

基于多微粒群优化的机器人气味源定位

巩敦卫, 戚成亮, 张 勇, 胡 滢

(中国矿业大学信息与电气工程学院, 江苏徐州 221116)

摘 要: 研究多气味源同时定位问题, 提出一种基于多微粒群优化的机器人气味源定位方法. 该方法将机器人看作一个微粒, 邻近的微粒组成一个子群, 不同的子群定位不同的气味源. 通过合并相似的子群和降低微粒在已搜索区域的适应值, 使得微粒群定位尽可能多的气味源. 当气味源所在环境变化时, 根据子群当代极值与前代全局极值之间的关系, 选择子群的全局极值. 将所提方法应用于 3 个典型静态环境与 1 个动态环境的气味源定位, 并与 5 种已有方法比较. 实验结果表明, 所提方法能够高效地定位多气味源.

关键词: 气味源定位; 机器人; 微粒群优化; 子群合并; 适应值调整

中图分类号: TP301 **文献标识码:** A **文章编号:** 0372-2112 (2013) 10-2000-10

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2013.10.021

Localizing Odor Sources Using Robots Based on Multi-swarm Particle Swarm Optimization

GONG Dun-wei, QI Cheng-liang, ZHANG Yong, HU Ying

(School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China)

Abstract: The problem of localizing multiple odor sources is focused on, and a method of localizing odor sources using robots based on multi-swarm particle swarm optimization (PSO) is presented in this paper. In this method, each robot is regarded as a particle, neighboring particles form a sub-swarm, and different sub-swarms are used to localize different odor sources. In order to make the whole swarm localize as many odor sources as possible, the merging strategy of similar sub-swarms and the reducing strategy of the individual fitness are incorporated into the proposed algorithm. When the environment in which these odor sources lie changes, the globally optimal solution of a sub-swarm is selected according to the relationship between the optimal solution of the sub-swarm in the current generation and that up to the previous generation. The proposed method is applied to localize odor sources in three typical static environments and one dynamic environment, and compared with five previous methods. The experimental results confirm that the proposed method can efficiently localize odor sources.

Key words: odor source localization; robot; PSO; sub-swarm emergence; fitness adjustment

1 引言

很多实际问题可以归结为气味定位问题, 如爆炸物搜索、有毒气体检测, 以及火灾预警等. 机器人用于气味定位始于 20 世纪 90 年代初期, 已经成为当今的热门研究方向之一^[1]. 根据环境中气味源的多少, 已有方法可以分为 2 类, 分别是单气味源定位和多气味源定位.

用于单气味源定位的方法主要有面向单机器人的传统方法和面向多机器人的智能方法, 其中, 基于单机器人的传统方法的代表性成果有: Holland 等根据真涡虫行为提出的 Z 形路径搜索策略^[2]、Russell 等提出的六边形算法^[3], 以及基于蚕蛾觅偶行为的搜索方法^[4]等,

该类方法易于实现, 但其扩展能力有限, 且鲁棒性较差. 基于多机器人系统的定位方法, 可以在一定程度上弥补上述缺陷^[5,6]. 在面向多机器人的气味源智能定位方面, Hayes 等给出了基于群体智能的多机器人协同气味源定位方法^[7]. 相比单机器人, 该方法可以更快地定位气味源, 但是, 机器人间的合作策略简单, 且没有充分利用不同机器人的状态. 利用微粒群优化^[8]解决气味源定位问题, Jatmiko 等提出了带电微粒群优化方法 (Charge Particle Swarm Optimization, CPSO)^[9], 以及检测与响应 PSO 方法 (Detect and Respond Particle Swarm Optimization, DRPSO). 实验表明, 在相同的环境下, CPSO 的气味源定位效果要优于 DRPSO^[9]. 此外, Jatmiko 等借助风的信息

分别还提出了风速法 I (Wind Utilization I, WUI) 与风速法 II (Wind Utilization II, WUII), 上述两种方法只需很少的参数, 即可拥有良好的气味源定位效果^[10]. 最近, 巩敦卫等提出了一种基于风向的自适应微粒群定位方法 (Adaptive Particle Swarm Optimization based on Wind Direction, WPSO)^[11], 在微粒更新时, 利用风趋向性动态调整学习因子. 该方法在定位成功率和耗时等方面均有很大改善, 但是, 所提策略仍是面向单个气味源, 无法同时定位多气味源定位问题.

上述工作作为机器人气味源定位问题提供了新的解决途径, 但是, 这些成果多面向理想或简单环境的单气味源定位问题. 对于多气味源定位问题, 目前的研究成果还较少. 处理多气味源定位问题, Marques 等提出了局部与全局混合搜索算法^[12], 当机器人找到气味信息素时, 进行局部搜索; 否则, 进行全局搜索. 然而, 作者没有给出多气味源同时定位的实现策略. Luo 等给出了一种基于改进蚁群优化的多机器人气味源定位方法^[13]. 该方法将气味源定位分为多个阶段, 在每个阶段, 机器人仅定位一个气味源. Jatmiko 等提出了基于改进微粒群优化 (Modified Particle Swarm Optimization, MPSO) 的多气味源定位方法^[14], 但所考虑的气味源环境, 以及微粒间的合作策略相对比较简单.

与单气味源定位相比, 利用微粒群优化定位多气味源时, 将产生如下新问题: (1) 微粒群的拓扑结构, 如果采用传统的微粒群拓扑结构, 那么, 整个微粒群每次只能定位一个气味源, 此时, 需要重新运行微粒群优化算法, 才能定位下一个气味源; (2) 子群间的合作, 如果采用多微粒群定位气味源, 将需要子群间的合作机制, 否则, 多个子群将重复搜索同一区域, 使得子群的定位效率大大降低; (3) 已有信息的利用, 如果不充分利用已有的信息, 那么, 微粒将难以逃离已搜索的适应值较高的区域, 造成计算资源的不必要浪费.

本文研究多气味源定位问题, 提出基于多微粒群优化的机器人气味源定位方法. 该方法将机器人抽象为一个微粒, 机器人所带传感器测得的气味浓度作为相应微粒的适应值, 并采用改进多种群微粒群优化方法引导机器人同时定位多个气味源. 相比已有文献, 本文主要工作如下: (1) 采用多种群策略, 不同的子群定位不同的气味源; (2) 通过合并相似的子群, 以及降低微粒在已搜索区域的适应值, 保证微粒群定位尽可能多的气味源; (3) 针对烟羽动态变化的情况, 以概率选择子群的全局极值, 增加整个微粒群的多样性.

2 提出的方法

本节给出基于多微粒群优化的机器人气味源定位方法. 该方法将机器人抽象为一个微粒, 机器人所带传

感器测得的气味浓度作为相应微粒的适应值; 将邻近的微粒组成一个子群, 不同的子群定位不同的气味源; 并通过合并相似的子群, 降低微粒在已搜索区域的适应值, 使得微粒群定位尽可能多的气味源. 此外, 当气味源所在的环境变化时, 采用固定概率选择当代极值作为子群的全局极值, 以增加整个微粒群的多样性.

2.1 子群形成

假定环境中存在 N_s 个气味源, N_r 个机器人用于定位这些气味源, 机器人之间可以相互通信. 为尽快找到这些气味源, 将 N_r 个机器人划分为若干子群, 且不同的子群用于定位不同的气味源. 起初, 微粒为了发现烟羽, 在整个空间中自由运动. 为便于阐述, 称不属于任何子群的微粒为游离微粒; 相反, 属于某个子群的微粒为归属微粒. 当某游离微粒发现烟羽, 也即测得的气味浓度大于设定的阈值时, 通知其最近的若干个游离微粒, 由这些微粒形成一个子群. 该子群的所有微粒进行烟羽跟踪, 依据传统的方法更新微粒的速度和位置.

当机器人足够多, 且气味源个数已知时, 将所有机器人等分为 N_s 个子群, 可以显著提高气味源的定位效率. 但是, 在很多情况下, 需要定位的气味源个数往往是未知的, 此时, 采用合适的方法, 确定子群的规模十分重要. 为了尽快找到气味源, 各子群的规模不能太小; 但是, 子群的规模太大, 微粒之间又会变得拥挤. 鉴于此, 本文的子群规模在某一区间随机选取. 记子群规模的下限和上限分别为 \underline{m} 和 \bar{m} , 那么, 所有子群的规模为 $[\underline{m}, \bar{m}]$ 中的随机整数.

取 $\underline{m} = \bar{m} = 5$, 某子群的形成过程如图 1 所示, 其中, “空心圆”表示发现烟羽的微粒 x_i , “实心圆”表示子群包含的微粒, “菱形”表示游离微粒. 一种特殊的情况是, 子群形成过程中, 有多个微粒与 x_i 的距离相等, 如微粒 1 和 2, 此时, 任选其一, 如微粒 2, 作为归属微粒.




图1 子群形成

2.2 子群合并

在定位气味源的过程中, 一种可能的情况是, 多个子群在相同的区域搜索. 此时, 这些子群的位置比较接近, 称为相似子群. 为了让更多的微粒用于定位其他气味源, 需要通过合并子群来减少相似子群的规模.

以两子群的空间距离刻画其相似程度, 当 t 时刻两子群的空间距离小于某阈值时, 称这两个子群是相似的, 需要对其合并. 记两子群分别为 S_i 和 S_j , 其该时刻

的全局极值点分别为 $P_{i,g}(t)$ 和 $P_{j,g}(t)$, r_1 为反映子群相似性的阈值. 当 $\|P_{i,g}(t) - P_{j,g}(t)\| < 2r_1$ 时 ($\|\cdot\|$ 为向量范数), 采用如下策略合并这两个子群, 并记合并后的子群为 S_m : (1) 计算 $P_{i,g}(t)$ 和 $P_{j,g}(t)$ 的适应值, 记为 $f(P_{i,g}(t))$ 和 $f(P_{j,g}(t))$, 如果 $f(P_{i,g}(t)) \geq f(P_{j,g}(t))$, 选择 $P_{i,g}(t)$ 作为合并后子群的全局极值, 记为 $P_{m,g}(t)$; 否则, $P_{m,g}(t)$ 取为 $P_{j,g}(t)$; (2) 对于 $\forall x_i \in S_i$ 和 $\forall x_j \in S_j$, 计算与 $P_{m,g}(t)$ 的距离, 并选择距 $P_{m,g}(t)$ 最近的 $|S_m| - 1$ 个微粒 (不含 $P_{m,g}(t)$ 自身), 形成合并后的子群, 其中, $|S_m|$ 表示 S_m 的规模, 且 $|S_m| = \max\{|S_i|, |S_j|\}$; (3) 初始化剩余微粒的速度和位置, 并使其重新成为游离微粒.

以 $f(P_{i,g}(t)) < f(P_{j,g}(t))$ 为例, 图 2 给出了两子群的合并过程, 图中, “圆”、“菱形”, 以及“矩形”分别为 S_i 、 S_j , 以及 S_m 的微粒.




图2 子群合并

2.3 微粒适应值调整

为了使微粒群定位尽可能多的气味源, 需要调整处于已搜索区域微粒的适应值, 准确地讲, 降低该区域微粒的适应值, 使得这些微粒能够远离已搜索区域.

如果某子群的全局极值连续 T_0 代没有变化, 那么, 认为该子群已经收敛, 并记所有已收敛子群全局极值的集合为 P^c . 根据传感器测得的气味浓度, 计算微粒 x_i 的适应值 $f(x_i)$ 后, 进一步计算 x_i 与 P^c 的距离, 记为 $\|x_i - P^c\|$, 它是 x_i 与 P^c 的元素距离的最小值, 那么, 可以通过式(1)得到 x_i 调整后的适应值, 记为 $f'(x_i)$:

$$f'(x_i) = \begin{cases} f(x_i) - \alpha \frac{r_2 - \|x_i - P^c\|}{r_2}, & \|x_i - P^c\| \leq r_2 \\ f(x_i), & \text{其他} \end{cases} \quad (1)$$

式中, α 为调整系数, r_2 为适应值调整阈值.

需要指出的是, 在定位气味源过程中, 不同子群的进化是不均衡的, 使得收敛的时刻也不同. 当某子群已经收敛, 其它子群可能仍在进化. 此时, 由于环境中还可能存在未被定位的气味源, 因此, 需要初始化这些已收敛的子群, 使其包含的微粒重新成为游离的, 以继续定位其他的气味源.

2.4 微粒更新

本文采用文献[15]所提公式更新微粒的速度和位置. 相对传统微粒更新公式, 对于一个子群 S_i , 微粒跟

踪气味源时, 采用下式动态调整用于微粒 x_i 更新的学习因子:

$$\begin{cases} c_1 = c_0 \frac{\alpha_2}{\alpha_1 + \alpha_2} \\ c_2 = c_0 - c_1 \end{cases} \quad (2)$$

式中, c_0 为常数, 本文取 4, α_1 和 α_2 分别是 $P_{i,p}(t) - x_i$ 和 $P_{i,g}(t) - x_i$ 与反风向的夹角. 其中, $P_{i,p}(t)$ 、 $P_{i,g}(t)$ 分别为子群 S_i 的个体极值点和全局极值点.

2.5 子群全局极值点更新

需要说明的是, 上述策略仅适用于气味源所在的环境变化较小的情况, 此时, 将该环境近似为静态的. 如果进风口的风向发生变化, 那么, 气味源所在的环境也将改变. 为便于分析, 本文假定环境从一个状态变化为另一状态是瞬间完成的.

当气味源所在的环境变化时, 微粒前一时刻的全局极值点和个体极值点将难以指导微粒的后续进化, 甚至会误导整个子群的进化方向. 为此, 需要采用新的策略, 选择子群的全局极值点.

鉴于子群的当代极值点能够反映最新的气味源信息, 因此, 依一定的概率选择子群的当代极值点, 作为子群的全局极值点, 是非常必要的. 记子群 S_i 的当代极值点为 $P_{i,c}(t)$, 那么, $P_{i,c}(t) = \arg \max_{j=1,2,\dots,|S_i|} f(x_j(t))$, S_i 的当代极值为 $f(P_{i,c}(t))$. 若仅选择 $P_{i,g}(t-1)$ 作为 S_i 的当代全局极值点, 那么, S_i 的微粒更新将依赖于 $P_{i,g}(t-1)$, 不能反映环境变化对微粒浓度的影响; 若仅选择 $P_{i,c}(t)$ 作为 S_i 的当代全局极值点, 那么, S_i 的微粒更新将不能很好地利用已有微粒的浓度信息. 鉴于此, 当环境变化时, 依一定的概率, 记为 $\delta_{i,c}(t)$, 选择 $P_{i,c}(t)$ 作为 S_i 当代的全局极值点. 尽管有多种方法确定 $\delta_{i,c}(t)$, 本文给出的 $\delta_{i,c}(t)$ 表示为:

$$\delta_{i,c}(t) = \frac{f(P_{i,c}(t))}{f(P_{i,c}(t)) + f(P_{i,g}(t-1))}$$

基于此, S_i 的全局极值点更新如下:

$$P_{i,g}(t) = \begin{cases} P_{i,c}(t), & \text{rand} < \delta_{i,c}(t) \\ P_{i,g}(t-1), & \text{否则} \end{cases} \quad (3)$$

式中, rand 为 $[0,1]$ 之间的随机数.

由式(3)可知, S_i 能够在 $P_{i,g}(t-1)$ 与 $P_{i,c}(t)$ 之间选择合适的全局极值点. 这样, 既利用了 S_i 的历史信息, 又利用了 S_i 的当前信息, 有利于增加种群的多样性, 以克服环境变化对子群进化的不利影响.

2.6 算法步骤

本文提出的基于多微粒群优化的机器人气味源定位方法的步骤如下:

步骤 1 在环境中初始化微粒群;

步骤 2 游离微粒在环境中随机移动, 如果某微粒

发现烟羽,那么,由 2.1 节的方法形成子群,其包含的微粒跟踪烟羽;

步骤 3 对于烟羽跟踪子群,执行如下步骤:

步骤 3.1 根据气味浓度,计算微粒的适应值;

步骤 3.2 由 2.3 节的方法调整微粒的适应值;

步骤 3.3 若气味源所在的环境变化,由 2.5 节的方法更新子群全局极值点;

步骤 3.4 由 2.4 节的方法更新微粒的速度和位置;

步骤 3.5 判断子群是否相似,若是,由 2.2 节的方法合并子群;

步骤 3.6 判断子群是否收敛,若连续 T_0 代,子群的全局极值不变,则认为该子群收敛,输出该子群的全局极值点;若否,转步骤 3.1;

步骤 3.7 重新初始化子群.

步骤 4 判断算法是否达到规定最大迭代次数 T_{\max} ,若是,终止算法,输出结果;否则,转步骤 2.

3 性能分析

本节分析子群合并与适应值调整对算法性能的影响.不妨设环境中 N_s 个气味源,由这些气味源形成的烟羽包含 N_o 个浓度极值点.当然,这 N_s 个气味源也是浓度的极值点.为了便于分析,假设整个微粒群被划分成 N 个子群,且这些子群同时进化,并收敛到浓度极值点.

如果 $N_o \leq N$,那么,只要将整个微粒群分割成若干子群,就有可能找到所有的浓度极值点,从而定位所有的气味源.这样一来,就不能体现本文提出的子群合并和微粒适应值调整策略对提高算法性能的作用.鉴于此,这里仅考虑 $N_o > N$ 的情况.

3.1 子群合并

当不采用子群合并策略时,这 N 个子群可能仅找到一个浓度极值点,也可能找到 2 个浓度极值点,……,依此类推,还可能找到 N 个浓度极值点.但是,找到的浓度极值点个数不可能大于 N .

现在考虑这 N 个子群找到 k 个浓度极值点的概率.由于这些子群找到 1 个浓度极值点,可能的子群组合数为 C_N^1 ,找到 2 个浓度极值点,可能的子群组合数为 C_N^2 ,……,依此类推,找到 N 个浓度极值点,可能的子群组合数为 C_N^N ,那么,它们找到 k 个浓度极值点的概率

为 $\frac{C_N^k}{\sum_{j=1}^N C_N^j}$.相应的,这些子群找到的浓度极值点个数的期望值为:

$$\sum_{k=1}^N (k \cdot \frac{C_N^k}{\sum_{j=1}^N C_N^j}) = \frac{1}{2^N - 1} \sum_{k=1}^N k \cdot C_N^k = N \cdot \frac{2^{N-1}}{2^N - 1}$$

当采用子群合并策略时,由于不同的子群寻找不同的浓度极值点,因此, N 个子群找到的浓度极值点个数为 N .

只要对整个微粒群分割,均有 $N \geq 2$,此时, $2^{N-1} < 2^N - 1$,那么, $N \cdot \frac{2^{N-1}}{2^N - 1} < N$.这说明,采用本文提出的子群合并策略,可以找到更多的浓度极值点,进而定位更多的气味源.

3.2 微粒适应值调整

当不采用微粒适应值调整策略时,每一个子群可能在被搜索的区域重复搜索,即使找到了某一浓度极值点,也不会继续搜索其他的浓度极值点.现在考虑某一浓度极值点被找到的概率.由于 N 个子群搜索不同的浓度极值点,一次微粒群划分,某浓度极值点被找到的概率为 $\frac{N}{N_o}$,那么,没有被找到的概率为 $1 - \frac{N}{N_o}$.微粒群被划分 n 次以后,某浓度极值点没有被找到的概率为 $(1 - \frac{N}{N_o})^n$.

当采用本文提出的微粒适应值调整策略时,对于已经找到某浓度极值点的子群,其归属微粒的适应值将随着与该浓度极值点距离的减小而降低,这使得这些微粒能够远离该浓度极值点,从而寻找其他的浓度极值点.现在考虑此时某一浓度极值点被找到的概率.由于子群找到某一浓度极值点以后,将不再重复寻找该极值点,而转向寻找其他的极值点,因此,对浓度极值点而言,第一次微粒群划分,某浓度极值点被找到的概率为 $\frac{N}{N_o}$,那么,没有被找到的概率为 $1 - \frac{N}{N_o}$;第 2 次微粒群划分,某浓度极值点被找到的概率为 $\frac{N}{N_o - N}$,那么,没有被找到的概率为 $1 - \frac{N}{N_o - N}$;……;第 n 次子群划分,某浓度极值点被找到的概率为 $\frac{N}{N_o - (n-1)N}$,那么,没有被找到的概率为 $1 - \frac{N}{N_o - (n-1)N}$.到第 n 次子群划分为止,某浓度极值点仍没有被找到的概率为 $\prod_{k=1}^n$

$$(1 - \frac{N}{N_o - (k-1)N})$$

由于 $N_o - (k-1)N \leq N_o$,因此, $\forall k \geq 1, 1 - \frac{N}{N_o - (k-1)N} \leq 1 - \frac{N}{N_o}$,从而 $\prod_{k=1}^n (1 - \frac{N}{N_o - (k-1)N}) \leq (1 - \frac{N}{N_o})^n$.这说明,采用本文提出的微粒适应值调整策略,可以增加某浓度极值点被找到的概率,从而提高气味源定位的效率.

上述分析表明,本文提出的子群合并和微粒适应值调整策略,可以不同程度的提高气味源定位的效率.

3.3 算法的时间复杂度

本文算法与标准微粒群优化的主要区别在于增加了子群划分与合并算子.考虑最差的情况,即每个微粒可以组成一个子种群,此时,划分子群需要进行 $O(N_r^2)$ 数量级的比较运算;同样,在上述最差情况下,执行 1 次种子种群合并策略的计算代价也为 $O(N_r^2)$.考虑到标准微粒群优化算法的计算复杂度为 $O(N_r)$,因此,本文算法的时间复杂度为 $O(N_r^2)$,其中, N_r 为微粒数目.

4 实验

4.1 环境描述

为验证所提方法的有效性,采用 Fluent 软件生成 3 个典型的静态环境,这 3 个环境均为标准 $k-\epsilon$ 湍流模型, $C_\mu = 0.09$,且具有如下共同的基本信息: $10 \times 10\text{m}^2$ 的空间、2 个宽 2m 的进风口、1 个宽 2m 的出风口、2 个气味源,3 个障碍物.这 2 个进风口的位置分别为 $(0, [8, 10])$ 和 $(0, [0, 2])$,出风口的位置为 $(10, [0, 2])$.2 个

气味源的位置分别为 $(3, 8)$ 和 $(3, 2)$.图 3 给出环境的初始状态,图中,“箭头”表示风向,“黑色线”越密,风速越大,“in-I”和“in-II”分别表示进风口 I 和 II,“out”表示出风口,颜色越浅,气体浓度越高.

环境 I 中 2 个进风口的风速均为 1m/s ,进风口 I 的风向与 X 轴呈 -45° ,进风口 II 的风向与 X 轴呈 18.4° .有 2 个浓度均为 200ppm 的乙醇源,且形成的烟羽没有交织.该环境较简单,2 子群间的影响程度较小.若能很好地形成若干子群,即可可解决定位该环境的气味源.

环境 II 中 2 个进风口的风速均为 1m/s ,且风向与 X 轴平行.有 2 个浓度均为 200ppm 的乙醇源,但形成的烟羽存在交织.该环境较复杂,交织部分有很多局部极值点.此时,适应值调整将能减少机器人对局部极值点的重复搜索,从而提高定位效率.

环境 III 中 2 个进风口的风速均为 1m/s ,且风向与 X 轴平行.有 2 个浓度分别为 200ppm 和 20ppm 的乙醇源,其中,上侧的气味源浓度为 200ppm ,且两烟羽存在交织.该环境最复杂,不仅具有环境 II 的所有困难,还由于 2 个气味源浓度相差一个数量级,使得环境中可能存在浓度大于 20ppm 的局部极值点,从而下侧的浓度为 20ppm 的气味源不易被找到.

4.2 对比方法与性能指标

选择的比较方法包括:简单遗传算法(Simple Genetic Algorithm,SGA)^[16]、标准微粒群优化(SPSO)算法、WUI^[10]、MPSO^[14]和含有蒸发机制的多量子群优化(Multiple Quantum Swarm Optimization with Evaporation Mechanism, mQSOE)算法^[17],其中,前 4 种方法已被应用于气味源定位问题,而后 1 种方法能够很好地解决多模态优化问题.

为公平比较各方法的性能,所有方法设置相同的种群规模 $N_r = 24$;对于微粒群优化算法,选取相同的机器人最大运行速度 $V_{\max} = 3\text{m/s}$ 、惯性权重 $w = 0.6$ 、 $T_{\max} = 100$ 与 $T_0 = 5$;剩余相关参数均采用参考文献中的建议值,表 1 列出这些方法的参数设置.在 MPSO 中, R 为

排斥半径; Q 为带电微粒的电荷;带电微粒共 $\left\lceil \frac{N_r}{2} \right\rceil$ 个,其余微粒为中性微粒.在 mQSOE 中, r_{excl} 为排斥半径; r_{cloud} 为种群半径; ν 为蒸发因子.此外,不考虑气体传感器的响应与恢复时间.

表 1 参数设置

参数	
SGA	$p_c = 0.7, p_m = 0.01$
SPSO	$c_1 = c_2 = 2$
WUI	$c_1 = c_2 = 2$
MPSO	$c_1 = c_2 = 2, R = 1, Q = 1$ 库仑
mQSOE	$c_1 = c_2 = 2, r_{\text{excl}} = 2, r_{\text{cloud}} = 1, \nu = 1$
本文方法	$r_1 = r_2 = 1$

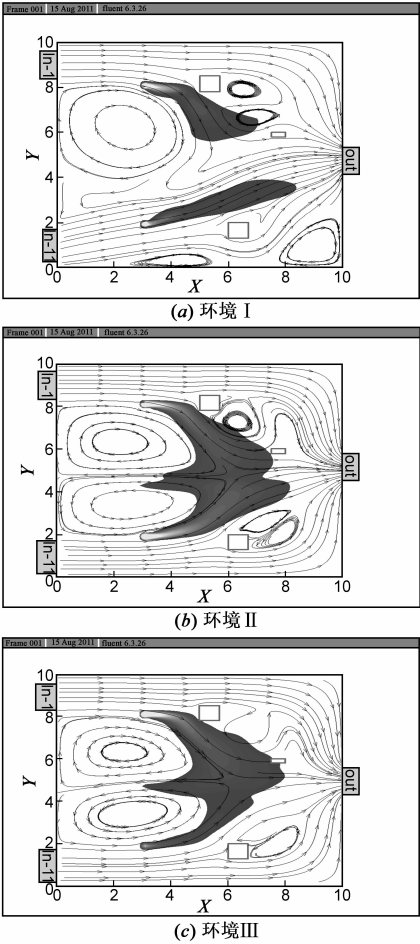


图3 环境的初始状态

采用如下 2 个指标,评价不同方法的性能:(1)成功率(Success Rate,SR),是某方法定位所有气味源的实验次数与总的实验次数的比,反映该方法成功定位气味源的能力;(2)耗时(Time Consumption,TC),是某方法定位所有气味源需要的时间,反映该方法定位气味源的效率.在终止代数内,如果某方法成功定位两个气味源,则认为该次实验是成功的;否则,为失败的.在上述两个性能指标中,成功率为第一指标,耗时仅起辅助作用.如果比较的两个方法的成功率相同,那么,耗时少的方法更优秀.

4.3 实验结果

(1)环境-I

针对环境 I 的气味源定位问题,独立运行每种方法 100 次,记录每次是否能够正确定位气味源 I 和 II,以及每次运行的耗时,并计算不同气味源定位的成功率和平均耗时,表 2 列出不同方法的定位成功率和平均耗时.

由表 2 可以看出,(1)本文方法同时定位 2 个气味源的成功率最高,为 100%,其次是 mQSOE 和 MPSO,成功率分别为 94% 和 91%,但是,SGA、SPSO 和 WUI 方法一次运行最多只能定位 1 个气味源,如 WUI 分别找到源 I 46 次,源 II 48 次,因此,这 3 种方法同时定位 2 个气味源的成功率均为 0;(2)本文方法同时定位 2 个气味源需要的时间为 0.47s,少于 mQSOE 的 0.56s 和 MPSO 的 0.75s.鉴于 SGA、SPSO 和 WUI 没有同时定位 2 个气味源,这里没有计算它们的运行时间.这说明,与其他 5 种方法相比,本文方法花最少的时间,能以最高的成功率,同时定位环境 I 的 2 个气味源.

表 2 不同方法的定位成功率和耗时(环境 I)

	定位源 I 的 成功率(%)	定位源 II 的 成功率(%)	同时定位源 I 和 II 的成功率(%)	耗时 (s)
SGA	40	42	0	
SPSO	45	46	0	
WUI	46	48	0	
MPSO	94	93	91	0.75
mQSOE	97	96	94	0.56
本文方法	100	100	100	0.47

(2)环境-II

对于环境 II 的气味源定位问题,按照与环境 I 相同的方法,可以得到不同方法的定位成功率和平均耗时,如表 3 所列.

由表 3 可知,(1)本文方法以 100% 的成功率同时定位了 2 个气味源,mQSOE 和 MPSO 的定位成功率次之,分别是 86% 和 79%,与环境 I 相同,SGA、SPSO 和 WUI

同时定位 2 个气味源的成功率仍为 0;此外,这 3 种方法定位气味源 I 或 II 的成功率最多仅为 41%;(2)与 MPSO 和 mQSOE 的耗时(分别为 0.84s 和 0.65s)相比,本文方法的耗时较少,仅为 0.56s.

表 3 不同方法的定位成功率和耗时(环境 II)

	定位源 I 的 成功率(%)	定位源 II 的 成功率(%)	同时定位源 I 和 II 的成功率(%)	耗时 (s)
SGA	35	14	0	
SPSO	40	15	0	
WUI	42	18	0	
MPSO	85	59	52	0.97
mQSOE	90	65	58	0.79
本文方法	100	96	96	0.67

由表 2 和 3 可知,(1)尽管环境 I 和 II 都有 2 个气味源,但是,mQSOE 和 MPSO 同时定位这 2 个气味源的成功率不同,mQSOE 由环境 I 的 94% 下降为环境 II 的 86%,MPSO 由环境 I 的 91% 下降为环境 II 的 79%;此外,SGA、SPSO 和 WUI 定位环境 II 的气味源 I 或 II 的成功率也比环境 I 下降,由环境 I 的最大值 48% 下降为环境 II 的 41%.主要原因在于:环境 II 的 2 个烟羽存在交织,产生较多的气味浓度局部极值点,增加了陷入局部极值的概率;(2)尽管环境 II 的烟羽存在交织,但是,与环境 I 一样,本文方法仍以 100% 的成功率定位 2 个气味源;(3)烟羽存在交织,使得 mQSOE、MPSO 和本文方法定位气味源的耗时均比环境 I 增加.

实验结果说明,对于像环境 II 的烟羽存在交织的较复杂环境气味源定位问题,与其他 5 种方法相比,本文方法花最少的时间,能以最高的成功率,同时定位 2 个气味源.

(3)环境-III

对于环境 III 的气味源定位问题,按照与环境 I 和 II 相同的方法,可以得到不同方法的定位成功率和平均耗时,如表 4 所列.

由表 4 可以看出,(1)虽然环境 III 很复杂,不但烟羽存在交织,而且不同气味源的浓度不同,但是,本文方法仍以很高的成功率(96%)同时定位了 2 个气味源;相比之下,mQSOE 和 MPSO 仅以 58% 和 52% 的成功率同时定位这 2 个气味源,而 SGA、SPSO 和 WUI 这 3 种方法仍然不能同时定位这 2 个气味源;这 3 种方法定位气味源 I 或 II 的最大成功率依然很低,特别是气味源 II,仅为 18%.这意味着,烟羽交织产生的气味浓度局部极值点,影响了所有算法的性能,特别是,对 SGA、SPSO 和 WUI 的性能影响更大;(2)与 mQSOE 和 MPSO 的耗时(分别为 0.79s 和 0.97s)相比,本文方法的耗时较少,仅

为 0.67s.

表 4 不同方法的定位成功率和耗时(环境 III)

	定位源 I 的成功率(%)	定位源 II 的成功率(%)	同时定位源 I 和 II 的成功率(%)	耗时(s)
SGA	36	33	0	
SPSO	38	36	0	
WUI	41	40	0	
MPSO	87	82	79	0.84
mQSOE	91	89	86	0.65
本文方法	100	100	100	0.56

由表 3 和 4 可知,(1)尽管环境 II 和 III 的烟羽都存在交织,但是,mQSOE 和 MPSO 同时找到 2 个气味源的成功率却相差很大,mQSOE 由环境 II 的 86% 急剧下降为环境 III 的 58%,MPSO 由环境 II 的 79% 急剧下降为环境 III 的 52%;SGA、SPSO 和 WUI 定位气味源 II 的最大成功率也由环境 II 的 40% 下降为环境 III 的 18%. 这说明,气味源的浓度相差很大,会显著增大陷入局部极值的概率;(2)本文方法定位气味源的成功率由环境 II 的 100% 下降为 96%,说明,本文方法定位气味源的性能受浓度的影响不大.

实验结果说明,即使对于像环境 III 这样的存在烟羽交织,且浓度相差很大的复杂环境气味源定位问题,与其他 5 种方法相比,本文方法在定位成功率和耗时等方面也是最优的,且受浓度的影响最小.

4.4 不同策略对本文方法性能的影响

本文使用了多种策略,包括:子群形成、子群合并、微粒适应值调整、属于收敛子群微粒的初始化,以及基于风趋向性的学习因子动态调整等.为了说明这些策略的有效性,对比具有如下策略的基于微粒群优化的机器人气味源定位方法:(1)标准微粒群优化方法,此时,运行一次仅能定位 1 个气味源,简称方法 1;(2)采用本文提出的子群形成策略,将整个微粒群划分为若干子群,多个子群同时定位气味源,此时,运行一次可以定位多个气味源,简称方法 2;(3)在方法 2 的基础上,增加子群合并策略,简称方法 3;(4)在方法 3 的基础上,增加微粒适应值调整策略,简称方法 4;(5)在方法 4 的基础上,增加属于收敛子群微粒的初始化策略,简称方法 5;(6)在方法 5 的基础上,增加基于风趋向性的学习因子动态调整策略,即本文算法.

容易知道,通过方法 2 与方法 1 的对比,可以说明子群形成策略的有效性;通过方法 3 与方法 2 的对比,可以说明子群合并策略的有效性,……,以此类推,可以说明本文所提所有策略的有效性.

采用上述方法,分别定位环境 I、II,以及 III 的气味

源,每种方法在每种环境下运行 100 次,记录每次是否能够同时定位气味源 I 和 II,以及每次运行的耗时,并计算气味源定位的成功率和平均耗时,表 5 列出不同方法的定位成功率和平均耗时.

表 5 不同策略的定位成功率和耗时

	环境 I		环境 II		环境 III	
	成功率(%)	耗时(s)	成功率(%)	耗时(s)	成功率(%)	耗时(s)
方法 1	0		0		0	
方法 2	85	0.78	76	0.90	71	1.08
方法 3	87	0.66	82	0.77	77	0.93
方法 4	91	0.59	86	0.69	80	0.84
方法 5	97	0.52	93	0.61	88	0.76
本文方法	100	0.47	100	0.56	96	0.67

由表 5 可以看出,(1)对于任一环境,方法 1,即标准微粒群优化方法,不能同时定位 2 个气味源;(2)对于相同的环境,随着本文所提策略的加入,同时定位 2 个气味源的成功率不断提高,耗时不断减少,如环境 I 和 II 的定位成功率分别从 85% 和 76% 增加到 100%,环境 III 从 71% 增加到 96%;环境 I、II,以及 III 的耗时分别从 0.78s、0.90s,以及 1.08s 减少到 0.47s、0.56s,以及 0.67s;(3)对于相同的方法,随着环境复杂度的增加,同时定位 2 个气味源的成功率不断降低,耗时不断增加,如方法 2、3、4、5,以及本文方法的定位成功率分别从 85%、87%、91%、97%,以及 100% 下降到 71%、77%、80%、88%,以及 96%;耗时分别从 0.78s、0.66s、0.59s、0.52s,以及 0.47s 增加到 1.08s、0.93s、0.84s、0.76s,以及 0.67s.这说明,本文提出的各种策略均有助于提高气味源定位的成功率,并减少定位气味源所需要的时间.

4.5 环境变化的气味源定位

本节及下两节将本文所提方法应用于环境变化的气味源定位.为验证所提方法的有效性,采用 Fluent 软件生成 1 个动态环境,同样选择标准的 $k-\epsilon$ 湍流模型,参数同 4.1 节.当运行时间为 $t = 0.2s$ 时,实验环境由图 4(a)快速变为图 4(b);当 $t = 0.4s$ 时,实验环境再次快速变为图 4(c).在所有实验环境下,风速均不改变,但风向改变.




图 4 环境变化

当 $t = 0.2s$ 和 $0.4s$ 时,将 2.5 节所提的全局极值点选择策略加入本文的方法.独立运行每种方法 100 次,

记录每次是否能够正确定位气味源 I 和 II,以及每次运行的耗时,并计算不同气味源定位的成功率和平均耗时,表 6 列出不同方法的定位成功率和平均耗时.

表 6 不同方法的定位成功率和耗时(环境变化)

	定位源 I 的成功率(%)	定位源 II 的成功率(%)	同时定位源 I 和 II 的成功率(%)	耗时(s)
SGA	32	34	0	
SPSO	36	37	0	
WUI	40	42	0	
MPSO	89	84	80	0.91
mQSOE	97	95	93	0.78
本文方法	100	99	99	0.60

由表 6 可知,(1)本文方法以 99% 的成功率同时定位了 2 个气味源,mQSOE 和 MPSO 的定位成功率次之,分别是 93% 和 80%,与环境 I 相同,SGA、SPSO 和 WUI 同时定位 2 个气味源的成功率仍为 0;此外,这 3 种方法定位气味源 I 或 II 的成功率最多仅为 42%;(2)与 MPSO 和 mQSOE 的耗时(分别为 0.91s 和 0.78s)相比,本文方法的耗时较少,仅为 0.60s.

由表 2 和 6 可知,(1)尽管环境 I 和 II 都有气味浓度相同的 2 个气味源,但是,mQSOE 和 MPSO 同时定位这 2 个气味源的成功率有所降低,mQSOE 由环境 I 的 94% 下降为环境变化的 93%,MPSO 由环境 I 的 90% 下降为环境变化的 80%,环境变化对 mQSOE 的影响程度远小于 MPSO;此外,SGA、SPSO 和 WUI 定位环境变化的气味源 I 或 II 的成功率也比环境 I 下降,由环境 I 的最大值 48% 下降为环境变化的 42%. 主要原因在于:烟羽摆动使得各方法原有的个体极值与全局极值失去了作用,从而在定位过程中误导了机器人,同时,由于 mQSOE 的蒸发机制能够很好地解决动态优化问题,因此,在环境变化下该方法受到的影响较小;(2)尽管烟羽摆动,但是,本文方法仍以 99% 的成功率定位 2 个气味源;(3)烟羽摆动,使得 mQSOE、MPSO 和本文方法定位气味源的耗时均比环境 I 增加.

实验结果说明,对于环境变化的气味源定位问题,与其它 5 种方法相比,本文方法花最少的时间,能以最高的成功率,同时定位 2 个气味源.

4.6 子群全局极值点更新策略对算法性能的影响

为解决环境变化的气味源定位问题,增加了子群全局极值点更新策略.为了说明该策略的有效性,对比是否具有该策略的基于微粒群优化的机器人气味源定位方法.表 7 列出了相应策略的定位成功率与耗时.

由表 7 可以看出,若不使用 2.5 节提出的全局极值更新策略,那么,定位 2 个气味源的成功率仅有 93%,耗时为 0.82s.若使用该策略,那么,定位 2 个气味源的成功率增加为 99%,而耗时减少为 0.60s.可见,全局极

值更新策略的加入能够提高所提方法的整体性能.

表 7 子群全局极值更新策略对定位成功率和耗时的影响

	定位源 I 的成功率(%)	定位源 II 的成功率(%)	同时定位源 I 和 II 的成功率(%)	耗时(s)
无更新策略	95	96	93	0.82
有更新策略	100	99	99	0.60

需要指出的是,与静态环境下的气味源定位相比,当环境变化时,所提方法的整体性能有所下降,这从表 2 和表 7 的相应数据可以看出,主要原因在于环境的变化.

4.7 环境变化的定位过程

为了反映环境变化时所提方法定位气味源的性能,图 5 给出环境变化时,WUI、MPSO、mQSOE,以及本文

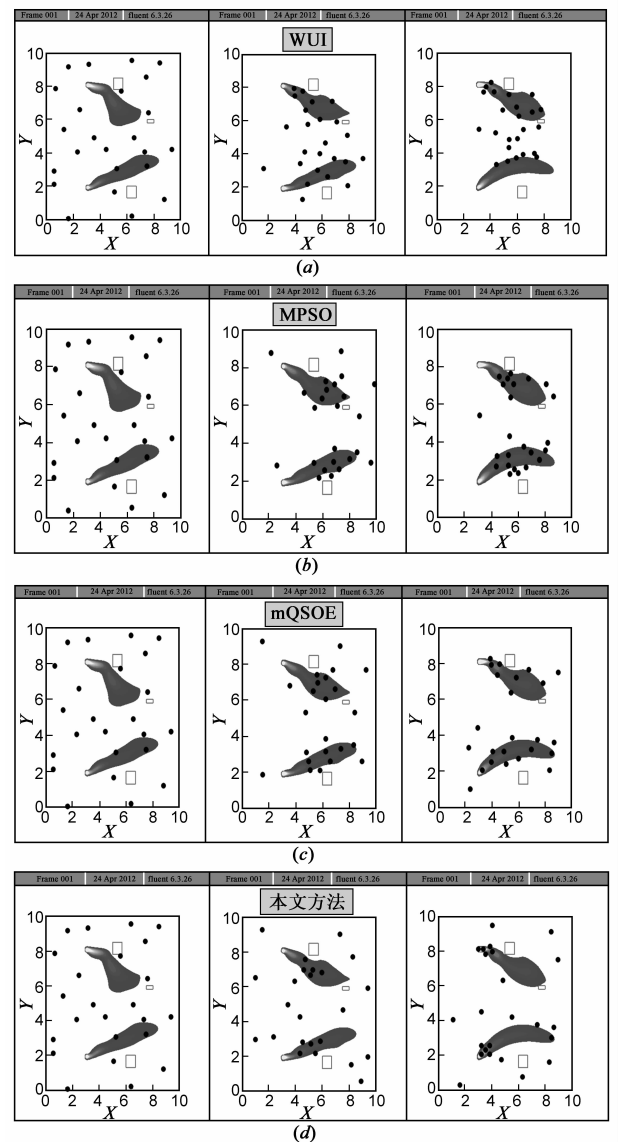


图5 气味源定位过程(环境变化)

方法的气味源定位过程. 为了公平比较, 每次运行时, 所有方法均采用相同的初始位置.

图 5 中, “圆”表示机器人. 由该图可以看出, 由于 WUI 没有分组策略, 因此, 所有的机器人只能同时定位一个气味源, 且两个气味烟羽同时影响机器人的移动方向, 使得机器人在两个气味源之间反复移动; MPSO 不能很好地应对环境变化的气味源定位, 虽然实验中烟羽摆动幅度较小, 但是, 仍然大大影响了 MPSO 的定位性能; 当 $t = 0.60\text{s}$ 时, 本文方法已经成功定位了 2 个气味源; 而 mQSOE 仅成功定位了气味源 II, 同时, 部分机器人也非常接近气味源 I.

5 结束语

本文研究多气味源定位问题, 提出了基于多微粒群优化的机器人气味源定位方法. 利用 Fluent 软件模拟 3 个典型的静态烟羽环境与 1 个动态环境, 并将所提方法应用于这些环境的气味源定位. 与 5 种已有方法的比较结果表明, 所提方法能够高效地定位多气味源. 值得注意的是, 本文的实验环境均由 Fluent 构建, 与实际环境有所区别. 因此, 在真实实验环境下验证所提方法, 是我们需要进一步研究的问题.

参考文献

- [1] Kowadlo G, Russell R. Robot odor localization: A taxonomy and survey[J]. The International Journal of Robotics Research, 2008, 27(8): 869 – 894.
- [2] Russell R A. Chemical source location and the RoboMole project [A]. Proceedings of the Australasian Conference on Robotics and Automation[C]. USA, 2003. 1 – 6.
- [3] Holland O, Melhuish C. Some adaptive movements of animats with single symmetrical sensor[A]. Proceedings of the Fourth International Conference on Simulation of Adaptive Behaviour [C]. Cambridge: MIT Press, 1996. 55 – 64.
- [4] Russell R. Locating underground chemical source by tracking chemical gradients in 3 demensions [A]. Proceedings of the 2004 IEEE/RSJ International Conference on Intelligent Robots and System[C]. USA: IEEE Press, 2004. 325 – 330.
- [5] 李俊彩, 孟庆浩, 梁琼. 基于进化梯度搜索的机器人主动嗅觉仿真研究[J]. 机器人, 2007, 29(3): 234 – 238.
Li Jun-cai, Meng Qing-hao, Liang Qiong. Simulation study on robot active olfaction based on evolutionary gradient search[J]. ROBOT, 2007, 29(3): 234 – 238. (in Chinese)
- [6] 黄庆成, 罗荣华. 一种多移动机器人主动协同定位方法的研究[J]. 电子学报, 2010, 38(11): 2644 – 2648.

- HUANG Qing-cheng, LUO Rong-hua. An active cooperative localization method for mobile robots [J]. Acta Electronica Sinica, 2010, 38(11): 2644 – 2648. (in Chinese)
- [7] Hayes A T. Self Organized Robotic System Design and Autonomous Odor Localization [D]. California Institute of Technology, 2002.
- [8] Kennedy J, Eberhart R C. Particle swarm optimization [A]. Proceedings of IEEE International Conference on Neural Networks [C]. USA: IEEE Press, 1995. 1942 – 1948.
- [9] Jatmiko W, et al. Distributed Odor Source Localization in Dynamic Environment [M]. Sensors, 2005. 254 – 257.
- [10] Jatmiko W, Sekiyama K. A PSO-based mobile robot for odour source localization in dynamic advection-diffusion with obstacle: theory, simulation and measurement [J]. IEEE Computational Intelligence Magazine, 2007, 2(2): 37 – 51.
- [11] GONG Dun-Wei, QI Cheng-Liang, ZHANG Yong, LI Ming. Modified particle swarm optimization for odor source localization of multi-robot [A]. Proceedings of IEEE Congress on Evolutionary Computation (CEC) [C]. USA: IEEE Press, 2011. 130 – 136.
- [12] Marques L, Nunes U, De Almeida A T. Particle swarm-based olfactory guided search [J]. Autonomous Robots, 2006, 20(3): 277 – 287.
- [13] 骆德汉, 邹宇华, 庄家俊. 基于修正蚁群算法的多机器人气味源定位策略研究[J]. 机器人, 2008, 30(6): 536 – 541.
Luo De-han, Zou Yu-hua, Zhuang Jia-jun. Multi-robot odor source localization strategy based on a modified ant colony algorithm [J]. ROBOT, 2008, 30(6): 536 – 541. (in Chinese)
- [14] Jatmiko W, et al. Localizing multiple odor sources in dynamic environment using ranged subgroup PSO with flow of wind based on open dynamic engine library [A]. International Symposium on Micro-NanoMechatronics and Human Science (MHS) [C]. USA: IEEE Press, 2009. 602 – 607.
- [15] 张勇, 巩敦卫, 任永强等. 用于约束优化的简洁多目标微粒群优化算法[J]. 电子学报, 2011, 39(6): 1436 – 1440.
Zhang Yong, Gong Dun-wei, Ren Yong-qiang, et al. Bare-bones multi-objective particle swarm optimizer for constrained optimization problems [J]. Acta Electronica Sinica, 2011, 39(6): 1436 – 1440. (in Chinese)
- [16] Goldberg D E. Genetic Algorithms In Search, Optimization and Machine Learning [M]. Addison-Wseley, Reading, Massachusetts, 1989.
- [17] Fernandez-Marquez J, Arcos J. An evaporation mechanism for dynamic and noisy multimodal optimization [A]. Proceedings of the Tenth Genetic and Evolutionary Computation Conference (GECCO) [C]. USA: ACM, 2009. 17 – 24.

作者简介




巩敦卫 男.1970 年 3 月出生,江苏铜山人.教授、博导,主要研究方向:智能控制、软件测试、交互式进化算法等.
E-mail: dwgong@vip.163.com



张 勇 男.1979 年 9 月出生,山东莱芜人.副教授、博士,主要研究方向:智能控制、进化计算、机器人协作等.



戚成亮 男.1986 年 3 月出生,江苏徐州人.硕士,主要研究方向:群体智能.
E-mail: qi_liang76@yahoo.com.cn



胡 滢 女.1988 年 4 月出生,安徽黄山人.硕士研究生,主要研究方向:智能控制.