

# 多传感器融合改进的机器人定位决策<sup>①</sup>

唐骥锋, 刘国栋

(江南大学 物联网工程学院, 无锡 214122)

**摘要:** 在复杂的不确定环境里, 采用单一传感器对机器人进行定位时精度较低, 并且易受干扰, 可靠性较差。针对这一问题在粒子滤波器移动机器人 SLAM 算法的基础上, 利用多传感器融合对算法进行改进, 将观测信息进行特征级融合, 充分利用各种传感器采集的冗余信息, 并将融合后的观测信息分别用来估计机器人路径和环境特征的后验概率分布。仿真试验表明, 改进后的算法在 SLAM 定位精度及可靠性上都有较大的提高, 证明了该种方法的可行性。

**关键词:** 机器人定位; 地图创建; 多传感器融合; 粒子滤波器

## Improved Robots Localization Decisions Based on Multi-Sensor Fusion

TANG Ji-Feng, LIU Guo-Dong

(Internet of Things Engineering College, Jiangnan University, Wuxi 214122, China)

**Abstract:** In a complex and uncertain environment, using a single sensor on the robot localization is poor in accuracy and reliability, and susceptible to the interference. For this problem, the mobile robot SLAM algorithm based on the particle filter is improved for use of multi-sensor fusion algorithm. The new algorithm fuses observe information on the feature level to take advantage of redundant information collected by various sensors, and the fusion information of observations were used to estimate the posterior probability distribution of robot path and the environmental characteristics. The simulation results show that the improved algorithm in accuracy and reliability of SLAM has greatly improved, and demonstrated the feasibility of the methods.

**Key words:** robot localization; map building; multi-sensor fusion; particle filter

近年来, 移动机器人的同时定位和地图构建 (Simultaneous localization and mapping, SLAM) 已经成为移动机器人领域的一个研究热点, 机器人同时定位和地图创建最先由 Smith Self 和 Cheese 提出<sup>[1]</sup>。在以往机器人定位过程中, 采用的多为单一传感器, 由于单一传感器分辨率较低, 在复杂环境中难以取得理想效果。因此在定位过程中, 需要引进多传感器融合算法。多传感器融合算法有多种, 但由于机器人定位过程的实时递推性, 以及机器人系统的非线性、非高斯性, 因此, 目前较为流行的是能够实时递推更新的扩

展卡尔曼滤波算法(EKF)<sup>[2]</sup>。

在以往的研究中多采用扩展卡尔曼滤波同时进行多信息融合和机器人 SLAM。但由于 EKF 存在较大的线性误差, 所以直接导致定位精度较低。本文在 Rao-Black-wellised 粒子滤波器的基础上<sup>[3,4]</sup>, 在观测阶段利用扩展卡尔曼滤波进行多传感器信息融合, 从而得到可靠的观测信息矩阵, 进一步通过粒子滤波器得到更为准确的环境特征以及机器人位姿的后验概率分布。其传感器采用移动机器人应用最为广泛的超声波传感器和激光测距仪。

① 收稿时间:2011-03-02;收到修改稿时间:2011-03-28

## 1 移动机器人及传感器模型建立

### 1.1 机器人运动模型的建立

由于移动机器人机构复杂,为了便于构造运动学模型,本文选择两轮驱动机器人作为运动平台。为了确定机器人在平面中的位置,建立平面全局参考坐标系  $OXY$  和机器人局部参考坐标系  $O_R X_R Y_R$ ,把  $O_R X_R Y_R$  坐标系的原点建立在移动机器人中心位置上。移动机器人位姿信息可表示为3元素向量:  $[x, y, \theta]^T$ ,机器人运动模型分直线型和圆弧形两种,由于机器人可以在原地做任意角度的转向,故采用较为简单的直线型运动模型。如图1所示:

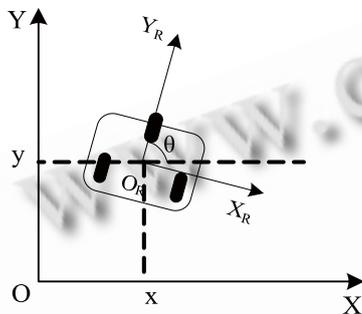


图1 机器人运动模型

文献[5]给出了机器人直线运动模型的推导过程,其直线模型为:

$$f(X_{k/k}, u_k) = \begin{pmatrix} x_k + \Delta D_k \cos(\theta_k + \Delta \theta_k) \\ y_k + \Delta D_k \sin(\theta_k + \Delta \theta_k) \\ \theta_k + \Delta \theta_k \end{pmatrix} \quad (1)$$

由此可得,其状态方程为:

$$X_{k+1/k} = f(X_{k/k}, u_k) + v_k \quad (2)$$

其中  $f(X_{k/k}, u_k)$  为通过里程计估计的移动机器人位姿,  $v_k$  为系统输入噪声,  $X_{k+1/k}$  为位姿估计值,  $u_k$  为移动机器人控制指令信息,  $\Delta D_k$  与  $\Delta \theta_k$  由里程计计算得出,进而推测机器人相对位姿的变化<sup>[6]</sup>。

### 1.2 传感器观测模型

超声波传感器的原理是发送一束超声波,通过测量该波反射和回到接受器其所占用的时间,来估计障碍物和机器人之间的距离。

假设障碍物在全局坐标系  $XYO$  中模型为  $a_j x + b_j y + c_j = 0$ , 设  $\delta$  为超声波带开放角,利用极坐标表示,得到以下超声波观测模型<sup>[7]</sup>:

$$\begin{bmatrix} \rho(k) \\ \varphi(k) \end{bmatrix} = \begin{bmatrix} \frac{a_j x(k) + b_j y(k) + c_j(k)}{\sqrt{(a_j + b_j)^2}} \\ \frac{\cos(\theta(k) - \alpha_j)}{\theta(k)} \end{bmatrix} \quad (3)$$

其中,  $\rho(k)$  和  $\varphi(k)$  分别为环境特征到传感器的距离和方向。

激光测距仪工作与超声波传感器工作原理相似,通过记录激光发射到接收的时间间隔,就可以算出激光测距仪到障碍物的距离。激光传感器测量数据也用极坐标表示:  $(\rho_n, \varphi_n)^T$ , 表示传感器到环境特征的距离和方向。推导其模型为<sup>[8]</sup>:

$$\rho_n = r_n \cos(\alpha_n - \varphi_n) \quad (4)$$

其中,  $r_n$  和  $\alpha_n$  分别为障碍物上一点到传感器的距离和方向角。

## 2 基于粒子滤波的SLAM决策

### 2.1 基本粒子滤波器

粒子滤波器是用有限的一组粒子来表示目标后验概率分布。机器人的定位是要获得其状态向量  $x_k$ , 而  $x_k$  的后验概率分布递推公式为:

$$p(x_k | z_{1:k}) = \frac{p(z_k | x_k) p(x_k | z_{1:k-1})}{p(z_k | z_{1:k-1})} \quad (5)$$

粒子滤波器采用带权重的随机采样点集来表示所需要的后验密度函数。首先初始化一群带权采样粒子  $\{x_k^i, w_k^i\}_{i=1}^N$ , 来表示后验概率分布函数  $p(x_k | z_{1:k})$  则有<sup>[9]</sup>:

$$p(x_k | z_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(x_{0:k} - x_{0:k}^i) \quad (6)$$

权值  $w_k^i$  的选择依据是重采样原理,若概率密度初始值  $p(x_0 | z_0) = p(x_0)$ , 对于一阶马尔可夫过程,有先验概率密度:

$$p(x_k | z_{1:k-1}) = \int p(x_k | x_{k-1}) p(x_{k-1} | z_{1:k-1}) dx_{k-1} \quad (7)$$

进而可求出后验概率分布  $p(x_k | z_{1:k})$ , 最后进行重采样,重采样是为了减少小权值粒子数目。通过对粒子进行  $N_s$  次重采样,就能凸显大权值粒子的比重。

### 2.2 SLAM 问题中的粒子滤波器

在 SLAM 中,用一个向量  $s$  表示机器人的位姿,向量  $m$  表示  $K$  个环境特征位置。在  $t$  时刻,  $i$  个传感器得到的观测信息向量为  $z_i$ , 机器人自身运动控制信息为  $u_i$ 。

同时,利用向量集  $s_t$  表示机器人经过的路径。

SLAM 的问题就是, 利用  $z_t$  和  $u_t$  估计出  $t$  时刻机器人路径和环境特征的后验概率分布:

$$p(s_t, m_t | z_t, u_t, n_t) = \eta p(z_t | s_t, m_t, n_t) \int p(s_t | u_t, s_{t-1}) p(s_{t-1} | z_{t-1}, u_{t-1}, n_{t-1}) ds_{t-1} \quad (8)$$

$n_t \in \{1, \dots, K\}$  表示  $t$  时刻的观测环境特征, 由于 (8) 式求解困难. 利用 Rao-Blackwellised 粒子滤波器, 则后验分布概率可表示为:

$$p(s_t, m_t | z_t, u_t, n_t) = p(m_t | z_t, u_t, n_t) p(s_t | z_t, u_t, n_t) = p(s_t | z_t, u_t, n_t) \prod_{i=1}^N p(m_i | s_t, z_t, u_t, n_t) \quad (9)$$

上式将 SLAM 问题分成位姿估计和环境特征估计两个部分. 分解之后, 对机器人路径和环境特征分别进行估计可以使计算复杂度减少至  $O(M \log k)$ .

### 3 基于多传感器融合改进的SLAM

#### 3.1 观测信息的融合

观测信息的融合采用扩展卡尔曼滤波来进行, 超声波传感器和激光测距仪分别得到一组观测信息:

$$z_s = \{z_s^1, \dots, z_s^n\} \text{ 和 } z_l = \{z_l^1, \dots, z_l^n\}$$

首先要对这两组信息进行关联匹配<sup>[10]</sup>. 设  $\{z_s^i, z_l^j\}$  为一个可能的关联匹配对, 则其必满足隐含的方程:

$$f(z_s^i, z_l^j) = 0 \quad (10)$$

函数  $f$  为融合误差函数由传感器标定确定. 对函数  $f$  进行线性化:

$$f(z_s^i, z_l^j) = h_{ij} + H_{ij}(z_s^i - \hat{z}_s^i) + J_{ij}(z_l^j - \hat{z}_l^j) \quad (11)$$

其中,  $h_{ij} = f(\hat{z}_s^i, \hat{z}_l^j)$

$$H_{ij} = \frac{\partial f}{\partial z_s^i} \Big|_{(\hat{z}_s^i, \hat{z}_l^j)}$$

$$J_{ij} = \frac{\partial f}{\partial z_l^j} \Big|_{(\hat{z}_s^i, \hat{z}_l^j)}$$

从以上获得其协方差矩阵:

$$C_{ij} = H_{ij} C_s^i H_{ij}^T + J_{ij} C_l^j J_{ij}^T \quad (12)$$

其中,  $C_s^i, C_l^j$  分别是  $z_s^i, z_l^j$  的协方差矩阵. 根据  $z_s^i, z_l^j$  之间的 Mahanalobis 距离的  $\chi^2$  验证来验证其相容性.

$$D_{ij}^2 = h_{ij}^T C_{ij}^{-1} h_{ij} < \chi_{d,\alpha}^2 \quad (13)$$

上式中:  $d = \text{rank}(h_{ij}), \alpha$  为可信度参数, 选  $z_s$  与  $z_l^j$  中欧式距离最近的观测特征作为最佳匹配. 然后通过扩展卡尔曼滤波进行融合:

$$W = C_s^i H_{ij}^T (H_{ij} C_s^i H_{ij}^T + J_{ij} C_l^j J_{ij}^T)^{-1} \quad (14)$$

$$\hat{z}_{st}^i = \hat{z}_s^i + W(-h_{ij}) \quad (15)$$

$$C_{st}^i = (I - WH_{ij}) C_s^i \quad (16)$$

#### 3.2 移动机器人位姿估计

将融合后的观测信息送入粒子滤波器进行位姿估计, 采用蒙特卡洛算法<sup>[11]</sup>, 得到路径的后验概率分布  $p(s_t | \hat{z}_{st}^i, u_t, n_t)$ , 由  $t-1$  时刻路径分布  $s^{t-1}$ , 控制信息  $u^t$  和融合观测信息  $\hat{z}_{st}^i$ , 可以递推得到  $s^t$ . 首先, 用  $s^{t-1}$  中粒子产生一个  $t$  时刻机器人位姿分布估计:

$$s_t \sim p(s_t | s_{t-1}, u_t) \quad (17)$$

从机器人运动模型中采样  $M$  个粒子, 则该  $M$  个粒子符合分布  $p(s_t | \hat{z}_{st}^i, u_t, n_{t-1})$ , 然后将  $M$  个粒子进行重采样, 得到新的集合  $s^t$ , 粒子依据权值  $w_k^i$  进行重采样, 权值计算如式 (18), 由  $s^t$  得到先验概率  $p(s_t | s_{t-1})$ , 再由贝叶斯公式得出后验分布  $p(s_t | s_{t-1}, \hat{z}_{st}^i, u_t, n_{t-1})$ , 同时将机器人位姿变化看作马尔可夫链<sup>[12]</sup>, 可计算出粒子的非正则重要权值:

$$\bar{w}_t^i = \bar{w}_{t-1}^i \frac{p(\hat{z}_{st}^i | s_t^i) p(s_t^i | s_{t-1}^i, u_t)}{p(s_t^i | s_{t-1}^i, \hat{z}_{st}^i, u_t, n_t)} \quad (18)$$

归一化之后, 权值为:  $w_t^i = \bar{w}_t^i / \sum_j \bar{w}_t^j$

#### 3.3 环境特征估计

由式 (9) 可知地图估计可分解为  $M$  个环境特征估计问题. 这里采用扩展卡尔曼滤波器 (EKF) 对机器人环境特征进行估计. 第  $i$  个粒子的环境特征估计可表示为:

$$\{\mu_k^i, \Sigma_k^i, \dots, \mu_k^i, \Sigma_k^i\}$$

其中,  $\mu_k^i$  和  $\Sigma_k^i$  分别是第  $i$  个粒子的地图中第  $j$  个特征的高斯均值和方差. 第  $K$  个环境特征位置估计  $m_k$  是否更新, 遵循下式<sup>[13]</sup>:

$t$  时刻观察到,  $n_t = k$  时:

$$\begin{aligned}
 p(m_k | s_t, u_t, \hat{z}'_{sl}, n_t) &\propto p(z_t | m_k, s_t, n_t) \\
 &* p(m_k | s_{t-1}, \hat{z}'_{sl}, u_t, n_t) \\
 &= p(z_t | m_k, s_t, n_t) p(m_k | s_{t-1}, \hat{z}'_{sl}, u_{t-1}, n_{t-1})
 \end{aligned}
 \tag{19}$$

t 时刻未观察到,  $n_t \neq k$  :

$$p(m_{n_t \neq k} | s_t, u_t, \hat{z}'_{sl}, n_t) \propto p(m_{n_t \neq k} | s_{t-1}, \hat{z}'_{sl}, u_{t-1}, n_{t-1}) \tag{20}$$

综上, 整个算法流程如下:

- 1)  $t=0$ , 初始化 M 个带权粒子, 每个粒子为  $3 \times 1$  维向量, 表示机器人的坐标和方向角。
- 2) 将传感器获得的信息进行融合, 得到融合后的观测信息。
- 3) 对每个粒子估计其观测值, 并利用观测信息更新粒子权值。
- 4) 每个粒子使用对应的 K 个扩展卡尔曼滤波器估计其观测到的环境特征位置。
- 5) 依据权值进行重采样, 保留大权值粒子。

#### 4 仿真结果及分析

实验仿真环境为  $180m \times 160m$  的区域, 随机分布 30 个环境特征点, 机器人移动速度设为  $2m/s$ , 机器人运动噪声为  $0.25m/s$ , 为了研究方便将两种传感器的观测距离都设为  $30m$ , 观测时间间隔为  $0.2s$ 。

首先, 对实验中的机器人检验其 SLAM 的整体效果。图 2 为多传感器融合改进后的 SLAM 模拟效果图, 其中实线为实际行走路径, 虚线为估计路径。图中“+”代表实际环境特征位置, 圆圈代表其估计位置, 实心方块代表机器人停顿转向点。从图 2 可知, 通过多传感器融合改进后的 SLAM 算法, 能取得较好的定位及构建地图的效果。

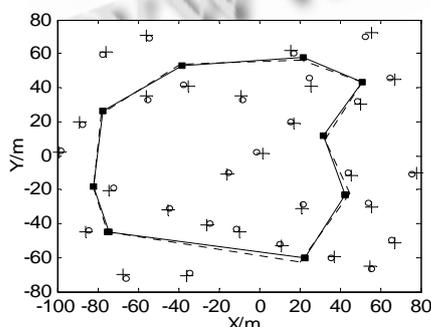


图 2 移动机器人 SLAM 模拟效果

再对比单一传感器和多传感器融合后的定位误

差。图 3 和图 4 为融合前后三种定位方式的位置和方向角误差曲线, 其横轴代表机器人的位移, 纵轴代表定位位置和方向角误差。

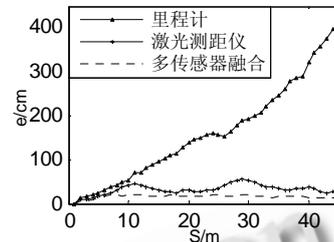


图 3 融合前后机器人定位位置误差

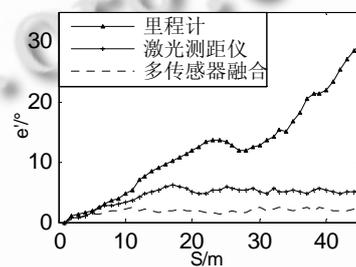


图 4 融合前后机器人定位方向角误差

从图 3 和图 4 中可以看出采用多传感器融合比采用单一传感器, 其定位精度高出许多。

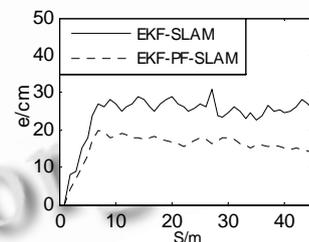


图 5 两种定位决策的位置误差

将基于 EKF 多传感器融合改进的机器人粒子滤波 SLAM 决策 (EKF-PF-SLAM), 同传统的 EKF 多传感器融合 SLAM 决策 (EKF-SLAM), 进行定位精度上的比对。图 5 和图 6 为两种定位决策的位置误差和方向角误差曲线。

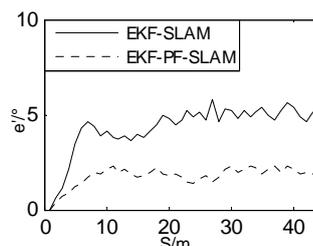


图 6 两种定位决策的方向角误差

从图5和图6中可以看出EKF多传感器融合改进的机器人粒子滤波SLAM决策,比传统EKF多传感器融合SLAM决策,在定位精度上有很大提高。

文献[14]给出了一种根据归一化估计方差NEES(normalized estimation error square)分析算法一致性的方法。如果滤波算法近似高斯分布,则NEES服从 $\chi^2$ 分布。对算法进行N次蒙特卡洛仿真后,可以将NEES的平均值作为评价算法一致性的指标<sup>[15]</sup>。 $\bar{\varepsilon}_k$ 表示NEES,当N趋向于无穷则 $\bar{\varepsilon}_k$ 趋向于向量维数d。所以,则有下式:

$$\varepsilon_k = (X_k - \hat{X}_{k|k})^T P_{k|k}^{-1} (X_k - \hat{X}_{k|k}) \quad (21)$$

$$\bar{\varepsilon}_k \leq \frac{1}{N} \chi_{N-d, \delta}^2 \quad (22)$$

其中,取N=50, d=3,  $\delta=0.95$ 为置信水平。由于, $\chi_{150,0.95}^2=179.58$ ,所以, $\bar{\varepsilon}_k \leq 3.59$ 。对算法进行50次蒙特卡洛仿真,所得位姿NEES均值曲线如图7所示。

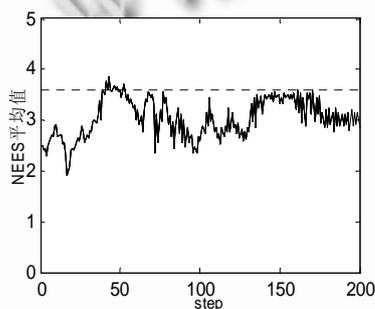


图7 机器人NEES平均值变化曲线

由图7可知,该算法的NEES平均值大多数在要求之下,符合一致性条件,因此可以认为该算法属于一次性估计。

## 5 结语

本文在移动机器人粒子滤波SLAM定位决策的基础上,采用多传感器融合算法对原有算法进行改进,改进后的算法取得良好的定位效果,提高了定位精度。通过对观测信息的融合,提高了信息的利用效率,减少信息冗余,因此,利用多传感器融合算法优化SLAM定位决策,是未来研究的重要方向。

## 参考文献

- Smith R, Cheesman MP. Estimating uncertain Spatial Relationships in Robotics. *Uncertainty in Artificial Intelligence*, 1988,2(8):435-461.
- 陶敏,陈新,孙振平. 移动机器人定位技术. *火力与指挥控制*, 2010,35(7):169-172.
- 鞠纯纯,何波,刘宝龙,王永清. 基于粒子滤波器的SLAM的仿真研究. *系统仿真学报*, 2007,19(16):3715-3723.
- Murphy K, Russul. Rao-Black wellized Particle Filtering for Dynamic. *Bayesian Networks. Robots and Systems*, 2001, 8(6):56-60.
- 陈小宁,黄玉清,杨佳. 多传感器信息融合在移动机器人定位中的应用. *传感器与微系统*, 2008,27(6):110-113.
- 赵璇,何波,吉得志,于清,张洁. 基于粒子滤波器的机器人定位及动态目标追踪. *系统仿真学报*, 2008,20(23):3715-3723.
- 周华. 传感器融合技术在移动机器人定位中的应用研究[硕士学位论文]. 武汉:武汉理工大学, 2009.
- 赵璇. 基于粒子滤波的机器人定位及动态目标追踪[硕士学位论文]. 青岛:中国海洋大学, 2008.
- 武二永,项志宇,刘继林. 鲁棒的机器人蒙特卡洛算法. *自动化学报*, 2008,34(8):907-911.
- 罗荣华,洪炳镕. 基于信息融合的同时定位与地图创建研究. *哈尔滨工业大学学报*, 2004,36(5):566-569.
- Delleart F, Fox D, Wburgard ST. Monte Carlo Localization for Mobile Robots. *IEEE Trans. on Robotics and Automation*, 1999,2(5):10-15.
- 周武,赵春霞. 一种基于遗传算法的FastSlam2.0算法. *机器人*, 2009,31(1):25-32.
- Mortmerlo M, Thrun S, Koller STD, et al. FastSLAM: A Factored Solution to the Simultaneous Localization and Mapping Problem. *Proc. of the AAAI National Conference on Artificial Intelligence*. Edmonton, Canada: AAAI Press, 2002.593-598.
- Bailey NJ, Nebot E. Consistency of the Fast SLAM algorithm. *Proc. of the IEEE International Conference on Robotics and Automation*. Piscataway, USA: IEEE, 2006. 424-429.
- 潘勃,冯金富,李骞,李斌. 毫米波/红外多传感器融合跟踪算法研究. *红外与毫米波学报*, 2010,29(3):230-235.