

精确稀疏扩展信息滤波的多机器人 SLAM 研究

明钊光, 石守东*, 王 刚

(宁波大学 信息科学与工程学院, 浙江 宁波 315211)

摘要: 在机器人同时定位与地图创建(SLAM)问题中, 多机器人 SLAM 成为目前机器人学中的研究热点. 因此, 基于精确稀疏扩展信息滤波算法(ESEIF)的多机器人 SLAM 问题, 根据多机器人的运动模型和观测模型分别对多机器人位姿估计及环境特征点进行观测, 并依据阈值划分观测特征点, 以完成机器人的观测更新, 同时边缘化机器人位姿并进行重定位. 实验仿真数据表明: 多机器人的位姿精度良好, 观测更新阶段时间基本上恒定, 与地图特征点数量无关, 体现了 ESEIF 算法在研究多机器人 SLAM 问题的有效性.

关键词: SLAM; 多机器人; 精确稀疏扩展信息滤波; 重定位

中图分类号: TP242.6

文献标志码: A

文章编号: 1001-5132 (2014) 04-0042-05

在未知环境中实现移动机器人同时定位与地图构建(Simultaneous Localization and Map Building, SLAM)是实现移动机器人进行自主导航定位的基础. 目前基于单机器人系统的 SLAM 技术在理论和实践方面都比较成熟, 而多机器人 SLAM 问题成为该领域的研究热点.

精确稀疏扩展信息滤波(Exactly Sparse Extended Information Filter, ESEIF)算法是稀疏扩展信息滤波(Sparse Extended Information Filter, SEIF)的一种优化算法. SEIF 和 ESEIF 算法都以信息矩阵来表示 SLAM 中的不确定信息^[1], 其信息矩阵的对角线元素相应表示机器人、环境特征的自关联关系, 非对角线元素表示机器人与不同机器人之间、机器人与环境特征以及不同环境特征之间的关联关系, 且元素值越大表示关联性越强. 为了提高计算效率, 节省计算机存储空间, ESEIF 算法将信息矩阵合理稀疏化来更新状态向量^[2-5].

在单机器人系统中, ESEIF 算法得到很好的应用^[6-7], 而基于 ESEIF 算法的多机器人 SLAM 研究却研究不多, 笔者采用 ESEIF 算法来研究多机器人 SLAM 问题, 并且在多机器人初始位姿未知的情况下, 实现多机器人同时定位与地图构建.

1 多机器人 SLAM

多机器人 SLAM 问题可描述为多机器人系统通过内部传感器和外部传感器采集到的数据以校正各机器人的位姿, 并同时增量式构建全局环境地图^[5]. 其多机器人 SLAM 问题的关键是获得状态向量 $\xi_t = [X_t^{1,T} \cdots X_t^{k,T} M^T]^T$, 即机器人群体的位姿 $X_t^K = x_t^1 \cdots x_t^k$ 和环境地图 M , 其中机器人 R_k 在 t 时刻的位姿 $x_t^k = [x_t^k \ y_t^k \ \theta_t^k]^T$ (文中研究 2 个同构机器人, 即 $k=1,2$, 下同). 多机器人 SLAM 问题估计 t 时刻状态向量的后验分布, 即 $p(\xi_t | z^t, u^t)$ 以获得机器人位姿和环境特征的位置. 机器人 t 时刻, 状态向量 ξ_t 服从均值为 μ_t 、协方差为 Σ_t 的高斯分布^[8], 即 $p(\xi_t | z^t, u^t) \propto N(\mu_t, \Sigma_t)$, 则有:

$$\begin{aligned} p(\xi_t | z^t, u^t) &\propto \exp\{-\frac{1}{2}(\xi_t - \mu_t)^T \Sigma_t^{-1} (\xi_t - \mu_t)\} \propto \\ &\exp\{-\frac{1}{2}\xi_t^T \Sigma_t^{-1} \xi_t + \mu_t^T \Sigma_t^{-1} \xi_t\} = \\ &\exp\{-\frac{1}{2}\xi_t^T A_t \xi_t + \eta_t^T \xi_t\} \propto N^{-1}(\eta_t, A_t), \quad (1) \end{aligned}$$

其中, η_t, A_t 为均值 μ_t 、协方差为 Σ_t 的信息形式.

2 ESEIF 算法探究多机器人 SLAM 问题

精确稀疏扩展信息滤波是稀疏扩展信息滤波的优化算法, 不同于 SEIF 算法的是在于其稀疏策略

收稿日期: 2013-01-10.

宁波大学学报(理工版)网址: <http://journalg.nbu.edu.cn/>

基金项目: 浙江省教育厅科研项目 (Y201121251); 宁波市自然科学基金 (2012A610008).

第一作者: 明钊光 (1988-), 男, 湖北黄石人, 在读硕士研究生, 主要研究方向: 多机器人的导航定位. E-mail: mingzhg@163.com

*通信作者: 石守东 (1964-), 男, 浙江宁海人, 副教授, 主要研究方向: 计算机及人工智能. E-mail: shishoudong@nbu.edu.cn

不是切断各个机器人与地图间的联系, 使其条件独立, 而是通过控制机器人集群与地图的结构来保持信息稀疏. ESEIF 将地图创建与机器人位姿估计分离开来, 在创建地图后, 再用地图中的部分特征对机器人进行重定位.

2.1 算法过程

假定机器人 R_1 和机器人 R_2 活动地图特征阈值分别为 Γ_1 和 Γ_2 , 在 t 时刻将地图上机器人 R_1 和 R_2 的活动特征点个数分别记为 N_{active}^1 和 N_{active}^2 , 则 ESEIF 算法处理多机器人 SLAM 问题步骤如下:

步骤 1 运动更新: 依据多机器人运动模型分别估计下一时刻各机器人的位姿及协方差. 该步骤与多机器人扩展信息滤波^[9](Extended Information Filter, EIF)的运动更新类似.

步骤 2 数据关联: 把机器人 R_1 和 R_2 观测到的特征点进行分类, 记机器人 R_1 和 R_2 上一时刻观测到的特征点 $\{z_f^1, z_f^2\}$ 个数分别为 n_1, n_2 , 从未观测到的新特征点 $\{z_n^1, z_n^2\}$ 个数分别为 m_1, m_2 . 其中, 将机器人 R_1 和 R_2 观测特征点 $\{z_f^1, z_f^2\}$ 中有活动特征点的个数分别记为 $n_1(\text{active}), n_2(\text{active})$, 不活动特征点个数分别记为 $n_1(\text{passive}), n_2(\text{passive})$.

步骤 3 分别判断机器人 R_1 和 R_2 当前特征点个数与其设定阈值 Γ_1, Γ_2 的关系. 以机器人 R_1 为例, 如果其满足 $N_{\text{active}}^1 + n_1(\text{passive}) \leq \Gamma_1$ 时, 则测量更新执行步骤 4; 否则, 转到执行步骤 5. 对于机器人 R_2 而言, 同理, 若 R_2 满足 $N_{\text{active}}^2 + n_2(\text{passive}) \leq \Gamma_2$ 条件时, 则测量更新执行步骤 4; 否则, 转到执行步骤 5.

步骤 4 依据 EIF 的观测更新^[9], 对该机器人状态向量的相应量值进行更新, 然后更新 N_{active}^k , 其值为 $N_{\text{active}}^k = N_{\text{active}}^k + n_k(\text{passive})$.

步骤 5 将机器人 R_k 观测值 z_f^k 分成两部分, 即 $z_f^k = [z_\alpha^k, z_\beta^k]$, 其中 z_β^k 的个数须小于等于阈值 Γ_k ; 用 z_α^k 来进行观测更新机器人 R_k 状态向量的相应量值, 同时边缘化机器人 R_k 位姿, 然后利用 z_β^k 重新定位机器人 R_k 位姿且重定义 N_{active}^k , 同时将 z_α^k 中活动特征点变为不活动特征点.

步骤 6 状态扩增: 将机器人 R_1 和机器人 R_2 观测到的新特征点 $\{z_n^1, z_n^2\}$ 添加到地图中. 返回重复步骤 1, 逐步迭代, 至到设定实验值.

步骤 5 是 ESEIF 算法解决多机器人 SLAM 问

题的关键技术, 即根据阈值进行特征点划分, 并进行各机器人的观测更新和重定位. ESEIF 的稀疏策略在不牺牲地图一致性的前提下, 对信息矩阵保持了理想的稀疏度.

2.2 精确稀疏技术

精确稀疏技术主要分为分割特征点、更新后验分布、边缘化机器人位姿和重定位 4 步.

2.2.1 分割特征点

特征点的划分主要依据机器人 R_k 重定位的特征点 m_β^k 数量. ESEIF 算法根据设置的阈值将各机器人观测到的特征点划分成 z_α^k, z_β^k 两部分, 其中 z_α^k 是特征点集 m_α^k 的观测值, 用来观测更新机器人 R_k 的状态向量, z_β^k 是特征点集 m_β^k 的观测值, 用来重新定位机器人 R_k 位姿.

对机器人 R_k 来而言, m_β^k 作为新的活动地图, 要求特征点集 m_β^k 个数不能超过阈值 Γ_k ; 同时, 为了降低机器人 R_k 位姿的估计误差, 重定位 m_β^k 中特征点个数要求尽可能多. 因此, 设置合理的阈值 Γ_k 非常重要, 新的活动地图 m_β^k 越接近阈值 Γ_k , 稀疏频率越大. 因此, 当 m_β^k 个数超过阈值时, 需要剔除部分特征点使 m_β^k 个数始终小于等于阈值 Γ_k .

2.2.2 更新后验分布

假设 t 时刻地图状态向量的分布为 $p(\xi_t | z^{t-1}, u^t)$, 在 ESEIF 算法中用特征点 m_α^k 及其观测值 z_α^k 提供的数据来观测更新机器人 R_k 状态, 即:

$$p(\xi_t | z^{t-1}, u^t) = N^{-1}(\xi_t; \eta_t, \Lambda_t) \xrightarrow{z_\alpha^k, z_\beta^k} p_1(\xi_t | \{z^{t-1}, z_\alpha^k, z_\beta^k\}, u^t) = N^{-1}(\xi_t; \bar{\eta}_t, \bar{\Lambda}_t).$$

后验分布 $p_1(\xi_t | \{z^{t-1}, z_\alpha^k, z_\beta^k\}, u^t)$ 与标准 EIF^[9] 的观测更新类似, 则:

$$\begin{aligned} p_1(\xi_t | \{z^{t-1}, z_\alpha^k, z_\beta^k\}, u^t) &= N^{-1}(\xi_t; \bar{\eta}_t, \bar{\Lambda}_t), \\ \bar{\Lambda}_t &= \Lambda_t + H_1^T R_1^{-1} H_1 + H_2^T R_2^{-1} H_2, \\ \bar{\eta}_t &= \eta_t + H_1^T R_1^{-1} (z_\alpha^k - h(\mu_t^1) + H_1 \mu_t^1) + \\ &\quad H_2^T R_2^{-1} (z_\beta^k - h(\mu_t^2) + H_2 \mu_t^2). \end{aligned} \quad (2)$$

(2) 式中 H_1, H_2 为机器人 R_1 和 R_2 的观测雅可比矩阵, 其非对角线元素只有在 z_α^k 与机器人 R_k 位姿对应的部分才不为零. 此过程在恒定时间内完成, 增强了机器人 R_k 与原活动特征点的关联, 增加了与不活动特征点的关联.

2.2.3 边缘化

ESEIF 算法通过边缘化机器人的位姿来获得

地图的分布情况, 即:

$$p_2(M|\{z^{t-1}, z_\alpha^1, z_\alpha^2\}, u^t) = \int \int p_1(\xi_t|\{z^{t-1}, z_\alpha^1, z_\alpha^2\}, u^t) dx_t^1 dx_t^2 = N^{-1}(M; \tilde{\eta}_t, \tilde{A}_t).$$

为了使推导更清晰, 将 $p_1(\xi_t|\{z^{t-1}, z_\alpha^1, z_\alpha^2\}, u^t)$ 分布展开, 则:

$$p_1(\xi_t|\{z^{t-1}, z_\alpha^1, z_\alpha^2\}, u^t) = N^{-1}(\xi_t; \bar{\eta}_t, \bar{A}_t),$$

$$\bar{\eta}_t = \begin{Bmatrix} \bar{\eta}_{x_t^1} \\ \bar{\eta}_{x_t^2} \\ \bar{\eta}_M \end{Bmatrix}, \bar{A}_t = \begin{Bmatrix} \bar{A}_{x_t^1 x_t^1} & 0 & \bar{A}_{x_t^1 M} \\ 0 & \bar{A}_{x_t^2 x_t^2} & \bar{A}_{x_t^2 M} \\ \bar{A}_{M x_t^1} & \bar{A}_{M x_t^2} & \bar{A}_{MM} \end{Bmatrix}.$$

根据边缘化公式推导可得:

$$p_2(M|\{z^{t-1}, z_\alpha^1, z_\alpha^2\}, u^t) = N^{-1}(M; \tilde{\eta}_t, \tilde{A}_t),$$

$$\tilde{A}_t = \bar{A}_{MM} - \bar{A}_{M x_t^k} (\bar{A}_{x_t^k x_t^k})^{-1} \bar{A}_{x_t^k M},$$

$$\tilde{\eta}_t = \bar{\eta}_{MM} - \bar{A}_{M x_t^k} (\bar{A}_{x_t^k x_t^k})^{-1} \bar{\eta}_{x_t^k},$$
(3)

其中, 内积 $\bar{A}_{M x_t^k} (\bar{A}_{x_t^k x_t^k})^{-1} \bar{A}_{x_t^k M}$ 中除了活动特征点对应的部分外都为零. 通过边缘化牺牲一些信息矩阵的填充, 来将地图与机器人 R_k 位姿的关联转化为活动特征点之间的关联.

2.2.4 重定位

重新定位机器人 R_k 的新位姿主要依据特征点集 z_β^k , 与标准 EIF 的状态扩增步骤类似.

机器人 R_k 新位姿的估计值依赖于传感器模型及特征点集 m_β^k , 以特征点集 m_β^k 及其观测值 z_β^k 来描述机器人 R_k 新位姿, 因存在模型不确定性和传感器噪声, 在表达式中需增加 1 个高斯白噪声 $v_t^k \sim N^{-1}(0, R_k)$, 则:

$$x_t^k = g(m_\beta^k, z_\beta^k) + v_t^k \approx g(\tilde{\mu}_{m_\beta^k}, z_\beta^k) + G_M^k (m_\beta^k - \tilde{\mu}_{m_\beta^k}) + v_t^k, \quad (4)$$

其中, $g(\tilde{\mu}_{m_\beta^k}, z_\beta^k)$ 为新位姿估计值, G_M^k 为相应的雅可比矩阵, 它除了特征点集 m_β^k 对应的部分外都为零, 是一个稀疏矩阵. 由于重定位步骤与增加特征点或扩增状态一样, 则:

$$p_{\text{ESEIF}}(\xi_t|z^t, u^t) = N^{-1}(\xi_t; \tilde{\eta}_t, \tilde{A}_t),$$

$$\tilde{A}_t = \begin{Bmatrix} R_1^{-1} & 0 & -R_1^{-1} G_M \\ 0 & R_2^{-1} & -R_2^{-1} G_M \\ -G_M^{1,T} R_1^{-1} & -G_M^{2,T} R_2^{-1} & \tilde{A}_t + G_M^{1,T} R_1^{-1} G_M^1 + G_M^{2,T} R_2^{-1} G_M^2 \end{Bmatrix},$$

$$\tilde{\eta}_t = \begin{Bmatrix} R_1^{-1} (g(\tilde{\mu}_{m_\beta^1}, z_\beta^1) - G_M \tilde{\mu}_{m_\beta}) \\ R_2^{-1} (g(\tilde{\mu}_{m_\beta^2}, z_\beta^2) - G_M \tilde{\mu}_{m_\beta}) \\ \tilde{\eta}_t - G_M^{1,T} R_1^{-1} (g(\tilde{\mu}_{m_\beta^1}, z_\beta^1) - G_M \tilde{\mu}_{m_\beta}) - G_M^{2,T} R_2^{-1} (g(\tilde{\mu}_{m_\beta^2}, z_\beta^2) - G_M \tilde{\mu}_{m_\beta}) \end{Bmatrix}. \quad (5)$$

由于雅可比矩阵 G_M^k 是稀疏的, 信息矩阵的子矩阵块 $-R_k^{-1} G_M = -(G_M^{k,T} R_k^{-1})^T$ 中, 机器人 R_k 与地图关联的部分不为零. 重定位后, 用于重定位的特征点 m_β^k 成为了活动地图.

2.3 重定位模型

新位姿估计值 $g(\tilde{\mu}_{m_\beta^k}, z_\beta^k)$ 的数学模型如下:

$$\bar{X}_t^k = g(\tilde{\mu}_{m_\beta^k}, z_\beta^k) = \begin{Bmatrix} \bar{x}_t \\ \bar{y}_t \\ \bar{\theta}_t \end{Bmatrix} = \begin{Bmatrix} x_i - \rho_i (\phi \cos \theta_i - \phi \sin \theta_i) / (M^2 + N^2) \\ y_i - \rho_i (\phi \cos \theta_i - \phi \sin \theta_i) / (M^2 + N^2) \\ \text{actan} \phi / \phi \end{Bmatrix}, \quad (6)$$

其中, $\phi = M(x_j - x_i) + N(y_j - y_i)$, $\varphi = M(x_j - x_i) - N(y_j - y_i)$, $M = \rho_j \cos \theta_j - \rho_i \cos \theta_i$, $N = \rho_j \sin \theta_j - \rho_i \sin \theta_i$, 其中, $(x_i, y_i), (x_j, y_j)$ 分别为 m_β^k 中任意 2 个特征点的坐标, 其相应观测值分别为 $(\rho_i, \theta_i), (\rho_j, \theta_j)$.

在重定位中, ESEIF 算法要求尽可能多的特征点来对机器人进行重定位, 因此为提高机器人位姿精度, 将每 2 个特征点得出 1 个估计值, 然后将其均值作为机器人的重定位估计值.

在多机器人 SLAM 问题中, ESEIF 算法并不是强制性的切断不理想的连接, 而是主动控制机器人和地图之间的约束信息.

3 实验仿真结果

计算机配置 i3-3220 CPU 3.30 GHZ, 主内存 4 G, 仿真实验环境 Matlab 2012, 运算位 64 位. 机器人 R_1 和机器人 R_2 是同构机器人, 地图设定有 733 个特征点, 它们初始参数: 机器人 R_1 和机器人 R_2 的初始状态是 $[0, 0, 0]^T$ 和 $[0, 250, 0]^T$, 运动线速度均为 $3 \text{ m} \cdot \text{s}^{-1}$, 角速度为 $\pi/4 \text{ rad} \cdot \text{s}^{-1}$, 最大转角是 $\pi/3 \text{ rad}$, 速度噪声为 $0.03 \text{ m} \cdot \text{s}^{-1}$, 角速度噪声为 $\pi/60 \text{ rad} \cdot \text{s}^{-1}$, 观测范围半径为 50 m 的半圆区域, 控制信号时间间隔为 0.025 s, 观测时间间隔是 0.025 s, 观测距离噪声 0.05 m, 观测角度噪声为 $\pi/360 \text{ rad}$. ESEIF 算

法中, 设定机器人 R_1 和机器人 R_2 活动特征点阈值 $\Gamma_1=12, \Gamma_2=16$. 仿真环境及路径如图 1 所示, 图中浅灰色圆点为特征点, 深色星号代表已建立的地图, 黑色线条为机器人运动轨迹.




图1 ESEIF 算法定位多机器人 SLAM 仿真环境

如图 2 所示(图例中, 机器人 R_1 为深色线条, 机器人 R_2 为浅色线条, 图 3~图 5 的线条设置与此相同), 由于起初预定路径的斜率比较大, 因此在机器人初始运动时, 当机器人方位角误差较大, 仿真初期出现很大的波动.




图2 ESEIF 算法定位多机器人方位角误差

如图 3 的 ESEIF 算法定位多机器人位置误差所示, 因初始方位角误差较大, 导致机器人 R_2 位置产生较大误差(图 3 中的位置误差为机器人偏离设




图3 ESEIF 算法定位多机器人位置误差

定路径的距离大小). 同时 SLAM 过程存在的不确定性(运动噪声和观测噪声)在机器人不断地运动和观测过程中产生位置累积误差, 图中机器人 R_1 误差曲线呈积累趋势, 而机器人 R_2 达到了不断自定位效果, 误差不断缩小, 原因在于 $\Gamma_2=16$, 比 $\Gamma_1=12$ 大, 因此机器人 R_2 重定位效果更好些.

在观测更新阶段(图 4), ESEIF 算法使用阈值划分特征点, 限制了用于机器人观测更新的特征点数目, 更新时间基本恒定. 而不同时刻机器人观测特征数目不一样, 导致在一定范围内曲线波动.




图4 ESEIF 算法观测更新时间

在运动更新阶段, 更新时间与环境活动特征点数量有关, 稀疏化后活动特征点数量基本保持一定数目, 因此更新时间并没有剧增, 大大提高了计算效率(图 5). 在图 4 和 5 中可以看出机器人 R_2 更新曲线(浅色线条)在机器人 R_1 更新曲线(深色线条)上方, 由于设定的阈值 $\Gamma_1 < \Gamma_2$, 因此, 机器人 R_2 更新时间比机器人 R_1 更新时间多一点.




图5 ESEIF 算法运动更新时间

信息矩阵是个具有自然稀疏的矩阵, ESEIF 算法中的信息矩阵, 采用精确稀疏策略, 大大节省了信息矩阵存储空间. 从图 6 的 ESEIF 算法信息矩阵存储空间及标准 EIF 算法信息矩阵的大小可以明显看出, ESEIF 算法节省了很大额存储空间.




图6 ESEIF 算法信息矩阵存储空间

4 结论与展望

运用 ESEIF 算法探究多机器人 SLAM 问题, 通过控制多机器人和地图的结构来保持稀疏, 大大提高了计算效率. 采用 ESEIF 算法精确稀疏策略, 测量更新阶段时间基本上恒定, 与地图特征点数量无关, 仅与观测到的设定部分特征点有关. 实验数据表明, ESEIF 算法并没有产生较大的机器人位姿误差, 体现了算法有效性. 然而, ESEIF 算法在重定位过程中很大程度上决定了机器人位姿的估计精确性, 这就要求用于重定位特征点的准确性, 如何筛选质量好(不确定小)的特征点, 是下一步研究的主要内容.

参考文献:

[1] Thrun S, Liu Y, Koller D, et al. Simultaneous localization and mapping with sparse extended information filters[J].

International Journal of Robotics Research, 2004, 23(7/8): 693-716.

[2] Walter M, Eustice R, Leonard J. Exactly sparse extended information filter for feature-based SLAM[J]. The International Journal of Robotics Research. 2007, 26(4): 335-359.

[3] Walter M, Eustice R, Leonard J. Sparse extended information filters: Insights into sparsification[C]. Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems, Edmonton, 2005:3281-3288.

[4] Walter M. Sparse Bayesian information filters for localization and mapping[D]. United States, Woods Hole: The Woods Hole Oceanographic Institution, 2008.

[5] Thrun S, Koller D, Ghahramani Z, et al. Simultaneous mapping and localization with sparse extended information filters: Theory and Initial Results[C]. Proceedings of the Fifth International Workshop on Algorithmic Foundations of Robotics, Nice, France, 2002.

[6] 郭剑辉, 赵春霞, 石杏喜. 稀疏扩展信息滤波 SLAM 算法的稀疏规则研究[J]. 系统仿真学报, 2008, 20(24): 6673-6677.

[7] 郭剑辉, 赵春霞. 一种改进的稀疏扩展信息滤波 SLAM 算法[J]. 模式识别与人工智能, 2009, 22(2):263-269.

[8] Smith R, Self M, Cheeseman P. Estimating uncertain spatial relationships in robotics[J]. Uncertainty in Artificial Intelligence, 1986(2):267-288.

[9] 徐斌斌, 石守东, 王小波. 基于扩展信息滤波的多机器人 SLAM 研究[J]. 宁波大学学报: 理工版, 2011, 24(1): 38-41.

Multi-robot SLAM with Exactly Sparse Extended Information Filtering

MING Zhao-guang, SHI Shou-dong*, WANG Gang

(College of Information Science and Engineering, Ningbo University, Ningbo 315211, China)

Abstract: In the robot simultaneous localization and mapping (SLAM) problem, the Multi-robot SLAM has drawn much attention recently in robotics. This paper investigates the Multi-robot SLAM problem in using exactly sparse extended information filters algorithm (ESEIF): Based on both the multi-robot motion model and observation model, the multi-robot pose is estimated and the environment features are observed. The threshold is set for partitioning and updating the observed features, and marginalizing the robot pose followed by relocating the robot. The simulation shows that the robots pose can be accurately estimated, and observation can be updated in a constant time fashion irrespective of the number of features in the map.

Key words: SLAM; Multi-robot; exactly sparse extended information filters; relocalization

(责任编辑 章践立)