

DOI: 10.19650/j.cnki.cjsi.J2006179

基于秩卡尔曼滤波的室内行人航位推算算法*

余志鹏¹, 熊 剑², 袁卫声², 郭 杭³, 钟启林²

(1. 南昌大学机电工程学院 南昌 330031; 2. 南昌大学信息工程学院 南昌 330031;
3. 南昌大学空间科学与技术研究院 南昌 330031)

摘 要:针对采用卡尔曼滤波进行室内行人导航数据融合时精度较低的问题,在行人航位推算技术的基础上,提出了一种基于秩卡尔曼滤波(RKF)的行人航位推算导航(PDR)方法。RKF技术由于采用特殊的秩采样机理,可以很好地处理非高斯和非线性系统问题。通过将RKF技术和零速修正(ZUPT)技术相结合,对室内行人运动中测得的多传感器数据进行融合,实现更加精确的室内行人导航定位。首先,利用零速检测算法从MEMS传感器测量数据中分析得到零速信息;然后,利用得到的零速信息作为ZUPT和RKF算法的信息源参与融合解算得到最终的行人位置;最后实验结果表明,基于RKF的PDR算法相对于采用扩展卡尔曼的行人航位推算算法有一定的提高,使得室内行人导航定位误差减小了18.91%。

关键词:室内行人导航;行人航位推算(PDR);秩卡尔曼滤波(RKF);零速修正(ZUPT)

中图分类号: TN96 TH89 **文献标识码:** A **国家标准学科分类代码:** 510.99

Indoor pedestrian dead reckoning algorithm based on rank Kalman filter

Yu Zhipeng¹, Xiong Jian², Zhong Weisheng², Guo Hang³, Zhong Qilin²

(1. School of Mechanical and Electrical Engineering, Nanchang University, Nanchang 330031, China;
2. School of Information Engineering, Nanchang University, Nanchang 330031, China;
3. Institute of Space Science and Technology, Nanchang University, Nanchang 330031, China)

Abstract: Aiming at the low accuracy problem in the data fusion of indoor pedestrian positioning and navigation using traditional Kalman filter algorithm, this paper proposes a new pedestrian dead reckoning navigation algorithm using rank Kalman filter (RKF) based on pedestrian dead reckoning technology. RKF technology can nicely handle non-Gaussian and nonlinear system due to its special rank sampling mechanism. Through combining RKF technology and zero velocity update (ZUPT) technology, the algorithm can fuse the multi-sensor data measured in indoor pedestrian motion, and achieve more accurate indoor pedestrian positioning and navigation. Firstly, the zero velocity detection algorithm is used to analyze and obtain the zero velocity information from the data measured with MEMS sensors. Then, the obtained zero velocity information is used as ZUPT, which is fused with the information from the RKF algorithm and the pedestrian position is obtained. Finally, the experiment result shows that indoor pedestrian dead reckoning (PDR) algorithm based on RKF achieves certain improvement compared with the pedestrian dead reckoning algorithm using extended Kalman filter, and reduces the indoor pedestrian navigation and positioning error by about 18.91%.

Keywords: indoor pedestrian navigation; pedestrian reckoning (PDR); rank Kalman filter (RKF); zero velocity update (ZUPT)

0 引 言

室内行人导航由于存在接收卫星导航信息难^[1],室内环境状况复杂^[2]等问题,其具体实现变得极其困难。

行人航位推算导航 (pedestrian dead reckoning, PDR)^[3]仅利用惯性测量器件 (inertial measurement units, IMU) 即可实现室内行人导航^[4]。利用 IMU 实现 PDR 的核心为融合算法,确定一种合适的融合算法直接影响最后的导航精度。

行人导航的融合算法,最典型的是卡尔曼滤波算法,然而卡尔曼滤波算法只能解决线性系统问题^[5],对于非线性系统,扩展卡尔曼滤波算法(extended kalman filter, EKF)可对非线性系统线性化处理、无迹卡尔曼滤波算法(unscented kalman filter, UKF)通过无迹变换可对非线性系统进行采样,这类常规高斯采样型滤波算法^[6-7]作为融合算法虽然均能取得一定的效果,但是其各自均存在自身的问题,EKF 滤波算法由于仅对非线性系统进行线性化处理,故而存在截断误差问题,UKF 滤波算法仅能对高斯模型进行采样。针对上述融合算法存在的问题,杨菊花等^[8]通过在 EKF 解算过程中引入滑模观测器,在卫星/惯性的融合过程中能够有效抑制误差发散,在一定程度上解决了 EKF 截断误差引起的发散问题。而王鼎杰等^[9]直接在 EKF 的基础上构建容错自适应卡尔曼滤波算法,对新息协方差矩阵进行自适应的调节,实现了卫星和惯导组合定位精度的提高。类似的,Liu 等^[10]提出了一种中心差分卡尔曼滤波算法,在同步定位与地图构建应用中很好地解决了多源数据融合精度过低问题。Fan 等^[11]在行人导航数据融合中,将自适应卡尔曼滤波算法和互补滤波器结合,有效提高了行人导航的定位精度与鲁棒性。针对非线性系统自身,Zhao 等^[12]介绍的容积卡尔曼滤波算法能够直接对非线性系统模型实现更高阶次的近似,进而能够减小组合导航中由融合算法引起的状态误差。在上述文献的融合算法中,本质上使用的方法依然是先对基于高斯分布假设的样本进行采样,而后对这些样本采样点线性或非线性的传播,最后经过融合得到更加精确的状态估计值。

对于一般非高斯分布假设的模型,秩卡尔曼滤波(rank Kalman filter, RKF)算法根据秩统计量相关原理来计算采样点以及与其采样点对应的权值^[13-14],由于这种特性,其对系统噪声不需要做高斯假设,因而可以在非线性和非高斯噪声的系统上得到很好的应用,相比其他滤波算法,RKF 算法应用的范围也更加的广阔^[15]。鉴于此,PDR 算法的导航框架体系下,使用微机电(micro electrical mechanical system, MEMS)惯性测量器件作为感知器件,利用 RKF 方法与零速修正技术(zero velocity update, ZUPT)^[16]相结合,提出一种基于 RKF 的 PDR 算法,使得室内行人导航精度得到进一步的提高。

1 PDR 算法

PDR 技术^[17-18]本质是通过航位推算(dead reckoning, DR)技术得到距离和方向信息,行人在从起点到终点的不断迭代中,实现整个路程的导航。其原理如图 1 所示。




图 1 DR 原理

Fig.1 DR principle

目前 PDR 方法整体实现主要包括 3 个核心步骤^[19]: 1) 步态检测(step detection)算法; 2) 步长估计(step length estimation)算法; 3) 航向估计(heading estimation)算法。传感器作为感知器件采集数据,利用采集到的数据通过步态检测得到步态信息,通过步长估计得到步长信息,通过航向估计得到行人行进的方向信息,最后解算得到所需的位置和航向信息,其中的位置解算如式(1)所示。

$$\begin{cases} E_k = E_{k-1} + d_k \sin\varphi_k \\ N_k = N_{k-1} + d_k \cos\varphi_k \end{cases} \quad (1)$$

式中: E_k 为东向的位置坐标; N_k 为北向的位置坐标; d_k 为从 t_{k-1} 时刻到 t_k 时刻所推算得到的距离信息; φ_k 为从 t_{k-1} 时刻到 t_k 时刻所推算得到的航向角信息。

2 RKF 算法

2.1 系统模型

$$\begin{cases} \mathbf{X}_k = \mathbf{f}(\mathbf{X}_{k-1}) + \mathbf{W}_k \\ \mathbf{Z}_k = \mathbf{h}(\mathbf{X}_k) + \mathbf{V}_k \end{cases} \quad (2)$$

式中: \mathbf{X}_k 为 k 时刻的系统状态矢量; \mathbf{Z}_k 为 k 时刻的系统量测矢量; $\mathbf{f}(\cdot)$ 为系统状态向量的非线性矢量函数; $\mathbf{h}(\cdot)$ 为量测的非线性矢量函数; \mathbf{W}_k 和 \mathbf{V}_k 分别为 k 时刻的系统噪声矢量和 k 时刻的量测噪声矢量,它们对应的方差矩阵分别为 \mathbf{Q}_k 和 \mathbf{R}_k , 同时满足:

$$\begin{cases} \text{Cov}[\mathbf{W}_k, \mathbf{W}_l] = \mathbf{Q}_k \delta_{kl} \\ \text{Cov}[\mathbf{V}_k, \mathbf{V}_l] = \mathbf{R}_k \delta_{kl} \\ \text{Cov}[\mathbf{W}_k, \mathbf{V}_l] = \mathbf{0} \end{cases} \quad (3)$$

式中: $\text{Cov}[\cdot]$ 表示的是协方差; δ_{kl} 是 δ 函数,其值表示为:当 $k = l$ 时, $\delta_{kl} = 1$, 当 $k \neq l$ 时, $\delta_{kl} = 0$ 。

2.2 秩采样原理

RKF 算法的算法整体架构与其他高斯采样模型算法相类似,但 RKF 算法无要求系统噪声模型服从高斯分布假设,利用秩采样机理,对一般非高斯分布进行采样后系统状态概率分布也更合理^[14]。构造出的非高斯分布采样点集为 $\{\mathbf{X}_{k-1}^i\}$:

$$\begin{aligned} \mathbf{X}_{k-1}^i &= \hat{\mathbf{X}}_{k-1} + r_j \lambda_{p_j} (\sqrt{\mathbf{P}_{k-1}})_l \quad l=1,2,\dots,n \\ \left\{ \begin{aligned} i &= (j-1)n + l, i=1,2,\dots,q \\ i &= (j-2)n + l, i=q+2, q+3, \dots, 2q+1 \end{aligned} \right. \end{aligned} \quad (4)$$

式中: \mathbf{X}_{k-1}^i 为 \mathbf{X}_{k-1} 的第 i 个采样点, 其中采样点的总数为 $2qn$; q 为采样的总层数; n 为 \mathbf{X}_{k-1} 的总维数; $(\sqrt{\mathbf{P}_{k-1}})_l$ 表示的意思是 \mathbf{P}_{k-1} 进行平方根运算后, 取第 l 列元素; λ_{p_j} 表示的是估计误差 $\mathbf{X}_{k-1} - \hat{\mathbf{X}}_{k-1}$ 所服从分布的一维标准分布概率 p_j 的分位点, 其中 p_j 代表着与第 j 层采样点对应的概率, 一般情况下应用的取值为 $p_j = (j-0.3)/(2q+1.4)$ 或 $p_j = j/(2q+2)$; r_j 表示的是第 j 层采样点修正系数, 其取值满足式(5)。

$$\sum_{j=1, j \neq q+1}^{2q+1} r_j \lambda_{p_j} = 0 \quad (5)$$

2.3 RKF 算法

1) 预测

(1) 状态预测:

$$\hat{\mathbf{X}}_{klk-1} = \frac{1}{2qn} \sum_{i=1}^{2qn} \mathbf{X}_{klk-1}^i \quad (6)$$

其中:

$$\mathbf{X}_{klk-1}^i = f(\mathbf{X}_{k-1}^i) + \boldsymbol{\mu}_{k-1}^W, \quad i=1,2,\dots,2qn \quad (7)$$

$$\boldsymbol{\mu}_{k-1}^W = \mathbf{E}[\mathbf{W}_{k-1}] \quad (8)$$

式中: $\mathbf{E}[\cdot]$ 表示期望。

(2) 协方差预测:

$$\mathbf{P}_{klk-1} = \frac{r_i^*}{\omega} \sum_{i=1}^{2qn} [r_i^* (\mathbf{X}_{klk-1}^i - \hat{\mathbf{X}}_{klk-1}) (\mathbf{X}_{klk-1}^i - \hat{\mathbf{X}}_{klk-1})^T] + \mathbf{Q}_{k-1} \quad (9)$$

2) 更新

(1) 重新秩采样, 得到采样点集 \mathbf{X}_{klk-1}^i 为:

$$\begin{aligned} \mathbf{X}_{klk-1}^i &= \hat{\mathbf{X}}_{klk-1} + r_j \lambda_{p_j} (\sqrt{\mathbf{P}_{klk-1}})_l, \quad l=1,2,\dots,n \\ \left\{ \begin{aligned} i &= (j-1)n + l, i=1,2,\dots,q \\ i &= (j-2)n + l, i=q+2, q+3, \dots, 2q+1 \end{aligned} \right. \end{aligned} \quad (10)$$

式中: \mathbf{X}_{klk-1}^i 为 \mathbf{X}_{klk-1} 的第 i 个采样点, 其中采样点的总数为 $2qn$; q 为采样的总层数; n 为 \mathbf{X}_{klk-1} 的总维数; $(\sqrt{\mathbf{P}_{klk-1}})_l$ 表示的意思是 \mathbf{P}_{klk-1} 进行平方根运算后, 取第 l 列元素; λ_{p_j}, p_j, r_j 的定义与式(4)完全相同。

(2) 状态估计更新

$$\hat{\mathbf{X}}_k = \hat{\mathbf{X}}_{klk-1} + \mathbf{K}_k (\mathbf{Z}_k - \hat{\mathbf{Z}}_{klk-1}) \quad (11)$$

其中:

$$\mathbf{Z}_{klk-1}^i = \mathbf{h}(\mathbf{X}_{klk-1}^i) + \boldsymbol{\mu}_k^V, \quad i=1,2,\dots,2qn \quad (12)$$

$$\boldsymbol{\mu}_k^V = \mathbf{E}[\mathbf{V}_k] \quad (13)$$

$$\hat{\mathbf{Z}}_{klk-1} = \frac{1}{2qn} \sum_{i=1}^{2qn} \mathbf{Z}_{klk-1}^i \quad (14)$$

(3) 估计误差的方差矩阵更新

$$\mathbf{P}_k = \mathbf{P}_{klk-1} - \mathbf{K}_k \mathbf{P}_{ZZ} \mathbf{K}_k^T \quad (15)$$

(4) 滤波增益矩阵

$$\mathbf{K}_k = \mathbf{P}_{XZ} \mathbf{P}_{ZZ}^{-1} \quad (16)$$

其中:

$$\mathbf{P}_{ZZ} =$$

$$\frac{r_i^*}{\omega} \sum_{i=1}^{2qn} [r_i^* (\mathbf{Z}_{klk-1}^i - \hat{\mathbf{Z}}_{klk-1}) (\mathbf{Z}_{klk-1}^i - \hat{\mathbf{Z}}_{klk-1})^T] + \mathbf{R}_k \quad (17)$$

$$\mathbf{P}_{XZ} =$$

$$\frac{r_i^*}{\omega} \sum_{i=1}^{2qn} [r_i^* (\mathbf{X}_{klk-1}^i - \hat{\mathbf{X}}_{klk-1}) (\mathbf{Z}_{klk-1}^i - \hat{\mathbf{Z}}_{klk-1})^T] \quad (18)$$

式中: r_i^* 为第 i 个采样点相应的协方差修正系数; 式中的 ω 所表示的是协方差权重系数, 其计算公式由式(19)确定。

$$\omega = \sum_{j=1, j \neq q+1}^{2q+1} r_j^2 \lambda_{p_j}^2 \quad (19)$$

在实际算法应用中, 采样层数 $q=2$, $r_i^* = r_i = 1, i=1, 2, \dots, 2qn$, 所以最后应用的 RKF 算法核心公式如式(20)所示。

$$\begin{cases} \hat{\mathbf{X}}_{klk-1} = \frac{1}{4n} \sum_{i=1}^{4n} \mathbf{X}_{klk-1}^{(i)} \\ \mathbf{P}_{klk-1} = \frac{1}{\omega} \sum_{i=1}^{4n} \{ (\mathbf{X}_{klk-1}^{(i)} - \hat{\mathbf{X}}_{klk-1}) \times (\mathbf{X}_{klk-1}^{(i)} - \hat{\mathbf{X}}_{klk-1})^T \} + \mathbf{Q}_{k-1} \\ \hat{\mathbf{X}}_k = \hat{\mathbf{X}}_{klk-1} + \mathbf{K}_k (\mathbf{Z}_k - \hat{\mathbf{Z}}_{klk-1}) \\ \mathbf{P}_k = \mathbf{P}_{klk-1} - \mathbf{K}_k \mathbf{P}_{ZZ} \mathbf{K}_k^T \\ \mathbf{K}_k = \mathbf{P}_{XZ} \mathbf{P}_{ZZ}^{-1} \end{cases} \quad (20)$$

3 基于 RKF 的 PDR 算法

3.1 基于 RKF 的 PDR 算法流程

在 RKF-PDR 算法中, 核心是将 RKF 算法和 ZUPT 相结合, 通过 RKF 算法对捷联惯性导航系统 (strap inertial navigation system, SINS) 得到的导航信息和零速检测算法提供的零速信息相融合, 减弱系统模型的非线性和非高斯影响, 从而使得最终位置信息更加精确, 算法结构如图 2 所示。

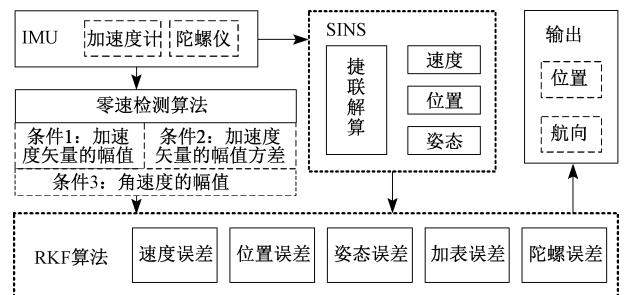


图 2 RKF-PDR 算法

Fig.2 RKF-PDR algorithm

其中核心的 RKF 算法结构如图 3 所示。

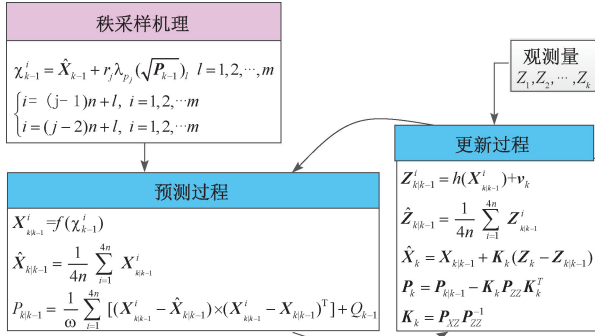


图3 RKF 算法结构流程

Fig.3 Structure flow chart of RKF algorithm

结合第 2 节, RKF 算法的具体步骤如下所示:

1) 初始化

$$\hat{\mathbf{x}}_0 = E[\mathbf{x}_0]$$

$$\mathbf{P}_0 = E[(\mathbf{x}_0 - \hat{\mathbf{x}}_0)(\mathbf{x}_0 - \hat{\mathbf{x}}_0)^T]$$

2) 预测过程

- (1) 根据式(4)和(5)计算秩采样点集;
- (2) 根据式(6)~(8)确定状态估计量;
- (3) 根据式(9)协方差估计值。

3) 更新过程

- (1) 根据式(11)~(14)计算量测预测值;
- (2) 根据式(15)计算协方差阵;
- (3) 根据式(16)~(18)计算滤波增益。

3.2 秩卡尔曼滤波器设计

RKF 算法作为融合模型参与 SINS 和零速度的滤波融合, 滤波融合得到的结果, 将用于修正 SINS 的值, 使之最后得到的距离和航向信息更加准确。基于 RKF 系统模型分为非线性状态模型和观测模型, 并在观测噪声中加入非高斯因素的影响。

1) 非线性系统模型

系统所使用的导航坐标系为东北天(ENU)坐标系 t , 其中 SINS 的平台误差角模型^[15,20]为:

$$\dot{\Phi} = (\mathbf{I} - \mathbf{C}_t^t) \hat{\omega}_{it}^t + \delta\omega_{it}^t - \mathbf{C}_b^t \delta\omega_{ib}^b \quad (21)$$

式中: 非线性形式主要体现在 $\mathbf{I} - \mathbf{C}_t^t$ 中, 各项参数具体形式见参考文献[15]中。

速度误差模型如下:

$$\delta\dot{\mathbf{V}} = [\mathbf{I} - (\mathbf{C}_t^t)^t] \mathbf{C}_b^t \hat{f}^b + \mathbf{C}_b^t \delta f^b - (2\hat{\omega}_{ie}^t + \hat{\omega}_{et}^t) \times \delta\mathbf{V} - (2\delta\omega_{ie}^t + \delta\omega_{et}^t) \times \mathbf{V} + \delta\mathbf{g} \quad (22)$$

位置误差模型如下:

$$\begin{cases} \delta\dot{L} = \frac{\delta v_y}{R_m + h} - \delta h \frac{v_y}{(R_m + h)^2} \\ \delta\dot{\lambda} = \frac{\delta v_x \sec L}{R_n + h} + \delta L \frac{v_x \tan L \sec L}{R_m + h} - \delta h \frac{v_x \sec L}{(R_n + h)^2} \\ \delta\dot{h} = \delta v_z \end{cases} \quad (23)$$

2) 状态方程和量测方程

系统状态方程为:

$$\dot{\mathbf{X}}_k = [\delta\Phi_k \quad \delta\omega_k \quad \delta\mathbf{P}_k \quad \delta\mathbf{V}_k \quad \delta\mathbf{a}_k]^T \quad (24)$$

式中: $\delta\Phi_k$ 按顺序依次表示 k 时刻的翻滚角、俯仰角、航向角误差; $\delta\omega_k$ 为 k 时刻的三轴陀螺仪常值漂移误差; $\delta\mathbf{P}_k$ 为 k 时刻的空间直角坐标系 $[\delta x \quad \delta y \quad \delta z]$ 位置误差; $\delta\mathbf{V}_k$ 为 k 时刻的 $[\delta v_x \quad \delta v_y \quad \delta v_z]$ 速度误差; $\delta\mathbf{a}_k$ 为 k 时刻的加速度计常值误差。整体的状态变量 $\delta\mathbf{X}_k$ 为一个 15 维的状态向量。

观测方程为:

$$\mathbf{Z} = \mathbf{H}\mathbf{X} + \mathbf{V} \quad (25)$$

式中: 观测量为 $\mathbf{Z} = [\delta V_{3 \times 3}]^T$; 观测系数矩阵为 $\mathbf{H} = [\mathbf{0}_{3 \times 3} \quad \mathbf{0}_{3 \times 3} \quad \mathbf{0}_{3 \times 3} \quad \mathbf{I}_{3 \times 3} \quad \mathbf{0}_{3 \times 3}]$; \mathbf{V} 为观测误差值。为验证 RKF 算法在 PDR 中对非高斯噪声抑制作用, 在观测方程中构造非高斯噪声。利用高斯混合模型产生的非高斯噪声为^[15]:

$$\mathbf{V} \approx \beta N(0, \mathbf{R}_1) + (1 - \beta) N(0, \mathbf{R}_2) \quad (26)$$

式中: β 是混合系数; \mathbf{R}_1 和 \mathbf{R}_2 是标准白噪声阵。

4 实验验证

4.1 室内测试环境

实验算法验证设备是 Xsens 公司的 MEMS IMU, 型号为 MTI, 其由 MEMS 的三轴陀螺仪、三轴加速度计以及三轴磁力计组成, MTI 的性能指标参数如表 1 所示, MTI 的实物图与固定位置如图 4 所示, 其中 MTI 固定在实验员的右脚。

表 1 IMU 性能参数表

Table 1 IMU performance parameter table

技术指标	数值
陀螺仪零偏稳定性	1°/s
陀螺仪量程	±300°/s
加速度计零偏稳定性	±50 m/s ²
加速度计量程	0.02 m/s ²
磁力计零偏稳定性	0.1 mguass
磁力计量程	±750 mguass
外形尺寸	58 mm×58 mm×22 mm
重量	50 g

测试场地是南昌大学信工机电楼 C 区的室内走廊部分区域,测试实际场景如图 5 所示。在测试时将 MEMS IMU 按图 4 所示固定在鞋子前部,行走轨迹如图 5 中实线所示,出发点为拍摄者所在位置。设定起点的平面二维坐标为(0, 0),沿着设定的路线行走,最终回到起点,行走的路程 D 全长为 76.8 m。行走轨迹中设计了 7 处转弯点,转弯处系统的非线性、非高斯特性较为明显,利于衡量算法解决非线性、非高斯问题的性能。



图 4 MTI 实物与安装图

Fig.4 MTI picture and MTI installation picture



图 5 实验场景与行走轨迹

Fig.5 Test scene and walking trajectory

4.2 性能分析

图 6 所示为实验过程中得到的最终行走轨迹对比曲线,黑色虚线是真实轨迹,蓝色实线是使用 EKF-PDR 算法作为融合模型得到的行人轨迹图,红色星线是使用 RKF-PDR 算法得到的行人轨迹图。从图 6 中可以看出,前 3 次转弯 EKF-PDR 算法行走表现和 RKF-PDR 算法相差不大,在第 4 次转弯时,EKF-PDR 和 RKF-PDR 算法的误差同时增大,因为转弯处系统模型的非线性程度会增大,RKF-PDR 和 EKF-PDR 算法虽均能将误差修正回来,但是从图 6 中可以看出 RKF-PDR 算法的效能更好。第 7 次转弯后,行人推算轨迹偏离实际轨迹越来越大,这是因为随着程序运行时间的增长,系统在非线性和非高斯噪声的作用下,位置误差逐渐发散,从图 6 中可以看出,RKF-PDR 算法偏离实际轨迹的距离较 EKF-PDR 的更小,这说明 RKF-PDR 算法抑制非线性系统和非高斯噪声引起的误差发散能力更强。因此,RKF-PDR 算法在解决非线性、非高斯问题时性能更加优异。

为进一步探究非线性系统和非高斯噪声模型下 EKF-PDR 算法和 RKF-PDR 算法对位置误差的性能表现,绘制了如图 7 所示状态向量 X_k 中的位置误差曲线

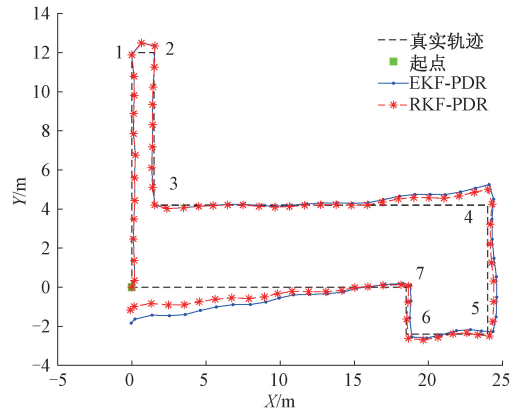


图 6 两种算法实验轨迹对比曲线

Fig.6 Experiment trajectory comparison diagram of two algorithm

图,横轴表示步数,纵轴显示的是状态向量中 x 方向和 y 方向位置的均方根误差值。蓝色虚线是 EKF-PDR 算法在解算过程中状态向量位置误差曲线,红色实线则是 RKF-PDR 算法的位置误差曲线。从图 7 中可看出,EKF-PDR 算法和 RKF-PDR 算法在行走的前阶段位置误差基本保持一致,但行走的中后阶段,位置误差曲线开始震荡发散,这正是由非线性系统和非高斯噪声干扰造成的。由于使用秩采样机理对非线性模型和非高斯噪声进行了更加合理精确的采样,RKF-PDR 算法的位置误差曲线相较于 EKF-PDR 算法的位置误差曲线更加的收敛,这说明 RKF-PDR 算法在非线性和非高斯噪声下性能更具优势。

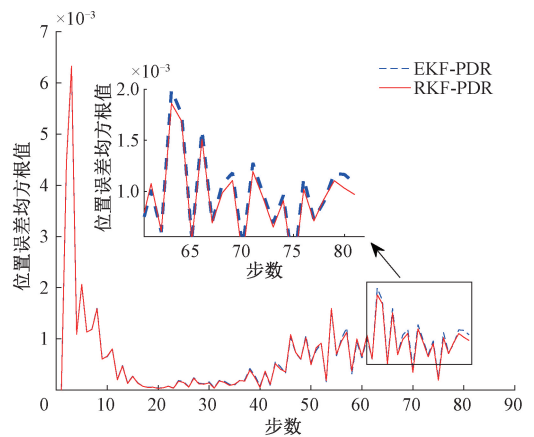


图 7 状态向量位置误差曲线

Fig.7 Position error curve graph in state vector

从算法效率角度进行分析,在处理器为 Intel Core i5-10210U,运行内存为 16 G 的计算机处理下得到表 2 所示的数据。从表 2 可知,RKF-PDR 算法程序对一组采样数据平均运行处理时间为 0.711 9 ms,较 EKF-PDR 算法的

0.695 0 ms 更慢一些,因为 RKF-PDR 算法需要采集足够的样本点,计算量较 EKF-PDR 算法更大,这说明算法在定位精度上的提高是以减慢效率为代价的,但是在提高 36%精度的情况下,降低 2%的效率是可以接受的。

表 2 运行效能比较

Table 2 Operation performance comparison

算法	定位误差/m	单组采样数据处理时间/ms
EKF-PDR	1.836 4	0.695 0
RKF-PDR	1.165 6	0.711 9

表 3 实验测试结果

Table 3 Experiment result table

实验次数	EKF-PDR 终点坐标	RKF-PDR 终点坐标	EKF-PDR 定位误差/m	RKF-PDR 定位误差/m	精度提升/%
1	(-0.040 6, -1.836)	(-0.091 34, -1.162)	1.836 4	1.165 6	36.53
2	(-0.735, -3.01)	(-0.714 7, -2.552)	3.098 4	2.650 2	14.47
3	(-1.405, -2.976)	(-1.263, -2.477)	3.291 0	2.780 4	15.51
4	(-1.284, -2.321)	(-1.099, -1.779)	2.652 5	2.091 1	21.17
5	(2.297, -1.51)	(2.23, -1.153)	2.748 9	2.510 4	8.67
6	(0.123, -2.386)	(0.272 7, -1.962)	2.389 2	1.980 9	17.09
平均	(-0.174 1, -2.339 8)	(-0.110 9, -1.847 5)	2.669 4	2.196 4	18.91




图 8 位置误差对比

Fig.8 Position error comparison graph

5 结 论

通过将 RKF 技术和 ZUPT 相结合,提出了一种基于 RKF 的室内 PDR 算法,本文算法能够缓解采用卡尔曼滤波进行室内行人导航数据融合时精度较低的问题。作为融合核心的 RKF 算法由于其独特的采样规则,可以对一般非高斯分布进行更加合理精确的采样,进而能够提高非线性模型和非高斯噪声下室内行人导航定位的精度。

通过多次试验进一步验证该算法在非线性系统和非高斯噪声模型下性能,得到表 3 所示数据。为使数据更加直观,实验位置误差对比如图 8 所示,前 6 组数据为试验位置误差对比,第 7 组为 6 组数据的平均位置误差对比。从图 8 的位置误差对比可以轻易看出,RKF-PDR 具有更佳的效果。对结果的进一步分析可知,基于 RKF 的 PDR 算法得到的位置误差均值为 2.196 4 m,而基于 EKF 的 PDR 算法得到的位置误差均值为 2.669 4 m,RKF-PDR 算法相比 EKF-PDR 算法误差平均减小了 18.91%。从上述数据可以看出,所提 RKF-PDR 算法能够有效抑制非线性系统和非高斯噪声的影响,具有更高的可靠性和稳定性。

最后通过实验结果表明,本文算法相对于使用 EKF 作为融合方法的 PDR 算法有一定的提高,使得室内行人导航定位的结果精度更高。算法验证采用了较短的行走轨迹,同时,对测试人员行走过程提出较多约束,与实际行人运动存在较大差异。在未来的研究工作中,将引入长距离复杂路径行走测试条件,分析并改进本文算法在长距离条件下性能表现。与此同时,将针对 RKF 算法带来的实时性问题展开进一步优化。

参考文献

[1] ZHU F, TAO X, LIU W, et al. Walker: Continuous and precise navigation by fusing GNSS and MEMS in smartphone chipsets for pedestrians[J]. Remote Sensing, 2019, 11(2): 139.

[2] DAVIDSON P, PICHE R. A Survey of selected indoor positioning methods for smartphones [J]. IEEE Communications Surveys & Tutorials, 2017, 19 (2): 1347-1370.

[3] GROVES, PAUL D. Principles of GNSS, inertial, and multi-sensor integrated navigation systems[J]. Industrial Robot, 2013, 67(3):191-192.

[4] HARLE R. A survey of indoor inertial positioning systems for pedestrians [J]. IEEE Communications Surveys & Tutorials, 2013, 15(3): 1281-1293.

[5] 徐元, 陈熙源. 面向室内行人的 Range-only UWB/INS 紧组合导航方法[J]. 仪器仪表学报, 2016, 37(9):

- 2115-2121.
- XU Y, CHEN X Y. Range-only UWB/INS tightly-coupled integrated navigation method for indoor pedestrian[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 2115-2121.
- [6] 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.
- [7] LEE M S, JU H, PARK C G. Map assisted PDR/Wi-Fi fusion for indoor positioning using smartphone [J]. International Journal of Control, Automation and Systems, 2017, 15(2): 627-639.
- [8] 杨菊花, 李文元, 陈光武, 等. 引入滑模观测器的 GPS/INS 组合导航滤波方法 [J]. 仪器仪表学报, 2019, 40(9): 78-86.
- YANG J H, LI W Y, CHEN G W, et al. GPS/INS integrated navigation filtering method based on sliding mode observer [J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 78-86.
- [9] 王鼎杰, 孟德利, 李朝阳, 等. 抗野值自适应卫星/微惯性组合导航方法 [J]. 仪器仪表学报, 2017, 38(12): 2952-2958.
- WANG D J, MENG D L, LI CH Y, et al. Adaptively outlier-restrained GNSS/MEMS-INS integrated navigation method [J]. Chinese Journal of Scientific Instrument, 2017, 38(12): 2952-2958.
- [10] LIU D, DUAN J, SHI H. A strong tracking square root central difference fast SLAM for unmanned intelligent vehicle with adaptive partial systematic resampling [J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(11): 3110-3120.
- [11] FAN Q, ZHANG H, PAN P, et al. Improved pedestrian dead reckoning based on a robust adaptive Kalman filter for indoor inertial location system [J]. Sensors, 2019, 19(2): 294.
- [12] ZHAO Y. Performance evaluation of Cubature Kalman filter in a GPS/IMU tightly-coupled navigation system [J]. Signal Processing, 2016, 119: 67-79.
- [13] 傅惠民, 杨海峰, 肖梦丽, 等. 非线性状态方程自校准滤波方法 [J]. 航空动力学报, 2019, 34(2): 267-273.
- FU H M, YANG H F, XIAO M L, et al. Nonlinear state equation self-calibration filtering method [J]. Journal of Aerospace Power, 2019, 34(2): 267-273.
- [14] 傅惠民, 肖强, 娄泰山, 等. 非线性非高斯秩滤波方法 [J]. 航空动力学报, 2015, 30(10): 2318-2322.
- FU H M, XIAO Q, LOU T SH, et al. Nonlinear and non-Gaussian rank filter method [J]. Journal of Aerospace Power, 2015, 30(10): 2318-2322.
- [15] 王磊, 程向红, 刘纯利, 等. 复杂环境下基于 Huber-RKF 的机器人信息融合算法 [J]. 中国惯性技术学报, 2019, 27(1): 60-65.
- WANG L, CHENG X H, LIU CH L, et al. Huber-based rank Kalman filtering algorithm for mobile robot in complex environment [J]. Journal of Chinese Inertial Technology, 2019, 27(1): 60-65.
- [16] FOXLIN E. Pedestrian tracking with shoe-mounted inertial sensors [J]. IEEE Computer Graphics & Applications, 2005, 25(6): 38-46.
- [17] XU L, XIONG Z, LIU J, et al. A novel pedestrian dead reckoning algorithm for multi-mode recognition based on smartphones [J]. Remote Sensing, 2019, 11(3): 294.
- [18] GOBANA F W. Survey of inertial/magnetic sensors based pedestrian dead reckoning by multi-sensor fusion method [C]. 2018 International Conference on Information and Communication Technology Convergence (ICTC), IEEE, 2018: 1327-1334.
- [19] 钱伟行, 周紫君, 谢非, 等. 基于机器学习与步态特征辅助的行人导航方法 [J]. 中国惯性技术学报, 2019, 27(4): 433-439, 447.
- QIAN W H, ZHOU Z J, XIE F, et al. Pedestrian navigation method based on machine learning and gait feature assistance [J]. Journal of Chinese Inertial Technology, 2019, 27(04): 433-439, 447.
- [20] ZHANG M, DAI H, HU B, et al. Robust adaptive UKF based on SVR for inertial based integrated navigation [J]. Defence Technology, 2019, DOI: 10.1016/j. dt. 2019. 10. 012.

作者简介



余志鹏, 2017 年于河南工业大学获得学士学位, 现为南昌大学硕士研究生。主要研究方向为行人导航及数据融合研究。

E-mail: yu_zhi_peng@126.com

Yu Zhipeng received his B. Sc. degree in 2017 from Henan University of Technology.

Now, he is a M. Sc. candidate in Nanchang University. His main research interest includes pedestrian navigation, data fusion.



熊剑 (通信作者), 1999 年于长安大学获得学士学位, 2004 年于南京航空航天大学获得硕士学位, 2011 年于南京航空航天大学获得博士学位, 现为南昌大学讲师, 主要研究方向为惯性导航与非线性滤波技术。

E-mail: xiongjian@ncu.edu.cn

Xiong Jian (corresponding author) received his B. Sc. degree in 1999 from Chang'an University, received his M. Sc. degree in 2004 and Ph. D. degree in 2011 both from Nanjing University of Aeronautics and Astronautics. Now, he is a lecturer in Nanchang University. His main research interest includes inertial navigation and non-linear filtering technique.