arXiv:2303.03539v2 [cs.RO] 6 Jul 2023

自然环境中的多机器人分位数估计研究

Isabel M. Rayas Fern´andez[1], Christopher E. Denniston[1,†], Gaurav S. Sukhatme[1,*]

摘要—自然现象的分位数能够帮助科学家深入了解浓度分布的不同范围。当有多台机器人可用时，以协作方式共享资源可能有助于提升性能。然而，要实际组建并协调一支多机器人团队并非易事。为此，我们基于信息路径规划方法，围绕使用多台机器人估计目标分布分位数的影响，从多个方面开展研究。在一项分析湖泊藻类浓度的无人机探索任务中，我们测量了团队规模不断增大时的分位数估计精度，以了解多机器人方法带来的益处。此外，我们还分析了若干参数，包括机器人初始位置的分散程度、规划预算和机器人间通信。我们发现，虽然使用更多机器人通常能够降低估计误差，但这一优势的实现取决于特定条件。我们结合真实的野外机器人应用介绍研究发现，并讨论这些结果的意义以及未来研究的有趣方向。

一、引言

研究自然环境的科学家已使用机器人协助调查或探索感兴趣的区域，例如监测有害藻华 [1], [2]。为了灵活且易于解读地描述这类现象，有人提出指定机器人在探索过程中可以针对的目标分位数 [3]。分位数估计 是指获取分布中给定分位数的数值。例如，藻类浓度中位数就是 0.5 分位数对应的数值。此前，相关情境下的分位数估计研究主要关注单机器人自适应调查；本研究则探讨多机器人调查，其动机在于有些团队拥有多台机器人，也在于不同团队可通过共享机器人资源开展协作调查，以最大化调查的科学产出。尽管直觉上可能认为机器人越多越好，但本研究旨在以严谨的方式探究这一判断在什么条件下成立。在环境中部署机器人可能

*本研究部分由南加州海岸水研究项目管理局资助，主要资金来自加利福尼亚州水资源控制委员会，协议编号为19-003-150；部分由美国农业部/国家食品与农业研究所项目资助，项目编号为2017-67007-26154。

本材料基于美国国家科学基金会研究生研究奖学金计划资助的工作，项目编号为DGE- 1842487。本材料中所表达的任何观点、研究结果、结论或建议均属于作者本人，并不一定反映美国国家科学基金会的观点。1

Dep计算机系 p科学 ，南加州大学y 南加州 .

*G.S. Sukhatme 同时担任南加州大学教授和亚马逊学者。本文介绍的工作是在南加州大学完成的，与亚马逊无关。

†C.E. Denniston 目前就职于 OffWorld, Inc. 本文介绍的工作是在南加州大学开展的，与 OffWorld 无关。

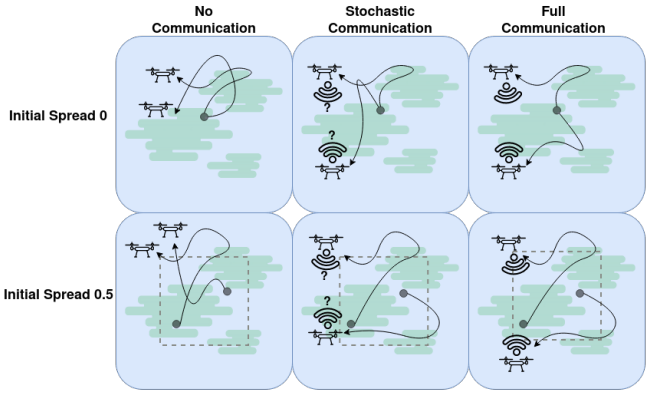


图 1：多机器人规划方法的若干变体。顶行展示初始分散状态 $\alpha = 0$：所有机器人均从中心出发。底行展示初始分散状态 $\alpha = 0.5$：机器人分散在一个长和宽均为整个工作空间 50% 的区域内。左列展示无通信：机器人彼此不了解；这相当于每个机器人都假设自己是唯一的机器人进行规划。中列展示随机通信：机器人尝试共享观测，但消息会根据机器人之间的距离以随机方式传输失败。右列展示完全通信：机器人共享相同的环境模型；这相当于集中式规划。

成本高昂，而且在此类用例中增加机器人数量能否实现规模化仍不明确。本研究评估了团队规模、起始位置、规划预算和通信对野外环境中分位数估计任务的影响。我们认为，这是为水生生物学领域的野外机器人部署制定合理决策迈出的重要第一步。

我们的贡献如下：

- 首个关于多机器人分位数估计的研究；
- 关于团队规模对真实水生数据集上性能影响的定量结果；
- 关于初始位置分布、探索预算和机器人间通信等参数对性能影响的定量结果，为多机器人研究中哪些因素至关重要提供了见解；
- 结合野外应用介绍了这些结果，以及它们可能对不同实验设置产生的影响。

II. 背景

我们介绍与所研究问题相关的背景，并将我们的贡献置于既有工作的背景下。

A. 环境分位数估计

监测和了解自然环境中的藻类生长是本研究的主要动机。空间

淡水和海洋生态系统中藻类及蓝细菌水华分布的空间异质性已广为人知[4]。准确描述其变化，对于研究水体系统中的平均趋势和危险状况都十分重要，因为接触蓝细菌或藻类毒素可能会对人类和动物造成毁灭性影响 [5]。以往的研究将机器人调查作为研究和分析这些环境及其藻类和蓝细菌特征的重要组成部分 [6], [7], ，近期研究则专门采用分位数估计，为这些研究提供了灵活的框架 [3]。

在此，我们以 [3], 的工作为基础，但存在若干差异。首先， [3] 旨在最终输出一组位置，在这些位置可以找到所需的分位数值；而我们的目标是准确估计所需的分位数值。其次，我们将问题推广到多机器人领域，而 [3] 仅考虑一台机器人。最后， [3] 针对分位数估计问题提出了新的规划目标函数，而我们关注的是考察不同因素对分位数估计精度的影响，因此在本研究中仅采用先前提出的一种目标函数。

B. 信息路径规划（*IPP*）

信息路径规划（IPP）是一种常见的规划框架，通常以在线方式使用。该框架利用以内部模型形式表示的环境知识来指导下一步行动；随后获取新信息并将其纳入模型，之后重复这一过程。IPP 使用取决于具体应用的目标函数，以确定每个步骤中信息量最大的行动。机器人在每个规划步骤都会生成一条规划轨迹 p，使目标函数 f达到最大值（或最小值）；这些轨迹共同构成完整路径 P。通常，问题设有规划步数限制或预算 B，用于规定路径 [8]的最大成本 c。我们将其表述为 $P^* = \text{argmax}_{P\in\Phi} f(P) \mid c(P) \leq B$，其中 Φ是完整轨迹空间， P^* 是最优轨迹。高斯过程（GP）是广泛使用的一种环境内部模型，它可以表示环境的信念分布，并在预测未测量位置时将分布的空间依赖性纳入考量。GP 会估计特定位置 x处的均值 $\mu(x)$ 和方差 $\sigma^2(x)$。我们将问题表述为一个信息路径规划问题，整体目标是使用 GP 对环境建模，从而最小化对环境中某个分布的一组分位数进行估计时产生的误差。

部分可观测马尔可夫决策过程（POMDPs）经常用于解决规划问题 [9], [10]。POMDPs能够表示环境中的不确定性，并根据噪声观测同时提供最优行动，因此在规划问题中具有广泛的适用性。基于这些原因，本文使用POMDP表述来解决我们的信息路径规划问题。

C. 多机器人研究

多机器人系统研究历史悠久；许多广为人知的问题都已扩展到多个机器人，例如多机器人同步定位与建图 [11], 多机器人探索 [12],和多机器人学习 [13]。在本文中，我们关注多机器人分位数估计问题。具体而言，我们探讨针对这一问题的多机器人方法是否有效，以及在什么条件下有效。

许多关于机器人团队规模对性能影响的既有研究，重点关注心理负荷和操作员工作负荷等人为因素 [14], [15], ；而那些研究自主群体性能的工作，对于性能与团队规模之间的相关性得出了不一致的结果 [16], ，并指出多机器人问题往往遵循边际收益递减定律 [17], [18],，该定律表明，向问题中添加更多资源时，所产生的收益会逐渐减少。这一性质也称为次模性，既体现在机器人数量方面，也体现在所获取的测量方面；既有研究已利用该性质近似求解规划问题 [19]。在此，我们旨在研究使用多个同构机器人对自然环境中分位数估计任务的影响，从而了解如何最有效地利用资源来应对具有挑战性且资源受限的野外作业问题。

1) 多机器人信息路径规划： 以往研究采用了熵或互信息等目标函数，来探索温度场、浮游生物密度、盐度和叶绿素等现象 [1], [20]。研究人员利用浓度的空间相关性来解决规划问题，同时改善性能与效率之间的权衡 [21]。带有连续连通性约束的规划也得到了研究。在 [22],中，研究人员使用二部图来确定机器人下一步访问的位置。尽管该研究的重点是改变通信半径以及用于决策的信息量，作者还发现，机器人数量与使用基于熵的目标函数所带来的改进之间存在线性关系。二部图匹配也被用于迭代地为机器人规划通往环境中信息量最大点的路径 [23]。 [24]研究了一个类似问题，其中杂乱环境中存在间歇通信。在该研究中，区域被划分为Voronoi单元，以便在机器人进入彼此的通信范围时更好地平衡机器人之间的工作负荷。重复的Voronoi划分已与有限的信息共享相结合，用于水下机器人 [25]。 [26] 还研究了这种非恒定连通性，其中利用隐式协调解决具有周期性连通性的多机器人搜索问题，以应对可扩展性挑战。研究人员使用强化学习学习规划策略，优先探索热点区域，并增强对机器人故障的鲁棒性 [27]。群体机器人学领域的既有研究考察了机器人在跟踪时变质量区域时的适应性 [28] ，以及群体规模对目标跟踪的影响 [29]。

我们的工作与这些研究的不同之处在于，它明确探讨了

不同团队规模及其他因素对性能的影响，并且其动机源于有针对性的野外机器人部署，而非大型群体所表现出的集体行为。此外，我们研究的任务是改进任意一组分位数的估计，而不是改进覆盖或热点区域；后者通常是其他研究的重点。

III. 方法

本文研究的问题是：通过让 N 机器人探索有限的二维工作空间，并在其访问的位置进行测量，从而准确估计目标分布的一组分位数，例如湖泊中的藻类浓度。具体而言，我们将规划空间离散化为 $\boldsymbol{G}^{\#} \subset \mathbb{R}^2$，即由网格定义、机器人可以访问的位置集合。机器人可以沿 $\pm x$ 或 y方向移动。共有 N 台协作式同构机器人，每台都是固定高度无人机，通过朝下的高光谱相机进行测量。机器人可以在每个位置拍照，测量分辨率高于 $\boldsymbol{G}^{\#}$，因此 $\boldsymbol{X}^{\#}$ 表示机器人在每个 $\boldsymbol{g}^{\#} \in \boldsymbol{G}^{\#}$拍照时可以测量的位置集合，而 $\boldsymbol{Y}^{\#}$ 表示这些位置上的实际值。目标分位数 Q 由科学家或操作人员给定，其真实值定义为 $V = \text{分位数}(\boldsymbol{Y}_{\#}\, Q)$。规划步数预算为 B_T。截至时间 t，机器人已进行测量的位置及相应的测量值分别表示为 $\boldsymbol{X}_{0:t}$ 和 $\boldsymbol{Y}_{0:t}$。每台机器人 n都会维护一组分位数值的估计，表示为 $\tilde{V}_n = quantiles(\mu_{GP_t}^{(n)}(\boldsymbol{X}^{\#})\ Q)$，其中 $\mu_{GP_t}^{(n)}(\boldsymbol{X}^{\#})$ 是利用以 $\boldsymbol{X}_{0:t}$ 和 $\boldsymbol{Y}_{0:t}$为条件的高斯过程对所有可能位置作出的估计。请注意，为简洁起见，本节其余部分将省略上标 (n)。

对于给定的 N和 B_T，我们的问题是在预算约束下，为每个机器人 n 选择一条由路径 P_n 组成的完整路径 $\boldsymbol{P}^*$：$\boldsymbol{P}^* = \text{argmax}_{\boldsymbol{P}}\, f(\boldsymbol{P})$，其中 $\boldsymbol{P} = \bigcup_{n \in N} P_n, \forall n \in N$：长度($P_n$) $\leq B_n$，且 f 是规划时使用的目标函数。在这项工作中，我们旨在估计 Q处潜在浓度的值。请注意，我们的目标不是寻找最高值，也不是优化每个位置的模型精度。因此，我们使用分位数标准误目标函数来评估一个候选位置 [3], ；该函数衡量使用机器人当前环境模型 $\mu_{GP_{i-1}}$估计分位数值的标准误，与使用当前模型并结合在候选位置 μ_{GP_i}处预期获得的新测量进行更新后估计的标准误之间的差异。第二项则通过参数 c加权，鼓励探索模型不确定性较高的位置： $f(\boldsymbol{X}_i) = \frac{d}{|Q|} + \sum_{x_j \in \boldsymbol{X}_i} c\sigma^2(x_j)$，其中 $d = \|se(\mu_{GP_{i-1}}(\boldsymbol{X}^{\#})\ Q) - se(\mu_{GP_i}(\boldsymbol{X}^{\#})\ Q)\|_1$。

—

我们将规划问题表述为一个部分可观测马尔可夫决策过程（见表 I），并使用 POMCPOW 求解器 [30] 求解该规划问题。在每个规划步骤中，机器人根据当前环境模型选择下一个要访问的位置。移动到下一个位置后，机器人会拍摄图像，采集一组（带噪声的）点测量，并将其反馈到高斯过程模型中。我们假设使用直线低层

表 I：将信息路径规划建模为部分可观测马尔可夫决策过程 [3]。

部分可观测马尔可夫决策过程	**信息路径规划**
状态	机器人位置 g_t，底层未知函数 GT
动作	邻近搜索点
观测	机器人位置 g_t，测量位置 $\boldsymbol{X}_t = o(g_t)$ 测量值 $\boldsymbol{Y}_t = GT(\boldsymbol{X}_t) + \mathcal{N}(0,\ \sigma_{\text{noise}})$
置信度	以先前测量为条件的高斯过程 位置（$\boldsymbol{X}_{0:t-1}$）和值（$\boldsymbol{Y}_{0:t-1}$）
奖励	f（$\boldsymbol{X}_t$）

运动规划器生成从一个位置到下一个位置的轨迹。我们还在机器人之间启用尽力而为的通信系统，并将其与其他方案进行比较（见第三节 C）。规划过程持续进行，直到每个 N 机器人都达到分配的预算，此时规划结束，机器人可以返回基地。此时，将汇总所有机器人的所有测量，并用于生成最终的˜分位数值估计：$V_{\text{final}} = quantiles(\boldsymbol{Y}_{\text{aggregate}}, Q)$。

现在，我们介绍多机器人方法的几种变体，如图 1 所示。

A. 初始位置分布

在信息路径规划过程中，机器人团队不会覆盖所有可能区域，其表现自然会受到初始区域的影响。为研究这一点，我们定义初始位置分布参数 α，取值范围为 0（所有机器人从同一位置出发）至 1（机器人分散在整个工作空间中）。例如，当分布参数为 0.5 时，机器人将在一个面积为整个工作空间一半的矩形内均匀分布并从中出发。我们采用劳埃德算法 [31] 的一种变体来确定机器人的初始位置；该算法通过迭代计算空间的近似沃罗诺伊镶嵌的质心，并将位置重新分配到这些质心。我们使用随机采样的 $100N$ 个点执行 100 次迭代。最终得到 N 个位置，它们在分配的工作空间内近似均匀分布。

B. 预算

为了控制机器人数量更多的团队在实际中仅仅拥有更多规划步数这一因素，并与单机器人基线进行更公平的比较，我们对预算约束进行了一种变体，称为共享预算：$\forall n \in N$： $B_n = B_T/N$。当（B_T模 N）$\neq 0$时，余数将在尽可能多的机器人之间平均分配。另一种选择是默认的完整预算，它为每个机器人提供完整预算，即 $\forall n \in N$：$B_n = B_T$。

C. 通信

为了研究通信的影响，我们区分了几种信息共享方式。完全通信假设通信完美且即时，这意味着每个机器人都使用同一个环境共享高斯过程模型，并且该模型会根据任意机器人进行的每次测量进行更新；这等同于集中式规划。另一个极端是无通信。在这种情况下，每个机器人都有自己的环境模型。从本质上说，这种实现方式等同于 N 机器人独立规划；进行新的测量后，这些测量只会用于更新该机器人自己的高斯过程。

我们认为，与无通信方式进行比较，有助于了解信息共享本身会产生什么影响，这可作为有价值的基线。从实际角度看，如果不同研究小组合用机器人，实现协调机制可能需要投入大量时间和精力。在这种情况下，直接部署现有机器人而不改变其行为，或许是最简单的做法。

第三种变体是随机通信。完成测量后，机器人会尝试将信息（像素位置及其对应的数值集合）传输给其他每个机器人。我们将每次尝试建模为一次伯努利试验，并假设数据成功传输的概率为 S 形概率 p_{success}，其遵循 [32]，其中 $distance$ 是两台机器人之间的距离，η 定义了 S 形曲线的陡峭程度，而 r 是通信质量下降到阈值以下时的距离：$p_{\text{success}} = (1 + e^{\eta(distance - r)})^{-1}$。我们假设，如果机器人 n 和 m 在时间步 i成功建立通信，则 m 会收到所有 $\boldsymbol{X}_i$（即不会传输部分测量数据或损坏的测量数据）。接收机器人的高斯过程会使用收到的数据进行更新。

我们还将其与将区域划分为多个区域的方法进行比较，即分区情形。该方法根据初始位置对工作空间进行Voronoi划分，并要求每台机器人始终停留在分配给自己的区域内。分区机器人之间不启用通信。

IV. 实验设置

我们使用两个不同的真实世界数据集，在仿真中评估性能。这些数据集由安装在无人机上的高光谱相机采集，无人机飞越一座淡水湖。每个数据集都在湖泊的同一区域采集，但采集日期不同，因此藻类分布也不同。机器人的活动范围限定在约 80×60 米的区域内。我们使用数据集中的 400纳米通道作为藻类的代理指标，并将测得的像素强度（$0-255$）归一化至 $[0,1]$。实验中测试两组目标分位数：四分位数 $Q = (0.25,\ 0.5,\ 0.75)$ 和极值$Q = (0.9,\ 0.95,\ 0.99)$。所有实验中的每种参数组合均运行 2 个随机种子。可用工作空间离散化为 25x25 网格 $\boldsymbol{G}^{\#}$。机器人事先并不知道环境情况。我们采用第三节 C 中描述的通信模型，其中 $\eta = 0.5$ 和 $r = 10$。此外，对每次测量添加均值为零、标准差为 $\sigma_{\text{noise}} = 0.05$ 的高斯噪声。在 POMCPOW 求解器中，我们将每步的滚动模拟次数设为 100，滚动深度设为 4，规划器折扣因子设为 0.8。高斯过程长度尺度为 12。无人机高度为 7 米，每张图像为 25 个像素（测量值）。

我们选取若干参数进行改变，以研究其对性能的影响。这些参数列于表 II 中。为衡量性能，我们报告调查结束时真实分位数值 V 与˜估计分位数值 V_{final} 之间的均方根误差（RMSE）。

A. 初始位置分布

我们首先改变 $\alpha = \{0.0, 0.33, 0.66, 1.0\}$。每个 α均在团队规模为 $N = \{2, 4, 8\}$的情况下进行测试，并保持预算恒定为 $B_T = 15$。此外，我们将每个 α 分别与无通信和随机通信进行比较，但不考虑单机器人情形，因为在只有一个机器人时，α 和通信不会产生任何影响。为量化所观察到的性能差异的显著性，我们报告了Wilcoxon符号秩检验的结果 [33],；该检验是t检验的非参数版本，用于检验两个配对样本是否来自不同的分布。

表 II：我们在实验中研究的参数。

参数	测试值
初始位置分布（α）	0.0、0.33、0.66、1.0
总预算（B_T）	10, 15, 30
预算类型	完整，共享
通信类型	无、随机、完整、分区

B. 规划预算

接下来，在完整预算情况下，我们改变 $B_T = \{10, 15, 30\}$，将 α 设置为常数值 0.66。我们同时考虑$N = 1$ 以及多机器人团队。此外，我们比较共享预算与完整预算，设置 $B_T = 15$。在所有情况下，我们启用机器人之间的随机通信。

C. 通信

最后，我们比较不同 N 在不同通信水平下的性能：完整、随机和无通信，并将其与空间分区进行比较。我们保持先前的参数不变：$\alpha = 0.66$；$B_T = 15$，并使用$N = \{1, 2, 4, 8\}$。请注意，在分区情况下，$\alpha = 1.0$。

V. 结果

现在，我们展示实验结果，并讨论其对现实世界多机器人野外作业的影响。箱线图展示了实验中估计的˜分位数值 V_{final} 与真实分位数值V 之间的最终均方根误差，纵轴表示该误差；结果既按团队规模汇总，也按团队规模细分。均方根误差以归一化像素强度表示。上方的横线表示配对实验组的威尔科克森符号秩显著性水平。

A. 初始位置分布

图 2 展示了使用单侧Wilcoxon符号秩检验对 α 进行实验所得的结果。我们观察到，总体而言，随着 α增加，性能往往会提升（误差降低）。具体来说，在没有随机通信的情况下，如图 2 上排所示，我们发现 $\alpha = 0.33$ 与 0。66 之间的性能提升具有统计显著性（T=266，$p \leq 0.001$）。在右上图中，按 N进一步区分后，我们同样观察到 $\alpha = 0.33$与 $\alpha = 0.66$ 之间的性能提升具有统计显著性，且对 $N = 2$ 和 $N = 4$ 均如此（分别为T=33，$p \leq 0.05$、T=32，$p \leq 0.05$）；但在这些情况下，我们没有观察到 $\alpha = 0.66$ 与 $\alpha = 1.0$ 之间有类似的提升。总体而言，我们还发现，机器人数量越多，α 对性能的影响越显著，这表现为最大误差不断降低。不过，总体来看，随着 α增大，收益似乎会逐渐递减。

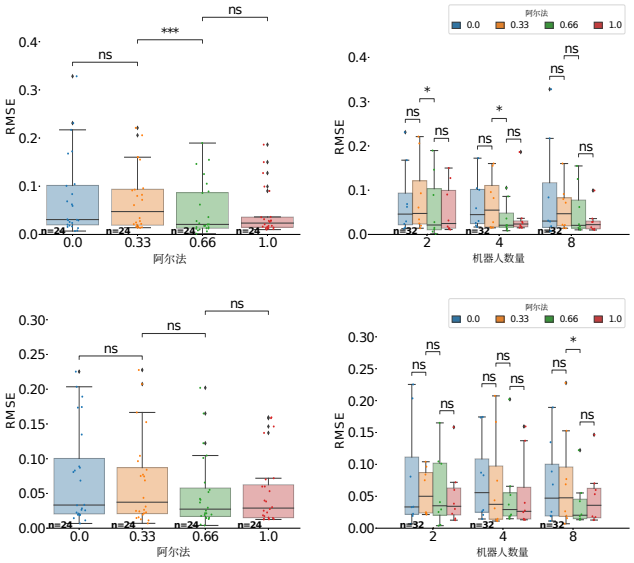


图2：**误差与初始位置分布（α）**。上：无通信。下：随机通信。右：按团队规模进一步细分的结果。上方的柱状标记表示单侧Wilcoxon符号秩检验的显著性；***：$p \leq 1e{-}3$，*：$p \leq 5e{-}2$，ns：无显著性 [34]。

图 2 下排展示了机器人在不同初始位置分散程度下彼此随机通信时的结果。尽管我们在左侧观察到了相同的总体趋势，但在这种情况下，误差并未显著降低。对右侧的结果按团队规模进行控制后，我们再次看到，α 增加会带来性能提升，这体现在中位误差和最大误差均较低。与无通信的情况相比，我们没有观察到 N 对 α 影响存在相同的依赖关系；换言之，α 带来的误差下降在 N 的不同取值下似乎相对相似（从相对中位误差和最大误差可以看出）。此外，我们注意到，对于 $N = 8$，从 $\alpha = 0.33$ 到 0。66 的误差下降具有统计显著性（T=33，p≤0.05）。根据这些结果，如果机器人必须部署在彼此附近但无法通信，那么小型机器人团队可能与大型团队表现相当，反之亦然；无法通信的小团队无需分散得很远也能有效工作。另一方面，在机器人之间无法通信时，较大的分散程度与较大的团队规模相结合会带来益处，但分散程度继续增大时收益将会有限。如果启用通信，较大的分散程度通常总是有益的（尽管同样会出现收益递减），无论团队规模如何。

B. 规划预算

观察图3左侧的最大误差表明，总体而言，更大的 B_T 会带来更好的性能，这是意料之中的。然而，我们从右侧观察到，性能提升实际上来自 N 的增加，而不是 B_T的增加，这有些出人意料（较高的 N对应较低的中位数误差）。

为进一步探究这一问题，我们控制总路径长度

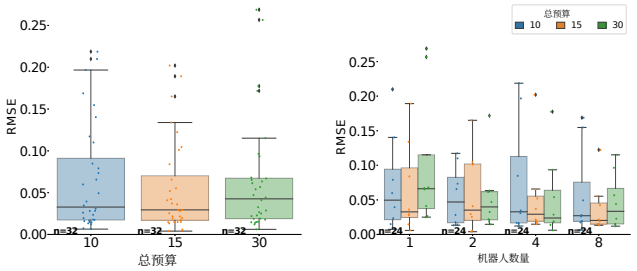


图3：**误差与预算（规划步数 B_T）**。右侧展示了按团队规模进一步细分的相同结果。

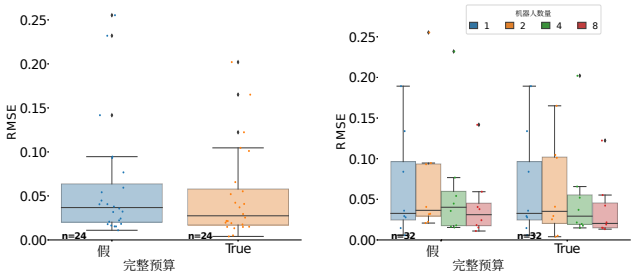


图4：**误差与预算类型（共享与完整）**。这里，$B_T = 15$。左：共享预算表示合并后的预算对于任何 N均为 B_T，而完整预算表示预算为$N \cdot B_T$。请注意，此处未包含 $N = 1$ 数据，因为预算类型不会产生影响。右：相同的结果，进一步按团队规模细分。显示 $N = 1$ （蓝色）以供比较。

$\sum_n B_n$ 并在图4中展示共享预算和完整预算下的结果。在本实验中，使用 $B_T = 15$ 和 $\alpha = 0.66$ 时，共享预算与完整预算的性能相近，这再次有悖直觉，因为我们通常会预期完整预算能带来改进。然而，当我们进一步控制右侧所示的 N时，便发现了实际效果。采用完整预算时，机器人数量增加（即步数增多）同样会带来更好的性能，这符合预期。值得注意的是，尽管所有情况下的误差中位数相近，但在总路径长度保持不变时，最大误差也有所改善。这一点尤其显著，因为在 $N = 8$ 情况下，这意味着每个机器人最多只能执行2步。根据这些结果，即使预算受限（例如受时间、路径长度限制），使用更多机器人似乎也优于让一个机器人拥有更大的预算。

C. 通信

图5展示了机器人团队采用不同通信方式时的分位数估计误差。请注意，右侧将单机器人情形作为基线纳入。左侧显示，总体而言，所有通信类型的中位性能与无通信时大致相同。不过，更多通信确实能提升性能，这一点可从较小的上四分位误差看出。这可能是因为机器人能够避免对不相关位置进行重复测量。

在右侧可以看到，与无通信相比，随机通信的影响并不大

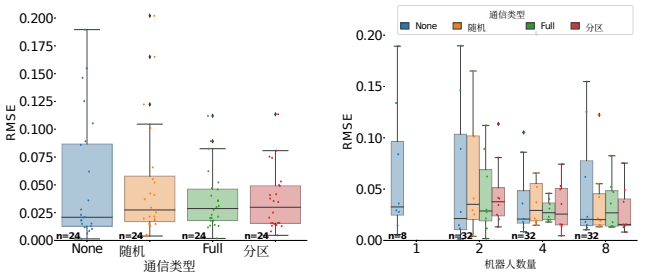


图 5：**误差与通信类型的关系**。 左：按不同的 N 汇总。注意，不包括 $N = 1$ 的结果，因为它们不受变化影响。右：按团队规模进一步细分的结果。纳入 $N = 1$ 以作比较。

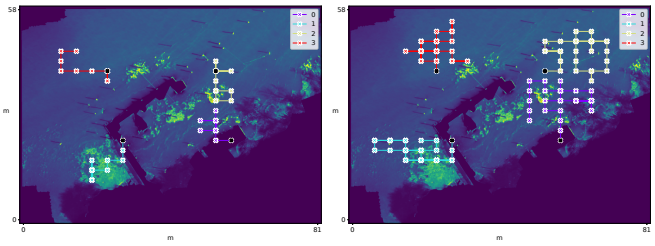


图 6：一个四机器人团队使用 $B_T = 10$（左）和 $B_T = 30$（右）的路径示例。

当 $N = 2$ 为 4 时，从相近的中位数误差和上四分位误差中也可以看出这一点。在 $N = 8$处，我们看到，无通信情况下的上四分位误差和最大误差都高得多。这表明，对于规模更大的团队，启用通信更有益处。我们还看到，总体而言，分区所达到的中位数误差与随机通信或完全通信时相近；对于规模更大的团队，其最大误差也尤其相近。鉴于此处的分区情况使用了 $\alpha = 1.0$ 而不是 0.66，这表明，如果整个区域都可以用于部署机器人但无法进行通信，那么进行空间分区是一种有效策略。根据这些结果，即使通信并不完美，启用机器人间通信也能提升性能，并且对于规模较大的团队尤其有益。

最后，我们展示了这些实验中生成的一些规划方案，以可视化图 6 和图 7 中的任务。机器人以不同颜色显示，其生成的路径则以相连的叉号表示。初始位置以黑色标出。如果机器人进行了分区，则用白线标示分配区域。图像背景是无人机先前在真实水生环境中采集的高光谱图像的正射影像。

VI. 讨论

现在，我们总结从所呈现结果中得出的主要结论，以及这些结论可能如何影响不同的野外机器人技术配置和未来工作。

关于初始位置分布，当 N 较大时，较大的分布似乎有益，但当 N 较小时则并非如此。此外，增大分布带来的收益有限。这些信息在规划实际野外部署时可能尤其有价值，因为将许多机器人部署到空间分布各异的区域需要耗费时间和资金，

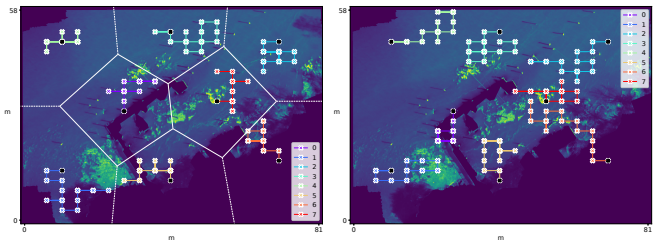


图7：采用分区（左）和无通信（右）策略的8机器人团队路径示例。

避免不必要的成本至关重要。此外，如果调查资源或设置使 α 受到限制而只能取很低的值，那么增加机器人数量或许有助于恢复部分性能。

值得注意的是，就预算 B_T而言，在固定N 的情况下，更大的预算本身并不会显著提升性能（假设初始分布适度）。相反，我们观察到性能对 N 本身的依赖更强；因此，相比一台 B_T 等于所有机器人总预算的单个机器人，更多台各自预算受限的机器人可能会产生更好的分位数估计。

我们的结果还表明，启用通信通常有利于分位数估计问题，尤其是对于较大的群体。我们注意到，将空间分区为互不相交区域并限制每个机器人仅在一个区域内活动，可能是一种有效的替代策略，特别是在无法进行机器人间通信的情况下。

展望未来，考虑能够顾及消息潜在效用的通信协议，或基于特定硬件能力的更细致通信模型，将会很有意义。我们也对其如何扩展到更大团队规模感兴趣。在湖泊监测及其他环境监测任务的背景下，通常不会部署群体；然而，对于大规模研究而言，了解这种影响可能会有所帮助。

在实践中，科学家团队需要权衡降低误差的益处，以及为特定应用获取、协调和部署更多机器人的可行性。

VII. 结论

在这项工作中，我们首次研究了用于环境分析的多机器人分位数估计。我们考察了多台机器人对分位数估计精度的影响，以及初始位置分布、规划预算和通信的作用。我们衡量了不同参数组合在分位数值估计误差方面的表现，并进一步提供了统计结果，以量化观察到的差异是否显著。这项工作是迈向刻画有效环境分析多机器人系统要素的重要第一步，有望帮助有意开展大型或协作调查项目的科学家，更好地了解不同实验设计选择的优缺点。进而，这或许能够改进环境监测和保护工作。

参考文献

[1] S. Kemna、O. Kroemer 和 G. S. Sukhatme，《自适应信息采样的试点调查》，载于 ICRA，2018年。[2] W. H. O. Institution，《有害藻华：了解其威胁及应对举措》，2022年。[3] I. M. Rayas Fern´andez、C. E. Denniston、D. A. Caron 和 G. S. Sukhatme，《用于环境分析的分位数估计信息路径规划》，IEEE机器人与自动化快报，第7卷，第4期，第10 280–10 287页，2022年。[4] B. Seegers、J. Birch、R. Marin、C. Scholin、D. Caron、E. Seubert、M. Howard、G. Robertson 和 B. Jones，《通过整合自主滑翔机、系泊式环境样品处理器和卫星遥感，观测南加州表层有害藻华的地下播种：有害藻华的地下播种》，湖沼学与海洋学，2015年。[5] A. C. Mehinto、J. Smith、E. Wenger、B. Stanton、R. Linville、B. W. Brooks、M. A. Sutula 和 M. D. A. Howard，《淡水生境中蓝藻毒素生态毒理学研究综述——评估制定保护美国水生生物阈值的依据》，总体环境科学，2021年。[6] Y. Zhang、B. Kieft、B. W. Hobson、J. P. Ryan、B. Barone、C. M. Preston、B. Roman、B.-Y. Raanan、R. Marin III、T. C. O’Reilly、C. A. Rueda、D. Pargett、K. M. Yamahara、S. Poulos、A. Romano、G. Foreman、H. Ramm、S. T. Wilson、E. F. DeLong、D. M. Karl、J. M. Birch、J. G. Bellingham 和 C. A. Scholin，《利用远程自主水下航行器，在外海涡旋中自主追踪并采样深层叶绿素最大值层》，IEEE海洋工程期刊，2020年。[7] S. L. Sharp、A. L. Forrest、K. Bouma-Gregson、Y. Jin、A. Cort´es 和 S. G. Schladow，《利用多平台遥感工具量化大型富营养化湖泊中蓝细菌空间变异性的尺度》，环境科学前沿，2021年。[8] C. E. Denniston、G. Salhotra、D. A. Caron 和 G. S. Sukhatme，《基于部分可观测马尔可夫决策过程并考虑特定领域因素的自适应采样》，载于 ICRA，2020年。[9] M. Toussaint，《贝叶斯搜索博弈》，载于《元启发式算法设计的理论与原则方法》，Y. Borenstein 和 A. Moraglio 编，2014年。[10] R. Marchant、F. Ramos 和 S. Sanner，《用于时空监测的序贯贝叶斯优化》，载于 UAI，2014年。[11] A. Howard，《利用粒子滤波器实现多机器人同步定位与建图》，国际机器人研究期刊，第25卷，第12期，第1243–1256页，2006年。[12] A. Howard、L. E. Parker 和 G. S. Sukhatme，《大型异构移动机器人团队的实验：探索、建图、部署与检测》，国际机器人研究期刊，第25卷，第5–6期，第431–447页，2006年。[13] G. Sartoretti、Y. Wu、W. Paivine、T. Kumar、S. Koenig 和 H. Choset，《用于多机器人去中心化协同建造的分布式强化学习》，载于《分布式自主机器人系统》，施普林格，2019年，第35–49页。[14] H. Wang、M. Lewis、P. Velagapudi、P. Scerri 和 K. Sycara，《搜索及其子任务如何随机器人数量扩展》，载于第四届 ACM/IEEE人机交互国际会议论文集，2009年，第141–148页。[15] P. Velagapudi、P. Scerri、K. Sycara、H. Wang、M. Lewis 和 J. Wang，《多机器人控制中的规模效应》，载于《2008年 IEEE/RSJ智能机器人与系统国际会议》。IEEE，2008年，第2121–2126页。[16] A. Rosenfeld、G. A. Kaminka、S. Kraus 和 O. Shehory，《提升机器人群体性能的机制研究》，人工智能，第172卷，第6–7期，第633–655页，2008年。[17] A. Rosenfeld、G. A. Kaminka 和 S. Kraus，《机器人团队边际性能特性研究》，2004年。[18] C. Stachniss、 ´O. Mart´ınez Mozos 和 W. Burgard，《利用移动机器人团队高效探索未知室内环境》，数学与人工智能年鉴，第52卷，第2期，第205–227页，2008年。[19] M. Corah 和 N. Michael，《用于多机器人探索的分布式拟阵约束次模最大化：理论与实践》，自主机器人，第43卷，第2期，第485–501页，2019年2月。[20] C. Guestrin、A. Krause 和 A. P. Singh，《高斯过程中的近最优传感器布设》，载于*ICML*，2005年。[21] N. Cao、K. H. Low 和 J. M. Dolan，《用于环境现象主动感知的多机器人信息路径规划：两种算法的故事》，*arXiv* 预印本 *arXiv:1302.0723*，2013年。[22] A. Dutta、A. Ghosh 和 O. P. Kreidl，《具有连续连通性约束的多机器人信息路径规划》，载于*2019*年国际机器人与自动化会议（*ICRA*）。IEEE，2019年，第3245–3251页。[23] K.-C. Ma、Z. Ma、L. Liu 和 G. S. Sukhatme，《用于持续环境监测的多机器人信息型自适应规划》，载于分布式自主机器人系统。施普林格，2018年，第285–298页。[24] A. Dutta、A. Bhattacharya、O. P. Kreidl、A. Ghosh 和 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杂志》，第17卷，第6期，页码1729881420970461，2020年。[25] S. Kemna、J. G. Rogers、C. Nieto-Granda、S. Young 和 G. S. Sukhatme，《通过动态 Voronoi 分区实现多机器人协调，以便在受限通信环境中进行信息型自适应采样》，载于*2017*年 *IEEE* 国际机器人与自动化会议（*ICRA*）。IEEE，2017年，第2124–2130页。[26] G. Hollinger 和 S. Singh，《具有周期性连通性的多机器人协调》，载于*2010*年 *IEEE* 国际机器人与自动化会议。IEEE，2010年，第4457–4462页。[27] L. Pan、S. Manjanna 和 M. A. Hsieh，《Marlas：用于协作自适应采样的多智能体强化学习》，*arXiv* 预印本 *arXiv:2207.07751*，2022年。[28] M. S. Talamali、A. Saha、J. A. Marshall 和 A. Reina，《少即是多：受限通信下机器人群更能适应变化》，《科学·机器人学》，第6卷，第56期，文章编号eabf1416，2021年。[29] H. L. Kwa、J. Philippot 和 R. Bouffanais，《群体密度对集体跟踪性能的影响》，《群体智能》，第1–29页，2023年。[30]Z. N. Sunberg 和 M. J. Kochenderfer，《具有连续状态、动作和观测空间的部分可观测马尔可夫决策过程在线算法》，载于第二十八届国际自动规划与调度会议，2018年。[31] S. Lloyd，《脉冲编码调制中的最小二乘量化》，《*IEEE* 信息论汇刊》，第28卷，第2期，第129–137页，1982年。[32] L. Clark、J. Galante、B. Krishnamachari 和 K. Psounis，《网络化多机器人探索的队列稳定框架》，*IEEE*机器人与自动化快报，第6卷，第2期，第2091–2098页，2021年。[33] F. Wilcoxon，基于秩排序方法的个体比较。施普林格，1992年。[34] F. Charlier、M. Weber、D. Izak、E. Harkin、M. Magnus、J. Lalli、L. Fresnais、M. Chan、N. Markov、O. Amsalem、S. Proost、A. Krasoulis、getzze 和 S. Repplinger，《Statannotations》，2022年10月。[在线]。获取地址：https://doi.org/10.5281/zenodo.7213391