

# 基于认知差异的多机器人协同信息趋向烟羽源搜索方法

宋程<sup>1†</sup>, 贺昱曜<sup>1</sup>, 雷小康<sup>2</sup>, 杨盼盼<sup>3</sup>

(1. 西北工业大学航海学院, 西安 710072; 2. 西安建筑科技大学信息与控制工程学院, 西安 710055, 3. 长安大学电子与控制工程学院, 西安 710064)

**摘要:** 多机器人协同稀疏烟羽源搜索研究中, 追求群体信息一致而忽视个体独立搜索能力的发挥, 导致群体无法有效适应复杂搜索状况. 为此, 提出一种基于认知差异的协同信息趋向源搜索方法. 首先, 利用相对熵度量群内个体对源位置估计的认知差异; 然后, 据此赋予不同个体烟羽采样以相应权重, 在贝叶斯推理过程自适应权衡自身线索与群体线索; 最后, 采用分布式信息熵决策实施协同信息趋向搜索. 多种场景下的仿真结果验证了所提出算法的优越性.

**关键词:** 烟羽源; 信息趋向; 协同搜索; 认知差异; 相对熵

**中图分类号:** TP242.6 **文献标志码:** A

## Multi-robot collaborative infotaxis searching for plume source based on cognitive differences

SONG Cheng<sup>1†</sup>, HE Yu-yao<sup>1</sup>, LEI Xiao-kang<sup>2</sup>, YANG Pan-pan<sup>3</sup>

(1. School of Marine Science and Technology, Northwestern Polytechnical University, Xi'an 710072, China; 2. School of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China; 3. School of Electronic and Control Engineering, Chang'an University, Xi'an 710064, China)

**Abstract:** In multi-robot plume source searching with sporadic cues, the classic approaches strive for achieving social information consistency of all robots while the exploration ability of individual robot is ignored, which weakens the adaptivity of the group in complex environment. To overcome this drawback, a cooperative infotaxis searching approach is proposed. The relative entropy is introduced to measure the cognitive differences of likelihood function of source location between robots. Then, different weights are assigned to the sensor measurements of individual robot based on the cognitive differences. In the Bayesian learning process, the trade-off between individual cues and social cues is adaptively regulated for acquiring private source location probability distribution. Finally, the collaborative infotaxis search strategy is implemented by performing an entropy decision of each robot. The advantages of the proposed method are illustrated by simulation experiments under different scenarios.

**Keywords:** plume source; infotaxis; collaborative search; cognitive differences; relative entropy

## 0 引言

利用具有化学痕迹检测功能的机器人系统探测有毒、有害物质线索, 进而追踪其释放源头, 是一种搜寻目标的有效手段, 其在污染物泄漏检测、火源探测、事故搜救和反恐排爆等领域具有广阔的应用前景<sup>[1]</sup>. 然而实际中, 受湍流影响, 目标释放的化学线索通常被撕裂成烟羽和碎片状, 导致机器人检测具有间断和稀疏分布的特点, 无法获得稳定的浓度梯度, 这给机器人追踪搜索带来严峻的挑战<sup>[2]</sup>.

在自然界, 很多动物拥有利用稀疏气味线索溯源

的优异能力(寻找食物、配偶、巢穴等). 例如, 雄蛾在数百米外即可嗅到雌蛾信息素并据此确定雌蛾位置<sup>[3]</sup>. 鲨鱼可感知浓度低于百万分之一的血腥味, 从而对数公里外的受伤猎物实施追捕<sup>[4]</sup>. 这为机器人源搜索研究提供了非常有价值的参考和启发. 对于生物这种卓越溯源能力内在机理的研究, 长期以来吸引着生物、物理、信息等学科研究者的关注, 相继提出了化学趋向性<sup>[5]</sup>、风趋向性<sup>[6]</sup>、刺激趋向性<sup>[7]</sup>等生物气味溯源理论或假说. 近年来, 信息论亦被用于解释许多生物嗅觉溯源行为的底层驱动机制<sup>[8]</sup>. 2007年,

收稿日期: 2016-11-08; 修回日期: 2017-02-22.

基金项目: 国家自然科学基金项目(61271143, 61473225).

作者简介: 宋程(1987—), 男, 博士生, 从事多机器人导航与控制的研究; 贺昱曜(1956—), 男, 教授, 博士生导师, 从事非线性控制理论等研究.

†通讯作者. E-mail: songcheng3@126.com

Vergassola等<sup>[9]</sup>最先提出以信息趋向性获得最大信息增益的嗅觉溯源搜索策略,成功揭示了嗅觉溯源行为的机理.该方法将气味浓度、风向、风速等融合为“信息”这一单一要素,以此作为个体实施搜索的行动指示,能有效克服湍流环境下的源搜索问题,且不依赖准确数学气味扩散模型<sup>[10]</sup>,搜索过程表现出了类似于生物嗅觉溯源行为的多样性和环境适应性<sup>[11]</sup>.目前,信息趋向性搜索机制已在单机器人领域开展了众多的理论和应用研究<sup>[12-13]</sup>,取得了良好的效果.

相较于单机器人探测,利用多机器人群体的协同效应解决复杂湍流环境下的源搜索问题,可在搜索时间、克服局部极值、鲁棒性、容错性等方面获得显著优势.此前,基于非信息趋向机制的协同源搜索方法主要包括:群Spiral-Surge算法<sup>[14]</sup>、通量趋向性算法<sup>[15]</sup>、粒子群优化算法<sup>[16]</sup>、生物群集搜索算法<sup>[17]</sup>等.Gintautas等<sup>[18-19]</sup>最先将信息趋向机制扩展到多机器人协同溯源领域,提出了多个体共享源位置概率分布的协同信息趋向搜索方法.在此基础上,Masson等<sup>[20]</sup>提出了全局信息熵决策方法,从整体角度协调各成员移动方向使共享概率地图的信息熵趋向减小方向.Zhang等<sup>[21]</sup>采用平均场理论构建了共享的源位置概率分布近似表达式,以应对机器人空间感知能力的不足.Lu等<sup>[22]</sup>将多个机器人各自的源位置分布概率组合成单一全局概率地图.

上述协同信息趋向源搜索方法的核心在于,通过交互个体间共享源概率地图借助群体效应增加各成员获得的烟羽采样数量,从统计意义上使源位置估计更加准确,从而提升整体的搜索性能<sup>[23]</sup>.然而,这种集聚所有成员采样数据的信息融合思想难以克服群体内个体误检或失效的影响<sup>[24]</sup>,导致个别个体因误检等原因产生的错误数据污染其他个体的决策.另一方面,共享概率地图机制限制了个体的环境探索能力,这种强调整体性使得群体对新线索的捕获敏感度降低,稀释了个体捕获新线索的能力,致使群体无法逃脱局部极值区域<sup>[24]</sup>.

本文针对共享源概率地图方法的不足,基于探索与利用平衡的思想,提出一种基于个体间认知差异的多机器人协同信息趋向源搜索方法.该方法采用相对熵衡量各机器人就源位置分布的认知一致程度,据此得到烟羽采样数据的相关度参量;个体在倾向于采用自身烟羽采样进行贝叶斯推理的同时,利用采样相关度调整其他机器人采样的相对权重;最后基于分布式信息熵决策实现了对稀疏烟羽源的协同搜索.通过不同场景下的仿真实验分析,验证了所提出

协同源搜索方法的可行性和有效性.

## 1 信息趋向原理

不同于传统基于化学信号强度的浓度梯度方法,信息趋向搜索将化学采样信号转化为“信息”,由信息增益驱动机器人运动.搜索过程中,机器人以内部扩散模型结合实时采样数据,利用贝叶斯推理得到源位置概率分布,进而基于检测模型计算期望信息增益,以最大熵降引导机器人搜索.当熵值降减为0时,不确定性消失,则认为找到源.

### 1.1 检测模型与扩散模型

设在自由空间 $W$ 某处有一个化学物质扩散源,其释放出的物质在湍流的作用下以烟羽形态散布于空间 $W$ 中.机器人配备浓度阈值传感器,即所谓的二元传感器(binary sensor).当某一位置检测到的物质浓度大于设定阈值时,则认为捕获到了化学线索,感知结果为“1”,否则感知结果为“0”.据此检测原理,在特定时间间隔 $\Delta t$ 内,某一位置 $r$ 处的化学烟羽物质检测近似一个泊松过程,满足

$$\rho_z(r) = \frac{\lambda_p^z}{z!} e^{-\lambda_p}. \quad (1)$$

其中: $z$ 为感知结果为“1”的次数; $\lambda_p = R(r|r_0)\Delta t$ 为平均次数, $R(r|r_0)$ 为采样率,表示烟羽扩散中源位置与化学采样之间的关系.

由流体力学可知,对于位于 $r_0 = (x_0, y_0)$ 处的化学释放源,其信号在空间 $r$ 处采样率 $R(r|r_0)$ 与离源距离、周边流场、环境结构等因素有关,依据Smoluchowski方程可表示为<sup>[9]</sup>

$$R(r|r_0) = \frac{Q}{\ln \frac{\lambda}{\alpha}} e^{-\frac{(y-y_0)V}{2D}} K_0\left(\frac{|r-r_0|}{\lambda}\right). \quad (2)$$

其中: $Q$ 为线索释放率; $D$ 为综合了湍流扩散和分子扩散的线索扩散率; $K_0$ 为零阶第II类贝塞尔函数; $\alpha$ 为搜索半径; $V$ 为流体的平均速度,由于扩散率 $D$ 的影响,其在方向和大小上均有瞬时波动; $\lambda = \sqrt{D\tau/(1+V^2\tau/4D)}$ 为特征长度, $\tau$ 为线索的平均寿命.

### 1.2 贝叶斯推理

基于上述二元传感器的检测原理,机器人既往运动轨迹 $\Gamma_t$ 上所发生烟羽线索捕获序列可记为 $[r(t_1), r(t_2), \dots, r(t_n)]$ ,其隐含了关于源位置的信息.在贝叶斯框架下,空间 $W$ 中源位置 $r_0$ 的概率分布 $P_t(r_0)$ 可表示为

$$P_t(r_0) = \frac{L_{r_0}(\Gamma_t)}{\int L_{r_x}(\Gamma_t) dr_x} =$$

$$\frac{\exp \left[ - \int_0^t R(r(t')|r_0) dt' \right] \prod_{n=1}^H R(r(t_n)|r_0)}{\int \exp \left[ - \int_0^t R(r(t')|r_x) dt' \right] \prod_{n=1}^H R(r(t_n)|r_x) dr_x} \quad (3)$$

其中:  $L_{r_0}(\Gamma_t)$  为轨迹  $\Gamma_t$  的似然函数,  $H$  为沿轨迹  $\Gamma_t$  捕获线索的次数,  $t_n$  对应于线索捕获时刻,  $\exp \left[ - \int_0^t R(r(t')|r_0) dt' \right]$  为未捕获项,  $\prod_{n=1}^H R(r(t_n)|r_0)$  为捕获项. 以上参数的详细含义见文献[9].

### 1.3 信息趋向算法

信息趋向算法的核心是将信息熵作为衡量源位置不确定性的测度, 将其变化视作瞬时势场, 驱使机器人向最大熵降方向移动. 任意时刻  $t$ , 基于历史烟羽采样序列得出的源位置概率分布  $P_t(r_0)$  的信息熵为  $S_t = - \int_W P_t(r_x) \log P_t(r_x) dr_x$ . 信息趋向使源位置概率分布  $P_t(r_0)$  的信息增益最大化, 即以最快熵降速度减少源位置估计的不确定性. 具体而言, 机器人从当前位置  $r(t)$  移动到相邻位置  $r_m$  可能的信息熵变化为

$$\Delta E_S(r(t) \rightarrow r_m) = P_t(r_m)(0 - S_t) + (1 - P_t(r_m)) \sum_{k=0}^{\infty} \rho_k \Delta S_k. \quad (4)$$

其中: 右侧第1项表示源以  $P_t(r_m)$  的概率位于  $r_m$  处时, 对应的熵减为  $0 - S_t$ ; 第2项表示  $r_m$  处未发现源, 但期望在  $r_m$  处捕获  $k$  次线索, 对应的熵减为  $\sum_{k=0}^{\infty} \rho_k \Delta S_k$ ,  $\rho_k$  为式(1)的泊松概率,  $\Delta S_k$  为  $P_{t+\Delta t}$  与  $P_t$  之间熵值的变化.

在此基础上, 机器人选择相邻位置中熵减幅度最大者作为机器人最佳移动方向; 如此往复, 直到源被确认.

## 2 基于认知差异的协同信息趋向源搜索算法(A-infotaxis)

目前基于信息趋向框架的多机器人协同源搜索算法大多采用共享概率地图的协作机制<sup>[18-22]</sup>, 其目的在于通过群体规模效应增加数据采集量, 弥补单个个体线索捕获间断丢失、推理数据量稀少等问题, 降低源位置估计的不确定性, 提升信息熵决策的效率. 共享概率地图协作方式简单, 适用于烟羽极度稀疏或采样数据较少的情况. 但是, 该机制着眼于追求群体信息一致性, 忽视了个体搜索的独立性, 导致其无法有效应对成员误检或失效等情况, 存在误导机器人陷入局部极值或伪源位置等问题<sup>[24]</sup>.

实际上, 生物群体中的个体在与群内其他个体保持行为决策一致的同时, 往往通过维持自身行为的独立性提高群体对于环境的探索能力. 这种探索与利用相权衡的机制, 是提高群体任务执行效率和适应动态环境的核心保障<sup>[25]</sup>. 从这一角度来审视, 共享概率地图方法仅体现了开发作用, 而探索作用未能体现.

事实上, 差异体现搜索灵活性, 在复杂环境下作用极为关键, 差异带来群体系统的功能异化, 得以展现丰富的搜索行为, 可应对多种复杂的搜索场景<sup>[26]</sup>. 基于此思想, 本文从探索与利用平衡角度出发, 以认知差异评估烟羽采样相关度来指导个体权衡利用自身及群体信息, 提出一种信息趋向协同源搜索方法.

### 2.1 个体认知差异度量

考虑由  $N$  个机器人组成的多机器人系统, 协同完成空间  $W$  某处烟羽物质扩散源的搜索任务, 机器人之间可进行通信且信息交互同步、无延迟. 记机器人  $i$  的源位置概率分布为  $P_t^{(i)}(r_0)$ , 个体独立进行源概率分布贝叶斯推理, 并倾向于自身烟羽采样数据. 由于个体采样线索量及分布位置的不同, 个体之间源位置概率分布的估计存在差异. 个体试图消除这种源位置认知差异而产生群体协同行为, 即差异协同. 概率分布的差异程度可以用概率距离衡量, 如巴氏距离和 K-L 散度等. 信息论中的 K-L 散度因其信息特性及非对称性较适用于信息趋向机制<sup>[27]</sup>. 为此, 本文采用 K-L 散度衡量群内个体对于源位置认知的差异程度.

令机器人  $i$  和  $j$  估计的源位置概率分布分别为  $P_t^{(i)}(r_0)$  和  $P_t^{(j)}(r_0)$ , 两者认知差异可表示为

$$D_{KL}(P_t^{(i)}(r_0) || P_t^{(j)}(r_0)) = \sum_{r_x \in W} P_t^{(i)}(r_x) \log \frac{P_t^{(i)}(r_x)}{P_t^{(j)}(r_x)}. \quad (5)$$

其中  $j \in N, j \neq i$ . 相对熵  $D_{KL}$  越小, 表示两者估计的源位置概率分布差异越小, 即认知的一致程度越高. 由于相对熵具有非对称性, 在  $P_t^{(i)}(r_0)$  较大的区域,  $P_t^{(j)}(r_0)$  对  $D_{KL}$  的影响较大; 相反, 在  $P_t^{(i)}(r_0)$  较小的区域,  $P_t^{(j)}(r_0)$  对  $D_{KL}$  的影响较小. 换言之,  $D_{KL}$  反映了  $P_t^{(i)}(r_0)$  高概率区域与  $P_t^{(j)}(r_0)$  高概率区域的相合程度.

在源搜索过程中, 若机器人  $i$  与  $j$  对源位置的概率分布估计完全一致, 则相对熵  $D_{KL} = 0$ ; 若两者对源位置概率分布的估计分歧越大, 则相对熵  $D_{KL} \rightarrow \infty$ , 意味着各自推理的源位置认知的一致度越低.

### 2.2 烟羽采样相关度

自然界中生物的推理学习过程通常倾向于采用自身采集的数据, 对其他个体的数据则采取有选择

接受的方式<sup>[28]</sup>. 随着线索捕获的不断发生, 源位置分布的宽度逐渐减小, 与自身认知差异较大的其他路径点上机器人的线索属同一烟羽分布的采样可能性越小. 据此规律, 定义了一个烟羽相关度参数  $\beta_{ij}$ , 用以权重化分配各路径点线索捕获事件在搜索过程中的贡献. 参数  $\beta_{ij}$  的定义如下:

$$\beta_{ij} = \sigma \exp[-D_{KL}(P_t^{(i)}(r_0) || P_t^{(j)}(r_0))]. \quad (6)$$

其中参数  $\sigma \in (0, 1]$ , 用于反映个体倾向于采用自身烟羽采样的相对权重. 若机器人  $i$  与  $j$  对源位置的认知完全一致, 即式(5)中  $D_{KL} = 0$ , 则  $\beta_{ij} = \sigma$ , 表示机器人  $j$  的采样数据与机器人  $i$  自身采样数据相关性最大; 若取  $\sigma = 1$ , 则两者采样数据的贡献相同.

基于式(6)的定义,  $\beta_{ij}$  随着相对熵  $D_{KL}$  的增大而减小, 即个体间的认知差异越小, 个体对于群体信息的认同度越大; 相反, 个体间的认知差异越大, 个体对于群体信息的认同度降低, 转而更为相信自身数据. 通过这一动态调节过程, 最终实现探索与利用的平衡. 当相对熵  $D_{KL}$  的增加致使  $\beta_{ij} \approx 0$  时, 机器人  $j$  的烟羽采样数据对于  $i$  没有任何价值.

### 2.3 协同信息趋向搜索

共享概率地图的思想是利用多机器人空间分散分布特性同时获取多个位置的烟羽采样, 汇集所有采样数据构建统一的共享概率地图, 以此提高源位置的估计精度和准确度, 进而提升搜索性能<sup>[19]</sup>. 共享概率地图  $P_t^{sh}(r_0)$  基于各机器人当前线索采样  $\{\eta_n, r_n(t + \Delta t)\} (n = 1, 2, \dots, N)$  以如下形式进行更新:

$$P_{t+\Delta t}^{sh}(r_0) = \frac{P_t^{sh}(r_0) \prod_{n=1}^N [L_{r_0}(\Gamma_{t+\Delta t}^{(n)})]}{Z_{t+\Delta t}}. \quad (7)$$

其中:  $L_{r_0}(\Gamma_{t+\Delta t}^{(n)}) = \exp[-R(r_n(t + \Delta t) | r_0) \Delta t] R^{\eta_n}(r_n(t + \Delta t) | r_0)$ ,  $\Gamma_{t+\Delta t}^{(n)}$  为机器人  $n$  在轨迹  $\Gamma_t^{(n)}$  上增加线索采样路径点,  $\eta_n$  为机器人  $n$  在时间间隔  $\Delta t$  内捕获线索次数,  $Z_{t+\Delta t}$  为归一化量. 此方法下群体内各机器人的源概率地图是一致的.

与共享概率地图不同, 本文考虑在贝叶斯推理中有差异地利用来自其他机器人的采样, 给予不同机器人采样的线索以相应的权重. 基于式(6)的采样相关度  $\beta_{ij}$  及式(3)的贝叶斯推理, 推导机器人  $i$  的概率地图  $P_t^{(i)}(r_0)$  以如下形式进行更新:

$$P_{t+\Delta t}^{(i)}(r_0) = \frac{P_t^{(i)}(r_0) L_{r_0}(\Gamma_{t+\Delta t}^{(i)}) \prod_{j=1, j \neq i}^N [L_{r_0}(\Gamma_{t+\Delta t}^{(j)})]^{\beta_{ij}}}{Z_{t+\Delta t}}. \quad (8)$$

其中:  $L_{r_0}(\Gamma_{t+\Delta t}^{(i)})$  为机器人  $i$  自身线索采样路径点的似然函数,  $L_{r_0}(\Gamma_{t+\Delta t}^{(j)}) (j \in N, j \neq i)$  为群内其他机器人线索采样路径点的似然函数.

式(7)对所有机器人捕获的线索同等对待, 这不仅会导致个别个体因误检等原因产生的错误数据“污染”其他个体行为决策, 而且个别个体在局部极值区域的骤增线索采样量会支配其他个体. 相比之下, 式(8)引入采样相关度  $\beta_{ij}$ , 利用认知差异赋予群体内个体的烟羽采样以不同的效用, 有效克服了上述问题. 本文方法蕴含多个体独立搜索和共享概率地图协同搜索相结合的机制: 若  $\beta_{ij} = 1$ , 则该方法退化为共享概率地图交互机制, 更多利用群体采样; 若  $\beta_{ij} = 0$ , 则该方法退化为无交互各自独立信息趋向, 更强调个体独立探索的能力.

在此基础上, 机器人  $i$  使用源概率分布  $P_t^{(i)}(r_0)$  进行信息熵决策, 由式(4)推导得

$$\Delta E_S(r_i(t) \rightarrow r_m^{(i)}) = P_t^{(i)}(r_m^{(i)}) (0 - S_t) + (1 - P_t^{(i)}(r_m^{(i)})) \sum_{k=0}^{\infty} \rho_k^{(i)} \Delta S_k^{(i)}. \quad (9)$$

据此, 机器人个体  $i$  在空间  $W$  的移动形式为

$$u_i = \arg \max_{r_m^{(i)} \in v_k} E_S(r_i(t) \rightarrow r_m^{(i)}), \quad (10)$$

其中  $v_k$  为当前机器人的相邻位置的集合. 该式表明机器人  $i$  选择获得最大熵降的相邻位置作为下一步运动的方向. 在此方法下, 个体利用认知差异的群体协同效应寻求搜索过程中探索与利用的平衡, 加速个体的信息趋向以降低对源位置估计的不确定性. 如此, 既能在稀疏环境中增加采样线索量, 获得更为准确的源概率分布, 又能发挥认知差异对群体成员的采样线索的可利用价值的区分. 该方法能在提高个体信息趋向搜索效率的同时具备歧离运动特性, 以应对复杂应用场景(传感器误检、个体失效及局部极值等问题).

### 2.4 算法流程

基于认知差异的协同信息趋向源搜索算法的执行步骤可描述如下.

对于群内任一机器人  $i (i = 1, 2, \dots, N)$ , 依次执行如下步骤.

**Step 1:** 初始化源概率分布估计  $P_{t=0}^{(i)}(r_0)$  和对应的信息熵  $S_{t=0}^{(i)}$ ;

**Step 2:** 待选移动位置  $r_m^{(i)}$  处期望捕获线索次数  $h(r_m^{(i)}) = \Delta t \int P_t^{(i)}(r_0) R(r_m^{(i)} | r_0) dr_0$ , 计算  $r_m^{(i)}$  处  $\Delta t$  时间内可能捕获  $k$  次线索的概率  $\rho_k(r_m^{(i)})$ ;

Step 3: 计算  $r_m^{(i)}$  处捕获  $k$  次线索得到源位置概率  $P_{t+\Delta t}^k$  和相应的信息熵  $S_k^{(i)}$ , 得到  $\sum_{k=0}^{\infty} \rho_k^{(i)} \Delta S_k^{(i)}$ ;

Step 4: 计算由位置  $r_i(t)$  移动到  $r_m^{(i)}$  期望引起的信息熵变化  $\Delta E_S(r_i(t) \rightarrow r_m^{(i)})$ , 进而选择最大者  $r_m^{(i)}$  作为最佳移动位置;

Step 5: 记录在  $t$  时刻位置  $r_i(t)$  移动到  $t + \Delta t$  时刻最佳位置  $r_m^{(i)}$  的时间间隔  $\Delta t$  内, 捕获的线索数量  $\eta_i = 0, 1, 2, \dots$ ;

Step 6: 从其他个体获得  $P_t^{(j)}(r_0)$  和当前线索采样  $\{\eta_j, r_j(t)\}$ ;

Step 7: 根据式(5)和(6)分别计算机器人  $i$  与其他成员的概率分布差异  $D_{KL}(P_t^{(i)}(r_0) || P_t^{(j)}(r_0))$  和烟羽采样相关度  $\beta_{ij}$ ;

Step 8: 更新源概率分布  $P_t^{(i)}(r_0)$  为  $P_{t+\Delta t}^{(i)}(r_0)$ , 相应的信息熵由  $S_t^{(i)}$  更新为  $S_{t+\Delta t}^{(i)}$ ;

Step 9: 返回 Step 3, 直至到达源所在位置结束.

### 3 仿真结果与分析

本节从路径长度和搜索成功率两方面出发, 对共享概率地图搜索算法 (S-infotaxis)<sup>[20]</sup> 和本文所提出基于认知差异的信息趋向协同搜索算法 A-infotaxis 的性能进行仿真对比分析. 仿真实验中的烟羽释放采用时间平均烟羽模型生成 (具体实现参见文献 [9]), 相应的扩散模型 (式 (2)) 的参数 (任意单位  $u$ ) 设置为: 粒子扩散率  $D = 1 u$ , 粒子生命周期  $\tau = 1500 u$ , 源释放率  $Q = 1 u$ , 平均风速  $V = 1 u$ , 传感器的测量半径  $\alpha = 1 u$ . 仿真空间  $W$  设为  $100 \times 200$ , 以均匀间距  $1 u$  将其离散为栅格, 每一步机器人仅能向相邻栅格位置集合  $v_k = \{\uparrow, \nearrow, \rightarrow, \searrow, \downarrow, \swarrow, \leftarrow, \nwarrow\}$  定义的方向移动. 为简便起见, 实验中仅考虑 3 个机器人, 其初始位置设定在下风方向  $160 u$  处半径为  $20 u$  的圆形区域内. 机器人之间无拓扑约束, 可进行全通信无时延, 其结果亦可拓展到数量更多的机器人群体. 搜索过程中, 若某一机器人位置与源位置距离小于阈值  $D_{th} = 3 u$ , 则认为源被确认, 搜索结束. 所有数值仿真在 Matlab 中进行.

#### 3.1 场景 1: 单源理想情形

为了检验本文所提出算法的有效性, 首先考虑单源理想情形, 此环境中分布的烟羽由单一源释放, 传感器检测数据能准确反映烟羽分布, 相关搜索轨迹如图 1 所示. 为便于比较, 图 1 中同时给出了无交互独立搜索方法 (I-infotaxis, 个体间不具备通信或通信失效) 的路径轨迹.

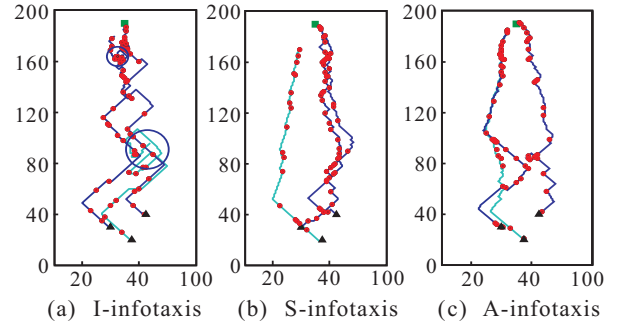


图 1 3 种搜索方法的搜索路径轨迹比较

由图 1 可以看出, 理想情况下, 3 种算法均可完成源搜索任务, 但三者的表现有所不同. I-infotaxis 方法丢失烟羽时回旋搜索, 或当局部多次检测而产生自陷 (图 1(a) 中画圈), 路径蜿蜒曲折较大. S-infotaxis 搜索方法下, 多机器人增加烟羽检测的数量使共享概率地图更加准确, 路径更加径向趋近源 (图 (b)). A-infotaxis 搜索方法下路径轨迹总体上与 S-infotaxis 接近, 但在起始阶段存在较大折转, 这是由于此阶段各机器人自身线索稀少使源概率差异较大, A-infotaxis 方法退化为 I-infotaxis 方法所致. 搜索过程中个体信息熵的变化可实时反映这一过程, 如图 2 所示.




图 2 搜索过程中信息熵变化曲线

图 2 给出了图 1 所示搜索过程最先到机器人对应的信息熵时间演化曲线. 从中可以看出, 起始阶段 ( $t < 40$  steps), 线索捕获量较少, S-infotaxis 方法汇集 3 个机器人的采样数据, 获得信息量最多, 信息熵下降最快; A-infotaxis 方法的 3 个机器人基于少量线索致源概率未形成一致认同, 烟羽采样相关度  $\beta_{ij} \approx 0$ , 弃用其他个体的烟羽采样, 故与 I-infotaxis 方法的信息熵下降趋势一致 (图 2 中红绿曲线的初始阶段基本重合). 当  $t > 40$  steps, 随着线索的不断收集, A-infotaxis 方法下个体对源分布认知趋于一致, 烟羽采样相关度  $\beta_{ij} \approx 1$ , 所有个体的烟羽采样数据纳入统一考量, 因此与 S-infotaxis 方法的信息熵变化趋势一致 (图 2 中实线和点划线的后期阶段基本重合).

为了进一步用量化指标说明 3 种方法的搜索效率, 图 3 给出了 3 种算法分别执行 50 次搜索任务所得

的路径长度统计结果.可以看出,相较于非合作的个体(I-infotaxis),合作个体(S-infotaxis和A-infotaxis)的搜索路径明显缩短,显现出协同搜索的优势.然而值得注意的是,在理想情形下,S-infotaxis方法的搜索路径比A-infotaxis方法略短,但两者区别并不显著.这是由于A-infotaxis方法在起始阶段机器人各自线索稀少,未能就源概率分布达成一致,因而分别基于自身稀少线索信息趋向决策,使得路径蜿蜒.




图3 3种搜索方法的搜索路径长度

### 3.2 场景2: 传感器误检

误检是指机器人所在位置未出现烟羽或其浓度未达到设定阈值而传感器有检测输出,导致采样数据不能准确反映真实烟羽分布.该情形在实际烟羽检测中客观存在<sup>[29]</sup>,可由环境噪声、传感器参数漂移等引起.对于二元传感器,误检可描述为以概率 $\theta \in [0, 1]$ 随机产生感知结果“1”, $\theta$ 称之为“误检率”.为了便于研究,本实验仅考虑群内单一机器人出现随机误检(确保误检数据来源单一),即式(8)线索采样数据 $\{\eta_n, r_n(t)\}$ 中的线索数量 $\eta_n$ 以概率 $\theta$ 随机加1.

为全面检验A-infotaxis和S-infotaxis协同机制下的误检传播情况及对误检的抑制能力,图4给出了不

同误检发生率下机器人的搜索成功率.从中可以看出,S-infotaxis方法对误检极度敏感,虽在误检率较小时( $\theta < 30\%$ ,误检数据占比小)其成功率接近于1,但随着误检率增加致使成功率急剧下降,S-infotaxis展现出较差的鲁棒性.相比之下,误检对A-infotaxis方法的搜索成功率影响较弱,即使群内某一个体的传感器完全失灵( $\theta = 100\%$ ),搜索成功率也未有显著下降.究其原因,采用S-infotaxis方法,某个体出现随机误检采样会污染群体共享概率地图(式(5)),概率地图的准确性受到破坏,并随着误检率增加而影响增大,导致搜索效率降低或引向错误的位置.A-infotaxis方法下个体对自身采样充分信任,同时通过采样相关度赋予来自其他个体线索不同的权重,因此某个体出现误检时错误检测对其他个体的影响较小,甚至不产生影响,显现出了认知差异协同的优势.




图4 不同误检率下的搜索成功率比较(每个误检率下分别进行50次蒙特卡洛仿真)

A-infotaxis方法的上述搜索表现表明,该方法具有良好的鲁棒性和容错性.为解释其内在机制,图5给出了 $\theta = 50\%$ 时搜索过程中群体的概率地图时序

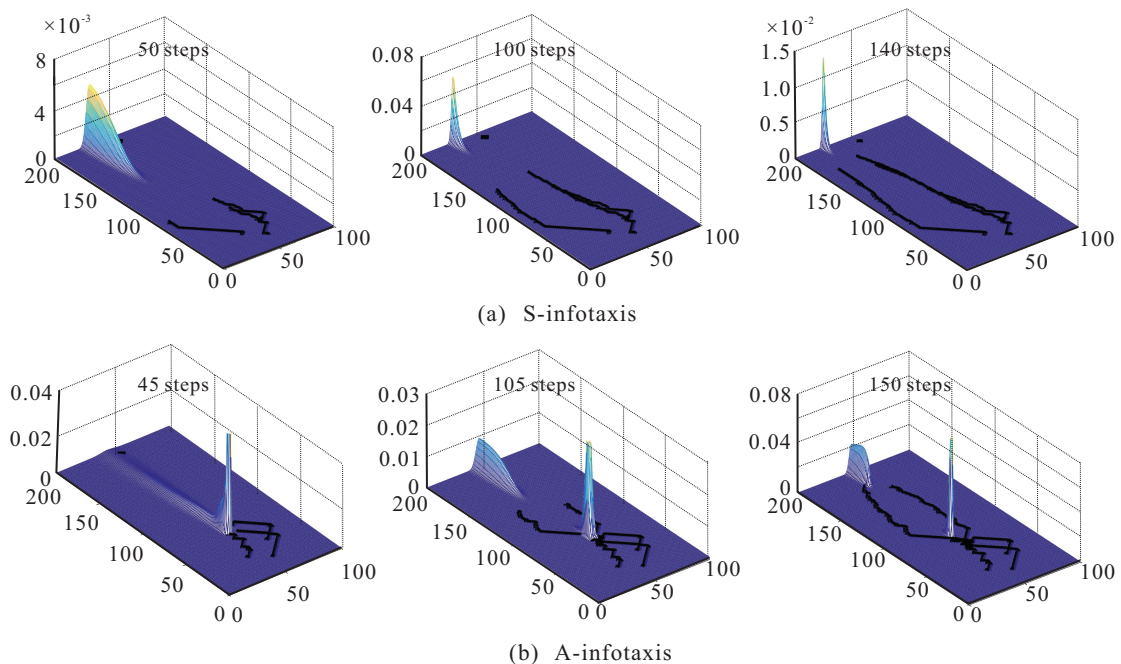


图5 误检情况下搜索过程概率地图变化

截图. 可以看出, S-infotaxis 方法的概率地图自始至终存在唯一且偏离真实源位置的高概率区域(图 5(a) 中凸起区域). 相比而言, A-infotaxis 方法在某一个体出现误检时, 起初产生单一高概率区域(图 5(b) 中 45 steps 处), 但高概率区域随后出现分离而脱离局部极值(图 5(b) 中 100 steps 和 150 steps 处). 这是由于差异协同使个体具有较强的独立性, 不易受到其他个体误检信息的干扰.

综合而言, 群体内某一个体发生误检或传感器失灵, S-infotaxis 方法会将误检个体的采样数据引入群体概率地图的推理过程中, 影响概率地图的准确性, 错误信息会导致搜索效率降低甚至误导搜索. 但对于 A-infotaxis 方法, 认知差异协同使误检采样数据对其他个体影响有限, 其他个体可继续实施协同搜索, 群体获得良好的鲁棒性和容错性.

### 3.3 场景 3: 局部极值

局部极值是指搜索空间中存在因烟羽集中而出现的持续高浓度区域, 导致局部区域采样数量骤增. 该情形对应于实际中化学物质受障碍物阻隔而形成局部堆积等状况<sup>[30]</sup>. 为便于研究, 本实验设空间中存在以 (40, 100) 为中心、半径为 10 的圆形烟羽集中区域, 此区域线索采样数据  $\{\eta_n, r_n(t)\}$  中的线索数量  $\eta_n$  以一定概率随机加 5.

图 6 给出了存在局部极值情形下两种方法的搜索路径比较. 可以看出, 对于 S-infotaxis 方法, 当某一机器人进入局部极值区域(图 6(a) 圆圈中检测点密集)后会吸引其他个体趋向此区域, 致使群体陷入局部极值区域而无法逃脱, 造成搜索失败. 相比之下, 采用 A-infotaxis 方法, 当某一机器人进入局部极值区域(图 6(b) 圆圈中检测点密集)时, 其自身虽无法逃脱此区域, 但不会吸引群体集体陷入, 其他个体可继续实施搜索. 究其原因, 在 S-infotaxis 方法中, 某一个体在极值区域产生的骤增采样量被群体所共享, 致使该个




图 6 局部极值情况下的搜索路径轨迹比较

体存在线索数量上的绝对优势而主导群体行为, 所有个体向此个体所在位置靠拢(图 6(a) 中圆圈位置). 而在 A-infotaxis 方法中, 当某一个体在极值区域产生骤增采样量时, 该个体的源概率分布估计与其他个体差异增大, 故其采样数据进入其他个体的推理过程的相对权重较小, 不足以支配其他个体的搜索行为.

## 4 结论

本文提出了一种基于个体间认知差异的协同信息趋向源搜索算法 A-infotaxis, 解决了传统共享概率地图机制在多机器人协同搜索化学烟羽源问题中存在的不足. 该方法利用相对熵的性质, 度量机器人个体之间因分布位置和线索量的不同而就源位置估计产生的认知差异, 使个体对自身采样线索和来自群体采样线索的效用得以评估. 进而在个体贝叶斯推理过程中, 个体倾向于采用自身采样线索的同时, 利用烟羽采样相关度给予来自群体的采样线索不同的权重, 获得符合自身认知的源概率分布. 据此, 源概率分布采用分布式信息熵决策, 实现了多机器人在搜索过程中探索与利用平衡. 最后在不同场景下对 A-infotaxis 方法进行了验证, 结果表明, 引入认知差异协同的思想, 在保证群体信息有效利用的同时个体具有独立探索能力, 相比于 S-infotaxis 方法, 多机器人行为表现出更多的鲁棒性、容错性、灵活性和多样性, 适应多种复杂未知烟羽环境. 本文针对无障碍环境旨在开发一种可高效利用烟羽分布特征的协同源搜索算法, 后续将对含障碍物的复杂烟羽环境的源搜索方法开展进一步研究.

## 参考文献(References)

- [1] 孟庆浩, 李飞. 主动嗅觉研究现状[J]. 机器人, 2006, 28(1): 89-96.  
(Meng Q H, Li F. Review of active olfaction[J]. Robot, 2006, 28(1): 89-96.)
- [2] Kowadlo G, Russell R A. Robot odor localization: A taxonomy and survey[J]. The Int J of Robotics Research, 2008, 27(8): 869-894.
- [3] Umbers K L, Symonds M E, Kokko H. The mathematics of female pheromone signaling: Strategies for aging virgins[J]. The American Naturalist, 2015, 185(3): 417-432.
- [4] Gardiner J M, Atema J. The function of bilateral odor arrival time differences in olfactory orientation of sharks[J]. Current Biology, 2010, 20(13): 1187-1191.
- [5] Naeem W, Sutton R, Chudley J. Chemical plume tracing and odour source localisation by autonomous vehicles[J]. J of Navigation, 2007, 60(2): 173-190.
- [6] Cardé R T, Willis M A. Navigational strategies used by insects to find distant, wind-borne sources of odor[J]. J of

- Chemical Ecology, 2008, 34(7): 854-866.
- [7] Webster D R, Volyansky K Y, Weissburg M J. Bioinspired algorithm for autonomous sensor-driven guidance in turbulent chemical plumes[J]. *Bioinspiration and Biomimetics*, 2012, 7(3): 129-135.
- [8] Tishby N, Polani D. Information theory of decisions and actions[M]. New York: Springer, 2011.
- [9] Vergassola M, Villermaux E, Shraiman I. 'Infotaxis' as a strategy for searching without gradients[J]. *Nature*, 2007, 445(7126): 406-409.
- [10] Rodríguez J D, Gómez-Ullate D, Mejía-Monasterio C. Limits on the performance of infotaxis under inaccurate modelling of the environment[J]. *ArXiv Preprint*, 2014, 1408(1873): 1-8.
- [11] Null N. Correction: Reactive searching and infotaxis in odor source localization[J]. *Plos Computational Biology*, 2014, 10(10): e1003861-e1003861.
- [12] Moraud E M, Martinez D. Effectiveness and robustness of robot infotaxis for searching in dilute conditions[J]. *Frontiers in Neurorobotics*, 2010, 4(4): 1-8.
- [13] Ristic B, Skvortsov A, Gunatilaka A. A study of cognitive strategies for an autonomous search[J]. *Information Fusion*, 2016, 28(C): 1-9.
- [14] Marjovi A, Nunes J, Sousa P, et al. An olfactory-based robot swarm navigation method[C]. 2010 IEEE Int Conf on Robotics and Automation(ICRA). Anchorage, 2010: 4958-4963.
- [15] Spears D F, Thayer D R, Zarzhitsky D V. Foundations of swarm robotic chemical plume tracing from a fluid dynamics perspective[J]. *Int J of Intelligent Computing and Cybernetics*, 2009, 2(4): 745-785.
- [16] 张建化, 巩敦卫, 张勇. 基于微粒群优化的有限通信多机器人气味寻源[J]. *控制与决策*, 2013, 28(5):726-730. (Zhang J H, Gong D W, Zhang Y. Localizing odor sources using multiple robots based on particle swarm optimization in limited communication environments[J]. *Control and Decision*, 2013, 28(5): 726-730.)
- [17] Davidson G P, Goodwin D, Robb T A. Simultaneous source localization and boundary mapping for contaminants[C]. IEEE American Control Conf. Montreal, 2012: 4174-4179.
- [18] Gintautas V, Hagberg A, Bettencourt L. Cooperative searching for stochastic targets[J]. *ArXiv Preprint*, 2011, 1103(4888): 1-8.
- [19] Gintautas V, Hagberg A, Bettencourt L. Leveraging synergy for multiple agent infotaxis[J]. *Proc of Social Computing, Behavioral Modeling, and Prediction*, 2008, 43(6): 32-47.
- [20] Masson J B, Bechet M B, Vergassola M. Chasing information to search in random environments[J]. *J of Physics A: Mathematical and Theoretical*, 2009, 42(43): 434009-434014.
- [21] 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): 1429-1430.)
- [22] Lu Q, Luo P. A learning particle swarm optimization algorithm for odor source localization[J]. *Int J of Automation and Computing*, 2011, 8(3): 371-380.
- [23] Bettencourt L. The rules of information aggregation and emergence of collective intelligent behavior[J]. *Topics in Cognitive Science*, 2009, 1(4): 598-620.
- [24] Hajieghrary H, Hsieh M A, Schwartz I B. Multi-agent search for source localization in a turbulent medium[J]. *Physics Letters A*, 2016, 380(20): 1698-1705.
- [25] Chen J, Xin B, Peng Z, et al. Optimal contraction theorem for exploration - exploitation tradeoff in search and optimization[J]. *IEEE Trans on Systems, Man, and Cybernetics, Part A: Systems and Humans*, 2009, 39(3): 680-691.
- [26] Al-Rifaie M M, Bishop J M, Caines S. Creativity and autonomy in swarm intelligence systems[J]. *Cognitive Computation*, 2012, 4(3): 320-331.
- [27] Siggia E D, Vergassola M. Decisions on the fly in cellular sensory systems[J]. *Proc of the National Academy of Sciences*, 2013, 110(39): 3704-3712.
- [28] Garnier S, Gautrais J, Theraulaz G. The biological principles of swarm intelligence[J]. *Swarm Intelligence*, 2007, 1(1): 3-31.
- [29] Ristic B, Skvortsov A, Walker A. Autonomous search for a diffusive source in an unknown structured environment[J]. *Entropy*, 2014, 16(2): 789-813.
- [30] Breugel F V, Dickinson M H. Plume-tracking behavior of flying *Drosophila* emerges from a set of distinct sensory-motor reflexes[J]. *Current Biology*, 2014, 24(3): 274-286.

(责任编辑: 孙艺红)