

## 基于因子图的多传感器融合定位方法<sup>①</sup>

孙晨阳<sup>②\*\*\*</sup> 张群莉\* 潘 聪<sup>\*\*\*</sup> 邵兵兵<sup>\*\*</sup> 方灶军<sup>③\*\*</sup>

(\* 浙江工业大学机械工程学院 杭州 310014)

(\*\* 中国科学院宁波材料技术与工程研究所 宁波 315201)

**摘 要** 针对移动机器人在室内环境中使用单一传感器或松耦合定位存在定位精度低和鲁棒性不足的问题,提出一种基于因子图的多传感器紧耦合定位算法。该算法分别接收来自惯性测量单元(IMU)、轮式编码器和 2D 激光雷达的数据,并构建 IMU 预积分因子、轮式里程计因子、位姿先验因子以及激光里程计因子;通过因子图对这些因子进行增量优化后输出得到移动机器人的状态信息,同时实时估计 IMU 的漂移量并进行校正。实验结果表明,无论是在未知环境还是已知环境下,该定位算法都可以有效提高移动机器人的定位精度和鲁棒性。

**关键词** 移动机器人;因子图优化;紧耦合;惯性测量单元(IMU)预积分

研究移动机器人技术的重要目标之一就是实现高精度的自主定位导航<sup>[1]</sup>,而准确的状态估计是实现该目标的关键技术之一,它可以为同时定位与建图(simultaneous localization and mapping, SLAM)、路径规划等其他关键技术提供所需的狀態信息。

常见的用于状态估计的传感器包括惯性测量单元(inertial measurement unit, IMU)、轮式编码器和 2D 激光雷达等,然而基于这些传感器的定位方法却各有优缺点。IMU 可以测得机器人本体的角速度和线加速度,但由于其本身存在随机误差<sup>[2]</sup>,这些输出量都有明显的漂移成分,使得积分后得到的机器人状态信息具有很大的误差,需要依靠激光雷达等外部传感器对其进行校正。对于快速运动物体检测,IMU 具有一定的优势,可以提供相对精确的状态估计信息。轮式编码器可以根据正运动学公式和航位推算法得到工作空间的状态信息,但由于运动学公式中相关参数未经标定<sup>[3]</sup>且移动机器人脚轮容易受地面打滑影响,获取的状态信息并不准确。在

机器人静止条件下由它得到的状态信息不会随着时间漂移,可对由 IMU 或 2D 激光雷达产生的状态信息提供零速校正和运动约束。2D 激光雷达存在测距精度高,抗光干扰能力强等优点,通过激光匹配<sup>[4]</sup>可以得到较为准确的状态信息,但是在动态环境或长走廊等特定环境下,激光匹配容易失效导致定位精度退化<sup>[5]</sup>。

由此可见,依靠单一传感器无法满足移动机器人自主定位导航的高精度定位要求,需要使用多传感器耦合技术,得到一个更加准确鲁棒的状态估计信息。目前多传感器耦合模型主要包括松耦合和紧耦合 2 种模型<sup>[6]</sup>,其中松耦合是先根据各个数据源分别产生各自的运动估计,再对这 2 个运动估计信息进行融合。尹皓等人<sup>[7]</sup>设计了非线性融合定位系统,通过高斯牛顿方程对激光雷达、IMU 和轮式里程计进行融合优化。张书亮等人<sup>[8]</sup>通过扩展卡尔曼滤波(extended Kalman filter, EKF)融合轮式里程计、惯性导航单元和超宽带定位,并利用自适应蒙特

① 国家自然科学基金(U1909215,92048201,52127803),浙江省重点研发计划(2022C01096),浙江省自然科学基金(LD22E050007),中科院装备研制项目(YJKYYQ20200030)和宁波市 2025 重大专项(2021Z020)资助项目。

② 男,1998 年生,硕士生;研究方向:移动机器人定位导航;E-mail: sunchenyang@nimte.ac.cn。

③ 通信作者,E-mail: fangzaojun@nimte.ac.cn。

(收稿日期:2022-10-27)

卡洛定位进一步融合激光雷达实现定位效果。这种模型计算简单易于实现,但是会依赖于激光点云的配准精度,且不能消除 IMU 的漂移量从而导致累计误差越来越大。而紧耦合直接融合各个数据源的原始数据,能够实时估计 IMU 的漂移量并进行校正,相比于松耦合模型具有更好的定位精度和鲁棒性。Qin 等人<sup>[9]</sup>采用以机器人为中心的紧耦合状态估计器,通过迭代误差状态卡尔曼滤波器递归地校正估计的状态信息。Shan 等人<sup>[10]</sup>通过平滑与建图完成紧耦合激光惯性里程计框架构建,且可以添加多个相对或绝对测量源作为因子添加进框架中。吕攀等人<sup>[11]</sup>通过多状态约束卡尔曼滤波器对激光雷达和 IMU 数据进行紧耦合。

针对移动机器人使用单一传感器或通过多传感器松耦合融合方法存在定位精度低、鲁棒性不足的问题,本文提出一种基于因子图的多传感器紧耦合定位算法。该算法先由 IMU 预积分模型预测机器人状态信息,利用由粗到细的激光匹配方式对其进行更新后,以 IMU 输出频率发布该定位结果,同时通过因子图对 IMU 漂移量进行估计并校正。

## 1 基于因子图的定位算法整体框架

在介绍框架之前,先对本文采用的符号进行说明。设惯性坐标系为  $W$ , 机器人坐标系为  $B$ , 同时为了计算简便设 IMU 体坐标系与机器人坐标系相一致。令机器人状态向量为

$$\mathbf{x} = [\mathbf{p} \quad \mathbf{v} \quad \mathbf{R} \quad \mathbf{b}_a \quad \mathbf{b}_g]^T$$

其中,  $\mathbf{p} \in \mathbb{R}^3$  是位置向量,  $\mathbf{v} \in \mathbb{R}^3$  是速度向量,  $\mathbf{R} \in \text{SO}(3)$  是姿态旋转矩阵,  $\mathbf{b}_a$  和  $\mathbf{b}_g$  分别是 IMU 上加速度计和陀螺仪的漂移量。令  $\mathbf{T} = [\mathbf{R}, \mathbf{p}] \in \text{SE}(3)$  表示从  $W$  到  $B$  的变换矩阵。另外,  $\mathbb{R}^3$  表示三维空间,  $\text{SO}(3)$  表示三维特殊正交群,  $\text{SE}(3)$  表示三维特殊欧式群。

因子图是一种由表示优化变量的变量节点  $\mathbf{x}_k \in \mathbf{X}$  和表示观测约束的因子节点  $f_k \in \mathbf{F}$  2 种节点构成的二分图<sup>[12]</sup>。由于机器人状态估计通常是最大后验概率分布问题且常假设高斯测量误差,因此可以通过因子图对其进行建模并假设图中各因子的条

件概率为高斯分布,再将该最大后验问题等价转化为非线性最小二乘问题。

基于因子图的多传感器紧耦合定位算法的整体框架如图 1 所示。该框架通过 4 个不同类型的因子节点以及 1 个变量节点来构建因子图。其中变量节点表示机器人在特定时刻的状态信息,该时刻由激光关键帧的时间戳决定,另外 4 个因子节点表示不同时刻的状态约束。每当机器人的状态变化量超过一定阈值时,便会有新的变量节点以及相应的因子节点添加进因子图中,构成如下式所示的目标函数:

$$F(\mathbf{x}_k) = \|\mathbf{f}_k^{\text{INS}}(\mathbf{x}_{k-1}, \mathbf{x}_k)\|_{\Sigma_k^{\text{INS}}}^2 + \|\mathbf{f}_k^{\text{WO}}(\mathbf{x}_{k-1}, \mathbf{x}_k)\|_{\Sigma_k^{\text{WO}}}^2 + \|\mathbf{f}_k^{\text{PP}}(\mathbf{x}_k)\|_{\Sigma_k^{\text{PP}}}^2 + \|\mathbf{f}_k^{\text{LO}}(\mathbf{x}_{k-1}, \mathbf{x}_k)\|_{\Sigma_k^{\text{LO}}}^2 \quad (1)$$

其中,  $f_k^{\text{INS}}(\cdot)$  是 IMU 预积分因子,  $f_k^{\text{WO}}(\cdot)$  是轮式里程计因子,  $f_k^{\text{PP}}(\cdot)$  是位姿先验因子,  $f_k^{\text{LO}}(\cdot)$  是激光里程计因子,  $\Sigma_k^{\cdot}$  是各个因子的协方差矩阵。通过 iSAM2 增量优化算法<sup>[13]</sup>将该目标函数转化成贝叶斯树进行建立、更新,并推理得到移动机器人状态信息,最终以 IMU 输出频率发布里程计定位结果。

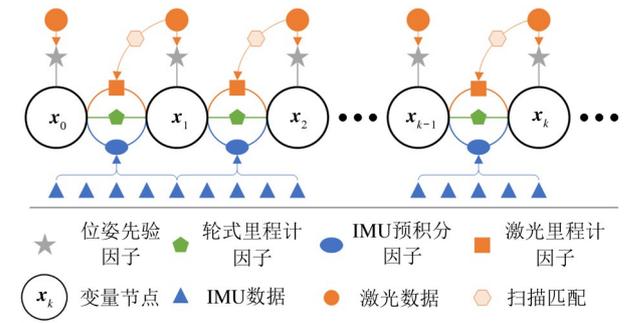


图 1 算法框架

## 2 因子节点构建

### 2.1 IMU 预积分因子

由于 IMU 的量测数据受系统误差和随机误差的影响,本文假设系统误差已经被校正过,因此受随机误差影响的 IMU 量测模型为

$$\begin{aligned} \tilde{\mathbf{a}} &= \mathbf{R}(\mathbf{a} - \mathbf{g}) + \mathbf{b}_a + \mathbf{n}_a \\ \tilde{\boldsymbol{\omega}} &= \boldsymbol{\omega} + \mathbf{b}_g + \mathbf{n}_g \end{aligned} \quad (2)$$

其中,  $\tilde{\mathbf{a}}$  和  $\tilde{\boldsymbol{\omega}}$  分别是 IMU 在体坐标系下的线加速度量测值和角速度量测值,  $\mathbf{a}$  和  $\boldsymbol{\omega}$  表示 IMU 在惯性坐标系下的线加速度真实值和角速度真实值,  $\mathbf{g}$  是惯性坐标系下的重力常量, 而  $\mathbf{n}_a$  和  $\mathbf{n}_g$  分别是 IMU 加速度计和陀螺仪的高斯白噪声。

根据 IMU 的量测模型, 可以通过 IMU 离散积分模型对  $t$  和  $t + \Delta t$  时刻间的 IMU 量测数据进行积分, 得到:

$$\begin{aligned} \mathbf{p}_{t+\Delta t} &= \mathbf{p}_t + \mathbf{v}_t \Delta t + \frac{1}{2} \mathbf{g} \Delta t^2 \\ &\quad + \frac{1}{2} \mathbf{R}_t (\tilde{\mathbf{a}}_t - \mathbf{b}_{a,t} - \mathbf{n}_{ad,t}) \Delta t^2 \\ \mathbf{v}_{t+\Delta t} &= \mathbf{v}_t + \mathbf{g} \Delta t + \mathbf{R}_t (\tilde{\mathbf{a}}_t - \mathbf{b}_{a,t} - \mathbf{n}_{ad,t}) \Delta t \\ \mathbf{R}_{t+\Delta t} &= \mathbf{R}_t \exp((\tilde{\boldsymbol{\omega}}_t - \mathbf{b}_{g,t} - \mathbf{n}_{gd,t}) \Delta t) \end{aligned} \quad (3)$$

其中,  $\Delta t$  是 IMU 量测周期,  $\mathbf{n}_{ad,t}$  和  $\mathbf{n}_{gd,t}$  分别是 IMU 加速度计和陀螺仪在  $t$  时刻的高斯白噪声离散化后的随机游走噪声。

在因子图迭代优化过程中, 为了避免对 IMU 量测数据重复积分, 浪费大量计算资源, 可以利用如图 2 所示的 IMU 预积分模型<sup>[14]</sup>。该模型通过对离散积分模型等量变换  $\mathbf{R}_k = \mathbf{R}_{k-1} \mathbf{R}_{k-1,k}$ , 得到一个 IMU 预积分量  $\mathbf{z}_k^{\text{INS}}$ , 这样在因子图迭代优化的过程中, 只需要对积分运算之外的状态信息进行调整, 而保持 IMU 预积分模型的结果相对不变, 便可以构建 IMU 预积分因子:

$$f_k^{\text{INS}}(\mathbf{x}_{k-1}, \mathbf{x}_k) = L_{k-1,k}(\mathbf{x}_k - h^{\text{INS}}(\mathbf{x}_{k-1}, \mathbf{z}_k^{\text{INS}})) \quad (4)$$

其中,  $h^{\text{INS}}(\mathbf{x}_{k-1}, \mathbf{z}_k^{\text{INS}})$  是根据上一激光关键帧与 IMU 预积分量得到的当前激光关键帧的估计值。  $L(\cdot)$  对于高斯分布噪声定义为平方马氏距离, 即  $L(\mathbf{e}_k) = \mathbf{e}_k^T \boldsymbol{\Sigma}^{-1} \mathbf{e}_k$ ,  $\boldsymbol{\Sigma}$  常取噪声协方差矩阵, 并将该因子节点添加进因子图中。

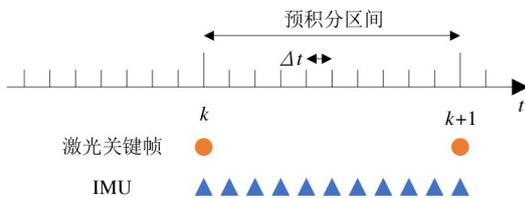


图 2 IMU 预积分模型

IMU 预积分模型的优势除了能够提高运算效

率、节省计算资源、自然而然地往因子图中添加该类因子节点之外, 由于 IMU 的输出频率相比激光雷达更高, 使用因子图估计出最新的 IMU 漂移量并进行校正之后, 可以通过该模型为下一激光关键帧提供先验状态信息, 同时能够以 IMU 的输出频率发布里程计定位结果。

## 2.2 轮式里程计因子

为了避免激光雷达定位效果受动态环境的影响, 同时在因子图优化过程中提供零速校正和运动约束来更好地估计出 IMU 的漂移量, 可以使用轮式编码器来获得移动机器人在平面上的状态信息。本文所使用的移动机器人单个脚轮的模型如图 3 所示, 该脚轮的正运动学模型如下:

$$\begin{bmatrix} -\cos\beta & -\sin\beta & -L\sin(\beta + \alpha) \\ -\sin\beta & \cos\beta & L\cos(\beta + \alpha) - d \end{bmatrix} \begin{bmatrix} v_x \\ v_y \\ \omega_z \end{bmatrix} = \begin{bmatrix} r\dot{\theta} \\ d\dot{\beta} \end{bmatrix} \quad (5)$$

其中,  $\beta$  是脚轮转动角度,  $L$  是脚轮到车体中心的长度,  $\alpha$  是脚轮与车体的夹角,  $d$  是脚轮偏置长度,  $r$  是脚轮半径长度,  $\dot{\theta}$  是脚轮滚动速度,  $\dot{\beta}$  是脚轮转动速度, 可以推广得到整个移动机器人的正运动学模型。另外  $v_x$  和  $v_y$  是  $\mathbf{v}$  在地面上的投影, 而  $\omega_z$  是机器人绕地面法线的角速度。

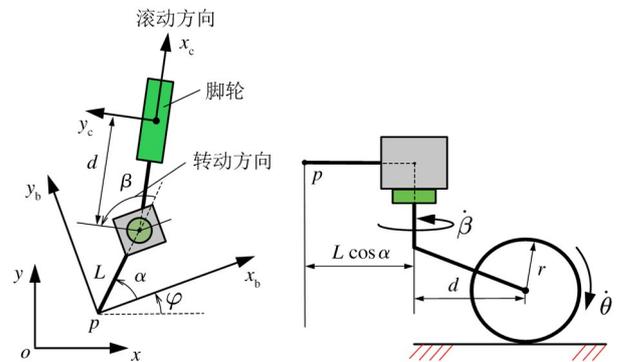


图 3 单个脚轮模型

同时利用最小二乘法和航位推算算法便能得到移动机器人在惯性坐标系下的状态信息  $\mathbf{T}$ , 直到累计得到 2 个激光关键帧之间的轮式里程计增量  $\mathbf{z}_k^{\text{WO}}$ , 就可以通过式(6)构建轮式里程计因子。

$$f_k^{\text{WO}}(\mathbf{x}_{k-1}, \mathbf{x}_k) = L_{k-1,k}(\mathbf{x}_k - h^{\text{WO}}(\mathbf{x}_{k-1}, \mathbf{z}_k^{\text{WO}})) \quad (6)$$

其中,  $h^{w0}(\mathbf{x}_{k-1}, \mathbf{z}_k^{w0})$  是根据上一激光关键帧与轮式里程计增量得到的当前激光关键帧的估计值, 并将该因子节点添加进因子图中。

### 2.3 激光里程计因子

目前常见的激光匹配算法有很多, 其中点线迭代最近点 (point-to-line iterative closing points, PLICP) 算法<sup>[15]</sup> 匹配精度较高, 但其对初始值较为敏感; 而相关性扫描匹配算法<sup>[16]</sup> 由于采用了帧图匹配方式, 相比 PLICP 具有更好的鲁棒性。因此, 本文将融合相关性扫描匹配算法和 PLICP 2 种方法, 即由粗到细的匹配方式。先通过相关性扫描匹配算法接收由 IMU 预积分模型提供的先验值, 获得一个鲁棒的初值之后再利用 PLICP 得到精度更高的状态信息。

#### 2.3.1 相关性扫描匹配算法

与机器人状态估计类似, 相关性扫描匹配算法也将激光匹配问题看成一个最大后验概率分布问题, 即求出当前帧最优位姿估计  $\mathbf{T}_k$  使得概率模型  $p(\mathbf{T}_k | \mathbf{T}_{k-1}, \mathbf{u}_k, q_k, m)$  的概率值最大化。通过贝叶斯法则并移除不相关条件, 从该模型可以得到:

$$p(\mathbf{T}_k | \mathbf{T}_{k-1}, \mathbf{u}_k, q_k, m) \propto p(\mathbf{T}_k | \mathbf{T}_{k-1}, \mathbf{u}_k) p(q_k | \mathbf{T}_k, m) \quad (7)$$

其中,  $p(\mathbf{T}_k | \mathbf{T}_{k-1}, \mathbf{u}_k)$  是运动模型, 即由上一激光关键帧位姿  $\mathbf{T}_{k-1}$  和帧间位姿变化量  $\mathbf{u}_k$  获得当前帧位姿  $\mathbf{T}_k$ ;  $p(q_k | \mathbf{T}_k, m)$  是激光观测模型, 即通过当前帧位姿  $\mathbf{T}_k$  和由固定尺寸窗口内的所有激光关键帧形成的局部概率栅格地图  $m$  获得当前帧观测数据  $q_k$ 。

根据式(7)可知, 为了获得最大后验概率, 可以从运动模型和激光观测模型两方面入手, 而由于 IMU 预积分模型, 运动模型的概率值为一定值, 因此需要对激光观测模型进行分析处理。

假设当前帧的各个激光点位置的概率分布是彼此独立的, 那么:

$$p(q_k | \mathbf{T}_k, m) = \prod_i p(q_k^i | \mathbf{T}_k, m) \quad (8)$$

其中,  $q_k^i$  表示当前帧观测数据中的各个激光点。激光观测模型如图 4 所示, 可以理解为按照当前帧位姿  $\mathbf{T}_k$  把当前帧观测数据  $q_k$  投影到已知的概率栅格

地图  $m$  中。由于采用了概率栅格地图, 每个栅格都维护一个对数形式的概率值, 式(8)中的乘法可转换成加法, 对所有被击中的栅格的概率值进行相加即可得到激光观测模型的概率值。它表示在该位姿下, 当前帧观测数据  $q_k$  与已知地图  $m$  相一致的程度。

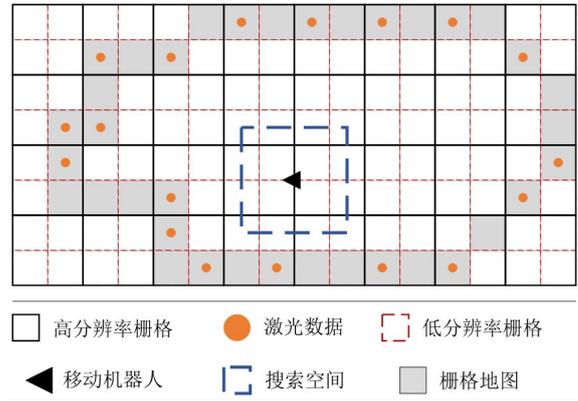


图 4 激光观测模型

为了得到更高的激光观测模型概率值, 可以在由 IMU 预积分模型提供的先验状态信息  $\mathbf{T}_k$  附近建立关于  $\mathbf{T}_k$  的搜索空间。同时可以采用如图 4 所示的多分辨率地图以及分支定界法<sup>[17]</sup> 以提高在搜索空间内的搜索速度。最后将得分最高的备选位姿作为位姿初值  $\hat{\mathbf{T}}_k$  进行输出。

#### 2.3.2 PLICP 算法

获得相关性扫描匹配算法输出的位姿初值  $\hat{\mathbf{T}}_k$  后, 便可以将当前帧观测数据  $q_k$  映射到上一激光关键帧的坐标系中; 再从上一激光关键帧中寻找与  $q_k^i$  距离最近的 2 个点, 分别记为  $q_{k-1}^1$  和  $q_{k-1}^2$ , 构成点到线段的匹配对。

完成所有的点线配对后, 就能利用拉格朗日乘子法迭代优化求解 PLICP 的误差模型:

$$f(\mathbf{T}) = \sum_i (\mathbf{n}_i^T [\mathbf{T}_k q_k^i - q_{k-1}^i])^2 \quad (9)$$

其中,  $\mathbf{n}_i^T$  是由  $q_{k-1}^1$  和  $q_{k-1}^2$  所形成线段上的归一化法向量。最终得到当前帧的最优位姿值  $\mathbf{T}_k$ 。

为了提高计算效率, 本文的定位算法只考虑对激光关键帧进行优化。因此在获得当前帧的最优位姿  $\mathbf{T}_k$  后, 需要与上一激光关键帧位姿  $\mathbf{T}_{k-1}$  进行对比, 若变化量超过一定阈值则认为当前帧为关键帧,

并将  $T_k$  作为新关键帧的位姿先验因子添加进因子图中,同时将这 2 个激光关键帧之间的位姿变换  $z_k^{LO}$  代入激光里程计因子:

$$f_k^{LO}(\mathbf{x}_{k-1}, \mathbf{x}_k) = L_{k-1,k}(\mathbf{x}_k - h^{LO}(\mathbf{x}_{k-1}, z_k^{LO})) \quad (10)$$

其中,  $h^{LO}(\mathbf{x}_{k-1}, z_k^{LO})$  是根据上一激光关键帧与激光里程计增量得到的当前激光关键帧的估计值,并将该因子节点添加进因子图中。

### 3 实验与结果

#### 3.1 实验设置

本文采用了中科院宁波材料所研发的基于解耦式主动万向脚轮的全向移动机器人,如图 5 所示。该机器人安装了 2 台北洋 UST-20LX 型号的 2D 激光雷达,1 台 Xsens MTi-300 型号的 IMU 以及 8 台轮式编码器;并将一台 CPU 型号为 i7-10510U、内存为 16 GB 的工控机以及一台 Galil DMC-2183 型号的运动控制卡分别作为上位机和下位机使用。其中激光雷达安装在机器人的对角线,IMU 安装在机器人的重心方向上。本文所提出的定位算法的编程语言完全基于 C++,并在基于 Ubuntu18.04 的机器人操作系统(robot operating system,ROS)上运行。

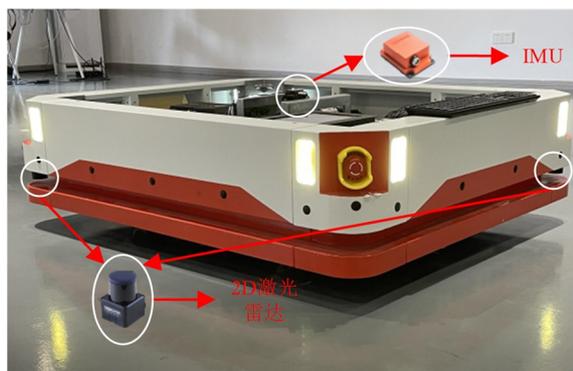


图 5 移动机器人

#### 3.2 实验测试

为了验证本文所提出的定位算法的有效性,选择激光里程计 PLICP 以及通过 EKF 对 PLICP 和 IMU 数据进行松耦合得到的里程计这 2 种算法与本文算法进行对比实验,该实验分别在未知环境和已知环境中进行。由于姿态误差可以体现在位置误差

中,本实验只对位置进行精度测试。

##### 3.2.1 未知环境实验

在已知轮式编码器分辨率的情况下,通过控制轮式编码器使移动机器人以  $0.4 \text{ m} \cdot \text{s}^{-1}$  的固定速度在姿态不变的情况下移动一圈,如图 6(a) 所示,图中箭头表示机器人姿态朝向。期间通过上位机采集各个传感器的量测数据。为了减少偶然因素的影响,重复进行该项实验,并将各定位算法得出的测量值与实际值进行对比得到如图 7 所示的位置误差分布图。

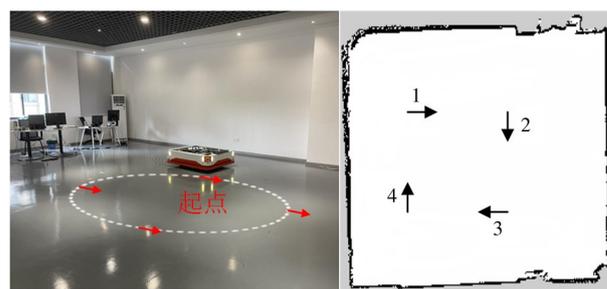


图 6 实验轨迹

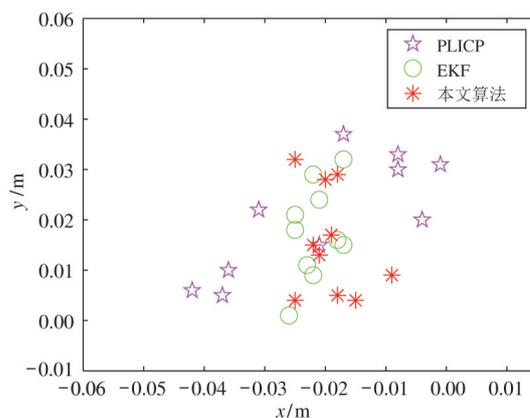


图 7 位置误差分布

根据图 7 所示的误差分布,可以看出在环境未知的情况下,激光里程计 PLICP 最大误差达到  $0.0424 \text{ m}$ ,通过 EKF 得到的松耦合激光里程计最大误差有  $0.0364 \text{ m}$ ,本文算法得到的最大误差达到  $0.0406 \text{ m}$ ,虽然本文算法的最大误差相比松耦合激光里程计较差,但从整体而言,本文所提出的定位算法相比其他算法得到的位置误差明显更小且误差分布更加集中。

为了定量地描述测量值偏离实际值的程度,采

用均方根误差 (root mean square error, RMSE) 公式获得各定位算法的精度, 如表 1 所示。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\mathbf{p}_i - \mathbf{p}_m)^2} \quad (11)$$

其中  $\mathbf{p}_m$  是实际测量值。

表 1 定位精度结果

定位算法	定位精度/m
PLICP	0.034 4
EKF	0.029 4
本文算法	0.027 1

从表 1 可以看出, 在定位精度方面, 本文所提出的定位算法相比激光里程计提升了 21.22%, 相比松耦合激光里程计提升了 7.82%。说明在未知环境中, 本文的定位算法在定位精度以及鲁棒性方面比其他算法有较高的提升。

### 3.2.2 已知环境实验

将该实验的操作步骤分为 4 步, 具体步骤如下:

(1) 利用 ROS 自带的开源 2D 激光 SLAM 算法 gmapping<sup>[18]</sup> 在室内环境下建立占据栅格地图, 再通过基于 ROS 的开源定位导航框架实现定位导航功能。

(2) 使用状态机程序在栅格地图中选取 4 个位置点以及相应角度作为移动机器人的目标点。为了保证移动机器人在前往目标点时有足够的角度变化, 从 1 号点到 4 号点, 每次目标点角度增加 90°, 如图 6(b) 所示。

(3) 以最高  $1 \text{ m} \cdot \text{s}^{-1}$  的速度进行定位导航, 期间周围有动态移动物体, 通过状态机程序向其依次发送 1 号到 4 号目标点的位姿, 期间采集各个传感器的量测数据, 并测量记录移动机器人在每个目标点的实际位姿。

(4) 多次重复实验, 并通过各定位算法获得移动机器人在各目标点的测量值。

为了避免移动机器人在目标点附近不断调整位姿而无法到达目标点的情况<sup>[19]</sup>, ROS 的定位导航框架会设定一个目标阈值来避免发生这种情况。因此在该实验中, 移动机器人导航到各目标点时的实际位置与目标点并不相同, 所以实际定位误差还包含

了导航误差。为了更准确地比较定位算法, 将步骤(4)获得的测量值与实际位置进行对比, 得到如图 8 所示的位置误差分布图。

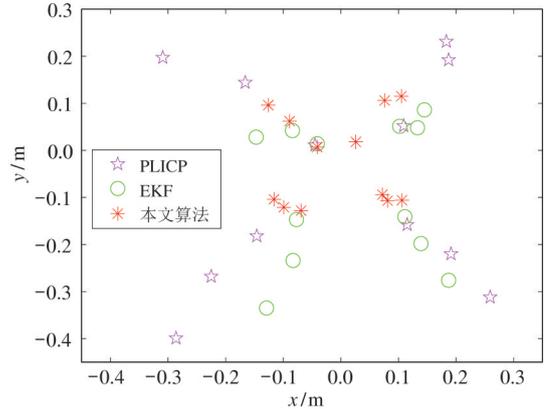


图 8 位置误差分布

从图 8 中可以看出, 在最大误差方面, 激光里程计 PLICP 达到 0.490 9 m, 松耦合激光里程计达到 0.359 0 m, 本文算法达到 0.158 4 m, 相比其他算法有明显提升。对于误差值大小和误差分布程度, 同样通过式(11)对 3 种算法的整体效果进行定量分析, 得到如表 2 所示的定位精度。

表 2 定位精度结果

定位算法	定位精度/m
PLICP	0.297 7
EKF	0.207 0
本文算法	0.130 8

根据表 2 可知, 在已知环境中进行定位导航时, 由于移动机器人处于动态环境, 运动轨迹相比上个实验更加复杂, 在定位精度方面, 本文算法相比激光里程计提高了 56.06%, 相比松耦合激光里程计提高了 36.81%, 可见本文算法的定位精度以及鲁棒性最好。

## 4 结论

针对移动机器人使用单一传感器或通过多传感器松耦合融合定位存在定位精度低以及鲁棒性不足的问题, 本文提出了一种基于因子图的多传感器紧耦合定位算法。与现有的激光里程计以及通过

EKF 的松耦合定位算法相比,无论是在未知环境还是已知环境下,该算法在定位精度和可靠性方面均有明显提升,证明了该定位算法在 SLAM、定位导航等领域中的有效性。

#### 参考文献

- [ 1 ] MOHAMED S A, HAGHBAYAN M H, WESTERLUND T, et al. A survey on odometry for autonomous navigation systems[J]. *IEEE Access*, 2019,7:97466-97486.
- [ 2 ] JOHNSON B, ALBRECHT C, BRAMAN T, et al. Development of a navigation-grade MEMS IMU[C]//2021 IEEE International Symposium on Inertial Sensors and Systems (INERTIAL). Kailua-Kona, USA: IEEE, 2021:1-4.
- [ 3 ] LIU J, GAO W, HU Z. Visual-inertial odometry tightly coupled with wheel encoder adopting robust initialization and online extrinsic calibration[C]//2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Macau, China: IEEE, 2019:5391-5397.
- [ 4 ] LI X, DU S, LI G, et al. Integrate point-cloud segmentation with 3D LiDAR scan-matching for mobile robot localization and mapping[J]. *Sensors*, 2019,20(1):237.
- [ 5 ] ZHEN W, SCHERER S. Estimating the localizability in tunnel-like environments using LiDAR and UWB[C]//2019 International Conference on Robotics and Automation. Montreal, Canada: ICRA, 2019:4903-4908.
- [ 6 ] CIOFFI G, SCARAMUZZA D. Tightly-coupled fusion of global positional measurements in optimization-based visual-inertial odometry[C]//2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Las Vegas, USA: IEEE, 2020:5089-5095.
- [ 7 ] 尹皓, 李海滨, 王利利. 基于多传感器融合的移动机器人定位研究[J]. *机床与液压*, 2021,49(9):6-10.
- [ 8 ] 张书亮, 谭向全, 吴清文. 基于多传感器融合技术的室内移动机器人定位研究[J]. *传感器与微系统*, 2021,40(8):53-56.
- [ 9 ] QIN C, YE H, PRANATA C E, et al. Lins: a lidar-inertial state estimator for robust and efficient navigation[C]//2020 IEEE International Conference on Robotics and Automation (ICRA). Paris, France: IEEE, 2020:8899-8906.
- [ 10 ] SHAN T, ENGLLOT B, MEYERS D, et al. LIO-SAM: tightly-coupled lidar inertial odometry via smoothing and mapping[C]//2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Las Vegas, USA: IEEE, 2020:5135-5142.
- [ 11 ] 吕攀, 辛越, 张恒, 等. 基于 MSCKF 的 IMU 与激光雷达紧耦合定位方法[J]. *仪器仪表学报*, 2020,41(8):13-20.
- [ 12 ] WEN W, PFEIFER T, BAI X, et al. Factor graph optimization for GNSS/INS integration: a comparison with the extended Kalman filter[J]. *NAVIGATION: Journal of the Institute of Navigation*, 2021,68(2):315-331.
- [ 13 ] KAESS M, JOHANSSON H, ROBERTS R, et al. iSAM2: incremental smoothing and mapping using the Bayes tree[J]. *The International Journal of Robotics Research*, 2012,31(2):216-235.
- [ 14 ] FORSTER C, CARLONE L, DELLAERT F, et al. On-manifold preintegration for real-time visual: inertial odometry[J]. *IEEE Transactions on Robotics*, 2016,33(1):1-21.
- [ 15 ] CENSI A. An ICP variant using a point-to-line metric[C]//2008 IEEE International Conference on Robotics and Automation. Pasadena, USA: IEEE, 2008:19-25.
- [ 16 ] OLSON E B. Real-time correlative scan matching[C]//2009 IEEE International Conference on Robotics and Automation. Kobe, Japan: IEEE, 2009:4387-4393.
- [ 17 ] POIKONEN S, GOLDEN B, WASIL E A. A branch-and-bound approach to the traveling salesman problem with a drone[J]. *INFORMS Journal on Computing*, 2019,31(2):335-346.
- [ 18 ] GRISETTI G, STACHNISS C, BURGARD W. Improved techniques for grid mapping with rao-blackwellized particle filters[J]. *IEEE Transactions on Robotics*, 2007,23(1):34-46.
- [ 19 ] 刘玉祥. 多传感器融合与点云匹配的移动机器人定位算法研究[D]. 成都:电子科技大学, 2020.

## Multi-sensor fusion localization method based on factor graph

SUN Chenyang<sup>\*\*</sup>, ZHANG Qunli<sup>\*</sup>, PAN Cong<sup>\*\*</sup>, SHAO Bingbing<sup>\*\*</sup>, FANG Zaojun<sup>\*\*</sup>

(\* College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014)

(\*\* Ningbo Institute of Materials Technology and Engineering, Chinese Academy of Sciences, Ningbo 315201)

### Abstract

Aiming at the problems of low localization accuracy and insufficient robustness of mobile robots using single sensor or loosely coupled localization in indoor environment, a multi-sensor tightly coupled localization algorithm based on factor graph is proposed. The algorithm receives data from inertial measurement unit (IMU), wheel encoder and 2D lidar, and constructs IMU pre-integration factor, wheel odometry factor, pose prior factor and laser odometry factor. The state information of the mobile robot is obtained after incremental optimization of these factors through the factor graph, and the drift of the IMU is estimated and corrected in real time. Experimental results show that the localization algorithm can effectively improve the localization accuracy and robustness of mobile robots in unknown or known environments.

**Key words:** mobile robot, factor graph optimization, tightly-coupled, inertial measurement unit (IMU) pre-integration