

DOI:10.19651/j.cnki.emt.2212076

基于平滑滤波的多传感器异步融合方法研究^{*}

刘云平¹ 范嘉宇¹ 苏东彦² 马 悅¹ 尹泽凡¹

(1.南京信息工程大学自动化学院 南京 210044; 2.常州大学怀德学院 靖江 214500)

摘要:无人巴士在定位循迹过程中,采样信号受噪声方差、带宽和采样率的影响,易出现信号缺失或间断现象,加之相关滤波算法缺乏异步采样和平滑能力,导致定位失败。为了提高定位精度并补充缺失数据,本文基于异步扩展卡尔曼滤波和非因果滤波平滑,提出一种改进的传感器异步采样融合平滑算法。首先利用异步扩展卡尔曼滤波对连续时间随机微分方程进行指数离散化,以处理任意时刻的测量值,预测更新下一时刻状态值之后,引入非因果滤波平滑给定可用的初始方差信息,使噪声方差影响更小,估计性能更好。将本算法在无人巴士上进行物理实验验证,结果表明这种多传感器异步融合平滑算法在车辆行驶中效果良好,与异步卡尔曼滤波算法结果相比,可以达到优于0.5 m的定位精度,数据预测误差均有明显降低,提高了定位精度和补充缺失数据。

关键词:异步采样;扩展卡尔曼滤波器;平滑滤波;传感器融合

中图分类号:TP249 文献标识码:A 国家标准学科分类代码:510.99

Research on asynchronous multi-sensor fusion location method based on smooth filtering

Liu Yunping¹ Fan Jiayu¹ Su Dongyan² Ma Yue¹ Yin Zefan¹(1. School of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China;
2. Changzhou University Huaide College, Jingjiang 214500, China)

Abstract: In the process of location and tracking of unmanned bus, the sampling signal is affected by noise variance, bandwidth and sampling rate, which is prone to signal loss or discontinuity. In addition, the related filtering algorithm lacks asynchronous sampling and smoothing capabilities, leading to location failure. In order to improve the positioning accuracy and supplement missing data, this paper proposes an improved sensor asynchronous sampling fusion smoothing algorithm based on asynchronous extended Kalman filtering and non causal filtering smoothing. First, asynchronous extended Kalman filter is used to exponentially discretize the continuous time stochastic differential equation to process the measured value at any time. After the state value at the next time is predicted and updated, the non causal filter is introduced to smooth the given available initial variance information, so that the noise variance impact is smaller and the estimation performance is better. The algorithm is verified by physical experiments on an unmanned bus. The results show that this multi-sensor asynchronous fusion smoothing algorithm has a good effect in vehicle driving. Compared with the results of asynchronous Kalman filtering algorithm, it can achieve a positioning accuracy better than 0.5 m. The data prediction error is significantly reduced, and the positioning accuracy is improved and missing data is supplemented.

Keywords: asynchronous sampling; extended Kalman filter; smooth filtering; sensor fusion

0 引言

在自动驾驶领域中,获取定位信息对传感器稳定性要求较高,单一传感器存在着定位精度低和数据易丢失的问题,无法满足系统需求。针对上述问题,融合惯性测量单元

(inertial measurement unit, IMU)、全球定位系统(global positioning system, GPS)与控制器局域网络(controller area network, CAN)中的数据,进而获得准确定位信息的手段开始得到应用。

在自动驾驶车辆的运动估计中,研究者往往基于扩展

收稿日期:2022-11-14

*基金项目:国家自然科学基金(51875293)、江苏省研究生实践创新项目(SJCX22_0358)资助

卡尔曼滤波(extended Kalman filter, EKF)融合异步传感器中的经纬度、线速度、加速度和角速度等信息来预测车辆的位置和状态^[1-3]。付心如等^[4]将 GPS 和 IMU 进行数据融合,提出一种非线性化误差模型,通过构建自适应因子来改进 EKF,提高了系统稳定性;杨菊花等^[5]提出加入滑模观测器的 EKF 融合导航算法,相比于传统 EKF 融合,有效降低定位误差;张勇等^[6]在融合 INS/GPS 中比较了卡尔曼滤波和 EKF,结果表明,EKF 定位效果更佳;Weon 等^[7]提出了一种先将 GPS 和 IMU 进行坐标校正,然后利用 EKF 融合激光雷达、GPS 和 IMU 数据,来提高自动驾驶定位导航精度的方法;Pua 等^[8]提出一种使用 EKF 和概率映射的方法,融合异步传感器数据,使移动机器人定位具有更强的抗干扰能力。但在实际应用过程中,上述方法都没有考虑到采样频率误差,易出现采样频率不同导致采样数据丢失的问题。

本文提出了一种基于连续时间模型改进的 EKF 传感器异步采样融合平滑算法,通过对任意时刻的信号进行预测重建,获得高精度定位信息,同时补全缺失数据使运动轨迹更加平滑。在无人巴士上进行物理实验验证的结果表明,即使 GPS 样本损失很大,本文提出的算法在行驶中也能实时预测更新定位信息,精度和缺失数据的补充效果也有所提高。

1 扩展卡尔曼滤波原理

非线性离散时间系统状态估计的最常见技术之一是 EKF^[9-10],其基本思想是将非线性系统线性化,然后进行卡尔曼滤波,因此其是一种次优滤波。在此基础上,利用状态估计进行改进,通过融合异步传感器的冗余信息,出现了 UKF^[11-12]和容积卡尔曼滤波器(cubature Kalman filter, CKF)^[13-14]。EKF 对非线性函数的泰勒展开式进行一阶线性化截断,忽略其余高阶项,将卡尔曼线性滤波算法应用于非线性系统中,从而转化为线性问题。

EKF 基本底层模型的非线性随机动态系统和输出方程如式(1)和(2)所示:

$$\dot{x} = f(x, \varepsilon_w) \quad (1)$$

$$y = h(x) + \varepsilon_v \quad (2)$$

式中: $x \in R^{n_x}$ 是系统状态, $y \in R^{n_y}$ 是测量值向量; ε_w 是具有高斯过程功率谱密度的连续时间噪声; ε_v 是采样时刻的有限方差离散时间噪声。

假设传感器的动态速度比信号测量速度快,采样时刻为有限方差离散时间噪声,非线性函数 $f(x, \varepsilon_w): R^{n_x} \rightarrow R^{n_x}$ 和 $h(x): R^{n_x} \rightarrow R^{n_y}$, 分别描述系统动态和输出非线性方程。给定线性化点的线性化方程如式(3)和(4)所示:

$$\dot{x} \approx A_c x + B_c \varepsilon_w \quad (3)$$

$$y \approx Hx + \varepsilon_v \quad (4)$$

式中: A_c 、 B_c 、 H 分别是状态 x 、过程噪声 w 和输出测量 y

的雅可比矩阵,计算公式如下:

$$A_c = \frac{\partial f(x, \varepsilon_w)}{\partial x} \quad (5)$$

$$B_c = \frac{\partial f(x, \varepsilon_w)}{\partial \varepsilon_w} \quad (6)$$

$$H = \frac{\partial h(x)}{\partial x} \quad (7)$$

2 改进的多传感器异步融合平滑算法

本文将异步扩展卡尔曼滤波(asynchronous extended Kalman filter, AEKF)和离散非因果滤波(rauch tung striebel smoother, RTSS)结合,提出一种改进的 EKF 传感器异步采样融合平滑算法。主要分为两个阶段:第 1 阶段,基于 EKF 进行连续时间预测和离散数据更新。由于数据是异步测量的,并且 EKF 需要整合一段时间内的状态预测值,直到有新的测量数据为止;第 2 阶段,为了更好的估计 AEKF 状态轨迹,用 RTSS^[15-16]提供未来时刻的状态估计,使轨迹更加平滑。

2.1 多传感器异步融合算法

IMU 采样频率是 100 Hz,GPS 采样频率约为 1 Hz,在 SAE J1939 CAN 总线协议中,每条消息都有自己的范围传输速率,但每个组的优先级可能会改变采样频率。从高优先级节点到低优先级节点,采样频率从 10 ms~1 s 不等。

测量可得以下信息:三元组组成的数据集: $\{(yt1, s1, t1), (yt2, s2, t2), \dots\}$, 三元组分别是传感器测量值、传感器型号和获取测量值时的时间戳。

测量多个不同传感器,得到不同时间戳的传感器数据,假如在某一时刻没有进行测量,这一时刻将成为状态预测的标志点。

由上述连续时间线性随机过程,可以得到时变离散化方程,对于一个给定状态 \hat{x}_t 、噪声 ε_w 和多传感器中获得采样数据时间戳之差采样间隔 δ_t ,近似配对离散状态方程 ψ 如下:

$$\hat{x}_t + \delta_t = \psi \quad (8)$$

$$\psi = [\psi_1 \ \psi_2]^T = e^{\begin{bmatrix} A_c & I \\ 0 & 0 \end{bmatrix} \delta_t} \cdot \begin{bmatrix} \hat{x}_t \\ f(\hat{x}_t, \varepsilon_w) - A_c \hat{x}_t \end{bmatrix} \quad (9)$$

$$\tilde{x}_t = \psi_1 \quad (10)$$

式中: \tilde{x}_t 是离散方程的给定状态。协方差状态的离散化基于相同的指数思想,协方差状态离散方程 ϕ 如式(11)所示:

$$\phi = \begin{bmatrix} \phi_{11} & \phi_{12} \\ 0 & \phi_{22} \end{bmatrix} = e^{\begin{bmatrix} A_c^T & B_c Q_c B_c^T \\ 0 & A_c \end{bmatrix} \delta_t} \quad (11)$$

$$\begin{cases} A_t = \phi_{22} \\ Q_t = \phi_{22}^T \phi_{12} \end{cases} \quad (12)$$

式中: A_c 、 B_c 分别是状态 x 、过程噪声 w 的雅可比矩阵, Q_c

是过程噪声, \mathbf{Q}_t 是协方差矩阵。

进一步, 可以得出数据异步融合的预测误差 $\tilde{\mathbf{P}}_t$ 如式(13)所示:

$$\tilde{\mathbf{P}}_t = \mathbf{A}_t \mathbf{P}_t \mathbf{A}_t^T + \mathbf{Q}_t \quad (13)$$

式中: P_t 是各种传感器的编号。

进一步, 传感器期望值的雅可比矩阵 \mathbf{H}_t^s 如式(14)所示:

$$\mathbf{H}_t^s = \frac{\partial h^s(x)}{\partial x} \mid x = \tilde{x}_t \quad (14)$$

式中: $h^s(x)$ 是各种传感器给出的测量值的数学期望。因此, 求得 EKF 增益 K_t , 预测状态 \hat{x}_t 和预测误差 $\tilde{\mathbf{P}}_t$ 如式(15)、(16)所示:

$$K_t = \tilde{\mathbf{P}}_t (\mathbf{H}_t^s)^T (\mathbf{H}_t^s \tilde{\mathbf{P}}_t (\mathbf{H}_t^s)^T + R^s)^{-1} \quad (15)$$

$$\hat{x}_t = \tilde{x}_t + K_t (y_t - h_t^s) \quad (16)$$

$$\tilde{\mathbf{P}}_t = (I - K_t \mathbf{H}_t^s) \mathbf{P}_t$$

2.2 融合平滑算法

在离散状态, 定义输出测量的雅可比矩阵为 \mathbf{T}_t , 则得到新的时间截 δt 如式(17)所示:

$$\delta t = \mathbf{T}_{i+1} t - \mathbf{T}_i t \quad (17)$$

进一步, 得到新的 EKF 增益 L_t , 异步多传感器融合平滑算法的状态估计 \hat{z}_t 如式(18)所示:

$$L_t = (\mathbf{T}_i P_t) (\mathbf{T}_{i+1} A_t)^T (\mathbf{T}_{i+1} \tilde{\mathbf{P}}_t)^{-1} \quad (18)$$

$$\hat{z}_t = \mathbf{T}_i \hat{x}_t + L_t (\hat{z}_t - \mathbf{T}_{i+1} \hat{x}_t)$$

2.3 算法应用

目前, 无人驾驶领域的商业化应用以无人巴士为主, 主要基于 GPS、IMU 和 CAN 测量^[17-18] 经纬度、线速度、角速度、加速度等车载传感数据, 进而获得车辆定位与状态信息。

根据车辆 CAN 网关协议的前轮速度测量值进行估算, 采用阿克曼转向几何结构^[19]。阿克曼机械配置意味着车辆的前轮以不同的速度转动, 以画出不同半径的圆。

在这种配置中, 其方向 ϕ_w 称为阿克曼角, 是前轮的平均角度, 可使用式(19)计算:

$$\phi_w = 0.5 \arcsin \frac{4L(v_R - v_L)}{W(v_R + v_L)} \quad (19)$$

式中: L 是前后轴之间的距离, W 是左右车轮之间的间距, v_R 和 v_L 分别是左右车轮的速度。定义方向盘方向为 ρ^s , 则利用方向盘角度和阿克曼角度(前轮平均方向)之间的比率, 计算 $\rho^s = f_s \phi_w$, 其中根据车辆参数定义无人巴士的转向系数 $f_s = 17$ 。最后, 车辆的角速度从 CAN 总线获得, 使用以下方程式计算线速度 v 和车轮方向 ϕ_w 。

$$\omega^{CAN} = \frac{v \tan \phi_w}{L} \quad (20)$$

式中: v^{CAN} 是 CAN 总线的线速度, $\{p_x^{GPS}, p_y^{GPS}\}$ 是 GPS 读取的笛卡尔位置。

为了估计车辆在平面内的运动学, 定义状态向量 x 为:

$$x = [p_x \ p_y \ \theta \ \omega \ v \ a \ o_{\omega}^{IMU} \ o_a^{IMU} \ o_{\omega}^{CAN}]^T \quad (21)$$

式中: p_x 和 p_y 是车辆的位置, θ 是航向或方位, ω 是角速度, v 是线速度, a 是加速度, o_{ω}^{IMU} 是 IMU 角速度偏移量, o_a^{IMU} 是 IMU 速度偏移量, o_{ω}^{CAN} 是 CAN 角速度偏移量。

进一步, 输出矢量 y 将被定义为:

$$y = [p_x^{GPS} \ p_y^{GPS} \ \theta^{IMU} \ \omega^{IMU} \ a^{IMU} \ \omega^{CAN} \ v^{CAN} \ a^{CAN}]^T \quad (22)$$

式中: p_x^{GPS} 和 p_y^{GPS} 是 GPS 测量的车辆位置, θ^{IMU} 是 IMU 测量的方位角, ω^{IMU} 是 IMU 测量角速度, a^{IMU} 是 IMU 测量加速度, ω^{CAN} 是 CAN 总线的角速度, v^{CAN} 是 CAN 总线线速度, a^{CAN} 是 CAN 总线加速度。

另一方面, 假设过程噪声为:

$$\boldsymbol{\epsilon}_w = [\epsilon_{p_x} \ \epsilon_{p_y} \ \epsilon_{\omega} \ \epsilon_a \ \epsilon_{\omega}^{IMU} \ \epsilon_{a_o}^{IMU} \ \epsilon_{\omega_o}^{CAN}]^T \quad (23)$$

式中: ϵ_{p_x} 、 ϵ_{p_y} 是车辆位置偏差, ϵ_{ω} 是角速度偏差, ϵ_a 是加速度偏差, ϵ_{ω}^{IMU} 是 IMU 角速度偏差, $\epsilon_{a_o}^{IMU}$ 是加速度偏差, $\epsilon_{\omega_o}^{CAN}$ 是 CAN 总线角速度偏差。

而测量噪声矢量为:

$$\boldsymbol{\epsilon}_v = [\epsilon_{p_x}^{GPS} \ \epsilon_{p_y}^{GPS} \ \epsilon_{\theta}^{IMU} \ \epsilon_{\omega}^{IMU} \ \epsilon_a^{IMU} \ \epsilon_{\omega}^{CAN} \ \epsilon_v^{CAN} \ \epsilon_a^{CAN}]^T \quad (24)$$

式中: $\epsilon_{p_x}^{GPS}$ 、 $\epsilon_{p_y}^{GPS}$ 是 GPS 位置测量偏差, ϵ_{θ}^{IMU} 是 IMU 测量方位角偏差, ϵ_{ω}^{IMU} 是角速度偏差, ϵ_a^{IMU} 是加速度偏差, ϵ_{ω}^{CAN} 是 CAN 总线测量角速度偏差, ϵ_v^{CAN} 是速度偏差, ϵ_a^{CAN} 是角速度偏差。

结果得到输出方程描述如式(25)所示:

$$\dot{x} = f(x, \boldsymbol{\epsilon}_w) = \begin{bmatrix} v \cos(\theta) \\ v \sin(\theta) \\ \omega \\ 0 \\ 0 \\ a \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} + \mathbf{B}_e \boldsymbol{\epsilon}_w \quad (25)$$

$$y = h(x, \boldsymbol{\epsilon}_v) = \mathbf{H}x + \boldsymbol{\epsilon}_v \quad (26)$$

式中: 对于一个给定状态 x_t , 噪声 $\boldsymbol{\epsilon}_w$, 采样间隔 δ_t , 过程噪声雅可比矩阵 \mathbf{B}_e , 输出测量雅可比矩阵 \mathbf{H} 和状态方程雅可比矩阵 \mathbf{A}_e 可表示为:

$$\mathbf{A}_e = \frac{\partial f(x, \boldsymbol{\epsilon}_w)}{\partial x} \mid x = x_t, \boldsymbol{\epsilon}_w = 0 \quad (27)$$

$$\mathbf{B}_e = \frac{\partial f(x, \boldsymbol{\epsilon}_w)}{\partial \boldsymbol{\epsilon}_w} \mid x = x_t, \boldsymbol{\epsilon}_w = 0 \quad (28)$$

$$\mathbf{H} = \frac{\partial h(x, \boldsymbol{\epsilon}_v)}{\partial x} \mid x = x_t \quad (29)$$

$$\mathbf{A}_c = \begin{bmatrix} 0 & 0 & -v\sin(\theta) & 0 & \cos(\theta) & 0 & 0 & 0 & 0 \\ 0 & 0 & v\cos(\theta) & 0 & \sin(\theta) & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (30)$$

$$\mathbf{B}_c = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \quad (31)$$

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \end{bmatrix} \quad (32)$$

3 实验验证

3.1 实验方案

为了验证本文提出的多传感器异步融合平滑算法在无人驾驶定位精度和缺失数据预测上的有效性, 在无人巴士上设计了相关实验进行验证。

实验采用的无人巴士运动学规格为: 车辆轴间距 $L=2875$ mm, 车轮轨道宽度 $W=1750$ mm。为了测量无人巴

士的经纬度、速度、角速度和线加速度等运动学变量, 在车辆旋转中心安装有 GPS/IMU 一体化测量单元。测量单元包括: 三轴磁力计(全量程 8 高斯, 均方根噪声 0.5 Pa)、三轴陀螺仪(全量程 450 欧/s, 偏置误差 0.2 欧/s)、三轴加速度计(全量程 200 m/s, 偏差 0.05 m/s)、气压计(全量程 30~110 kPa, 均方根噪声 3.6 Pa)和 GPS, 水平精度为 1 m(笛卡尔坐标 x/y), 垂直精度为 2 m(z 坐标)。实验环境的软硬件配置如表 1、图 1 所示。

表 1 软硬件环境

软硬件	版本与型号
CPU	6-core NVIDIA Carmel ARM® v8.2 64 bit CPU 6MB L2+4MB L3
编程语言	C/C++
开发环境	VS Code
无人巴士线控底盘	南京金龙智慧小巴
工控机	TW-T506
惯性测量单元	星网宇达 XW-GI5610
卫导天线	北斗 AIS 卫导

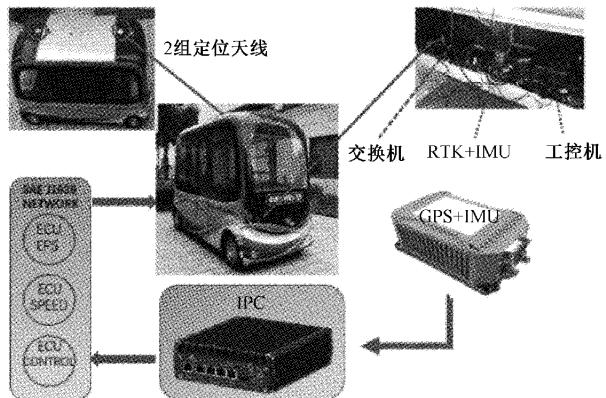


图 1 实物连接总体框图

首先, 分别从 GPS、IMU 和 CAN 总线内采集经纬度坐标、速度、加速度和角速度信息, 并利用本文提出的算法进行距离解算, 最后完成导航任务。实验总体流程如图 2 所示。

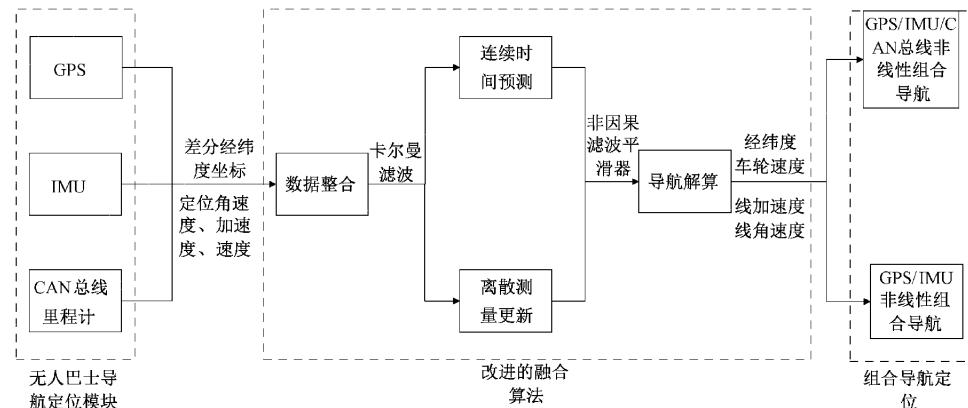


图 2 实验总体流程

3.2 融合高精度定位验证

本次实验模拟车辆日常情况比如直行、转角等;整体行迹 2 000 m, 经历 4 次转角, 数据记录的工作时间是 400 s。无人巴士园区内整体行迹如图 3 所示。

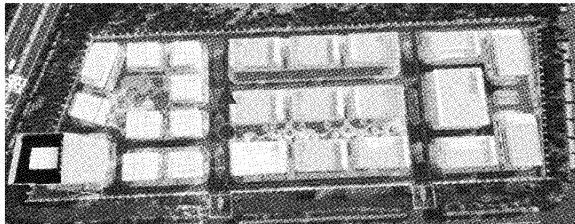


图 3 无人巴士整体航行轨迹

图 3、4 所示,在相同路段,保持运行速度不变,在单位时间内分别对 AEKF 定位数据和固定区间平滑算法(recursion time smoother, RTS)定位数据和改进的融合法定位数据进行经度、纬度以及经纬度定位对比,图 4(a)表示在单位时间内 AEKF 数据、RTS 算法和改进的融合法定位数据进行经度变化效果,随着时间推移,AEKF 数据偏移,而改进的融合法定位数据与 RTS 算法相比更具备线性特征;

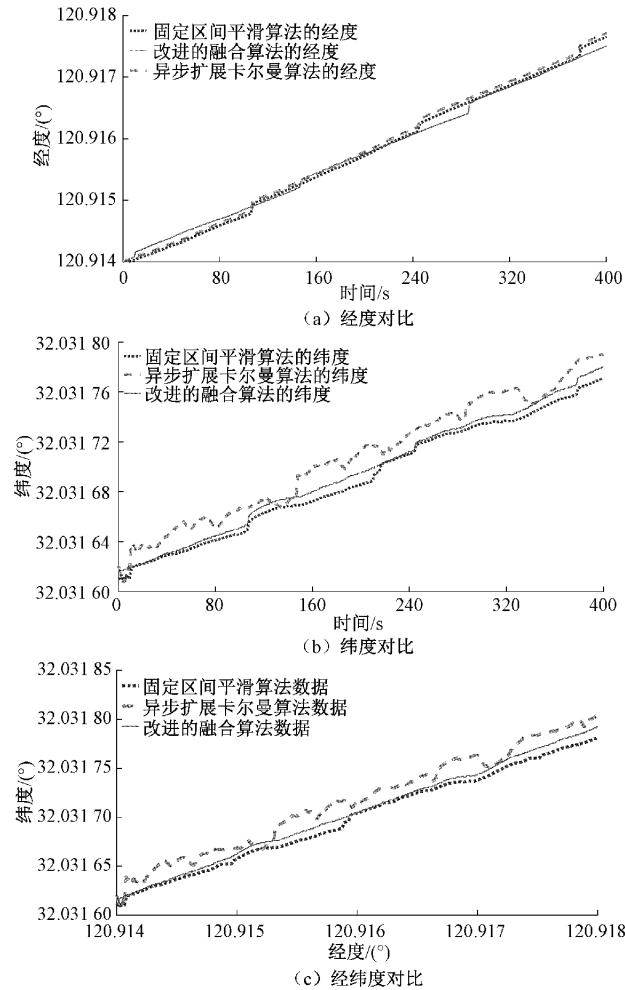


图 4 定位数据对比

图 4(b)表示单位时间内 AEKF 数据和改进的融合法定位数据纬度变化效果,从图中可以看出,随着时间推移,AEKF 数据震荡持续到结束,RTS 算法产生一定程度的偏移,而改进的融合法定位数据具有线性特征;图 4(c)表示在相同经度情况下,纬度的变化,AEKF 数据震荡,改进的融合法定位数据稳定,定位精度最高。

轨迹定位点通过坐标转换,可以将经纬度坐标转化为车体坐标系,即 x 轴对应车头左右方向, y 轴对应车头前后方向,表 2 为改进的融合算法、RTS 算法和 AEKF 算法的 2D 定位误差各项指标。

表 2 定位结果误差对比

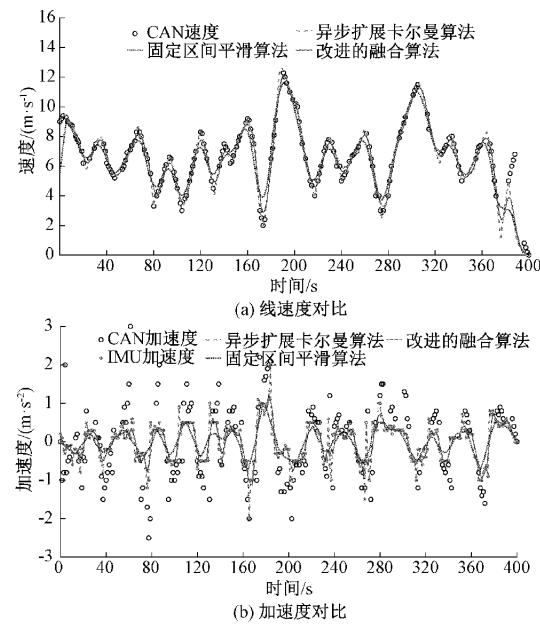
算法	max	mse	media	rmse	std
改进的融合算法	0.472	0.188	0.165	0.433	0.092
固定区间平滑算法	0.503	0.212	0.223	0.460	0.103
异步扩展卡尔曼	0.515	0.298	0.294	0.545	0.124

表 2 中 max 表示定位误差最大值,反映车辆定位精度的鲁棒性;mse、media 和 rmse 分别表示误差均值、中位数和均方根,这 3 类误差反映定位精度。std 表示标准误差,反映定位的稳定性。从表 2 可以看出,改进的融合算法能更好的获得定位结果,且最大误差保持在 0.5 m 以内,满足无人巴士的定位需求。

3.3 缺失数据预测验证

1) 车辆行驶阶段改进的融合算法预测、RTS 算法预测、AEKF 预测和单一传感器测量对比

为了验证补全缺失数据效果,实验模拟车辆日常情况比如直行、转角等;整体行迹 2 000 m,整体过程持续时间 400 s,期间无人巴士行驶的线速度、加速度和角速度的改进的融合算法预测、RTS 算法预测、AEKF 算法预测和单一传感器测量对比如图 5 所示。



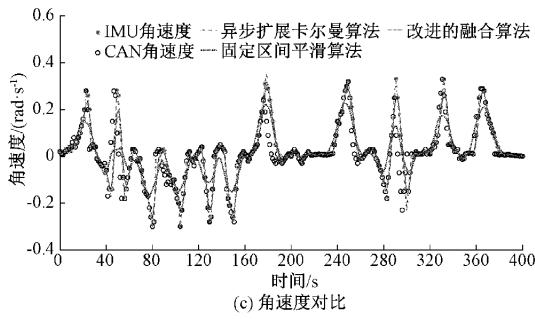


图 5 运动学变量对比

图 5(a)表示改进的融合算法预测、RTS 算法预测、AEKF 算法预测和 CAN 总线速度对比效果;图 5(b)表示改进的融合算法预测、RTS 算法预测、AEKF 算法预测、CAN 总线加速度和 IMU 的加速度对比效果;图 5(c)表示改进的融合算法、RTS 算法预测、AEKF 算法预测、CAN 总线角速度和 IMU 角速度对比效果。CAN 总线数据中线速度有效降低了车辆性能估计误差,而 CAN 总线加速度

由于数据不连续和跳跃存在比较大的误差,来自 CAN 总线的角速度具有恒定的误差。IMU 测量的加速度和角速度在一段时间后有很高的误差。单一传感器数据离散,数据时常缺失,改进的融合算法比 AEKF 算法和 RTS 算法更好改善估计,补偿误差。

无人巴士行驶阶段实验中 AEKF 算法、RTS 算法和改进的融合算法相应的误差如表 3 所示。其中,mse 表示误差均值,media 表示误差中位数,这两者反映预测结果的准确性;std 表示标准误差,反映预测结果稳定性。AEKF 算法的角速度、速度、加速度误差均值分别为 0.052 2、0.423 2 和 0.285 4;RTS 算法的角速度、速度、加速度误差均值分别为 0.047 6、0.368 2 和 0.133 4;改进的融合算法的角速度、速度、加速度误差均值分别为 0.043 5、0.332 2 和 0.086 1。从预测结果的误差均值和误差中位数中得出,改进的融合算法预测精度优于 AEKF 算法和 RTS 算法;从标准误差中得出,改进的融合算法预测稳定性优于 AEKF 算法和 RTS 算法。

表 3 行驶阶段预测数据结果误差对比

参数	异步扩展卡尔曼算法			改进的融合算法			固定区间平滑算法		
	有 CAN 总线数据			有 CAN 总线数据			有 CAN 总线数据		
	mse	media	std	mse	media	std	mse	media	std
角速度/(rad·s ⁻¹)	0.052 2	0.050 4	0.037 4	0.043 5	0.045 4	0.023 1	0.047 6	0.047 3	0.027 8
速度/(m·s ⁻¹)	0.423 2	0.357 2	0.207 5	0.332 2	0.320 2	0.151 4	0.368 2	0.355 0	0.178 4
加速度/(m·s ⁻²)	0.285 4	0.273 3	0.117 4	0.086 1	0.061 5	0.040 3	0.133 4	0.126 5	0.076 3

2) 车辆制动阶段改进的融合算法与 RTS、AEKF 对比

当车辆处于制动阶段时,测量误差估计以恒定的速度从数据集中得到。给定平滑情况下可用的额外非因果信息,改进的融合算法性能对于实际过程噪声方差参数设置影响比 AEKF 和 RTS 小。

如图 6(c)所示,当车辆制动时,所提出的改进的融合算法估计没有停止,如果不使用 CAN 数据,改进的融合算法估计车辆处于停止状态大约需要 40 s。如图 6(a)、(b)所示,在没有 CAN 数据的情况下,AEKF 算法会偏移到负速度,RTS 算法也会延迟制动,然而使用 CAN 数据的改进融合算法估计要精确得多,这些 CAN 总线速度减少了 AEKF 和 RTS 偏移。

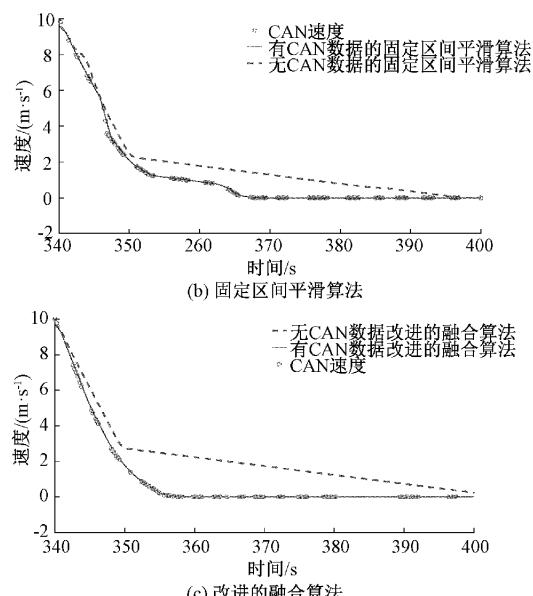
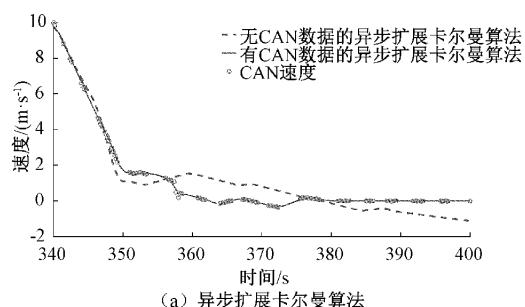


图 6 AEKF 算法、RTS 算法和改进的融合算法对比图

数据融合算法将来自 GPS、IMU 和 CAN 总线的不同采样率的异步信号相结合。可以看出,3 种数据采样速率明显不规则,改进的融合算法能够正确估计线速度、加速度和角速度,同时角速度噪声大大降低,并且所有传感器

偏差都能够得到补偿。

从图 7 看出, CAN 总线数据的角速度偏移量为 -0.003 rad/s 。偏差值很低, 偏差会累积起来, 并且在几秒钟内, 偏差会非常高, 这些偏移量通过传感器融合进行补偿。

AEKF 算法、RTS 算法和改进的融合算法各种数据统计误差如表 4、5 所示。

从表 4、5 看出, 无人巴士制动过程中, CAN 总线数据确实显著降低了速度误差、角速度偏移量误差, 改进的融

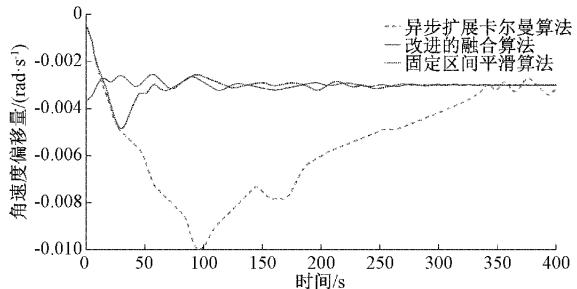


图 7 角速度偏移量

表 4 制动阶段有 CAN 总线数据预测数据结果误差对比

参数	异步扩展卡尔曼算法			改进的融合算法			固定区间平滑算法		
	有 CAN 总线数据			有 CAN 总线数据			有 CAN 总线数据		
	mse	media	std	mse	media	std	mse	media	std
速度/(m·s⁻¹)	0.412	0.406	0.209	0.286	0.236	0.114	0.308	0.306	0.154
角速度偏移量/(rad·s⁻¹)	0.019	0.014	0.006	0.004	0.003	0.002	0.007	0.009	0.004

表 5 制动阶段无 CAN 总线数据预测数据结果误差对比

参数	异步扩展卡尔曼算法			改进的融合算法			固定区间平滑算法		
	无 CAN 总线数据			无 CAN 总线数据			无 CAN 总线数据		
	mse	media	std	mse	media	std	mse	media	std
速度/(m·s⁻¹)	0.443	0.432	0.272	0.330	0.268	0.123	0.368	0.332	0.168
角速度偏移量/(rad·s⁻¹)	0.020	0.018	0.007	0.007	0.006	0.003	0.013	0.011	0.005

合算法相比于 AEKF 算法和 RTS 算法, 各部分数据的误差均值、误差中位数和标准误差较低, 预测性能更优。

4 结 论

本文中提出了一种改进的 EKF 传感器异步采样融合平滑算法, 将自动驾驶领域中来自 IMU、GPS 和基于 CAN 里程计的数据以任意采样率融合。在无人巴士上的实验结果表明: 由于 CAN 信息可以提供更精确的经纬度、线速度、加速度和角速度数据, 因此 3 个数据源的融合有利于在缺失数据情况下估计无人巴士行驶状态。此外, 改进的融合算法在实际过程噪声方差参数设置的影响度低于 AEKF 和 RTS 算法, 允许信号在任意时间点重建, 对均值和方差使用指数矩阵实现自适应离散化。该方法允许融合来自全球定位系统 GPS、IMU 和 CAN 总线数据, 可以使定位误差低于 0.5 m , 极大的降低估计误差, 提高定位精度和补充缺失数据。

参考文献

- [1] CHIANG K W, TSAI G J, CHU H J, et al. Performance enhancement of INS/GNSS/Refreshed-SLAM integration for acceptable lane-level navigation accuracy [J]. IEEE Transactions on Vehicular Technology, 2020, 69(3): 2463-2476.
- [2] HU J, WU Z, QIN X, et al. An extended Kalman

filter and back propagation neural network algorithm positioning method based on anti-lock brake sensor and global navigation satellite system information [J]. Sensors, 2018, 18(9): 2753.

- [3] ESFANDIARI H, MIRROKNI V, ZHONG P. Almost linear time density level set estimation via dbscan[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(8): 7349-7357.
- [4] 付心如, 徐爱功, 孙伟. 抗差自适应 UKF 的 INS/GNSS 组合导航算法[J]. 导航定位学报, 2017, 5(2): 111-116.
- [5] 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.
- [6] 张勇, 姜鑫蕾, 杨文武, 等. 基于卡尔曼滤波的 GNSS 系统联合定位技术研究[J]. 电子测量技术, 2021, 44(3): 109-103.
- [7] WEON I S, LEE S G. Environment recognition based on multi-sensor fusion for autonomous driving vehicles [J]. Journal of Institute of Control, Robotics and Systems, 2019, 25(2): 125-131.
- [8] PUA M T, YAMAMOTO Y. Integration of look-ahead control and multi-sensor fusion capability for an autonomous mobile robot under outdoor environment[C].

- The Japan Society of Mechanical Engineers, 2019, 1P1-R09.
- [9] MENG X, WANG H, LIU B. A robust vehicle localization approach based on GNSS/IMU/DMI/Lidar sensor fusion for autonomous vehicles [J]. Sensors, 2017, 17(9): 2140.
- [10] ARROSPIDE LABORDA J, SALGADO ÁLVAREZ DESOTOMAYOR L, NIETO DONCEL M, et al. On-board robust multiple vehicle detection and tracking using adaptive quality evaluation [C]. IEEE International Conference on Image Processing. IEEE, 2008, DOI:10.1109/ICIP.2008.4712178.
- [11] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [12] ZHANG W, WANG Z, ZOU C, et al. Advanced vehicle state monitoring: Evaluating moving horizon estimators and unscented Kalman filter [J]. IEEE Transactions on Vehicular Technology, 2019, 68(6): 5430-5442.
- [13] MAGNUS J R, PIJLS H G J, SENTANA E. The Jacobian of the exponential function [J]. Journal of Economic Dynamics and Control, 2021, 127(1): 104-122.
- [14] HONG DE D, SHAO WU D, YUAN CAI C, et al. Performance comparison of EKF/UKF/CKF for the tracking of ballistic target [J]. TELKOMNIKA Indonesian Journal of Electrical Engineering, 2012, 10(7): 1692-1699.
- [15] PAN D, LIU H, QU D, et al. Human falling detection algorithm based on multisensor data fusion with SVM [J]. Mobile Information Systems, 2020, 49(3): 2020.
- [16] ARMESTO L, GIRBES V, SALA A, et al. Duality-based nonlinear quadratic control: Application to mobile robot trajectory-following [J]. IEEE Transactions on Control Systems Technology, 2015, 23(4): 1494-1504.
- [17] JEONG Y N, SON S R, JEONG E H, et al. An integrated self-diagnosis system for an autonomous vehicle based on an IoT gateway and deep learning [J]. Applied Sciences, 2018, 8(7): 1164.
- [18] GIRBÉS-JUAN V, ARMESTO L, HERNÁNDEZ-FERRÁNDIZ D, et al. Asynchronous sensor fusion of GPS, IMU and CAN-based odometry for heavy-duty vehicles [J]. IEEE Transactions on Vehicular Technology, 2021, 70(9): 8617-8626.
- [19] BRUZZONE L, BAGGETTA M, NODEHI S E, et al. Functional design of a hybrid leg-wheel-track ground mobile robot [J]. Machines, 2021, 9(1): 10.

作者简介

刘云平,博士,教授,主要研究方向为智能机器人、集群无人系统、智能仪器与装备。
E-mail:1477422021@qq.com