arXiv:2602.02790v1 [cs.HC] 2 Feb 2026

模拟人类视听搜索行为

Hyunsung Cho 阿尔托大学 芬兰赫尔辛基 卡内基梅隆大学 美国宾夕法尼亚州匹兹堡
hyunsung@cs.cmu.edu

Xuejing Luo 阿尔托大学与ELLIS研究所 芬兰赫尔辛基
xuejing.luo@aalto.fi

Byungjoo Lee 延世大学 大韩民国首尔
byungjoo.lee@yonsei.ac.kr

David Lindlbauer 卡内基梅隆大学 美国宾夕法尼亚州匹兹堡
davidlindlbauer@cmu.edu

Antti Oulasvirta 阿尔托大学与ELLIS研究所 芬兰赫尔辛基 antti.oulasvirta@aalto.fi

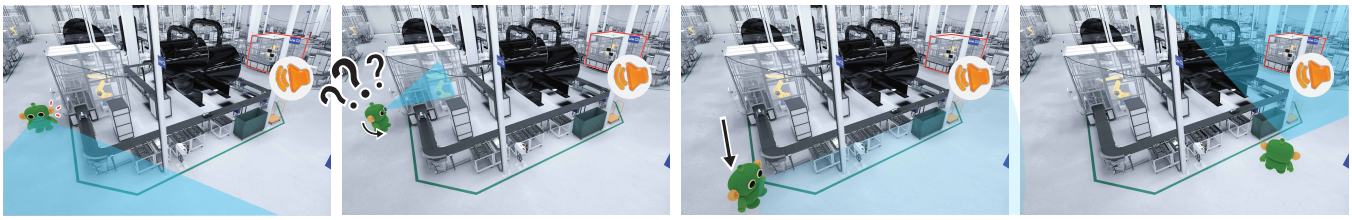


图 1：Sensonaut 是一种用于模拟具身视听搜索行为的模型。它模拟人类如何通过头部旋转和移动等具身动作，消解噪声、遮挡和混淆等感知歧义。该模型可用于预测用户在各种人机交互应用中定位空间声源所需的体力付出和时间。

摘要

根据听觉和视觉线索定位目标——例如在拥挤的停车场中找到一辆汽车，或在虚拟会议中识别发言者——需要在不确定性下权衡付出、时间和准确率。现有的视听搜索模型往往将感知与行动孤立处理，忽视了人们如何自适应地协调运动和感官策略。我们提出 Sensonaut，一种具身视听搜索的计算模型。其核心假设是，人们会调动身体和感觉系统，采取自己认为最能有效提高目标定位概率的方式，并在感知限制下权衡时间与付出。我们的模型将这一过程表述为部分可观测条件下的资源理性决策问题。我们通过新收集的人类数据对模型进行验证，结果表明，该模型既能再现任务复杂度、遮挡和分心条件下搜索时间与付出的自适应变化，也能再现人类特有的错误。我们对类人资源理性搜索的模拟，有助于设计能够降低搜索成本和认知负荷的视听界面。

CCS概念

• **以人为中心的计算 → 人机交互理论、概念与模型。**

关键词

计算行为建模；用户仿真；多模态感知；计算理性；强化学习

ACM 引用格式：

Hyunsung Cho、Xuejing Luo、Byungjoo Lee、David Lindlbauer 和 Antti Oulasvirta。2026。模拟人类视听搜索行为。载于*2026 年 ACM 人机交互系统因素会议论文集（CHI '26），2026年4月13日至17日，西班牙巴塞罗那。*ACM，纽约州纽约，美国，17 页。https://doi.org/10.1145/3772318.3790614

本作品采用 Creative Commons 署名 4.0 国际许可协议授权。*CHI '26*，西班牙巴塞罗那© 2026 版权所有，归所有者/作者所有。ACM ISBN 979-8-4007-2278-3/2026/04 https://doi.org/10.1145/3772318.3790614

1 引言

帮助人们定位空间中的物体，是人机交互研究长期以来面临的一项挑战 [20, 22]。在普适计算领域，这包括帮助驾驶员在拥挤的停车场找到自己的汽车、引导访客前往会议室，或在高风险环境中为用户提供指引，例如为繁忙的重症监护病房（ICU）中的护士，或工业设施中的应急救援人员提供指引（图 1）。在沉浸式环境中，这一问题还延伸至嵌入周围场景的数字元素，例如浮动小部件、通知或虚拟化身。虽然在条件明确时，简单的方向指引可能就足够了，但指引线索往往会显得模糊不清：声音可能被背景噪声掩盖，物体可能被其他物体遮挡，多个物品也可能看起来或听起来相似。为了消除这种不确定性，人们不会被动等待指令，而是会主动移动眼睛、头部和身体，随着时间推移收集信息。因此，有效的空间辅助不能仅依赖静态线索，还必须根据用户不断变化的行为和身体限制进行调整。因此，我们认为，建立关于这一行为的计算模型至关重要，

它有助于预测辅助何时会成功或失败，以及如何改进辅助效果。

然而，当前的计算模型要么专注于低层次的感知定位，要么侧重于无法刻画具身策略的抽象认知架构。例如，听觉定位模型解释了人们如何根据双耳线索估计声音方向 [7, 38], ，但无法进一步预测用户如何移动并通过连续搜索来进行估计。基于贝叶斯推断框架（如递归贝叶斯估计）的理想观察者模型 [37] 能够描述感官证据如何随时间累积，但通常会忽略塑造现实世界搜索的具身动作和资源限制。我们仍缺少一种能够将感官推断与资源理性决策相结合的框架，以刻画人们在部分可观测条件下搜索目标时，如何整合不确定线索与具身行动。

为弥补这一缺口，我们提出了 Sensonaut，这是一种新颖的具身视听搜索计算模型，用于模拟人们如何在不确定性下定位目标。我们将这一任务形式化为部分可观测马尔可夫决策过程（POMDP）：用户必须根据有关目标位置的不完整感官信息，序贯决策看向何处以及向何处移动。模型接收多感官观测，包括由耳间时间差（ITD）产生的听觉线索和视觉瞥见，并将多感官观测与先验相结合，以更新潜在位置的信念分布。我们通过强化学习训练模型，使其逼近一种资源理性策略：在信息价值与行动的物理成本（例如转动头部或行走）之间取得平衡。通过模拟这一过程，模型可生成涌现的搜索轨迹，不仅能预测成功率，还能预测找到目标所需的时间和精力，以及发生特定错误的可能性。

我们通过一项受控虚拟现实（VR）研究中新收集的行为数据，对模型进行了验证。在这项研究中，参与者在遮挡物数量、干扰物数量和初始目标方向各不相同的情况下，搜索发声目标。模型再现了关键的表现趋势，包括干扰物和目标位置对搜索难度的影响。至关重要的是，该模型捕捉到了任务的具身特性，反映了人类策略：优先通过低成本的头部旋转收集信息，并仅在必要时通过移动消除歧义。模型也再现了人类搜索错误的典型模式。这些结果表明，我们的模型为视听搜索提供了一种资源理性解释，并可作为设计视听界面的仿真工具。我们的实现和数据集已作为开放源代码发布，网址为 https://augmented-perception.org/publications/2026-sensonaut.html。

总之，我们的贡献有三方面：

- 一种具身视听搜索的资源理性模型，将线索整合与具身行动成本下的决策统一起来。
- 该模型的一种实现方式是将其构建为一个通过强化学习求解的部分可观测马尔可夫决策过程，能够模拟类人搜索策略及其错误。
- 一个任务复杂度经过系统变化的视听搜索任务人类行为数据集。

2 背景与相关工作

2.1 人类视听定位与线索整合

人类通过整合多种听觉线索来定位声源，其中最主要的是双耳时间差（ITD）和双耳声级差（ILD），以及头部和耳廓引入的频谱滤波 [7, 38]。双工理论解释了为什么 ITD 在低频下占主导地位，而 ILD 在高频下占主导地位 [38], ；但在宽带条件下，ITD 往往能提供最可靠的方位角信息 [35, 49]。人类通过主动监测头部和身体来减少前后混淆等歧义，并利用具身动作改变声学输入 [9, 51]。

定位很少仅依赖听觉：视觉线索会约束听觉估计并降低不确定性。经典的视错觉效应表明，人们会在知觉上融合听觉和视觉信号；当两者发生冲突时，视觉通常占主导地位 [1] ，这与贝叶斯线索组合模型的预测一致 [19]。这也给视听搜索带来了挑战：如果某个视觉干扰项与目标相似，或者另一个声音恰好出现在干扰项附近，观察者可能会将听觉声源错误地归因于视觉对象。因而，当线索一致时，这种跨模态绑定既能提高定位精度；当线索不一致时，也可能造成系统性的混淆。计算解释将这一现象归因于对多感官证据进行近乎最优的可靠性加权融合 [2, 5, 21]。因此，线索整合并非被动过程，而是受到具身策略的影响：重新定向和移动能使模糊的声源进入视野，从而降低不确定性。这些发现表明，视听搜索本质上是一种主动过程，源于多感官融合与具身探索的相互作用 [36, 37]。

2.2 具身视听搜索的计算模型

长期以来，计算建模一直致力于将人们如何在不确定性下整合感觉线索形式化。贝叶斯理想观察者模型预测，智能体应如何最优地结合似然与先验来定位声源 [4, 45]。尽管这些模型颇具启发性，但通常假设观测是被动进行的，忽略了人类听众如何主动重新定向以获取更多信息。近期研究将贝叶斯推断扩展至主动感知框架，在此框架中，转头等行动会被选择以最大化预期信息增益 [40, 41]。

此类问题可形式化为部分可观测马尔可夫决策过程（POMDP），其中序贯决策会同时改变观测与信念 [18, 37]。由于在复杂环境中解析求解部分可观测马尔可夫决策过程难以实现，研究者采用强化学习（RL）来近似资源理性策略 [6, 33]。基于强化学习的智能体学习何时重新定向、移动或作出决断，在准确率与时间和精力成本之间取得平衡 [10, 11, 24, 31]。

然而，既有研究大多关注机器人导航或单模态听觉定位等场景，而非人类进行的视听搜索。这些任务通常涉及朝已知目标进行目标导向运动，或估计单一声源位置，而且往往发生在

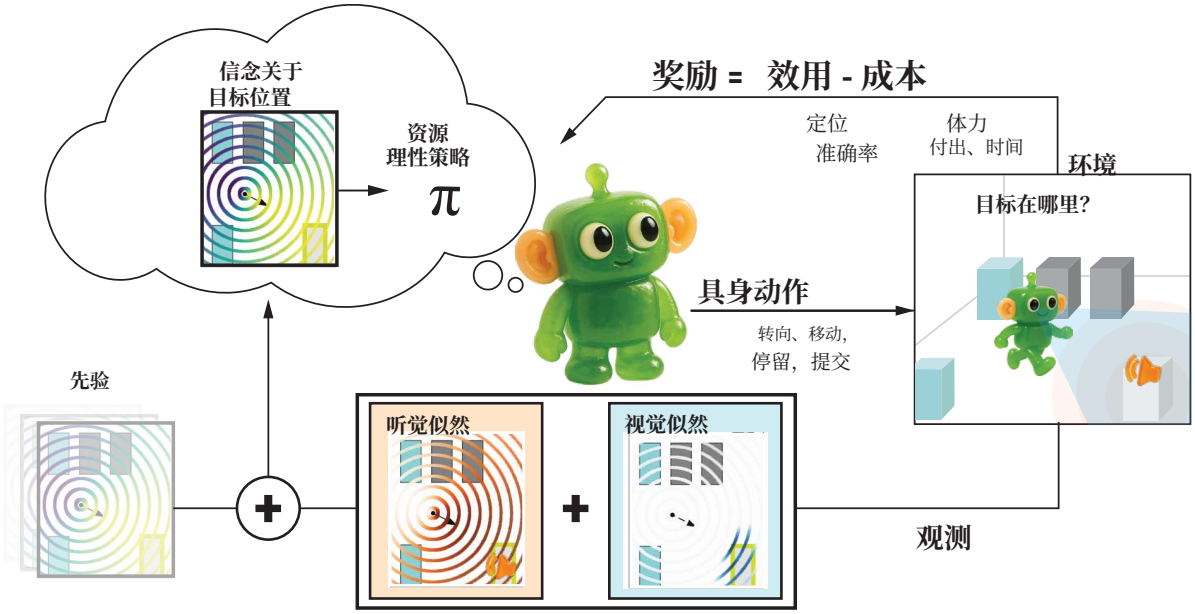


图 2：我们的具身视听搜索计算模型概览。智能体通过将先验知识与听觉和视觉似然相结合，维持对可能目标位置的信念。该信念逐步更新，并传递给资源理性策略；该策略权衡期望效用与体力付出和时间的成本。策略选择具身动作（转向、向前迈步、停留或提交），这些动作塑造来自环境的新观测。通过这一循环，模型模拟人们如何将线索整合与行动代价相结合，从而在不确定性下高效定位目标。

感知歧义有限的环境中。相比之下，类人视听搜索需要融合异质线索（例如听觉双耳时间差、视觉特征和遮挡结构），维持对多个潜在目标与干扰物的不确定性，并在时间压力下作出具身决策。与侧重空间规划或定位准确性的机器人导航任务不同，我们的模型刻画了人在感知与资源约束下进行具身视听搜索时的类人行为。

2.3 人机交互中的视听感知计算模型

在人机交互领域，感知计算模型通常侧重于预测多模态界面中的可注意性和注意力 [13, 14, 32]。视觉显著性模型可预测哪些显示区域会吸引视线 [52]，并已扩展至扩展现实，以支持自适应界面 [12, 27]。与此同时，听觉注意模型会估计显著声音如何在杂乱环境中引导注意力 [8, 30]。其他研究则探讨跨模态线索如何提升人们对系统事件的感知 [15, 17]。近期研究成果（如 Auptimize）[16]明确致力于优化扩展现实中空间音频线索的布置，以最大限度减少感知混淆并提升可辨别性，凸显了多感官感知的计算解释如何指导交互系统的设计。然而，这些方法通常关注线索布置或信号设计，而非搜索的具身动力学。我们的研究在此基础上，将研究范围从线索优化扩展至完整的具身搜索：我们不再关注线索应放置在何处，而是对……进行建模用户如何动态整合听觉和视觉信号、更新信念，并采取具身行动来消除不确定性。这种更广泛的解释不仅能说明感知敏感性，还能解释沉浸式搜索任务中涌现的策略性资源理性行为。

3 具身视听搜索模型

在本节中，我们介绍 Sensonaut，一种具身视听搜索的计算模型（图 2）。该模型模拟人类如何整合听觉和视觉线索，并采取具身动作（例如转动头部或向前移动），以在搜索过程中降低不确定性。我们通过一个智能体来实例化这一过程，该智能体借助含噪的听觉和视觉线索感知环境，并在不确定性下选择具身动作。这模拟了人类如何权衡提交正确位置的价值与转向、移动或等待的成本，而这可以通过视听搜索的资源理性解释来建模。这使我们能够解释并预测用户在视听搜索任务中的行为，而这些任务是扩展现实或听觉界面等领域中许多人机交互应用的基础。

3.1 资源理性形式化

我们将视听搜索视为一种资源理性决策问题。资源理性是认知科学中的一项原则，用来描述人们如何在认知和物理约束下近似实现理性行为 [33]。理论上，我们可以设想一位理想观察者进行穷尽式最优搜索，即考虑

每一个可能的位置，精确地更新概率，并持续搜索直至确信无疑。而实际上，人们并非如此行事：他们会提前停止、走捷径，并在准确率与所涉及的时间、精力和风险之间权衡。以资源理性的视角思考，有助于我们刻画这些有界策略：它们在准确率或效用（U）与成本（C）之间进行权衡。这在具身视听搜索中尤其重要，因为每一次转头、向前迈步或犹豫，都会带来实际的时间和体力付出成本。

因此，智能体的决策问题是最大化净效用，表示如下：

$$\pi^* = \arg\max_{\pi} \mathbb{E}\Big[\sum_{t=0}^{T} \gamma^t (U(b_t, a_t) - C(a_t))\Big], \tag{1}$$

其中，π是一个策略，将每个信念状态 b_t映射到动作 a_t。索引 t表示决策步骤，T是回合时域。项 $\gamma \in [0,1]$是一个折扣因子，用于控制未来成本和奖励随时间的权重。函数 $U(b_t, a_t)$表示在信念 b_t下成功找到目标所获得的效用，而 $C(a_t)$表示执行行动 a_t的成本。这体现了对人类行为的直觉：只要额外付出的努力看起来值得，人类就会继续搜索；但一旦不确定性降低到足以让进一步搜索不再值得其额外成本的程度，他们就会做出决定。换言之，做出决定并非要彻底消除不确定性，而是在考虑已付出成本的基础上，判断信心是否已达到“足够好”的程度。

效用 U反映了成功识别目标声源所带来的收益。在搜索任务结束时，如果智能体的估计值（$\hat{}r, \theta$）落在真实目标位置的容差界限内，就会获得正ˆ奖励；否则会受到惩罚。因此，做出决定的价值取决于后验信念分布 $p(r, \theta | audio, visual, prior)$的集中程度。当分布宽泛且不确定时，做出决定存在风险；当分布尖锐且呈单峰时，做出决定的期望效用会提高。

具身动作在塑造这一期望效用方面发挥着重要作用。转头会改变双耳时间差线索的几何结构，减少前后混淆，并提高对方位角的信心。前向移动不仅会改变距离，还会改变与目标之间的相对角度，从而使方位与径向证据产生可预测的变化。这些变化有助于区分附近的目标与远处的干扰物，并消除先前重叠声源之间的歧义。即使是小幅度的重新定向，也能将模糊证据转化为决定性证据，从而有效锐化后验分布，提高提交决策的期望奖励。行动不仅是需要最小化的成本，也是能够增加最终提交收益的投资。

成本 C 不仅涵盖外部代价，也涵盖人类具身的内部约束。每个具身动作都伴随成本，反映了移动所需的代谢与时间消耗，以及在杂乱环境中发生碰撞的风险。在我们的表述中：

- 转头会受到少量惩罚，以模拟重新调整方向来获取新的双耳信息所需的能量成本。
- 移动（前向移动）会受到更大的惩罚，以体现所需的努力以及与干扰物碰撞的潜在风险。
- 碰撞会产生严厉的惩罚，体现了具身交互中的失败。
- 被动等待会产生时间成本，延误任务完成，并在速度可能至关重要时阻碍及时响应。

通过这种方式，成本结构同时编码了外部环境以及人类认知和生理机能的内在限制，确保模型能够捕捉人们在决定是否值得为额外探索付出成本时所面临的真实权衡。我们研究中使用的具体参数值列于附录 B。

3.2 多感官感知与信念更新

在我们的模型中，感知源于听觉和视觉线索的结合。听觉线索提供持续的全向证据，即使目标位于视野之外或被遮挡，也能为智能体提供方向指引；而视觉线索则提供精确、信息丰富的确认，但仅当目标直接可见时才能发挥作用。

为表示空间不确定性，智能体在自我中心极坐标网格世界中维护其信念。我们将空间离散化为极坐标网格 $R \times \Theta$，其中 R是一组径向距离，Θ是一组方位角。该网格的距离分辨率为 1 m，方位角分辨率为 1°，并定义了智能体计算和更新其后验分布的空间范围。在每个时间步，智能体都会在该网格上维护后验信念分布 $b_t(r, \theta)$，表示目标位于相对于智能体的每个极坐标（r, θ）处的可能性。如图 2 所示，后验分布通过将新的感觉似然（听觉和视觉）与前一个时间步的先验信念相结合进行更新，从而使累积证据和不确定性能够随时间传播。

图 3 展示了一个信念更新示例。在顶行中，绿色箭头表示智能体及其朝向，粉色箭头表示一条示例人类轨迹。蓝色、白色和黑色矩形表示场景中的物体，加粗的浅绿色轮廓标记目标。这三行分别显示基于音频的信念、基于视觉的信念，以及将视听证据与先验相结合的后验分布，该先验即上一步的后验分布。

3.2.1 听觉似然。 听觉线索在视听搜索中提供连续的全向证据：无论目标位于何处，即使它在听者身后或被遮挡而不可见，这些线索始终可用。我们将这一贡献表示为同一极坐标网格 $R \times \Theta$ 上、时间步 t处的听觉似然 $\mathrm{L}_{\mathrm{audio},t}(r, \theta)$。

我们的模型基于双耳时间差（ITD）线索，该线索在人类对宽带声音 [49] 的水平（方位角）方向判断中起主导作用。我们通过假设在给定 θ 的条件下 ITD 的条件概率分布服从高斯分布，来对听觉似然进行建模：

$$\mathcal{L}_{\mathrm{audio},t}(\theta) = \frac{1}{\sqrt{2\pi\sigma_{\mathrm{ITD}}^2}} \exp\left(-\frac{(itd_t - \widehat{\mathrm{ITD}}(\theta))^2}{2\sigma_{\mathrm{ITD}}^2}\right) \tag{2}$$

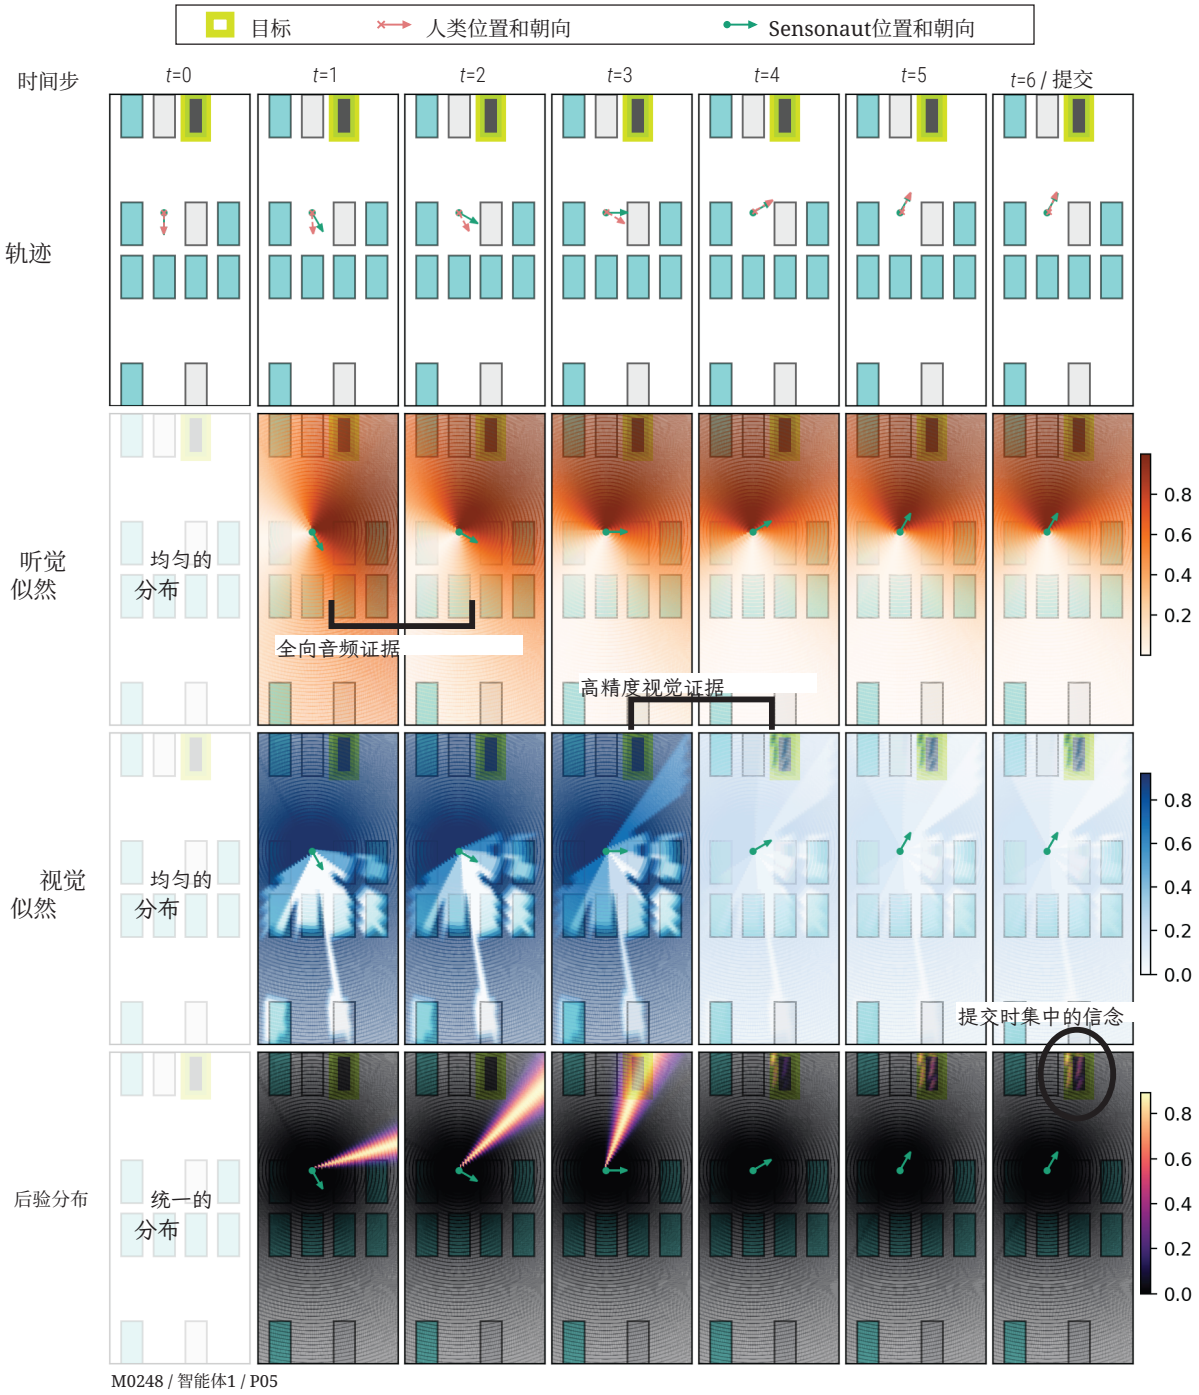


图 3：Sensonaut 在各时间步中的示例轨迹和信念更新。顶行显示智能体在地图网格视图中的位置和朝向（绿色实线箭头），以及一名人类参与者的位置和朝向（粉色虚线箭头），并标出隐藏目标（绿色高亮方框）。第二行和第三行显示不断变化的听觉和视觉似然：听觉提供全向证据，而视觉则提供高精度但依赖视角且受遮挡限制的证据。底行显示后验信念（作为下一时间步的先验），它整合了两种模态和先验。随着时间推移，转头等具身动作会重塑似然、减少歧义，并使信念质量集中于真实目标位置（圆圈标出）。

其中 σ_{ITD} 为ITD观测噪声，ITD(θ)是在方位角假设 θ下预测的ITD。 ITD(θ)基于Woodworth球形头部模型在方位角网格上计算得出 [53]:

$$\widehat{\mathrm{ITD}}(\theta) = \frac{r_{head}\theta + r_{head}\sin\theta}{c}, \tag{3}$$

其中 r_{head} 为人类平均头部半径（≈ 8.75厘米）， θ 为声音相对于头部朝向的方位角， c 为声速（343米/秒）。此函数会生成一张查找表，其中包含所有方位角假设对应的ITD预测值。观测ITD itd_t 是智能体在每个时间步 t可获取的单个值，通过对目标方位角处的真实ITD ITD(θ^*)添加高斯噪声 ϵ_{ITD}来模拟 $itd_t = \widehat{\mathrm{ITD}}(\theta^*) + \epsilon_{\mathrm{ITD}}$， $\epsilon_{\mathrm{ITD}} \sim \mathrm{N}(0, \sigma^2_{\mathrm{ITD}})$，从而生成带噪声但无偏的样本，用于稳健训练。

由于 ITD 主要是一种方位角线索，并且几乎不传递径向信息，我们将听觉似然建模为与距离无关:

$$\mathcal{L}_{\mathrm{audio},t}(r,\theta) = \mathcal{L}_{\mathrm{audio},t}(\theta), \quad \forall r. \tag{4}$$

这反映了这样一个事实：ITD 能提供稳健的方向信息，但对径向（距离）的敏感度较弱 [7, 49, 53]。对距离的消歧则通过具身行动和视觉观测来实现。

3.2.2 视觉似然。 视觉线索通过将概率质量锚定到可直接看到的物体上，并排除已经过视觉检查的区域，提供互补的高精度证据。我们将这一贡献表示为以自我为中心的极坐标网格 $R \times \Theta$ 上、时间步 t 处的视觉似然 $\mathrm{L}_{\mathrm{visual},t}(r,\theta)$，其中每一对 (r_i, θ_i) 索引一个离散的距离–方位角分箱。

我们首先构建视觉证据图 $E_{\mathrm{visual},t}(r,\theta)$。在每个时间步，智能体具有航向角 ψ_t。方位θ落在以 ψ_t 为中心的 110° 视野内的物体被视为处于视野中。为处理遮挡，在方位相差小于 5° 的物体中，仅将最近者视为可见，从而得到一组可见极坐标网格单元 $\{(r_i, \theta_i)\}$。每个可见物体在其网格单元 (r_i, θ_i) 处贡献一个由特征相似度加权的峰值。这些贡献被求和，并按可见物体的数量进行归一化，以使总质量保持有界。

当区域被检查并确认为空时，视觉也会提供负证据。沿每条视野射线，我们从智能体所在位置向外逐步扫描，直至遇到第一个遮挡物。遮挡物之前的所有单元格都标记为视线（LOS）空区域，并乘以一个衰减因子（$1-\delta$）。如果射线上的第一个可见表面与目标外观不匹配，则对截至该表面的所有单元格应用相同的折减，从而减少干扰物造成的混淆。应用这些视线和表面折减后，对地图重新归一化，以得到 $E_{\mathrm{visual},\ t}(r,\ \theta)$。

由于视觉信息具有瞬时性且取决于视角，我们在智能体的自我中心坐标系中随时间对其进行累积。令 $\Delta\psi_t$ 表示时间步 $t-1$ 与 t之间的朝向变化。在与新证据结合之前，我们通过沿方位角维度移动先前的视觉似然，并在 θ 中进行环绕处理，来旋转该似然：$\mathrm{L}_{\mathrm{visual},t-1}(r, \theta - \Delta\psi_t)$。然后，我们将移动后的先前地图与当前证据结合，使用指数移动平均:

$$\begin{aligned}\tilde{\mathcal{L}}_{\mathrm{visual},t}(r,\theta) &= (1-\lambda_{\mathrm{visual}})\,\mathcal{L}_{\mathrm{visual},t-1}(r,\theta-\Delta\psi_t)\\ &\quad + \lambda_{\mathrm{visual}}\,E_{\mathrm{visual},t}(r,\theta),\end{aligned} \tag{5}$$

并在 $R \times \Theta$ 上归一化，以得到

$$\mathcal{L}_{\mathrm{visual},t}(r,\theta) = \frac{\tilde{\mathcal{L}}_{\mathrm{visual},t}(r,\theta)}{\sum_{r,\theta}\tilde{\mathcal{L}}_{\mathrm{visual},t}(r,\theta)}.$$

这会产生一种以头部为中心、经过时间平滑的视觉似然，将概率质量集中在可见且特征一致的物体上，并降低那些已被观察且确认为空的区域的权重。图 3 展示了目标首次进入视野时视觉似然如何在其周围变得更加集中，以及被排除的区域如何随时间推移继续受到抑制。

3.2.3 信念更新。 在每个时间步，智能体都会在极坐标网格上的候选目标位置上维持一个后验信念 $b_t(r,\theta)$。我们假设各位置服从均匀先验，并且在给定真实目标位置的条件下，听觉观测与视觉观测相互独立。基于这些假设，我们首先将听觉似然与视觉似然相乘，计算瞬时联合似然 $\mathrm{L}_{joint,t}(r,\theta)$:

$$\mathcal{L}_{joint,t}(r,\theta) = \mathcal{L}_{\mathrm{audio},t}(r,\theta)\mathcal{L}_{\mathrm{visual},t}(r,\theta). \tag{6}$$

取对数后可得加法形式:

$$\log\mathcal{L}_{joint,t}(r,\theta) = \log\mathcal{L}_{\mathrm{audio},t}(r,\theta) + \log\mathcal{L}_{\mathrm{visual},t}(r,\theta). \tag{7}$$

在对数空间中，较强或更一致的线索会自然地对后验分布产生更大的影响，而较弱或不一致的线索影响较小，从而重现人类多感官知觉中观察到的基于可靠性的线索整合 [1, 19]。

为在时间步之间累积证据，同时避免对早期观测过度承诺，我们在对数空间中采用一种泄漏式时间更新:

$$\log b_t(r,\theta) = (1-\alpha)\,\log b_{t-1}(r,\theta) + \alpha\,\mathcal{L}_{joint,t}(r,\theta), \tag{8}$$

其中， α控制新证据的影响程度。该更新使后验分布能够保持多峰性，在干扰项存在时保留相互竞争的假设，同时强化一致的线索。由此得到的信念随时间平滑演变，既反映了先前证据的稳定性，也反映了当前观测的可靠性。

3.3 不确定多感官知觉下的决策

智能体形成后验信念 $b_t(r,\ \theta)$ 后，必须决定如何据此采取行动。这一决策过程受到两个根本挑战的影响：（1）智能体无法直接观察世界的真实状态，只能获得部分且带有噪声的听觉—视觉线索；（2）每一次具身行动都会带来时间、精力或风险方面的成本。因此，智能体面临一个资源理性问题：必须权衡提交决策的期望效用，与进一步探索的成本和潜在收益。

当后验分布尖锐且集中于某个假设时，提交的效用相对于进一步探索的成本较高，智能体可能会终止搜索。在图 3 的后验分布图中，随着转头，目标位置的概率从 t = 3开始变得更加集中。然而，

信念往往是分散的或呈多峰分布。杂乱的场景中可能包含外观或位置与目标相似的干扰物，从而在后验分布中形成相互竞争的峰值，并降低提交的期望效用。模型不会丢弃这些干扰物，而是将其保留为备选假设，直到有更多证据足以做出判断；这反映了人类在不确定性下推迟做出决定的方式，正如后文图 7c 和图 8 所示。

在这些情况下，智能体会权衡额外的具身行动是否值得其成本。转头相对低成本，并能从两个通道带来丰富的信息增益：它们重塑双耳时间差几何关系以消解前后方位歧义，并扩展视野以揭示先前位于视野之外的物体。前向移动成本更高，但有时必不可少，因为它们会同时改变距离与方位角，从而区分沿同一视线或听觉方位对齐的两个歧义物体。它们还使智能体能够绕过遮挡物，将隐藏物体带入视野以供确认。停留不会产生体力付出，但会延缓进展。

以此方式，动作作为资源理性选择而出现：智能体行动不仅是为了利用其当前的最佳估计，也是为了策略性地将不确定或含糊的信念转化为更具决定性的信念。因此，提交或继续搜索的决定由后验信念与具身行动的成本共同塑造。

3.4 部分可观测马尔可夫决策过程建模

我们将这一控制问题形式化为一个部分可观测马尔可夫决策过程（POMDP）M = S，A，O T，Ω，R，γ，该过程描述隐状态、行动与含噪观测如何相互作用，以及信念如何随时间演变。

- **状态 S：**以自我中心极坐标表示的目标位置、以世界坐标表示的智能体位置和朝向，以及包含干扰物和遮挡物的静态场景布局。该状态对智能体而言是隐含的，无法直接观测。

- **动作 A：**向左转_、向右转_、向前移动_、停留、提交。这些代表重新调整朝向、向前移动、等待或做出决定等具身行动。这些是离散动作，其中转向动作采用固定转向角 θ_{turn}，移动动作采用固定步长 d_{step}。

- **观测 O：**每个时间步，智能体都会接收到由以下内容构成的认知状态：(i) 关于自我中心极坐标的完整后验信念分布 $b_t(r,\ \theta)$；(ii) 汇总特征，包括最大后验概率（MAP）估计以及 r和 θ中的不确定性；(iii) 最近采取的动作；以及 (iv) 已经过的时间。智能体不会直接观测原始听觉或视觉线索，而是由模型在感知层面对这些线索进行处理，并将其整合到后验信念中。这一设计反映了人类认知：决策基于能够体现不确定性的感知状态，而不是直接基于感官测量。

- **转移** T: 在世界层面，动作会确定性地改变智能体的具身状态：转向旋转朝向，前进步将位置移动固定距离，停留使状态保持不变，提交则转移到吸收性终止状态。在信念层面，这些具身变化会转化后验分布。转向会沿方位角旋转信念分布，使其与新的以头部为中心的参考系对齐。前进一步会沿朝向方向将概率质量向内移动，反映出与前方物体的距离缩短。停留不会改变智能体的物理状态，但会相对于先验强化最近一次观测，并在感知输入保持一致时逐渐使后验分布更加尖锐。提交或碰撞会终止该回合。这些转移刻画了动作如何不仅重塑外部世界，也通过智能体的具身视角重塑其可获得的信息。

- **观测模型** Ω**：**在给定候选项方位角的情况下，接收 itd_t 的似然由围绕$\widehat{ITD}$（θ）的高斯模型定义。视觉似然为可见物体增加局部化证据，并受特征相似度和遮挡的调节。

- **奖励** $R(=U-C)$: 正确提交可获得正效用，而错误提交则会受到惩罚。所有动作都会产生每步时间成本，以反映延迟完成任务的机会成本。转向、前进步和碰撞具有分级成本，分别反映时间、努力和风险，而停留没有额外成本。该奖励结构编码了准确率与成本之间的资源理性权衡

- **折扣因子** γ**：**我们将 $\gamma = 0.99$ 设定为使未来奖励相对于即时奖励略有折扣。这鼓励智能体重视更快的解决，而非不必要的冗长搜索轨迹，同时在预期能降低不确定性时仍允许进行多步探索。

3.5 参数化与策略学习

在部分可观测马尔可夫决策过程中，实际求解不确定性下的最优行动方式是难以实现的，因此 Sensonaut 通过强化学习，学习一个近似策略 $\pi(a \mid b)$，将信念 b 映射为行动 a。通过近端策略优化（PPO），智能体在试错过程中不断改进策略，并依据准确定位获得的奖励，以及因成本高昂或效率低下的行动而受到的惩罚进行调整。我们使用 Stable Baselines 3 实现 PPO，并在附录A中列出训练所用的参数。

通过训练，智能体逐渐形成了资源理性的视听搜索行为：通过转向消除对称峰，通过向前移动区分排列成一线或被遮挡的物体，并在信念变得集中且呈单峰时提交。由此，强化学习将形式化的部分可观测马尔可夫决策过程框架与类似人类搜索的具身策略联系起来。

4 数据收集：人类视听搜索

为了将模型模拟与人类行为进行比较，我们在受控的虚拟现实停车场环境中收集了一个人类视听搜索数据集。

4.1 方法

4.1.1 参与者。共招募了12名来自当地大学社区的人员（6名女性、5名男性、1名非二元性别者；年龄范围为21–33岁，$M = 26, SD = 4.42$）。所有参与者均报告其视觉、听觉和运动能力正常或矫正后正常。研究采用便利抽样，招募可参加



图4：数据收集设置。每次试次开始前，参与者佩戴 Meta Quest 3 头显，查看一条指示目标汽车颜色的文本指令。试次期间，他们在虚拟现实停车场中转身并行走，以寻找发出声音的目标车辆。按下 Quest 控制器上的 ‘A’ 键即可提交，这会清除所有汽车；随后，他们使用射线投射选择器记录估计的目标位置。

线下虚拟现实研究的学生和教职员工。参与者在一次单独的实验中完成了所有试次，并获得一张20欧元礼品卡作为报酬。

4.1.2 设备。 研究在一间宽敞的房间内进行，参与者可以在其中实际行走和转身（图4）。虚拟现实设备使用 Meta Quest 3 头显及其右手控制器进行输入。虚拟环境由 Unity 实现，是一个停有蓝色、黑色和白色汽车的停车场。其中一辆汽车被指定为目标车辆，并循环播放汽车鸣笛声。为增强真实感并加入听觉噪声，研究还循环播放停车库的环境背景噪声。汽车鸣笛声和背景噪声的频谱图见附录（表10）。

听觉设置。 在 Steam Audio 引擎中使用 KEMAR [23] 的头部相关传递函数（HRTF）的空间取向声学格式（SOFA）[34]，对目标声和背景声进行空间化。本实验选择这种通用 HRTF，而非个体化 HRTF，因为先前研究一致表明，通用 HRTF 对动态听觉定位的准确率没有显著影响（例如， [43, 46]）。

视觉设置。 Meta Quest 3 头显的水平视野为 110 度，垂直视野为 96 度，每只眼睛的显示分辨率为 2,064 × 2,208 像素。参与者需调整机械镜片间距，以获得最清晰的视觉效果。

4.1.3 研究设计。 本研究采用被试内实验设计，每位参与者均完成所有条件。

自变量。 实验地图包含以下变化因素：(a) ANGLE：目标的初始角度（前方、侧方或后方）；(b) NUM_OBJS：场景中物体的总数（5、7 或 12 辆汽车）；以及 (c) DISTRACTORS：视觉干扰项的数量（与目标颜色相同的汽车，0、2 或 4 辆），共形成 27 种条件（$3 \times 3 \times 3$）。

在受控地图生成中，首先为目标物体随机分配一个位置和颜色。随后，将剩余的 NUM_OBJS - 1 辆汽车随机放置到其他位置。为控制视觉干扰项，将非目标汽车的颜色设定为：其中恰有 DISTRACTORS - 1 辆与目标物体的颜色相同。最后，随机采样智能体的初始位置和朝向，直到其与目标物体之间的角度落在相应的角度范围内：前方（-55° 至 55°）、后方（125° 至 235°）或侧方（55° 至 125°，以及 -125° 至 -55°）。这些范围基于 Meta Quest 3 支持的 110° 视野。通过这种方式，在实验条件和分析中，将连续的相对角度作为分类自变量（角度）处理。

因变量。 在每个试次中，我们根据估计的目标角度和距离测量了搜索时间、头部累计旋转、位移和定位成功率。搜索时间计算为任务开始与确认事件之间的时长。头部累计旋转对人类而言是通过对逐帧偏航角变化求和得到的，对我们的模型而言则是由离散动作推导求和（每个旋转步长 30°）。位移计算为 Unity XZ 平面上起点与终点位置之间的欧几里得距离。定位成功率记录为一个二元变量，表示极坐标 (r, θ) 中的最终估计是否正确匹配真实目标位置。

4.1.4 流程。 在数据收集开始时，参与者填写了人口统计调查并提供了参与同意。他们被告知，其任务是尽可能快速且准确地找到具有目标颜色并发出蜂鸣声的目标车辆。参与者在教程（通过屏幕投射进行监控）的引导下，使用仅用于训练阶段的地图变体（例如，包含 2-3 辆汽车和 1 个干扰项）。

在每个试次开始之前，参与者会查看一条指示目标颜色的文本指令。他们使用透视模式在实体房间中安全地重新定向，然后按下 Meta 按钮进入 VR 停车场（图 4）。地图配置已根据实验条件预先生成；所有参与者以随机顺序体验同一组地图。在试次期间，参与者通过行走和转向进行实体导航，依靠听觉和视觉线索寻找目标。确信后，他们按下 A 进行提交（图 4 中）。这一行动记录了搜索时间，并在参与者使用射线投射选择器记录其估计之前清除汽车（图 4 右）。该机制确保位置估计仅依赖于所收集的信息

在提交决策之前。参与者共完成了 270 个试次（每种条件下 10 个试次）。他们被告知可以随时休息，并被要求标记任何因物理房间限制而限制其运动的试次。

4.1.5 数据记录与处理。行为日志（位置、朝向和输入事件）及结果指标均由 Unity 自动保存。每个试次的累积偏航旋转量通过对偏航角位移的绝对值求和计算得出。参与者按错按钮，或报告因墙壁阻挡而无法继续移动的试次均予以剔除（占所有试次的 1.57%）。完成时间超过参与者平均值 3 个标准差的离群值也予以剔除（占试次的 1.3%）。

5 结果：人类与 Sensonaut

我们在与人类研究相同的 270 张地图上评估了 Sensonaut。为考虑随机性，我们以随机化的地图顺序运行模型 12 次，生成 12 个智能体个体，以便与 12 名人类参与者进行比较。这些评估地图未纳入训练回合，确保表现反映的是泛化而非记忆化。接下来，我们将模型模拟与人类行为进行比较，考察准确率、搜索时间、转头次数和位移，重点介绍支持我们建模假设的相似之处，以及为理解具身视听搜索提供进一步见解的差异。

5.1 人类搜索行为概述

我们分析了角度（前方、侧方、后方）、NUM_个物体（5、7、12）和干扰项（0、2、4）对以下因变量的影响：准确率、搜索时间、转头次数和位移。除非另有说明，结果均来自经过 Tukey 校正的事后比较方差分析。为考虑移除异常值（~3%）所造成的轻微数据不平衡，我们报告了估计边际均值（EMM）。

5.1.1 准确率。逻辑回归显示，角度、NUM_个物体或干扰项对准确率均无显著主效应或交互效应（均为 $p > .10$）。各条件下的准确率始终维持在较高水平（94.7%）。

5.1.2 搜索时间。角度（$F_{2,3162} = 30.84, p < .001, \eta^2 = .020$）、NUM_个物体（$F_{2,3162} = 83.24, p < .001$ $\eta^2 = .004$ F_2 3162 = 51.72 $p < .001$,）和干扰项（, , ,$\eta^2 = .050$ × ）均有显著主效应，此外还存在一个显著的双向交互效应：干扰项与角度（$F_{4,3162} = 2.99, p < .05, \eta^2 = .003$）。三向交互效应也显著（$F_{8,3162} = 4.42, p < .001, \eta^2 = .010$）。在后方寻找目标（$M = 4.30$ s, $SE = 0.12$ s）显著慢于在侧方寻找（$M = 3.42$ s, $SE = 0.12$ s）：$\Delta M = 0.88$ s, $p < .001$；也显著慢于在前方寻找（3.04 $SE = 0.12$ $\Delta M = 1.26$ $p < .001$ s, s）：s, 。

对于干扰项，搜索时间随着干扰项增多而单调增加：2 个与 0 个干扰项相比（$\Delta M = 0.90$ s, $p < .001$），4 个与 0 个干扰项相比（$\Delta M = 2.11$ s, $p < .001$），以及 4 个与 2 个干扰项相比（$\Delta M = 1.22$ s, $p < .001$）。

5.1.3 转头。方差分析显示，干扰物、$F_{2,3162} = 36.79$, $p < .001$, $\eta^2 = .023$ 以及角度$F_{2,3162} = 241.94$, $p < .001$, $\eta^2 = .153$均有显著主效应。NUM 3.86 $p = .004$ $\eta^2 = .050$ OBJS 与干扰物之间存在显著交互效应$F_{4,}$, , , 干扰物与角度之间也存在显著交互效应，$F_{4,3162} = 3.24$, $p = .011$, $\eta^2 = .004$。干扰物越多，转头次数越多：2 个与 0 个干扰物相比（$\Delta M = 21.49, p < .001$），4 个与 0 个干扰物相比（$\Delta M = 42.16, p < .001$），以及 4 个与 2 个干扰物相比（$\Delta M = 20.67$, $p < .001$ ）。角度的影响很大：侧方目标所需的头部旋转幅度大于前方目标（$\Delta M = 35.84$, $p < .001$）；后方目标所需的头部旋转幅度则显著大于前方（$\Delta M = 106.22$, $p < .001$）和侧方目标（$\Delta M = 70.38, p < .001$），这表明参与者在搜索身后目标时转头幅度最大。

5.1.4 位移。方差分析显示，NUM_OBJS、$F_{2,3162} = 5.53, p = .004, \eta^2 = .003$、DISTRACTORS、$F_2$ F_2 $p <$, .001 $\eta^2 = .019$ $_{3162} = 69.49, p < .001, \eta^2 = .041$以及角度存在显著主效应，,$_{3162} = 31.78$, , 。NUM_OBJS与DISTRACTORS之间也存在显著交互作用，$F_{4,3162} = 2.64, p = .032, \eta^2 = .003$；NUM_OBJS、DISTRACTORS和角度之间存在显著三重交互作用，$F_{8,3162} = 4.55$, $p < .001, \eta^2 = .011$。位移随干扰项数量增加而单调增大：2 0 $\Delta M =$ vs（,），vs（,），0.33 $p < .001$ 4 0 $\Delta M = 0.62$ $p < .001$ 4 2 $\Delta M = 0.29$ 以及vs（,$p < .001$ ）。参与者在提交目标前会从起点行进更远。侧方目标所需的行走距离大于前方目标（$\Delta M = 0.16, p = .006$），后方目标所需的行走距离则大于前方目标（$\Delta M = 0.42$, $p < .001$）和侧方目标（$\Delta M = 0.26$, $p < .001$ ）。

5.1.5 总结。综合各项测量结果，人类会针对任务难度作出选择性反应：

- 角度是影响时间、位移，尤其是转头次数的主要因素（后方的难度最高）。
- 干扰物会增加时间和错误，但当视角不利时，其影响最强；它们并不会普遍拖慢表现。• NUM_OBJS的主效应较小，但会通过交互效应产生影响。
- 准确率始终较高，这表明人们主要投入精力来维持表现，而非追求微小的准确率提升。

5.2 表现

图5总结了人类和Sensonaut在角度、NUM_OBJS和干扰物条件下的四项指标表现：准确率、搜索时间、累计转头次数和位移。在所有指标上，人类和模型都呈现出相同的系统性模式，表明该模型能够泛化视听搜索的核心效应。

总体而言，准确率仍然很高，但在侧方角度以及存在干扰物时略有下降，模型的表现与人类表现高度一致。当目标位于身后或存在干扰物时，搜索时间会增加，反映出在这些情况下辨别线索歧义的难度有所上升。在这些情况下，转头次数也会增加，凸显出人类和模型都依赖重新定向来消除歧义。然而，人类的转头幅度更大、变化也更多，这与人类能够进行不同幅度的转向相符，而模型只能按固定的30°步长转向。位移仍然相对较小；与人类相比，模型更倾向于尽量减少行走，这反映了其明确设定的动作成本。

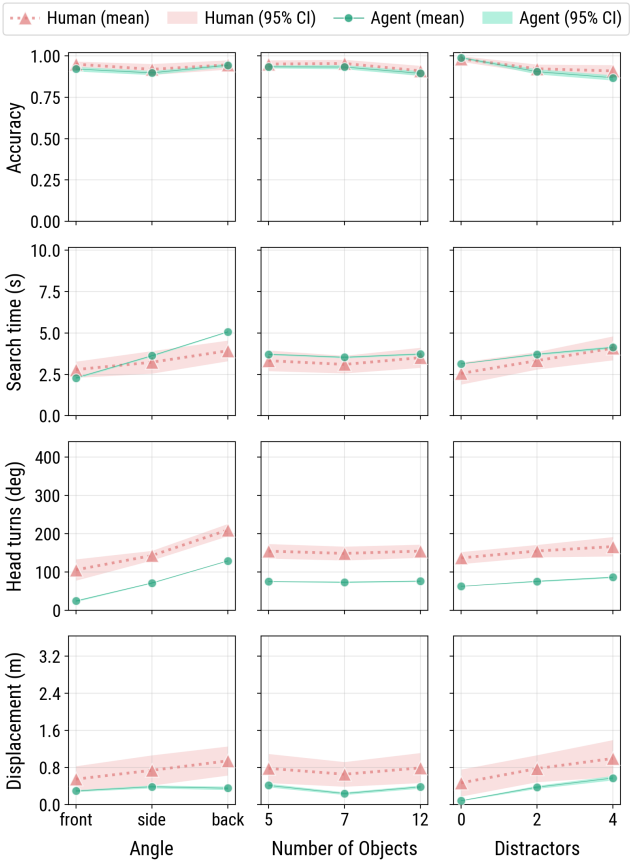


图5：人类与 Sensonaut 在初始目标角度、物体数量和干扰项数量不同的情况下的表现。每一行展示平均准确率、搜索时间、转头次数和位移，阴影区域表示95%置信区间。当目标一开始位于侧方或身后，或干扰项较多时，人类和智能体的搜索时间都会更长、转头次数更多、移动距离也更大。

这些模式表明，我们的模型展现了视听搜索中的关键具身策略，例如主要依靠转头，在不确定性较高时加大努力，并在保持高准确率的同时尽量减少代价高昂的运动。

5.3 相关性

为了系统比较人类与 Sensonaut 的行为，我们计算了人类和模型预测的地图级中位数之间的相关性（图6）。比较中位数能够捕捉人类行为在每张地图上的集中趋势，同时减弱参与者个体差异的影响。这为评估模型能否在不同环境中复现具身视听搜索的系统性模式提供了稳定依据。

拟合结果表明，模型解释了准确率方差的 35%（$R^2 = 0.35$）、搜索时间方差的 26%（$R^2 = 0.26$）、转头方差的 58%（$R^2 = 0.58$）以及位移方差的 6%（$R^2 = 0.06$）。准确率吻合良好，表明模型能够预测人类错误。

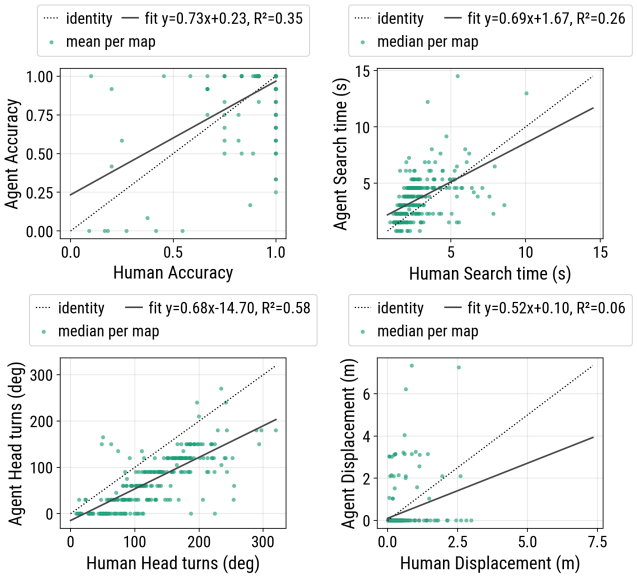


图6：人类与 Sensonaut 在准确率、搜索时间、头部累计旋转和位移方面的相关性。Sensonaut 复现了准确率、搜索时间和转头次数的地图级模式，但在位移方面的对应关系较弱；第5.6节将对此作进一步分析。

搜索时间也吻合，模型捕捉到了条件越困难、搜索时间越长的趋势，不过它往往比人类稍慢。这反映了模型的保守策略：持续探索，直到不确定性充分降低。

最明显的一致性体现在转头上，Sensonaut 捕捉到了参与者如何将旋转作为一种主要且低成本的证据收集方式。人类可以按任意角度旋转，并累积不同幅度的旋转，而 Sensonaut 只能按 30° 的增量转向。尽管存在这一限制，相关性仍然很高，表明该模型捕捉到了旋转的核心作用。位移的一致性最弱。参与者从起点出发的移动距离各不相同，而模型则更加稳定。人类个体差异较大，这解释了该指标较低的可预测性。

尽管这些 R^2 数值不高，但与留一法的人类对人类相关性结果一致：搜索时间为 $R^2 = 0.22$，转头为$R^2 = 0.26$，位移为 $R^2 = 0.11$。这说明，鉴于人类策略存在个体差异，完美拟合并不现实。散点图还显示，模型输出呈现阶梯状，这自然是其离散化动作空间（每次转向 30°，每次移动 1 米）的结果。即便如此，该模型仍能再现视听搜索的主要具身策略，并对差异出现的位置及其原因给出有理有据的解释。

5.4 搜索策略

我们的模型表现出与人类相似的具身搜索策略，其驱动力来自资源理性决策。图7展示了三种典型模式。

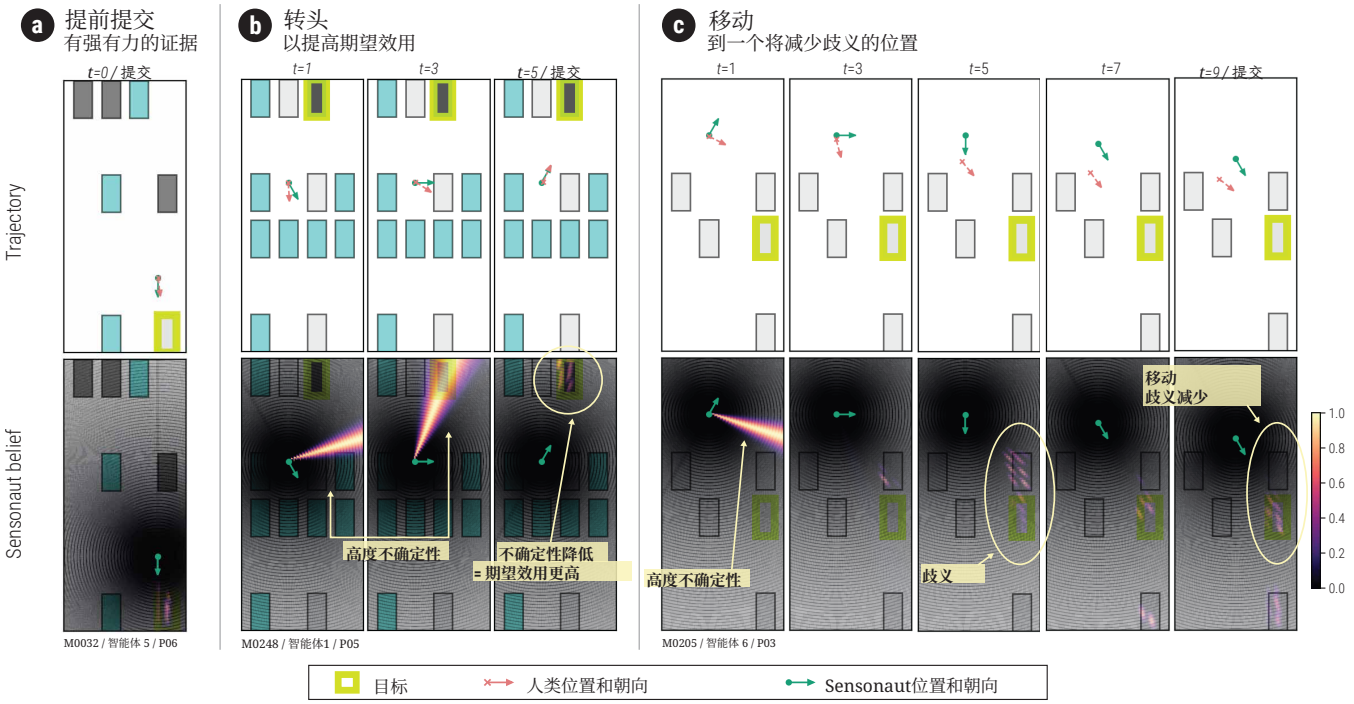


图7：Sensonaut 产生的类人搜索策略示例。（a）有强有力的证据时提前提交。当初始视听证据强烈偏向某个候选项时，人类和智能体都会立即提交。（b）通过转头提高期望效用。当初始后验分布存在歧义时，Sensonaut 会进行渐进式转头，从而大幅降低不确定性，与人类行为相一致。（c）移动到能够减少歧义的位置。当仅靠旋转无法消除不确定性时，人类和 Sensonaut 都会移动到能够提供明确判别性线索的位置。在此示例中，智能体转向其后方尚未探索的区域，随后移动到易混淆物体之间的中点，以获得左右对比，使后验分布迅速收敛。

强证据下的提前提交。 当视听证据强烈偏向单一候选项时，人类和Sensonaut都会立即提交。在这些情况下，试次第一步之后的后验分布已经明显呈尖峰（图7a），从而在没有头部运动或移动的情况下直接提交。当置信度较高时，这种行为通过优先采取提交行动而非高成本探索来最大化期望效用。

通过转头提高期望效用。 当初始后验分布具有误导性或存在歧义时——目标通常位于后方（图7b中的t=1）——人类和 Sensonaut 都会通过转头来收集信息。旋转具有双重作用。首先，在不同角度采集听觉样本，并通过视觉排除错误位置，从而消除前后混淆，校正方向估计（t=3）。随后，将目标纳入视野会使后验分布收敛为一个尖锐峰值（t=5）。这说明，学习到的策略会在提交之前利用低成本的感知动作来提高期望效用。

通过移动减少歧义。 在转头后歧义仍然存在的试次中，人类和 Sensonaut 都进行了移动。在 t=5 图7c中，后验分布仍呈双峰状态，分别集中于真实目标和一个竞争性干扰项。为解决这一问题，两个智能体都移动到了一个能够产生运动视差、利用遮挡几何并产生更具区分性的音频线索的位置。由此产生的后验更新成功排除了干扰项，使后验分布收敛于单一候选项，如图7c中的 t=7 和 t=9 所示。这些由移动驱动的消歧行为自然地源自基于信念的策略，使智能体能够高度自信地提交。

5.5 错误

为了评估我们的模型是否不仅能捕捉人类成功的搜索行为，也能捕捉错误，我们分析了所有错误的人类试次（占总试次数的 6%；由一位作者手动编码），并将其分为五类：遮挡驱动的错误、相似方向上较近干扰物引起的混淆、较远干扰物引起的混淆、前后混淆以及选择错误。图 8 展示了模型重现人类错误的三种主要错误类型，并从计算角度解释了这些错误如何由感知歧义和场景结构引起。

遮挡驱动的错误（*35%*）。最常见的人类错误是由遮挡造成的：从起始视点看，目标被中间遮挡物完全或部分遮住。人类参与者经常会选择可见干扰项，因为它的外观和方向与听觉线索相符，例如图 8a 所示的两个例子。我们的模型也出现了相同的错误模式，

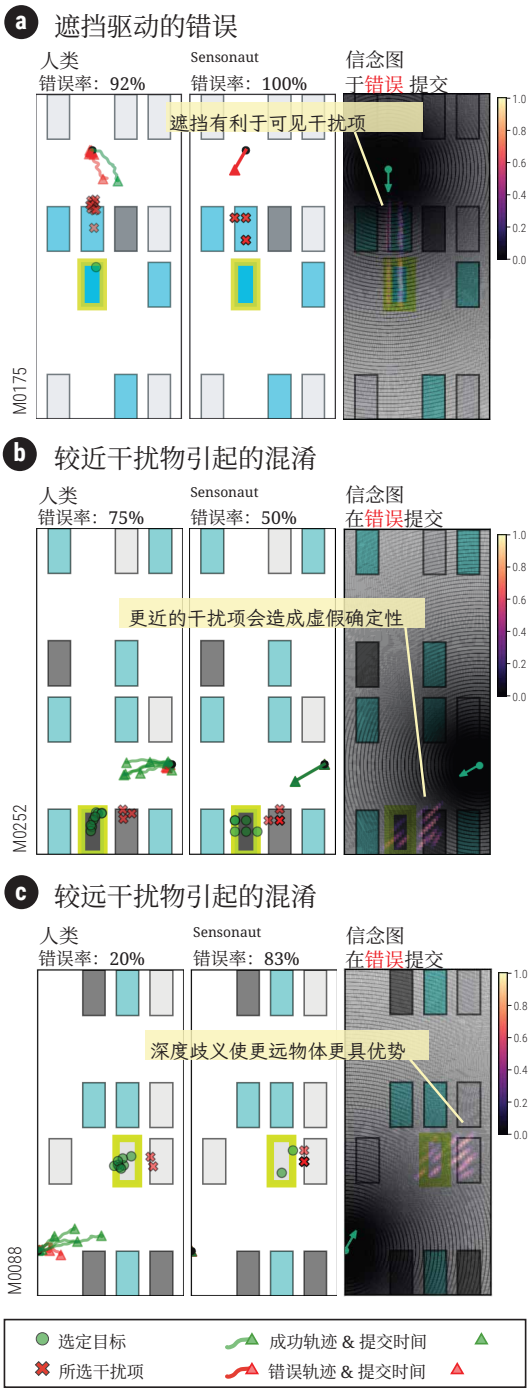


图 8：Sensonaut 再现了由感觉不确定性导致的人类错误。人类和模型都会被视角相似但深度不同的干扰物误导。信念图（右）展示了其原因：感知歧义会在遮挡（a）、邻近（b）和距离（c）场景中造成虚假确定性。

复现了人类参与者所犯遮挡驱动错误实例的 100%。信念图显示，Sensonaut 始终保持较高的

由于对被遮挡区域存在不确定性，因此选择了干扰项；而从起始位置获得的视听证据对备择假设的支持仍然较弱。

较近干扰物引起的混淆（*28%*）。人类和 Sensonaut 都过早地选择了一个与目标方向相似的较近干扰项。在图 8b 中，尽管真实目标尚未被完全排除，该干扰项已经形成了一个不确定性相对较低的后验众数。因此，这个干扰项成为一个局部上颇具说服力的假设。我们的模型再现了此类人类错误实例的 42.9%。在同一张地图中，无论是人类还是模型，只要走近目标，就能通过减少歧义成功选出正确目标。

较远干扰物引起的混淆（*5%*）。当远处物体与目标方向对齐时，布局中会出现由较远干扰项引起的混淆，形成拉长的后验峰值。人类偶尔会选择较远的干扰项，而在这些地图中，Sensonaut 在人类错误中有 30% 重现了这一结果。图8c展示了在提交时刻仍未消解的后验分布，尽管线索部分提供了信息，最终还是导致选择了干扰项。

其余错误类型与我们的模型范围关联较小。在人类试次中，当参与者过早选择前方的物体，而真实目标位于他们后方时，就会出现前后混淆。Sensonaut 并未重现这些错误，因为该智能体始终执行转头动作，在提交之前消解了歧义。选择错误反映了参与者未能回忆起目标的颜色或位置，并非由视听推断导致，因此我们在评估模型的感知行为时将其排除。

5.6 运动轨迹

我们通过找出人类与模型之间绝对位移差超过 1.5 米的地图，分析了运动差异。这些情况分为模型移动过头和人类走得更远两类。图9展示了每种情形中观察到的最大偏差。

Sensonaut 比人类走得更远。 在若干地图中，尽管场景中仍存在不确定性，人类还是很早就提交了选择。在图9a中，大多数参与者没有继续迈步，而是选择了较近的候选项，尽管更远物体仍是一个合理的选项。然而，我们的模型仍为更远的干扰项保留了一定概率，因此继续向前移动以收集更多证据，有时会导致错误提交。

人类比 Sensonaut走得更远。 在其他地图中，人类会采取探索性步伐来解决部分遮挡问题。在图9b中，他们会移动以更清楚地观察仅部分可见的目标。由于初始视听似然已产生峰值尖锐的后验分布，我们的模型在这些情况下并未移动。这在一定程度上源于当前视觉似然对可见性的二元处理：只要目标的任何部分可见，模型就会将其视为完全可见。此外，我们的模型只能以1米级增量移动，而人类可以通过更细微的动作调整位置。这些因素导致过早

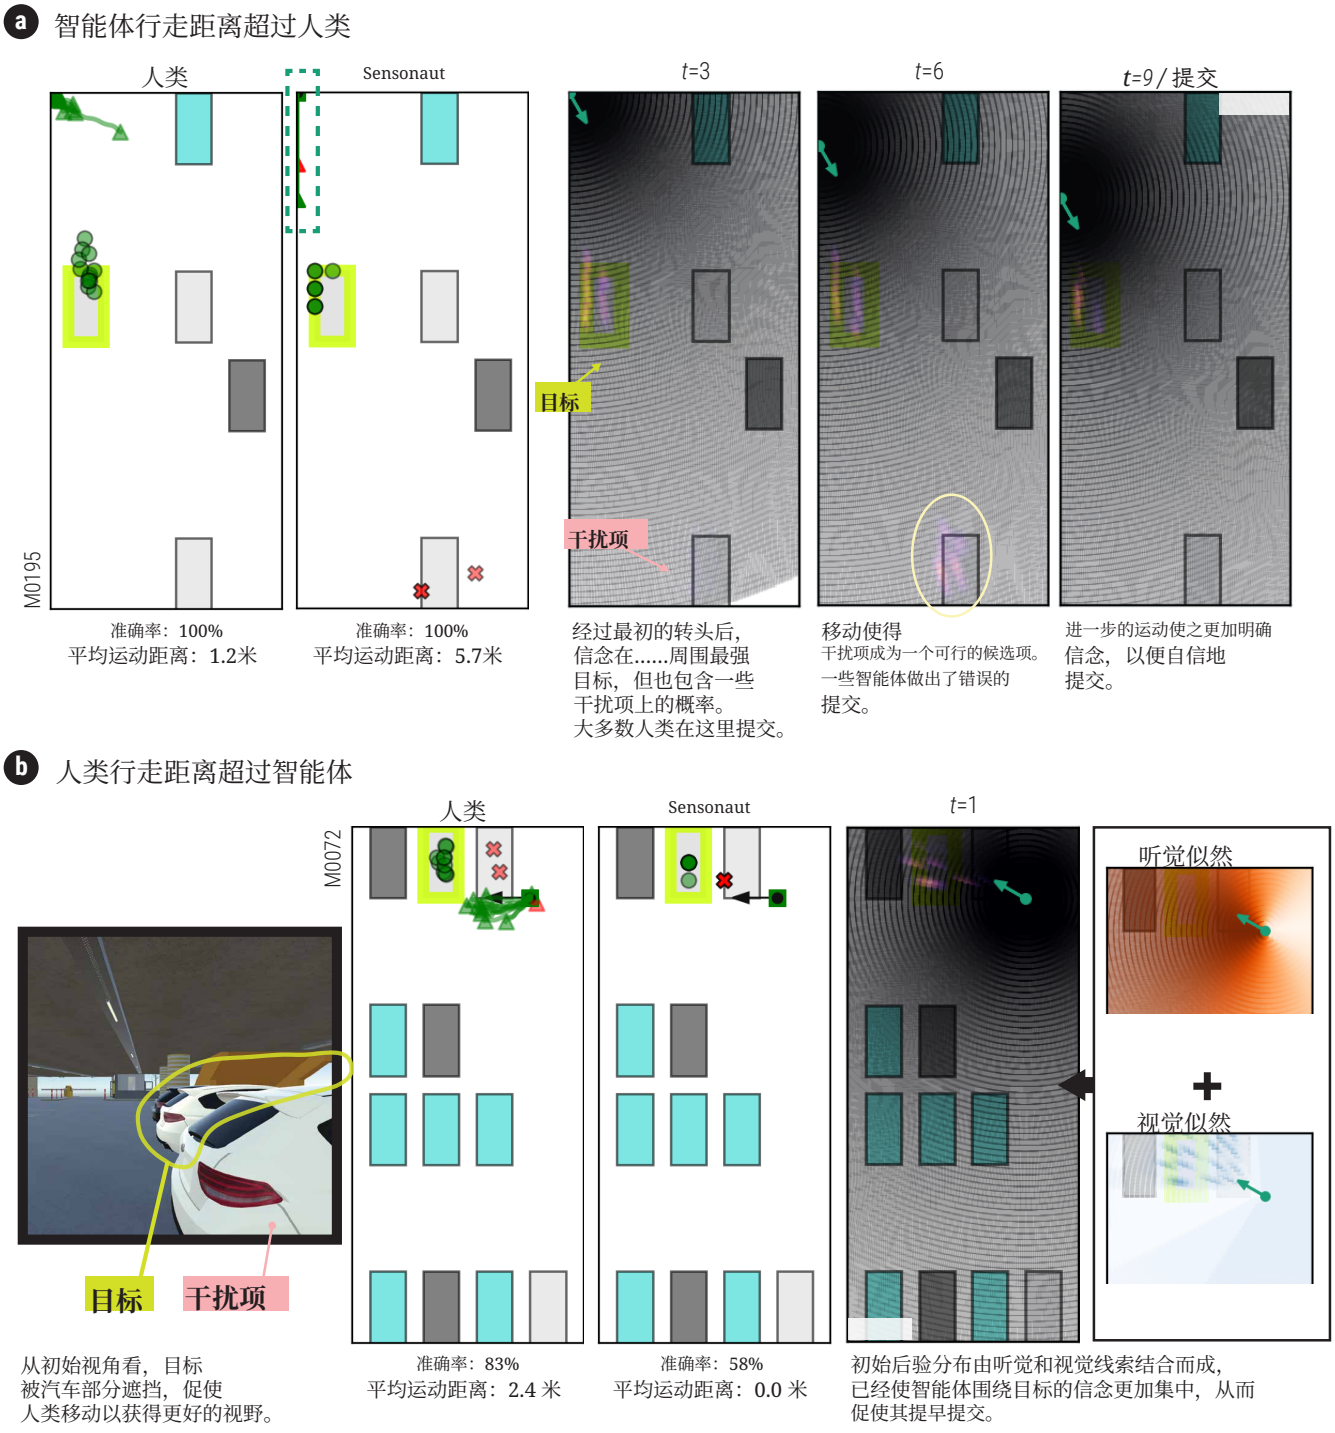


图9：人类与智能体移动差异最大的案例。(a) Sensonaut 比人类走得更远。在这类案例中，一旦目标在视觉上变得合理，人类往往会提前提交，而 Sensonaut 则继续移动以消除剩余歧义，有时因此导致错误提交。(b) 人类比 Sensonaut 走得更远。部分视觉信息促使人类移动以获得更清晰的视野，但 Sensonaut 由于初始视听似然已形成峰值明显的后验分布，进而触发立即提交，因此提前停止。

确定性和受抑制的移动，而人类在只能看到物体一部分时仍会继续收集证据。

6 讨论

我们的工作旨在深化对视听搜索的理解，并为其提供计算方面的支持。尽管视听搜索在虚拟现实、混合现实和物理环境中都很常见，但此前人们对如何解决这类任务缺乏可操作的见解。本文提出了一种新的计算理论，首次解释并预测用户的具身动作。在贝叶斯理想观察者模型等既有方法的基础上，我们的理论认为，人们会通过头部旋转和移动形成信念，从而帮助自己辨别目标。重要的是，用户会考虑这些行动的成本，并将其与高效完成任务的概率权衡。在时间压力下，他们不得不"冒险"，在不确定的情况下做出决定。

我们展示了如何在计算模型中实现该理论，并使用一项真实感搜索任务的数据对模型进行了检验。Sensonaut在决策理论模型（部分可观测马尔可夫决策过程，POMDP）中实现了资源理性，使我们能够在奖励函数中同时编码效用和成本。部分可观测马尔可夫决策过程适用于这项任务，因为它假设奖励会延迟出现（序列性），且必须在不确定性下选择行动（部分可观测性）。然而，POMDP此前缺少信念形成模型；我们提出以对两种信号进行概率整合的方式来建模信念形成。通过强化学习求解由此得到的POMDP后，模型能够逐时刻预测搜索行为。

总而言之，该模型的预测与人类数据中的四个关键变量中的三个相符：搜索时间、头部旋转和成功率。随着汽车和干扰物数量增加，该模型也捕捉到了人类数据中观察到的影响，以及目标方向的影响。不过，在移动位移方面，我们观察到一处差异：人类通常会在试次开始时迈出一步，而模型由于预设的成本而避免这样做。但在涉及较长移动路径的试次中，该模型的表现则更为吻合。值得肯定的是，所有这些发现都源于同一项基本原理。因此，我们的结果为资源理性作为一种关键认知机制的可行性提供了强有力的证据。

6.1 应用与更广泛的影响

Sensonaut 可作为一种分析工具，用于通过计算机模拟评估空间布局、用户界面或辅助系统如何影响用户定位信息的能力。实践者可以在与其应用领域相符的环境中训练模型，然后利用学习到的策略评估哪些布局可能会使用户困惑、哪些干扰物最具误导性，或哪些位置会造成不确定性，因而需要投入更多时间或精力。

除了静态仿真外，该模型还可作为自动化设计优化的目标函数，或支持人工智能助手或机器人引导用户前往信息更丰富的视点。此外，该模型可在多种平台上运行，例如 Unity3D，从而支持其在混合现实环境和游戏中的应用。为促进这些应用，我们将发布本文发表后，模型和训练代码将以开放源代码形式发布。

除视听搜索外，底层计算结构还可推广到更广泛的人机交互问题，这些问题涉及感知、不确定性和主动探索。许多交互任务要求用户整合不完美的线索、评估部分可见性，或在获取更多信息与依据不完整的知识采取行动之间做出选择。相关示例包括打字 [48], 图表阅读 [47], 在增强现实与物理环境之间切换注意力 [3], 虚幻现实交互 [25, 29], 以及人机交互 [50]。基于信念的模型能够统一表示多个感官通道中的不确定性，并模拟用户如何收集证据、可能在哪里感到困惑，以及何时容易过早做出决断。这些能力表明，资源理性模型可得到更广泛的应用，成为理解交互系统中的感知与决策的工具。

6.2 局限性与未来工作

我们的分析揭示了运动不匹配的潜在结构性成因。Sensonaut 目前尚未对人类近距离偏差进行建模，即人类往往会将较近的候选项作为第一估计，即使较远的候选项仍然合理。这导致智能体在某些情况下比人类走得更远。视觉似然还将智能体所见的可见性视为二元状态，因此当目标只有一部分可见时，智能体会过早产生确定感。相比之下，人类常会迈出一两小步进行探索，以消除部分遮挡带来的影响。这些问题还受到智能体粗略动作空间的加剧：智能体每步前进一米，且转向与移动彼此分离；而人类则会在连续行走的同时转动身体。纳入更精细的具身动力学和分级可见性，是提升我们方法有效性的一个有前景的下一步。

Sensonaut 建模的是单一资源理性策略，而非人类策略的分布。因此，我们的评估聚焦于人类与智能体行为之间的对齐，这与人机交互中用户仿真方面的先前工作 [12, 47, 48], 类似，而不是采用经典统计检验对人类与智能体"群体"之间的差异进行零假设检验，因为 Sensonaut 更接近个体。通过参数化变体扩展该模型，以反映不同的人类策略，是一个重要方向。尽管我们的被试内数据集（N=12）揭示了系统性的行为模式，但它并未涵盖人类行为的全部多样性。更大规模的数据收集将支持更广泛的验证，并有助于学习个体差异。我们计划未来在这一方向上拓展研究。用于支持该方向的数据集、模型和数据收集软件可在
h
ttps://aug
mented-perception.org/publications/2026-sensonaut. html 获取。

7 结论

沉浸式环境中的视听搜索可以理解为资源理性行为：人们整合存在不确定性的听觉和视觉线索，并有策略地移动头部和身体，以减少歧义。我们推出了 Sensonaut，一种计算

模型，将这一过程形式化为部分可观测马尔可夫决策过程，并利用强化学习近似人类策略。该模型再现了行为的关键模式：准确率较高，仅在存在干扰物和背面角度时略有下降；在歧义较大的情况下，搜索时间更长、转头次数更多；除非必要，否则几乎不行走。更重要的是，它还再现了人类典型的失误模式，揭示了视觉角度对齐的干扰物如何引发虚假确定性，导致错误提交。该模型通过信念更新和具身行动来解释具身视听搜索行为。Sensonaut 兼顾知觉整合与动作成本，不仅能预测结果，还能阐明其背后的过程，为扩展现实和辅助系统的基于仿真的设计奠定基础，使其能够预判用户行为，并根据人类的限制调整引导方式。

致谢

本研究获欧洲研究理事会高级资助（编号101141916）、芬兰研究理事会Subjective Functions项目（资助编号357578）、芬兰人工智能中心（资助编号328400、345604、341763）、韩国国家研究基金会（RS-2023-00223062）以及信息与通信技术规划与评估研究所（RS-2020-II201361）的支持。

参考文献

[1] David Alais和David Burr。2004年。腹语效应源于近似最优的双模态整合。《当代生物学》14，3（2004年2月），257–262。doi:10.1016 2004 01 029 / j.cub. . . Dora E Angelaki、Yong Gu和Gregory C DeAngelis。2009年。多感官整合：心理物理学、神经生理学与计算。《神经生物学当前观点》19，4（2009），452–458。[3] Yunpeng Bai、Aleksi Ikkala、Antti Oulasvirta、Shengdong Zhao、Lucia J Wang、Pengzhi Yang和Peisen Xu。2024年。Heads-Up Multitasker：模拟光学头戴式显示器上的注意力切换。载于《*2024*年*CHI*人机交互会议论文集》。1–18。[4] Roberto Barumerli、Piotr Majdak、Michele Geronazzo、David Meijer、Federico Avanzini和Robert Baumgartner。2023年。人类对宽带静态声源进行方向定位的贝叶斯模型。《声学学报》7（2023），12。[5] Peter W Battaglia、Robert A Jacobs和Richard N Aslin。2003年。用于空间定位的视觉与听觉信号贝叶斯整合。《美国光学学会杂志*A*》20，7（2003），1391–1397。[6] Marcel Binz和Eric Schulz。2022年。通过资源理性强化学习对人类探索进行建模。《神经信息处理系统进展》35（2022），31755–31768。[7] Jens Blauert。1997年。空间听觉：人类声源定位的心理物理学。MIT出版社。[8] Baptiste Bouvier、Patrick Susini、Catherine Marquis-Favre和Nicolas Misdariis。2023年。通过音色属性对听觉显著性的调制，揭示由刺激驱动的注意力成分。《科学报告》13，1（2023），6842。[9] W Owen Brimijoin和Michael A Akeroyd。2012年。头部运动和信号频谱在听觉前后错觉中的作用。《*i-Perception*》3，3（2012），179–182。[10] Changan Chen、Ziad Al-Halah和Kristen Grauman。2021年。语义视听导航。载于《*IEEE/CVF*计算机视觉与模式识别会议论文集》。15516–15525。[11] Changan Chen、Unnat Jain、Carl Schissler、Sebastia Vicenc Amengual Gari、Ziad Al-Halah、Vamsi Krishna Ithapu、Philip Robinson和Kristen Grauman。2020年。Soundspaces：三维环境中的视听导航。载于《欧洲计算机视觉会议》。施普普林格，17–36。[12] Xiuli Chen、Aditya Acharya、Antti Oulasvirta和Andrew Howes。2021年。基于注视的选择自适应模型。载于《*2021*年*CHI*人机交互会议论文集》。1–11。[13] Yi Fei Cheng和David Lindlbauer。2025年。在环境信息环境中感知可注意性。载于《*2025*年*CHI*人机交互会议论文集》。1–17。[14] Hyunsung Cho、Drew Edgar、David Lindlbauer和Joseph O'Hagan。2025年。评估XR中音频+视觉消息通知的动态传递。载于《*2025*年*IEEE*虚拟现实与三维用户界面会议（*VR*）》。IEEE，277–287。[15] Hyunsung Cho、Naveen Sendhilnathan、Michael Nebeling、Tianyi Wang、Purn- ima Padmanabhan、Jonathan Browder、David Lindlbauer、Tanya R. Jonker 和 Kashyap Todi。2024。SonoHaptics：一种用于扩展现实（XR）中基于注视的物体选择的音频-触觉光标（UIST '24）。美国计算机协会，纽约，纽约州，美国。doi:10.1145/3654777.3676384[16] Hyunsung Cho、Alexander Wang、Divya Kartik、Emily Liying Xie、Yukang Yan 和 David Lindlbauer。2024。Auptimize：扩展现实中空间音频线索的最优放置。载于第37届 ACM用户界面软件与技术研讨会年会论文集。1–14。[17] Seungwon Do 和 Byungjoo Lee。2020。提升虚拟碰撞响应可靠性：一种线索整合技术。载于2020年 CHI人机交互会议论文集。1–12。[18] Jan Drugowitsch、Rubén Moreno-Bote、Anne K Churchland、Michael N Shadlen 和 Alexandre Pouget。2012。知觉决策中累积证据的成本。《神经科学杂志》32，11（2012），3612–3628。[19] Marc O. Ernst 和 Martin S. Banks。2002。人类以统计学最优的方式整合视觉和触觉信息。《自然》415，6870（2002年1月），429–433。doi:10.1038/415429a[20] João Marcelo Evangelista Belo、Mathias N Lystbæk、Anna Maria Feit、Ken Pfeuffer、Peter Kán、Antti Oulasvirta 和 Kaj Grønbæk。2022。AUIT——用于设计扩展现实应用的自适应用户界面工具包。载于第35届 ACM用户界面软件与技术研讨会年会论文集。1–16。[21] Christopher R Fetsch、Alexandre Pouget、Gregory C DeAngelis 和 Dora E Angelaki。2012。多感官整合中基于可靠性的线索加权的神经相关机制。《自然·神经科学》15，1（2012），146–154。[22] Daniel J Finnegan、Eamonn O'Neill 和 Michael J Proulx。2016。利用不一致性补偿视听虚拟环境中的距离压缩。载于2016年 CHI人机交互会议论文集。200–212。[23] Bill Gardner、Keith Martin 等。1994。KEMAR假人头麦克风的HRTF测量。[24] Petros Giannakopoulos、Aggelos Pikrakis 和 Yannis Cotronis。2021。采用深度强化学习的多说话人环境音频导航方法。载于ICASSP 2021——2021 IEEE声学、语音与信号处理国际会议（ICASSP）。IEEE，3475–3479。[25] Eric J Gonzalez 和 Sean Follmer。2023。利用随机最优反馈控制对重定向伸手进行感觉运动仿真。载于2023年 CHI人机交互会议论文集。1–17。[26] D Wesley Grantham 和 Frederic L Wightman。1978。变化的双耳时间差的可检测性。a《美国声学学会杂志》63，2（1978），511–523。[27] Tim Halverson 和 Anthony J Hornof。2011。用于人机交互中视觉搜索的"主动视觉"计算模型。《人机交互》26，4（2011），285–314。[28] Takao Imai、Steven T Moore、Theodore Raphan 和 Bernard Cohen。2001。行走和转向过程中身体、头部与眼睛之间的相互作用。《实验脑研究》136，1（2001），1–18。[29] Mohamed Kari 和 Parastoo Abtahi。2025。Reality Promises：通过隐形移动机器人在混合现实中实现虚实解耦错觉。载于第38届 ACM用户界面软件与技术研讨会年会论文集。1–17。[30] Emine Merve Kaya 和 Mounya Elhilali。2017。听觉注意建模。《英国皇家学会哲学汇刊B辑：生物科学》372，1714（2017），20160101。[31] Wessel Ledder、Yuzhen Qin 和 Kiki van der Heijden。2025。自然环境中的头部朝向音频驱动强化学习。载于ICASSP 2025——2025年 IEEE声学、语音与信号处理国际会议（ICASSP）。IEEE，1–5。[32] Zhipeng Li、Yi Fei Cheng、Yukang Yan 和 David Lindlbauer。2024。预测虚拟现实中动态虚拟元素的可注意性。载于2024年 CHI人机交互会议论文集。1–17。[33] Falk Lieder 和 Thomas L. Griffiths。2020。资源理性分析：将人类认知理解为对有限计算资源的最优利用。《行为与脑科学》43（2020），e1。doi:10.1017/S0140525X1900061X[34] Piotr Majdak、Fabian Brinkmann、Julien De Muynke、Michael Mihocic 和 Markus Noisternig。2022。空间定向声学格式2.1：简介与最新进展。《音频工程学会杂志》70（2022），565–584。[35] Tobias May、Steven van de Par 和 Armin Kohlrausch。2011。一种基于双耳听觉前端的鲁棒定位概率模型。IEEE音频、语音与语言处理汇刊19，1（2011年1月），1–13。doi:10.1109/TASL.2010.2042128[36] Ken I McAnally 和 Russell L Martin。2014。通过头部运动进行声源定位：对三维音频显示的启示。《神经科学前沿》8（2014），79254。[37] Glen McLachlan、Piotr Majdak、Jonas Reijniers、Michael Mihocic 和 Herbert Peremans。2025。贝叶斯主动声源定位：人类在多大程度上表现得像理想观察者？《PLOS计算生物学》21，1（2025），e1012108。

[38] John C Middlebrooks 和 David M Green。1991。人类听者的声源定位。《style id='2'>年度心理学评论 42（1991），135–159。[39] Volodymyr Mnih、Koray Kavukcuoglu、David Silver、Alex Graves、Ioannis Antonoglou、Daan Wierstra 和 Martin Riedmiller。2013。使用深度强化学习玩Atari游戏。《style id='5'>arXiv预印本 arXiv:1312.5602（2013）。[40] Jiri Najemnik 和 Wilson S Geisler。2005。视觉搜索中的最优眼动策略。《style id='8'>自然 434，7031（2005），387–391。[41] Mark E Nelson 和 Malcolm A MacIver。2006。主动感知系统中的感觉信息获取。《style id='11'>《比较生理学杂志A辑》 192，6（2006），573–586。[42] Sheryl Paul、Anand Balakrishnan、Xin Qin 和 Jyotirmoy V Deshmukh。2024。使用进化博弈为定时任务进行多智能体路径规划。载于定量评估系统与定时系统形式化建模和分析国际会议。施普林格，302–321。[43] Vedran Planinec、Jonas Reijniers、Marko Horvat、Herbert Peremans 和 Kris- tian Jambrošić。2023。采用头部追踪的双耳音频系统中动态声源定位的准确率，以及个体头相关传递函数的辨识能力。《style id='17'>《应用科学》 13，9（2023），5254。[44] Thierry Pozzo、Alain Berthoz 和 Loic Lefort。1990。人类在各种运动任务中的头部稳定：I. 正常受试者。《style id='20'>《实验脑研究》 82，1（1990），97–106。[45] J. Reijniers、D. Vanderelst、C. Jin、S. Carlile 和 H. Peremans。2014。人类声源定位的理想观察者模型。《style id='23'>《生物控制论》 108，2（April 2014 169 181 10 1007 00422 014 0588 4），–。doi: . /s - - - Stefan Riedel、[46] Matthias Frank 和 Franz Zotter。2025。头相关传递函数与头部运动对真实和虚拟录音室环境中视听定位的影响。《style id='26'>《声学学报》 9（2025），21。[47] Danqing Shi、Yao Wang、Yunpeng Bai、Andreas Bulling 和 Antti Oulasvirta。2025。Chartist：用于图表阅读的任务驱动眼动控制。载于*2025*年 *CHI*人机交互会议论文集。1–14。[48] Danqing Shi、Yujun Zhu、Jussi PP Jokinen、Aditya Acharya、Aini Putkonen、Shumin Zhai 和 Antti Oulasvirta。2024。CRTypist：通过计算理性模拟触摸屏打字行为。载于*2024*年 *CHI*人机交互会议论文集。1–17。[49] Barbara G Shinn-Cunningham、Scott Santarelli 和 Norbert Kopco。2000。混淆环面：听者可及范围内声源的双耳定位线索。《style id='35'>《美国声学学会杂志》 107，3（2000），1627–1636。[50] Kyle Strabala、Min Kyung Lee、Anca Dragan、Jodi Forlizzi、Siddhartha S Srinivasa、Maya Cakmak 和 Vincenzo Micelli。2013。迈向无缝人机交接。《style id='38'>《人机交互杂志》 2，1（2013），112–132。[51] H. Wallach。1940。头部运动、前庭线索和视觉线索在声源定位中的作用。《style id='41'>《实验心理学杂志》 27，4（1940年10月），339–368。doi:10.1037/h0054629[52] Jeremy M Wolfe。2021。Guided Search 6.0：视觉搜索的更新模型。《style id='44'>《心理学通报与评论》 28，4（2021），1060–1092。[53] Robert Sessions Woodworth 和 Harold Schlosberg。1954。《style id='47'>实验心理学。牛津与IBH出版社。

A 训练：模型架构与 PPO 超参数

自我们特征提取器实现了一个多分支特征提取器，将低维历史向量与可选的高维后验图相结合。

输入与分支：

- est_theta $\in \mathbb{R}^H$：多层感知机 $[H \to 128 \to 128]$，在隐藏层使用层归一化 $\to$ 128-D。
- theta_不确定性 $\in \mathbb{R}$：多层感知机 $[1 \to 32 \to 32] \to$ 32-D。
- est_r $\in \mathbb{R}^H$：多层感知机 $[H \to 128 \to 128]$，使用层归一化 $\to$ 128-D。
- r_不确定性 $\in \mathbb{R}$：多层感知机 $[1 \to 32 \to 32] \to$ 32-D。
- 最近_个 $\in$ 动作 H多重离散空间，卡 $= 6$）：每个时间步（H 个词元）进行词元嵌入（大小为 8） $\to$ 展平 $H \times 8 \to$ 多层感知机 $[H \cdot 8 \to 64 \to 64] \to$ 64-D。可兼容索引、独热编码或展平的独热编码。
- 后验分布 $\in \mathbb{R}^{R\Theta}$（视为二维映射）：重塑为 $(1,\ R = 30,\ \Theta)$ $\to$ 二维卷积$(1 \to 16,\ 3 \times 5,\ s = (1,\ 2)\ p = (1,\ 2))$ +修正线性单元 $\to$ 二维卷积$(16 \to 32,\ 3 \times 3,\ s = 2,\ p = 1)$ + 修正线性单元 $\to$自适应平均池化 $2\ \ 1 \times 1 \to 32 \to 32 \to$ d( ) 层归一化( ) $256 \to 256$ 线性层( ) 修正线性单元 -D。
- 后验分布_熵 $\in \mathbb{R}$：多层感知机 $[1 \to 16 \to 16] \to$ 16-D。

输出维度： $128 + 32 + 128 + 32 + 64 + 256 + 16 = 656$。

提取器将所有活动分支的输出拼接起来，并返回此特征向量，随后将其传递给 SB3 的策略/价值头。

PPO 策略与优化。 我们使用此提取器作为特征_提取器_类来训练 PPO （ Stable-Baselines3 ）。行动者 – 评论家使用独立的多层感知机头：

- **策略头（π）：** $[256, 256, 256]$。
- **价值头（V）：** $[256, 256, 256]$。

超参数：

- 算法：近端策略优化（SB3）
- 策略：多输入策略（使用自定义特征提取器）
- 设备：NVIDIA GeForce RTX 3090。CUDA 12.9
- 学习率：3×10^{-4}
- 采样长度：$n_steps = 4096$
- 批量大小：4096（每次采样进行全批量更新）
- 折扣因子：0.99
- 广义优势估计 λ：0.95
- _ 10 训练轮数：裁剪范围：.2
- 训练步数：1,000,000
- 随机种子编号：42

B 模型参数

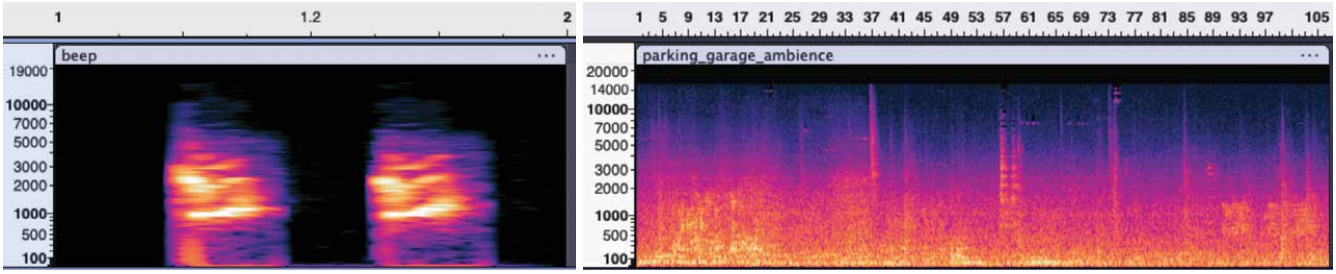
所有模型参数均列于表1。

C 数据收集中的声音

数据收集研究中汽车鸣笛声和背景声的频谱图如图10所示。

表1：Sensonaut 模型参数摘要。每个参数均列出默认值，并根据任务设计、知觉建模假设或深度强化学习（RL）中的标准做法简要说明其依据。

参数名称	值	描述
状态与动作		
历史长度	4	状态中存储的过往观测数量。为处理部分可观测性提供短期记忆，并使模型能够学习近期具身动作的后果。长度为 4 也遵循常见的部分可观测强化学习实践，例如 DQN [39] 中的 4 帧堆叠。
转向角	30°	每次转向动作的角增量。与行走时头部角速度的平均最大值相符，同时确保动作空间适用于强化学习。
步幅	1 m	前向移动步长。近似于人类的平均步距 [28, 44] 同时确保在基于网格的导航任务中进行一致且高效的探索。
最大步数 回合	an 30	对回合长度设置上限，以鼓励高效搜索并防止出现退化的长时间试次。这是强化学习导航任务中的常见做法（例如 [42]），并根据难度进行了调整以适应我们的 13×29 搜索地图。
奖励		
任务奖励	10	正确定位目标所获得的正向奖励。它为其他奖励设定尺度，并鼓励提高准确率。
时间步惩罚	0.1	每个时间步收取少量成本，以避免闲置并鼓励高效的搜索行为。
前进惩罚	0.3	针对移动的惩罚，经过调整以反映体力付出成本，并偏向于最小化运动。
转向惩罚	0.1	针对头部/身体转向动作的惩罚，以反映旋转较低但非零的具身成本经过调整，使转头保持低成本，但并非没有成本。
碰撞惩罚	5.0	设置较高的惩罚，以防止智能体与障碍物发生碰撞，确保轨迹真实且安全。
感知		
视野	110°	智能体的视野，用于近似人类使用时的水平视野 Meta Quest 3 头显。
新证据融合系数——数 α	0.8	用于控制新感官证据相较于旧证据对信念的更新力度。经过调节，可确保信念稳定更新，避免过度敏感。
视觉-听觉比率	0.7	控制视觉和听觉似然在后验分布中相对影响力的权重因子。基于贝叶斯线索整合原理，每种感官模态的权重根据其可靠性进行加权 [1, 19]..
ITD噪声尺度	30 μ秒	应用于双耳时间差（ITD）线索的噪声尺度。与已知的人类低频下双耳时间差辨别的检测阈值相符 [26]。
视觉证据融合因子 λ_{visual}	0.7	整合新的视觉证据与过去视觉证据时所使用的相对权重。通过经验调节以匹配人类行为中明显的视觉主导。
可见物体权重	5.0	在信念更新中强调可见物体贡献的权重，确保较强的视觉确认的影响。经调参以促进逼真的视听整合。
视觉排除衰减 δ	0.5	用于排除先前已见物体的衰减率。经经验调参。



汽车鸣笛声 停车场背景声

图 10：数据收集研究中汽车鸣笛声和停车场背景噪声的频谱图。