

一种新的移动机器人全局定位算法

厉茂海, 洪炳熔, 蔡则苏

(哈尔滨工业大学计算机科学与技术学院, 黑龙江哈尔滨 150001)

摘 要: 粒子滤波器能够给出移动机器人全局定位非线性非高斯模型的近似解. 然而, 当新感知出现在先验概率的尾部或者与先验相比感知概率太尖时, 传统的粒子滤波器会退化导致定位失败. 本文提出了一种重要性采样跟中心差分滤波器 (central difference filter, CDF) 相结合的新算法, 并对测量更新步的加权粒子集应用基于 KD 树的加权期望最大 (weighted expectation maximization, WEM) 自适应聚类算法获得表示机器人位姿状态后验密度的高斯混合模型 (Gaussian mixture model, GMM). 实验结果表明, 新方法提高了定位准确率, 降低了计算复杂度.

关键词: 移动机器人; 全局定位; 粒子滤波器; 中心差分滤波器; 加权期望最大; 高斯混合模型

中图分类号: TP24 **文献标识码:** A **文章编号:** 0372-2112 (2006) 03-0553-06

A Novel Algorithm for Mobile Robot Global Localization

LIMao-hai HONG Bing-rong CAI Ze-su

(Dept. of Computer Science & Technology, Harbin Institute of Technology, Harbin, Heilongjiang 150001, China)

Abstract The particle filter can give the approximate solutions to the non-linear non-Gaussian model of mobile robot global localization. However, if the new measurements appear in the tail of the prior or if the likelihood is too peaked in comparison to the prior, the conventional particle filter can degenerate and make localization fail. We present a novel algorithm that combines an importance sampling with central difference filter (CDF). The posterior pose state density is represented by Gaussian mixture model (GMM) that is recovered from the weighted particle set of the measurement update step by means of a weighted expectation maximization (WEM) adaptive clustering algorithm, which based on the kd-trees. Experimental results show that this new approach has an improved localization accuracy and reduces computational complexity.

Key words mobile robot; global localization; particle filter; central difference filter (CDF); weighted expectation maximization (WEM); Gaussian mixture model (GMM)

1 引言

移动机器人定位是机器人领域中的一个基本问题, 可以分为: 位置跟踪和全局定位. 位置跟踪是指初始位置已知, 通过纠正里程计累积误差估计位姿. 而全局定位要求机器人能够在初始位置不确定的情况下, 通过具有噪声的传感器感知信息估计位姿. 因此全局定位更具有挑战性. 解决全局定位有许多方法: 多假设卡尔曼滤波器^[1], 马尔可夫定位^[2]和粒子滤波器 (particle filter, PF)^[3]方法等. PF 方法已经取得了很大成功, 已被应用到许多实际机器人系统中. 但传统 PF 有许多局限性: 一个是如果在正确状态附近没有足够的粒子会导致滤波器发散. 另一个是粒子经常快速收敛仅得到子最优结果. 怎样提高滤波器的准确性和

有效性, 并防止粒子发散和滤波器退化 (degeneracy) 是研究者一直关心的问题. 为了防止滤波器退化, 经常应用采样重要性重新采样 (sampling-importance resampling, SIR)^[4], 但它又导致了粒子的耗尽 (depletion) 问题. 为了使粒子更好的表示后验概率密度, Trun 提出了混合蒙特卡罗法^[5], 以及最近提出的基于自适应采样的方法^[6], 虽然提高了滤波器的有效性, 但也加重了计算负担.

本文提出了一种基于测量更新步的重要性采样跟产生提议分布的中心差分滤波器 (central difference filter, CDF) 相结合的新算法. 通过对测量更新步的加权粒子集应用基于 KD 树的加权期望最大 (Expectation Maximization, EM) 算法获得表示机器人位姿状态后验密度的高斯混合模型 (Gaussian mixture model, GMM), 并且自适应聚

类选择 GMM 的个数^[7-10]. 实际实验结果表明, 新方法提高了定位准确率, 降低了计算复杂度.

2 研究背景

2.1 贝叶斯滤波器

机器人定位就是应用具有噪声的传感器感知信息 $Z_t = \{z_t | t=1 \dots t\}$ 估计机器人隐式位姿状态 s_t 的最优化问题. 如图 1 所示, 具有初始分布 $p(s_0)$ 的状态 s_t 按照条件概率 $p(s_t |$

图 1 动态状态空间模型

s_{t-1}) 不断进化. 如果根据概率 $p(z_t | s_t)$ 产生的感知 z_t 独立于给定的状态 s_t 则该动态状态空间模型用非线性系统方程表示为:

$$s_t = F(s_{t-1}, u_t, \varepsilon_{t-1}) \quad (\text{运动方程}) \quad (1)$$

$$z_t = G(s_t, \eta_t) \quad (\text{感知方程}) \quad (2)$$

其中 ε_t 和 η_t 是噪声, 函数 $F(\cdot)$ 和 $G(\cdot)$ 分别描述状态传递概率 $p(s_t | s_{t-1})$ 和感知概率 $p(z_t | s_t)$, 系统输入 u_t 已知. 假设环境是马尔可夫的, 贝叶斯滤波器 (Bayesian filter) 递归计算后验概率密度 $p(s_t | Z_t)$ 分为两步:

预测 根据运动模型 $p(s_t | s_{t-1}, u_{t-1})$ 对上一时刻状态 s_{t-1} 和控制输入 u_{t-1} 预测当前状态 s_t :

$$p(s_t | Z_{t-1}) = \int p(s_t | s_{t-1}, u_{t-1}) p(s_{t-1} | Z_{t-1}) ds_{t-1} \quad (3)$$

更新 根据感知模型 $p(z_t | s_t)$ 更新获得新感知信息的当前状态 s_t :

$$p(s_t | Z_t) = p(z_t | s_t) p(s_t | Z_{t-1}) / p(z_t | Z_{t-1}) \quad (4)$$

2.2 粒子滤波器

粒子滤波器的核心思想就是用加权的粒子集 $\Psi_t = \{(s_t^i, w_t^i) | i=1 \dots N\}$ 表示后验概率 $p(s_t | Z_t)$, 其中 s_t^i 表示 t 时刻可能的机器人位姿状态, 权重 w_t^i 表示 s_t^i 的可信度. 因为后验概率是未知的, 因此我们不能直接对其进行采样, 通常我们用较容易采样的提议分布 $q(s_t | Z_t)$ 近似后验:

$$\hat{p}(s_t | Z_t) = \sum_{i=1}^N w_t^i \delta_{s_t^i}(ds_t) \quad (5)$$

提议分布除了用来采样外, 还用来计算粒子权重:

$$w_t^i = w_{t-1}^i p(z_t | s_t^i) p(s_t^i | s_{t-1}^i) / q(s_t^i | s_{t-1}^i, Z_t) \quad (6)$$

因此选择一个好的提议分布在粒子滤波器设计中非常重要. 传统方法是把传递先验 $p(s_t | s_{t-1})$ 作为提议分布. 然而 $p(s_t | s_{t-1})$ 并没有考虑最近的传感器感知信息 z_t , 如果感知概率比较尖 (传感器信息较为可靠时发生) 或者预测状态在后验分布的尾部 (状态预测不准确时发生), 则会引起严重的退化问题. 我们在第 3 节中提出了一种更好的产生提议分布的方法.

传统粒子滤波器应用顺序重要性采样 (sequential importance sampling, SIS), 会引起粒子退化. 因为随着循环

的运行, 一些粒子越来越重要, 规一化的权重逐渐趋向 1 而另一些权重趋向 0 这样大量低权重的粒子就被从粒子集里删掉了, 为了避免这种退化, 有研究者应用重要性采样重新采样 (sampling-importance resampling, SRS), 忽略低权重粒子, 对高权重粒子不断复制, 这种方法的一个极端情况是粒子集中仅包含一个特定的粒子和它的所有复制, 引起严重的粒子耗尽问题, 我们在第 4 节中提出了一种新方法.

3 中心差分滤波器设计提议分布

我们改进传递先验吸收当前感知, 对该优化的提议分布高斯近似:

$$q(s_t | s_{t-1}, Z_t) = N(s_t; \hat{x}_t^i, P_t^i), \quad i=1, 2, \dots, N \quad (8)$$

我们用基于 Sterling 插值公式的多项式近似来扩展非线性状态转换函数 $s_t = F(s_{t-1})$, 泰勒扩展的第一、二阶导数用中心差分代替:

$$\begin{aligned} s_t &\approx F(\bar{s}_{t-1}) + \Delta s_{t-1} F'(\bar{s}_{t-1}) + \frac{1}{2} \Delta s_{t-1}^2 F''(\bar{s}_{t-1}) + \dots \\ F'(\bar{s}_{t-1}) &= \{F(\bar{s}_{t-1} + h\Delta s_{t-1}) - F(\bar{s}_{t-1} - h\Delta s_{t-1})\} / 2h \quad (9) \\ F''(\bar{s}_{t-1}) &= \{F(\bar{s}_{t-1} + h\Delta s_{t-1}) + F(\bar{s}_{t-1} - h\Delta s_{t-1}) \\ &\quad - 2F(\bar{s}_{t-1})\} / h^2 \end{aligned}$$

该公式是 CDF 的基础, CDF 的结果集是从 s 先验统计提取的 $2L+1$ (L 是 s 维数) 个西格玛 (Sigma) 点:

$$\begin{aligned} \hat{x}_t^0 &= \hat{s}_t \\ w_t^0 &= (h^2 + L) / h^2 \\ \hat{x}_t^i &= \hat{s}_t + h \sqrt{P_t}, \quad i=1 \dots, L \\ w_t^i &= 1/2h^2, \quad i=1 \dots, 2L \\ \hat{x}_t^i &= \hat{s}_t - h \sqrt{P_t}, \quad i=L+1 \dots, 2L \end{aligned} \quad (10)$$

完整的 CDF 定义如下:

初始化: $\hat{s}_0 = E[s_0]$

$P_0 = E[(s_0 - \hat{s}_0)(s_0 - \hat{s}_0)^T]$

For $t=1 \dots$

Sigma 点计算:

$$x_{t-1} = [\hat{s}_{t-1} \quad \hat{s}_{t-1} + \gamma \sqrt{P_{t-1}} \quad \hat{s}_{t-1} - \gamma \sqrt{P_{t-1}}]$$

运动更新:

$$x_{t|t-1}^e = F(x_{t-1}, u_{t-1})$$

$$\hat{s}_t = \sum_{i=0}^{2L} w_t^i x_{t|t-1}^e$$

$$P_t^- = \sum_{i=0}^{2L} w_t^i [x_{t|t-1}^e - \hat{s}_t] [x_{t|t-1}^e - \hat{s}_t]^T + R^v$$

$$x_{t|t-1} = [\hat{s}_t^- \quad \hat{s}_t^- + \gamma \sqrt{P_t^-} \quad \hat{s}_t^- - \gamma \sqrt{P_t^-}]$$

$$Z_{t|t-1} = G(x_{t|t-1}),$$

$$\hat{z}_t = \sum_{i=0}^{2L} w_t^i Z_{t|t-1}$$

测量更新:

$$P_{z|t} = \sum_{i=0}^{2L} w_t^i [Z_{t|t-1} - \hat{z}_t] [Z_{t|t-1} - \hat{z}_t]^T + R^w$$

$$P_{s|t} = \sum_{i=0}^{2L} w_t^i [x_{t|t-1} - \hat{s}_t] [x_{t|t-1} - \hat{s}_t]^T$$

$$K_t = P_{s_t} P_{z_t}^{-1} \hat{s}_t = \hat{s}_t + K_t (z_t - \hat{z}_t)$$

$$P_t = P_t - K_t P_{z_t}^{-1} K_t^T$$

end for


其中 R^v 和 R^o 分别是处理和感知噪声协方差, $\{W_i\}$ 是权重集

因为 CDF 把当前感知信息吸收到状态估计中, 使粒子向高概率区域移动 (图 2), 因此减少了粒子的耗尽和滤波器的退化。这两者的结合称为中心差分粒子滤波器 (central difference particle filter, CDPF)。每个粒子的提议分布如下:

$$q(s_t^i | s_{t-1}^i, Z_t) = N(\bar{s}_t, P_t), \quad i = 1, \dots, N \quad (11)$$

其中状态 s 的平均值 \bar{s}_t 和协方差 P_t 根据 CDF 计算。尽管 CDPF 比传统的 PF 在估计性能上有很大的提高, 但它也加重了计算负担, 因为对后验状态分布中的每一个粒子运行 CDF 需要时间复杂度 $O(ML^2)$ (M 是感知维数)。为此我们对 CDPF 进一步改进提出了高斯混合模型的 CDPF (Gaussian Mixture Model Central Difference Particle Filter, GM-MCDPF), 它在不降低估计性能的前提下, 大大减少了 CDPF 的计算开销。

图 2 吸收当前感知, 先验分布粒子向高概率区域移动



4 高斯混合模型中心差分滤波器

GMMCDPF 应用 CDF 运动更新和产生提议分布, 并且应用 GMM 表示后验密度, 通过对加权的后验粒子集应用 EM 聚类算法产生 GMM, 减少了滤波器退化, 降低了计算开销。

4.1 高斯混合模型近似

任何概率分布 $p(x)$ 可以被 GMM 近似为 $p(x) \approx \sum_{g=1}^G \alpha_g^s N(\mu_g^s, P_g^s)$, 其中 G 是混合模型数, α_g^s 是混合权重。根据方程 1 和 2 假设先验密度 $p(s_{t-1} | Z_{t-1})$ 和系统噪声密度 $p(\varepsilon_{t-1})$, $p(\eta_t)$, 都用 GMM 表示, 则预测先验密度和更新的后验密度也可用 GMM 分别近似为:

$$p(s_t | Z_{t-1}) \approx \tilde{p}(s_t | Z_{t-1}) = \sum_{g'=1}^{G'} \alpha_{g'}^s N(\tilde{\mu}_{g'}^s, \tilde{P}_{g'}^s) \quad (12)$$

$$p(s_t | Z_t) \approx \tilde{p}(s_t | Z_t) = \sum_{g''=1}^{G''} \alpha_{g''}^s N(\mu_{g''}^s, P_{g''}^s)$$

其中 $G' = G \downarrow G'' = G' \downarrow$ (G 和 J 分别是状态, 移动噪声和感知噪声的 GMM 模型数)。高斯模型的平均值和协方差用 CDF 计算。混合权重更新过程见 4.3A。显然 GMM 的模型数在运动更新步从 G 增长到 G' , 在测量更新步从 G' 增长到 G'' 。总模型数随时间指数增长, 因此 4.3B 给出了聚类自适应选择模型数的方法。

4.2 加权期望最大自适应聚类算法

传统 PF 基于测量更新的重要性采样后, 输出 N 个加

权粒子, 为了防止粒子收敛过快, 加入重新采样保证粒子之间的差异, 然而, 当传感器信息较为可靠时, 引起感知概率分布较窄, 导致粒子集退化成仅含有同一个粒子的多个拷贝, 这种情况我们直接用 WEM (directWEM) 替换重新采样。否则也可以重新采样后再 EM (resample-then-EM) 方法。考虑到在结构化的室内环境中, 声纳数据较为可靠, 我们采用 directWEM 方法代替重新采样。GM-MCDPF 用 GMM 表示后验分布, 由于它内在的“核平滑 (kernel smoothing)”属性, 通过一个高斯核集 (Gaussian kernels) 可以有效的平滑后验粒子集, 因此避免了粒子的 depletion 问题, 同时 GMM 模型数 G 通过聚类自适应优化选择, 以更好的描述后验粒子分布。

4.3 GMMCDPF 算法

完整的 GMMCDPF 算法描述如下:

(A) 运动更新和提议分布产生

在时刻 $t-1$ 假设先验密度 $p(s_{t-1} | Z_{t-1})$, 运动噪声 $p(\varepsilon_{t-1})$ 和感知噪声 $p(\eta_t)$ 已知, 并且用 GMM 表示:

$$\tilde{p}(s_{t-1} | Z_{t-1}) = \sum_{g=1}^G \alpha_{g-1}^s N(\mu_{g-1}^s, P_{g-1}^s)$$

$$\tilde{p}(\varepsilon_{t-1}) = \sum_{i=1}^I \beta_{i-1}^s N(\mu_{i-1}^s, Q_{i-1}^s)$$

$$\tilde{p}(\eta_t) = \sum_{j=1}^J \gamma_{j-1}^s N(\mu_{j-1}^s, R_{j-1}^s) \quad (13)$$

现在我们根据下面步骤用 CDF 计算 $p(s_t | Z_{t-1})$ 和 $p(s_t | Z_t)$ 的 GMM 近似, 定义

$$g' = g + (i-1)G, \quad g'' = g' + (j-1)GI$$

(1) For $j=1, \dots, J$ 置 $\tilde{p}_j(\eta_t) = N(\mu_{j-1}^s, R_{j-1}^s)$, for $i=1, \dots, I$ 置 $\tilde{p}_i(\varepsilon_t) = N(\mu_{i-1}^s, Q_{i-1}^s)$, for $g=1, \dots, G$ 置 $\tilde{p}_g(s_{t-1} | Z_{t-1}) = N(\mu_{g-1}^s, P_{g-1}^s)$ 。

(2) For $g'=1, \dots, G'$, 用 CDF 运动更新计算高斯近似 $\tilde{p}_{g'}(s_t | Z_{t-1}) = N(\tilde{\mu}_{g'}^s, \tilde{P}_{g'}^s)$, 并且更新混合权重

$$\alpha_{g'}^s = \alpha_{g-1}^s \beta_{i-1}^s \left(\sum_{g=1}^G \sum_{i=1}^I \alpha_{g-1}^s \beta_{i-1}^s \right)^{-1}$$

(3) For $g''=1, \dots, G''$, 用 CDF 感知更新计算高斯近似 $\tilde{p}_{g''}(s_t | Z_t) = N(\mu_{g''}^s, P_{g''}^s)$, 并且更新混合权重 $\alpha_{g''}^s = \alpha_{g'}^s \gamma_{j-1}^s \Lambda_{g'}^j$ $\left(\sum_{g=1}^G \sum_{j=1}^J \alpha_{g'}^s \gamma_{j-1}^s \Lambda_{g'}^j \right)^{-1}$, 其中当 $s_t = \tilde{\mu}_{g'}^s$ 对感知 z_t 估计为 $\Lambda_{g'}^j = p_j(z_t | s_t)$ 。

现在, 预测状态密度可以用 GMM 近似为:

$$\tilde{p}(s_t | Z_{t-1}) = \sum_{g'=1}^{G'} \alpha_{g'}^s N(\tilde{\mu}_{g'}^s, \tilde{P}_{g'}^s) \quad (14)$$

提议分布 $q(s_t | Z_t)$ 的后验状态密度用 GMM 近似为:

$$q(s_t | Z_t) = \tilde{p}(s_t | Z_t) = \sum_{g''=1}^{G''} \alpha_{g''}^s N(\mu_{g''}^s, P_{g''}^s) \quad (15)$$

(B) 测量更新

(1) 从提议分布 $q(s_t | Z_t)$ 提取 N 个粒子 $\{x_i^j, i=1, \dots, N\}$ 并计算它们对应的权重:

$$\tilde{w}_i^j = p(z_t | x_i^j) \tilde{p}(x_i^j | Z_{t-1}) / q(x_i^j | Z_t) \quad (16)$$

$$(2) \text{ 归一化权重: } w_i^1 = \tilde{w}_i^1 / \sum_{i=1}^N \tilde{w}_i^1$$

(3) 用基于 KD 树的 WEM 聚类算法替代重新采样, 寻找适合加权粒子集 $\phi_i = \{w_i^1, x_i^1, i=1 \dots N\}$ 的 GMM 模型数 G 通过聚类算法自适应选择.

(a) 在粒子集上构建 KD 树, 树的每一个节点是粒子集的一个子集. 根节点拥有所有的粒子. 每一个非叶子节点有两个孩子. 孩子根据值 $Node_{splitval}$ 划分父亲:

$$\begin{aligned} x_i \in Node_{left} &\Leftrightarrow x_i < Node_{splitval} \text{ 并且 } x_i \in Node_{parent} \\ x_i \in Node_{right} &\Leftrightarrow x_i \geq Node_{splitval} \text{ 并且 } x_i \in Node_{parent} \end{aligned} \quad (17)$$

如果一个节点不能再分, 就认为是叶子. 在自上而下创建树的过程中, 通过剪枝确定某个节点是否是叶子, 而不必搜索所有孩子节点, 如果 GMM_g 的任意 g 模型满足如下条件就剪枝:

$$max(w_g) - min(w_g) < t \left(\sum w_g + Node_{numparticle} \times min(w_g) \right) \quad (18)$$

其中 $w_g = p(M_g | x_i, \theta)$ 表示模型 M_g 拥有粒子 x_i 的概率:

$$\begin{aligned} w_g &= p(M_g | x_i, \theta) = a_{g,c_g} \prod_{k=1}^G \alpha_k c_k \\ a_g &= p(x_i | M_g, \theta) \\ &\approx (2\pi \| P_g \|)^{-1/2} \exp(-\frac{1}{2} (x_i - \mu_g)^T P_g^{-1} (x_i - \mu_g)) \end{aligned} \quad (19)$$

$c_g = p(M_g | \theta)$, $\theta = (c_1, \dots, c_G; \mu_1, \dots, \mu_G; P_1, \dots, P_G)$ 其中 θ 表示 GMM 的所有参数, μ 和 P_g 分别是模型 M_g 的平均值和协方差.

(b) 对 KD 树执行 EM 循环, 树的根调用函数 $MakeStates()$, $MakeStates(Node, \theta_i)$ 返回 $3G$ 个值:

$$\begin{aligned} Sw_g &= \sum_{x_i \in Node} w_{ig}, Sw_{x_g} = \sum_{x_i \in Node} w_{ig} x_i, \\ Sw_{xx_g} &= \sum_{x_i \in Node} w_{ig} x_i x_i^T \end{aligned} \quad (20)$$

$MakeStates(ROOT)$ 的结果用来构建参数 θ_{i+1} :

$$\begin{aligned} c_g &= Sw_g / N, \mu_g = Sw_{x_g} / Sw_g, P_g = (Sw_{xx_g} / Sw_g) - \mu_g \mu_g^T \quad (21) \end{aligned}$$

如果叶子节点调用 $MakeStates()$, 对每一个 M_g 简单计算为:

$$\begin{aligned} \bar{w}_g &= p(M_g | \bar{x}, \theta_i) \\ &= P(\bar{x} | M_g, \theta_i) p(M_g | \theta_i) \prod_{k=1}^G p(\bar{x} | M_k, \theta_i) p(M_k | \theta_i) \end{aligned} \quad (22)$$

其中 $\bar{x} = Node_{centroid}$, 那么返回

$$\begin{aligned} Sw_g &= \bar{w}_g \times Node_{numparticles}, Sw_{x_g} = \bar{w}_g \times Node_{numparticles} \times \bar{x} \\ Sw_{xx_g} &= \bar{w}_g \times Node_{numparticles} \times Node_{cov} \end{aligned} \quad (23)$$

如果非叶节点调用 $MakeStates()$, 则它的两个孩子节点递归调用 $MakeStates()$, 最终返回两个孩子节点的结果集.

现在, 我们可以用更新的 G 个 GMM 近似状态后验分布

(C) 输出

状态估计的平均值 $\hat{s}_i = E[s_i | Z_i]$ 和对应误差协方差

$P_i = E[(s_i - \hat{s}_i)(s_i - \hat{s}_i)^T]$ 在加权 EM 聚类之前计算为:

$$\hat{s}_i = \sum_{i=1}^N w_i^1 x_i^1, P_i = \sum_{i=1}^N w_i^1 (x_i - \hat{s}_i)(x_i - \hat{s}_i)^T \quad (25)$$

经过 GMM 近似后计算为:

$$\hat{s}_i = \sum_{g=1}^G \alpha_i^g \mu_i^g, P_i = \sum_{g=1}^G \alpha_i^g (P_i^g + (\mu_i^g - \hat{s}_i)(\mu_i^g - \hat{s}_i)^T) \quad (26)$$

5 实现细节

为了实现全局定位, 必须建立运动模型 $s_t = F(s_{t-1}, u_t, \varepsilon_{t-1})$ 和感知模型 $z_t = G(s_t, \eta_t)$, 一旦这两个模型确定, 就可以直接应用上面提到的 $GMM CDPF$ 实现定位.

5.1 运动模型

运动模型预测机器人位姿状态随时间的变化, 当包括前进和角速度的控制 u 输入机器人时:

$$\begin{bmatrix} x_t \\ y_t \\ \theta_t \end{bmatrix} = \begin{bmatrix} x_{t-1} \\ y_{t-1} \\ \theta_{t-1} \end{bmatrix} + \begin{bmatrix} v_{t-1} \Delta T \cos(\theta_{t-1} + \omega_{t-1} \Delta T) \\ v_{t-1} \Delta T \sin(\theta_{t-1} + \omega_{t-1} \Delta T) \\ \theta_{t-1} + \omega_{t-1} \Delta T \end{bmatrix} + \varepsilon_{t-1} \quad (27)$$

其中 (x_t, y_t, θ_t) 是机器人在时刻的位姿和方向, 对所有粒子 $i=1, \dots, N$, v_{t-1} 和 ω_{t-1} 分别是机器人的线速度和角速度, ΔT 是时间间隔, $\varepsilon = [\varepsilon_x \ \varepsilon_y \ \varepsilon_\theta]^T$ 是运动噪声.

5.2 感知模型

应用运动模型预测机器人的位姿后, 还需要更多的传感器感知信息更新估计获得更可靠的位姿. $Pioneer II$ 移动机器人本体周围的 16 个声纳作为距离测距仪 (图 3). 为了更加准确, 还需要考虑每个声纳在机器人上的安装位置. 每个声纳偏离机器人正前方的角度是 $22.5^\circ \cdot j$ ($j=0 \dots 15$ 是声纳的序号). 因此如果机器人全局位姿为 $s_t = (x_t^G, y_t^G, \theta_t^G)$, 则第 j 个声纳在全局坐标系中的坐标计算为:

$$\begin{aligned} \theta_{sj} &= \theta_t^G - 22.5^\circ \cdot j \quad (j=0 \dots 7) \\ \theta_{sj} &= 360 - 22.5^\circ \cdot j + \theta_t^G, \quad (j=8 \dots 15) \\ x_{sj} &= x_t^G + D \cdot \cos \theta_{sj}, \quad y_{sj} = y_t^G + D \cdot \sin \theta_{sj} \end{aligned} \quad (28)$$

其中 D 是声纳到机器人中心的距离 (图 3), 则对应声纳读数的机器人声纳传感器感知计算为:

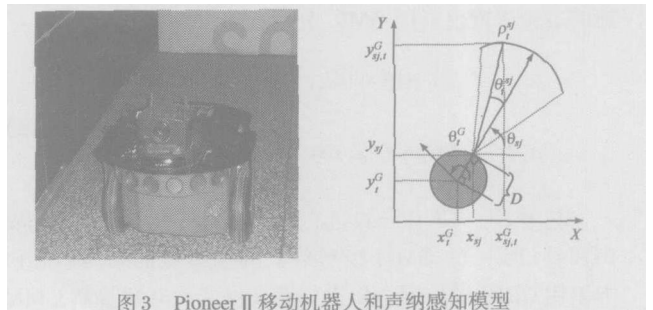


图3 Pioneer II 移动机器人和声纳感知模型

$$\begin{bmatrix} x_{sj,t}^G \\ y_{sj,t}^G \end{bmatrix} = \begin{bmatrix} x_t^G \\ y_t^G \end{bmatrix} + D \cdot \begin{bmatrix} \cos \theta_{sj} \\ \sin \theta_{sj} \end{bmatrix} + \eta \cdot \begin{bmatrix} \cos(\theta_{sj} + \theta_{sj}^G) \\ \sin(\theta_{sj} + \theta_{sj}^G) \end{bmatrix} + \eta_t \quad (29)$$

其中 $\eta = [\eta_x \ \eta_y]^T$ 是传感器感知噪声.

6 实验结果

我们在实际 PioneerII 移动机器人上完成了试验,数据来源包括声纳传感器扫描和里程计测量,声纳感知和电机控制在机器人上实现,定位的主要算法在本地主频 1.6GHz 的 PC 机上实现,PC 机通过无线连接机器人.试验场地是实验室室内环境,大小 $10 \times 8\text{m}^2$,并用木板和纸箱划分空间间隔成一个高度对称的环境.初始机器人放置在底部中间隔间里,运行后,机器人须通过中间通道到达上左最大的一个隔间,并确定自身位姿.

图 4 左侧给出了用传统粒子滤波器的定位结果,采用 10000 个粒子(蓝色)表示后验分布,并用传递先验作为提议分布,对提议分布冗余重新采样(residual resampling),初始所有粒子均有分布在空间.图 4 右侧是应用




图 4 移动机器人定位:左侧用传统粒子滤波器,右侧用 GMMCDPF,小黑方块是实际机器人位置




图 5 定位误差比较

本文提出的 GMMCDPF 的运行结果.每个 GMM 500 个粒子,初始 35 个 GMM 也均匀分布在空间(红色).随算法分运行,当机器人通过中间通道时,由于环境的高相似性,使机器人位姿的不确定性非常高,导致了传统的粒子滤波器退化,定位失败.而 GMMCDPF 不断吸收当前的传感器输入,通过多 GMM 准确表示了机器人位姿后验的所有可能假设,随着位姿不确定性的降低,模型数也随着减少,最终成功定位.我们从定位误差、运算时间和存储空间三个方面对 PF、CDPF 和 GMMCDPF 进行了比较,由于 CDPF 和 GMMCDPF 将当前的感知吸收进提议分布,克服了传统 PF 的一些局限性,因此

定位有更高的准确性(图 5),并且它们对传统 PF 基于测量更新重要性采样输出加权粒子的混合高斯建模,使它们的计算时间和存储空间需求都大大降低.虽然 CDPF 和 GMMCDPF 定位准确性相差不大,但由于后者采用了基于 KD 树聚类类的自适应选择高斯混合模型数,因此从时间上,尤其是存储空间上对 CDPF 有了较大改进(图 6 7).




图 6 每个循环的计算时间




图 7 存储需求

7 结论

针对传统粒子滤波器的退化,以及 SIR 导致的粒子耗尽(depletion)问题,本文提出了一种基于测量更新步的重要性采样跟产生提议分布的 CDF 相结合的新算法.通过对测量更新步的加权粒子集应用加权 EM 算法获得表示机器人位姿状态后验密度的高斯混合模型 GMM,并且自适应聚类选择 GMM 的个数.最后在实际 PioneerII 移动机器人上完成的实验结果表明,新方法以较高的准确率和较低的计算复杂度实现了全局定位.并为解决非线性非高斯的估计问题提供了一种新途径.

参考文献:

- [1] Reuter J M. Mobile robot self localization using PDA B[A]. In Proceedings of the IEEE International Conference on Robotics and Automation (ICRA) [C]. San Francisco: IEEE Press, 2000. 3512-3518.
- [2] Fox D, Burgard W, Thrun S. Markov localization for mobile robots in dynamic environments[J]. Journal of Artificial Intelligence Research, 1999, 11(3): 391-427.
- [3] Andrieu C, Doucet A. Particle filtering for partially observed gaussian state space Models[J]. Journal of the Royal Statistical Society Series B (Statistical Methodology), 2002, 64(4): 827-836.
- [4] Doucet A, Godsill S J, Andrieu C. On sequential Monte Carlo sampling methods for bayesian filtering[J]. Statistics and Computing, 2000, 10(3): 197-208.

- [5] Thrun S, Fox D, Burgard W. Robust monte carlo localization for mobile robots[J]. Artificial Intelligence, 2001, 128(1-2): 99- 141
- [6] Fox D. Adapting the sample size in particle filters through KLD-Sampling[J]. International Journal of Robotic Research, 2003, 22(12): 985- 1004
- [7] Kotecha J, Djuric P M. Gaussian sum particle filtering [J]. IEEE Transactions on Signal Processing, 2003, 51(10): 2602- 2612
- [8] Andrew Moore. Very fast EM-based mixture model clustering using multiresolution kd-trees[J]. Advances in Neural Information Processing Systems, 1999, 11: 543- 549
- [9] Aspach D L, Sorenson H W. Nonlinear bayesian estimation using gaussian sum approximations[J]. IEEE Transactions on Automatic Control, 1972, 17(4): 439- 448
- [10] Wan E A, Van derMerve R. The unscented kalman filter for nonlinear estimation[A]. In Proc of IEEE Symposium 2000 (IEEE AS-SPCC) [C]. Lake Louise, Alberta: IEEE Press, 2000: 153- 158

作者简介:



厉茂海 男, 1980年3月生于山东省潍坊市, 2002年毕业于哈尔滨工业大学, 获学士学位, 现为哈尔滨工业大学计算机科学与技术学院硕博连读研究生, 主要研究方向为移动机器人导航、定位, 同时定位与地图生成。

E-mail: lmaoha@hit.edu.cn



洪炳熔 男, 1937年生, 哈尔滨工业大学教授、博士生导师, 机器人研究中心主任, 中国人工智能学会常务理事, 中国人工智能学会机器人足球工作委员会主任, 国际机器人足球联盟(FIRA)副主席, FIRA中国分会会长, 主要研究方向是: 分布式人工智能、多智能体机器人系统、智能机器人、机器人足球、虚拟现实。发表 200多篇论文, 著作 4部

拟现实。发表 200多篇论文, 著作 4部

蔡则苏 男, 1966年生于江苏, 哈尔滨工业大学副教授, 从事月球车、家庭机器人的研究工作, 发表论文 10余篇, 著作 1部。