基于认知不确定性建模的多智能体协同决策策略

贾颖淼[1]，范书瑞[1,2†]，张 勇[3]，李 颖[1]，夏克文[1]，王 莉[1]

(1. 河北工业大学 电子信息工程学院，天津 300401；
2. 河北工业大学 创新研究院 (石家庄)，石家庄 050299；
3. 天津商业大学 信息工程学院，天津 300134)

摘 要: 在大尺度三维空间中, 气体扩散呈现出明显的各向异性、空间非均匀性与时间间歇性特征, 使传统信息趋向策略在环境认知表征与运动决策过程中难以有效刻画搜索过程中的不确定性演化, 从而影响搜索效率与决策稳定性. 针对上述问题, 提出一种基于认知不确定性建模的多智能体协同搜索决策策略. 在统一的贝叶斯推断框架下, 利用加权粒子方差对环境认知不确定性进行量化, 实现对认知状态的动态表征. 在此基础上, 构建信息-势场联合驱动的决策模型, 并基于认知不确定度量设计自适应权重调节策略与各向异性步长调节机制, 使搜索策略能够根据环境认知状态变化动态调节探索与利用之间的平衡以及不同方向上的运动尺度. 同时, 引入约束更新协商机制实现多智能体系统之间的决策交换, 以降低协同行为冲突与路径冗余. 仿真实验结果表明, 本研究提出的多智能体协同决策策略能够有效提升气味源搜索任务中的搜索效率、决策稳定性与鲁棒性.

关键词: 信息趋向；粒子滤波；认知不确定性；自适应权重；各向异性步长；协同决策；多智能体系统

中图分类号: TP242.6 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2026.0176

引用格式: 贾颖淼, 范书瑞, 张勇, 等. 基于认知不确定性建模的多智能体协同决策策略 [J]. 控制与决策.

A multi-agent cooperative decision strategy based on cognitive uncertainty modeling

JIA Ying-miao[1]，*FAN Shu-rui*[1,2†]，*ZHANG Yong*[3]，*LI Ying*[1]，*XIA Ke-wen*[1]，*WANG Li*[1]

(1. School of Electronic and Information Engineering，Hebei University of Technology，Tianjin 300401，China；2. Innovation and Research Institute，Hebei University of Technology，Shijiazhuang 050299，China；3. School of Information Engineering，Tianjin University of Commerce，Tianjin 300134，China)

Abstract: In large-scale three-dimensional environments, gas diffusion exhibits pronounced anisotropy, spatial non-uniformity, and temporal intermittency. These characteristics make it difficult for traditional infotaxis-based strategies to effectively characterize the dynamic evolution of uncertainty in environmental cognition and motion decision-making, thereby affecting search efficiency and decision stability. To address these challenges, a multi-agent cooperative search decision-making strategy based on cognitive uncertainty modeling is proposed. Within a unified Bayesian inference framework, the weighted particle variance of the posterior particle distribution is used to quantify environmental cognitive uncertainty, enabling dynamic representation of the cognitive state during the search process. On this basis, an information-potential-field jointly driven decision-making model is constructed. Furthermore, a variance-adaptive weighting strategy and an anisotropic adaptive step-size strategy are designed based on the cognitive uncertainty measure, allowing the search strategy to dynamically adjust the balance between exploration and exploitation, as well as the motion scale in different directions, in response to changes in the environmental cognitive state. In addition, a constraint update negotiation mechanism is introduced to enable decision exchange and coordination among agents, thereby reducing cooperative conflicts and path redundancy. Simulation results demonstrate that the proposed multi-agent cooperative decision-making strategy effectively improves search efficiency, decision stability, and robustness in odor source localization tasks.

收稿日期: 2026-03-05；**录用日期:** 2026-06-25.

基金项目: 国家自然科学基金面上项目 (42075129); 石家庄市科技合作专项 (SJZZXA24006); 中央引导地方科技发展资金项目 (264Z1818G).

责任编委: 王龙.

†通信作者. E-mail: fansr@hebut.edu.cn.

Keywords: infotaxis；particle filtering；cognitive uncertainty；adaptive weight；anisotropic step size；collaborative decision-making；multi-agent systems

0 引言

气味源定位 (Odor Source Localization, OSL) 在危险化学品泄漏预警[1]、城市环境监测[2]、工业安全防护[3] 以及灾害应急救援[4] 等领域具有重要的应用价值[5]. 在真实复杂风场条件下, 气体羽流呈现间歇性、斑块化和强随机性, 使固定式传感器难以实现高精度定位[6]. 相比之下, 搭载化学传感器的移动机器人具备更高的机动性和自主决策能力[7], 已成为应对复杂环境气体探测任务的核心技术.

但是, 湍流扩散的非均匀[8] 和非稳态特性[9] 使浓度信号极为稀疏, 传统梯度法与逆扩散方法往往难以稳定工作. 同时, 群体智能算法缺乏对环境不确定性与气体扩散机理的定量刻画[10-12]. 因此, 近年来研究者逐渐引入贝叶斯推理与信息论度量方法[13], 通过概率推断对气味源位置进行建模, 并以信息增益最大化作为决策依据, 从而形成了一类典型的信息驱动搜索策略.

自 Vergassola 等提出 Infotaxis[14] 以来, 基于信息增益最大化的概率推理框架逐渐成为 OSL 的重要研究方向. Moraud 等[15] 将 Infotaxis 应用于机器人平台, 验证了其在稀薄信号下的有效性. 随后研究者围绕信息度量形式、动作生成机制以及概率认知建模等方面对 Infotaxis 进行了持续改进. Ristic 等人将粒子滤波引入到信息趋向框架, 并提出了弱化利用项的 Infotaxis II[16]. He 等人[17] 利用 Rényi 散度代替传统信息熵, 用于河流与海洋环境中的源释放定位任务. Park 等人[18] 引入高斯混合模型对粒子后验分布进行聚类分析, 从而生成连续的候选动作集合. Sun 等[19] 进一步提出基于生成模型的信息趋向方法, 通过高斯混合气柱与概率图推断实现源参数估计. Song 等人[20] 则尝试将信息熵项与势能项相结合, 用于增强自主嗅觉搜索过程中的目标趋近能力. 上述研究在单智能体气味源搜索问题上取得了较为丰富的成果, 并在多种仿真与半真实环境中得到验证[21-24].

然而, 在搜索空间尺度显著增大、羽流结构高度间歇、气流条件动态变化的情形下, 单智能体搜索策略往往难以同时兼顾搜索效率与定位精度, 其在信息获取速率、空间覆盖能力以及路径冗余控制等方面的固有限制尤为突出. 因此, 多智能体系统 (Multi-Agent Systems, MAS) 被引入气味源搜索任务中, 通过多平台的协作感知、分布式决策与并行搜索, 实现大尺度范围内的高效溯源.

2009 年, Masson 等人[25] 首先将 infotaxis 扩展至多机器人系统. 张思齐等[26] 基于自由能最小化原理建立了气味源概率分布模型, 通过最小化自由能实现个体决策与群体协同. Karpas[27] 等人提出 Socialtaxis, 将社会行为建模引入信息趋向框架. 宋程等人[28, 29] 进一步提出基于认知差异的协同信息趋向算法, 首次引入了个体认知差异度量机制. Rahbar 等人[30] 提出分布式源项估计算法, 在贝叶斯框架下实现了多机器人间的后验信念传播与动态一致化, 有效降低了计算负担并提高了估计精度. Nanavati 等人[31] 将分布式贝叶斯滤波与覆盖控制相结合, 提出了一种基于共识的信念更新机制. Park 等[32] 则从通信与协作角度出发, 引入被动协调与协商协调模式, 使多个智能体在共享最小信息量的条件下实现信息驱动协作搜索.

尽管上述研究在多智能体气味源搜索领域取得了重要进展, 但仍存在以下不足: 首先, 现有方法多采用单一信息度量描述搜索状态, 缺乏对粒子后验分布空间结构的系统刻画, 难以准确表征环境认知不确定性. 其次, 搜索决策通常依赖固定或经验式参数, 缺乏能够根据环境认知状态动态调节的决策机制, 导致探索与利用之间难以保持有效平衡. 最后, 多智能体系统中各个体通常独立生成局部最优动作, 缺乏有效的一致化机制, 容易产生路径冲突与冗余搜索, 从而降低整体协同效率.

针对上述问题, 本文提出一种基于认知不确定性建模的多智能体协同搜索决策策略. 首先, 从粒子滤波后验分布出发, 构建认知不确定性表征方法, 利用加权粒子方差刻画潜在源位置估计的不确定程度. 在此基础上, 构建信息-势场联合决策模型, 并设计方差自适应权重与各向异性步长调节机制, 实现探索与利用关系以及运动尺度的动态调节. 同时, 提出约束更新协商机制实现多智能体决策一致化, 从而降低路径冲突与冗余搜索, 提升群体搜索效率与稳定性.

1 三维认知建模

基于无人机平台的气味源搜索问题天然具有三维属性, 相较于二维情形, 三维气味源溯源面临更高的建模与决策复杂度, 本节构建适用于三维运动的贝叶斯推断框架, 为后续决策提供不确定性感知基础.

1.1 气体扩散模型与传感器模型

在宏观湍流环境中, 气体扩散往往表现出各向异性特征, 因此传统信息趋向算法中常用的各向同性湍流模型并不适用于三维环境, 研究学者们常选用高斯湍流模型作为气体扩散模型, 以更准确地描述浓度变化. 高斯湍流模型由气味源位置$r_s=[x_s, y_s, h_s]$, 气体释放速率Q_s, 平均风速V, 以及扩散系数σ进行描述, 整个参数集合由θ表示. 标准高斯气体扩散模型认为气体浓度沿扩散方向呈正态分布, 通过引入横向、垂直扩散系数, 进一步细化不同方位的浓度分布, 在感知位置$r_k=[x_k, y_k, h_k]$上计算得到的浓度为:

$$c(r_k|\theta)=\frac{Q_s}{2\pi V\sigma_y\sigma_h}e^{-\frac{(y-y_s)^2}{2\sigma_y{}^2}}[e^{-\frac{(h-h_s)^2}{2\sigma_h{}^2}}+e^{-\frac{(h+h_s)^2}{2\sigma_h{}^2}}]. \tag{1}$$

公式中, 风向沿x轴正半轴, $\sigma_y=\dfrac{0.08dx}{\sqrt{1+0.001dx}}$代表横向扩散系数, $\sigma_h=\dfrac{0.06dx}{\sqrt{1+0.001dx}}$代表垂直扩散系数.

在气味溯源过程中, 传感器模型用于计算粒子在当前观测下的似然概率. Infotaxis 策略中将传感器捕获羽流信号的过程建模为粒子碰撞, 并用粒子碰撞率$R(r_k|r_s)$来描述信号的空间分布, 对于位于r_s的气味源, 传感器在位置r_k的粒子碰撞率$R(r_k|r_s)$表现为:

$$R_{3D}(r_k|r_s)=\frac{aQ_s}{|r-r_s|}e^{\frac{(x-x_s)V}{2D}}e^{-\frac{|r-r_s|}{\lambda}}. \tag{2}$$

传感器的检测可以理解为对进入其敏感区域的气体粒子的统计过程, 粒子击中传感器的行为可视为相互独立的到达事件. 因此, 整个检测过程可以用泊松过程进行建模, 传感器在时间窗口dt内检测到粒子的概率可以表示为:

$$p(z_k|\mu_k)=\frac{{\mu_k}^{z_k}}{z_k!}e^{-\mu_k}. \tag{3}$$

其中, $\mu_k=R_{3D}(r_k|r_s)*dt$代表在时间间隔 dt 内检测到粒子的平均次数, z_k代表粒子的击中次数.

1.2 联合源估计

在N个智能体组成的多智能体系统中, 假设在离散时刻k时, 第n个智能体在位置$r_{(k,n)}=[x_{(k,n)}, y_{(k,n)}, h_{(k,n)}]$处, 传感器模型获得的气体观测值为$z_{(k,n)}$. 将所有的智能体在时刻$k$的观测记为$\mathcal{Z}_k=\{z_{(k,1)}, z_{(k,2)}, ..., z_{(k,N)}\}$. 在高斯湍流扩散模型的基础上, 源位置的后验概率分布递推为:

$$p(\theta_k|\mathcal{Z}_{1:k})\propto p(\theta_k|\mathcal{Z}_{1:k-1})p(\mathcal{Z}_k|\theta_k). \tag{4}$$

其中$p(\theta_k|\mathcal{Z}_{1:k-1})$是先验概率, $p(\mathcal{Z}_k|\theta_k)$是联合似然函数, 在给定源参数$\theta_k$的条件下, 假设各智能体的观测相互独立, 则多智能体联合似然函数可表示为:

$$p(\mathcal{Z}_k|\theta_k)=\prod_{n=1}^{N}p(z_{(k,n)}|\theta_k, r_{(k,n)}). \tag{5}$$

$p(z_{(k,n)}|\theta_k, r_{(k,n)})$表示单个智能体的观测似然函数, 通过式 (3) 进行计算. 使用粒子滤波方法对后验分布进行近似表示结果如下:

$$p(\theta_k|\mathcal{Z}_{1:k})\approx\sum_{m=1}^{M}w_k^{(m)}\delta(r-r_k^{(m)}). \tag{6}$$

采样粒子$\theta_k^{(m)}=\{r_k^{(m)}, w_k^{(m)}\}_{m=1}^{M}$表示可能的源估计, 称为“潜在源项”. $r_k^{(m)}$表示估计位置, $w_k^{(m)}$表示可信度, 其更新公式如下:

$$\tilde{w}_k^{(m)}=w_{k-1}^{(m)}\prod_{n=1}^{N}p(z_{(k,n)}|\theta_k^{(m)}, r_{(k,n)}). \tag{7}$$

通过归一化得到:

$$w_k^{(m)}=\frac{\tilde{w}_k^{(m)}}{\sum_{j=1}^{M}\tilde{w}_k^{(j)}}. \tag{8}$$

为避免粒子退化问题, 在权值分布过于集中的情况下可引入重采样操作[33], 以维持粒子集合的有效样本规模. 设置阈值M_{th}, 当有效粒子数低于阈值时进行重采样操作, 舍弃低权重粒子, 并根据高权重粒子的分布重新生成粒子集合. 有效粒子数计算公式如下:

$$M_{eff}=\frac{1}{\sum_{m=1}^{M}(w_k^{(m)})^2}. \tag{9}$$

通过上述权值更新与重采样过程, 粒子分布能够随着观测信息的不断积累逐渐向高概率源区集中, 从而实现对气味源位置的持续逼近.

2 基于不确定性认知的多智能体协同决策

在多智能体联合认知建模基础上, 本节进一步研究基于共享后验的协同决策机制, 提出一种基于信息-势场的联合驱动的自适应多智能体协同决策策略 AMGraRényitaxis, 其基本框架如图 1.

2.1 认知不确定性建模

在传统信息趋向方法中, 环境认知状态通常通过后验概率的单一信息度量进行描述, 例如信息熵或 Rényi 散度. 这类度量主要反映信息增益或者概率分布的不确定程度, 难以直接刻画粒子分布在空间中的结构特征. 在粒子滤波表示中, 粒子分布的空间离散程度能够更直观地反映当前对源位置认知的不确定程度. 当粒子在空间中分布较为分散时, 说明

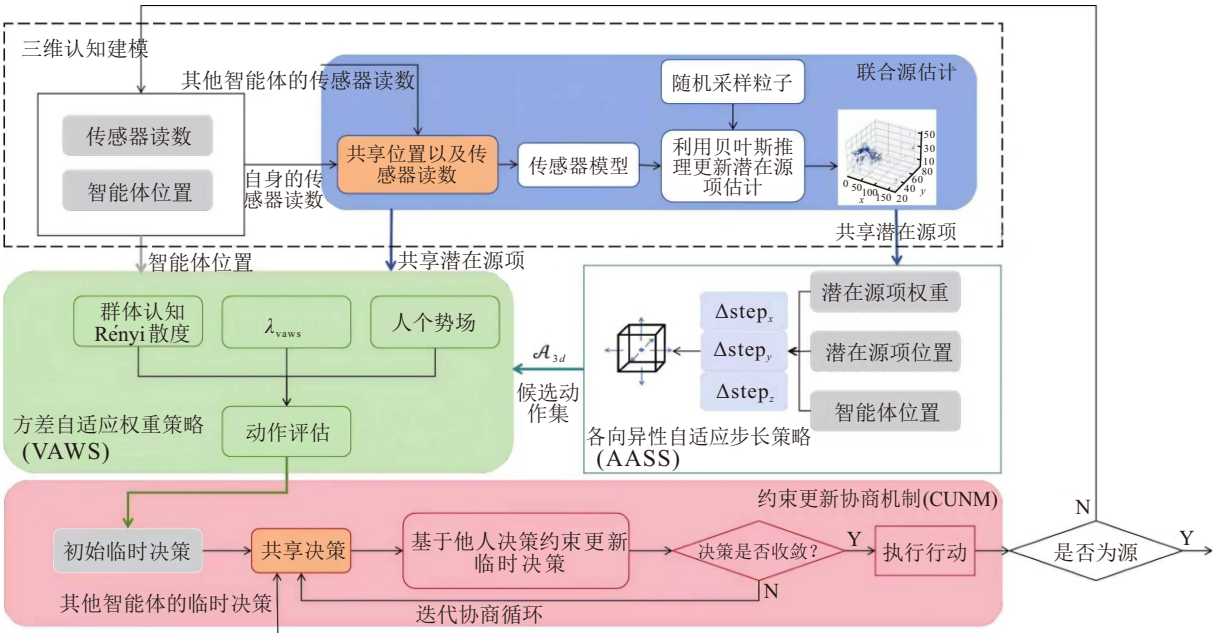

图 1 AMGraRényitaxis 框架

智能体对源位置的认知仍然存在较大不确定性. 而当粒子逐渐集中于某一区域时, 则表明认知不确定性正在降低.

基于上述认知, 本文将粒子后验分布的离散分布特性定义为认知不确定性 (Cognitive Uncertainty, CU), 为了实现对认知不确定性的量化描述, 引入加权粒子方差 (Weighted Particle Variance, WPV) 作为度量指标.

$$WPV = \sum_{m=1}^{M} w_k^{(m)} ||r_k^{(m)} - \bar{r}_k||_2^2. \tag{10}$$

其中, $\bar{r}_k$为潜在源项加权均值. WPV刻画了潜在源项在搜索空间中的整体离散程度. 当粒子分布较为分散时, WPV 取值较大, 表示智能体对源位置的认知仍存在较高不确定性. 当粒子逐渐向真实源位置收敛时, WPV 随之减小, 表明认知不确定性逐渐降低.

进一步地, 为刻画认知不确定性在不同空间方向上的分布特征, 将 WPV 分解为三个方向分量. 设粒子位置为$r_k^{(m)} = (x_k^{(m)}, y_k^{(m)}, h_k^{(m)})$, 则粒子在各空间方向上的离散程度可表示为:

$$WPV_i = \sum_{m=1}^{M} w_k^{(m)} ||i_k^{(m)} - \bar{i}_k||_2^2. \tag{11}$$

其中, $i \in (x, y, h)$表示不同空间方向, WPV_i表示粒子分布在x, y, h方向上的离散程度. 因此, WPV揭示了不确定性在不同空间方向上的分布差异, 为后续运动决策提供重要依据.

2.2 各向异性自适应步长策略

在三维空间中, 动作集合需要扩展至体素化环境, 以满足智能体在 x-y-h 三个方向上的移动需求. 典型的三维动作集合$\mathcal{A}_{3D}$包括$\{\cdot, \uparrow, \downarrow, \leftarrow, \rightarrow, \swarrow, \nearrow\}$七个动作. 七动作模型提供了智能体最基本的可达性, 使其能够在体积域中进行分层搜索, 同时保持动作结构的简洁性和计算效率.

但是在实际搜索过程中观察到, 尽管粒子的后验分布会随着观测信息的积累逐步向真实气味源位置聚集, 但由于智能体移动步长固定或仅由整体尺度调节, 其运动轨迹往往难以及时跟踪这种空间聚集过程, 尤其是在不同方向收敛速率不一致的情况下. 这种认知收敛快于运动响应的现象, 容易导致定位延迟甚至搜索效率显著下降.

为此, 本文提出一种面向三维空间的各向异性自适应步长策略 (Anisotropic Adaptive Step-Size Strategy, AASS), 该策略不再为所有空间方向分配统一的运动尺度, 而是根据认知不确定性度量WPV在不同方向上的分布差异分别确定 x, y 及高度 h 上的自适应步长, 从而使智能体运动尺度更好地匹配三维 CU 的空间分布.

因此, 为实现自适应调节, 引入各方向的不确定性因子:

$$\rho_i = clip(\frac{WPV_i}{W_i}, 0, 1). \tag{12}$$

W_i对应方向的归一化尺度常数, $i \in (x, y, h)$. 同时定义各方向的归一化距离:

$$d_i = clip(\frac{||i - \bar{i}_k||}{D_i}, 0, 1). \tag{13}$$

在此基础上, 计算自适应步长如下:

$$\Delta step_i = s_{mid}\rho_i + (s_{min} + (s_{max} - s_{min})d_i)(1-\rho_i). \tag{14}$$

由此, 智能体的运动控制策略在每个方向上均具备独立的调节自由度, 从而避免在已收敛方向上的冗余运动, 提高整体搜索效率. 结合基本动作$\mathcal{A}_{3D}$, 上述各向异性步长可直接映射候选动作集如下:

$$\mathcal{A}_{3D} = \{\cdot, \Delta step_h, -\Delta step_h, -\Delta step_x, \Delta step_x, \Delta step_y, -\Delta step_y\}. \tag{15}$$

2.3 信息-势场联合决策模型

在信息趋向搜索框架中, 智能体在搜索过程中需要同时考虑对未知区域的探索能力和对潜在源区的利用能力. 因此, 奖励函数被分为探索项和利用项两部分. 在经典 Infotaxis 中[14], 利用项表示找到源的奖励, 探索项表示找不到源的奖励, 如下式:

$$R_{Infotaxis} = p(r'_{k+1})[0 - H_k] + (1 - p(r'_{k+1}))[E(\hat{H}_{k+1}(\hat{z}_{k+1})) - H_k]. \tag{16}$$

Ristic 等人删除奖励函数的利用项, 只保留探索项, 提出 Infotaxis II[16] 如下:

$$R_{Infotaxis\ II} = [E(\hat{H}_{k+1}(\hat{z}_{k+1})) - H_k]. \tag{17}$$

以上奖励函数以香农熵H_k为信息度量基础, 有$H_k = -\sum_{m=1}^{M} w_k^{(m)} \log w_k^{(m)}$. 其目的是根据后验概率分布不确定性的变化来选择下一步移动方向. 然而, 在基于粒子滤波的联合源估计中, 后验概率分布由有限数量的粒子及其权重近似表示. 当粒子数量较少或经过多次重采样后, 粒子可能集中在少数高概率区域, 导致不同候选动作对应的后验熵变化较小. 此时, 单纯依赖香农熵变化难以充分区分不同候选动作对后验认知分布的影响, 容易降低动作评价的敏感性.

因此, 研究采用 Rényi 熵代替香农熵作为信息度量基础. Rényi 熵是香农熵的广义形式, 在香农熵中增加阶数α, 提供了一种更灵活的方式来衡量分布的不确定性, 如下式:

$$H_\alpha(w_k^{(m)}) = \frac{1}{1-\alpha} log \sum_{m=1}^{M} (w_k^{(m)})^\alpha. \tag{18}$$

进一步利用 Rényi 散度代替传统 Infotaxis 中的熵降指标作为探索项, 可得:

$$R_{explore}(k) = \frac{1}{\alpha - 1} log \sum_{m=1}^{M} (w_k^{(m)})^\alpha (w_{k-1}^{(m)})^{1-\alpha}. \tag{19}$$

其中, 阶数参数α调节信息度量对概率分布不同区域的敏感性, 通过合理设置α能够提高对粒子权重分布细微变化的分辨能力, 从而更有效地区分不同候选动作对源位置认知更新的贡献.

进一步, 将引力势场作为利用项, 构建信息-势场联合奖励函数, 利用项计算形式如下:

$$R_{exploit}(k,n) = \sum_{m=1}^{M} \frac{w_k^{(m)}}{||r_{(k,n)} - r_k^{(m)}||^\gamma + \epsilon}. \tag{20}$$

在公式 (19)(20) 中, 潜在源项位置$r_k^{(m)}$及其权重$w_k^{(m)}$均来自多智能体联合观测更新后的后验分布, 因此探索奖励反映了群体共享认知状态随时间演化的整体差异性, 而利用奖励则体现了群体共享认知基础上的个体局部利用. 本研究并未将多个智能体的引力势场进一步加权融合为统一的群体势场, 主要原因在于, 后验分布已经完成了多智能体观测信息在认知层面的融合, 而引力势场项的作用是为各智能体提供与自身空间位置相关的局部利用评价. 若进一步将多个智能体的利用项融合为统一的群体势场, 容易弱化不同智能体之间的位置差异和动作选择差异, 使决策过程更接近集中式群体目标优化, 不利于保持分布式搜索中的局部适应性与空间互补性.

针对复杂环境中搜索空间自由度增加所带来的决策平衡问题, 提出一种方差自适应权重策略 (Variance-Adaptive Weighting Strategy, VAWS). 该策略以潜在气味源后验概率分布的不确定性WPV作为调节依据, 不依赖显式时间变量, 通过动态调整权重比例实现探索与利用之间的自适应平衡, 其计算形式如下:

$$\lambda_{VAWS}(k) = w_{\min} + (1 - w_{\min} * (1 - e^{-0.002*\max(0, WPV - v_{\min})})). \tag{21}$$

其中, $\lambda_{VAWS}(k)$表示k时刻的自适应权重参数, $w_{\min}$表示探索项的最小权重, $v_{\min}$表示收敛阈值. 在此基础上, AMGraRényitaxis 的混合奖励函数如下:

$$R_{VAWS} = \lambda_{VAWS}(k) * R_{explore}(k) + (1 - \lambda_{VAWS}(k)) * R_{exploit}(k,n). \tag{22}$$

信息-势场联合决策模型并不是对信息项和势场项的简单叠加, 而是利用自适应权重$\lambda_{VAWS}(k)$将“全局探索”和“个体利用”统一到同一候选动作评价函数中. 当后验分布较为分散、CU 较高时, 模型增强探索项作用, 使智能体优先获取降低不确定性的观测信息. 当后验分布逐渐集中、CU 较低时, 模型增强利用项作用, 引导智能体向高概率源区收敛. 因此, 该联合决策模型能够在不确定性削减和目标区域接近之间实现动态平衡, 从而提高多智能体气味源搜索的效率与决策稳定性.

2.4 动作选择

在获取所有候选动作之后, 利用 2.3 节的联合决策模型对每个动作进行评估, 智能体按照最大奖励准则选择决策作为临时决策, 如下式:

$$a_k^* = \arg\max_{a_k \in \mathcal{A}_{3D}} (R_{VAWS}(a_k)). \tag{23}$$

多智能体协同奖励函数的作用并非直接给出群体的最终动作决策, 而是为各智能体提供在统一认知基础下的动作评价准则, 从而定义一致的优化目标. 在式 (23) 中计算的是智能体在当前时刻和当前认知条件下的临时最优决策, 而不是群体层面上的最终一致决策. 群体决策并非由该评价过程直接确定, 而是通过后续引入的分布式协商机制, 在多智能体之间对临时决策进行迭代更新后形成.

2.5 约束更新协商机制

在多智能体协同搜索过程中, 即使各智能体基于统一的共享后验概率以及奖励函数进行动作评价, 其独立求解得到的最优动作依旧会产生方向冲突, 路径交叉以及冗余覆盖的问题, 进而降低整体搜索效率和稳定性. 因此, 在单个决策周期内, 我们提出了约束更新协商机制 (Constraint Update Negotiation Mechanism, CUNM), 使群体在分布式计算的环境下形成一致的最优决策. 进行协商的整体流程如下:

算法 1 约束更新协商机制 (第 n 个智能体视角)

step 1: 输入: 共享后验粒子集$\theta_k^{(m)}$, 候选动作集$\mathcal{A}_{3D}$, 最大协商次数$L_{max} = 5$;

step 2: 根据式 (23) 在候选动作集中选择初始临时决策$a_{(k,n)}^{(0)}$, 并广播给其他智能体集合$\mathcal{N}$;

step 3: 接收其他智能体的临时决策集合$\{a_{(k,j)}^{(l-1)}\}_{j\in\mathcal{N}}$, l表示迭代轮次;

step 4: 将接收到的临时决策集合视为其他智能体的最优响应, 在此约束条件下更新本智能体的潜在源项估计$\hat{\theta}_{(k,n)}^{(l)}$;

step 5: 计算不同候选方向的奖励函数, 利用最大奖励准则更新本轮次的临时决策$a_{(k,n)}^{(l)}$, 并广播给其他智能体;

step 6: 判断当前轮次临时决策是否与上一轮一致, 即是否满足以下一致性条件:

$a_{(k,n)}^{(l)} = a_{(k,n)}^{(l-1)}$: 本智能体的决策未发生变化

$a_{(k,j)}^{(l)} = a_{(k,j)}^{(l-1)}$: 其他智能体的决策也未发生变化;

step 7: 如果未满足一致性条件, 判断当前迭代次数l是否已达到最大迭代次数L_{max};

step 8: 如果未达到最大迭代次数, 转至 step3, 继续协商. 如果达到最大迭代次数, 则选择在这些迭代中最频繁出现的决策作为最终的下一步动作, 并结束协商.

step 9: 如果在某一轮中, 所有智能体的临时决策相较上一轮均未发生变化 (满足一致性条件), 直接输出本轮决策作为下一步动作, 协商结束.

step 10: 输出: 智能体的下一步移动位置$r_{k+1}^{(n)}$.

本文规定, 当连续两轮迭代中各智能体的决策向量保持不变, 则决策已经达成共识, 协商过程终止并输出动作. 为保证在线决策的实时性, 将协商轮次限制为 5 次, 若在该上限内仍未完全收敛, 则采用保守的兜底策略, 从迭代过程中选择出现次数最多的动作输出, 以避免协商失败导致的停滞或不稳定行为. CUNM 的核心思想是在保持分布式计算架构的前提下, 通过有限次的动作级信息交换逐步对齐各智能体的行动选择, 从而抑制个体最优导致的群体冲突, 提升协同行为的稳定性与执行一致性.

3 仿真实验及结果分析

为保证不同搜索策略在仿真对比中的公平性与可重复性, 本文给出统一仿真环境的基本参数设置. 除特别说明外, 后续所有仿真实验均在相同的环境参数条件下开展. 通过固定环境配置, 仅改变搜索策略, 可有效避免环境差异对实验结果的干扰, 从而确保性能比较的客观性与一致性. 本文采用的仿真环境基本参数如下:

1) 气味源参数: 气味源位置$r_s = (10, 50, 25)$, 源释放强度$Q_s = 10$, 扩散粒子寿命$\tau = 400$;

2) 环境参数: 问题规模$\Omega = 200 \times 100 \times 50$, 平均风速$V = 1$;

3) 智能体参数: 初始位置$r_a = [(180, 30, 0), (180, 50, 0), (180, 70, 0)]$, 智能体搜索半径$a = 2$, 采样时间$dt = 1s$.

3.1 示例性运行

图 2 为协同认知策略的经典搜索轨迹, 为了实验可复现, 在仿真过程中设置随机种子 seed=2. 图中, 三种不同颜色的路径曲线为搜索轨迹, 轨迹上的空心圆表示击中点, 蓝色表示所构建的粒子滤波器中的潜在源项, 其颜色深浅反映权重大小. (a) 中表示用 Infotaxis Ⅱ认知策略[16, 32]进行协同搜索的轨迹, 使用 131 个时间步找到了气味源. (b) 中表示用 AMGraRényitaxis 进行协同搜索的轨迹, 花费 58 个时间步找到了气味源, 与 Infotaxis Ⅱ相比搜索时间减少了 55.73%, 极大地提高了搜索效率.

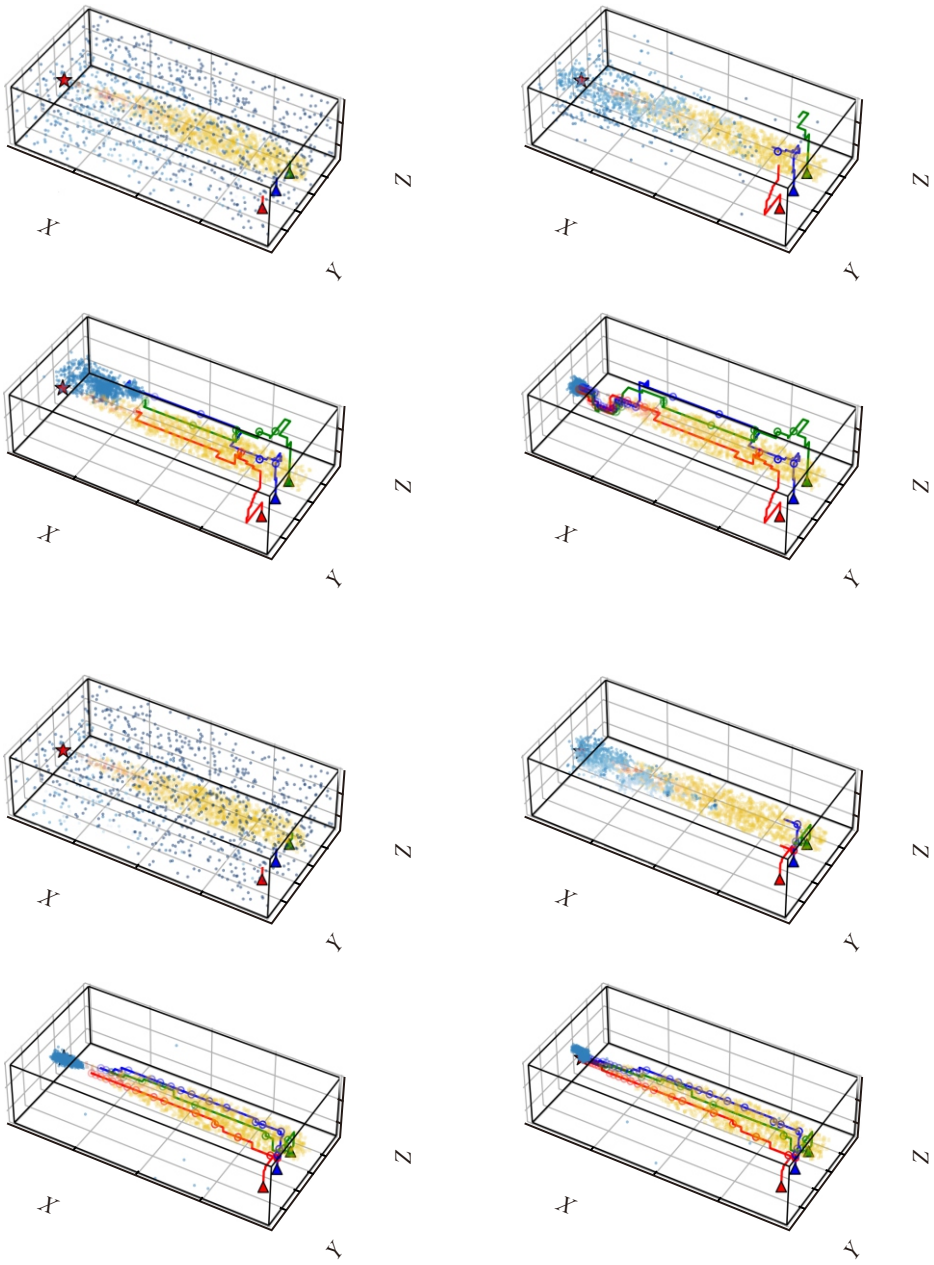

图 2　协同 Infotaxis Ⅱ (a) 与 AMGraRényitaxis(b) 搜索轨迹图

从图 2(a) 可以看出, 潜在源项的后验分布收敛较为缓慢, 搜索过程中智能体存在明显的无效运动, 其轨迹在空间中发生局部的徘徊和偏移, 未能沿着单一方向持续推进. 这是由于 Infotaxis Ⅱ删除了奖励函数中的利用项, 导致决策过程过度偏向探索. 并且在搜索后期, 三个智能体的路径高度重合, 智能体选择相似的高信息收益区域进行搜索, 产生重复采样和观测冗余. 在图 2(b) 中, 随着搜索的推进, 潜在源项快速收敛于上风向区域. 智能体首先向上进行移动, 探索获取有效信息后, 迅速转向逆风运动, 气味命中主要集中在逆风阶段. 同时, 三个智能体基本保持在有效羽流区域内运动, 未出现明显的无效搜索行为; 其轨迹之间的重叠和交叉现象也显著减少, 从而有效降低了路径冗余.

3.2　关键模块消融实验

为对比在三维空间中气体扩散模型、各向异性自适应步长策略以及基于 VAWS 加权机制的影响, 本节进行了多种算法配置组合的仿真. 另外, 本节设置了两种不同场景, 分为早期可观测 (Early-observable, EO) 场景与迟滞可观测 (Delayed-observable, DO) 场景, 表示气味源与智能体初始位置的相对空间关系, 场景配置如下:

1) EO 场景: 气味源位置 (10, 50, 25), 智能体搜索起始位置 [(180, 30, 0), (180, 50, 0), (180, 70, 0)],

部分智能体在初始阶段与气味源在横向上具有较高对齐程度, 能够较早进入有效气味羽流区域, 从而在搜索初期获得相对充足的气味观测信息.

2) DO 场景: 气味源位置 (10, 70, 25), 智能体搜索起始位置 [(180, 30, 0), (180, 20, 0), (180, 10, 0)], 智能体初始位置与气味源在空间上存在较大偏移, 搜索早期难以获得稳定气味信息, 需依赖探索行为逐步接近高置信区域, 整体可观测性显著滞后.

为了分析扩散模型的影响, 引入各向同性羽流模型 (Isotropic Plume Model, IPM) 进行对比; 为了分析步长调节机制的作用, 引入固定步长 (Fixed Step, FS) 以及各向同性自适应步长策略 (Isotropic Adaptive Step Size, IASS) 对比; 为了分析加权策略的影响, 引入时间衰减权重 (Time Decaying Weight Strategy, TDWS) 作为对比, 其具体策略设置如表 1. 实验结果如表 2.

表 1 策略设置

序号	策略名称	气体扩散模型	步长策略	权重策略
A	AMGraRényitaxis	GPM	AASS	VAWS
B	AMGRT_IPM	IPM	AASS	VAWS
C	AMGRT_FS	GPM	FS	VAWS
D	AMGRT_AS	GPM	IASS	VAWS
E	AMGRT_DW	GPM	AASS	TDWS

表 2 不同变体策略性能对比

场景	策略	平均搜索步数	标准差	平均移动距离
EO场景	A	**59.62**	**7.8125**	**224.5129**
	B	120.32	29.7068	310.8165
	C	168.16	22.8634	336.3067
	D	69.46	8.7526	274.3841
	E	66.94	14.3169	241.2846
DO场景	A	**93.24**	**9.6448**	**299.6825**
	B	136.80	20.2040	343.7292
	C	178.34	14.9875	356.6400
	D	101.86	12.6064	350.2121
	E	99.34	14.1288	311.6131

注: 各变体策略的搜索成功率(SR)均为100%, 因此表中未对该指标进行单独展示.

为了评估不同模块对策略性能的影响, 本研究选取成功率(Success Rate, SR)平均搜索步数(Mean Search Steps, MSS)、搜索步数标准差(Standard Deviation, STD)和平均移动距离(Mean Moving Distance, MMD)作为主要评价指标, 对不同变体策略的搜索性能进行对比分析. SR 表示成功搜索次数占总搜索次数的比例, MSS 反映策略的搜索效率, STD 表征搜索过程的稳定性, MMD 用于衡量智能体完成源定位任务所需的运动代价. 这些平均指标都是基于成功样本进行计算的.

基于表 2, 本文所提出的改进方法在搜索效率和鲁棒性方面均展现出显著优势.在两种场景下与变体策略对比, 策略 A(ours) 均展现了最小的平均步数、标准差以及移动距离. 在 EO 场景下, 其搜索效率相较于策略 B(使用 IPM) 平均步数降低 50.45%, 相较于策略 C(固定步长) 降低了 64.54%, 相较于策略 D(各向同性步长) 降低了 14.16%, 相较于策略 E(时间衰减权重) 降低了 10.93%. 在 DO 场景下, 策略 A 的平均搜索步数为 93.24 步, 相较于策略 B、策略 C、策略 D 和策略 E 分别降低了 31.84%、47.72%、8.46% 和 6.14%. 这表明所提出策略在早期可观测和迟滞可观测条件下均能够保持较高的搜索效率, 尤其在观测信息不足、搜索过程更加困难的 DO 场景中, 仍能有效降低搜索步数并提升搜索稳定性.

图 3 画出了在 50 次重复试验条件下各策略搜索步数的箱型分布, 可以看出, 提出的 AMGraRényitaxis 与 4 种变体策略相比, 其搜索步数分布明显下移, 箱型图长度缩短, 并且离群异常点减少, 表明该策略在搜索效率与稳定性方面均具有明显优势. 三个对比模块中, 对搜索步数影响最为显著的是步长策略, 由固定步长改变为自适应步长可以大幅度提高效率. 但是由于三维空间中的各向异性特征, 各方向采用相同的步幅进行移动仍可能会导致智能体产生部分的冗余路径, 因此 AMGraRényitaxis 的搜索效率优于采用各向同性步长的策略 D, 再优于采用固定步长的策略 C. 其次, 对搜索性能影响较大的因素为气

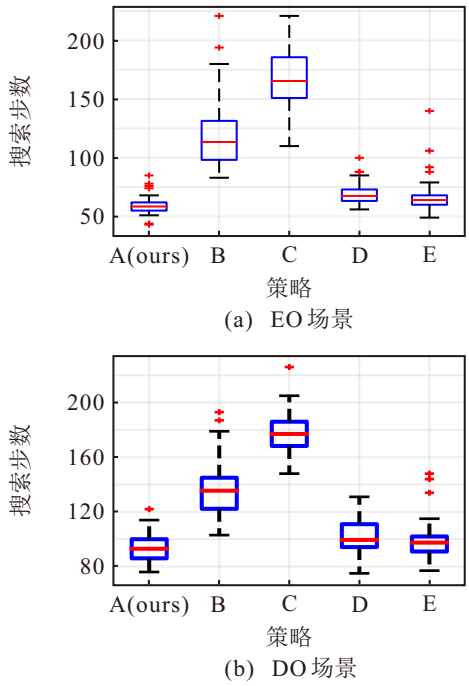

图 3 EO 场景下 (a) 和 DO 场景下 (b) 搜索时间分布

体扩散模型. 从实验结果中发现, IPM 浓度预测阶段引入了较大的模型误差, 导致观测带来的信息增益降低, 使智能体的搜索效率大幅度下降. 而权重调节策略主要影响搜索过程的稳定性. 从箱型图的长度以及离群点分布可以看出, 权重策略的引入能够在一定程度上降低搜索步数的波动范围, 使搜索过程更加稳定, 但其对平均搜索效率的影响相对较小.

3.3　经典策略对比

本节选取多种具有代表性的经典认知策略作为对比算法, 包括 Infotaxis Ⅱ[16][32](策略 F), Entrotaxis[34](策略 G), Rényitaxis[17](策略 H), Gravtaxis(策略 I) 以及 Space-aware Infotaxis[35](SAI, 策略 J). 这些策略中, Infotaxis Ⅱ, Entrotaxis, Rényitaxis 是纯信息驱动的认知策略, Gravtaxis 是引力势场驱动的认知策略, SAI 则是信息度量和距离度量混合驱动的认知策略, 通过与这些策略进行比较, 能够较为全面地反映目前主流气味源搜索认知策略的性能特征.

考虑到气味源定位任务中环境不确定性对搜索行为的显著影响, 本节分别在固定气味源与随机气味源两种场景下开展对比实验. 在固定气味源实验中, 气味源位置在所有重复实验中保持不变, 用于评估各算法在相同目标条件下的搜索稳定性与路径一致性. 在随机气味源实验中, 气味源位置在搜索区域内随机生成, 用以检验算法在未知目标分布条件下的鲁棒性与泛化性能. 对于每种算法和每类实验场景, 均进行 50 次独立重复实验, 以降低随机初始条件和观测噪声对结果的影响. 实验结果如表 3, 图 4 中画出了两组实验的搜索时间分布箱型图.

表 3　经典策略性能对比

场景	策略	SR	MSS	STD	MMD	$T_{ave}(s)$	T_{des}
固定气味源	A	**100%**	**61.52**	**7.3273**	230.2876	8.8630	0.1402
	F	100%	111.44	29.7759	288.3833	9.2739	0.0832
	G	100%	111.34	29.7756	288.2493	8.3208	**0.0744**
	H	100%	105.26	26.3202	275.0993	8.7487	0.0829
	I	100%	107.06	24.0653	271.4722	**8.1351**	0.0760
	J	100%	84.5	9.8127	**215.3918**	10.1227	0.1204
随机气味源	A	**100%**	**72.82**	**40.5116**	**203.7243**	**8.8525**	0.1202
	F	100%	124.98	74.1068	284.1072	12.3802	0.1003
	G	100%	126.94	77.2806	290.0807	10.8517	0.0861
	H	100%	108.92	49.4137	251.4079	10.6204	0.0972
	I	100%	117.52	52.9223	257.1790	9.5669	**0.0815**
	J	74%	104.6216	83.7013	197.2224	9.9263	0.0926

注: 表中各项平均指标均基于成功搜索样本计算.

除 3.2 节中的评价指标外, 本节还增加了平均任务耗时 (T_{ave}) 以及单次决策耗时 (T_{des}) 对不同策略的计算开销进行分析, T_{ave}表示成功完成一次气味源搜索任务的平均运行时间, T_{des}则代表智能体进行一次决策的平均时间.

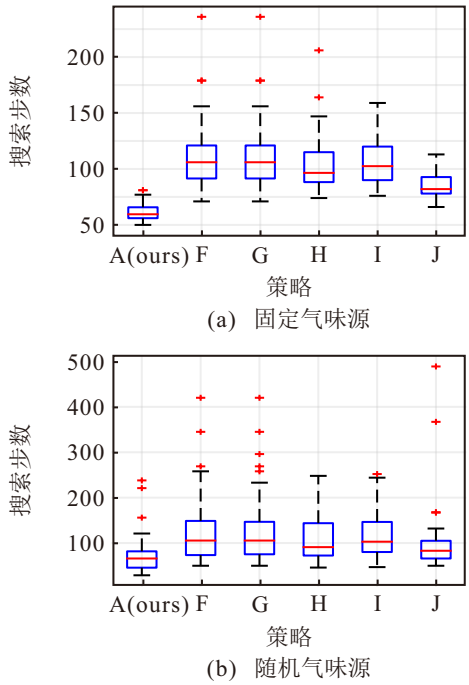

图 4　固定气味源 (a) 随机气味源 (b) 搜索时间分布

在固定气味源条件下, 策略 A 取得了最少的平均搜索步数和最低的标准差. 平均搜索步数为 61.52, 相比策略 F、G、H、I 和 J 分别降低了 44.80%、44.75%、41.56%、42.54% 和 27.20%. 在平均移动距离中, 策略 J 的移动路径最短, 策略 A 次之.这是由于策略 J 将空间距离约束直接引入奖励函数中, 导致搜索路径更倾向于短距离移动, 形成较短的搜索路径. 但是这种方法对于搜索步数提升不明显, 并且鲁棒性较差.整体来看, 策略 A 在相同气味源条件下具有更高的搜索效率和更好的搜索稳定性.

在随机气味源条件下, 策略 A 同样实现了最好的综合搜索性能. 其平均搜索步数为 72.82, 相比策略 F、G、H、I 和 J 分别降低了 41.73%、42.63%、33.14%、38.04% 和 30.40%. 平均移动距离为 203.7243, 相对于 F、G、H 和 I 分别降低了 28.29%、29.77%、18.97% 和 20.79%.虽然策略 J 的平均移动距离略小于策略 A, 但其成功率仅为 74%, 且标准差达到 83.7013, 为所有策略中最高, 说明 SAI 策略中过强的空间距离偏好会削弱其对不同源位置的适应能力, 容易导致搜索失败或搜索步数波动增大.

从计算开销来看, 策略 A 由于同时引入 Rényi 散度、引力势场和自适应权重计算, 单次决策耗时较高, 在固定气味源和随机气味源场景下分别为 0.1402 s 和 0.1202 s, 均高于其他策略. 但在随机气味源场景中, 策略 A 显著减少了搜索步数, 使其平均任

务耗时降至 8.8525 s, 为所有策略中最低, 说明其能够通过更少的搜索步数弥补单步计算量的增加. 在固定气味源场景中, 由于智能体初始位置正好位于源的下风向羽流区域, 部分简单策略也能较快获得有效观测, 因此策略 A 的单步计算优势没有完全转化为最短任务耗时. 不过策略 A 的平均任务耗时也与最优结果较为接近.

两种环境进行纵向比较, 策略 A 无论在固定气味源环境还是随机气味源环境中搜索步数和稳定性都明显更优, 其单步决策耗时虽然最高但是可以通过较少的搜索步数弥补, 从而缩短完整任务耗时. 策略 A 在搜索性能、鲁棒性和计算开销之间取得了较好的平衡.

图 4 可以进一步验证以上结论, 在两种场景中, 策略 A 的箱体位置都明显低于其他策略, 并且箱体高度较小, 这说明多数实验可以在较小的步数内完成搜索. 另外, 采用 Rényi 散度的策略 H 与基于香农熵的策略 F 和 G 相比, 其离群点明显减少, 平均值以及中位数都降低. 这说明, Rényi 散度能够更有效地区分候选动作对后验分布更新的贡献, 从而减少搜索过程中的波动.

3.4 协同机制对比

为了评估分布式协商机制在多智能体气味源搜索中的效果, 本节在共享感知的基础上, 对独立决策、分布式协商决策和集中式决策对比. 独立式决策表示各智能体基于共享后验独立选择动作, 但在决策过程中不进行动作协商. 分布式协商决策利用提出的 CUNM 进行协商, 得到最终行动结果. 而集中式决策则由中心节点统一迭代智能体的联合动作空间.

实验结果表明, 协同机制对智能体进行气味源搜索性能有显著影响. 如图 5 所示, 三种决策方式中, 分布式决策获得了最短的搜索步数 78 步, 并且其路径相对于其他两种协同方式更平滑, 其次是集中式决策.在图 5(c) 中的集中式决策轨迹图中, 搜索后期三个智能体的路径高度重合, 这是由于在集中式决策中将分布式的个体势场变为了群体融合势场, 这种方法导致三个智能体的差异性消失, 其移动目标完全一致.而在图 5(a) 的独立式决策中, 各智能体的路径明显比分布式决策与集中式决策更曲折, 存在较多的路径冗余和交叉, 这就是缺乏协商导致的后果.从图 5 可以看出, 分布式决策凭借合理的协商方式, 显著提升了任务完成效率, 轨迹更平滑, 有效地增强了智能体之间的协同性.

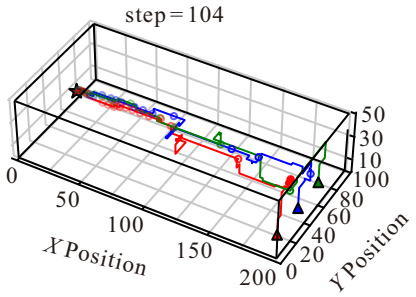

(a) 独立式决策

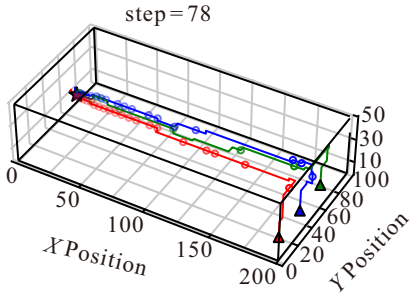

(b) 分布式协商决策

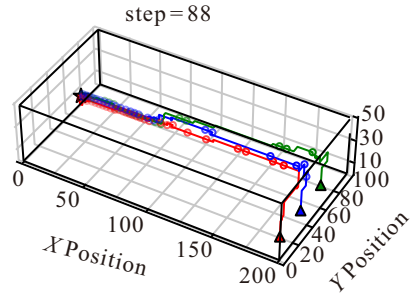

(c) 集中式决策

图 5 不同协同机制典型搜索轨迹图

表 4 展示了对三种机制在完全相同的环境下重复运行 50 次的统计结果, 气味源位置为(20, 45, 35), 释放速率$Q = 5$, 其余参数与前文保持一致. 除前文提到的评价指标外, 表 4 中增加了决策复杂度f_d用于表示每轮决策中需要评价的候选动作规模. 独立式决策中, 各智能体仅从自身 7 个候选动作中选择最优动作, 因此$f_d = 7$. 分布式协商决策在局部动作评价基础上进行迭代协商, 若最大协商次数为 5, 则最大评价规模为 7×(5+1). 集中式决策需要由中心节点枚举所有智能体的联合动作组合, 当 3 个智能体各有 7 个候选动作时, 其复杂度为7^3. 由此可见, 集中式决策复杂度随智能体数量呈指数增长, 而分布式协商决策仅随协商次数近似线性增加.

分布式协商决策显著提高了多智能体源搜索的

表 4 不同协同机制性能对比

协同机制	MSS	STD	MMD	T_{des}(s)	f_d
独立式	95.9	21.4954	295.5509	0.0199	7
分布式协商	85.6	22.7253	275.2427	0.1623	最大为7×6
集中式	96.82	22.8978	296.9516	1.6025	7^3

搜索效率, 其平均搜索步数相对于独立式搜索降低了 10.74%, 相对于集中式搜索降低了 11.59%. 从计算开销上看, 独立式的单次决策耗时仅为 0.0199s, 其计算开销最低, 但由于缺乏协同约束, 其平均搜索步数和平均移动距离均较大. 分布式协商决策由于需要进行决策交换与迭代优化, 单次决策耗时增加到 0.1623s, 但仍显著低于集中式决策的 1.6025s, 说明 CUNM 在引入协同优化的同时保持了较低的计算开销. 综合来看, 分布式协商决策在搜索效率、移动代价和计算开销之间取得了较好的平衡.

4 结论

针对随机粒子采样条件下信息趋向策略在认知表征与决策调节方面存在的信息梯度响应不足、搜索尺度与方向适配性有限以及多智能体决策不一致等问题, 本文提出了一种基于认知不确定性建模的多智能体协同决策策略, 用于稀疏环境下的气味源搜索定位. 该策略构建信息驱动探索与势场驱动利用相结合的信息-势场联合决策模型, 利用认知不确定性度量实现决策权重与各向异性运动步长的自适应调节, 使搜索尺度与方向能够随环境认知状态动态调整. 同时, 设计了约束更新协商机制实现多智能体之间的决策一致化, 在保持分布式决策灵活性的同时有效降低路径冗余与协同行为冲突.

为系统验证所提方法的有效性与鲁棒性, 本文开展了大量仿真实验, 通过关键模块消融实验、经典认知策略对比实验以及协同机制对比实验, 对算法性能进行了系统评估. 实验结果表明, 所提出的协同搜索决策策略在搜索效率、稳定性以及路径优化方面均优于多种典型信息趋向方法, 并能够在固定气味源与随机气味源条件下保持稳定的搜索性能. 同时, 约束更新协商机制能够有效降低多智能体之间的路径冗余与行为冲突, 并且避免了高维联合动作的计算负担, 保证了系统的实时决策能力, 从而进一步提升整体协同搜索效率.

参考文献 (References)

[1] Zhang M H, Wang H L, Ji H X, et al. UAV autonomous source seeking with cumulative exposure minimization in complex hazardous environments[J]. Aerospace Science and Technology, 2024, 151: 109330.

[2] Xue Y Y, Mou S M, Chen C M, et al. Rapid distance estimation of odor sources by electronic nose with multi-sensor fusion based on spiking neural network[J]. Sensors and Actuators B: Chemical, 2025, 422: 136665.

[3] Sheng H, Chen G H, Xu Q M, et al. An advanced gas leakage traceability & dispersion prediction methodology using unmanned aerial vehicle[J]. Journal of Loss Prevention in the Process Industries, 2024, 88: 105276.

[4] Tan Q, Fu M, Wang Z X, et al. A real-time early warning classification method for natural gas leakage based on random forest[J]. Reliability Engineering & System Safety, 2024, 251: 110372.

[5] 何丽, 杜洋鋆, 李知远, 等. 移动机器人主动嗅觉气源定位方法研究综述[J]. 计算机工程与应用, 2025, 61(10): 36-49.
(He L, Du Y Y, Li Z Y, et al. Review of active olfactory odor source localization methods for mobile robots[J]. Computer Engineering and Applications, 2025, 61(10): 36-49.)

[6] Liu Z Z, Li X F. A new sensor configuration design method for source term estimation in urban neighborhood with complex conditions under different wind directions[J]. Building and Environment, 2024, 252: 111210.

[7] Hutchinson M, Oh H, Chen W H. A review of source term estimation methods for atmospheric dispersion events using static or mobile sensors[J]. Information Fusion, 2017, 36: 130-148.

[8] Shen Z Y, Lang J L, Li M Z, et al. Impact of inlet boundary number and locations on gas diffusion and flow in a typical chemical industrial park near uneven terrain[J]. Process Safety and Environmental Protection, 2022, 159: 281-293.

[9] 宋程, 马少杰, 贺昱曜, 等. 非稳态扩散下基于指数权重调节和分层重采样的信息趋向溯源算法[J]. 控制与决策, 2026, 41(5): 1468-1476.
(Song C, Ma S J, He Y Y, et al. An infotaxis algorithm using exponential weight adaptation and stratified resampling for unsteady diffusion conditions[J]. Control and Decision, 2026, 41(5): 1468-1476.)

[10] Liao Y, Chen A X, Cai H, et al. An experimental study on locating time-varying pollutant sources in a dynamic indoor environment with mechanical ventilation based on multi-robot cooperation[J]. Journal of Building Engineering, 2023, 67: 105962.

[11] Zhou S W, Zhang C X, Cai H, et al. Locating a time-varying contaminant source in naturally ventilated indoor environments: An experimental study to find effective multi-robot olfaction methods[J]. Building and Environment, 2022, 216: 108954.

[12] 高跃庭, 桂方志, 王欢, 等. 基于多策略改进鲸鱼算法的多无人机协同路径规划[J]. 控制与决策, 2026, 41(5): 1529-1539.
(Gao Y T, Gui F Z, Wang H, et al. Multi-strategy improved whale optimization algorithm for UAV cooperative path planning[J]. Control and Decision, 2026, 41(5): 1529-1539.)

[13] 黄浩乾, 吕奥奇, 王迪, 等. 基于贝叶斯和统计相似度量测的水下自主定位方法[J]. 控制与决策, 2025, 40(1): 48-54.
((Huang H Q, Lv A Q, Wang D, et al. Underwater autonomous positioning method based on Bayesian and statistical similarity measurement[J]. Control and Decision, 2025, 40(1): 48-54.) (Hang H Q, Lv A Q, Wang D, Zhang Y T. Underwater autonomous positioning method based on Bayesian and statistical

similarity measurement[J]. Control and Decision, 2025, 40(1): 48-54.))

[14] Vergassola M, Villermaux E, Shraiman B I. 'Infotaxis' as a strategy for searching without gradients[J]. Nature, 2007, 445(7126): 406-409.

[15] Moraud. Effectiveness and robustness of robot infotaxis for searching in dilute conditions[J]. Frontiers in Neurorobotics, 2010, 4(1): 1.

[16] Ristic B, Skvortsov A, Gunatilaka A. A study of cognitive strategies for an autonomous search[J]. Information Fusion, 2016, 28: 1-9.

[17] He Y Y, Song C, Jing C, et al. Robot active olfaction search in turbulent flow and infotaxis search based on Rényi divergence[C]. OCEANS 2017 - Aberdeen. Aberdeen, 2017: 1-9.

[18] Park M, An S, Seo J, et al. Autonomous source search for UAVs using Gaussian mixture model-based infotaxis: Algorithm and flight experiments[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(6): 4238-4254.

[19] Sun Y, Qi Q Y, Liu Y. Probabilistic generative olfactory-based navigation in turbulent environments for Mars methane exploration[J]. Nonlinear Dynamics, 2025, 113(11): 13167-13192.

[20] Song C, He Y Y, Lei X K. Autonomous searching for a diffusive source based on minimizing the combination of entropy and potential energy[J]. Sensors, 2019, 19(11): 2465.

[21] Ruddick J, Marjovi A, Rahbar F, et al. Design and performance evaluation of an infotaxis-based three-dimensional algorithm for odor source localization[C]. 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems. Madrid, 2019: 1413-1420.

[22] Hutchinson M, Liu C J, Chen W H. Information-based search for an atmospheric release using a mobile robot: Algorithm and experiments[J]. IEEE Transactions on Control Systems Technology, 2019, 27(6): 2388-2402.

[23] Chen X X, Huang J. Combining particle filter algorithm with bio-inspired anemotaxis behavior: A smoke plume tracking method and its robotic experiment validation[J]. Measurement, 2020, 154: 107482.

[24] Chen X X, Marjovi A, Huang J, et al. Particle source localization with a low-cost robotic sensor system: Algorithmic design and performance evaluation[J]. IEEE Sensors Journal, 2020, 20(21): 13074-13085.

[25] Masson J B, Bechet M B, Vergassola M. Chasing information to search in random environments[J]. Journal of Physics A: Mathematical and Theoretical, 2009, 42(43): 434009.

[26] 张思齐, 徐德民. 湍流环境中多弱感知机器人气味源搜索算法[J]. 控制与决策, 2015, 30(8): 1429-1433.
(Zhang S Q, Xu D M. Odor source search employing multi-robots with limited perception in turbulence environments[J]. Control and Decision, 2015, 30(8): 1429-1433.)

[27] Karpas E D, Shklarsh A, Schneidman E. Information socialtaxis and efficient collective behavior emerging in groups of information-seeking agents[J]. Proceedings of the National Academy of Sciences of the United States of America, 2017, 114(22): 5589-5594.

[28] 宋程, 贺昱曜, 雷小康, 等. 基于认知差异的多机器人协同信息趋向烟羽源搜索方法[J]. 控制与决策, 2018, 33(1): 45-52.
(Song C, He Y Y, Lei X K, et al. Multi-robot collaborative infotaxis searching for plume source based on cognitive differences[J]. Control and Decision, 2018, 33(1): 45-52.)

[29] Song C, He Y Y, Ristic B, et al. Multi-agent collaborative infotaxis search based on cognition difference[J]. Journal of Physics A: Mathematical and Theoretical, 2019, 52(48): 485202.

[30] Rahbar F, Martinoli A. A distributed source term estimation algorithm for multi-robot systems[C]. 2020 IEEE International Conference on Robotics and Automation. Paris, Piscataway: IEEE, 2020: 5604-5610.

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

[32] Park M, Oh H. Cooperative information-driven source search and estimation for multiple agents[J]. Information Fusion, 2020, 54: 72-84.

[33] 高新慈, 高明, 刘一凡, 等. 基于概率 Transformer-粒子滤波的旋转导向钻井工具系统智能故障诊断[J/OL]. 控制与决策, https://doi.org/10.13195/j.kzyjc.2026.0084.
(Gao X C, Gao M, Liu Y F, et al. Intelligent fault diagnosis of rotary steerable drilling tool system based on probabilistic Transformer-particle filter[J/OL]. Control and Decision, https://doi.org/10.13195/j.kzyjc.2026.0084.)

[34] Hutchinson M, Oh H, Chen W H. Entrotaxis as a strategy for autonomous search and source reconstruction in turbulent conditions[J]. Information Fusion, 2018, 42: 179-189.

[35] Loisy A, Eloy C. Searching for a source without gradients: How good is infotaxis and how to beat it[J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2022, 478(2262): 20220118.

作者简介

贾颖淼 (1998−), 女, 博士生, 主要研究方向为嗅觉感知与自主搜索, E-mail: 202211901001@stu.hebut.edu.cn;

范书瑞 (1979−), 男, 教授, 博士, 博士生导师, 主要研究方向为气象环境感知、无人机协同探测与智能传感, E-mail: fansr@hebut.edu.cn;

张勇 (1979−), 男, 教授, 博士, 主要研究方向为目标源识别、定位与追踪, E-mail: zhangyong@tjcu.edu.cn;

李颖 (2003−), 女, 硕士生, 主要研究方向为多机协同中的通信调度优化, E-mail: 202431903111@stu.hebut.edu.cn;

夏克文 (1965−), 男, 教授, 博士, 主要研究方向为智能信息处理与计算智能, E-mail: kwxia@hebut.edu.cn;

王莉 (1977−), 女, 副教授, 博士, 主要研究方向为智能信息处理, E-mail: qhdzywl@hebut.edu.cn.