arXiv:2301.08537v1 [cs.RO] 20 Jan 2023

# 迈向多机器人探索：无人机森林探索的分布式策略

Luca Bartolomei、Lucas Teixeira 和 Margarita Chli,
Vision For Robotics Lab，苏黎世联邦理工学院¨，瑞士

摘要——**高效的探索策略对于搜救任务和灾害勘测等任务至关重要。无人机在此类应用中尤为普及，有望以较高速度覆盖大片区域。此外，随着机载无人机感知技术日趋成熟，研究重点正转向单机器人和多机器人任务中的高层推理。然而，对此前未知的大型空间进行自主导航和探索仍是一项尚未解决的挑战；尤其是在环境杂乱、障碍物密度高、遮挡频繁且严重的情况下，例如森林环境。此外，在这类场景中，远距离无线通信也可能成为限制因素，尤其是在实现无人机集群导航自动化时。为此，本文提出一种探索策略，使无人机无论单独行动还是组成小型集群，都能以分布式方式快速探索复杂场景。该策略赋予每架无人机在不同执行模式之间切换的决策能力，从而在对完全未知区域进行谨慎探索与更积极地探索较小的未知空间之间取得良好平衡。由此，无人机能够全面覆盖不同密度的森林区域，且速度始终快于先进水平。本文展示了该策略在单架无人机及最多三架无人机组成的集群中的成功部署，并为杂乱场景下的多机器人探索确立了基本原则：单架无人机的速度提升最高可达 65%，多无人机配置在相同任务时间内的探索面积则可增加 40%。**

## I. 引言

人们对无人机的兴趣日益浓厚，使其广泛应用于巡检和搜救任务等工作中。在这些应用中，机器人自主快速探索并绘制未知环境地图的能力至关重要。关于这一主题的文献十分丰富，多年来已有许多不同的方法被提出 [1]–[5]。然而，探索未知环境面临的最大挑战之一，是如何在相互冲突的目标之间取得良好权衡：既要缩短感兴趣区域的探索时间（即提高导航速度），又要确保安全，而这要求限制每台机器人的速度。事实上，在已知空间与未知空间的边界附近导航颇具挑战，因为机器人可能会陷入死胡同，或需要执行复杂的规避动作以避免碰撞。因此，为了保障平台及其周围环境的安全，大多数路径规划器都会生成保守的启停运动，未能充分发挥

本研究得到 NCCR Robotics、Amazon Research Awards 和 HILTI集团的支持。

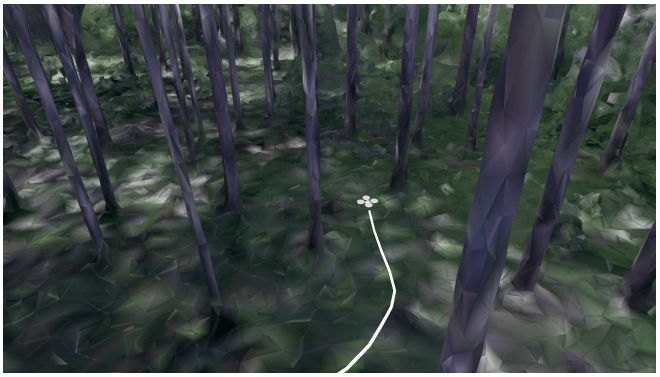


图 1：在真实森林的数字模型中，引导无人机安全、成功探索的所提出系统的三维视图[6]。规划器能够避免无人机与障碍物发生碰撞，通过在谨慎导航与积极利用已知自由空间之间取得平衡，实时清除前沿，从而最大限度地提高探索效率。

无人机高速飞行的能力。当待探索环境格外杂乱时，这一问题会更加严重，例如在森林中，进而导致覆盖率低下且不完全。这些方法通常通过引导探索优先覆盖较大的未探索空间，来推动探索过程。虽然这种策略在开阔宽敞的空间中可能有利，但在探索杂乱场景时却可能适得其反。事实上，这类策略的主要缺陷在于：探索过程试图尽可能覆盖未知空间，但在障碍物众多的环境中实施时，较狭窄的未知空间路径仍会被遗漏（例如因遮挡所致），因此需要在大部分已探索区域再进行一轮搜索。

为了缓解这些问题并加快对关注区域的覆盖，也有人提出了用于探索的多机器人扩展 [7]–[10]。然而，这些方法关注的是系统层面的协调问题；尽管从全局规划的角度来看，它们表现可能更好，但在障碍物密集的环境中，它们仍存在与单无人机情形相同的局限性。

受这些挑战的启发，在本研究中，我们提出了一种自主无人机机器人的探索策略，旨在探索树木密度不断增加的森林，因为这类森林给探索规划带来了最严峻的挑战。我们的目标是充分发挥平台的动力学特性，尽管障碍物密度很高，仍能高效地实现对环境的完整覆盖。为此，所提出的策略使每架机器人能够在两种不同的行为之间切换——

一是在未知空间中谨慎探索，二是在已探索区域中采取更积极的机动动作，以清除因遮挡而形成的较小未知空间。我们在一系列具有挑战性的仿真实验中评估了所提出的方法，实验既在随机生成的森林中进行，也在真实森林的三维重建场景中进行（图 1）。与先进水平进行基准测试后发现，所提出的方法效率更高，能够实现更高的无人机整体速度和更短的探索时间。最后，为构建迈向分布式多机器人探索规划的基础框架，我们展示了所提出的策略如何支持多个无人机参与探索任务，并证明我们的方法与基于地图分割的集中式方法性能相当或更优。

总之，本工作的贡献如下：

- 设计了一种探索策略，能够在谨慎探索与对已探索地图进行积极利用之间实现有效平衡，
- 将单机器人设计扩展为多机器人分布式方法，并且
- 在仿真中进行了大量评估，结果表明其性能优于当前最先进的方法。

## II. 相关工作

过去几十年来，无人机在未知环境中的自主探索一直是一个活跃的研究领域。探索感兴趣区域最常用的方法是利用前沿，即已知空间与未知空间之间的边界 [11]。这些前沿可用于识别可能包含信息的空间区域，从而高效地推动探索过程，直到找不到新的前沿，并可认为探索过程已经完成。选择下一个要探索的前沿时，可以采用不同的标准，例如根据其与当前视场的距离、遵循贪心选择策略，或由全局规划决定选择结果 [12]。然而，尽管基于前沿边界的方法已被证明能够取得令人满意的性能，尤其是在覆盖率方面 [2], [3], ，但通常会导致运动效率低下以及次优的动作选择。这主要是因为用于生成待探索环境地图的传感方式存在局限：最常见的传感器，如 RGB-D 和立体相机，探测范围有限。因此，无人机必须谨慎飞行以确保安全。Cieslewski 等人 [4] 针对这一局限提出了一种探索策略，根据新检测到的前沿生成速度指令，以尽可能提高无人机的速度。研究表明，该方法优于经典方法 [11], ，但仅关注局部前沿边界。相比之下，FUEL [5] 提出了一种分层规划器，可生成高效的全局路径，同时鼓励安全灵活的局部机动动作，以实现高速探索。在障碍物密度较低的场景中，FUEL 的策略优于 [4] 和 [11] 。然而，该策略的计算开销更大，因为它需要维护活跃前沿边界列表，并计算这些前沿之间的精确距离。这在更杂乱、复杂的环境（如森林）中，这些额外的簿记工作会变得难以承受且不切实际。事实上，在这类场景中，由树干、树枝和灌木造成的遮挡会使前沿的数量迅速增加。

另一类研究则侧重于基于采样的路径规划，通过引导机器人沿着由采样构型构成的可能路径行进，生成用于探索空间的视点 [13], [14]。通常采用贪心方法 [14], ，根据信息增益的定义，寻求实现完整探索或精确表面重建 [2] 的最佳路径。尽管如此，这些采样路线可能生成偏离最短路径的轨迹，且未考虑机器人的动力学。因此，无人机会沿之字形轨迹飞行，导致运动效率低、速度慢，且机动动作较为保守。

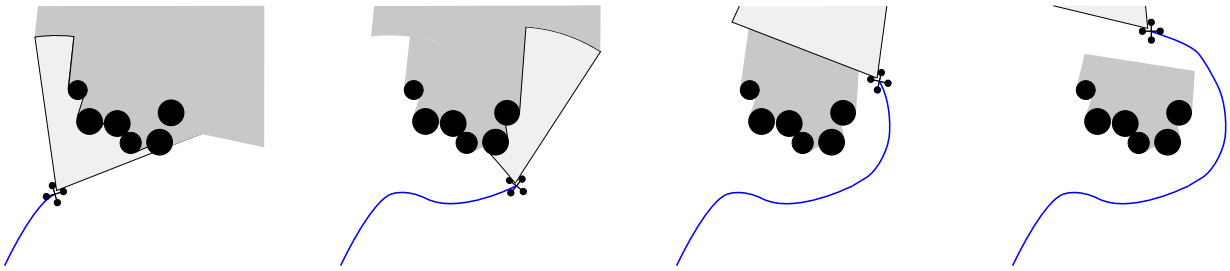
为克服基于边界的方法和基于采样的方法的局限性，研究者也提出了混合方法 [1], [15]。这类方法会规划通往信息量最大的前沿的全局路径，同时使用基于采样的规划器生成局部轨迹。然而，这些方法没有充分利用平台的全部动力学特性，因此生成的路线并非最优。

为提高探索效率，文献中也提出了多种多机器人协同边界方法，既有集中式方案 [16]，也有分布式方案 [17]。沿着这一思路，文献 [18]采用贪心策略分配视点构型，而文献 [19] 则通过对待探索区域进行基于 Voronoi 图的划分，在智能体之间分配工作量。然而，这些方案面临着与单机器人情形相同的局限性。相比之下，文献 [20] 提出的方法能够生成用于三维重建的高效轨迹，并通过集中式架构实现多机器人协调。不过，该方法需要预先对感兴趣区域进行一次高空飞行，因此不适用于森林探索。文献 [7] 提出的方法更侧重于森林中的导航问题，但其重点更多在于状态估计，而非路径规划。

受这些局限性启发，我们提出了一种策略，使机器人能够在类似森林的复杂环境中高速飞行并进行探索。这得益于规划器赋予每架无人机的自由度和灵活性，使其能够在线切换不同的导航模式。较慢的谨慎探索采用基于前沿的方法，而对于因遮挡造成的未探索空间路径，我们则采用更积极的局部探索策略，高效地加以清除，从而提升任务效率并缩短覆盖给定感兴趣区域所需的总时间。此外，我们还展示了所提出的流程也可以通过分布式方式扩展到多机器人场景。

## III. 方法论

本研究考虑的总体问题是，如何以尽可能短的时间探索未知的杂乱环境，例如森林，



(a) 时刻 1 (b) 时刻 2 (c) 时刻 3 (d) 时刻 4

图 2：示意图展示了贪心式边界探索的问题：随着时间推移，探索会形成被自由区域包围的未知空间孤岛。机器人的视场以浅灰色阴影区域表示，边界由黑色实线标出；障碍物和未探索空间分别以黑色和深灰色表示（a）。机器人朝信息量最大的前沿移动（b）；然而，由于传感器范围有限，障碍物遮挡的空间并未被清除（c）。因此，由于探索过程偏向较大、信息量更丰富的前沿，天真的规划器会操控无人机机器人飞行，忽略较小部分的未探索空间（d）。

并假设机器人配备了感知范围有限的前视深度相机，且能够以恒定频率获取里程计信息。然而，类森林场景的特点是存在大量尺寸各异的障碍物（例如树干、树叶和树枝），这使得标准的基于前沿的探索方法效率低下。事实上，在探索过程中，通常会遗留许多未知空间孤岛，如图 2 所示，因此需要在几乎完全探索过的地图上再次进行探索。为解决这一局限，我们提出了一种探索流程，可根据机器人周围的前沿改变其探索行为。具体而言，我们提出为机器人定义两种不同的运行模式，即探索者模式和收集者模式。在探索者状态下，机器人由前沿引导，任务是探索大面积的未知区域。因此，它主要沿着已知区域与未知区域之间最外围的边界行动。相反，处于收集者模式的机器人会清除探索阶段因遮挡而遗留下来的小片未知空间孤岛。收集者的目标是在行进过程中清除这些区域，从而避免之后重新访问地图，但代价是需要进行短距离的局部绕行。不过请注意，这些绕行可以高速完成，因为机器人在收集器模式下主要在已探索区域中行动。通过允许机器人在这两种模式之间切换，并在地图探索与利用之间实现恰当的权衡，我们可以快速实现对大型杂乱环境的全面覆盖。下文将首先概述所提出的系统和探索策略，然后说明如何将其扩展至多机器人场景。

### *A.* 系统概述

如图 3 所示，该流程由三个主要组件组成：建图系统、模式选择器和路径规划器。

根据输入的深度和里程计信息，生成环境的体素栅格地图 $\mathcal{M}$ 。每次更新时，从 $\mathcal{M}$ 中提取前沿并进行聚类。对于每个簇，我们采用 [5]中的采样策略生成覆盖前沿的视点，并将其作为探索过程中的候选目标位姿。

此外，每个簇都会经过一个二分类步骤，以识别不连通的前沿孤岛或路径。如果采用传统的基于前沿的探索方法，这一步对于识别那些可能需要在任务接近尾声时进行额外重访阶段的区域是必要的。在此，若某个簇的凸包被自由空间包围，或者它只有另一个相邻簇，则将其视为路径 。这意味着，待探索区域角落的大多数簇都会被分类为路径。我们认为，这样设计是合理的，因为角落通常信息价值较低，因而不利于探索。事实上，首次扫描地图时很少会覆盖这些区域，因此需要进行重访步骤。随后，利用已标记的簇，由ModeSelector为机器人选择最佳探索策略，决定机器人是坚持当前模式，还是切换到探索者或收集者模式。模式分配依据无人机附近的前沿进行调节。鉴于我们的目标是在局部清除路径，以避免在地图上大范围绕行，当靠近机器人的路径达到最低数量时，我们便将机器人分配为收集者。相反，当所有较小的未知空间孤岛都已清除，或路径远离无人机时，我们会采用更具探索性的策略。选定策略后，将最有潜力的簇的视点选作新的目标位姿，并将其交给路径规划器 [21] ，由其生成引导无人机飞向目的地的轨迹。下面将更详细地介绍不同的探索模式。

### *B.* 探索策略

*1)* 探索者： 探索者以地图前沿为驱动，其目标是覆盖大片此前的未知空间。与 [4],我们处理最新地图更新中的前沿簇$C$ 并提取其中成本最低的簇 $J_E$类似。请注意，这些簇大多与无人机的运动方向一致，这意味着，如果选择其中一个作为目标，机器人就能避免飞行方向突然改变或进行激进的

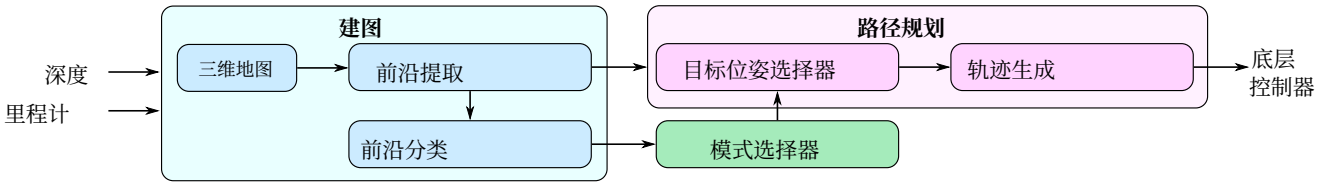



图 3：所提出的单个智能体探索流程示意图。系统的输入是机器人的里程计和深度信息。这些信息用于生成环境的三维栅格地图，并从中提取前沿并进行聚类。随后识别前沿轨迹，并据此为智能体选择合适的探索模式。然后选取下一个目标位姿，并使用 [21] 生成通往目标位姿的轨迹。

机动动作。

与视点 $\xi_c := \{\mathbf{x}_c, \gamma_c\}$覆盖簇 $c \in \mathcal{C}$ 相关的成本定义为

$$J_E(\xi_c) := \omega_D J_D(\xi_c) + \omega_V J_V(\xi_c) + \omega_L J_L(c), \quad (1)$$

其中 $\mathbf{x}_c \in \mathbb{R}^3$ 是视点的位置， $\gamma_c \in \mathbb{R}$ 是其方向。代价 $J_D$ 是$\mathcal{M}$ 中当前机器人位置与$\mathbf{x}_c$之间路径的长度，并使用 A* 算法计算。相反， $J_V$ 与行进方向的变化相关，而 $J_L$ 与簇 $c$的标签相关。项 $\omega_D, \omega_V$ 和 $\omega_L$ 是常数权重。

代价 $J_V(\xi_c)$ 的计算方式为

$$J_V(\xi_c) := acos(\mathbf{v}_R^T \frac{\mathbf{x}_c - \mathbf{x}_R}{||\mathbf{x}_c - \mathbf{x}_R||_2}), \quad (2)$$

其中 $\mathbf{v}_R \in \mathbb{R}^3$ 和 $\mathbf{x}_R \in \mathbb{R}^3$ 分别是机器人当前的速度和位置。该代价与速度和指向覆盖簇 $c$的候选位置$\mathbf{x}_c$ 的方向向量之间的夹角直接相关。不过，簇也可能被标记为路径，例如，细长障碍物（如树干）造成遮挡时就会出现这种情况。由于探索者应专注于实际前沿，我们对这些簇施加惩罚：

$$J_L(c) = \begin{cases} 0 & \text{if } c \text{ is } frontier \\ p_{trail} & \text{if } c \text{ is } trail \end{cases}, \quad (3)$$

其中 $p_{trail}$ 是与以下内容相关的常数惩罚 路径。

然后，我们选择下一个最佳视点作为目标位姿$\xi_{c^*} := \{\mathbf{x}_{c^*}, \gamma_{c^*}\}$ 以最低成本覆盖簇 $c^*$：

$$\xi_{c^*} := \arg \min_{\xi_c} \min_{\forall c \in \mathcal{C}} J_E(\xi_c). \quad (4)$$

如果无人机陷入死胡同，或者机器人前方没有可用的新簇，我们就忽略与机器人速度相关的成本，并采用贪心方法来选择新的目标位姿。我们使用与公式 1 相同的成本函数，在最大距离$d_{max}$ 范围内找到机器人附近的最佳簇，其中 $J_V$ 设为零：

$$\xi_{c^*} := \arg \min_{\xi_c} \min_{\forall c \in \mathcal{C}} \omega_D J_D(\xi_c) + \omega_L J_L(c) \quad s.t. \ ||\mathbf{x}_c - \mathbf{x}_R||_2 \leq d_{max}. \quad (5)$$

*2)* 收集者：收集者的目标是清除尽可能多的路径，以避免在任务结束时重访地图中探索不足的区域。由于这项任务意味着偏离主要探索方向，因此需要提高无人机的速度以便尽快返回探索者模式。为实现这一目标，我们通过为每个簇$c \in \mathcal{C}_{trails}$分配成本 $J_C$ ，对路径集合 $\mathcal{C}_{trails} \subseteq \mathcal{C}$ 进行排序：

$$J_C(\xi_c) := \omega_P J_P(\xi_c) + \omega_A J_A(\xi_c), \quad (6)$$

其中 $J_P$与到达$\mathbf{x}_c$ 所需的时间相关，而 $J_A$ 与当前机器人偏航角和视点方向之间角度变化的覆盖时间相关。另一方面， $\omega_P$ 和$\omega_A$ 是常数权重。

给定从 $\pi_c^R \mathbf{x}_R$ 到 $\mathbf{x}_c$ 的路径以及最大允许速度 $v_{max}$，$J_P$ 计算为

$$J_P(\xi_c) := \frac{\text{length}(\pi_c^R)}{v_{max}}. \quad (7)$$

类似地，给定机器人当前的航向 $\gamma_R$、视点的方向 $\gamma_c$ 以及最大允许偏航角速度$\dot{\gamma}_{max}$， $J_A$ 计算为

$$J_A(\xi_c) := \frac{\angle(\gamma_R, \gamma_c)}{\dot{\gamma}_{max}}, \quad (8)$$

其中 $\angle(\gamma_R, \gamma_c)$ 表示 $\gamma_R$与 $\gamma_c$之间的角度差。

随后，机器人通过逐步的贪心过程选择目标轨迹，并作为收集者行动，直到所有邻近轨迹都被清除。由于这些轨迹被已知自由空间包围，因此与处于探索者模式时相比，我们将最大速度提高了一倍。因此，无人机能够最大化其速度，从而实现快速运动，迅速覆盖与这些轨迹相关联的所有视点。

### C. 扩展至多机器人

*1)* 系统架构：所提出的探索策略可以轻松扩展到多机器人场景。扩展后的流程如图4所示。假设各智能体能够在公共参考坐标系中定位，它们会交换局部子地图，以及里程计信息、当前目标位姿和执行模式。请注意，我们在此提出的是一种去中心化架构。集中式方法通常假设智能体之间以及智能体与地面站之间可以进行无限距离的通信。然而，标准 Wi-Fi通信的范围有限，而且在森林等杂乱环境中导航时，通信线路可能受到阻挡，导致信号丢失。在本研究中，我们提出采用一种更灵活的点对点策略，并假设每对智能体之间都存在最大通信距离。我们的

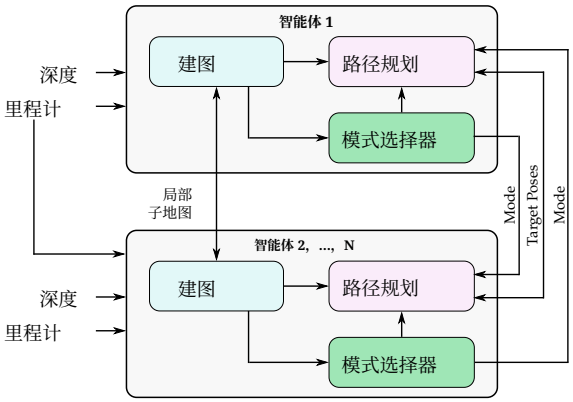



图4：多机器人场景下流程的概览，无人机的任务是协同构建感兴趣区域的完整地图。为实现这一目标，智能体会交换里程计信息和局部子地图，以及当前执行模式和目标位姿。我们假设机器人之间存在最大通信距离。如果两个智能体之间的距离超过这一限值，通信就会中断，信息也不再交换，导致协调不佳。

设计旨在使智能体保持在有效通信距离内。如果智能体之间的距离超过最大通信范围，通信就会中断，信息也不再交换，从而导致智能体间协调不佳和决策次优。我们还假设，通信中断后又恢复时，智能体能够同步地图。

*2*）多机器人协调：只有当一对智能体从探索角度来看执行兼容动作时，我们才鼓励它们进行协调。这意味着，如果两架无人机处于相同模式，它们可以协作探索更多未知空间（探索者）或清理路径（收集者）。相反，不应鼓励探索者与收集者之间进行协调，因为它们的任务本质上不同。在这种情况下，我们提出领导者—跟随者范式：探索者（领导者）不受第二个智能体位置的影响，探索未知区域；而收集者（跟随者）则跟随领导者，清理其留下未探索的路径。这种设计选择使任务执行期间更加灵活，因为可以在线切换执行模式。请注意，如果所有智能体之间的通信都中断，它们的探索策略将退回到单机器人情形。

通过修改公式 1 和公式 6 中的代价函数，我们将机器人团队内部的协作策略作为软约束加以鼓励。考虑位置为 $\mathbf{x}_R^i$ 的机器人 $i$，已知团队中其他 $N-1$ 个机器人的位置 $\mathcal{X}_R^i := \{\mathbf{x}_R^k\}_{k=0}^{N-1}$（其中 $k \neq i$），以及它们当前的目标位置 $\mathcal{G}_R = \{\mathbf{x}_{c^*}^k\}_{k=0}^{N-1}$，我们对机器人 $i$ 的代价函数 $J_E$ 和 $J_C$ 作如下修改：

$$J_E(\xi_c, \mathcal{X}_R^i, \mathcal{G}_R) := \omega_D J_D(\xi_c) + \omega_V J_V(\xi_c) + \omega_L J_L(c) + \omega_F J_F(\xi_c, \mathcal{X}_R^i, \mathcal{G}_R) \quad (9)$$

and

$$J_C(\xi_c, \mathcal{X}_R^i, \mathcal{G}_R) := \omega_P J_P(\xi_c) + \omega_A J_A(\xi_c) + \omega_F J_F(\xi_c, \mathcal{X}_R^i, \mathcal{G}_R), \quad (10)$$

其中，$\omega_F$ 是一个常数权重。代价函数 $J_F(\xi_c, \mathcal{X}_R^i, \mathcal{G}_R)$ 定义如下：

$$J_F(\xi_c, \mathcal{X}_R^i, \mathcal{G}_R) := J_F^{att}(\mathcal{X}_R^i) + J_F^{rep}(\xi_c, \mathcal{X}_R^i, \mathcal{G}_R), \quad (11)$$

其中，$J_F^{att}$旨在使智能体 $i$ 和 $k$ 保持在通信范围内，而 $J_F^{rep}$ 则确保它们之间保持最小距离，以避免碰撞。此外，$J_F^{rep}$ 通过对靠近其他智能体当前目标的候选目标位置赋予较高代价，来促进地图分割。

具体而言，智能体 $i$ 的函数 $J_F^{att}$定义如下：

$$J_F^{att}(\mathcal{X}_R^i) := \sum_{k=0, k\neq i}^{N-1} \mathcal{I}(i,k) \cdot \frac{1}{2} k_A ||\mathbf{x}_R^i - \mathbf{x}_R^k||_2, \quad (12)$$

其中，$k_A$ 是常数因子，$\mathcal{I}(i, k)$是一个嵌入了我们协调策略的指示函数：

$$\mathcal{I}(i,k) := \begin{cases} 0 & \text{if } i \text{ Explorer and } k \text{ Collector} \\ 1 & \text{otherwise} \end{cases}. \quad (13)$$

这表明，只有当智能体 $i$ 和智能体 $k$ 处于兼容的执行模式时，前者才会被后者吸引。相反，在领导者—跟随者 模式下，即机器人 $i$ 是探索者而机器人 $k$ 是收集者时，领导者会忽略跟随者，且$J_F^{att}$变为零。需要注意的是，若 $i$ 是收集者而$k$ 是探索者，则 $\mathcal{I}(i, k) = 1$ 且 $J_F^{att} \neq 0$。

相反，$J_F^{rep}$ 按如下方式计算：

$$J_F^{rep}(\xi_c, \mathcal{X}_R^i, \mathcal{G}_R) := \sum_{k=0, k\neq i}^{N-1} J_{ik}^{rep}(\mathbf{x}_R^i, \mathbf{x}_R^k) + J_{ik}^{rep}(\mathbf{x}_c^i, \mathbf{x}_{c^*}^k), \quad (14)$$

其中，给定欧几里得距离 $d_{AB} := ||\mathbf{x}_A - \mathbf{x}_B||_2$,

$$J_{AB}^{rep}(\mathbf{x}_A, \mathbf{x}_B) := \begin{cases} k_R(d_c - d_0)^2 \frac{d_c d_0}{d_0 - d_c} & \text{if } d_{AB} \leq d_0 \\ k_R(d_{AB} - d_0)^2 & \text{if } d_c \leq d_{AB} \leq d_0 \\ 0 & \text{otherwise} \end{cases}. \quad (15)$$

参数 $k_R$ 是常数权重，而 $d_0$ 表示位置 $A$ 和 $B$ 发生碰撞时的最小距离。参数 $d_c$ 表示位置之间应保持的距离下限。该参数可根据无人机之间所需的安全距离进行选择。请注意，$J_{ik}^{rep}$ 不受智能体 $i$ 和 $k$ 的角色影响，因为必须始终满足安全距离和最小距离要求。

## IV. 实验

我们在仿真中的单无人机和多无人机设置下评估了所提出的探索流程。具体而言，我们在一系列树木密度逐渐增加的逼真随机生成的森林 [22]，以及真实森林的三维重建 [6] 上对该方法进行了基准测试。

在单智能体设置中，我们将所提出的方法与 FUEL [5]，进行比较；在多机器人实验中，我们则将其与基于地图划分的集中式策略进行比较。在所有测试中，我们根据地图尺寸使用 0.10m 或 0.15m 的栅格地图分辨率，并为所有规划器设置相同的动态限制：$v_{max} = 1.5\,\text{m/s}$ 和 $\dot{\gamma}_{max} = 0.9$ rad/s。我们模拟了一台量程固定为

| | Ours | FUEL [5] |
|---|---|---|
| REAL FOREST | | |
| 完成时间 [秒] | **500.7 ± 14.8** | 757.7 ± 47.9 |
| 行驶距离 [m] | 645.0 ± 20.0 | **533.2 ± 11.0** |
| 速度 [m/秒] | **1.3 ± 0.5** | 0.7 ± 0.4 |
| 稀疏森林（0.05 棵树 / $m^2$） | | |
| 完成时间 [秒] | **665.4 ± 32.7** | 1114.1 ± 97.4 |
| 行驶距离 [m] | 860.9 ± 34.0 | **758.1 ± 57.6** |
| 速度 [m/s] | **1.3 ± 0.6** | 0.7 ± 0.5 |
| 中等密度森林 (0.10 树木 / $m^2$) | | |
| 完成时间 [秒] | **779.6 ± 110.9** | 954.1 ± 28.8 |
| 行驶距离 [m] | 910.3 ± 63.7 | **713.5 ± 33.1** |
| 速度 [米/秒] | **1.2 ± 0.6** | 0.7 ± 0.5 |
| 茂密森林 (0.15 树木 / $m^2$) | | |
| 完成时间 [秒] | **613.2 ± 16.2** | 1130.2 ± 28.8 |
| 行驶距离 [m] | **789.7 ± 16.8** | 791.0 ± 37.7 |
| 速度 [m/s] | **1.2 ± 0.6** | 0.7 ± 0.5 |
| 极密森林（0.20 棵树 / $m^2$） | | |
| 完成时间 [秒] | **658.2 ± 57.2** | 904.1 ± 109.5 |
| 行驶距离 [m] | 802.0 ± 52.7 | **680.6 ± 49.9** |
| 速度 [m/s] | **1.2 ± 0.6** | 0.7 ± 0.5 |

表 I：单个智能体的实验结果。我们报告了 3 次运行的平均完成时间，以及平均行驶距离和速度。最佳表现以粗体显示。完成任务所需时间的标准差相对较高，尤其是在树木密度为 0.10 和 0.20 trees/$m^2$，的情况下，这是由地图的复杂特性和大量遮挡造成的。

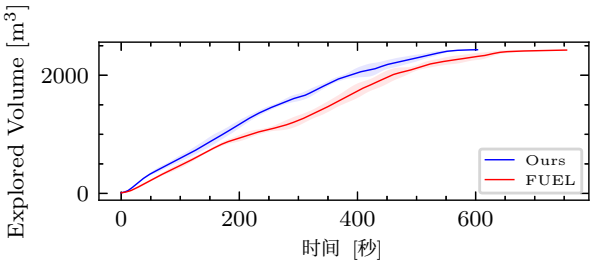



图 5：REAL FOREST 模型实验期间的平均探索率。阴影区域表示标准差。与 FUEL 相比，所提出的方法用时更短即可实现完全覆盖 [5]。

4.5m 的深度相机，使用 [23] 的基于 Vulkan 的渲染器，以及与 [5] 中相同的物理模拟器。我们从完成场景探索所需的时间、总行驶距离，以及每次实验期间无人机的平均速度等方面报告规划器的性能。

### *A.* 单机器人实验

在单机器人实验中，合成森林模型的尺寸为 50 m × 50 m × 2m，而 REAL FOREST 的三维重建尺寸为 40 m × 40 m × 2m。地图分辨率设为 0.10 m。如表 I 所示，所提出的规划器在所有场景中，达到全面覆盖所需的时间均优于 FUEL [5]（图 5）。这得益于我们的自适应探索策略，该策略使

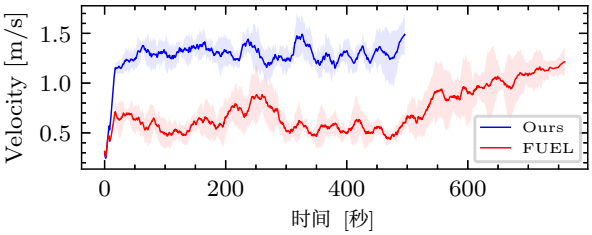



图 6：REAL FOREST 实验期间无人机的平均速度。阴影区域表示标准差。与 FUEL 相比，所提出的策略能够使无人机以更高的速度飞行，从而提高任务效率（即完成任务所需的时间）。任务接近结束时，采用 FUEL 策略的无人机也会加速，因为此时地图大部分已探索完毕，较短的路径也已清理完成，这与所提出策略中的收集器模式相似。

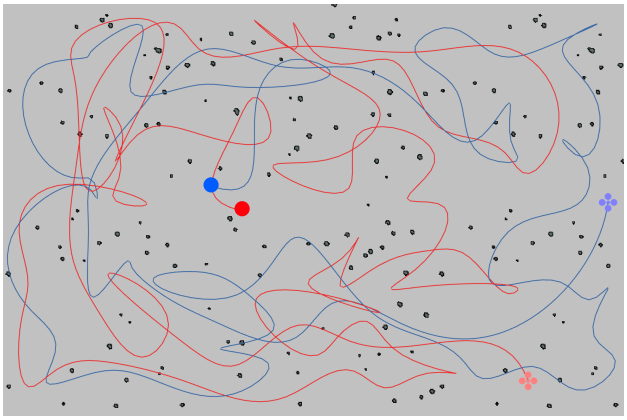


图 7：探索任务的俯视图，两架无人机组成的团队需要绘制一片随机生成的森林地图，其树木密度为 0.05 棵树/$m^2$，，图中以黑点表示。无人机的初始位置以彩色团块标出，最终位置则以放大的无人机模型表示，以便更清晰地展示。地图表示为二维占据栅格，由距地面 1.5m 处的三维模型切片生成。

得无人机在整个任务期间始终保持较高的速度，如图 6 所示。这些结果表明，与固定模式方法相比，采用所提出的自适应探索策略更具优势。不过请注意，所提出的设计会导致行驶距离更长，但能确保不会留下小块未探索区域。事实上，探索者模式和收集者模式下的决策都是在局部地图层面进行的，这可能导致无人机飞行路线更长，偏离最短路径。尽管如此，在所提出的策略中，我们通过鼓励能够提高无人机速度的决策来弥补这一不足，从而缩短任务时间。

### *B.* 多机器人实验

在多机器人实验中，我们在各种具有固定均匀障碍物密度的模型中，以及在地图不同区域树木密度各异的随机生成森林中，对所提出的规划策略进行了测试。

*1*）树木密度固定的地图：表 II 展示了两个智能体在树木密度固定的地图上采用多机器人协作探索策略的结果，其中

| | Ours | 分割地图 (FUEL [5]) |
|---|---|---|
| 稀疏森林 (0.05 树木 / m²) | | |
| 完成时间 [秒] | **780.3 ± 32.2** | 834.3 ± 64.3 |
| 行驶距离 [米] | 958.8 ± 9.2 | **595.7 ± 51.8** |
| | 958.7 ± 60.4 | |
| 速度 [米/秒] | **1.2 ± 0.6** | 0.7 ± 0.4 |
| | **1.3 ± 0.7** | |
| 中等密度森林（0.10 棵树 / 米²） | | |
| 完成时间 [秒] | **838.5 ± 64.4** | 848.1 ± 98.5 |
| 行驶距离 [m] | 915.3 ± 68.4 | **616.1 ± 40.7** |
| | 906.2 ± 58.3 | |
| 速度 [米/秒] | **1.2 ± 0.5** | 0.8 ± 0.4 |
| | **1.1 ± 0.6** | |
| 茂密森林（0.15 棵树 / m²） | | |
| 完成时间 [秒] | 786.3 ± 40.7 | **754.0 ± 23.9** |
| 行驶距离 [米] | 839.0 ± 26.1 | **586.7 ± 14.2** |
| | 882.2 ± 32.0 | |
| 速度 [米/秒] | **1.2 ± 0.7** | 0.8 ± 0.4 |
| | **1.3 ± 0.7** | |
| 极密森林（0.20 树木 / 米²） | | |
| 完成时间 [秒] | 803.7 ± 52.8 | **705.8 ± 73.2** |
| 行驶距离 [m] | 873.8 ± 47.0 | **580.3 ± 73.3** |
| | 912.6 ± 42.7 | |
| 速度 [米/秒] | **1.2 ± 0.7** | 0.7 ± 0.5 |
| | **1.2 ± 0.8** | |

表 II：两架无人机探索树木密度固定的随机生成森林的结果，取 3 次运行的平均值。对于所提出的策略，我们报告每个智能体的平均行驶距离和速度。最佳表现以粗体标出。

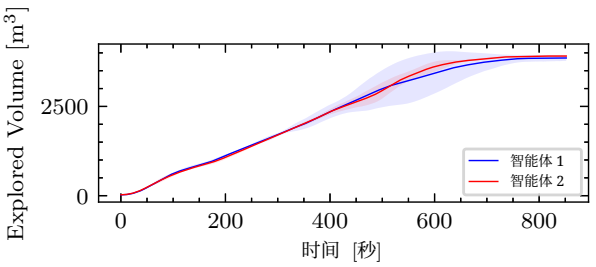



图 8：在密度为 0.10 棵树/平方米的随机森林中进行实验时，采用所提出的方法使用两架无人机得到的每个智能体的平均探索率。阴影区域表示标准差。结果显示，两个智能体的探索体积始终保持均衡。

假设智能体之间进行数据交换的最大连接距离为 50 米（图 7）。在此处，实验在尺寸为 100 米 ×50 米×2 米、地图分辨率为 0.10 米的森林模型中进行。将所提出的方法与我们设计的集中式策略进行比较；该策略采用 FUEL 规划器 [5]，并将无人机分配到尺寸相等的地图区域进行探索（即使用地图划分）。请注意，该策略假设森林地图均匀且已知原始地图尺寸，因此不适用于实际部署；而所提出的方法则不存在这一问题。不过，为了进行基准测试，仍然给出比较结果。

与使用 FUEL 的集中式方法相比，所提出的策略取得了相当的结果。与单机器人探索类似，所提出的策略让无人机以更高的速度飞行，因此行驶距离更长。此外，我们的策略能够自动实现探索任务的负载均衡，使每个智能体的探索率相近，如图 8 所示。然而，在更茂密的森林模型中，所提出方法的性能有所下降，因为无人机需要在彼此的连接范围内飞行，导致行动自由度受限。在较小的地图中，障碍物和遮挡数量增加，使这一问题更加严重，探索率也随之降低。尽管如此，如前所述，与使用 FUEL 的基准策略相比，所提出的方法能够在实际中部署。

*2*）地图中的非均匀树木密度：表 III 展示了由两个智能体组成的团队在障碍物密度不均匀的地图中的实验结果。我们采用尺寸为 100 m × 200 m × 2m 的模型，并在不同地图区域设置不同的树木密度（0.2、0.3 和 0.5 棵树/m²）。占据栅格地图的分辨率设为 0.15 m，智能体间通信范围最大为 200 m。我们按照第 IV-B.1 节中的方法进行相同分析，并假设无人机的最大飞行时间为 1500 s，以贴近实际情况。由于所有受测规划器都无法在限定时间内完全探索环境，因此我们报告固定时间戳下的团队总覆盖率。与采用 FUEL [5] 作为规划后端的地图划分方案相比，所提出的方法始终表现更优。性能提升得益于我们的策略能够让无人机在障碍物密度较低的区域飞行得更快，同时谨慎探索更拥挤的区域，并在飞行过程中清除较短的前沿轨迹。这使探索过程更加高效，能够更充分地发挥无人机执行高度动态飞行的能力。

最后，我们报告了部署由三台机器人组成的团队时本方法的性能。如表 IV 所示，团队规模越大，总覆盖率越高。这表明，本研究提出了一种有效策略，可在大面积森林区域中点对点共享探索任务责任；按照这一范式，可将该方法扩展至由更多无人机组成的团队，从而推动面向探索的可扩展分布式多机器人规划。

## V. 结论与未来工作

在这项工作中，我们提出了一种探索流程，适用于在复杂、杂乱环境中运行的自主无人机，并特别关注森林。我们选择这类环境，是因为森林具有更多障碍物和遮挡，因而本质上属于最具挑战性的环境之一，不利于有效规划。所提出的策略允许每架无人机在不同的探索行为之间切换，在任务执行过程中自主平衡对未知空间的谨慎探索与更积极的机动动作，并利用已建图空间。借助更高速的飞行，该方法能够缩短完成时间，进而实现比先进水平更高效、更快速的地图覆盖。此外，我们还展示了如何将所提出的方法扩展到三台乃至更多机器人，并以分布式方式运行，从而证明该方法能够在参与智能体之间自动实现有效的负载均衡。继

| | Ours | 分割地图（FUEL [5]） |
|---|---|---|
| 行驶距离 [米] | 1481.9 ± 467.0<br>1487.0 ± 440.8 | **735.2 ± 500.1**<br>**697.1 ± 365.6** |
| 速度 [m/秒] | **1.3 ± 0.6**<br>**1.2 ± 0.7** | 0.7 ± 0.4<br>0.6 ± 0.5 |
| 探索体积 [$m^3$] - 300 秒 | **542.3 ± 23.3**<br>565.9 ± 31.4 | 514.6 ± 313.0<br>**632.0 ± 184.8** |
| 探索体积 [$m^3$] - 600 秒 | **1062.8 ± 81.3**<br>**1011.6 ± 65.3** | 840.0 ± 580.7<br>728.3 ± 163.5 |
| 探索体积 [$m^3$] - 900 秒 | **1400.0 ± 265.3**<br>**1302.6 ± 110.5** | 1145.3 ± 814.7<br>798.8 ± 146.2 |
| 探索体积 [$米^3$] - 1200 秒 | **1626.7 ± 431.2**<br>**1466.5 ± 185.4** | 1330.1 ± 905.3<br>910.4 ± 83.9 |
| 探索体积 [$m^3$] - 1500 秒 | **1816.0 ± 550.8**<br>**1637.0 ± 299.1** | 1437.8 ± 971.8<br>1040.5 ± 124.3 |

表 III：在树木密度不均匀的随机生成的森林中使用两个无人机进行探索的结果，取 3 次运行的平均值。我们报告了 1500 秒时每个智能体的平均行驶距离和速度，以及团队在不同时间戳下的总探索体积。最佳性能以粗体突出显示。

| 时间戳 | 两个智能体 | 三个智能体 |
|---|---|---|
| 300 秒 | $1108.2 \pm 54.7$米$^3$ | **1208.0 ± 91.6 米**$^3$ |
| 600 秒 | $2074.3 \pm 144.8$米$^3$ | **2098.4 ± 143.8 米**$^3$ |
| 900 秒 | $2702.6 \pm 375.9$米$^3$ | **2748.3 ± 111.9 米**$^3$ |
| 1200 秒 | $3093.2 \pm 616.6$m$^3$ | **3223.5 ± 127.9 米**$^3$ |
| 1500 秒 | $3453.0 \pm 849.9$m$^3$ | **3621.8 ± 321.0 米**$^3$ |

表 IV：在随机生成的森林中，不同模型区域具有不同树木密度时的结果，取 3 次运行的平均值。这里由两架和三架无人机构成的团队对地图进行探索。我们报告团队在不同时间戳所覆盖的总体积。最佳表现以粗体标出。

续推动机器人任务中更高层次决策的自动化，这项工作为机器人团队实现有效的探索规划树立了重要里程碑。

这项工作的自然后续步骤是解决如何将所提出的流程集成并部署到真实平台上，同时进一步研究如何推动更大规模多机器人团队的协作策略发展。

参考文献


[1] M. Selin, M. Tiger, D. Duberg, F. Heintz, and P. Jensfelt, 《大规模三维环境的高效自主探索规划》，*IEEE*机器人与自动化快报，2019年。[2] L. Schmid, M. Pantic, R. Khanna, L. Ott, R. Siegwart, and J. Nieto, 《未知环境中在线信息路径规划的高效采样方法》，*IEEE*机器人与自动化快报，2020年。[3] Y. Kompis, L. Bartolomei, R. Mascaro, L. Teixeira, and M. Chli, 《用于大型场景三维重建的知情采样探索路径规划器》，*IEEE*机器人与自动化快报，2021年。

[4] T. Cieslewski, E. Kaufmann, and D. Scaramuzza, 《多旋翼快速探索：高速飞行的前沿选择方法》，载于《2017年IEEE/RSJ智能机器人与系统国际会议（IROS）》，2017年。[5] B. Zhou, Y. Zhang, X. Chen, and S. Shen, 《FUEL：使用增量前沿结构与分层规划的无人机快速探索》，IEEE机器人与自动化快报，2021年。[6] A. Ahmad, V. Walter, P. Petrˊaˇcek, M. Petrlˊık, T. Bˊaˇca, D. ˇZaitlˊık, and M. Saska, 《GNSS拒止且障碍物密集环境中的自主空中集群》，载于《2021年IEEE机器人与自动化国际会议（ICRA）》，2021年。[7] Y. Tian, K. Liu, K. Ok, L. Tran, D. Allen, N. Roy, and J. P. How, 《利用多架无人机在森林冠层下进行搜救》，《国际机器人研究期刊》，2020年。[8] T. Rouˇcek, M. Pecka, P. ˇCˊıˇzek, T. Petˇrˊıˇcek, J. Bayer, V. ˇSalanskˋy, D. Heˇrt, M. Petrlˊık, T. Bˊaˇca, V. Spurnˋy et al., 《DARPA地下挑战赛：地下环境中的多机器人探索》，载于《自主系统建模与仿真国际会议》。施普林格，2019年。[9] L. Bartolomei, M. Karrer, and M. Chli, 《采用代理端-服务器架构，在部分未知环境中实现自主导航的多机器人协调》，载于《2020年IEEE/RSJ智能机器人与系统国际会议（IROS）》，2020年。[10] M. Corah, C. O'Meadhra, K. Goel, and N. Michael, 《面向大型环境中多机器人探索的高效通信规划与建图》，IEEE机器人与自动化快报，2019年。[11] B. Yamauchi, 《自主探索的基于前沿的方法》，载于《1997年IEEE机器人与自动化计算智能国际研讨会论文集（CIRA'97）》，1997年。[12] D. L. da Silva Lubanco, M. Pichler-Scheder, and T. Schlechter, 《一种面向移动机器人的新型基于前沿的探索算法》，载于《2020年第六届机电与机器人工程国际会议（ICMRE）》，2020年。[13] C. Connolly, 《下一个最佳视点的确定》，载于《IEEE机器人与自动化国际会议论文集》，1985年。[14] A. Bircher, M. Kamel, K. Alexis, H. Oleynikova, and R. Siegwart, 《用于三维探索的滚动时域"下一最佳视点"规划器》，载于《2016年IEEE机器人与自动化国际会议（ICRA）》，2016年。[15] B. Charrow, G. Kahn, S. Patil, S. Liu, K. Goldberg, P. Abbeel, N. Michael, and V. R. Kumar, 《结合轨迹优化的稠密三维建图信息论规划》，《机器人学：科学与系统》第十一届会议，2015年。[16] A. Mannucci, S. Nardi, and L. Pallottino, 《大范围区域的自主三维探索：协作式基于前沿的方法》，载于《自主系统建模与仿真》。查姆：施普林格国际出版，2018年。[17] R. G. Colares and L. Chaimowicz, 《下一个前沿：结合信息增益与距离代价的分布式多机器人探索》，《第31届ACM应用计算年度研讨会论文集》，2016年。[18] G. Hardouin, J. Moras, F. Morbidi, J. Marzat, and E. M. Mouaddib, 《利用多架无人机对大规模三维环境进行表面重建的下一最佳视点规划》，载于《2020年IEEE/RSJ智能机器人与系统国际会议（IROS）》，2020年。[19] A. Dutta, A. Bhattacharya, O. P. Kreidl, A. Ghosh, and P. Dasgupta, 《通过连续区域划分在未知环境中进行多机器人信息路径规划》，《国际先进机器人系统期刊》，2020年。[20] D. Morilla-Cabello, L. Bartolomei, L. Teixeira, E. Montijano, and M. Chli, 《Sweep-Your-Map：面向大型环境空中团队的高效覆盖规划》，IEEE机器人与自动化快报，2022年。[21] B. Zhou, F. Gao, L. Wang, C. Liu, and S. Shen, 《快速自主飞行的鲁棒高效四旋翼轨迹生成》，IEEE机器人与自动化快报，2019年。[22] H. Oleynikova, M. Burri, Z. Taylor, J. Nieto, R. Siegwart, and E. Gal-ceran, 《用于无人机在线重新规划的连续时间轨迹优化》，载于《IEEE/RSJ智能机器人与系统国际会议（IROS）》，2016年。[23] L. Bartolomei, Y. Kompis, L. Teixeira, and M. Chli, 《利用深度强化学习实现多旋翼飞行器自主紧急着陆》，载于《2022年IEEE/RSJ智能机器人与系统国际会议（IROS）》，2022年。