

基于粒子滤波的未知环境下机器人同时定位、地图构建与目标跟踪

伍明，孙继银

(中国人民解放军第二炮兵工程大学 指挥信息系统工程系,陕西 西安 710025)

摘要:为了解决机器人在未知环境下的目标跟踪问题,提出了一种基于粒子滤波的机器人同时定位、地图构建与目标跟踪方法。该方法采用 Rao-Blackwellized 粒子滤波器对机器人位姿状态、标志柱分布和目标位置同时进行估计。该方法中,粒子群的总体分布情况表征机器人位姿状态,而每个粒子均包含 2 类 EKF 滤波器,其中一类用来完成对标志柱分布的估计,另一类用来完成对目标状态的估计,粒子的权值则由粒子状态相对于标志柱和目标状态 2 类相似度共同产生。通过仿真和实体机器人实验证了该方法的有效性。

关键词:Rao-Blackwellized 粒子滤波;同时定位与地图构建;目标跟踪

中图分类号: TP242.6 文献标志码:A 文章编号:1673-4785(2013)02-0168-09

Simultaneous localization, mapping and object tracking in an unknown environment using particle filtering

WU Ming, SUN Jiayin

(The department of commander information system, The PLA Second Artillery Engineering College, Xi'an 710025, China)

Abstract:The proposed research paper examines a simultaneous localization, mapping, and object tracking method. The examination was in part based on a particle filter that allows a robot to track an object in an unknown environment. This method utilizes the Rao-Blackwellized particle filtering to estimate the pose of robot, landmarks distribution, and object position simultaneously. The general distribution of a particle swarm represents the pose of a robot, and each particle includes two kinds of Extended Kalman Filter (EKF). One EKF estimates distribution of landmarks, while the other EKF estimates the state of the object. The weight of particle is determined by the combination of two likelihoods, one is the likelihood between particle state and landmarks, and the other is the likelihood between particle state and object state. The results of the research indicate the valid robot experimentation and simulation, confirm the proposed research approach is very effective.

Keywords:Rao-Blackwellized particle filter; simultaneous localization and mapping; object tracking

机器人同时定位与地图构建(simultaneous localization and mapping, SLAM)是指机器人在未知环境下,根据传感器信息的迭代完成环境地图构造,并同时对机器人位姿状态进行估计的过程,SLAM 的难度在于准确的地图构建依靠于准确的机器人位姿估计,而准确的机器人位姿估计反过来又依靠于准确的环境地图。对于这个“鸡生蛋,蛋生鸡”的问题主要存在 2 类解决方法:1) 基于扫描点匹配的方

法^[1-3];2) 基于 Bayesain 估计的方法,而基于 Bayesain 估计的方法又主要分成基于扩展式卡尔曼滤波的方法^[4-6]和基于粒子滤波的方法^[7-9]。

对于某些实际任务单凭传统的 SLAM 方法是无法解决的,例如未知环境下目标的跟踪任务、未知环境下机器人的围捕任务。这些任务要求机器人在未知环境条件下完成对目标的追踪,与传统目标跟踪问题不同,传统的目标跟踪问题往往假设系统准确知道传感器的状态,并在此基础上,通过 Bayesain 方法对目标状态进行预测和更新。而本文所研究问题的特点有:1)传感器的移动性和运行环境的未知性。在目标

追踪的过程中,机器人需要始终保持与目标的追随关系,也就是说,机器人在跟踪过程中保持运动状态,因此存在机器人状态估计问题,而由于机器人事先并不了解其运动环境,所以还需对环境特征状态进行估计,实际上这就是传统的 SLAM 问题;2) 机器人状态和目标状态相关性。目标的状态估计是在机器人状态估计的基础上完成的,如果将两者分开进行那么就不能有效表示两者的相关性,进而影响最终目标估计的准确性。由此可见,本文研究的问题是 SLAM 问题和目标跟踪问题的耦合,如何设计一种一体化的估计算法正是本文的目的。Wang 等^[10,11]首先对该问题进行了研究并提出一种基于扫描点匹配的解决方法,由于该方法采用的是 ICP (iterative closest point) 匹配算法,因此无法描述机器人和目标的不确定性和相关性,并且存在累积误差^[12]。

1 同时定位、地图构建与目标跟踪问题描述

假设机器人 R 以一定轨迹 $s^k = [s_1 \ s_2 \ \cdots \ s_k]$ 运动, 其在 k 时刻的状态为 $s_k = [x_k^R \ y_k^R \ \theta_k^R]^T$, 并且运动环境中包含若干个固定标志点 $L_M = [l_{m_1} \ l_{m_2} \ \cdots \ l_{m_m}]$, 标志点 i 对应的坐标为 $l_{m_i} = [x_i \ y_i]^T$, $i \in \{1, 2, \dots, m\}$. 同时目标轨迹为 $t^k = [t_1 \ t_2 \ \cdots \ t_k]$, 其在 k 时刻的状态为 $t_k = [x_k^T \ y_k^T \ \theta_k^T]^T$. 设 $z^k = [z_1 \ z_2 \ \cdots \ z_k]$, 为从观测开始一直到 k 时刻机器人对于环境的观测值, 在很多应用场合该观测值可以是角度和深度信息. 那么 SLAMTO (simultaneous localization and mapping with tracking of objects) 问题等同于求式(1):

$$p(s_k, L_M, t_k | z^k, u^k). \quad (1)$$

也就是说,要通过观测值 $z^k = [z_1 \ z_2 \ \cdots \ z_k]$ 和机器人的控制量 $u^k = [u_1 \ u_2 \ \cdots \ u_k]$ 来确定机器人的状态 s_k , 标志点的位置 L_M 以及目标的状态 t^k . 该过程实际上可以描述成为动态 Bayesian 网络, 如图 1 示. 图 1 中节点表示动态系统中各部分在时间序列中的状态, k 代表时刻, 箭头表示各状态的依赖关系. 从该图可知目标 k 时刻的观测值 z_k^t 依赖于机器人 k 时刻的状态 s_k 以及目标 k 时刻的状态 t_k .

因此利用该观测值可以估计机器人和目标的状态; 对于标志柱 k 时刻的观测值 z_k^l 依赖于标志柱的位置 l_m ($i=1, 2, \dots, m$) 以及机器人 k 时刻的状态, 因此同样能够利用该值估计机器人状态和标志的位置.

在此基础上给出基于 Bayesian 估计的机器人同时定位、地图构建和目标跟踪理论描述. 为了递归式地得到机器人状态 s_k , 目标状态 t_k 以及地图状态 L_M 的后验概率, 应用条件概率的定义将 s_k, t_k, \dots, z_k 的联合概率以 s_k, t_k, L_M 的条件概率进行扩展可得

$$\begin{aligned} p(s_k, t_k, L_M, z_k | z^{k-1}, u^k) &= \\ p(s_k, t_k, L_M | z^k, u^k) p(z_k | z^{k-1}, u^k). \end{aligned} \quad (2)$$

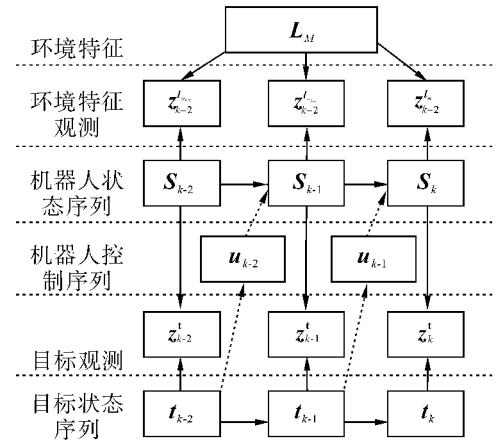


图 1 SLAMTO 的 Bayesian 网络关系

Fig. 1 A dynamic Bayesian network of SLAMTO

类似地, 以 z_k 的条件概率进行扩展可得:

$$\begin{aligned} p(s_k, t_k, L_M, z_k | z^{k-1}, u^k) &= \\ p(z_k | s_k, t_k, L_M, z^{k-1}, u^k) p(s_k, t_k, L_M | z^{k-1}, u^k). \end{aligned} \quad (3)$$

变换式(2)并将式(3)代入得:

$$\begin{aligned} p(s_k, t_k, L_M | z^k, u^k) &= \frac{p(s_k, t_k, L_M, z^k | z^{k-1}, u^k)}{p(z_k | z^{k-1}, u^k)} = \\ p(z_k | s_k, t_k, L_M, z^{k-1}, u^k) p(s_k, t_k, L_M | z^{k-1}, u^k) &= \\ \frac{p(z_k | s^k, t_k, L_M) p(s^k, t_k, L_M | z^{k-1}, u^k)}{p(z_k | z^{k-1}, u^k)}. \end{aligned} \quad (4)$$

式(4)为 SLAMT 问题的 Bayesian 估计描述, 其中 $p(z_k | s_k, t_k, L_M)$ 表示观测值的相似度 (likelihood), 用于对预测概率分布的矫正; $p(z_k | z^{k-1}, u^k)$ 为归一化系数, $p(s_k, t_k, L_M | z^{k-1}, u^k)$ 是对机器人状态、目标状态和地图的预测概率分布.

下面介绍式(4)分子部分第 2 项 $p(s_k, t_k, L_M | z^{k-1}, u^k)$ 的推导. 利用全概率公式用 s_{k-1} 和 t_{k-1} 对该式变换可得:

$$\begin{aligned} p(s_k, t_k, L_M | z^{k-1}, u^k) &= \\ \iint p(s_k, s_{k-1}, t_k, t_{k-1}, L_M | z^{k-1}, u^k) ds_{k-1} dt_{k-1}. \end{aligned} \quad (5)$$

利用条件概率定义, 用 s_{k-1}, t_{k-1} 和 L_M 对式(5)进行

展开可得

$$\begin{aligned} p(\mathbf{s}_k, \mathbf{t}_k, \mathbf{L}_M | \mathbf{z}^{k-1}, \mathbf{u}^k) &= \iint p(\mathbf{s}_k, \mathbf{s}_{k-1}, \mathbf{t}_k, \mathbf{t}_{k-1}, \mathbf{L}_M | \mathbf{z}^{k-1}, \mathbf{u}^k) d\mathbf{s}_{k-1} d\mathbf{t}_{k-1} = \\ &\underbrace{\iint p(\mathbf{s}_k, \mathbf{t}_k | \mathbf{z}^{k-1}, \mathbf{u}^k, \mathbf{s}_{k-1}, \mathbf{t}_{k-1}, \mathbf{L}_M)}_{\text{第1项}} \underbrace{p(\mathbf{s}_{k-1}, \mathbf{t}_{k-1}, \mathbf{L}_M | \mathbf{z}^{k-1}, \mathbf{u}^{k-1}) d\mathbf{s}_{k-1} d\mathbf{t}_{k-1}}_{\text{第2项}}. \end{aligned} \quad (6)$$

式(6)中已经体现出递归式估计过程,其中积分中第2项代表了 $k-1$ 时刻得出的联合后验概率密度。为了得出最终的预测概率密度还需计算式(6)中第1项 $p(\mathbf{s}_k, \mathbf{t}_k | \mathbf{z}^{k-1}, \mathbf{u}^k, \mathbf{s}_{k-1}, \mathbf{t}_{k-1}, \mathbf{L}_M)$,该项代表了机器人状态和目标状态的联合概率密度从 $k-1$ 到 k 时刻发生的变换,以下分2种情况进行讨论。

1) 当机器人状态和目标状态不相关的情况,此时有

$$\begin{aligned} p(\mathbf{s}_k, \mathbf{t}_k | \mathbf{z}^{k-1}, \mathbf{u}^k, \mathbf{s}_{k-1}, \mathbf{t}_{k-1}, \mathbf{L}_M) &= \\ p(\mathbf{s}_k | \mathbf{s}_{k-1}, \mathbf{u}^k) p(\mathbf{t}_k | \mathbf{t}_{k-1}, \mathbf{u}^k). \end{aligned} \quad (7)$$

从式(7)可知,机器人和目标状态的联合概率密度变化为机器人状态变化和目标状态变化的乘积,两者之间并没有相互作用。

2) 当机器人状态和目标状态相关时有

$$\begin{aligned} p(\mathbf{s}_k, \mathbf{t}_k | \mathbf{z}^{k-1}, \mathbf{u}^k, \mathbf{s}_{k-1}, \mathbf{t}_{k-1}, \mathbf{L}_M) &= \\ \int p(\mathbf{s}_k | \mathbf{z}^{k-1}, \mathbf{u}^k, \mathbf{s}_{k-1}, \mathbf{t}_{k-1}, \mathbf{t}_k, \mathbf{L}_M) p(\mathbf{t}_k | \mathbf{z}^{k-1}, \\ \mathbf{u}^k, \mathbf{s}_{k-1}, \mathbf{t}_{k-1}, \mathbf{L}_M) d\mathbf{t}_{k-1} = \\ \int p(\mathbf{s}_k | \mathbf{s}_{k-1}, \mathbf{u}^k, \mathbf{t}_{k-1}) p(\mathbf{t}_k | \mathbf{t}_{k-1}, \mathbf{u}^k) d\mathbf{t}_{k-1}. \end{aligned} \quad (8)$$

式(8)由全概率公式得出,表示了机器人状态变化受到了 $k-1$ 时刻目标状态的影响,这种情况体现在现实中为机器人不光要跟踪目标同时还需要尾随目标的情况。下面介绍解决 SLAMTO 问题的具体实现方法。

2 基于 Rao-Blackwellised 粒子滤波器的 SLAMTO 实现

2.1 问题的因式化表示

如图 1 所示,如果知道机器人的路径 $\mathbf{s}^k = [\mathbf{s}_1 \ \mathbf{s}_2 \ \dots \ \mathbf{s}_k]$,那么时间序列上的观测值 $\mathbf{z}^k = [\mathbf{z}_1 \ \mathbf{z}_2 \ \dots \ \mathbf{z}_k]$ 将是相互独立的。那么式(1)能够进行因式化,如式(9):

	机器人状态	目标状态	路标1	...	路标 \mathbf{L}_{M_k}	
粒子 1:	S_k^1	$[x_k^R \ y_k^R \ \theta_k^R]^T$	T	$[\mu_k^{11} \ \Sigma_k^{11}]^T$	\mathbf{L}_M	$[\mu_1^1 \ \Sigma_1^1]^T$
					\dots	\mathbf{L}_M
						$[\mu_{L_{m_k}}^1 \ \Sigma_{L_{m_k}}^1]^T$
粒子 2:	S_k^2	$[x_k^R \ y_k^R \ \theta_k^R]^T$	T	$[\mu_k^{12} \ \Sigma_k^{12}]^T$	\mathbf{L}_M	$[\mu_1^2 \ \Sigma_1^2]^T$
					\dots	\mathbf{L}_M
						$[\mu_{L_{m_k}}^2 \ \Sigma_{L_{m_k}}^2]^T$
\vdots	\vdots	\vdots				
粒子 N_s :	$S_k^{N_s}$	$[x_k^R \ y_k^R \ \theta_k^R]^T$	T	$[\mu_k^{1N_s} \ \Sigma_k^{1N_s}]^T$	\mathbf{L}_M	$[\mu_1^{N_s} \ \Sigma_1^{N_s}]^T$
					\dots	\mathbf{L}_M
						$[\mu_{L_{m_k}}^{N_s} \ \Sigma_{L_{m_k}}^{N_s}]^T$

图 2 粒子结构示意
Fig.2 Structure of each particles

2.2 粒子权值的计算

下面介绍粒子权值的计算,粒子权值相当于该粒子对应观测值的相似度,即

$$\begin{aligned} w_k^i &= p(z_k | s_k^i, \bar{t}_k, z_{k-1}, u_k) = \\ &p(z_{f_k}, z_{t_k}, z_{n_k} | s_k^i, \bar{t}_k, z_{k-1}, u_k) \stackrel{\text{Independent}}{=} \\ &p(z_{f_k} | s_k^i, z_{k-1}, u_k) p(z_{t_k} | s_k^i, \bar{t}_k, z_{k-1}, u_k) \\ &\stackrel{\text{Markov}}{=} p(z_{n_k} | s_k^i, z_{k-1}, u_k) = \\ &p(z_{f_k} | s_k^i) p(z_{t_k} | s_k^i, \bar{t}_k) p(z_{n_k} | s_k^i) \propto \\ &p(z_{f_k} | s_k^i) p(z_{t_k} | s_k^i, \bar{t}_k). \end{aligned} \quad (11)$$

式中: $z_{f_k}, z_{t_k}, z_{n_k}$ 分别代表对已知标志柱、目标和新标志柱的观测值, \bar{t}_k 为预测阶段根据 EKF 得到的目标状态(参见下 2.3 节内容),而 $p(z_{n_k} | s_k^i)$ 认为是均匀分布的,因此最终权值可表示为标志柱观测值相似度和目标观测值相似度之间的乘积。以下具体介绍目标观测值相似度 $p(z_{t_k} | s_k^i, \bar{t}_k)$ 的计算。

假设机器人的观测值为距离和角度信息,则机器人对目标的观测模型:

$$z_t = h(s, t) = \begin{bmatrix} d \\ \theta \end{bmatrix} = \begin{bmatrix} \sqrt{(x^R - x^t)^2 + (y^R - y^t)^2} \\ \arctan\left(\frac{\sqrt{(y^R - y^t)^2}}{\sqrt{(x^R - x^t)^2}}\right) - \theta^R \end{bmatrix}. \quad (12)$$

式中: $s = [x^R \ y^R \ \theta^R]^T$ 表示机器人的状态量, $t = [x^t \ y^t \ \theta^t]^T$ 表示目标的状态量, d 和 θ 分别为机器人的观测值。

假设观测值相似度服从正态分布 $p(z) \sim N(\mu^z, \Sigma^z)$, 则相似度函数 $p(z_t | s, \bar{t})$ (为了简洁表示省去上标和下标)如式(13):

$$\begin{aligned} p(z_t | s, \bar{t}) &= \\ &\frac{1}{(2\pi)^{d/2} |\Sigma^z|^{1/2}} \exp\left(-\frac{1}{2} (z_t - \eta^z)^T (\Sigma^z)^{-1} (z_t - \eta^z)\right). \end{aligned} \quad (13)$$

式中: η^z 为根据该粒子表示的机器人状态 s 和预测目标状态 \bar{t} 由式(12)得到的预测观测值, z_t 为实际的观测值, Σ^z 为观测值的协方差矩阵,下面介绍 Σ^z 的计算。

协方差阵 Σ^z 反映对目标观测值的误差情况,这种误差由三方面造成,首先是传感器本身的误差,设其值为 R^{sen} ;其次是由目标状态不确定性引起的误差,设其值为 R^t ;最后为机器人状态不确定性引起的误差,由于这里用粒子群来代表这种不确定性,因此对于单个粒子来说,认为机器人状态不存在误差。最终 Σ^z 表示如式(14):

$$\Sigma^z = R^t + R^{\text{sen}} = H^t \bar{\Sigma}^t (H^t)^T + R^{\text{sen}}. \quad (14)$$

式中: $\bar{\Sigma}^t$ 为预测阶段由 EKF 得到的目标状态协方差

阵, H^t 为式(12)对 t 的雅克比阵在 s 和 \bar{t} 处的值,即

$$H^t = \frac{\partial h}{\partial t} \Big|_{\bar{t}} = ((\bar{x} - x^R)^2 + (\bar{y} - y^R)^2)^{-1/2} \cdot \begin{bmatrix} \bar{x} - x^R & \bar{y} - y^R & 0 \\ y^R - \bar{y} & \bar{x} - x^R & 0 \end{bmatrix}.$$

类似,可以计算出 $p(z_{f_k} | s_k^i)$ 。

2.3 目标和标志柱均值和方差的计算

接下来介绍目标点状态的估计,基于单个粒子目标点状态估计可表示为

$$\begin{aligned} p(t_k | s_k^i, z^k, u^k) &\stackrel{\text{Bayes}}{=} \\ &\alpha p(z_k | s_k^i, z^{k-1}, t_k, u^k) p(t_k | s_k^i, z^{k-1}, u^k) \propto \\ &p(z_k | s_k^i, z^{k-1}, t_k, u^k) p(t_k | s_k^i, z^{k-1}, u^k) \stackrel{\text{Markov}}{=} \\ &p(z_k | s_k^i, t_k) p(t_k | s_k^i, z^{k-1}, u^k) \stackrel{\text{Chapman-Kolmogorov}}{=} \\ &p(z_k | s_k^i, t_k) \int p(t_k | t_{k-1}, s_k^i, z^{k-1}, \\ &u^k) p(t_{k-1} | s_k^i, z^{k-1}, u^k) dt_{k-1} \stackrel{\text{Markov}}{=} \\ &\underbrace{p(z_k | s_k^i, t_k)}_{\text{更新阶段}} \underbrace{\int p(t_k | t_{k-1}, u_k) p(t_{k-1} | s_{k-1}^i, z^{k-1}, u^{k-1}) dt_{k-1}}_{\text{预测阶段}}. \end{aligned} \quad (15)$$

式中: α 为归一化系数, s_k^i 为 k 时刻第 i 个粒子状态。式(15)可以应用 EKF 进行估计,EKF 分为预测和更新 2 个阶段,分别介绍如下。

2.3.1 EKF 预测阶段

本文假设目标以恒速 $u = [v \ \omega]^T$ 运动并且 u 上存在协方差为 Q^u 的误差(这里假设目标的运动为单模态形式,多模态运动形式将是今后研究的目标)。并且目标运行遵循差动驱动模型,即非完整性约束模型:

$$\begin{aligned} t_k &= g^t(t_{k-1}, u_k) = \\ &\begin{bmatrix} x_{k-1} \\ y_{k-1} \\ \theta_{k-1} \end{bmatrix} + \begin{bmatrix} v_k \cdot \Delta t \cdot \cos(\theta_{k-1} + \Delta t \cdot \omega_k) \\ v_k \cdot \Delta t \cdot \sin(\theta_{k-1} + \Delta t \cdot \omega_k) \\ \Delta t \cdot \omega_k \end{bmatrix}. \end{aligned} \quad (16)$$

式中: Δt 为输入的间隔时间。从式(16)可见,目标在 k 时刻的不确定性由 2 部分组成,1)是由 $k-1$ 时刻的不确定性传播而来,记作 Σ_{k-1}^t ;2)是由输入量的不确定性 Q^u 传播而来,记作 Σ^u 。则根据误差传播公式可以得到 k 时刻的预测误差协方差阵 $\bar{\Sigma}_k^t$ 为

$$\bar{\Sigma}_k^t = \Sigma^t + \Sigma^u = H^t \bar{\Sigma}_{k-1}^t (H^t)^T + H^u Q^u (H^u)^T. \quad (17)$$

式中: H^u 为式(16)对于输入 u 的雅克比阵在 u_k 和 t_{k-1} 处的值, H^t 为式(16)对于机器人状态 t 的雅克比阵在 u_k 和 t_{k-1} 处的值,即

$$H^u = \frac{\partial g^t}{\partial u} \Big|_{u_k, t_{k-1}} =$$

$$\begin{bmatrix} \Delta t \cdot \cos(\theta_{k-1} + \Delta t \cdot \omega_k) & -v_k \cdot \Delta t^2 \cdot \sin(\theta_{k-1} + \Delta t \cdot \omega_k) \\ \Delta t \cdot \sin(\theta_{k-1} + \Delta t \cdot \omega_k) & v_k \cdot \Delta t^2 \cdot \cos(\theta_{k-1} + \Delta t \cdot \omega_k) \\ 0 & \Delta t \end{bmatrix},$$

$$H^t = \frac{\partial g^t}{\partial t} \Big|_{u_k, t_{k-1}} =$$

$$\begin{bmatrix} 1 & -v_k \cdot \Delta t \cdot \sin(\theta_{k-1} + \Delta t \cdot \omega_k) \\ 0 & v_k \cdot \Delta t \cdot \cos(\theta_{k-1} + \Delta t \cdot \omega_k) \\ 0 & 1 \end{bmatrix}.$$

2.3.2 EKF 更新阶段

在每一次迭代过程中若机器人没有发现目标，即目标的观测值为空时，那么 EKF 只进行预测，其结果是目标的不确定性将不断增大。当机器人发现目标时，EKF 将利用观测值对目标的均值和方差进行修正，而减少目标的不确定性。

假设由预测阶段已经得到目标均值和方差为 μ_k^t 和 Σ_k^t ，而实际观测值为 z_t ，则 EKF 对均值和方差的更新为

$$\begin{aligned} \mu_k^t &= \bar{\mu}_k^t + K_{\text{kalman}}(z_t - H^t \bar{\mu}_k^t), \\ \Sigma_k^t &= (I - K_{\text{kalman}} H^t) \bar{\Sigma}_k^t. \end{aligned} \quad (18)$$

式中： K_{kalman} 为卡尔曼系数其值， $K_{\text{kalman}} = \bar{\Sigma}_k^t (H^t)^T (H^t \bar{\Sigma}_k^t (H^t)^T + R^{\text{sen}})^{-1}$ ， R^{sen} 为传感器误差协方差阵。

单个粒子标志柱位置估计也同样能够用相似的方式进行描述，不再赘述。

2.4 SLAMTO 算法

算法主要思想是对整个粒子群应用粒子滤波进行重要性采样及重采样，而在每个粒子中又应用 EKF 对标志柱及目标的均值和方差进行预测和校正操作，具体算法如下。

- [$\{s_k^i, \mu_k^{t,i}, \Sigma_k^{t,i}, \mu_{1,2,\dots,l_{m_k}}^i, \Sigma_{1,2,\dots,l_{m_k}}^i\}_{i=1}^{N_s}\}] =$
- PFSLAMT[$\{s_{k-1}^i, \mu_{k-1}^{t,i}, \Sigma_{k-1}^{t,i}, \mu_{1,2,\dots,l_{m_{k-1}}}^i, \Sigma_{1,2,\dots,l_{m_{k-1}}}^i\}_{i=1}^{N_s}\}]$
- 1) FOR $i = 1:N_s$,
- 2) $s_k^i \sim p(s_k | s_{k-1}^i, u_k)$,
- 3) $\bar{\mu}_k^{t,i} = g^t(\mu_{k-1}^{t,i}, u_k)$,
- 4) $\bar{\Sigma}_k^{t,i} = H^t \Sigma_{k-1}^{t,i} (H^t)^T + H^t Q^u (H^u)^T$,
- 5) ENDFOR
- 6) IF $z_k \neq \emptyset$
- 7) FOR $i = 1:N_s$,
- 8) [$z_{f_k}, z_{n_k}, z_{t_k}, \text{Table}\]$] = Data_association($z_k, [\mu_{1,2,\dots,l_{m_k}}^i, \Sigma_{1,2,\dots,l_{m_k}}^i]$)
- 9) IF $z_{t_k} \neq \emptyset$
- 10) $w_k^{i,t} = p(z_{t_k} | s_k^i, \bar{\mu}_k^{t,i}, \bar{\Sigma}_k^{t,i})$
- 11) [$\mu_k^{t,i}, \Sigma_k^{t,i}\]$] = EKFUPDATE($\bar{\mu}_k^{t,i}, \bar{\Sigma}_k^{t,i}, z_{t_k}$)
- 12) ENDIF

- 13) IF $z_{f_k} \neq \emptyset$
- 14) $w_k^{i,L_M} = p(z_{f_k} | s_k^i) p(z_{f_k^2} | s_k^i) \cdots p(z_{f_k^m} | s_k^i)$
- 15) [$\mu_{1,2,\dots,l_{m_{k-1}}}^i, \Sigma_{1,2,\dots,l_{m_{k-1}}}^i\]$] = EKF[$\mu_{1,2,\dots,L_M}^i, \Sigma_{1,2,\dots,L_{M_{k-1}}}^i, z_{f_k}$]
- 16) ENDIF
- 17) $w_k^i = w_k^{i,t} \cdot w_k^{i,L_M}$
- 18) IF $z_{n_k} \neq \emptyset$
- 19) [$\mu_{1,2,\dots,l_{m_k}}^i, \Sigma_{1,2,\dots,l_{m_k}}^i\]$] = ADD_LANKMARK($([\mu_{1,2,\dots,l_{m_{k-1}}}^i, \Sigma_{1,2,\dots,l_{m_{k-1}}}^i], z_{n_k}, s_k^i)$)
- 20) ENDIF
- 21) ELSE
- 22) [$\mu_{1,2,\dots,l_{m_k}}^i, \Sigma_{1,2,\dots,l_{m_k}}^i\]$] = [$\mu_{1,2,\dots,l_{m_{k-1}}}^i, \Sigma_{1,2,\dots,l_{m_{k-1}}}^i\]$
- 23) ENDELSE
- 24) ENDFOR
- 25) ENDIF
- 26) IF Resample_condition_satisfy
- 27) [$\{s_k^i, \mu_k^{t,i}, \Sigma_k^{t,i}, \mu_{1,2,\dots,l_{m_k}}^i, \Sigma_{1,2,\dots,l_{m_k}}^i\}_{i=1}^{N_s}\}] = \text{RESAMPLE}[\{s_k^i, \mu_k^{t,i}, \Sigma_k^{t,i}, \mu_{1,2,\dots,l_{m_k}}^i, \Sigma_{1,2,\dots,l_{m_k}}^i\}_{i=1}^{N_s}]$
- 28) ENDIF

其中 1) ~ 5) 是预测阶段(prediction step)，首先根据机器人状态转移方程对粒子进行预测撒点(粒子滤波形式)，之后对该粒子中对应的目标状态均值和方差利用目标的状态转移方程进行预测(EKF 预测阶段式(16)和(17))，此时的预测结果是存在误差的，当有观测值出现，算法进入修正阶段，即 6) ~ 24)，主要包括：根据式(11)进行的粒子权值的更新，目标状态和标志柱位置的更新。具体来讲，第 8) 行运用数据关联方法将观测值 z_k 区分为 $z_{f_k}, z_{t_k}, z_{n_k}$ (分别表示对标志柱、目标、新标志柱的观测值)，而 Table 则包含 z_{f_k} 和已知标志柱的对应关系，需要注意的是每个粒子 i 均拥有自己的 k 时刻环境地图 $1, 2, \dots, l_{m_k}$ ，并根据该地图进行数据关联。9) ~ 12) 行利用 z_{t_k} 和式(11)对粒子权值进行更新，并根据式(18)用 EKF 对目标的均值和方差进行修正，类似地 13) ~ 16) 行利用 z_{f_k} 对粒子权值进行更新，并用 EKF 对已知标志柱均值和方差进行修正，需要注意的是当观测到多个已知标志柱时粒子权值等于其对应的每一个相似度(likelihood)的乘积。17) 行根据式(11)生成最终的粒子权值。18) ~ 23) 行完成对于标志柱地图的更新。26) ~ 27) 行利用文献[13]介绍的方法对粒子群进行重采样。

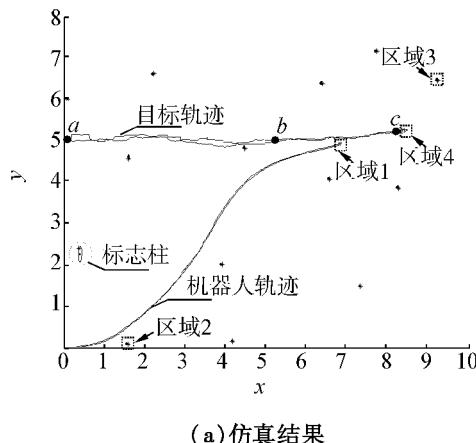
3 实验结果

下面首先通过仿真实验从定位准确性、粒子数量和标志柱数量对定位的影响三方面来验证算法的

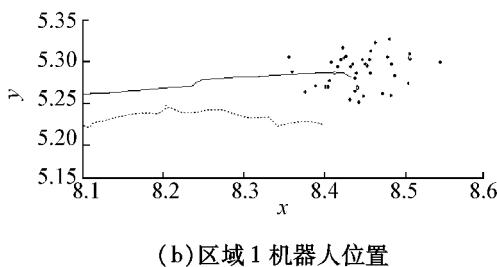
有效性,仿真是在 Matlab7.0 环境下进行的,假设环境中包含若干个标志柱、一个机器人以及一个目标。为了减少问题的复杂性,假设环境中不存在障碍物,机器人能够感知一定范围内的目标和标志柱,并且获得以方向和深度为表征的观测值。另外,机器人会根据目标位置调整输入使其能够追踪目标,而目标速度及角速度控制量为恒定值。

3.1 实验 1

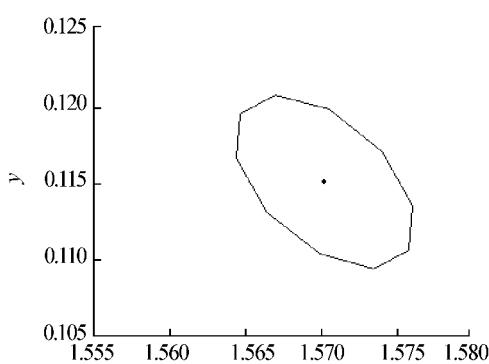
假设环境为 $10 \times 10 \text{ m}^2$,其中均匀分布着 20 个标志柱,算法采用的粒子数为 200,并假设机器人速度和角度控制噪声方差阵为 $\text{diag}(0.4 \text{ m}, 0.0872 \text{ rad})$ 。目标速度和角度控制噪声方差阵为: $\text{diag}(0.8 \text{ m}, 0.6 \text{ rad})$, 观测的误差协方差阵为: $\text{diag}(0.1^2 \text{ m}, 0.008^2 \text{ rad})$, 仿真实验迭代 320 次并且假设 8 次迭代发生 1 次观测,这样的实验共进行了 20 次,其中一次实验结果场景如图 3 所示。



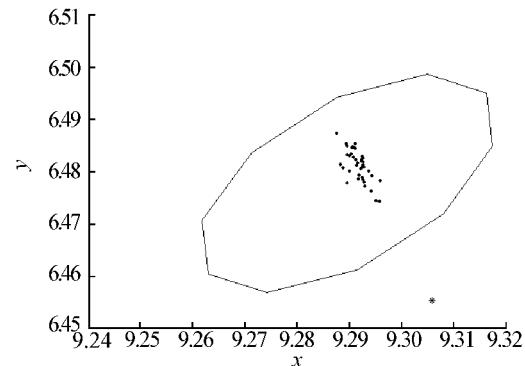
(a) 仿真结果



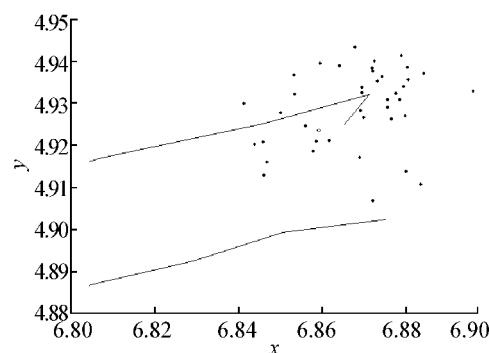
(b) 区域 1 机器人位置



(c) 区域 2 标志柱粒子



(d) 区域 3 标志柱粒子



(e) 区域 4 目标位置

图 3 SLAMTO 仿真结果

Fig. 3 Simulation results of SLAMTO

图 3 中,星点代表标志点的实际位置,以下结论是在多次仿真基础上得出的,运用一次仿真结论只是为了说明方便。由于观测频率相对于环境更迭频率较慢(1:8),运动噪声较大以及机器人定位误差的传播导致目标定位误差大于机器人定位的误差(误差均值 0.039 3, 误差均方差 0.013 6),尽管如此,对目标的定位仍比较准确(误差均值 0.063 9, 误差均方差 0.010 4)。图 3(b)~(e) 是特定区域的放大图,其中图 3(b)、(e) 中粒子群代表对机器人和目标的位置估计,图 3(c)、(d) 中粒子群代表对应标志柱的估计值,要注意的是图 3(b)、(e) 中和图 3(c)、(d) 中的粒子是对的,即图 3(b)、(e) 中粒子是 s_k 中对应的 s_k^i 和 μ_k^{ij} 分量,而图 3(c)、(d) 中粒子是 s_k 中对应第 3 个和第 12 个标志柱的均值分量。图 3(b)、(e) 中由于重采样的作用代表机器人和目标位置的粒子群分布集中并且多数粒子分布重合,因此粒子群分布能够代表机器人和目标的位置。对于图 3(d) 来说所有粒子均重合,这同样是重采样的结果,因为对于该标志点的观测早已发生,在跌代的过程中误差较大的粒子逐步被误差小的粒子取代,最终只有早期单个离子对应的该标志点位置估计保留下来。而图 3(c) 中对应标志点的粒子群较为分散,这是因为该标志点刚刚发现,重采样过程还没

有将粒子分布单一化。

接下来分析机器人运动轨迹对状态估计的影响,从图3中可见,标志点 LandMark1 的误差较大,其原因是机器人在追随目标过程中由于观测视野的限制对于该标志点的观测次数较少,没有能够进一步利用观测值来纠正误差。另外,在跟踪的前期(a 点~ b 点)对于目标的定位误差较大(均值为0.073 6),而后期(b 点~ c 点)误差变的相对较小(均值为0.054 2),造成这种现象的原因是,前期阶段机器人距离目标较远因此观测所引入的误差较大,而随着机器人和目标的距离缩小,观测误差也随之变小,从而对于目标的定位也变得准确。由此可见,如何设计巡游策略使机器人能够同时较准确地估计标志点和目标的位置对于 SLAMT 问题至为重要,这也将是今后研究的重点。

3.2 实验2

分析粒子数量对机器人和目标定位的影响,每次仿真除了粒子数外其他设置和实验1相同,针对不同粒子数分别进行20次仿真,其平均定位误差均值和均方差如图4所示。

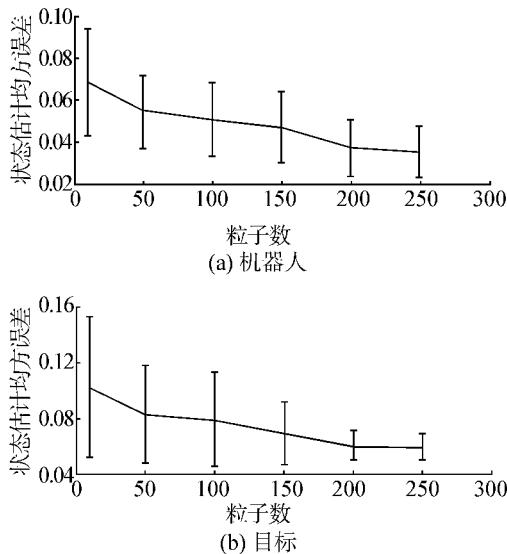


图4 机器人和目标定位精度随粒子个数变化

Fig.4 Localization accuracy of robot and target as a function of the number of particles

从结果可知,随着粒子数的增加定位精度逐步提高,但精度提高的幅度逐渐变小,相比来说机器人定位精度更高,这是由于对于目标的定位是在机器人定位基础上进行的,因此机器人定位误差将会传播到目标定位误差上使其误差增加。

3.3 实验3

分析标志点数量对于机器人和目标定位的影响,仿真中除了标志点个数不同外其余条件与实验

1相同,针对不同标志点数分别进行20次仿真,每次仿真的标志点分布服从均匀分布并随机产生,将所有结果取平均得到定位误差均值和均方差如图5所示。

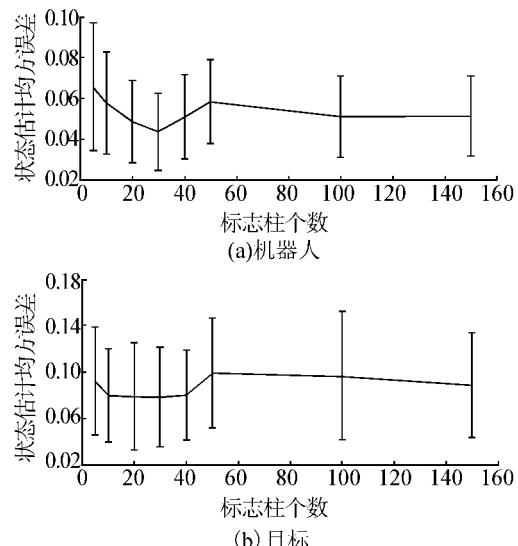


图5 机器人和目标定位精度随标志柱个数变化

Fig.5 Localization accuracy of robot and target as a function of the number of landmarks

由图5可知,对机器人和目标的定位精度并非随着标志柱数量的增加而提高,定位精度存在一个饱和值,因此,在具体应用中并不需要将所有发现的环境特征都纳入估计中,否则会增加系统的运算量,只需选择合适的环境特征即可,选择标准将是下一步研究的内容。

为了验证算法的准确性,以下将本文算法所得的定位误差同机器人 SLAM 和目标跟踪独立进行估计所得的定位误差进行对比。结果为100次蒙特卡罗实验得到的误差平均值和方差,算法中粒子数量为300个,环境特征数为100个,对比结果如表1所示。

表1 算法定位准确性对比

Table 1 Localization accuracy comparison between algorithms

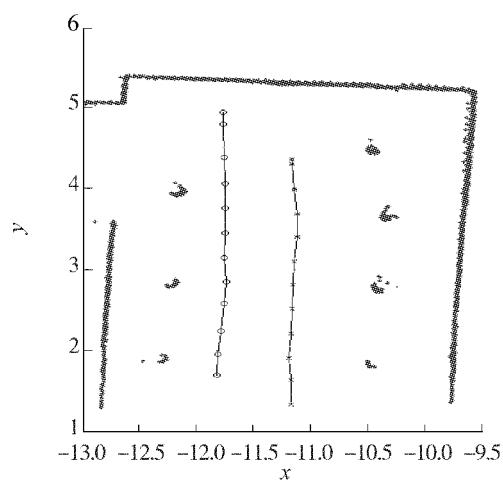
均方 误差	本文算法				独立估计结果		
	机器人 定位 误差	目标运动 方向误差	目标定 位误差	机器人 定位 误差	目标运动	目标定	位误差
					方向误差	位误差	
均值	0.043	0.052	0.062	0.095	0.062	0.132	
方差	0.007	0.002	0.012	0.026	0.004	0.063	

从表1可见,本文设计算法在机器人定位精度上与独立估计结果基本相同,但在对目标的定位精度上却明显高于后者,这是由于算法在进行状态估计时,将机器人和目标状态作为估计整体,从而引入了机器人和目标的相关性,使对目标的状态估计更加准确。

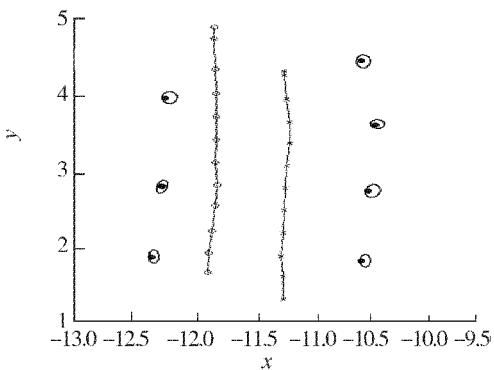
最后将利用2台Pioneer3DX实体机器人验证该方法的实用性。实验环境如图6(a)所示,机器人 R_1 和目标机器人 R_2 均以直线轨迹穿过布满标志柱的环境,为了检测到目标机器人(R_2),对其用色块进行标注。当 R_1 检测到 R_2 时将根据方向信息并利用激光扫描仪返对 R_2 的深度和角度观测值。图6(b)显示了利用本文方法得到的 R_1 和 R_2 的运行轨迹以及扫描点的分布图。



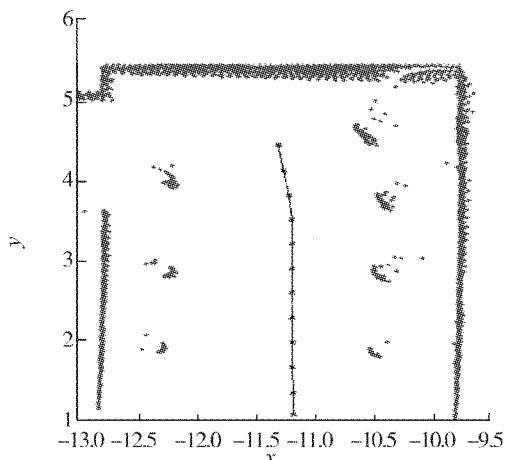
(a) 实验环境



(b) 扫描点分布以及目标、机器人轨迹



(c) 标志柱不确定性分布



(d) 轮盘编码器定位扫描点分布

图6 实体机器人实验结果

Fig. 6 Results of real robot experiment

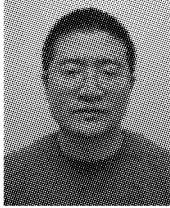
图6(c)显示了得到的标志柱不确定性分布和 R_1, R_2 的轨迹图。图6(d)显示了只用轮盘编码器得到的结果图,对比图6(b)和图6(d)可见,运用本文设计方法得到的扫描点分布的一致性明显优于只用轮盘编码器进行定位的结果。

4 结束语

本文针对机器人同时定位、地图构建与目标跟踪问题提出了一种基于粒子滤波的解决方法。该方法的特点在于将机器人SLAM和目标状态估计作为整体进行粒子滤波估计,从而在系统状态估计过程中引入了机器人状态、环境特征状态以及目标状态之间的相关性,进而提高了目标状态估计的准确性。该算法为解决更为复杂的机动目标跟踪问题铺平了道路,并拓宽了传统SLAM的应用范围,使之能够应用到诸如未知环境下机器人围捕、入侵检测等实际任务中。

参考文献:

- [1] BESL P J, MCKAY N D. A method for registration of 3-D shapes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239-256.
- [2] FU L, MILIOS E. Robot pose estimation in unknown environments by matching 2D range scans[J]. Journal of Intelligent and Robotic Systems, 1997, 18: 249-275.
- [3] MINGUEZ J, LAMIRAUD F, MONTESANO L. Metric-based scan matching algorithms for mobile robot displacement estimation [C]//Proceedings of IEEE International Conference on Robotics and Automation. Barcelona: IEEE Computer Society, 2005: 563-570.
- [4] CHATILA R, LAUMOND J P. Position referencing and consistent world modeling for mobile robots[C]//Proceed-

- ings of IEEE International Conference on Robotics and Automation. St Louis, USA: IEEE Computer Society, 1985: 138-145.
- [5] SMITH R, SELF M, CHEESEMAN P. A stochastic map for uncertain spatial relationships[C]//Proceedings of International Symposium of Robotics Research. Santa Cruz: University of California, 1987: 467-474.
- [6] SMITH R, SELF M, CHEESEMAN P. Estimating uncertain spatial relationships in robotics. autonomous robot vehicles [M]. New York: Springer-Verlag, 1990: 167-193.
- [7] MONTEMERLO M, THUN S, KOLLER D, et al. FastSLAM: a factored solution to simultaneous mapping and localization[C]//Proceedings of the National Conference on Artificial Intelligence. [S. l.]: The AAAI Press, 2002: 593-598.
- [8] MONTEMERLO M, THUN S, KOLLER D, et al. FastSLAM 2.0: an improved particle filtering algorithm for simultaneous localization and mapping that provably converges[C]//Proceedings of International Joint Conference on Artificial Intelligence. Acapulco: The AAAI Press, 2003: 1151-1157.
- [9] HAHNEL D, WEGBREIT B, FOX D, et al. An efficient FastSLAM algorithm for generating maps of large-scale cyclic environments from raw laser range measurements[C]// Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems. Las Vegas: IEEE Computer Society, 2003: 206-211.
- [10] WANG C C, THORPE C. Simultaneous localization and mapping with detection and tracking of moving objects [J]. International Journal of Robotics Research, 2007, 26(9): 889-916.
- [11] WANG C C, THORPE C, THRUN S. Online simultaneous localization and mapping with detection and tracking of moving objects: theory and results from a ground vehicle in crowded urban areas[C]//Proceedings of the IEEE International Conference on Robotics and Automation. Taipei, China: IEEE Computer Society, 2003: 842-849.
- [12] BORRMANN D, ELSEBERG J, LINGEMANN K. Globally consistent 3D mapping with scan matching[J]. Robotics and Autonomous Systems, 2008, 56: 130-142.
- [13] SANJEEV A, SIMON M, GORDON N. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking [J]. IEEE Transactions on Signal Processing, 2002, 50(2): 174-188.
- 作者简介:**
- 

伍明,男,1981年生,讲师,博士,主要研究方向为自主机器人控制、多机器人协作、机器人环境构建。
- 

孙继银,男,1952年生,教授、博士生导师,国家“863”计划评审专家,二炮导弹技术专家,中国计算机学会高级会员,中国计算机用户协会理事。全军先进教育工作者,享受国务院特殊津贴,多项科研成果获全军科技进步奖。发表学术论文70余篇。