

基于自适应观测模型的移动机器人室内蒙特卡罗动态定位系统研究^①

郑文磊^{②*} 程 嵘^{③*} 余秋月^{*} 陈泓宇^{*} 吴秋轩^{**}

(^{*} 武汉科技大学信息科学与工程学院 武汉 430081)

(^{**} 杭州电子科技大学自动化学院 杭州 310018)

摘要 针对存在玻璃门、动态行走的行人的环境时,传统的蒙特卡罗移动机器人定位算法因环境噪声的增大致使观测信息剧烈变化导致定位性能下降的问题,提出了一种基于改进的观测模型的蒙特卡罗定位(MCL)算法。该算法通过在观测模型中引入测量失败误差和动态误差提高激光传感器测量数据的有效性,利用激光传感器测得数据匹配已创建的占用栅格地图,检测已知环境是否发生变化,从而改变随机误差、测量失败误差、动态误差对应的权重,降低噪声对测量值的影响,提高在复杂环境下的定位准确性。基于机器人操作系统(ROS)进行了实验,实验结果表明该算法具有较好的有效性。

关键词 蒙特卡罗定位(MCL)算法, 观测信息, 激光传感器, 占用栅格地图, 机器人操作系统(ROS)

0 引言

移动机器人定位是利用先验地图信息、机器人位置的当前估计即传感器的观测值等输入信息,经过一定的处理和变换,对机器人在导航环境中所处的当前地理位置的估计过程^[1]。传统的机器人自定位算法有航迹推演算法^[2],扩展卡尔曼滤波算法^[3]。其中扩展卡尔曼滤波算法采用非线性近似求解来得到满意的位姿估计值。但该算法仅仅采用了非线性系统泰勒展开式一阶导数部分,常常导致在估计状态后验分布时产生较大的误差,影响机器人自定位的准确性。近些年,一种基于蒙特卡罗思想的非线性、非高斯系统的粒子滤波算法^[4-6]得到广泛地应用。该算法通过预测和更新系统概率密度函数的样本集,来近似估计机器人位姿,其在处理非高斯、非线性系统的状态估计问题方面具有独特的

优势和广阔的前景。Doucet^[7]在前人研究的基础上给出了基于序贯重采样的粒子滤波方法,即利用序贯重采样在动态状态空间得到一组粒子,其中每个粒子都对应一个权重值,然后通过对这些粒子状态加权来获得机器人位姿的估计值。但该方法采样大量粒子来减少环境噪声对其算法准确性的影响,从而增加了算法的时间复杂度。Fox^[8,9]等人提出了Kullback-Leibler距离(KLD)采样算法,该算法采用KL距离,即机器人状态的后验分布的真值与估计值之间的误差限,来调整每次滤波的粒子数,即当机器人状态分布不确定性较大时采用较多的粒子,反之采用较少的粒子。但是该算法的计算复杂度过高。与此同时,上述定位方法在面对复杂环境时,如存在玻璃门以及动态行走的行人时,由于环境信息较为复杂,传感器测得的观测信息噪声较大,导致定位算法精度下降,甚至出现定位丢失情形。因此本论文提出一种改进的观测模型的蒙特卡罗定位(Monte

^① 国家自然科学基金(60705035,61203331,61573263),湖北省自然科学基金(2014CFB813),湖北省科技支撑计划(2015BAA018),湖北省教育厅科研计划重点项目(D20131105),国家级大学生创新创业训练计划(201610488009)和杭州电子科技大学重中之重学科开放基金和浙江省自然科学基金(LY16F030007)资助项目。

^② 男,1993年生,硕士生;研究方向:智能机器人及其导航控制;E-mail: zhengwenlei93@163.com

^③ 通信作者,E-mail: chenglei@wust.edu.cn

(收稿日期:2016-06-12)

Carlo localization, MCL) 算法, 并通过激光传感器测得的数据去匹配已构建的栅格地图, 判断已知环境是否发生变化, 如静态环境中出现行走的行人, 以及出现的玻璃门或者吸收光线的物体, 其较容易使观测数据产生较大的噪声, 导致测量精度下降, 进而机器人定位算法结果不确定性增大。因此通过改变观测模型中误差因素对应的权重, 降低噪声对传感器测得数据的影响, 从而提高算法的准确性。本论文选取适当的粒子数, 通过实验证明了该算法的有效性。

1 移动机器人自定位算法

1.1 蒙特卡罗定位(MCL) 算法

Gordon^[10] 等人在 1993 年提出了粒子滤波算法, 并逐步受到人们的重视, 并被应用到多个领域中, 取得了良好的效果。该算法主要思想是根据系统状态向量的先验分布在状态空间产生一组随机样本的集合, 然后根据观测量不断调整粒子的权重和位置, 通过调整后的粒子信息修正最初的先验分布。当样本容量趋近无穷大时, 就近似于状态变量的真正的后验概率密度函数。

在机器人定位研究中, 假定机器人的状态空间模型描述表示如下:

$$\begin{aligned} \mathbf{x}_k &= f_k(\mathbf{x}_{k-1}, v_{k-1}) \\ \mathbf{z}_k &= h_k(\mathbf{x}_k, n_k) \end{aligned} \quad (1)$$

其中, \mathbf{x}_k 表示 k 时刻状态向量, f_k 表示状态转移函数, v_{k-1} 表示过程噪声, \mathbf{z}_k 表示观测向量, h_k 表示测量函数, n_k 表示测量噪声。

根据贝叶斯理论可知, 假设概率密度函数 $p(\mathbf{x}_0 | \mathbf{z}_0) = p(\mathbf{x}_0)$ 已知, 状态估计问题就是根据之前一系列的已有数据 \mathbf{z}_k 递推计算出当前状态 $p(\mathbf{x}_k | \mathbf{z}_{1:k})$ 的可信度。假定 $k-1$ 时刻的概率密度函数 $p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1})$ 已知, 则预测系统在下一时刻的先验概率分布如下:

$$\begin{aligned} p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) &= \int p(\mathbf{x}_k, \mathbf{x}_{k-1} | \mathbf{z}_{1:k-1}) d\mathbf{x}_{k-1} \\ &= \int p(\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1}) d\mathbf{x}_{k-1} \end{aligned} \quad (2)$$

其中系统状态转移满足一阶马尔可夫过程, 即 $p(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{z}_{1:k-1}) = p(\mathbf{x}_k | \mathbf{x}_{k-1})$ 。传感器在时刻 k 获得测量值 \mathbf{z}_k , 从而利用贝叶斯公式对先验概率密度进行更新, 得到 k 时刻的后验概率。

$$p(\mathbf{x}_k | \mathbf{z}_{1:k}) = \frac{p(\mathbf{z}_k | \mathbf{x}_k, \mathbf{z}_{1:k-1}) p(\mathbf{x}_k | \mathbf{z}_{1:k-1})}{p(\mathbf{z}_k | \mathbf{z}_{1:k-1})} \quad (3)$$

其中 $p(\mathbf{z}_k | \mathbf{z}_{1:k-1})$ 为归一化常数: $p(\mathbf{z}_k | \mathbf{z}_{1:k-1}) = \int p(\mathbf{z}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{y}_{k-1})$ 。

综上可得, 贝叶斯滤波以递推的形式给出后验概率密度函数的最优解。但是, 对于非线性、非高斯模型, 消去中间参数和其他未知参量所涉及的计算复杂并且困难, 难以获得解析式来求解上述的概率密度函数。因此, 在非线性、非高斯情形下, 采用近似算法来获得状态估计, 而蒙特卡罗算法就是一种近似求解后验概率密度函数的方法。

在蒙特卡罗算法中, 利用 $\{\mathbf{x}_{0:k}^i, w_k^i\}_{i=1}^N$ 描述 k 时刻目标状态 \mathbf{x}_k 的后验概率分布 $p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k})$, $\{\mathbf{x}_{0:k}^i, i = 0, \dots, N\}$ 是对应权值为 $\{w_k^i, i = 0, \dots, N\}$ 的粒子集合, 其中 $\mathbf{x}_{0:k} = \{\mathbf{x}_j, j = 0, \dots, k\}$ 是 0 到 k 时刻的状态集合。其权值被归一化为 $\sum_i^{N=k} w_k^i = 1$, 则 k 时刻目标状态的后验概率分布离散地加权为

$$p(\mathbf{x}_k | \mathbf{z}_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i) \quad (4)$$

因此由蒙特卡罗方法直接估计的后验概率, 可以进一步推算出当前状态的期望值:

$$\begin{aligned} E[f(\mathbf{x}_k)] &\approx \int f(\mathbf{x}_k) p(\mathbf{x}_k | \mathbf{z}_{1:k}) d\mathbf{x}_k \\ &= \sum_{i=1}^N \int f(\mathbf{x}_k) w_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i) d\mathbf{x}_k \\ &= \sum_{i=1}^N w_k^i f(\mathbf{x}_k^i) \end{aligned} \quad (5)$$

其中 $f(\mathbf{x}_k)$ 是每个粒子的状态函数; $E[f(\mathbf{x}_k)]$ 是采样的粒子的状态值加权得到的期望值。

但是从后验密度函数中采样过程繁杂, 因此从已知的重要密度函数 $q(\mathbf{x}_{0:k} | \mathbf{z}_{1:k})$ 中进行采样。假设重要概率密度函数可以分解为 $q(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}) = q(\mathbf{x}_{0:k-1} | \mathbf{z}_{1:k-1}) q(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{z}_{1:k})$ 。其后验概率密度函数的递归形式可以表示为

$$\begin{aligned}
p(\mathbf{x}_{0:k} \mid \mathbf{z}_{1:k}) &= \frac{p(\mathbf{z}_k \mid \mathbf{x}_{0:k}, \mathbf{z}_{1:k-1}) p(\mathbf{x}_{0:k} \mid \mathbf{z}_{1:k-1})}{p(\mathbf{z}_k \mid \mathbf{z}_{1:k-1})} \\
&= \frac{p(\mathbf{z}_k \mid \mathbf{x}_k) p(\mathbf{x}_k \mid \mathbf{x}_{k-1}) p(\mathbf{x}_{0:k-1} \mid \mathbf{z}_{1:k-1})}{p(\mathbf{z}_k \mid \mathbf{z}_{1:k-1})} \\
&\propto p(\mathbf{z}_k \mid \mathbf{x}_k) p(\mathbf{x}_k \mid \mathbf{x}_{k-1}) p(\mathbf{x}_{0:k-1} \mid \mathbf{z}_{1:k-1})
\end{aligned} \tag{6}$$

因此其重要性权值更新公式^[5]为

$$\begin{aligned}
w_k^i &\propto \frac{p(\mathbf{x}_{0:k}^i \mid \mathbf{z}_{1:k})}{q(\mathbf{x}_{0:k}^i \mid \mathbf{z}_{1:k})} \\
&= \frac{p(\mathbf{z}_k \mid \mathbf{x}_k^i) p(\mathbf{x}_k^i \mid \mathbf{x}_{k-1}^i) p(\mathbf{x}_{0:k-1}^i \mid \mathbf{z}_{1:k-1})}{q(\mathbf{x}_k^i \mid \mathbf{x}_{0:k-1}^i, \mathbf{z}_{1:k-1}) q(\mathbf{x}_{0:k-1}^i \mid \mathbf{z}_{1:k-1})} \\
&= w_{k-1}^i \frac{p(\mathbf{z}_k \mid \mathbf{x}_k^i) p(\mathbf{x}_k^i \mid \mathbf{x}_{k-1}^i)}{q(\mathbf{x}_k^i \mid \mathbf{x}_{0:k-1}^i, \mathbf{z}_{1:k-1})} \tag{7}
\end{aligned}$$

由上述推导可得,经典蒙特卡罗算法流程为

(1) 初始状态:用大量粒子模拟 $x(t)$, 粒子在空间内均匀分布。

(2) 预测阶段:根据状态转移方程,每个粒子得到一个预测粒子。

(3) 校正预测:对预测粒子进行评价,更新每个粒子的权重,越接近与真实状态的粒子,其权重越大。

(4) 重采样:根据粒子权重对粒子进行筛选。筛选过程中,既要保留权重大的粒子,又要保留一小部分权重小的粒子,得到新的粒子集,并使新的粒子集每个粒子的权重归一化为 $1/N$ 。

(5) 滤波:将重采样后的粒子带入状态转移方程中,得到新的预测粒子,即预测阶段。

1.2 改进观测模型的 MCL 算法

对于移动机器人而言,在已知或者未知的环境中自主行走,定位是最基本的问题。由于传统的机器人观测模型仅仅考虑由传感器自身精度、测量范围以及自身的物理因素所引起的观测误差,其概率模型一般是以理想测量距离为均值的高斯模型,其模型为

$$p_{\text{hit}}(z_t^k \mid x_t, m) = \begin{cases} \eta N(z_t^k, z_t^{k*}, \sigma_{\text{hit}}^2), & 0 \leq z_t^k \leq z_{\max} \\ 0, & \text{其他} \end{cases} \tag{8}$$

其中 z_t^{k*} 是从地图 m 上从位姿 x_t 沿激光束方向到障碍物的实际距离, z_t^k 是传感器测量距离, σ_{hit} 是高斯模型的标准方差, η 是归一化常数。

然而机器人自主行走在复杂的动态的未知环境中,比如行走的人或者易穿透的玻璃门,这样使经典蒙特卡罗定位算法结果带来很大不确定性,导致定位精度下降,不能高效率地使机器人从环境中穿行并到达指定的目标点。本论文为了克服这些问题,在观测模型中加入动态物体带来的误差和测量失败的误差,并利用栅格地图进行辅助定位。

(1) 动态物体误差

在机器人导航过程中,其周围环境动态变化,而保存的地图是静态的。当行人出现在机器人行走的环境中有时会产生一个较小的测量噪声。当传感器检测到障碍物的距离较大时,检测到动态物体的概率较小,其概率随距离的增大呈指数下降趋势,因此其概率模型如下:

$$P_{\text{short}}(z_t^k \mid x_t, m) = \begin{cases} \eta \lambda_{\text{short}} e^{-\lambda_{\text{short}} z_t^k}, & 0 \leq z_t^k \leq z_t^{k*} \\ 0, & \text{其他} \end{cases} \tag{9}$$

其中 λ_{short} 为指数分布的固有参数, η 是归一化常数。

(2) 测量失败误差

当传感器探测环境信息时,有时检测不到障碍物。例如当检测到玻璃墙或者吸收光线的物体时,此时的检测数据为无效数据。在此情形时,将传感器最大探测距离作为返回的检测数据。其概率模型为

$$p_{\text{max}}(z_t^k \mid x_t, m) = \begin{cases} 1, & z = z_{\max} \\ 0, & \text{其他} \end{cases} \tag{10}$$

其中 z_{\max} 为激光传感器检测的最大距离。因此最终的加权概率密度模型表示如下:

$$p(z_t^k \mid x_t, m) = \begin{pmatrix} z_{\text{hit}} \\ z_{\text{short}} \\ z_{\max} \end{pmatrix}^T \cdot \begin{pmatrix} p_{\text{hit}}(z_t^k \mid x_t, m) \\ p_{\text{short}}(z_t^k \mid x_t, m) \\ p_{\text{max}}(z_t^k \mid x_t, m) \end{pmatrix} \tag{11}$$

通过引进动态误差、测量失败误差降低测量数据中的噪声,提高定位算法的精度。另一方面,在机器人复杂拥挤的环境时,其观测误差模型的 3 个权重值不能动态地根据环境变化而调整,因此通过搭载在机器人上的激光传感器,绘制出环境占用栅格

地图(occupancy grid mapping)作为辅助定位。当机器人自主行走在已知环境中时,利用激光数据匹配已创建的占用栅格地图,如果匹配局部环境地图失败,或者检测到占用栅格地图中,一些原先占有率较

低的位置其占有率变得较高时,表示已知环境信息发生了较大变化,因而动态改变观测模型中 z_{hit} , z_{short} , z_{max} 的权重值,进而减少传感器测量数据的噪声。具体改进算法流程如下:

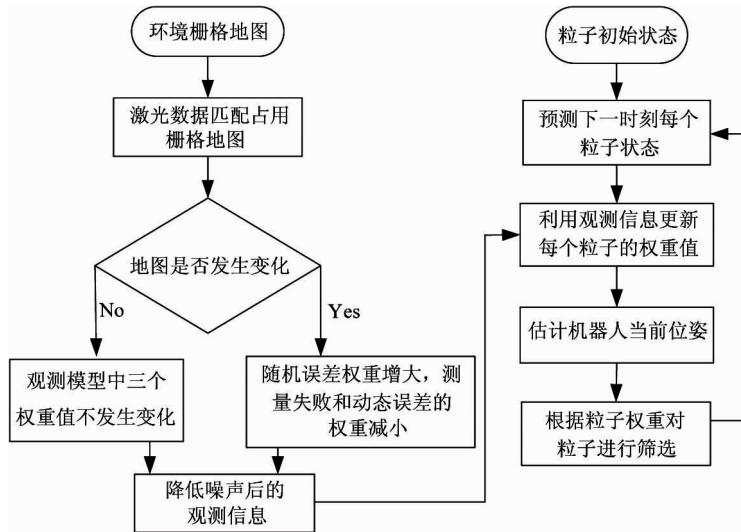


图1 自适应观测模型的改进算法流程图

2 实验结果与分析

本实验平台为 Ubuntu 系统下搭载机器人操作系统(robot operating system, ROS)的全向轮 JS 智能机器人,其上装有编码器和激光传感器,可以采集里

程计数据和感知环境信息。通过 ROS 中 RVIZ 可可视化界面软件,显示已创建的占用栅格地图,以及实时显示的激光数据和粒子的位姿分布。如图 2 所示,左边窗口为添加需要显示的话题栏,中间窗口为显示选中话题的具体内容。

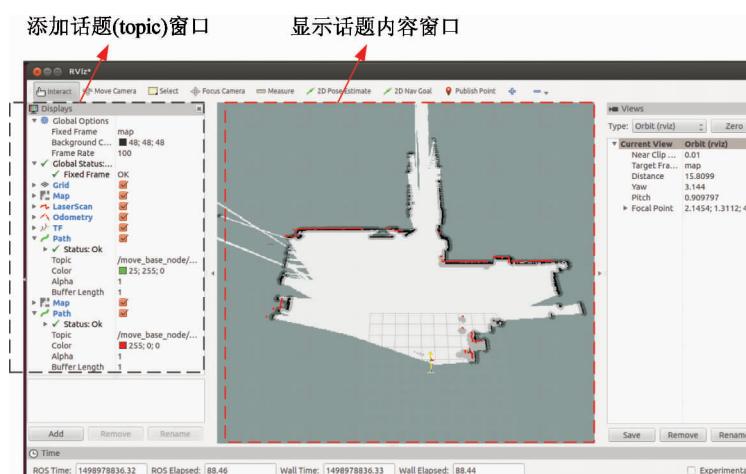


图2 基于 ROS 的可视化界面

2.1 ROS 框架介绍

2010 年 Willow Garage 公司发布了机器人操作

系统(ROS),由于其具有点对点设计、不依赖编程语言、开源等优点,很快在机器人领域展开了学习和使

用 ROS 的热潮。ROS 是一种分布式处理框架,这使可执行文件能被单独设计,并且在运行时松散耦合。这些过程可以封装到数据包和堆栈(stacks)中,以便于共享和发布。占用概率栅格地图的创建采用 ROS 官网发布的软件包 GMapping^[11]。该功能包提供了基于激光的 SLAM 算法,并创建 slam_gmapping 节点(nodes)。该节点通过订阅(subscribe)移动平台发布的 odom 话题(topic)和激光测距仪节点发布(publish)的 scan 话题,获取话题中的数据,创建出实验室占用栅格地图。

2.2 实验分析

本文将实验分为两部分:第一部分,以静态环境和相同的粒子数作为对比因素,对比里程计测量法、经典蒙特卡罗定位(MCL)算法、改进蒙特卡罗定位算法(IMCL)定位的精度;第二部分,以动态环境和相同的粒子数作为对比因素,对比静态环境时改进的蒙特卡罗算法定位的精度。其中实验环境是 8m × 9m 的走廊环境。算法参数设置如下,激光最大扫描距离为 $z_{\max} = 10\text{m}$, 扫描范围 $\theta \in [0^\circ, 180^\circ]$, 采用的粒子数 $N = 300$, 概率栅格地图的分辨率为



(a) 真实环境

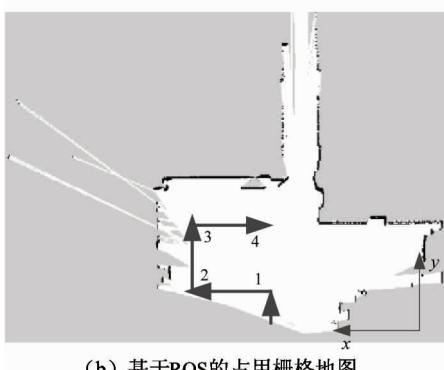


图 3 定位算法对比实验环境

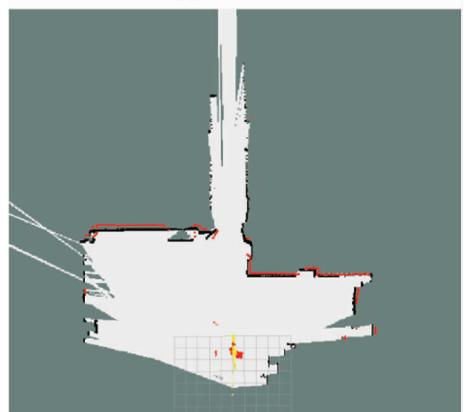
0.5, 分别对应的初始 z_{hit} , z_{short} , z_{\max} 权重值为 0.8, 0.1, 0.1。

2.3 静态环境下定位算法分析

基于 ROS 平台下室内机器人自适应观测模型蒙特卡罗定位实验设计如下。其中图 4(a)为定位时初始化粒子在环境中的分布图,图 4(b)为机器人行走一段时间的粒子收敛图。



(a) 粒子初始化



(b) 最终收敛

图 4 定位时粒子分布图

为分析存在玻璃材质门对静态实验环境对定位算法精度的影响,设计如下实验。首先在静态实验环境中,通过激光传感器绘制环境占用栅格地图,并在实验走廊中设置 4 个目标点,控制 JS 智能机器人自主依次从起始点运动到终点,行走过程中机器人分别采用相同粒子数的经典的蒙特卡罗定位算法和改进的蒙特卡罗定位算法,并以一定采样频率采集机器人在环境中的位姿信息,最后通过 Matlab 软件处理获取的机器人位姿信息,如图 5 所示。

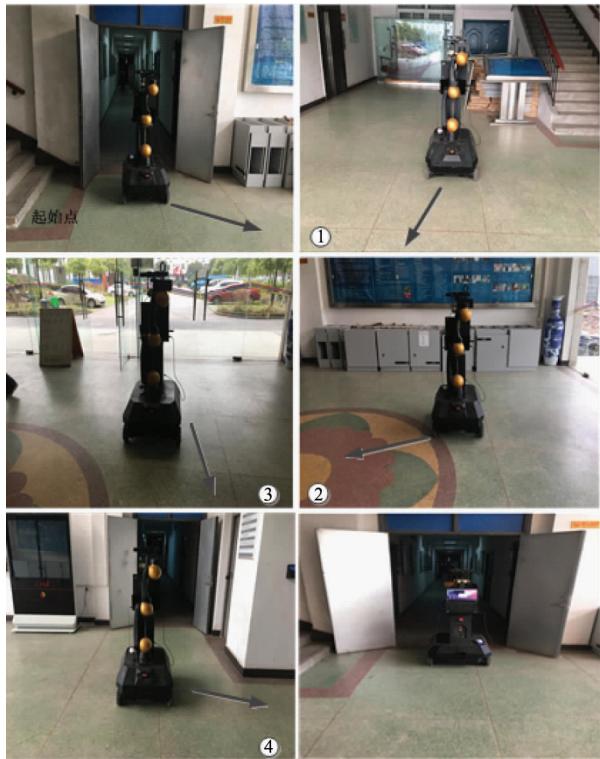


图 5 静态环境实验测试

由图 6 和表 1 可知,随着机器人移动的位移增加,改进的蒙特卡罗算法的定位精度高于经典蒙特卡罗算法和里程计法。其中里程计法由于累积误差的出现,其定位精度逐渐下降,随着位移的增加,利用里程计法测得的机器人 4 个目标位置与实际位置

相比平均误差为 30cm 左右,其定位精度较低。另一方面,由于目标点 2 与 3 之间的环境中存在较多玻璃材质门,使得激光传感器测得的数据误差较大,导致经典蒙特卡罗算法测得机器人在目标点 2 和 3 位置相对真实位置平均误差为 18cm 左右。而改进的蒙特卡罗算法由于考虑其测量失败噪声模型,其动态改变 3 个误差权重值分别为 0.88, 0.09, 0.03, 因此其算法估计的位置相对真实位置偏离 8cm。由表 1 误差分析可知,机器人分别到达目标点中,其改进观测模型的蒙特卡洛定位算法精度较为精确。

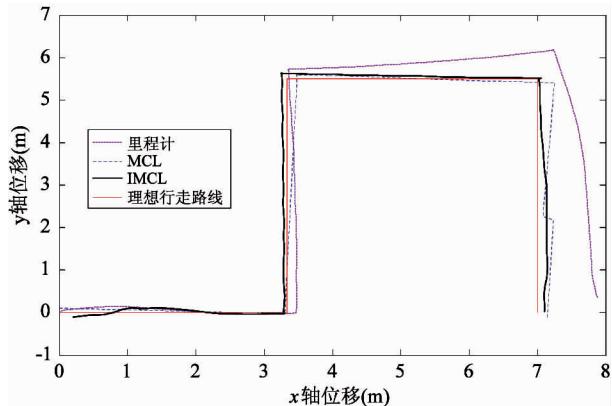


图 6 不同算法测得机器人轨迹

表 1 不同算法测得机器人在目标点时的位置 (m)

目标点	1	2	3	4
里程计	(3.461, -0.014)	(3.356, 5.732)	(7.236, 6.183)	(7.871, 0.383)
MCL	(3.312, -0.010)	(3.482, 5.593)	(7.253, 5.409)	(7.148, -0.075)
IMCL	(3.310, -0.017)	(3.247, 5.629)	(7.053, 5.522)	(7.103, 0.035)
理想路线	(3.300, 0.000)	(3.300, 5.500)	(7.000, 5.500)	(7.000, 0.000)
里程计误差	(0.161, -0.014)	(0.056, 0.232)	(0.236, 0.683)	(0.871, 0.383)
MCL 误差	(0.012, -0.010)	(0.182, 0.093)	(0.253, 0.091)	(0.148, -0.075)
IMCL 误差	(0.010, -0.017)	(0.053, 0.129)	(0.053, 0.022)	(0.103, 0.035)

2.4 动态环境定位算法分析

为验证环境中行人走动、玻璃材质门和阳光对定位算法的影响,设计如下实验。行人随机行走在阳光照射的实验环境中,机器人自主移动到目标点期间,采用改进的蒙特卡罗算法,滤除阳光照射、玻璃材质门以及行走的行人对激光影响的数据。其次通过激光匹配已知占用栅格地图,实时检测环境是

否发生变化,如机器人前进时,走廊上的门人为地关闭。此时通过测得的激光数据匹配已知局部栅格地图,计算得出匹配率为 89.09%,证明其环境发生了变化,进而动态改变观测噪声模型的 3 个权重值。其中测得此时激光数据内容、激光数据匹配局部环境地图如图 7、图 8 所示。

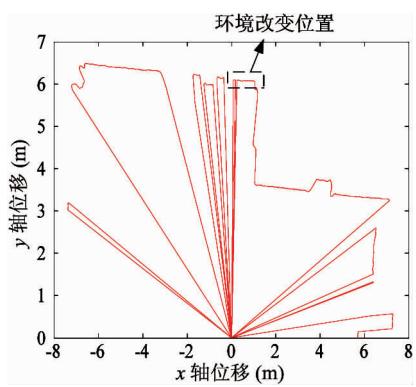


图 7 激光数据内容



图 8 激光匹配局部栅格地图

然后在动态环境中继续使机器人自主移动到目标点,采集机器人运动轨迹,对比静态环境时改进的蒙特卡罗定位算法移动相同路径的轨迹,结果如图 9、图 10 所示。



图 9 动态环境实验测试

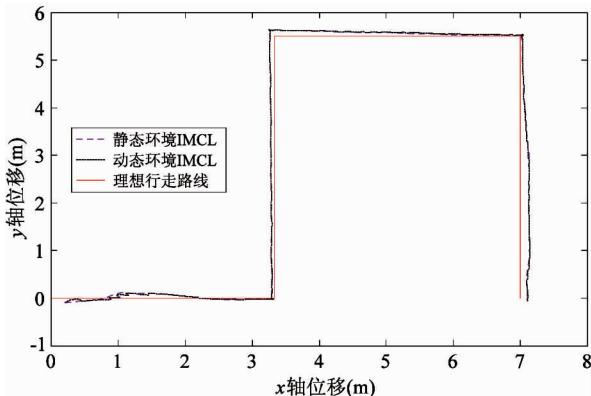


图 10 不同环境下 IMCL 定位算法对比

表 2 不同环境下 IMCL 定位位置 (m)

目标点	1	2	3	4
静态 IMCL	(3.310, -0.017)	(3.247, 5.629)	(7.053, 5.522)	(7.103, 0.035)
动态 IMCL	(3.298, -0.021)	(3.249, 5.632)	(7.055, 5.537)	(7.110, -0.051)
理想路线	(3.300, 0.000)	(3.300, 5.500)	(7.000, 5.500)	(0.871, 0.383)
静态 IMCL 误差	(0.010, -0.017)	(0.053, 0.129)	(0.053, 0.022)	(0.103, 0.035)
动态 IMCL 误差	(0.002, -0.021)	(0.051, 0.132)	(0.055, 0.037)	(0.110, -0.051)

由图 9、图 10 和表 2 可知,在动态环境中,行人的走动以及阳光照射和玻璃材质门对激光测得数据有一定的影响,通过改进观测模型的蒙特卡罗定位算法,可有效地剔除无效的激光数据点,提高机器人

在动态复杂环境下的定位精度。其次机器人根据激光传感器数据匹配环境占用栅格地图,辅助地动态调整观测模型中 3 个权重值,提高激光数据的有效性,进而提高定位算法的精度。由表 2 可知,机器人

行走在存在玻璃材质门以及行人走动的目标点 2 和 3 之间环境中时, 动态调整 3 个误差权重值 z_{hit} , z_{short} , z_{max} 分别为 0.91, 0.05, 0.04, 此时其定位的精度与静态环境时 IMCL 的定位精度近似, 其偏差都在 8cm 左右, 能准确定位机器人在环境中的位置。因此, 该算法在较为复杂环境时, 具有较好的准确性。

3 结 论

针对存在玻璃门、动态行走的行人的环境下移动机器人的传感器测量数据噪声较大, 导致机器人定位精度下降甚至定位失败等问题, 提出了一种自适应观测模型蒙特卡罗定位算法。该算法一方面改进观测模型来提高激光传感器测量数据的有效性, 另一方面通过激光数据匹配占用栅格地图, 动态调整观测模型中 3 个权重值, 提高定位精度。在空旷的走廊环境中, 与经典的蒙特卡罗算法和里程计法进行对比实验, 分析了环境中易穿透物质因素对传感器测量数据和定位性能影响, 并在动态环境中进行定位实验。实验结果表明, 本文所提出的算法能提高静态环境下移动机器人定位性能的有效性, 同时改进的算法能提高移动机器人在动态环境中的准确性。

参考文献

- [1] 程磊. 移动机器人系统及其协调控制 [M]. 武汉: 华中科技大学出版社, 2013. 12
- [2] 张利, 潘承毅, 刘征宇. 差动驱动机器人的一种航迹推算定位方法 [J]. 合肥工业大学学报: 自然科学版, 2010, 33(11): 1605-1608
- [3] Lekkala K K, Mittal V K. Simultaneous aerial vehicle localization and human tracking [C]. In: Proceedings of the 2016 IEEE Region 10 Conference, Singapore, 2016. 379-383
- [4] Yuan S, Song H, Patrice M. Gauss based auxiliary particle filter [C]. In: Proceedings of the 2016 IEEE International Conference on Robotics and Biomimetics, Qingdao, China, 2016. 2209-2214
- [5] Wu Z, Jiang J, Yue M. A particle filter-based approach for effectively detecting low-rate denial of service attacks [C]. In: Proceedings of the 2016 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery, Chengdu, China, 2016. 86-90
- [6] 付巍, 郑宾. 基于改进的粒子滤波的静电目标跟踪算法 [J]. 高技术通讯, 2014, 24(2): 138-143
- [7] Doucet A, Godsill S, Andrieu C. On sequential Monte Carlo sampling methods for Bayesian filtering [J]. Statistics and Computing, 2000, 10(3): 197-208
- [8] Fox D. Adapting the sample size in particle filters through KLD-sampling [J]. International Journal of Robotics Research, 2003, 22(12): 985-1003
- [9] Li T, SunS, Sattar T P. Adapting sample size in particle filters through KLD-resampling [J]. Electronics Letters, 2013, 49(12): 740-742
- [10] Gordon N J, Salmond D J, Smith A F M. Novel approach to nonlinear/non-Gaussian Bayesian state estimation [J]. Proceedings F-Radar and Signal Processing, 1993, 140(2): 107-113
- [11] Oh S I, Kang H B. A modified sequential Monte Carlo Bayesian occupancy filter using linear opinion pool for grid mapping [C]. In: Proceedings of the 2015 IEEE International Conference on Computer Vision Workshop, Santiago, Chile, 2015. 192-198

Research on an indoor Monte Carlo dynamic positioning system for mobile robots based on adaptive observation model

Zheng Wenlei*, Cheng Lei*, Yu Qiuyue*, Chen Hongyu*, Wu Qiuxuan**

(* School of Information Science and Engineering, Wuhan University of Science and Technology, Wuhan 430081)

(** School of Automation, Hangzhou Dianzi University, Hangzhou 310081)

Abstract

Aiming at the problem that the positioning performance of traditional Monte Carle localization (MCL) algorithms for mobile robots delines when working in the environment with glass doors and pedestrians because environmental noises cause dramatic changes in observation information, a new Monte Carlo localization algorithm based on an improved observation model is presented. The algorithm introduces the measurement failure error and dynamic error into the observation model to improve the laser sensor's effectiveness of data measuring, and the data measured by the laser is used to match the created grid map to detect whether known environment changes, so the corresponding weight of the random error is changed, and the failure error and the dynamic error are measured, and then the noise impact on the measured value is reduced, which improves the location accuracy of the improved algorithm in complex environment. The new algorithm is tested based on the robot operating system (ROS), and the experimental results prove its effectiveness.

Key words: Monte Carle localization (MCL) algorithm, observation information, laser sensor, occupancy grid mapping, robot operating system (ROS)