

DOI:10.19651/j.cnki.emt.2211255

UWB与IMU融合的室内动态定位算法*

王鹏 侯忠生

(青岛大学自动化学院 青岛 266071)

摘要:针对超宽带(UWB)定位易受多种噪声和非视距(NLOS)的影响产生定位误差的问题,提出了一种基于UWB与惯性测量单元(IMU)融合的室内动态定位算法。该算法首先采用扩展卡尔曼滤波算法对基于到达角度(AOA)定位方法的位置信息进行滤波,并与IMU数据进行时间同步,通过相邻时刻UWB位置信息变化速度与IMU所测量标签运动速度对比,实现对NLOS数据的识别及补偿,从而降低NLOS对定位精度的影响;然后基于改进粒子滤波算法对融合后的数据进行最优估计,以抑制噪声的干扰,最终实现对标签的准确定位。实验结果表明,所提算法采用基于AOA的定位方法可以在保证定位精度的前提下节约硬件成本;与单一使用UWB传感器的定位方案相比,所提算法可根据IMU提供的先验信息有效降低UWB的定位误差,在非视距环境下具备较高可靠性;与基于扩展卡尔曼滤波和无迹卡尔曼滤波的融合算法相比,定位精度分别提高了65.6%和56.0%;与标准粒子滤波算法相比,所提算法基于改进的粒子滤波算法运行时间缩短了42.3%。

关键词:超宽带;惯性测量单元;扩展卡尔曼滤波;改进粒子滤波;动态定位

中图分类号: TN96 **文献标识码:** A **国家标准学科分类代码:** 53510

Indoor dynamic positioning algorithm fused with UWB and IMU

Wang Peng Hou Zhongsheng

(School of Automation, Qingdao University, Qingdao 266071, China)

Abstract: An indoor dynamic positioning algorithm based on UWB and inertial measurement unit (IMU) fusion is proposed to deal with the problem that ultra-wideband (UWB) positioning is susceptible to various noises and non-line-of-sight (NLOS). The algorithm firstly uses the extended Kalman filtering algorithm to filter the position information based on the angle of arrival (AOA) positioning method, and synchronizes the time with IMU data. By comparing the change speed of UWB position information at adjacent times with the movement speed of tags measured by IMU, the algorithm realizes the recognition and compensation of NLOS data, thus reducing the impact of NLOS on positioning accuracy. Then the improved particle filtering algorithm is used to optimally estimate the fused data to suppress noise interference and finally achieve accurate label location. The experimental results show that the proposed algorithm using AOA based location method can save the hardware cost while ensuring the location accuracy. Compared with the positioning scheme using only UWB sensors, the proposed algorithm can effectively reduce the positioning error of UWB according to the prior information provided by IMU, and has high reliability in the non-line of sight environment. Contrary to the fusion algorithm based on extended Kalman filter and unscented Kalman filter, the positioning accuracy is improved by 65.6% and 56.0% respectively. In contrast to the standard particle filtering algorithm, the running time of the proposed algorithm based on the improved particle filtering algorithm is reduced by 42.3%.

Keywords: ultra-wide band; inertial measurement unit; extended Kalman filter; improved particle filter; dynamic positioning

0 引言

随着物联网发展以及快递仓库机器人、博物馆导航、智能家居等智能设备的广泛应用,人们对室内定位的精度要

求越来越高。目前广泛应用的室内定位技术主要有 Wi-Fi、蓝牙和超宽带(ultra-wide band, UWB)^[1],其中 UWB 技术与 Wi-Fi、蓝牙相比具有如下优点:1)精准度高, WiFi 和蓝牙精确度分别为 2~50 m 和 2~10 m,而 UWB 能达到

收稿日期:2022-09-02

* 基金项目:国家自然科学基金(61833001)项目资助

cm 级;2)安全性高,UWB 的脉冲信号持续时间为 ns,且通常分布在很宽的频谱上,因此每个脉冲的能量非常低,所以不容易被捕获^[2];3)可靠性高、实时性好、延时短,分辨率可达 mm 级;4)覆盖范围广,蓝牙仅为 10~15 m,WiFi 为 50~150 m,而 UWB 可达 25~250 m。但 UWB 定位易受到噪声和非视距的影响,导致定位不准确^[3]。

UWB 技术通常基于到达时间(time of arrival, TOA)、到达时间差(time difference of arrival, TDOA)、到达角度(angle of arrival, AOA)或者到达相位差(phase difference of arrival, PDOA)^[4]实现室内定位。然而,基于 TOA 或 TDOA 的方法需要基站设备较多;且基于 TDOA 的方法需要基站之间严格时间同步,增加了施工难度;基于 PDOA 的方法仅在一定范围内定位结果较准确,超过该范围则存在较大误差;而基于 AOA 的定位方法无需基站间时间同步,只需两个基站即可完成定位。

为了减弱基于 UWB 的定位方法中噪声和非视距的影响,文献[5]在最小二乘算法的目标函数中引入线性误差分析项,使用 BP 神经网络训练方法建立了高精度的测距模型,但训练神经网络需要大量数据和计算资源;文献[6]在定位算法中融入路径损耗模型并使用标准卡尔曼滤波算法,提升了在非视距环境下的定位效果,但标准卡尔曼滤波对非线性模型处理能力有限;文献[7]提出了一种基于改进无迹卡尔曼滤波(UKF)的静态定位算法,通过构建状态误差补偿函数对标签位置进行自适应补偿,实验证明该算法的定位精度高于最小二乘和标准 UKF 算法;文献[8]提出了一种基于 TOA-AOA 的融合定位算法,仿真结果表明比单一基于 AOA 定位方法的精度有所提高;文献[9]提出了一种基于粒子滤波(PF)和最大似然的 TDOA 定位算法,仿真表明,同样场景下 PF+TDOA 算法的定位精度高于 UKF+TDOA 算法。虽然通过上述方法对定位精度有所提高,但单一使用 UWB 传感器定位具有局限性,将 UWB 与惯性测量单元(inertial measurement unit, IMU)组合是一种低成本且能有效提高精度的定位方式。文献[10]使用基于扩展卡尔曼滤波(EKF)算法的松耦合方式来跟踪行人的移动;文献[11]利用 EKF 对 UWB 和基于 IMU 的行人航位推算技术(PDR)进行融合改进,实验结果表明该算法可以有效提升室内定位的精度;文献[12]在 EKF 融合算法的基础上通过增加自适应校准因子来动态调整 UWB 观测值的权重,从而校准位置误差;文献[13]采用 UKF 算法对 UWB 和 IMU 数据进行融合以提高定位精度。上述文献中,文献[5,13]都通过最小二乘算法解算 UWB 的定位结果,虽然初始迭代时收敛速度很快,但受观测误差的影响较大;文献[10-12]中基于 EKF 的融合算法精度不高、稳定性较差、对运动目标反应迟缓;文献[7,13]均选择了 UKF 算法,虽然可以提高定位精度,但 UKF 算法需要进行无损变换和选取 sigma 点,实现较复杂,且对非高斯噪声的抑制能力不强;与文献[10]中的松耦合融合方式相比,文献[11-13]

的紧耦合融合方式有更好的抗差分噪声性能。

综上所述,本文提出了一种基于 UWB 与 IMU 融合的室内动态定位算法。该算法首先选择 EKF 滤波算法对 UWB 的定位结果进行平滑处理,然后设计 NLOS 补偿机制以降低其对定位精度的影响,最后采用基于 PF 的紧耦合融合方式将 UWB 的定位结果与 IMU 数据进行融合。本文的主要贡献为:1)选择基站需要数较少的基于 AOA 的定位方法,并采用受误差影响更小的 EKF 算法求解 UWB 的定位结果;2)相较于文献[11-13]中的方法,只利用 IMU 测得标签的加速度与速度数据,减小了向量维数,降低了计算复杂度和对计算性能的要求,加快了算法运行速度;3)基于 PF 的紧耦合融合算法相较于基于 EKF 和 UKF 的紧耦合融合算法处理非线性模型和抑制噪声的能力更强;4)在 PF 算法的基础上自适应调整粒子数目,节约了计算资源,提高了计算效率。

1 基于 AOA 定位方法原理

基于 AOA 的定位方法是基于双向测距(two way ranging, TWR)获取距离信息实现的。TWR 测距分为单边双向测距(single sided two way ranging, SS-TWR)和双边双向测距(double sided two way ranging, DS-TWR)。SS-TWR 是对单个往返消息时间的简单测量,测距原理如图 1 所示。




图 1 SS-TWR 测距原理

图 1 中 T_{round} 为标签(Tag)端时间差, T_{reply} 为基站(Node)端时间差。Tag 与 Node 之间信号传递时间 T_{prop} 模型如式(1)所示:

$$T_{prop} = \frac{1}{2}(T_{round} - T_{reply}) \quad (1)$$

DS-TWR 是单边双向测距的一种扩展测距方法^[14],通过计算两次往返的时间差得出信号传递时间,虽然增加了响应的的时间,但可以有效降低测距误差,测距原理如图 2 所示。根据 T_{reply1} 是否等于 T_{reply2} ,又分为对称的双边双向测距和非对称的双边双向测距:

1)非对称双边双向测距(ADS-TWR): $T_{reply1} \neq T_{reply2}$, 时间控制比较灵活;

2)对称双边双向测距(SDS-TWR): $T_{reply1} = T_{reply2}$, 可简化测距计算过程,适合低功耗下使用。

假设 Tag 和 Node 的时钟偏移分别为 e_{Tag} 和 e_{Node} , DS-




图 2 DS-TWR 测距原理

TWR 测距误差分析如下:

1) 在 SDS-TWR 方式下:

$$\hat{T}_{prop} = \frac{1}{4}(\hat{T}_{round1} - \hat{T}_{reply1} + \hat{T}_{round2} - \hat{T}_{reply2}) \quad (2)$$

$$error = \hat{T}_{prop} - T_{prop} = \frac{1}{2}(e_{Tag} + e_{Node})T_{prop} \quad (3)$$

其中, T_{prop} 和 \hat{T}_{prop} 分别表示理论值与实际值。

2) 在 ADS-TWR 方式下:

$$\hat{T}_{prop} = \frac{(T_{round1} \times T_{round2}) - (T_{reply1} \times T_{reply2})}{T_{round1} + T_{round2} + T_{reply1} + T_{reply2}} =$$

$$\begin{cases} (1 + e_{Tag})T_{prop} \\ (1 + e_{Node})T_{prop} \end{cases} \quad (4)$$

$$error = \hat{T}_{prop} - T_{prop} = \begin{cases} e_{Tag} \times T_{prop} \\ e_{Node} \times T_{prop} \end{cases} \quad (5)$$

详细误差分析参考文献[15]。

SDS-TWR 方式计算量较小,但当设备间的测距响应时延不相等时,会有较大的误差;ADS-TWR 方式计算相对复杂,但对双方设备的测距响应时延没有要求,灵活性较强。本文在基于 AOA 的定位方法中选择 ADS-TWR 方式,定位原理如图 3 所示。




图 3 基于 AOA 定位方法原理

其中, d_1 、 d_2 分别为基站 A、基站 B 与 Tag 之间的距离, L 为基站 A 与基站 B 间的距离。

AOA 定位模型如下:

$$\begin{cases} (x_{Tag} - x_{NodeA})^2 + (y_{Tag} - y_{NodeA})^2 = d_1^2 \\ (x_{Tag} - x_{NodeB})^2 + (y_{Tag} - y_{NodeB})^2 = d_2^2 \end{cases} \quad (6)$$

由式(6)可得 Tag 位置为:

$$x_{Tag} = \frac{d_1^2 - d_2^2 + L^2}{2L} \quad (7)$$

$$y_{Tag} = \sqrt{d_1^2 - x_{Tag}^2} \quad (8)$$

2 IMU 定位原理

为描述载体的空间运动状态,首先需要选择合适的坐标系。在体坐标系(B坐标系)中, X 轴和 Y 轴分别沿着纵向和横向指向前方, Z 轴沿着载体方向垂直向下,与 X 轴和 Y 轴一起形成右手坐标系;在导航坐标系(N坐标系)中,选择北东地(NEG)坐标系,即 X 轴和 Y 轴分别指的是局部水平面上的北和东方向,而 Z 轴则指的是沿地球垂直直线向下的方向。B 坐标系和 N 坐标系之间的坐标变换矩阵是载体的姿态矩阵。系统中加速度计和陀螺仪的坐标属于 B 坐标系,加速度、速度和位置的最终输出属于 N 坐标系。因为欧拉角法比四元数法更直观,所以通常采用欧拉角法进行 N 坐标系与 B 坐标系之间的姿态变换。以 N 坐标系为参考坐标系,设载体的航向角 ψ , 俯仰角 θ , 横摇角 γ 。参数 ψ 、 θ 和 γ 构成一组欧拉角,描述了 N 坐标系和 B 坐标系之间的空间角位置关系。用欧拉角旋转坐标时,由于不同的乘积表示不同的旋转顺序,矩阵的乘积不能互换。

设 C_N^1 、 C_1^2 和 C_2^B 分别表示从 N 坐标系到第 1 个旋转系统、从第 1 个旋转系统到第 2 个旋转系统以及从第 2 个旋转系统到 B 坐标系的基本旋转。从 N 坐标系到 B 坐标系的坐标变换矩阵 C_N^B 表示如式(9)~(13)所示:

$$C_N^B = C_2^B C_1^2 C_N^1 \quad (9)$$

$$C_2^B = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\gamma & \sin\gamma \\ 0 & -\sin\gamma & \cos\gamma \end{bmatrix} \quad (10)$$

$$C_1^2 = \begin{bmatrix} \cos\theta & 0 & -\sin\theta \\ 0 & 1 & 0 \\ \sin\theta & 0 & \cos\theta \end{bmatrix} \quad (11)$$

$$C_N^1 = \begin{bmatrix} \cos\psi & \sin\psi & 0 \\ -\sin\psi & \cos\psi & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (12)$$

两个笛卡尔坐标系之间的变换矩阵是正交矩阵。因此:

$$C_N^1 = (C_1^2)^{-1} = (C_1^2)^T \quad (13)$$

在系统中,姿态更新是指基于 IMU 输出的坐标变换矩阵 C_N^B 的实时计算。设 ω_{NB} 表示 B 坐标系相对于 N 坐标系的角速度, ω_{NB}^B 表示 ω_{NB} 在 B 坐标系的分量。 ω_{NB}^B 如式(14)所示。

$$\begin{bmatrix} \omega_{NBx}^B \\ \omega_{NBy}^B \\ \omega_{NBz}^B \end{bmatrix} = C_2^B C_1^2 \begin{bmatrix} 0 \\ 0 \\ -\psi \end{bmatrix} + C_2^B \begin{bmatrix} 0 \\ \theta \\ 0 \end{bmatrix} + \begin{bmatrix} \gamma \\ 0 \\ 0 \end{bmatrix} \quad (14)$$

由式(14)得到欧拉角:

$$\begin{bmatrix} \gamma \\ \theta \\ \psi \end{bmatrix} = \begin{bmatrix} 1 & 0 & -\sin\theta \\ 0 & \cos\gamma & \sin\gamma \cos\theta \\ 0 & -\sin\gamma & \cos\gamma \cos\theta \end{bmatrix}^{-1} \begin{bmatrix} \omega_{NBx}^B \\ \omega_{NBy}^B \\ \omega_{NBz}^B \end{bmatrix} \quad (15)$$

B 坐标系中的加速度 a^B 由三轴加速度计测量:

$$\mathbf{a}^B = [a_x^B \ a_y^B \ a_z^B]^T \quad (16)$$

因此, N 坐标系的加速度 a^N 通过如下坐标变换获得:

$$\mathbf{a}^N = \begin{bmatrix} a_x^N \\ a_y^N \\ a_z^N \end{bmatrix} = \mathbf{C}_B^N \mathbf{a}^B - \begin{bmatrix} 0 \\ 0 \\ \mathbf{g} \end{bmatrix} \quad (17)$$

其中, \mathbf{g} 为重力矢量。

当采样间隔足够短时, 可视为载体受到恒定的力和均匀的线性运动加速度。设 Δt 为采样间隔, Δv^N 表示 N 坐标系中相邻采样时刻的速度变化量:

$$\begin{bmatrix} \Delta v_x^N \\ \Delta v_y^N \\ \Delta v_z^N \end{bmatrix} = \begin{bmatrix} a_x^N \\ a_y^N \\ a_z^N \end{bmatrix} \Delta t \quad (18)$$

设 $v^N(t)$ 表示 t 时刻 N 坐标系中的速度, N 坐标系中 $t+1$ 时刻的速度 $v^N(t+1)$ 可以通过 $v^N(t)$ 与 Δv^N 得到, 如式(19)所示:

$$\begin{bmatrix} v_x^N(t+1) \\ v_y^N(t+1) \\ v_z^N(t+1) \end{bmatrix} = \begin{bmatrix} v_x^N(t) \\ v_y^N(t) \\ v_z^N(t) \end{bmatrix} + \begin{bmatrix} \Delta v_x^N \\ \Delta v_y^N \\ \Delta v_z^N \end{bmatrix} \quad (19)$$

若设 $X^N(t)$ 表示 t 时刻 N 坐标系中的位置, 在 $t+1$ 时刻 N 坐标系中的位置 $X^N(t+1)$ 描述如式(20)所示:

$$\begin{bmatrix} X_x^N(t+1) \\ X_y^N(t+1) \\ X_z^N(t+1) \end{bmatrix} = \begin{bmatrix} X_x^N(t) \\ X_y^N(t) \\ X_z^N(t) \end{bmatrix} + \begin{bmatrix} v_x^N(t) \\ v_y^N(t) \\ v_z^N(t) \end{bmatrix} \Delta t + \frac{1}{2} \begin{bmatrix} a_x^N \\ a_y^N \\ a_z^N \end{bmatrix} \Delta t^2 \quad (20)$$

IMU 计算位移需要对加速度进行二次积分, 随着时间推移或路程增长定位误差会逐渐增大, 最终使解算得到的轨迹偏离实际路线。


3 UWB/IMU 融合定位算法设计

传感器融合需要一个概率贝叶斯推理框架, 该框架中广泛使用的卡尔曼滤波(Kalman filter, KF)算法需要依赖两个假设: 一方面目标的运动和观测模型都是线性的; 另一方面它们的误差和初始估计概率是高斯分布^[16]。在静态定位时满足这两个假设, 可直接使用 EKF 或 UKF 算法; 而在动态定位中, 仅有距离作为观测量, 不仅传感器模型是非线性的, 噪声也可能存在多种分布模式, 因此不能被建模为高斯分布^[17]。针对此问题, 本文提出了一种基于改进 PF 的 UWB/IMU 融合的动态定位算法, 其中 PF 算法可以通过全局定位或维持多模态分布来处理非线性和复杂的模型。


3.1 EKF 计算 UWB 位置

不同的使用环境会导致 UWB 测距结果与真实值存在系统偏差, 因此需要在使用前对其进行标定。标定方式为

0.5~3 m 每间隔 10 cm 采集 300 个数据计算平均值后与真实距离比较, 统计所有差值进行线性拟合, 拟合结果如图 4 所示。



(a) d_1 测距校正系统偏差的线性拟合



(b) d_2 测距校正系统偏差的线性拟合

图 4 系统偏差校正

拟合方程为式(21):

$$\begin{cases} \hat{d}_1 = 1.000 \ 5d_1 + 18.835 \ 1 \\ \hat{d}_2 = 1.002 \ 4d_2 + 14.905 \ 2 \end{cases} \quad (21)$$

UWB 在动态定位时非线性较强, 标准的 KF 算法对非线性处理能力有限, 而 EKF 是利用泰勒级数展开将非线性系统进行线性化, 并采用 KF 框架对信号进行滤波, 与 UKF 相比计算速度较快, 是一种高效的递归滤波器。EKF 公式如式(22)~(27)所示:

预测方程:

$$\hat{x}_{\bar{k}} = \mathbf{A} \hat{x}_{k-1} \quad (22)$$

量测方程:

$$z_k = \mathbf{H}_k x_k \quad (23)$$

向前推算误差协方差:

$$P_{\bar{k}} = \mathbf{A} P_{k-1} \mathbf{A}^T + \mathbf{Q} \quad (24)$$

计算卡尔曼增益:

$$K_k = P_{\bar{k}} \mathbf{H}_k^T (\mathbf{H}_k P_{\bar{k}} \mathbf{H}_k^T + \mathbf{R})^{-1} \quad (25)$$

由量测变量 z_k 更新估计:

$$\hat{x}_{\bar{k}} = \hat{x}_{\bar{k}} + K_k (z_k - \mathbf{H}_k \hat{x}_{\bar{k}}) \quad (26)$$

更新误差协方差:

$$P_{\bar{k}} = (\mathbf{I} - K_k \mathbf{H}_k) P_{\bar{k}} \quad (27)$$

式中: \mathbf{A} 为状态转移矩阵, \mathbf{Q} 为过程噪声协方差矩阵, \mathbf{R} 为测量噪声协方差矩阵, \mathbf{H}_k 为 k 时刻状态向量到量测向量的转移矩阵, 如式(28)所示:

$$\mathbf{H}_k = \begin{bmatrix} \frac{x_k - x_{nodeA}}{d_{1k}} & \frac{y_k - y_{nodeA}}{d_{1k}} \\ \frac{x_k - x_{nodeB}}{d_{2k}} & \frac{y_k - y_{nodeB}}{d_{2k}} \end{bmatrix} \quad (28)$$

其中, (x_k, y_k) 为 k 时刻标签的坐标, (x_{node}, y_{node}) 为基站坐标, d_{1k}, d_{2k} 为 k 时刻基站 A、基站 B 与 Tag 之间的距离。

3.2 UWB 与 IMU 数据同步

采样频率过低会导致采样周期变长, 而通过积分加速度数据进行标签移动速度计算的 IMU 会迅速累计速度误差, 因此 IMU 通常选择较高的采样频率; 而 UWB 在实际应用中为了节省功耗, 会设置较低的采样频率, 从而导致与 IMU 采样频率不相同。为实现数据同步, 本算法设置了滑动窗口来计算 IMU 的加速度与速度的平均值, 因 IMU 采样频率较高, 滑动窗口内加速度与速度的平均值可近似于 UWB 体系下标签当前时刻的运动状态。

3.3 NLOS 数据识别与补偿

为了降低 NLOS 对定位精度的影响, 本算法设置了 NLOS 数据识别与补偿机制。在导航坐标系下, 通过式(29)计算当前采样时刻的 UWB 定位坐标与上一时刻定位坐标的变化率得出标签的运动速度, 然后与 IMU 测量的标签速度进行比较, 若超过阈值则判别为 NLOS 数据, 如式(30)所示。

$$\begin{cases} v_x^{UWB} = \frac{x_k - x_{k-1}}{\Delta t} \\ v_y^{UWB} = \frac{y_k - y_{k-1}}{\Delta t} \end{cases} \quad (29)$$

$$\begin{cases} |v_x^{UWB} - v_x^{IMU}| > \beta_{Th} v_x^{IMU} \\ or \\ |v_y^{UWB} - v_y^{IMU}| > \beta_{Th} v_y^{IMU}, NLOS \\ |v_x^{UWB} - v_x^{IMU}| < \beta_{Th} v_x^{IMU} \\ and \\ |v_y^{UWB} - v_y^{IMU}| < \beta_{Th} v_y^{IMU}, LOS \end{cases} \quad (30)$$

其中, β_{Th} 为在视距环境下多次实验统计的阈值。若识别到 NLOS 数据, 将上一时刻滤波算法的预测结果作为当前时刻的测量值。

3.4 自适应调整粒子数的改进粒子滤波算法

在二维平面中, 定义 $\mathbf{X}(k)$ 为 k 时刻的状态向量, 包含位置、速度和加速度, 表示如下:

$$\mathbf{X}(k) = [x(k) \quad y(k) \quad v_x(k) \quad v_y(k) \quad a_x(k) \quad a_y(k)]^T \quad (31)$$

转换成矩阵形式的状态方程表示如下:

$$\mathbf{X}(k+1) = \mathbf{F}\mathbf{X}(k) + \mathbf{W}(k) \quad (32)$$

其中, \mathbf{F} 表示状态转移矩阵, $\mathbf{W}(k) = [\omega_x(k) \quad \omega_y(k)]^T$

表示 k 时刻均值为 0 的过程噪声向量。

$$\mathbf{F} = \begin{bmatrix} 1 & 0 & dt & 0 & \frac{dt^2}{2} & 0 \\ 0 & 1 & 0 & dt & 0 & \frac{dt^2}{2} \\ 0 & 0 & 1 & 0 & dt & 0 \\ 0 & 0 & 0 & 1 & 0 & dt \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (33)$$

其中, dt 为 UWB 采样间隔。

自适应调整粒子数的改进粒子滤波算法流程: 假设 n 为独立分布的样本数, k 为采样时刻, \mathbf{X}_k 表示 k 时刻目标的状态, $\mathbf{X}_{0:k} = \{\mathbf{X}_0, \mathbf{X}_1, \dots, \mathbf{X}_k\}$ 与 $\mathbf{Z}_{0:k} = \{\mathbf{Z}_0, \mathbf{Z}_1, \dots, \mathbf{Z}_k\}$ 分别表示 $0 \sim k$ 时刻的所有状态与观测值, 前者与上一时刻的 \mathbf{X}_{k-1} 有关, 后者相互独立, 只与 \mathbf{X}_k 有关。

初始化: 从先验分布 $p(\mathbf{X}_0)$ 中抽取初始化状态 $\mathbf{X}_0^{(i)}$ 。

重要性采样: 采样 $\hat{\mathbf{X}}_k^{(i)} \sim q(\mathbf{X}_k | \mathbf{X}_{0:k-1}^{(i)}, \mathbf{Z}_{1:k})$, 其中 $\hat{\mathbf{X}}_k^{(i)}$ 为从参考分布中随机抽取的 n 个样本点, 并设置 $\mathbf{X}_{0:k-1}^{(i)} \triangleq (\mathbf{X}_{0:k}^{(i)}, \hat{\mathbf{X}}_k^{(i)})$ 。 k 时刻的每个粒子重新计算权重为:

$$\omega_k^{(i)} = \omega_{k-1}^{(i)} \frac{p(\mathbf{Z}_k | \mathbf{X}_k^{(i)}) p(\mathbf{X}_k^{(i)} | \mathbf{X}_{k-1}^{(i)})}{q(\mathbf{X}_k | \mathbf{X}_{0:k-1}^{(i)}, \mathbf{Z}_{1:k})} \quad (34)$$

归一化权重:

$$\tilde{\omega}_k^{(i)}(\mathbf{X}_{0:k}^{(i)}) = \frac{\omega_k(\mathbf{X}_{0:k}^{(i)})}{\sum_{i=1}^N \omega_k(\mathbf{X}_{0:k}^{(i)})} \quad (35)$$

自适应调整粒子数: 有效粒子数是粒子滤波算法退化程度的衡量指标, 有效粒子数个数越少, 退化越严重, 且权重很小的粒子浪费了大量计算资源。定义有效粒子数为:

$$N_{eff} = \text{ceil}(1 / \sum_{i=1}^N (\omega \tilde{\omega}_k^{(i)})^2) \quad (36)$$

式中: $\text{ceil}(\cdot)$ 表示向上取整的运算。设定阈值 N_{th} , 若 $N_{eff} > N_{th}$, 则将粒子按权重从大到小排序, 选取前 N_{eff} 个大权重对应的粒子组成新的样本集合, 然后输出状态估计值; 否则则进行重采样。对于阈值 N_{th} 的选取, 一般设为 $N_{th} = N/3$, 通过自适应调整粒子数, 既保留了权重大的有效粒子防止退化, 又减少了粒子个数提高计算效率。

重采样: 根据近似分布 $p(\mathbf{X}_{0:k}^{(i)} | \mathbf{Z}_{1:k})$ 产生 N 个随机样本集合 $\mathbf{X}_{0:k}^{(i)}$, 从初始粒子集合 $\{\mathbf{X}_k^{(i)}, i = 1, 2, \dots, n\}$ 得到一组新的粒子集合 $\{\tilde{\mathbf{X}}_k^{(i)}, i = 1, 2, \dots, n\}$ 。根据归一化权重 $\omega \tilde{\omega}_k^{(i)}(\mathbf{X}_{0:k}^{(i)})$ 的大小对粒子集合 $\hat{\mathbf{X}}_{0:k}^{(i)}$ 进行复制和淘汰, 此时重采样后一组权值较大的粒子代替了权值较小的粒子, 重新设置权重 $\omega_k^{(i)} = \omega \tilde{\omega}_k^{(i)} = \frac{1}{N}$ 。

输出: 根据更新后的 $\{(\mathbf{X}_k^{(i)}, \omega_k^{(i)})\}_{i=1}^n$, PF 后验概率分布被更新为:

$$p(\mathbf{X}_k | \mathbf{Z}_{1:k}) \approx \sum_{i=1}^N \omega_k(\mathbf{X}_{0:k}^{(i)}) \quad (37)$$

其中, $\delta(\mathbf{X}_k - \mathbf{X}_k^{(i)})$ 为狄拉克函数, 即 $\delta(\mathbf{X}_k - \mathbf{X}_k^{(i)}) =$

$0, \mathbf{X}_k \neq \mathbf{X}_k^{(i)}$ 。k 时刻的状态估计值为:

$$\hat{\mathbf{X}}_k = \sum_{i=1}^n \omega_k^{(i)} \tilde{\mathbf{X}}_k^{(i)} \quad (38)$$

4 实验与分析

本文通过实地实验验证所提算法的有效性。

4.1 实验设备及环境

实验设备是 Decawave 公司生产的 DWM1000 模块, DWM1000 模块是基于 Decawave 公司 DW1000 芯片设计的超宽带收发模组,该模块集成天线及所有的射频电路、电源管理和时钟电路,可用在基于 TOA、TDOA 或 AOA 定位方法的系统中,其测距误差小于 10 cm;并且该模块支持高达 6.8 Mbps 的数据传输率。本实验使用 3 个 DWM1000 模块,其中 1 个作为移动标签,标签中含一个 MPU6050 六轴 IMU 模块,2 个作为基于 AOA 定位方法的基站。

4.2 动态定位实验与分析

动态定位选择环境较为复杂的山东高速 T2 大楼负一层地下车库(如图 5),测试范围包含一个 $0.92 \text{ m} \times 0.75 \text{ m}$ 的承重立柱 1 和一个 $0.75 \text{ m} \times 0.75 \text{ m}$ 的承重立柱 2 制造非视距遮挡。手持标签在轨迹为 $12.58 \text{ m} \times 5.15 \text{ m}$ 的矩形边缘移动,用 PC 采集串口数据进行实时定位。

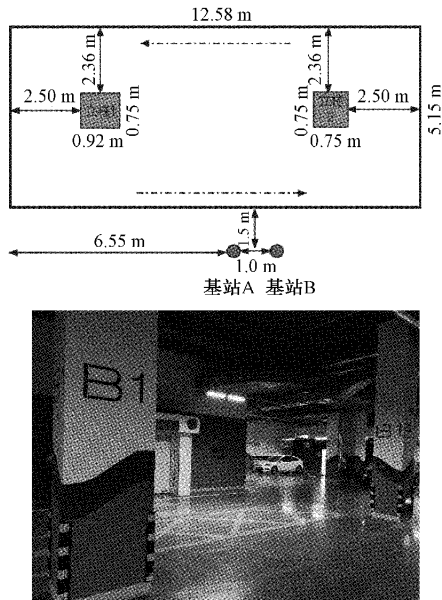


图 5 动态定位实验环境

实验中 IMU 采样频率为 100 Hz, UWB 采样频率为 20 Hz,所以设置大小为 5 的滑动窗口;本实验环境下 NLOS 数据识别阈值 β_{th} 设为 0.3;EKF 参数设置如下:

$$\mathbf{A} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, \mathbf{Q} = \begin{bmatrix} 0.8 & 0 \\ 0 & 0.8 \end{bmatrix}, \mathbf{R} = \begin{bmatrix} 0.65 & 0 \\ 0 & 0.65 \end{bmatrix}.$$

图 6 中黑色实线为参考轨迹,可以看出由 UWB 直接定位的轨迹与真实轨迹存在较大偏差,当标签运动到平面

图中左上角和右上角位置时,因为立柱的遮挡造成非视距,此时出现较大的定位误差,由表 1 所示最大偏差值为 3.21 m;且右上角采样点个数明显较其他位置稀疏,此时出现信号丢失的现象。带有 NLOS 补偿的 UWB 定位轨迹相较直接定位的轨迹减少了 NLOS 导致的明显异常点,所以轨迹更平滑,但仍然与真实轨迹有较大误差,最大偏差值为 2.79 m,这是由于实验环境中噪声对 UWB 定位的干扰。对比仅进行 NLOS 补偿的 UWB 定位轨迹,基于 PF 算法的带有 NLOS 补偿的 UWB 定位轨迹效果更好,最大偏差值减小到 1.34 m,这表明利用 PF 算法对噪声起到了抑制作用。上述 3 种仅单一使用 UWB 传感器的定位算法的优化效果有限,平均误差均超过了 0.5 m,而本文融合 UWB 与 IMU 数据进行定位的算法,因加入了参考信息,融合算法得到的轨迹与真实轨迹吻合度更高,最大偏差值为 0.38 m,平均误差仅为 0.11 m。上述不同算法的累计误差概率分布如图 7 所示。




图 6 不同算法定位轨迹对比




图 7 不同算法累计误差概率分布

图 8(a)中对比了基于不同滤波算法的 UWB/IMU 融合定位算法的轨迹,结合图 6 可知 UWB/IMU 融合定位算法的精度比单一使用 UWB 的定位算法有明显提升,当 UWB 处于非视距和丢失数据的情况下,IMU 可以提供标签的加速度与速度信息,有效地抑制 UWB 的观测误差,确保定位的准确性;图 8(b)、(c)给出了基于不同融合算法在 X 轴和 Y 轴方向上的误差,可得本文所提算法的定位精度


表 1 不同定位算法误差比较

误差	UWB 轨迹	带 NLOS	带 NLOS	UWB/IMU 融合算法 轨迹
		补偿的 UWB 轨迹	补偿的 PF+ UWB 轨迹	
最大误差/m	3.21	2.79	1.34	0.38
平均误差/m	0.75	0.70	0.59	0.11


EKF 和 UKF 的融合算法相比,定位精度分别提高了 65.6%和 56.0%。

表 2 基于不同融合算法误差比较


误差	基于 EKF	基于 UKF	基于 PF
最大误差/m	0.52	0.47	0.38
平均误差/m	0.32	0.25	0.11



(a) 基于不同融合算法的定位轨迹图



(b) X轴方向定位误差



(c) Y轴方向定位误差

图 8 基于不同融合算法的定位轨迹及误差对比

高于基于 EKF 和 UKF 的融合算法,由表 2 可知,平均误差分别下降了 0.21 和 0.14 m。这是因为 PF 算法处理非线性模型和复杂模型的能力相较于 EKF 和 UKF 算法更强,而且对于实验环境中分布的多种噪声,PF 算法的抑制效果更好。实验证明该算法具有良好的抗干扰性能,与基于

为了测试本文所提算法的实时性,表 3 比较了基于不同融合算法的运行时间。基于 EKF 和 UKF 的融合算法的运行时间明显短于基于 PF 的融合算法,而基于自适应调整粒子数的 PF 算法的运行时间比基于标准 PF 算法的运行时间缩短了 42.3%,提高了算法的计算效率,增强了算法的实时性。实验表明,虽然本文所提算法增大了时间复杂度,但整体定位效果要优于 EKF 和 UKF 两种算法。在复杂度低、噪声干扰小的环境中可以优先考虑基于 EKF 或 UKF 的融合定位算法。

表 3 基于不同融合算法运行时间比较

	基于 EKF	基于 UKF	基于 PF	基于自适应调整 粒子数的 PF
运行时间/s	0.01	0.04	1.82	1.05

5 结 论

针对超宽带定位易受多种噪声和非视距遮挡的影响造成定位不准确的问题,本文提出带有 NLOS 补偿的基于自适应调整粒子数的改进 PF 的 UWB/IMU 融合定位算法。实验结果表明,仅单一使用 UWB 传感器的定位算法优化效果有限,需要增加新的信息以提高定位精度;基于自适应调整粒子数的改进 PF 的融合算法在改善定位效果的同时也缩短了运行时间。在将来的工作中,计划继续对 PF 算法进行改进,采用增强粒子滤波算法,结合观测方程和状态方程的两组粒子,通过增强状态空间以便计算权重,进一步提高算法的性能。

参考文献

- [1] 钟亮, 李晓东. 基于 UWB 的自适应小波与卡尔曼滤波定位算法[J]. 电子测量技术, 2020, 43(22): 165-169.
- [2] 赵红梅, 赵杰磊. 超宽带室内定位算法综述[J]. 电信科学, 2018, 34(9): 130-142.
- [3] PETERSEIL P, MARZINGER D, ETZLINGER B, et al. Labeling for UWB ranging in weak NLOS conditions [C]. 2022 International Conference on Localization and GNSS(ICL-GNSS), 2022: 1-6.
- [4] 徐爱功, 刘韬, 隋心, 等. UWB/INS 紧组合的室内定位定姿方法[J]. 导航定位学报, 2017, 5(2): 14-19.

- [5] 浦佳祺, 陈德旺. 基于最小二乘法和 BP 神经网络的 TOA 定位算法[J]. 计算机技术与发展, 2018, 28(5): 5-8.
- [6] 李晨辉, 甄杰, 祝会忠, 等. 复杂环境下的超宽带高精度定位算法[J]. 测绘科学, 2020, 45(1): 4-10.
- [7] 傅军, 许达, 付阳. 一种自适应 UKF 在 UWB 室内定位中的应用[J]. 测绘通报, 2019(S1): 12-17, 25.
- [8] 杨晓倩. 基于 TOA-AOA 数据融合的定位算法研究[J]. 电子测量技术, 2020, 43(16): 104-108.
- [9] 黄波, 李伟. LOS_NLOS 下基于 PF 和最大似然的 TDOA 定位算法[J]. 计算机仿真, 2022, 39(3): 481-484, 489.
- [10] FAN Q, SUN B, SUN Y, et al. Performance enhancement of MEMS-based INS/UWB integration for indoor navigation applications[J]. IEEE Sensors Journal, 2017, 17(10): 3116-3130.
- [11] 李景文, 韦晶闪, 周俊芬, 等. 融合 UWB+PDR 的室内定位方法改进[J]. 测绘通报, 2022(3): 36-40.
- [12] 刘宇, 谢宇, 彭慧, 等. 基于 UWB/PDR 的航向发散自适应修正算法研究[J]. 电子测量技术, 2022, 45(3): 98-103.
- [13] CHEN P, KUANG Y, CHEN X. A UWB/improved PDR integration algorithm applied to dynamic indoor positioning for pedestrians[J]. Sensors, 2017, 17(9): 2065.
- [14] 王红尧, 郑鸿林, 田劼, 等. 面向矿井动目标的 PSO-SVR 模型与 UWB Chan 优化距离指纹融合定位方法[J]. 电子测量与仪器学报, 2022, 36(7): 106-114.
- [15] NEIRYNCK D, LUK E, MCLAUGHLIN M. An alternative double-sided two-way ranging method[C]. 2016 13th Workshop on Positioning, Navigation and Communications(WPNC), 2021: 1-4.
- [16] KALMAN R. A new approach to linear filtering and prediction problems[J]. Journal of Basic Engineering, 1960, 82(1): 35-45.
- [17] FENG D, WANG C, HE C, et al. Kalman-filter-based integration of IMU and UWB for high accuracy indoor positioning and navigation[J]. IEEE Internet of Things Journal, 2020, 7(4): 3133-3146.

作者简介

王鹏, 硕士研究生, 主要研究方向为无模型自适应控制及 UWB/INS 定位技术。

E-mail: wangpeng106@foxmail.com

侯忠生(通信作者), 博士, 教授, 主要研究方向为无模型自适应控制及数据驱动控制。

E-mail: zhshhou@bjtu.edu.cn