

DOI: 10.13382/j.jemi.B2205370

关于 PDR 算法步长估计模型的改进研究^{*}

邸克 刘茹鑫 杜佳佳 任杰 赵卫峰 刘宇

(重庆邮电大学光电工程学院 重庆 400065)

摘要:为了更加精确地判别基于微惯性测量单元(IMU)的行人定位信息,本文深入研究了传统行人航迹推算(PDR)算法模型,发现传统算法所采用的判别条件单一且精准度不高。针对传统算法中步长估计模型不准确的问题,本研究首先提出一种基于扩展卡尔曼滤波的误差补偿优化算法,以实现 IMU 内集成的加速度计、陀螺仪等传感器的误差补偿。将优化后的原始数据放入 BP 神经网络算法对单参数步长估算经验模型进行训练。实验结果表明,基于 BP 神经网络融合基础模型的步长算法相比单纯的基础步长模型,闭环精度提高了 0.3% 以上,开环误差减小了 8.5 倍,基于 BP 神经网络的改进 PDR 算法可以有效抑制惯性算法的误差发散。

关键词: 行人定位;步长估计;卡尔曼滤波;BP 神经网络

中图分类号: TP212.9;TN912.3 **文献标识码:** A **国家标准学科分类代码:** 510.99

Research on the improvement of step size estimation model of PDR algorithm

Di Ke Liu Jiaxin Du Jiajia Ren Jie Zhao Weifeng Liu Yu

(School of Optoelectronic Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: In order to better distinguish the pedestrian positioning information based on micro inertial measurement unit (IMU), this paper deeply studies the traditional pedestrian dead reckoning (PDR) algorithm model, and finds that the traditional algorithm has single discrimination conditions, low accuracy and is not suitable for scenes with a variety of terrain. Aiming at the problem of inaccurate step estimation model in traditional algorithms, this study first proposes an error compensation optimization algorithm based on extended Kalman filter (EKF) to realize the error compensation of accelerometer, gyroscope and other sensors integrated in IMU. The study put the optimized original data into BP neural network algorithm to train the single parameter step estimation empirical model. The experimental results show that the step size algorithm based on BP neural network fusion basic model can improve the closed-loop accuracy by more than 0.3% and reduce the open-loop error by 8.5 times compared with the simple basic step size model. The improved PDR algorithm based on BP neural network can effectively suppress the error dispersion of inertial algorithm.

Keywords: pedestrian positioning; step estimation; Kalman filter; BP neural network

0 引言

伴随着人类活动领域的不断扩张,定位导航相关技术也一直在不断地发展,活动范围衍生到哪个领域,就会有对应的定位需求和相应技术^[1]。基于位置服务^[2](location-based services, LBS)开始广泛地受到各方面的关注,并应用在整个社会的多个领域。近年来作为室内定位技术主流之一的惯性导航定位技术也开始被应用到

了其他更广泛的领域之中^[3],其定位原理是通过运动载体上的配置的惯性传感器,对运动载体全方位的姿态角和加速度等信息进行采集和融合处理,并将这些运动信息代入到 PDR 算法或者其它惯性定位算法中求得运动载体实时的位置信息和姿态信息,与过去信息进行对比和累加操作,实现导航定位^[4-5]。美国 Inter Sense 公司与凯斯西储大学合作研发的基于 IMU 的导航系统,将 MIMU 固定于人的鞋上,即“导航鞋”,“导航鞋”是一种自主式行人导航系统,无论在室内还是室外,都能进行导

航定位^[6]。美国卡耐基梅隆大学将 IMU 固定于小腿处,并在双腿处增加声纳系统辅助测量步长,并作为 PDR 算法的测距的约束条件,但是整体系统体积偏大,在民用市场中存在局限^[7]。Zhang 等^[8]通过在行人的足部和上身部位安装微惯性器件判断行人步态周期的零速时刻,并在此基础上提出了基于自适应阈值(adaptive threshold, AT)的零速更新算法(zero velocity updates, ZUPT),该算法可以有效降低积分法产生的扩大误差,但是微惯性器件在保持长久航时后,仍会出现明显的积分漂移误差。

当前行人自主定位研究多采用异质传感器进行辅助定位,纯粹依靠惯性器件进行定位的精度较低,且由于存在“累计误差”无法保证长久航时精度。同时在实际生活中,行人步行运动并非是一个标准的线性系统,过程中非线性因素较多且不可忽略,需要将行人的步行运动作为非线性情形进行处理,传统 PDR 算法多数采用单一特征统计量作为判决条件,导致 IMU 的精度很难保持稳定,同时也不能满足行人在不同运动模式下步长判别的精确要求。BP 神经网络作为一种将误差反向传播用来训练前馈网络的算法,具有很好的自学习和自适应能力,在行人惯性定位领域具有重要的研究意义和实用价值。本文拟对 IMU 中加速度计、陀螺仪、磁力计等惯性的原始数据进行误差补偿,并将优化后的数据放入 BP 神经网络中对 PDR 算法中的单参数步长估计经验模型进行训练,得到不同身高和运动模式下的最佳 K 值,从而保证行人步长的精确性和长航时的精度。

1 步态的检测特征

为了准确地识别行人步数,首先需要对行人的行走步态进行基本的认知和研究。行人行走过程中的步态变化如图 1 所示。行走运动是一个周期过程:行人的脚部运动从脚跟离地开始,经过滞空摆动和脚跟落地,最后脚部与地面贴合并保持相对静止持续一段时间,之后又开始另外一只脚步的脚跟离地动作,以此做周期性循环。

本研究将从脚步离地到重新落回地面的过程称为一个步态周期,其中脚部未贴合地面的阶段称为运动区间,而脚部与地面完全贴合的阶段称为零速区间。在行人的步行运动的过程中,人体的水平速度和垂直速度都将会在每个步态周期中呈现规律变化,脚与地面贴合时,速度为 0,垂直的向下加速度最大,当执行抬脚动作时人体获得了垂直向上的加速度,速度开始变大,当脚抬至最高点时速度也到达最大值且加速度最小,随后脚部落下直至贴合整个地面的过程中加速度再次变大且速度减小到 0。在每个步态周期过程中,加速度都会出现相应的最大值和最小值,因此可以将加速度作为行人步态运动模式检测的特征检测值^[9]。




图 1 行人步态图
Fig. 1 Pedestrian gait diagram

本文实验对于步数的统计都是以单步的计数。基于 IMU 的行人步数识别模型通常包括的步骤有数据采集环节、信号预处理环节、特征提取环节、识别训练环节、识别处理环节。这些步骤之间的关系如图 2 所示。




图 2 IMU 行人步数识别模型
Fig. 2 Step recognition model for pedestrians in IMU

2 基于扩展卡尔曼滤波的误差优化

针对非线性系统,学者在标准卡尔曼滤波算法的基础上提出了扩展卡尔曼滤波算法,扩展卡尔曼滤波算法是针对标准卡尔曼滤波算法无法处理非线性问题而提出的改进算法,核心思想是利用泰勒级数的一阶展开公式获取当前系统斜率来构造近似线性函数,从而使非线性系统线性化,最后采用增益方程和更新方程对参数指标进行优化。本研究行人运动过程非线性状态作为一个将扩展卡尔曼系统,将运动状态进行线性化,然后采用线性框架对输入信号进行优化处理。

在标准卡尔曼滤波算法中其 5 个核心递推更新方程如下^[10]:

1) 状态的一步预测方程:

$$\hat{x}_k^- = A\hat{x}_{k-1} + Bu_{k-1} \quad (1)$$

2) 均方误差的一步预测方程:

$$P_k^- = AP_{k-1}A^T + Q \quad (2)$$

3) 卡尔曼增益方程:

$$K_k(k) = P_k^- H_k^T [H_k P_k^- H_k^T + R]^{-1} \quad (3)$$

4) 最优估计方程:

$$x_k = x_k^- + K_k [z_k - Hx_k^-] \quad (4)$$

5) 估计协方差矩阵更新方程:

$$P_k = P_k^- - K_k H_k P_k^- \quad (5)$$

以上即为标准卡尔曼滤波的 5 个核心公式,式(1)和(2)前两个方程为时间更新方程,式(3)~(5)为状态更新方程,式(1)~(5)里右上角带“-”标记的为预测量。只要已知初始状态量和初始协方差矩阵,则可通过 k 时刻的观测量和卡尔曼增益方程,迭代得到 k 时刻的最优估计量。

针对非线性系统,首先将标准卡尔曼滤波算法中离散线性系统的状态方程和观测方程改写成如下形式:

$$\begin{cases} x_t = f(\hat{x}_{t-1}, u_{t-1}) + w_t \\ z_t = h(\hat{x}_t, v_t) \end{cases} \quad (6)$$

因为在非线性系统中,噪声等参数不满足正态分布,状态估计和预测都是通过线性化近似逼近线性系统下的最优解,因此新的动态方程表示为:

$$\begin{cases} X_k \cong \tilde{X}_k + A(X_{k-1} - \hat{X}_{k-1}) + Ww_{k-1} \\ Z_k \cong \tilde{Z}_k + H(X_k - \tilde{X}_k) + Vv_k \end{cases} \quad (7)$$

$$\begin{bmatrix} 0 & -(w_x - bw_x) & -(w_y - bw_y) & -(w_z - bw_z) \\ \frac{1}{2} \begin{bmatrix} w_x - bw_x & 0 & w_z - bw_z & -w_y - bw_y \\ w_y - bw_y & -(w_z - bw_z) & 0 & w_x - bw_x \\ w_z - bw_z & w_y - bw_y & -(w_x - bw_x) & 0 \end{bmatrix} & \begin{bmatrix} q_0(t-1) \\ q_1(t-1) \\ q_2(t-1) \\ q_3(t-1) \end{bmatrix} \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

本研究将三轴加速度计和磁力计的测量值作为观测值,因此通过式 t 时刻状态空间的状态预测方程进行更新后得到的观测方程如下^[13]:

$$\begin{cases} \hat{z}_k = \begin{bmatrix} \hat{a} \\ \hat{m} \end{bmatrix} = \begin{bmatrix} c_n^b & 0 \\ 0 & c_n^b \cdot c_{mag} \end{bmatrix} \cdot \begin{bmatrix} g \\ h \end{bmatrix} \\ c_{mag} = \begin{bmatrix} \cos(\sigma) & \sin(\sigma) & 0 \\ -\sin(\sigma) & \cos(\sigma) & 0 \\ 0 & 0 & 1 \end{bmatrix} \end{cases} \quad (12)$$

其中, c_{mag} 为磁力计的修正矩阵, σ 表示磁力计指北方向与地理北向的夹角, h 表示将磁力计在 Y/Z 轴上形

式中: X_k 是当前时刻的实际状态量, Z_k 是当前时刻的系

统观测量, $\tilde{X}_k$ 和 $\tilde{Z}_k$ 是近似状态量和观测量。本研究采用陀螺仪数据作为状态预测量,再利用加速度计和磁力计的观测数据量来更新预测状态方程,用来消除加速度计、陀螺仪等惯性器件在解算过程中产生的累积误差^[11]。

结合四元数定义:

$$Q = q_0 + q_1 i + q_2 j + q_3 k \quad (8)$$

本研究将系统的状态量参数设为:

$$\hat{x} = \{q_0, q_1, q_2, q_3, bw_x, bw_y, bw_z\} \quad (9)$$

其中, bw_x, bw_y, bw_z 表示的是陀螺仪三轴上的角速率零偏值。

姿态角四元数微分方程为^[12]:

$$\begin{cases} \dot{Q} = \frac{1}{2} Q \otimes W \\ Q(t_0) = Q_0 \end{cases} \quad (10)$$

式中: Q 表示四元数, W 为载体坐标系下的姿态角速率的矩阵形式, t_0 为解算的初始时间, Q_0 为初值。其中 W 的表达式为:

$$W = \begin{bmatrix} 0 & -w_x & -w_y & -w_z \\ w_x & 0 & w_z & -w_y \\ w_y & -w_z & 0 & w_x \\ w_z & w_y & -w_x & 0 \end{bmatrix} \quad (11)$$

则根据式(9)~(11)可以得到 t 时刻状态空间的预测矩阵为:

成的单位矢量, g 表示重力加速度。根据上述公式,可得到当前时刻加速度计和磁力计的观测值,然后通过增益方程更新陀螺仪的状态量。

最后对比三轴和加速度数据在滤波前后输出数据。其三轴加速度的原始波形如图 3 所示,滤波前后的和加速度波形对比如图 4 所示。

从图 4 可以看出,经过 EKF 算法后的和加速度数据比起滤波前减少了突变波动,抑制了非线性噪声的出现,整体得到更加平滑稳定的信号波形。通过加速度计的输出结果对比可知,本研究设计的扩展卡尔曼滤波算法能




图 3 三轴原始加速度
Fig. 3 Triaxial original acceleration




图 4 滤波前后的和加速度对比

Fig. 4 Comparison of and acceleration before and after filtering

可以达到数据融合、优化精度的效果。

3 基于 BP 神经网络的步长估计模型

行人行走过程中,位置的轨迹的判断其实本质是从每一次步长位移累加而成。假设人的起始点坐标为 (x_0, y_0) ,每一步的步长为 $SL_i (i=1, 2, \dots, k)$,航向为 ψ_i , k 时刻的位置坐标可以表示为^[14]:

$$\begin{cases} x_k = x_0 + \sum_{i=1}^n SL_i \cos \psi_i \\ y_k = y_0 + \sum_{i=1}^n SL_i \sin \psi_i \end{cases} \quad (13)$$

PDR 算法的基本原理示意如图 5 所示。步长的估算精度是 PDR 算法非常重要的一个参数指标。

目前主流采用的步长估算模型除了设置分类固定步长的方式外,单参数经验模型使用较为广泛。该模型如




图 5 PDR 算法原理图

Fig. 5 Schematic diagram of PDR algorithm

式(14)所示^[15]:

$$L = K \times \sqrt{A_{\max} - A_{\min}} \quad (14)$$

其中, $A_{\max}$ 、 $A_{\min}$ 表示完成一次跨步过程中加速度的最大模值和最小模值, K 为单位转换的常数。在算法的实际使用中, K 值一般取真实步长与估算步长的比值。单参数经验模型计算简便,且与步态检测算法能够很方便的结合。

本文提出的步长估算算法模型是先利用采集的加速度计数据在 BP 神经网络中对校准系数 K 进行训练,然后代入式(14)中计算每个步态周期的步长,最后结合测试数据预测结果。输出层的单元是校准系数 K ,其大小与实验人员的身高 h 和运动模式 m 具有强相关性,可以建立如下非线性关系:

$$K = \Phi(h, m) \quad (15)$$

在对 K 值进行训练的 BP 网络结构中,输出层单元只有 1 个 K 值,输入层单元为身高 h 和运动模式 m ,设隐含层的节点数为 r ,其结构为图 6 所示^[16]。




图 6 对 K 值训练的 BP 神经网络结构

Fig. 6 Structure diagram of BP neural network for k -value training

用式(16)可求得网络中隐含层单元个数:

$$\begin{cases} r \leq 2n + 1 \\ r = \log_2 n \\ r < \sqrt{(m+n)} + c \end{cases} \quad (16)$$

式中; m, n 表示输入单元和输出单元个数, c 是 0~10 范围内的常数^[17]。对参数 r 具体值的求解需要首先确定 r

的大致范围,之后在该范围内需要多次试验确定 r 的最佳值,本研究通过多次的训练结果总结出 $r=5$ 为隐含层最优单元个数。图7为本文提出的BP神经网络融合经验模型计算步长的流程图^[18]。




图7 步长算法流程

Fig. 7 Step size algorithm flow chart

要想获得精确的校准系数 K 值,需要采集不同身高的行人在不同运动模式下的行走数据对BP神经网络进行大量训练^[19],使其能够根据采集得到运动数据对输出的 K 值进行实时的预测和修正。本研究将行人的身高分为155~160 cm、160~165 cm、165~170 cm、170~175 cm、175~180 cm、180~185 cm 6个数据区间,将行人的运动模式分为慢走、奔跑两种模式,由身高从155~185 cm的6位测试人员佩戴IMU,分别沿着长度为200 m的道路按照2种不同的行走模式每人完成5组测试。求出60组数据的校准系数平均值 K ,将数据放入网络模型中对权重、阈值参数进行训练。

为了验证基于BP神经网络的步长算法的优越性,本文将BP神经网络修正 K 值步长算法模型和固定 K 值的传统基础模型进行比较,让身高不同的6位实验人员分别进行上述实验,即沿总长为200 m的直线用2种不同运动模式完成步行运动,如图8所示。





图8 BP神经网络进行训练的两种模式

Fig. 8 Two training modes of BP neural network


最后对这些数据进行仿真得到两种算法的估计步长,通过步长计算出距离值,其结果对比图分别如图9和10所示。

从图9和10可以看出,在慢走模式下的对比可知,慢走运动模式下的基础模型的位移在194.1~209.6 m之间,BP神经网络模型的位移在197.8~206.2 m,基础模型的步长误差为7.5%左右,BP神经网络模型的误差约为4.6%,误差降低了3%左右;奔跑运动模式下的基础模型测试的位移在185.2~198.3 m之间,BP神经网络模



(a) 基础模型的步长估计结果

(a) Step size estimation results of basic model



(b) 基础模型的步长估计结果

(b) Step size estimation results of BP model

图9 基础模型与BP模型在慢走状态下的步长估计对比


Fig. 9 Comparison of step size estimation between basic model and BP model in slow walking state

型测试的位移在190.2~197.8 m,基础模型的步长误差为6.5%左右,BP神经网络模型的误差约为3.8%,误差降低了2.7%左右。


最后在室外场景进行综合验证^[20],测试基于BP神经网络的步长估计模型的改进PDR算法的整体精度。综合验证的实验地点选在室外运动操场,外圈长度为 $S_1=160$ m,宽 $S_2=85$ m,测试路线如图11所示。

测试方案:图11中,六角星所标志位置为操场主席台,本实验将其作为行人出发的起始点,实验人员依照图中箭头方向前进,并最终返回起点处^[21]。测试人员在起点位置站定,当IMU系统数据通过嵌入式系统平台进行解算,并上发给接收机,当接收机接收到IMU数据时实验人员开始出发,实验人员按照预定路线行走一圈后回到起点,随后完成本次测试。最后利用仿真软件复现实验人员的平面运动路线,如图12所示。

从图11中所复现的路线形状来看,与实际测试路线



(a) 基础模型的步长估计结果
(a) Step size estimation results of basic model



(b) 基础模型的步长估计结果
(b) Step size estimation results of BP model

图 10 基础模型与 BP 模型在奔跑走状态下的步长估计对比
Fig. 10 Comparison of step size estimation between basic model and BP model in running state



图 11 综合测试场景
Fig. 11 Comprehensive test scenario

基本保持一致。图 11 中显示的最终坐标点为 $(-0.3, 1.1)$, 总误差保持在 1.14 m 。测试路线的总长度为 490 m , 因此运动轨迹的闭环误差在 0.23% 。X 轴坐标的最大变化值为 161.3 m , Y 轴的最大变化值为 85.2 m , X 轴和 Y 轴的开环误差分别为 0.81% 和 0.24% 。

为了对比分析, 本实验针对同一测试路线采用传统




图 12 基于 BP 神经网络的改进 PDR 算法的行人轨迹图
Fig. 12 Pedestrian trajectory diagram based on improved PDR algorithm of BP neural network

PDR 算法进行对比, 使用仿真软件将行人运动轨迹进行复现, 如图 13 所示。




图 13 基于传统 PDR 算法的行人轨迹图
Fig. 13 Pedestrian trajectory map based on traditional PDR algorithm

从图 13 可以看出, 行人运动轨迹的形状与图 12 已有较大出入, 行走过程中会出现数据跳变突刺和的问题, 并且由于传统 PDR 算法的步长估计误差较大, 导致轨迹的长度变小, 宽度变大了。根据突出显示的终点坐标 $(-2.3, 2.5)$, 总误差为 3.39 m , 测试路线的总长度为 490 m , 因此运动轨迹的闭环误差在 0.7% 。同理也需要考虑开环误差, 定位轨迹的中 X 轴坐标的最大变化值为 157.3 m , Y 轴的最大变化值为 92.1 m , X 轴和 Y 轴的开环误差分别为 1.7% 和 8.3% 。

本研究针对综合实验总共进行了 8 组对照试验, 将基于 BP 神经网络的改进 PDR 的误差和基于传统 PDR 的误差进行对比, 表 1 是综合实验测试轨迹的闭环误差和开环误差对比。从表 1 中的统计结果可知, 传统

PDR 的闭环误差平均值到达了 0.71%,开环误差误差平均值为 5.19%;基于 BP 神经网络的改进 PDR 的闭环误差平均值为 0.29%,开环误差误差的均值为 0.61%。经上对比结果发现,就闭环误差而,基于 BP 神经网络的改进 PDR 的误差均值和传统 PDR 的误差均值差距不大差值维持在 0.4%左右,但在实际工程或生活中,行人并不会在每次运动后都返回原处,因此开环误差更具有参考价值和实际意义,通过表 1 的统计发现,开环误差减小了约 8.5 倍。

表 1 综合实验误差对比

Table 1 Comparison of comprehensive experimental errors

测试 组号	基于 BP 神经网络改进		传统 PDR 轨迹(X/Y)	
	PDR 轨迹(X/Y)			
	闭环误差/%	开环误差/%	闭环误差/%	开环误差/%
1	0.23	0.81/0.24	0.70	1.72/8.32
2	0.34	0.93/0.34	0.72	1.75/8.85
3	0.27	0.78/0.21	0.80	1.84/9.45
4	0.22	0.88/0.29	0.64	1.62/8.21
5	0.21	0.85/0.36	0.72	1.73/9.04
6	0.26	0.83/0.29	0.69	1.65/8.14
7	0.31	0.91/0.25	0.70	1.71/8.38
8	0.25	0.94/0.54	0.73	1.79/8.91
均值	0.29	0.61	0.71	5.19

4 结 论

本研究针对行人运动过程中出现的非线性干扰采用了扩展卡尔曼滤波波进行处理,提升了 IMU 内集成的陀螺仪和加速度计的输出精度;基于 BP 神经网络融合基础模型的步长算法模型相比传统的基础步长算法模型,精度得到提高。但由于 IMU 自身的器件精度问题以及实验人员操作规范等问题,基于 BP 神经网络修正 K 值的步长估计算法依旧存在一定可接受范围内的误差。

步长估计是当前 PDR 算法的最为关键的参数,本文关于改进 PDR 算法的研究,在行人惯性定位、导航与授时方面具有重要研究意义。

参考文献

[1] GUPTA R, RAO U P. An exploration to location-based service and its privacy preserving techniques; A survey[J]. Wireless Personal Communications, 2017, 96 (2): 1973-2007.

[2] ZHAO L, QIU H Y, FENG Y M. Analysis of a robust Kalman filter in loosely coupled GPS/INS navigation system[J]. Measurement, 2016, 80(16): 138-147.

[3] XU H, YE D, LI P, et al. An RFID indoor positioning algorithm based on bayesian probability and K-nearest neighbor[J].Sensors, 2017, 17(8): 1806-1823.

[4] 王巍. 惯性技术研究现状及发展趋势[J]. 自动化学报, 2013, 39(6): 723-729.

WANG W. Research status and development trend of inertial technology[J]. Acta Automatica Sinca, 2013, 39(6): 723-729.

[5] SHAEFFER D K. MEMS inertial sensors: A tutorial overview[J]. Communications Magazine IEEE, 2013, 51(4): 100-109.

[6] STIRLING R, COLLIN J, FYFE K, et al. An innovative shoe-mounted pedestrian navigation system [C] Proceedings of European Navigation Conference GNSS, 2011:110-115.

[7] LU CH H. Indoor positioning system based on Chest-Mounted IMU[J]. Sensors, 2019, 19(2): 420-420.

[8] ZHANG R, YANG H, HOFLINGER F, et al. Adaptive zero velocity update based on velocity classification for pedestrian tracking [J]. IEEE Sensors Journal, 2017, 17(7): 2137-2145.

[9] 张旭. 基于分布式多节点微传感器的行人自主定位技术研究[D]. 重庆:重庆邮电大学, 2019.

ZHANG X. Research on pedestrian localization technology based on distributed multi node micro sensors [D]. Chongqing: Chongqing University of Posts and Telecommunications, 2019.

[10] ZHENG B, YANG X R, HU H T. Research on attitude solving algorithm of towing cable based on convolutional neural network fusion extended kalman filter [C]. Abstracts of the 7th International Conference of Pioneering Computer Scientists, Engineers and Educators (ICPCSEE 2021) Part I. Taiyuan: ICPCSEE, 2021: 83-85.

[11] 郑智源. 基于 FPGA 的扩展卡尔曼滤波波算法的设计[D]. 哈尔滨: 哈尔滨理工大学, 2020.

ZHENG ZH Y. Design of extended Kalman filter algorithm based on FPGA[D]. Harbin: Harbin Institute of Technology, 2020.

[12] 黄玉. 地磁场测量及水下磁定位技术研究[D]. 哈尔滨:哈尔滨工程大学, 2011.

HUANG Y. Research on geomagnetic field measurement and underwater magnetic positioning technology [D]. Harbin: Harbin Engineering University, 2011.

[13] 施奇杰,曹大平. 基于扩展卡尔曼滤波的姿态估计算法[J]. 信息技术, 2020, 44(6): 78-83.

SHI Q J, CAO D P. Attitude estimation algorithm based on extended Kalman filter[J]. Information Technology, 2020, 44 (6): 78-83.

[14] 陈丽娜. WLAN 位置指纹室内定位关键技术研究[D]. 上海:华东师范大学, 2014.

- CHEN L N. Research on key technologies of WLAN location fingerprint indoor location[D]. Shanghai: East China Normal University, 2014.
- [15] ZHANG Z X, CAO Y. PDR algorithm based on motion behavior recognition [J]. International Journal of Science, 2020, 7(4): 19-22.
- [16] 唐若玥. 基于感性工学的塑料材料质感意象模型研究[D]. 哈尔滨: 哈尔滨工业大学, 2013.
- TANG R Y. Research on plastic material texture image model based on perceptual engineering [D]. Harbin: Harbin Engineering University, 2013.
- [17] 刘多纳. 室内定位领域的无线惯性传感自组网技术研究[D]. 重庆: 重庆邮电大学, 2018.
- LIU D N. Research on wireless inertial sensor ad hoc network technology in indoor positioning field [D]. Chongqing: Chongqing University of Posts and Telecommunications, 2018.
- [18] SUN Y L. Human localization using multi-source heterogeneous data in indoor environments [J]. IEEE Access, 2017, 5: 812-822.
- [19] MANDAL D. A hesitant intuitionistic fuzzy set approach to study ideals of semirings[J]. International Journal of Fuzzy System Applications (IJFSA), 2021, 10(3): 1-17.
- [20] FARHADINIA B, CHICLANA F. Extended fuzzy sets and their applications[J]. Mathematics, 2021, 9(7): 770-770.
- [21] ROAN T N. Representing complex intuitionistic fuzzy set by quaternion numbers and applications to decision making [J]. Applied Soft Computing Journal, 2020, 87(C): 105961.

作者简介



邸克, 2007 年于山西大学获得学士学位, 2010 年于山西大学获得硕士学位, 2013 年于山西大学获得博士学位, 现为重庆邮电大学副教授, 主要研究方向为惯性器件信号处理。

E-mail: dike@cqupt.edu.cn

Di Ke received his B. Sc. degree from Shanxi University in 2007, M. Sc. degree from Shanxi University in 2010 and Ph. D. degree from Shanxi University in 2013, respectively. Now he is an associate professor in Chongqing University of Posts and Telecommunications. His main research interest includes signal processing of inertia device.