

基于显著区域的探索前沿偏置

Matteo Luperto^{1*}, Valerii Stakanov^{1,2}, Giacomo Boracchi², Nicola Basilico¹, and Francesco Amigoni²



Fig. 1: 并非所有的前沿区域对探索来说都同样重要；有些可以导致完成房间内的局部探索，而其他则可以将机器人引导到建筑物的完全不同部分。我们将显著区域识别为对探索有高度兴趣的区域，并用浅蓝色标出，并将这一理念整合到不同的探索策略中。

Abstract—自主探索是一个广泛研究的问题，其中机器人逐步构建一个先前未知环境的地图。机器人使用探索策略选择下一个要到达的位置。为此，机器人必须在一些竞争性目标之间取得平衡，例如尽可能快地探索整个环境。大多数探索策略试图最大化已探测区域以加快探索速度；然而，它们没有考虑到环境中的某些部分比其他部分更重要，因为它们能导致发现大片未知区域。我们提出了一种方法，通过使用从神经网络获得的显著性地图来识别显著区域，这些区域是对探索具有高兴趣的区域。该神经网络根据当前地图实现一个终止标准，以估计环境是否可以被认为是已被完全探索。我们利用显著区域来影响一些广泛使用的探索策略，通过广泛的实验活动表明，这种知识可以显著影响机器人在探索过程中的行为。

I. 介绍

探索是自主移动机器人领域中广泛研究的问题，涉及机器人通过迭代规划和执行一系列动作来构建未知环境的地图。尽管近年来提出了一些基于学习的方法 [1]，探索通常通过遵循“下一步最佳视图” (NBV) 方法进行 [2]：给定当前的地图，机器人计算一组候选位置，并根据探索策略选择最有前途的位置。在这项工作中，我们将前沿，即已知空间与未知空间之间的边界，视为候选位置，以便在探索中取得进展 [3]。在机器人到达最有前途的前沿后，它将获得的知识整合到其地图中，并重复此过程，直到满足终止标准。

探索的目标是最终构建环境的地图 [4]。然而，为了实现这样的目标，机器人需要在至少两个相互竞争的目标之间取得平衡。一方面，地图应该覆盖环境的全部。另一方面，需要高效地探索环境，从而最小化探索时间和机器人的总路径长度。在这种情况下，几项工作 [5]–[9] 展示了如何平衡这两个需求远非简单。探索策略如 [3]，它倾向于首先探索机器人位置周围的环境，这种策略会系统地缓慢地增加已映射的区域。更具攻击性的环境探索策

略会选择可能离机器人当前位置较远的高潜力地点，并可能在探索的早期阶段获得较高的映射面积百分比，但也可能导致环境中若干部分区域被部分探索，因此在过程的后阶段迫使机器人回溯到先前访问过的位置 [5]。选择哪种探索策略更好使用也隐含地受到终止标准 [10] 的影响，该标准决定何时应认为探索过程完成。在某些应用中，当过程不再获取相关信息时，例如，当没有超过最小长度的前沿可以被探索时，探索会停止 [7]。这通常发生在主要目标是实现地图的完全覆盖的情况下。在这种情况下，最好使用首先探索机器人周围环境的探索策略，然后再到地图的其他部分。在其他操作环境中，例如城市搜救 [11]，探索过程在预定（通常很短）的时间后停止，因为应用需要快速向人类救援者提供（可能不完整的）环境信息。在这些环境中，常常使用那些即使离机器人当前位置很远也试图首先到达高信息量前线的探索策略。

在大多数研究中，机器人使用的探索策略和用于停止探索的终止标准被视为两个独立的方法。因此，机器人的行为不受机器人接近（或不接近）探索终点这一事实的影响。

某些探索策略通过估计当机器人到达边界时可见的新区域的数量，假设那些导致映射区域期望增量最大的边界对机器人来说是更好的选择。这种估计通常被称为信息增益。选择高信息增益的边界会引导机器人向开放区域的大边界移动，从而增加快速扩展已映射区域的可能性。然而，尽管信息增益考虑了从目标位置可以观察到的期望区域量，但它没有考虑到环境中的所有区域并不都同等重要 [12]。例如，位于走廊和小房间的两个边界可以有相似的信息增益；然而，首先探索走廊可以引导机器人到达环境中一个全新的未探索部分，从而发现其他高信息量的边界。同时，在房间内探索边界较不可能引导机器人发现新的边界。

在 [10] 中，我们提出了一种方法，如果估计出环境中未映射的部分被认为是不具信息性的，就会停止探索过程。这在探索运行的后期阶段是一种常见情况，此时机器人需要很长时间来探索覆盖其总面积仅为 1 或 2% 的小角落或部分，而不会向映射过程添加额外知识。

在本文中，我们最初使用方法 [10] 的副产品来估计地图中哪些部分对于将地图分类为未探索最为相关。从直觉上看，当还有多个前沿区域需要探索时，我们估计探索过程的进展，并突出显示那些仍需探索的地图部分。我们称这些区域为显著区域。一个例子如图 1 所示：虽然整个环境中还有几个前沿区域，但我们识别出地图底部的走廊（浅蓝色）是最有希望的探索区域，以到达建筑物中新较大未探索部分。

因此，我们提出了一种使用终止准则中获取的知识来偏向探索策略的方法，从而使这两种方法能够互相影响。这样，我们通过根据探索过程的状态调整选择来修改探

索策略。我们展示了一些反直觉的实验结果，对于某些探索策略而言，给访问非常有前途的前沿加上负偏置（需要支付的代价）可能是机器人更好的选择。

我们的贡献如下：(1) 我们提出了一种方法，通过使用该方法的副产品 [10] 来提取探索的显著区域；(2) 我们扩展了不同的探索策略，以利用显著区域的概念；(3) 我们进行了广泛的实验评估，使用模拟环境来研究显著区域的知识如何影响和改变广泛使用的探索策略的行为。

II. 相关工作

自主探索的主要目标是获取最初未知环境的地图，通常认为这个环境是静态的。最近的一个调查 [13] 很好地覆盖了该领域内的广泛文献。除了获得完整地图的目标外，通常还有其他的需求，例如最大化机器人构建的地图的质量 [14] 或在给定时间内映射区域的数量 [15]。探索策略通常通过结合机器人当前位置的距离（即机器人需要支付的成本）和预期的信息增益（IG，即机器人在访问边界时可以获取的关于环境的新信息的估计值）来对边界进行排序。然而，一些工作 [5]–[9] 指出了如何平衡这两种需求并非易事。探索策略倾向于总是达到最近的边界 [3]，因此不考虑信息增益，可能会构建覆盖大部分环境的地图，但通常较慢，因为它们转移到更有趣且信息丰富的边界前彻底探索了机器人位置的周围。探索策略倾向于选择信息增益较高（同时也考虑其距离）的边界，通常能够快速探索建筑物的大部分区域，但之后会迫使机器人回溯到之前访问过的位置，留下信息增益较低的边界。最终，倾向于早期快速探索的策略可能需要比执行更系统探索的策略更长时间以完全探索环境 [2]。

早期的工作使用乐观的方法来估计每个前沿的信息增益，例如假设前沿之外所有未映射的区域都是空的 [16]，或者使用一些启发式方法，例如考虑较长的前沿更有前途，即具有更高的信息增益 [2], [17]。

最近的一些方法 [6], [18]–[24] 侧重于在给定环境的部分 2D 地图的情况下，预测环境未观察部分的合理理论（但可能不准确）状态。尽管这些方法的细节差异很大，其一般方法可以总结如下：通过机器人获得的当前地图被输入到一个模型中，该模型利用了室内环境存在某些规律性 [25]。然后使用该模型预测环境中未被机器人绘制部分的合理理论（但可能不准确）状态。预测的地图用于为探索过程提供信息，因为它可以让机器人更好地估计每个前沿的信息增益。因此，机器人在探索的早期阶段可以更快地探索大面积区域，但在后期阶段需要更多的回溯。地图的预测通常使用深度学习修复方法，例如 [6], [19]–[24] 中所示，或者基于特征的方法 [18]。为了应对预测地图可能不准确的情况，一些方法会产生同一环境的不同配置估计，并使用它们来获得信息增益的概率估计 [22]。这些工作的一个局限性是，由于在现实环境中或带有噪声的传感器读数情况下预测地图的未见部分是困难的，因此大多数这些工作都是在空环境的干净地图中设计、训练和测试的，假设机器人的感应、导航和定位完美无误 [20], [22]–[24]。

尽管大多数研究集中在探索策略上，但有一些工作指出，决定何时停止探索是一个特别相关但未被充分研究的问题 [7], [14]。在 [7] 中，作者概述了常见的停止标准并讨论了其局限性。一个简单的方法是在预设的时间预算耗尽后停止探索 [26]，但这种方法不能保证生成的地

图是完整的。其他工作建议在没有候选位置剩余时结束探索 [3]，这确保了地图的完整性，但经常导致较长的探索时间。有些方法在环境的某一百分比被映射后停止探索 [15]，因此需要知道环境的总大小，或者当不同时刻生成的地图几乎相同时停止 [27]，表明没有新区域被观察到。在这些工作中，探索策略不受机器人接近（或不接近）探索结束这一事实的影响。

在信息论方法中，终止标准与探索策略是紧密联系在一起的，比如那些基于地图熵的 [7], [28]；这些方法建议在熵下降到某个阈值以下或达到饱和时停止探索，并使用相同的熵度量来驱动探索。终止标准与探索策略之间的紧密联系使得将这些方法与其他策略（如基于前沿的探索）结合起来变得困难。

在我们的工作中，我们不使用任何地图预测来估计信息增益，而是利用从终止标准中检索到的知识来指导探索策略。由于我们的方法仅依赖于地图的可用性，因此可以与不同的探索策略相结合。

III. 提出的方法

在本文中，我们考虑一个自主移动机器人，它使用基于前沿的探索策略 [3] 来探索一个最初未知的二维环境。在探索过程中，机器人可以访问当前探索过程状态的评估，这被用作终止标准 [10]。

终止标准在地图中识别显著性区域。我们将在第 III-B 节详细介绍这一过程。显著性区域表示环境中更为重要的部分，这些部分的探查对于达到结束探索的目标更为关键，因此会触发终止标准。本文的目标是研究对这些区域的了解是否可以指导不同的探索策略。

为此，我们关注三种不同的探索策略，这些策略代表了基于边界探索的不同方法族（第 III-A 节）。然后，通过在边界评估中添加一个代表其相对于整个探索过程的显著性的附加项，我们扩展了这些策略（第 III-C 节）。

A. 基于前沿的探测

一个使用前沿探索的机器人迭代更新一个代表机器人可感知空间的二维度量地图 M ，我们假设它是一个网格地图。 M 的每个单元格可以是空闲的、障碍物的或未知的。机器人从当前地图 M 中识别出前沿集 F 。前沿是一连串邻接于未知单元格的空闲单元格。机器人通过最大化一个效用函数来选择最佳前沿 $f^* \in F$ ：

$$u(f) = \alpha \cdot IG(f) - (1 - \alpha) \cdot dist(f), \quad (1)$$

其中 $IG(f)$ 是前沿的信息增益， $dist(f)$ 是其质心到机器人的距离， $\alpha \in [0, 1]$ 参数在这两个因素之间平衡。注意虽然 $dist$ 是需要机器人最小化的成本，而 IG 是需要最大化的增益。 IG 和 $dist$ 都在 $[0, 1]$ 中使用它们在 F 的前沿中的最大值和最小值进行归一化。

根据此功能，探索策略优先考虑邻近且有潜力的前沿，因为这些区域更可能揭示出大面积的未知空间。在选择前沿 f^* 之后，机器人规划并沿着一条路径前往 f^* 的中心，在旅行过程中用新获取的传感数据更新地图。我们考虑三种不同的探索策略，以代表不同的方法。

首先，我们考虑一种最近前沿探索策略（NF）[3]，其中 $\alpha = 0$ ，因此机器人在选择下一个要访问的前沿时不考虑信息增益。该策略始终选择最近的前沿。

然后，我们考虑第二种策略，它使用从前沿的质心可能观察到的空间来估计信息增益，如同 [2] 中的做法，因此




Fig. 2: 在环境 e_1 的不同探索阶段的显著区域。(c) 中为完整地图。

我们将其标记为 IG 。我们对信息增益的估计是乐观的，因为它假设机器人传感器覆盖范围内每个前沿之外的未观察区域是空的，并且可以被全部观察到。与 NF 相比，该策略能够快速增加机器人观察到的区域，但最终导致环境全面覆盖所需的时间更长 [9]。我们设置 $\alpha = 0.5$ 。

最后，我们考虑第三种策略，称为 IG^* ，它通过更准确地估计越过边界的地图状态来预测边界的信息增益。最近一些方法提出了这个想法，即预测环境中未知部分的状态，并利用这种预测来估计从边界中心可观测的区域面积。通过这种方式，估计的信息增益比 IG 更准确且不那么乐观。从经验上看，这些方法在探索运行的早期阶段显著加速，但代价是在结束时回溯以观察信息增益较低的边界 [5]。我们假设信息策略 IG^* 拥有最佳的知识，即我们使用环境的完整地图来计算每个边界的精确信息增益，从而模拟出一个完美的地图预测方法。此外，对于 IG^* ，我们设置 $\alpha = 0.5$ 。

B. 估计探索运行的进展

机器人依靠 [10] 中提出的方法，并使用描绘当前栅格地图的图像来检测其是否令人满意地代表整个环境。分类输出定义了终止标准。这里我们简要介绍该方法；详细信息请参阅 [10]。

该分类模型基于卷积神经网络 (CNN)。终止判据被建模为一个视觉识别问题，其中的分类任务是区分仍然为 *not-explored* 的地图和那些已经足够 *explored* 的地图。我们从一个地图数据集开始，标记为 *not-explored* 的是那些人类（知道环境的完整地图）会认为不完整的地图，因为它们缺少感兴趣的区域，比如整个房间或环境的相关部分。然后，我们将人类认为足够完整以代表整个环境的地图标记为 *explored*。注意，在标记为 *explored* 的地图中，环境的小部分（如角落）可能还没有完全被映射，但这些部分被认为不重要，即使这些部分缺失，映射过程也可以停止。通常，超出这些剩余前沿的地图可以从已知的地图部分 [20], [29] 中轻松估计出来，如在房间的角落尚未完全探索的情况下，但其周围的其他墙壁和房间已经被知晓的情况下。一张 *explored* 地图的示例如图 6 所示。

我们使用 EfficientNet B1 [30] 作为 CNN，该模型在

ImageNet [31] 上进行了预训练，并在大约 20,000 张地图的数据集上进行了微调，该数据集是在不同的探索运行期间收集的，并被自动标记为 *explored* 或非 *explored*。

该方法的输出是一个标签，用于指示地图是 *not-explored* 还是 *explored*，进而决定探测活动是应该继续还是可以停止。然后，我们利用训练好的 CNN 分类器上的显著性图来设计新的探测策略。显著性图，如 Grad-CAM [32]，是一种可解释性技术，它为每幅输入图像提供一个热图，突出显示主要影响网络决定特定类别的区域。因此，与类别 *not-explored* 相关的显著性图可以建议在探测中优先考虑哪些区域，如图 1 所示。我们称这些区域为显著性区域。这些显著性区域在探测过程中会不断演变和变化，如图中 3a，1，和 2 a-b 所示，展示了来自同一探测运行的四张地图。在探测的早期阶段（图 3a），模型突出了大多数前沿地区；随着探测的进展（图 2 a-b），只有那些位于未探测房间或导致环境中新未观察部分的前沿被突出显示。最后，图 2 c 展示了被标记为 *explored* 时的地图。我们可以看到，在探测运行的不同阶段，显著性区域可以突出显示环境中最重要的部分进行探测：在探测的早期阶段，所有的前沿区域都是同等重要的，而在后期阶段，只有那些通向环境新部分的前沿被突出显示。

C. 用显著性图引导探索

为了利用显著性区域来告知不同的探索策略，我们在方程 1 描述的框架中引入了一个新项，即

$$u(f) = \alpha \cdot IG(f) - (1 - \alpha) \cdot dist(f) + \beta \cdot S(f), \quad (2)$$

其中 β 是权重， $S(f)$ 评估前沿的显著性。

Grad-CAM [32] 的输出是一个与地图图像大小相同的掩码，值在 $[0, 1]$ 范围内，其中不相关区域的值为 0。该掩码的一个例子如图 3a 所示。在 Grad-CAM 图像上应用阈值 $\theta = 0.1$ ，将所有低于 θ 的值设为 0。然后，我们使用连通分量分析识别地图中所有非零区域，找到所有显著性区域的形状。该阈值步骤的结果如图 3b 所示。对于每个显著性区域，我们找到其 Grad-CAM 的平均值，并将该值用于整个区域。最后，通过在显著性图中投影前




Fig. 3: GRAD-Cam 输出 (a) 和显著性区域 (b)。




Fig. 4: $S(f)$ 的值的分布。

沿的重心并使用相应显著性区域的值来计算 $S(f)$ 。图 4 显示了一个地图的 $S(f)$ 的经验分布，其范围为 $[0, 0.25]$ ，平均值为 0.15。注意，在显著性区域内的前沿 f ，即使其具有 $S(f) = 0$ ，机器人仍然可以访问，并且不会被丢弃。此外，当地图更新并重新计算显著性图时，相同前沿的值 $S(f)$ 可以发生变化。

IV. 实验评估

在本节中，我们对如何使用显著性区域可以为不同的探索策略提供信息进行了广泛的实验评估。

A. 实验设置

我们使用来自数据集的三个不同的大规模模拟环境，这些环境代表了 MIT+KTH 校区 [27]，其地图显示在图 2c（环境 e_1 ）和图 5（环境 e_2 和 e_3 ）中。我们使用 ROS，在 STAGE 中模拟了一个 Turtlebot3 机器人，并配备了一个范围为 10m 和视野为 360° 的 2D LiDAR，具有真实模拟的传感器读数和机器人运动噪声。我们使用 [33] 进行 SLAM，并使用 ROS 导航栈进行导航。实验在配备 i7-7700 CPU 和 1060 GPU 的计算机上、配备 i7-7400 CPU 和 1050 GPU 的计算机上，以及配备 Ryzen7 5700 CPU 和 3060Ti GPU 的计算机上进行。来自 [10] 的 Grad-CAM 实时处理地图，并与 ROS 导航栈集成。

我们测量覆盖面积 A 的百分比和机器人行驶距离随时间的变化。为了简洁起见，我们仅报告时间，因为时间与距离成比例。我们用 A_x 表示覆盖地图总面积 $x\%$ 所需的时间。我们还记录当从 [10] 触发终止准则时的时间 T 。我们在每种环境的每种配置下进行 5 次运行，报告平均值和标准差。我们继续探索，直到所有可达的边界都被探索完。只有当从 [10] 的终止准则未被触发时，显著性图才可用，因为它们是为标记为 not-explored 的地图获得的。在地图被标记为 explored 之后，我们使用最



Fig. 5: 用于实验的三个环境中的两个。




Fig. 6: 我们系统在 ROS 中的一个示例，其中地图根据我们的终止标准被视为 explored。在这种情况下，使用最后一个 not-explored 地图中的显著性图来计算 $S()$ 。

后可用的显著性区域，因为它们仍然指示了有潜力的边界所在的区域。图 6 中展示了一个示例。

B. 实验结果

我们评估了方程 2 中不同 β 值如何影响第 III-A 节中三种不同探索策略的性能。我们用 $+S(\beta)$ 来表示使用显著图并赋予其一个给定 β 值的探索策略。表 I 显示了结果；我们用粗体标出每种探索策略的最佳值，并在蓝色中标出总的最佳值。图 ?? 展示了 e_1 的 A 随时间的进展。

我们测试了不同的 $\beta = \{-2, 1, 2, 4\}$ 值。由于显著性区域代表了环境中需要重点探索的部分，方程 2 中的 β 取正值会偏向于让机器人在短期内最大化已探索区域，从而推动机器人前往环境中未探索的部分。因此，正值的 β 会强化由 IG 引发的激进行为。相反，负值的 β 会推动机器人首先充分探索其周围环境，为机器人探索具有高显著性的新领域设定了代价，这些新领域可能会引导其探索环境中大量未访问的部分。

总体而言，表 I 的结果表明，使用显著性区域对所有探索策略都可以产生相关的积极影响，因为它可以使机器人识别出哪些前沿区域会引导到环境中非常有前景的未探索区域，而哪些不会。

当我们考虑 NF 时， β 的正值使机器人能够表现得类似于使用 IG 的方法，从而允许机器人更快地达到更高百分比的探索区域（达到 A_{70} ），但代价是在探索的后期阶段需要回溯。

Env.	Strategy	A_{30}	A_{50}	A_{70}	A_{90}	A_{95}	A_{99}	$\bar{T}$
e_1	NF	289,20 $\pm$ 118,98	535,60 $\pm$ 109,07	793,40 $\pm$ 131,18	1145,20 $\pm$ 193,76	1365,60 $\pm$ 331,53	1560,20 $\pm$ 256,52	-
	NF+S(1)	210,20 $\pm$ 43,81	393,60 $\pm$ 86,71	636,40 $\pm$ 124,14	935,00 $\pm$ 107,42	1245,80 $\pm$ 348,56	1603,40 $\pm$ 232,08	1389,20
	NF+S(2)	244,20 $\pm$ 50,77	465,40 $\pm$ 100,21	724,80 $\pm$ 106,34	1210,60 $\pm$ 208,06	1367,80 $\pm$ 140,51	1657,40 $\pm$ 211,85	1478,60
	NF+S(4)	210,60 $\pm$ 24,39	457,00 $\pm$ 83,54	754,80 $\pm$ 187,63	1241,20 $\pm$ 216,32	1479,80 $\pm$ 165,90	1731,60 $\pm$ 242,27	1560,60
	NF+S(-2)	198,20 $\pm$ 47,89	457,20 $\pm$ 169,46	646,00 $\pm$ 159,82	980,80 $\pm$ 286,77	1127,40 $\pm$ 241,33	1282,40 $\pm$ 226,39	1106,80
	IG	198,20 $\pm$ 45,53	712,80 $\pm$ 533,56	1139,60 $\pm$ 514,49	1549,60 $\pm$ 437,18	1779,60 $\pm$ 586,78	2257,20 $\pm$ 801,66	-
	IG+S(1)	244,40 $\pm$ 46,01	403,20 $\pm$ 53,15	554,20 $\pm$ 52,29	855,80 $\pm$ 101,29	994,00 $\pm$ 168,52	1379,40 $\pm$ 184,71	1053,00
	IG+S(2)	257,20 $\pm$ 87,43	486,60 $\pm$ 116,52	674,80 $\pm$ 78,24	943,20 $\pm$ 104,29	1077,20 $\pm$ 105,42	1378,80 $\pm$ 267,88	1118,60
	IG+S(4)	189,00 $\pm$ 70,95	316,00 $\pm$ 60,66	575,40 $\pm$ 38,23	907,60 $\pm$ 139,18	1158,60 $\pm$ 269,09	1774,12 $\pm$ 327,47	1311,80
	IG *	204,00 $\pm$ 47,27	443,33 $\pm$ 108,51	704,67 $\pm$ 111,05	1297,33 $\pm$ 408,39	1410,33 $\pm$ 490,84	1847,83 $\pm$ 885,57	-
	IG * +S(2)	230,00 $\pm$ 54,69	530,20 $\pm$ 163,05	830,80 $\pm$ 179,28	1233,40 $\pm$ 231,70	1488,40 $\pm$ 381,44	1742,80 $\pm$ 387,60	1586,20
	IG * +S(4)	213,60 $\pm$ 45,07	581,00 $\pm$ 184,02	952,60 $\pm$ 253,16	1488,20 $\pm$ 461,78	1653,40 $\pm$ 409,25	1916,20 $\pm$ 572,55	1679,00
	NF	117,50 $\pm$ 59,71	160,33 $\pm$ 77,49	214,50 $\pm$ 59,46	407,50 $\pm$ 48,29	491,00 $\pm$ 65,01	580,83 $\pm$ 69,29	-
	NF+S(1)	56,20 $\pm$ 18,34	81,20 $\pm$ 31,55	139,60 $\pm$ 56,15	327,40 $\pm$ 31,85	398,20 $\pm$ 91,81	493,80 $\pm$ 91,81	398,40
e_2	NF+S(2)	48,00 $\pm$ 0,00	84,80 $\pm$ 9,39	210,20 $\pm$ 109,69	485,80 $\pm$ 101,44	581,60 $\pm$ 102,09	673,60 $\pm$ 90,09	581,80
	NF+S(4)	64,40 $\pm$ 22,46	122,60 $\pm$ 18,78	197,60 $\pm$ 27,12	511,40 $\pm$ 93,65	611,60 $\pm$ 83,38	753,60 $\pm$ 121,08	636,60
	NF+S(-2)	47,00 $\pm$ 0,00	59,40 $\pm$ 18,39	71,80 $\pm$ 9,07	270,40 $\pm$ 34,61	328,00 $\pm$ 37,58	456,00 $\pm$ 76,40	286,40
	IG	84,20 $\pm$ 30,71	133,60 $\pm$ 73,34	154,20 $\pm$ 75,77	439,20 $\pm$ 177,27	513,60 $\pm$ 175,81	629,20 $\pm$ 175,41	-
	IG+S(1)	84,20 $\pm$ 72,02	117,40 $\pm$ 92,04	146,20 $\pm$ 80,36	345,00 $\pm$ 53,50	494,00 $\pm$ 66,06	597,00 $\pm$ 69,31	431,80
	IG+S(2)	80,00 $\pm$ 30,99	88,00 $\pm$ 28,99	108,80 $\pm$ 29,35	278,00 $\pm$ 61,11	381,60 $\pm$ 61,06	481,00 $\pm$ 70,55	340,20
	IG+S(4)	89,20 $\pm$ 162,95	130,60 $\pm$ 94,70	185,20 $\pm$ 63,57	327,00 $\pm$ 45,65	402,40 $\pm$ 38,89	477,40 $\pm$ 43,51	373,00
	IG *	55,80 $\pm$ 18,57	109,60 $\pm$ 48,82	184,40 $\pm$ 47,66	388,20 $\pm$ 83,15	479,40 $\pm$ 142,33	720,80 $\pm$ 185,57	-
	IG * +S(2)	52,20 $\pm$ 9,39	118,40 $\pm$ 47,80	197,60 $\pm$ 53,84	435,40 $\pm$ 61,93	535,40 $\pm$ 91,63	636,00 $\pm$ 131,33	502,40
	IG * +S(4)	288,56 $\pm$ 9,07	126,60 $\pm$ 31,12	222,40 $\pm$ 68,56	494,40 $\pm$ 97,42	590,00 $\pm$ 101,86	669,40 $\pm$ 133,25	510,60
	NF	198,67 $\pm$ 43,99	484,17 $\pm$ 120,75	639,67 $\pm$ 171,15	1074,17 $\pm$ 253,13	1300,17 $\pm$ 264,92	1853,17 $\pm$ 311,92	-
	NF+S(1)	205,60 $\pm$ 41,26	529,40 $\pm$ 92,33	857,20 $\pm$ 108,38	1220,20 $\pm$ 197,36	1522,60 $\pm$ 241,32	1901,80 $\pm$ 436,33	1345,40
	NF+S(2)	205,00 $\pm$ 41,33	567,60 $\pm$ 78,15	905,80 $\pm$ 281,01	1355,80 $\pm$ 246,25	1736,40 $\pm$ 316,32	2478,00 $\pm$ 504,59	1520,00
	NF+S(4)	266,20 $\pm$ 76,58	680,80 $\pm$ 151,54	871,80 $\pm$ 208,36	1387,40 $\pm$ 301,58	1655,20 $\pm$ 259,20	2380,00 $\pm$ 678,52	1685,40
	NF+S(-2)	246,80 $\pm$ 76,87	415,40 $\pm$ 94,84	749,00 $\pm$ 107,90	1091,60 $\pm$ 202,74	1273,00 $\pm$ 55,62	2592,60 $\pm$ 1177,43	1214,00
e_3	IG	204,40 $\pm$ 56,74	386,00 $\pm$ 109,12	584,00 $\pm$ 139,95	1758,20 $\pm$ 1057,47	1876,80 $\pm$ 1026,90	2646,00 $\pm$ 1088,98	-
	IG+S(1)	179,20 $\pm$ 34,51	403,80 $\pm$ 73,61	589,00 $\pm$ 54,46	1090,80 $\pm$ 180,15	1285,60 $\pm$ 229,85	1890,00 $\pm$ 563,90	1216,40
	IG+S(2)	247,00 $\pm$ 77,02	392,60 $\pm$ 71,53	689,00 $\pm$ 157,87	1174,20 $\pm$ 145,49	1342,20 $\pm$ 155,32	1886,20 $\pm$ 307,13	1385,20
	IG+S(4)	204,80 $\pm$ 82,56	386,00 $\pm$ 117,33	688,20 $\pm$ 93,78	1029,60 $\pm$ 221,93	1327,60 $\pm$ 302,20	2521,80 $\pm$ 356,76	1397,20
	IG *	285,40 $\pm$ 67,76	547,60 $\pm$ 118,51	792,80 $\pm$ 131,78	1476,60 $\pm$ 405,61	1661,20 $\pm$ 523,74	2785,80 $\pm$ 840,53	-
	IG * +S(2)	269,20 $\pm$ 100,18	626,60 $\pm$ 166,32	897,60 $\pm$ 204,44	1433,00 $\pm$ 256,23	1682,00 $\pm$ 250,60	2666,80 $\pm$ 429,18	1711,80
	IG * +S(4)	274,00 $\pm$ 76,59	519,60 $\pm$ 49,73	848,40 $\pm$ 152,19	1353,20 $\pm$ 273,89	1579,20 $\pm$ 292,15	2286,20 $\pm$ 410,90	1428,00
	NF	198,67 $\pm$ 43,99	484,17 $\pm$ 120,75	639,67 $\pm$ 171,15	1074,17 $\pm$ 253,13	1300,17 $\pm$ 264,92	1853,17 $\pm$ 311,92	-
	NF+S(1)	205,60 $\pm$ 41,26	529,40 $\pm$ 92,33	857,20 $\pm$ 108,38	1220,20 $\pm$ 197,36	1522,60 $\pm$ 241,32	1901,80 $\pm$ 436,33	1345,40
	NF+S(2)	205,00 $\pm$ 41,33	567,60 $\pm$ 78,15	905,80 $\pm$ 281,01	1355,80 $\pm$ 246,25	1736,40 $\pm$ 316,32	2478,00 $\pm$ 504,59	1520,00
	NF+S(4)	266,20 $\pm$ 76,58	680,80 $\pm$ 151,54	871,80 $\pm$ 208,36	1387,40 $\pm$ 301,58	1655,20 $\pm$ 259,20	2380,00 $\pm$ 678,52	1685,40
	NF+S(-2)	246,80 $\pm$ 76,87	415,40 $\pm$ 94,84	749,00 $\pm$ 107,90	1091,60 $\pm$ 202,74	1273,00 $\pm$ 55,62	2592,60 $\pm$ 1177,43	1214,00
	IG	204,40 $\pm$ 56,74	386,00 $\pm$ 109,12	584,00 $\pm$ 139,95	1758,20 $\pm$ 1057,47	1876,80 $\pm$ 1026,90	2646,00 $\pm$ 1088,98	-
	IG+S(1)	179,20 $\pm$ 34,51	403,80 $\pm$ 73,61	589,00 $\pm$ 54,46	1090,80 $\pm$ 180,15	1285,60 $\pm$ 229,85	1890,00 $\pm$ 563,90	1216,40
	IG+S(2)	247,00 $\pm$ 77,02	392,60 $\pm$ 71,53	689,00 $\pm$ 157,87	1174,20 $\pm$ 145,49	1342,20 $\pm$ 155,32	1886,20 $\pm$ 307,13	1385,20
	IG+S(4)	204,80 $\pm$ 82,56	386,00 $\pm$ 117,33	688,20 $\pm$ 93,78	1029,60 $\pm$ 221,93	1327,60 $\pm$ 302,20	2521,80 $\pm$ 356,76	1397,20

TABLE I: 不同策略下占用面积 A 随时间的变化。每个探索策略中的最佳值用粗体表示，整体上每个环境的最佳值用 蓝色 表示。

更有趣的是， $\beta = -2$ 的负值通常可以使机器人在更短的时间内完全探索整个环境，并且它往往是在我们测试的选项中最优的探索策略。这是因为 NF 总是选择最近的前沿，但这可能导致机器人远离其当前位置（例如，如果最近的前沿是通向新房间的门口）。使用 NF+S(-2)，我们对那些会将机器人引导到新环境部分的远处前沿进行惩罚，从而促进对其邻近区域更细致的探索，因此进一步增加了 NF 的“保守”行为。这些发现证实了 [9] 的发现，该研究最近提出了一种探索策略，首先探索机器人的局部附近，从而最大限度地减少机器人未来为探索其他前沿所需的距离。这一点尤其在环境 e_1 和 e_2 中可以看出。另一个环境 (e_3) 特别复杂，因此 NF 和 NF+S(-2) 的行为更为相似。

当我们考虑使用 IG 的探索策略时，我们只测试 β 的正值，因为 IG 和 $S(f)$ 是相关的，并且都推动机器人优先选择高度相关的边界。 β 的负值将与 IG 竞争并替代它。我们可以看到 IG+S(2) 和 IG+S(4) 在探索运行的早期阶段如何提高，并使机器人比 IG 在更短的时间内达到 A_{90} 。如预期的那样，这种行为的代价是机器人在探索的后期阶段被迫回溯，因此与 NF 相比，需要更长的时间才能达到 A_{99} 。

最后，对于了解每个边界的真实信息增益的探索策略 IG*，给高度相关的边界添加偏差并不能改善结果。这是因为显著性图 $S(f)$ 只是潜在区域的估计，而 IG*(f) 已经提供了机器人通过访问边界获得的真实信息增益。然而，即使机器人拥有真实 IG 的全部知识，如在 IG* 中，使用估计的 IG 具有高值 β （例如 IG+S(4)）通常是更好的选择。这进一步证明了显著性图可以被视为

一种更精细的方法来评估边界的信息增益，因为它们估计边界可以在中长期内观察到环境的全新部分。最后，我们注意到使用终止标准可以显著减少总探索时间 $\bar{T}$ ，特别是在使用 NF+S(-2) 时。

V. 结论

在这项工作中，我们提出了一种方法来估计在部分探索的环境中最值得访问的区域，以促使机器人更快地完成探索。我们展示了这些显著区域如何为不同的探索策略提供信息，以满足不同的需求。

未来的工作涉及测试显著图的概念，结合地图预测方法 [22] 和基于学习的方法 [1]，以及在真实机器人上的评估。

REFERENCES

- [1] Y. Cao, T. Hou, Y. Wang, X. Yi, and G. Sartoretti, “ARiADNE: A reinforcement learning approach using attention-based deep networks for exploration,” in Proc. ICRA, 2023, pp. 10219–10225.
- [2] H. González-Baños and J.-C. Latombe, “Navigation strategies for exploring indoor environments,” Int J Robot Res, vol. 21, no. 10-11, pp. 829–848, 2002.
- [3] B. Yamauchi, “A frontier-based approach for autonomous exploration,” in Proc. CIRA, 1997, pp. 146–151.
- [4] I. Lluvia, E. Lazkano, and A. Ansuategi, “Active mapping and robot exploration: A survey,” Sensors, vol. 21, no. 7, p. 2445, 2021.
- [5] L. Ericson, D. Duberg, and P. Jensfelt, “Understanding greediness in map-predictive exploration planning,” in Proc. EECR, 2021, pp. 1–7.
- [6] L. Ericson and P. Jensfelt, “Beyond the frontier: Predicting unseen walls from occupancy grids by learning from floor plans,” IEEE RAL, 2024.

- [7] J. Placed and J. Castellanos, "Enough is enough: Towards autonomous uncertainty-driven stopping criteria," *Proc. IAV*, pp. 126–132, 2022.
- [8] M. Luperto, M. Antonazzi, F. Amigoni, and N. A. Borghese, "Robot exploration of indoor environments using incomplete and inaccurate prior knowledge," *Robot Auton Syst*, vol. 133, 2020.
- [9] L. Ericson, J. Pedro, and P. Jensfelt, "Information gain is not all you need," *arXiv preprint arXiv:2504.01980*, 2025.
- [10] M. Luperto, M. M. Ferrara, G. Boracchi, and F. Amigoni, "Estimating map completeness in robot exploration," *arXiv preprint arXiv:2406.13482*, 2024.
- [11] Y. Liu and G. Nejat, "Robotic urban search and rescue: A survey from the control perspective," *J Intell Robot Syst*, vol. 72, no. 2, pp. 147–165, 2013.
- [12] A. Quattrini Li, R. Cipolleschi, M. Giusto, and F. Amigoni, "A semantically-informed multirobot system for exploration of relevant areas in search and rescue settings," *Auton Robot*, vol. 40, no. 4, pp. 581–597, 2016.
- [13] D. Brugali, L. Muratore, and A. De Luca, "Mobile robots exploration strategies and requirements: A systematic mapping study," *Int J Robot Res*, p. 02783649241313471, 2025.
- [14] J. Placed, J. Strader, H. Carrillo, N. Atanasov, V. Indelman, L. Carlone, and J. A. Castellanos, "A survey on active simultaneous localization and mapping: State of the art and new frontiers," *IEEE T Robot*, vol. 39, no. 3, 2023.
- [15] F. Amigoni, A. Quattrini Li, and D. Holz, "Evaluating the impact of perception and decision timing on autonomous robotic exploration," in *Proc. EECMR*, 2013, pp. 68–73.
- [16] A. Bircher, M. Kamel, K. Alexis, H. Oleynikova, and R. Siegwart, "Receding horizon next-best-view planner for 3D exploration," in *Proc. ICRA*, 2016, pp. 1462–1468.
- [17] F. Amigoni, "Experimental evaluation of some exploration strategies for mobile robots," in *Proc. ICRA*, 2008, pp. 2818–2823.
- [18] M. Luperto, L. Fochetta, and F. Amigoni, "Exploration of indoor environments through predicting the layout of partially observed rooms," in *Proc. AAMAS*, 2021, pp. 836–843.
- [19] Y. Katsumata, A. Kanechika, A. Taniguchi, L. El Hafi, Y. Hagiwara, and T. Taniguchi, "Map completion from partial observation using the global structure of multiple environmental maps," *Adv Robot*, vol. 36, no. 5-6, pp. 279–290, 2022.
- [20] R. Shrestha, F.-P. Tian, W. Feng, P. Tan, and R. Vaughan, "Learned map prediction for enhanced mobile robot exploration," in *Proc. ICRA*, 2019, pp. 1197–1204.
- [21] Y. Tao, E. Iceland et al., "Learning to explore indoor environments using autonomous micro aerial vehicles," in *Proc. ICRA*. IEEE, 2024.
- [22] C. Ho, S. Kim, B. Moon et al., "Mapex: Indoor structure exploration with probabilistic information gain from global map predictions," *arXiv preprint arXiv:2409.15590*, 2024.
- [23] S. Baek, B. Moon, S. Kim, M. Cao, C. Ho, S. Scherer et al., "Pipe planner: Pathwise information gain with map predictions for indoor robot exploration," *arXiv preprint arXiv:2503.07504*, 2025.
- [24] K. Song, G. Chen, M. Tomizuka, W. Zhan, Z. Xiong, and M. Ding, "P2 explore: Efficient exploration in unknown clustered environment with floor plan prediction," *arXiv preprint arXiv:2409.10878*, 2024.
- [25] M. Luperto, A. Quattrini Li, and F. Amigoni, "A system for building semantic maps of indoor environments exploiting the concept of building typology," in *Proc. RoboCup*, 2013, pp. 504–515.
- [26] C. Leung, S. Huang, and G. Dissanayake, "Active slam in structured environments," in *Proc ICRA*, 2008, pp. 1898–1903.
- [27] F. Amigoni, V. Castelli, and M. Luperto, "Improving repeatability of experiments by automatic evaluation of slam algorithms," in *Proc. IROS*, 2018, pp. 7237–7243.
- [28] M. Ghaffari Jadidi, J. Valls Miro, and G. Dissanayake, "Sampling-based incremental information gathering with applications to robotic exploration and environmental monitoring," *Int J Robot Res*, vol. 38, no. 6, pp. 658–685, 2019.
- [29] M. Luperto, V. Castelli, and F. Amigoni, "Predicting performance of slam algorithms," *arXiv preprint arXiv:2109.02329*, 2021.
- [30] M. Tan and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," in *Proc. ICML*, 2019, pp. 6105–6114.
- [31] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in *Proc. CVPR*, 2009, pp. 248–255.
- [32] R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-cam: Visual explanations from deep networks via gradient-based localization," in *Proc. ICCV*, 2017, pp. 618–626.
- [33] G. Grisetti, C. Stachniss, and W. Burgard, "Improved techniques for grid mapping with Rao-Blackwellized particle filters," *IEEE T Robot*, vol. 23, pp. 34–46, 2007.