d\mathbf{x}. \tag{17}$$

与式 (7) 不同, 式 (17) 采用在线预测得到的区域重要度函数, 可用于在线决策.

为提高系统对未来高价值区域的响应能力, 令上层覆盖控制器为智能体i生成期望速度指令

$$\tilde{\mathbf{v}}_i(t_k) = k_c\,\nabla_{\mathbf{p}_i}\hat{J}(t_k). \tag{18}$$

其中, $k_c > 0$为控制增益. 由链式法则可得

$$\nabla_{\mathbf{p}_i}\hat{J}(t_k) = \int_{\Omega} w_{t_k}(\mathbf{x})\,\nabla_{\mathbf{p}_i}\mathcal{C}(\mathbf{x},\mathbf{p}(t_k))\,d\mathbf{x}. \tag{19}$$

由式 (6) 与式 (5) 可得

$$\nabla_{\mathbf{p}_i}\mathcal{C}(\mathbf{x},\mathbf{p}(t_k)) = \Big(\prod_{j\neq i}(1-c_j(\mathbf{x},t_k))\Big)\,\nabla_{\mathbf{p}_i}c_i(\mathbf{x},t_k).$$

以及

$$\nabla_{\mathbf{p}_i}c_i(\mathbf{x},t_k) = \kappa\,c_i(\mathbf{x},t_k)(1-c_i(\mathbf{x},t_k))\times \frac{\mathbf{x}-\mathbf{p}_i(t_k)}{\|\mathbf{x}-\mathbf{p}_i(t_k)\|}, \tag{20}$$

当$\mathbf{x} \neq \mathbf{p}_i(t_k)$时, 上述梯度表达式成立. 集合$\{\mathbf{x} = \mathbf{p}_i(t_k)\}$在二维任务区域内为零测集, 因此不影响积分结果. 又由$0 \leqslant c_i \leqslant 1$可知$\|\nabla_{\mathbf{p}_i}c_i\| \leq \kappa/4$几乎处处成立. 由于$\Omega$有界且$w_{t_k}(\mathbf{x})$在$\Omega$上有界, 加权梯度由可积函数$\|w_{t_k}\|_\infty\kappa/4$控制, 故可对相应差商应用勒贝格控制收敛定理, 将关于$\mathbf{p}_i$的求导移入积分号. 因此, 覆盖控制律引导智能体沿代理覆盖目标函数的梯度方向移动, 优先靠近未来时刻重要度较高的区域, 所得期望速度再由底层速度跟踪控制器转换为加速度输入.

为严格区分采样时刻t_k与区间内的连续时间t, 对任意$t \in [t_k, t_{k+1})$定义冻结预测权重后的局部覆盖目标函数

$$\hat{J}_k(\mathbf{p}(t)) = \int_{\Omega} w_{t_k}(\mathbf{x})\,\mathcal{C}(\mathbf{x},\mathbf{p}(t))\,d\mathbf{x}.$$

在$t = t_k$时有$\hat{J}_k(\mathbf{p}(t_k)) = \hat{J}(t_k)$. 该记号说明权重函数在单个决策区间内保持不变, 而目标函数仍随智能体位置$\mathbf{p}(t)$连续变化. 结合前述两层控制结构并忽略底层速度跟踪误差, 可得到如下结论.

定理 1 设Ω为有界区域, $w_{t_k}(\mathbf{x})$在Ω上有界, 并在决策区间$[t_k, t_{k+1})$内保持不变. 若忽略底层速度跟踪误差, 且智能体在该区间内满足理想梯度流

$$\dot{\mathbf{p}}_i(t) = k_c\,\nabla_{\mathbf{p}_i}\hat{J}_k(\mathbf{p}(t)),\ k_c > 0, \tag{21}$$

则局部覆盖目标函数$\hat{J}_k(\mathbf{p}(t))$沿该系统轨迹单调不减.

证明 由上述有界性条件及前述求导换序结果, $\hat{J}_k$关于$\mathbf{p}$可微. 由于$w_{t_k}(\mathbf{x})$在区间内固定, $\hat{J}_k$关于时间的变化仅由$\mathbf{p}(t)$引起. 由链式法则并代入理想梯度流可得

$$\frac{d}{dt}\hat{J}_k(\mathbf{p}(t)) = \sum_{i=1}^{N}(\nabla_{\mathbf{p}_i}\hat{J}_k)^{\top}\dot{\mathbf{p}}_i = k_c\sum_{i=1}^{N}\|\nabla_{\mathbf{p}_i}\hat{J}_k\|^2 \geqslant 0. \tag{22}$$

因此, $\hat{J}_k(\mathbf{p}(t))$在每个固定权重的决策区间内单调不减. 该结论不要求权重更新前后的目标函数数值保持单调, 而是刻画每个区间内理想上层闭环的性能改进性质. 证明成立. □

定理 1 表明, 在忽略预测误差、离散执行误差与底层跟踪误差的理想条件下, 所设计控制律在每个决策区间内具有明确的性能改进趋势, 为真实系统中的覆盖控制提供了依据.

2.4 任务提取与分配

为避免多热点场景下智能体在局部区域的聚集现象以及覆盖冗余, 本文在每个决策时刻基于区域重要度函数$w_{t_k}(\mathbf{x})$提取高敏感任务区域, 并进行任务分配. 具体地, 从$w_{t_k}(\mathbf{x})$中识别出$M(t_k)$个高敏感子区域, 构成任务集合

$$\mathcal{T}(t_k) = \{\mathcal{R}_{\Updownarrow}(t_k)\}_{m=1}^{M(t_k)}. \tag{23}$$

对于每个任务区域$\mathcal{R}_{\Updownarrow}(t_k)$, 采用其代表点$\mathbf{h}_m(t_k)$和任务价值$q_m(t_k)$进行表征. 其中, $\mathbf{h}_m(t_k)$可取该区域的峰值点或加权质心, 任务价值定义为

$$q_m(t_k) = \int_{\mathcal{R}_{\Updownarrow}(t_k)} w_{t_k}(\mathbf{x})\,d\mathbf{x}. \tag{24}$$

令$z_{i,m}(t_k) \in \{0,1\}$表示任务区域$\mathcal{R}_{\Updownarrow}(t_k)$是否分配给智能体$i$. 为统一处理任务数与智能体数不匹配的情形, 定义$K(t_k) = \min\{M(t_k), N\}$, 将任务分配过程表述为如下优化问题:

$$\begin{aligned}\min_{\{z_{i,m}\}} \ & \sum_{i=1}^{N}\sum_{m=1}^{M(t_k)} z_{i,m}(t_k)\,\rho_{i,m}(t_k)\\ \text{s.t.} \ & \sum_{m=1}^{M(t_k)} z_{i,m}(t_k)\leqslant 1,\ \forall i,\\ & \sum_{i=1}^{N} z_{i,m}(t_k)\leqslant 1,\ \forall m,\\ & \sum_{i=1}^{N}\sum_{m=1}^{M(t_k)} z_{i,m}(t_k)=K(t_k),\end{aligned}\tag{25}$$

其中, $\rho_{i,m}(t_k)$表示智能体i执行任务区域$\mathcal{R}_{\Updownarrow}(t_k)$的分配代价, 用于综合权衡机动成本与任务收益. 对机动成本项和任务价值项分别进行无量纲化处理, 将分配代价定义为

$$\rho_{i,m}(t_k)=\frac{\|\mathbf{p}_i(t_k)-\mathbf{h}_m(t_k)\|^2}{d_\Omega^2}-\lambda\frac{q_m(t_k)}{q_{\max}(t_k)},\tag{26}$$

其中, $d_\Omega=\operatorname{diam}(\Omega)$为任务区域直径, $q_{\max}(t_k)=\max\limits_m q_m(t_k)$为当前时刻最大任务价值, $\lambda>0$为权衡系数. 上述代价函数表明, 智能体更倾向于被分配到距离自身较近且任务价值较高的区域.

当$M(t_k)<N$时, 未分配任务的智能体继续执行预测驱动的覆盖任务; 当$M(t_k)>N$时, 仅选择其中N个任务参与分配, 其余任务留待后续滚动决策处理.

为使任务分配结果能够直接作用于智能体的运动决策, 在得到基础覆盖速度$\tilde{\mathbf{v}}_i(t_k)$后, 进一步引入任务引导项, 得到智能体$i$的最终期望速度指令

$$\begin{aligned}\mathbf{v}_i^{\mathrm{des}}(t_k)=\tilde{\mathbf{v}}_i(t_k)+k_h\sum_{m=1}^{M(t_k)} z_{i,m}(t_k)\\ \times\left(\mathbf{h}_m(t_k)-\mathbf{p}_i(t_k)\right),\end{aligned}\tag{27}$$

其中, $k_h>0$为任务引导增益.

由于$\sum\limits_{m=1}^{M(t_k)} z_{i,m}(t_k)\leqslant 1$, 每个智能体在决策时刻至多受一个任务区域引导. 式 (27) 同时融合了预测驱动的全局覆盖优化信息与任务分配驱动的局部协同引导信息, 前者使智能体朝向未来高重要度区域移动, 后者通过分工抑制多智能体在同一热点区域的重复聚集, 从而兼顾整体覆盖效能与协同效率.

2.5　算法流程

综上, 所提方法在每个决策时刻t_k的完整执行流程如下.

算法 1　基于时空高斯过程预测与任务分配的多智能体自适应覆盖控制算法.

输入: 任务区域Ω, 智能体数量N, 总决策步数K, 时间步长Δt, 初始状态$\{\mathbf{p}_i(t_0),\mathbf{v}_i(t_0)\}_{i=1}^{N}$, 滑动窗口长度$W$, 短时预测步长$\tau_0$, 时空高斯过程核函数$k(\cdot,\cdot)$, 观测噪声方差$\sigma_n^2$, 不确定性权衡系数$\beta$, 控制增益$k_c,k_v$, 任务引导增益$k_h$, 任务分配权衡参数$\lambda$.

输出: 智能体轨迹$\{\mathbf{p}_i(t_k),\mathbf{v}_i(t_k)\}_{k=0}^{K}$.

step 1: 初始化滑动窗口数据集$\mathcal{D}_{t_0}\leftarrow\emptyset$;

step 2: 对$k=0,1,\ldots,K-1$, 重复执行以下步骤;

step 3: 对每个智能体$i=1,\ldots,N$, 在当前位置采集局部带噪观测$y_i(t_k)=\phi(\mathbf{p}_i(t_k),t_k)+\varepsilon_i(t_k)$;

step 4: 汇总所有智能体观测, 并按式 (12) 更新滑动窗口数据集$\mathcal{D}_{t_k}$;

step 5: 基于$\mathcal{D}_{t_k}$按式 (14) 与 (15) 预测$t_k+\tau_0$时刻的敏感度场均值$\mu_{t_k}(\mathbf{x},\tau_0)$与方差$\sigma_{t_k}^2(\mathbf{x},\tau_0)$;

step 6: 按式 (16) 计算区域重要度函数$w_{t_k}(\mathbf{x})$;

step 7: 从$w_{t_k}(\mathbf{x})$中提取$M(t_k)$个高敏感任务区域构成任务集合$\mathcal{T}(t_k)$, 并计算各区域的代表点$\mathbf{h}_m(t_k)$与任务价值$q_m(t_k)$;

step 8: 令$K(t_k)=\min\{M(t_k),N\}$, 求解式 (25) 得到任务分配变量$\{z_{i,m}(t_k)\}$;

step 9: 对每个智能体$i=1,\ldots,N$, 按式 (18) 计算基础覆盖速度, 并按式 (27) 融合任务引导项得到期望速度$\mathbf{v}_i^{\mathrm{des}}(t_k)$;

step 10: 按式 (2) 计算加速度控制输入$\mathbf{u}_i(t_k)$;

step 11: 采用数值积分更新智能体速度$\mathbf{v}_i(t_{k+1})$与位置$\mathbf{p}_i(t_{k+1})$;

step 12: 转至 step 2, 直至$k=K-1$.

3　实验验证

本节通过仿真实验与半实物平台实验, 从覆盖性能、协同分工能力与动态响应特性等方面评估所提方法.

3.1　实验设计

仿真环境为二维有界区域Ω, 其中设置若干动态高敏感热点, 真实敏感度场由多个高斯核叠加生成, 热点中心随时间连续移动、强度随时间增强或衰减. 每个智能体仅能获取当前位置邻域内叠加高斯噪声的敏感度观测. 时空高斯过程采用平方指数核, 超参数在各组对比实验中保持一致. 除方法自身机制外, 其余仿真条件均相同, 主要参数如表 1 所示.

对比方法包括无预测覆盖方法 (Reactive-Coverage)、有预测无任务分配方法 (No-Task Allocation) 与本文方法 (Proposed). Reactive-Coverage 仅依据当前局部观测进行响应式覆盖控制; No-Task Allocation 采用时空高斯过程在线预测并据此设计覆盖控制, 但不引入任务分配机制; 本文方法在此基

表 1 仿真实验主要参数设置

类别	参数符号	取值	单位	说明
仿真环境	Ω	$[0,100]\times[0,100]$	m	任务区域
	T	40	s	仿真总时长
	Δt	0.1	s	控制步长
智能体	N	3	–	智能体数量
	$v_{\max}$	4	m/s	最大速度
	r_s	10	m	感知半径
ST-GP预测	ℓ_s	20	m	空间长度尺度
	ℓ_t	3	s	时间长度尺度
	W	5	s	窗口长度
覆盖与分配	τ_0	0.5	s	短时预测步长
	N_{alloc}	10	步	分配更新周期
	β	0.3	–	不确定性权衡系数
	λ	0.6	–	任务价值权重

础上进一步结合任务提取与分配. 三者在相同初始条件与环境配置下仿真.

实验设计了三类典型场景, 分别为单动态热点迁移场景、多动态热点无任务分配场景与多动态热点引入任务分配场景, 各场景的设置与目的在结果分析中分别说明.

评价指标选取式 (7) 定义的环境加权覆盖效能$\eta(t)$、覆盖性能恢复时间以及长期平均覆盖效能. 其中, 覆盖性能恢复时间为环境发生显著变化后系统覆盖性能恢复至稳定水平所需的时间, 反映对热点迁移等扰动的响应能力; 长期平均覆盖效能为$\eta(t)$在整个仿真周期内的时间平均.

3.2 实验结果与性能评估

场景一: 动态热点迁移场景

该场景仅设置一个沿预设轨迹连续移动的高敏感热点, 用于验证前瞻预测机制对热点连续迁移的响应能力. 由于不存在显著的任务竞争, 本节重点对比前瞻预测覆盖方法与反应式覆盖方法. 图 3(a) 和 (b) 分别给出时空高斯过程预测得到的敏感度场及其不确定性分布.

由图 4(a) 可见, 两种方法在初始接近阶段轨迹相近, 但进入热点区域后, 前瞻预测方法更好地贴合热点移动趋势, 反应式方法则出现明显的路径偏移与跟踪滞后. 图 4(b) 表明, 前瞻预测方法在稳态阶段

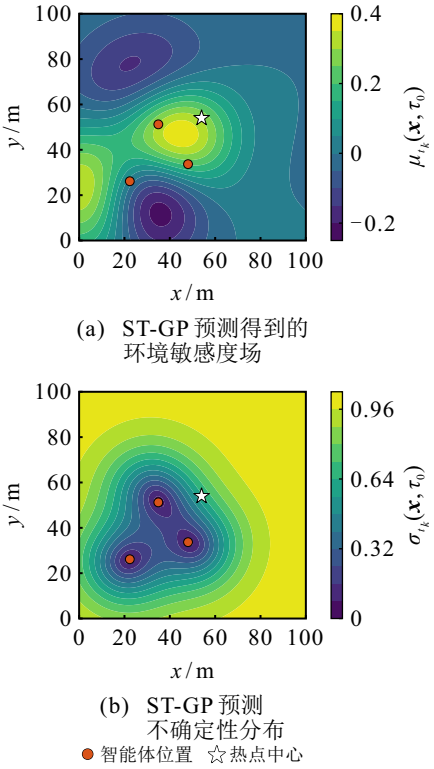

(a) ST-GP 预测得到的环境敏感度场

(b) ST-GP 预测不确定性分布

图 3 ST-GP 预测覆盖控制方法的预测敏感度场及不确定性分布

长期维持较高的局部敏感度值, 而反应式方法的敏感度值逐渐下降, 难以持续覆盖高敏感区域.

图 4(c) 表明前瞻预测方法的热点中心误差收敛更快并保持在较低水平. 图 4(d) 表明, 反应式方法因缺乏前瞻感知而表现出明显的跟踪滞后与性能波动, 前瞻预测方法则能根据短时预测提前调整部署位置, 在热点连续迁移过程中维持更高且更稳定的环境加权覆盖效能.

场景二: 多动态热点无任务分配场景

该场景同时设置多个沿不同轨迹移动、强度变化不一的高敏感热点, 用于分析缺少任务分配机制时仅依赖预测驱动覆盖策略的局限性.

图 5(a) 显示, 未引入任务分配时, 两种方法均存在局部聚集或重复覆盖, 说明仅依赖预测仍难以在多热点场景中形成明确分工. 图 5(b) 和图 5(c) 分别给出有无任务分配时的团队覆盖效能和覆盖重叠比例. 引入任务分配后, 覆盖效能提高且重叠比例降低,

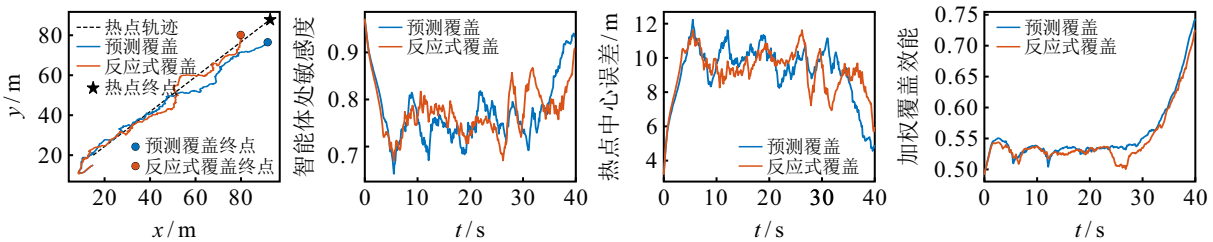

(a) 轨迹对比 (b) 智能体处敏感度 (c) 热点中心误差 (d) 环境加权覆盖效能

图 4 不同方法在轨迹、智能体处敏感度、热点中心误差及环境加权覆盖效能上的对比

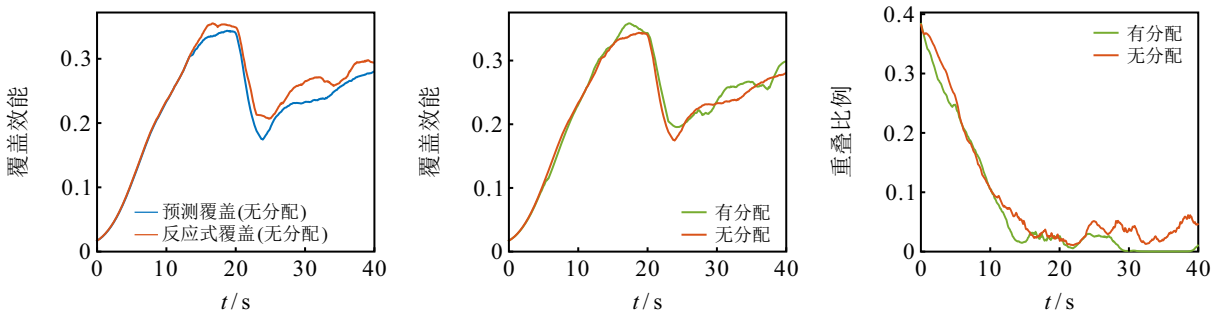

(a) 无任务分配机制下团队总体覆盖效能　(b) 有无任务分配机制时团队总体覆盖效能　(c) 有无任务分配机制时覆盖重叠比例

图 5　任务分配机制对团队总体覆盖效能与覆盖重叠比例影响的对比结果

说明该机制能够缓解局部聚集与重复覆盖, 提高多热点场景下的协同效率.

场景三: 多动态热点引入任务分配场景

该场景在多热点连续迁移条件下为两种方法均引入任务分配机制, 以对比前瞻预测覆盖方法与反应式覆盖方法的协同覆盖性能. 图 6(a) 和 (b) 分别给出两种方法的仿真可视化结果, 图 6(c) 给出团队总体覆盖效能对比.

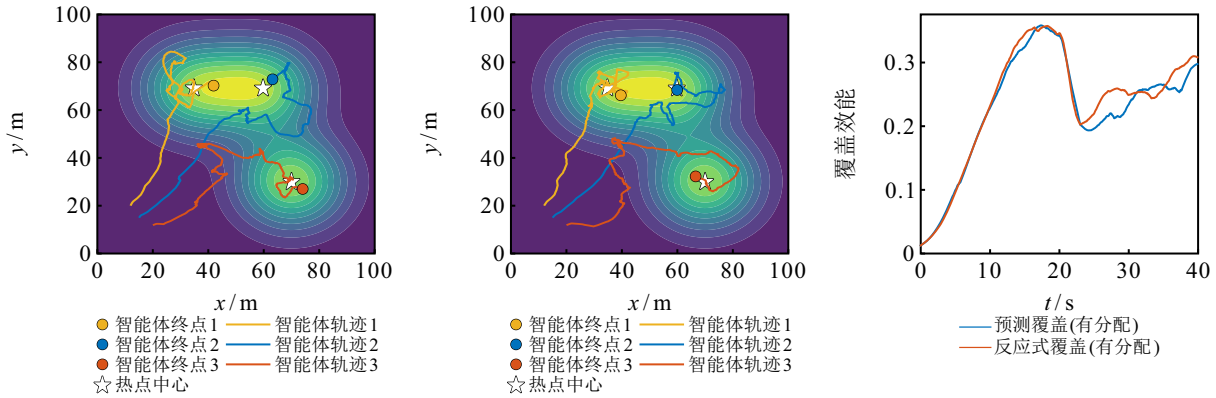

(a) 引入任务分配机制后前瞻预测覆盖方法的多热点场景仿真可视化　(b) 引入任务分配机制后反应式覆盖方法的多热点场景仿真可视化　(c) 引入任务分配后团队总体覆盖效能对比

图 6　引入任务分配机制后不同方法在多热点场景下的仿真结果及团队总体覆盖效能对比

在任务分配机制作用下, 两种方法均能实现一定程度的多热点分工覆盖, 其中前瞻预测覆盖方法在热点持续迁移过程中更稳定地跟踪高敏感区域, 完成初始覆盖后长期保持较高且稳定的团队覆盖效能; 反应式覆盖方法虽能实现基本覆盖, 但平均覆盖效能较低且更易随热点位置变化而波动.

3.3　室内半实物平台算法验证

为验证所提方法在真实物理系统中的可部署性, 本文搭建了室内半实物验证平台. 平台以由 12 台红外相机组成的 NOKOV 光学运动捕捉系统实时获取无人机与移动目标的位姿并提供毫米级反馈, 实验在包含道路、建筑与起降平台等元素的模拟城市沙盘中进行. 空中智能体为三架 Crazyflie 2.1 小型无人机, 作为执行覆盖任务的移动传感节点; 地面移动目标为 TianbotMINI 无人车, 用于模拟动态高敏感热点. 上位机根据运动捕捉系统反馈的位置状态运行所提算法, 计算并下发无人机期望运动指令, 构成半实物闭环验证系统.

实验将移动无人车视为动态热点中心, 无人机需根据热点位置变化和任务分配结果调整轨迹, 实现对移动热点的持续覆盖与跟踪. 与纯数值仿真相比, 半实物实验引入了真实的定位误差、通信延迟、动力学约束与执行误差, 能够检验算法向实际多无人机系统迁移的可行性.

图 7 给出了实验过程快照, 其中 (a) 为三架无人机在起降区域的初始部署, (b) 为无人机集群进入任务区域执行任务, (c) 为无人机对随无人车运动而迁移的热点的跟踪过程, (d) 为多无人机协同覆盖结果. 可以看出, 多架无人机能够根据移动热点的位置变化调整空间分布并形成协同覆盖态势, 说明所提方法能将预测与任务分配结果转化为真实无人机的可执行运动指令.

图 8 给出了无人机与移动热点的轨迹可视化结果, 其中 (a) 为水平面内的运动轨迹, (b) 和 (c) 分别为三维空间中初始阶段和执行过程的轨迹. 可以看出, 无人机轨迹随热点运动趋势相应调整并逐渐向

(a) 无人机起飞与初始部署

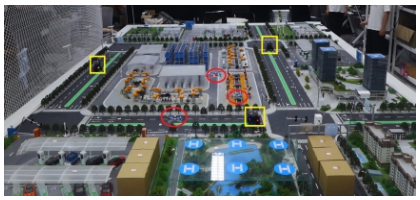

(b) 无人机集群执行任务

(c) 移动热点跟踪过程

(d) 多无人机协同覆盖结果

图 7 室内半实物平台实验过程快照

各自分配的任务区域靠近, 在保持飞行高度和运动连续性的同时避免集中于同一局部区域, 体现了任务分配机制对多无人机空间分布的引导作用.

3.4 消融实验与参数敏感性分析

为进一步量化预测机制与任务分配机制的独立贡献并考察关键超参数的影响, 本节在统一的多热点动态场景下对三种方法进行 16 次独立试验并取均值, 采用长期平均覆盖效能、覆盖性能恢复时间、热点中心跟踪误差 (RMSE) 与覆盖重叠比例四项指标进行评估. 其中, 覆盖性能恢复时间定义为强热点发生结构性突变后重新被某智能体捕获所需的时间, 其余指标在稳态窗口内统计.

三种方法的性能指标对比如表 2 所示. 可以看出, 本文方法在四项指标的试验均值上均表现最优, 其长期平均覆盖效能最高、恢复时间最短、中心跟踪误差最小、覆盖重叠比例最低, 表明预测与任务分配的协同能够共同改善动态覆盖性能.

为分离两机制的独立贡献, 进一步开展消融实验, 结果如表 3 与图 9 所示. 引入预测机制 (由 Reactive-Coverage 到 No-Task Allocation) 使长期平均覆盖效能由 0.233 提升至 0.248, 表明前瞻预测改善了对动态热点的跟踪与覆盖. 在此基础上引入任务分配机制 (由 No-Task Allocation 到 Proposed) 使

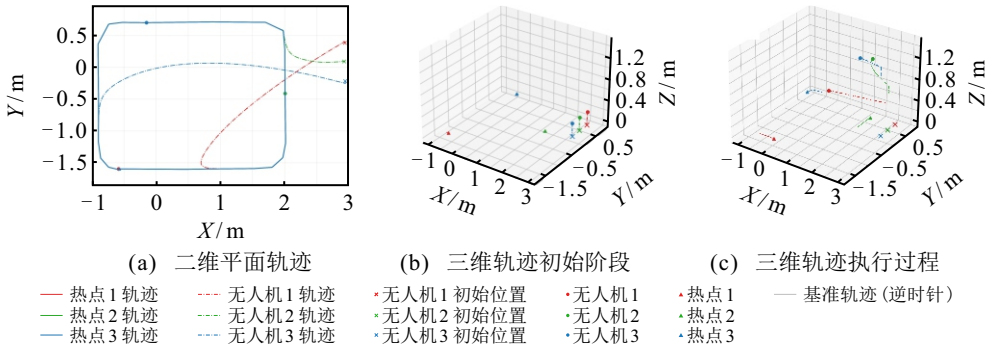

图 8 无人机与移动热点在二维与三维空间中的轨迹可视化结果

表 2 不同方法在动态覆盖场景下的性能指标对比 (16 次实验均值)

方法	覆盖效能	恢复时间/s	中心误差/m	重叠比例
Reactive-Coverage	0.233	16.7	14.4	0.034
No-Task Allocation	0.248	15.3	12.9	0.039
Proposed	0.251	13.7	12.2	0.029

表 3 预测机制与任务分配机制的消融实验结果 (16 次实验均值)

方法	预测机制	任务分配	覆盖效能	重叠比例
Reactive-Coverage	×	×	0.233	0.034
No-Task Allocation	✓	×	0.248	0.039
Proposed	✓	✓	0.251	0.029

覆盖重叠比例由 0.039 降至 0.029, 同时覆盖效能进一步提升至 0.251, 表明任务分配有效抑制了智能体在高敏感区域附近的重复聚集.

三种方法的智能体轨迹与真实敏感度场如图 10 所示. 在无任务分配的情况下, 多个智能体易聚集于同一高敏感区域, 且对突变后迁移的热点存在漏覆盖. 引入任务分配后, 本文方法实现了一机一热点的均衡部署, 对各热点的覆盖更为充分.

最后考察不确定性权衡系数β与任务价值权重λ的敏感性, 结果如图 11 所示. 当β过小时探索不足, β过大时因过度探索而偏离高价值区域, 覆盖效能在β约为0.2至0.3时取得较优折中, 同时覆盖重叠比例

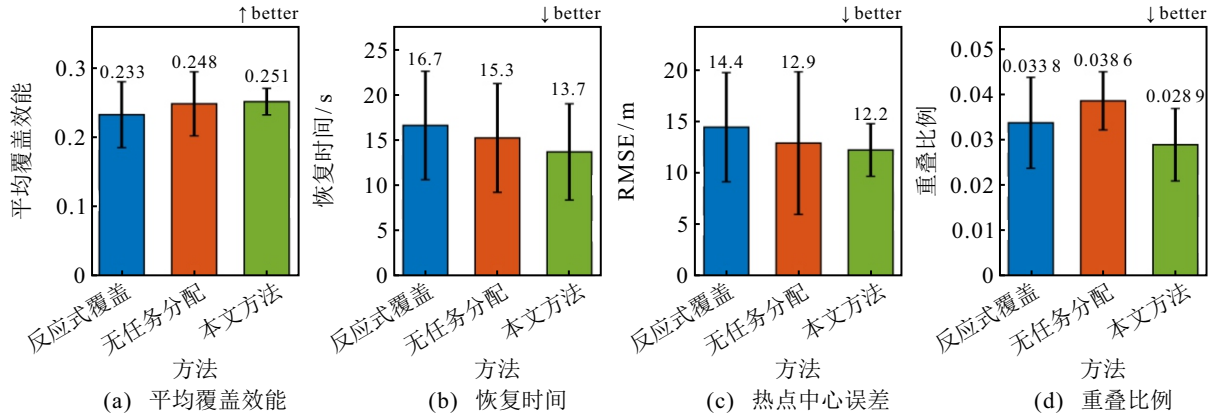

图 9　消融实验: 3 种方法在 4 项指标上的对比 (误差棒为 16 次实验标准差)

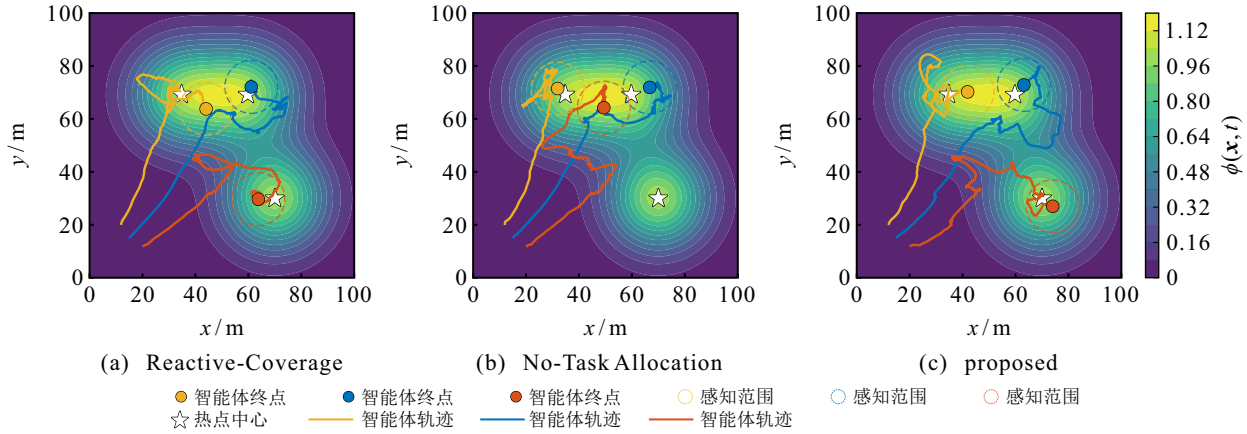

图 10　3 种方法在多热点动态场景下的智能体轨迹与真实敏感度场

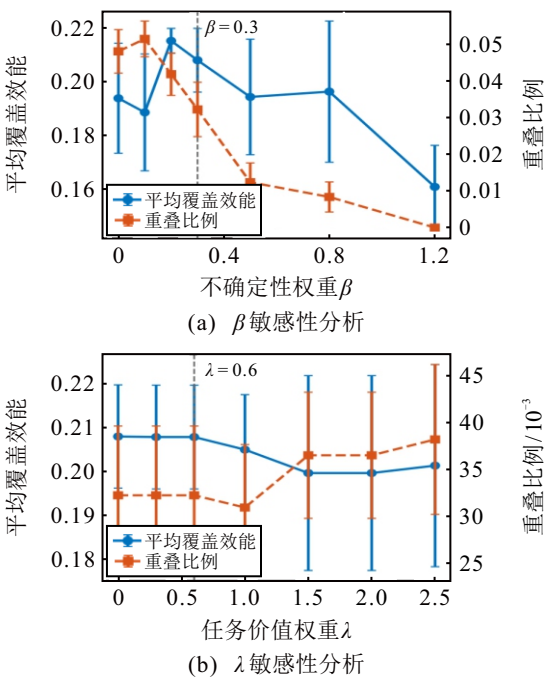

图 11　长期平均覆盖效能与覆盖重叠比例随β、λ变化的敏感性分析 (16 次实验均值, 误差棒为标准差)

随β增大而总体下降, 故本文取$\beta = 0.3$. 覆盖效能对λ在$[0, 1]$区间内较为稳健, 仅当λ过大时因过度追逐远处高价值目标而略有下降, 故本文取$\lambda = 0.6$. 上述分析论证了超参数选取的合理性.

4　结　论

本文针对动态环境下的多智能体覆盖控制问题, 提出一种基于时空高斯过程预测与任务分配协同的自适应覆盖控制方法, 构建由预测、分配和执行组成的闭环框架. 该方法在线建模并短时预测环境敏感度场, 融合预测均值与不确定性信息设计覆盖控制策略, 并通过任务提取与分配提高多热点场景下的协同覆盖能力. 数值仿真与半实物平台实验表明, 前瞻预测机制能够改善连续迁移热点的跟踪与覆盖性能, 任务分配机制能够减少重复覆盖并提高协同效率. 相关结果验证了所提方法在所设动态场景中的有效性与实际部署可行性, 为动态环境下的多智能体协同覆盖提供了可行技术路径.

参考文献 (References)

[1] Olfati-Saber R, Fax J A, Murray R M. Consensus and cooperation in networked multi-agent systems[J]. Proceedings of the IEEE, 2007, 95(1): 215-233.

[2] Ren W, Beard R W, Atkins E M. Information consensus in multivehicle cooperative control[J]. IEEE Control Systems Magazine, 2007, 27(2): 71-82.

[3] Dunbabin M, Marques L. Robots for environmental monitoring: Significant advancements and applications[J]. IEEE Robotics & Automation Magazine, 2012, 19(1): 24-39.

[4] Ju C, Kim J, Seol J, et al. A review on multirobot systems in agriculture[J]. Computers and Electronics in Agriculture, 2022, 202: 107336.

[5] 张世勇, 张雪波, 苑晶, 等. 旋翼无人机环境覆盖与探索规划方法综述[J]. 控制与决策, 2022, 37(3): 513-529.
(Zhang S Y, Zhang X B, Yuan J, et al. A survey on coverage and exploration path planning with multi-rotor micro aerial vehicles[J]. Control and Decision, 2022, 37(3): 513-529.)

[6] 王洪民, 庄育锋, 韦凌云, 等. 基于信息图的多无人机三维协同搜索动目标方法[J]. 控制与决策, 2023, 38(12): 3534-3542.
(Wang H M, Zhuang Y F, Wei L Y, et al. Multi-UAV 3D collaborative searching for moving targets based on information map[J]. Control and Decision, 2023, 38(12): 3534-3542.)

[7] Cortés J, Martínez S, Karatas T, et al. Coverage control for mobile sensing networks[C]. Proceedings of the IEEE International Conference on Robotics and Automation. Washington DC, 2002: 1327-1332.

[8] Pimenta L C A, Kumar V, Mesquita R C, et al. Sensing and coverage for a network of heterogeneous robots[C]. Proceedings of the 47th IEEE Conference on Decision and Control. Cancun, 2008: 3947-3952.

[9] Breitenmoser A, Schwager M, Metzger J C, et al. Voronoi coverage of non-convex environments with a group of networked robots[C]. IEEE International Conference on Robotics and Automation. Anchorage, 2010: 4982-4989.

[10] Pimenta L C A, Schwager M, Lindsey Q, et al. Simultaneous coverage and tracking (SCAT) of moving targets with robot networks[C]. Algorithmic Foundation of Robotics VIII. Berlin, 2009: 85-99.

[11] Lee S G, Diaz-Mercado Y, Egerstedt M. Multirobot control using time-varying density functions[J]. IEEE Transactions on Robotics, 2015, 31(2): 489-493.

[12] Zhang R, Ma H, Li N. Multi-agent coverage control with transient behavior consideration[C]. Proceedings of the 6th Annual Learning for Dynamics and Control Conference. Cambridge, 2024: 1464-1476.

[13] Liu W B, Borikarnphanichphaisal K, Song J, et al. Safe 3D coverage control for multi-agent systems[J]. Actuators, 2025, 14(4): 186.

[14] Miah S, Fallah M M H, Spinello D. Non-autonomous coverage control with diffusive evolving density[J]. IEEE Transactions on Automatic Control, 2017, 62(10): 5262-5268.

[15] Zuo L, Shi Y, Yan W S. Dynamic coverage control in a time-varying environment using Bayesian prediction[J]. IEEE Transactions on Cybernetics, 2019, 49(1): 354-362.

[16] 刘金培, 罗瑞, 陈华友, 等. 基于多尺度 3D-CNN-CBAM 的空气质量指数时空预测[J]. 控制与决策, 2025, 40(2): 404-412.
(Liu J P, Luo R, Chen H Y, et al. Spatio-temporal forecasting of air quality index based on multi-scale 3D-CNN-CBAM[J]. Control and Decision, 2025, 40(2): 404-412.)

[17] Mantovani M, Catellani M, Sabattini L. Distributed multi-robot ergodic coverage control for estimating time-varying spatial processes[J]. IEEE Robotics and Automation Letters, 2026, 11(4): 3955-3962.

[18] Wei L, McDonald A, Srivastava V . Multi-robot multitask Gaussian process estimation and coverage[EB/OL]. (2026-03-11)[2026-04-30]. https://arxiv.org/abs/2603.11264.

[19] Nanavati R V, Coombes M J, Liu C J. Distributed multi-robot source term estimation with coverage control and information theoretic based coordination[J]. Information Fusion, 2024, 111: 102503.

[20] Liu H X, Shao Z C, Zhou Q Z, et al. Task allocation algorithm for heterogeneous UAV swarm with temporal task chains[J]. Drones, 2025, 9(8): 574.

[21] Cao M L, Peng J Y, Yang L, et al. Multi-UAV task allocation and path planning in emergency rescue scenarios with uncertain requirements[J]. Journal of Industrial and Management Optimization, 2025, 21(10): 6107-6133.

[22] Cao J H, Wang Y T, Li K, et al. Multi-UAV adaptive cooperative coverage search method based on area dynamic sensing[J]. Journal of Computational Design and Engineering, 2025, 12(4): 77-93.

[23] 王宁, 梁晓龙, 李哲, 等. 分层池化: 带宏观引导收益的 UAV 集群区域覆盖搜索方法[J]. 控制与决策, 2025, 40(12): 3763-3777.
(Wang N, Liang X L, Li Z, et al. Layered pooling: A UAV swarm area coverage search method with macro guidance benefits[J]. Control and Decision, 2025, 40(12): 3763-3777.)

[24] Agrawal D R, Panagou D. Multi-agent clarity-aware dynamic coverage with Gaussian processes[C]. Proceedings of the IEEE 63rd Conference on Decision and Control. Milan, 2024: 37-44.

[25] Haydon B, Mishra K D, Keyantuo P, et al. Dynamic coverage meets regret: Unifying two control performance measures for mobile agents in spatiotemporally varying environments[C]. Proceedings of the 60th IEEE Conference on Decision and Control. Austin, 2021: 521-526.

作者简介

石磊 (1991−), 男, 教授, 博士, 主要研究方向为多智能体协同控制、多智能体协同定位, E-mail: shilei910918@126.com;

吕建鹏 (1996−), 男, 硕士生, 主要研究方向为多智能体强化学习, E-mail: 104754232851@henu.edu.cn;

麻壮壮 (1995−), 男, 讲师, 博士, 主要研究方向为多智能体协同控制、多智能体强化学习, E-mail: zhuangma912@126.com.