

# 控制与决策

Control and Decision

## 基于InEKF和深度学习的车辆定位研究

郭戈, 林皓栋, 刘佳庚, 李增勃

引用本文:

郭戈, 林皓栋, 刘佳庚, 等. 基于InEKF和深度学习的车辆定位研究[J]. *控制与决策*, 2024, 39(12): 4037-4044.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.1570>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### [基于MobileNet的多目标跟踪深度学习算法](#)

Deep learning algorithm based on MobileNet for multi-target tracking

*控制与决策*. 2021, 36(8): 1991-1996 <https://doi.org/10.13195/j.kzyjc.2019.1424>

#### [基于转换量测容积卡尔曼滤波器带多普勒量测的目标跟踪算法](#)

Converted measurement cubature Kalman filter for Doppler-assisted target tracking

*控制与决策*. 2021, 36(6): 1425-1434 <https://doi.org/10.13195/j.kzyjc.2019.1070>

#### [基于MCPDDPG的智能车辆路径规划方法及应用](#)

The method and application of intelligent vehicle path planning based on MCPDDPG

*控制与决策*. 2021, 36(4): 835-846 <https://doi.org/10.13195/j.kzyjc.2019.0460>

#### [多目标小尺度车辆目标检测方法](#)

Multi-target and small-scale vehicle target detection method

*控制与决策*. 2021, 36(11): 2707-2712 <https://doi.org/10.13195/j.kzyjc.2020.0635>

#### [基于改进堆叠自动编码器的循环冷却水系统工艺介质温度预测控制方法](#)

Predictive control method of process medium temperature in circulating cooling water system based on improved stacked auto encoders

*控制与决策*. 2020, 35(12): 2835-2844 <https://doi.org/10.13195/j.kzyjc.2019.0694>

# 基于 InEKF 和深度学习的车辆定位研究

郭戈<sup>1,3†</sup>, 林皓栋<sup>2</sup>, 刘佳庚<sup>2</sup>, 李增勃<sup>2</sup>

- 东北大学 流程工业综合自动化国家重点实验室, 沈阳 110819;
- 东北大学 信息科学与工程学院, 沈阳 110819;
- 东北大学秦皇岛分校 控制工程学院, 河北 秦皇岛 066004)

**摘要:** 研究一种利用不变拓展卡尔曼滤波器 (invariant extended Kalman filter, InEKF) 和深度学习的车辆定位方案. 首先, 通过引入轮速计测量模型, 构建基于自编码器的深度神经网络, 并重构车辆速度真值; 然后, 基于 InEKF 推导以 SE(3) 为状态量的滤波算法, 使用该算法融合多源信息以估计车辆位置. 实验结果表明, 与现有先进方法相比, 所提出车辆定位系统可在城市环境下显著提高定位精度.

**关键词:** 车辆定位; 多源融合; 深度学习; 轮速计模型

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.1570

引用格式: 郭戈, 林皓栋, 刘佳庚, 等. 基于 InEKF 和深度学习的车辆定位研究 [J]. 控制与决策, 2024, 39(12): 4037-4044.

## Research on vehicle localization based on InEKF and deep learning

GUO Ge<sup>1,3†</sup>, LIN Hao-dong<sup>2</sup>, LIU Jia-geng<sup>2</sup>, LI Zeng-bo<sup>2</sup>

- State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110819, China;
- College of Information Science and Engineering, Northeastern University, Shenyang 110819, China;
- School of Control Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China)

**Abstract:** A vehicle positioning scheme using the invariant extended Kalman filter (InEKF) and deep learning is studied. Firstly, by introducing the wheel speedometer measurement model, a deep neural network based on autoencoder is constructed, and the true value of vehicle speed is reconstructed. Then, based on the InEKF, a filtering algorithm with SE(3) as the state quantity is derived, and the algorithm is used to fuse multi-source information to estimate the vehicle position. Experimental results show that compared with the existing advanced methods, the proposed vehicle positioning system can significantly improve the positioning accuracy in urban environment.

**Keywords:** vehicle localization; multi-source fusion; deep learning; wheel speed sensor model

## 0 引言

车辆定位对自动驾驶安全有效运行至关重要<sup>[1]</sup>. 传统的定位技术依赖于全球卫星导航系统 (global navigation satellite system, GNSS), 尤其是基于载波相位差分技术的 RTK (real-time kinematic), 可在信号稳定且连续时提供厘米级定位精度<sup>[2-4]</sup>. 但因卫星与终端设备连通性差等问题, 在城市峡谷、楼群及室内环境下易受阻塞和多径效应影响<sup>[5-6]</sup>. 为此, 出现了大量融合 GNSS 与其他传感器或网络信号的定位研究<sup>[7-10]</sup>.

通常, 这种融合采用卡尔曼滤波及其变种实

现<sup>[11]</sup>, 如拓展卡尔曼滤波 (extended Kalman filter, EKF)、无迹卡尔曼滤波 (unscented Kalman filter, UKF) 和粒子滤波 (particle filter, PF) 等. 经前期研究工作<sup>[3-6,11]</sup>发现此种贝叶斯框架下的滤波融合技术存在两个缺陷: 1) 不确定的过程噪声和测量噪声协方差矩阵造成无法建立准确的过程模型; 2) 卡尔曼滤波存在正反馈和非一致性等问题<sup>[12-13]</sup> (见图 1).

对于缺陷 1), 常用人工智能方法调整噪声协方差矩阵. 如文献 [14] 利用车辆动力学模型引入伪测量, 通过卷积神经网络实现对观测噪声参数自适应调整. 文献 [15] 设计了深度神经网络模型, 利用惯性

收稿日期: 2023-11-10; 录用日期: 2024-03-01.

基金项目: 国家自然科学基金项目 (62173079, U1808205); 2024 年河北省硕士在读研究生创新能力培养项目 (CXZZSS2024180).

责任编辑: 关新平.

† 通讯作者. E-mail: geguo@yeah.net.

\* 本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

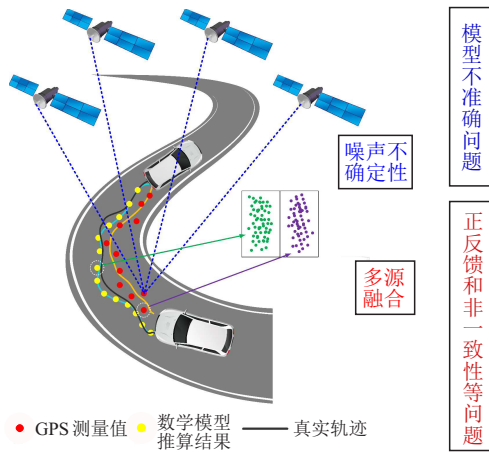


图1 基于滤波器融合技术的两个缺点

传感器检测结果调整瞬时系统噪声协方差矩阵。现有研究表明,人工智能在图像和信号降噪处理中效果显著<sup>[16-17]</sup>,但如何适应车辆定位系统降噪处理有待进一步研究。对于缺陷2),最近研究采用不变拓展卡尔曼滤波(invariant extended kalman filter, InEKF)在李群形式的状态空间中传递状态,并利用矩阵李群上的误差定义满足对数线性微分方程的特性。InEKF不依赖当前状态估计,收敛性较好且估计精度高,由Bonnabel首次提出并用于车辆定位和姿态估计<sup>[18]</sup>,Barrau<sup>[19]</sup>扩展了这项研究,并完整阐述了误差状态下InEKF及在导航领域的应用<sup>[19]</sup>,Zhang等<sup>[20]</sup>分析了SLAM中InEKF的一致性和收敛性。近年来InEKF在惯性导航中逐渐成为研究热点<sup>[21-24]</sup>。文献[21]利用InEKF融合IMU和声学多普勒速度仪,完成水下航行器导航定位。文献[24]通过将相机和IMU的语义局部地图与在线地图数据库匹配来估计车辆位置信息,并通过InEKF完成状态传递。

文献[25]综合分析了上述两种缺陷,利用深度学习削弱测量噪声影响,但忽略了雷达安装角度对速度测量产生的影响。为此,本文在前期工作基础上<sup>[4,6]</sup>,提出一种全新车辆定位框架。首先,引入轮速计测量模型,给出一种基于深度学习的速度解算方法;然后,推导并开发了基于InEKF的多源融合算法。本文主要工作如下:1)引入一种轮速计测量模型并使用深度学习方法来预测车辆前向速度;2)推导以特殊欧式群SE(3)为状态空间的InEKF,并利用其融合车辆自身运动和GNSS测量以估计车辆位置信息;3)提出一种车辆定位框架,可以以较低成本的方式给出精确定位结果。

## 1 系统框架

本文提出的定位框架由4个模块组成:传感器模块、速度预处理模块、模型模块和滤波模块(见图2)。

传感器模块包含陀螺仪、轮速计和GPS;速度预处理模块包括自编码器和中值滤波器,其中自编码器是该模块的核心;模型模块包括状态传递模型和观测模型。

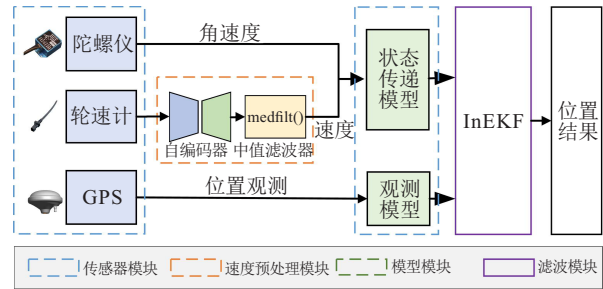


图2 基于InEKF和深度学习的车辆定位框架

陀螺仪、轮速计和GPS分别用于采集角速度、速度和位置数据;自编码器用于降低轮速计输出的原始速度噪声,中值滤波器用于排除离群值;状态传递模型用于描述车辆运动过程,观测模型用于描述GPS位置观测;滤波模块主要用于融合多源信息,并基于InEKF求解车辆状态。具体为:首先,将轮速计粗值输入到由自编码器和中值滤波器组成的神经网络,并预测速度结果;其次,利用陀螺仪提供的角速度和预测的速度建立误差状态的微分方程并将其离散化为状态传递方程;然后,考虑GNSS的位置观测和观测误差的定义建立观测方程;最后,在滤波模块中通过InEKF预测更新传递状态,输出定位结果。

## 2 系统实现

本节基于所提出的轮速计测量模型设计以自编码器为核心的神经网络,并推导特殊欧式群SE(3)状态空间的状态传递模型和观测模型,最后给出InEKF滤波过程。下文中, $\tilde{(\cdot)}$ 和 $\hat{(\cdot)}$ 分别表示量测和估计值。

### 2.1 基于深度学习的速度预处理

本节将介绍轮速计测量模型、速度预处理模块中的神经网络结构和训练细节。

#### 2.1.1 轮速计测量模型

轮速计测量值常受车辆自身和外部环境双重因素影响。对于车辆自身:轮胎打滑、侧滑和振动会造成轮速计瞬时异常;轮胎磨损、车辆自身载重的变化造成轮速计外参变化,进而影响到测量值。对于外部环境:地面的不平整度和道路几何形状变化会对轮速计测量产生噪声。本文将轮速计因各种因素产生的噪声定义为 $w_t^{\text{wheel}}$ ,则轮速计测量模型为

$$\tilde{v}_{\text{wheel}} = v_{\text{wheel}} + w_t^{\text{wheel}}. \quad (1)$$

其中: $\tilde{v}_{\text{wheel}}$ 表示速度的原始测量值, $v_{\text{wheel}}$ 表示速度的真实值, $w_t^{\text{wheel}}$ 表示速度的测量噪声。

轮速计的速度测量伴有噪声,会对定位结果产生影响. 为解决这一问题,本节提出一种深度学习方法,以估计车辆真实速度.

### 2.1.2 神经网络结构

速度预处理模块由自编码器和中值滤波器构成(见图3).其中,自编码器用于去除轮速计速度噪声.

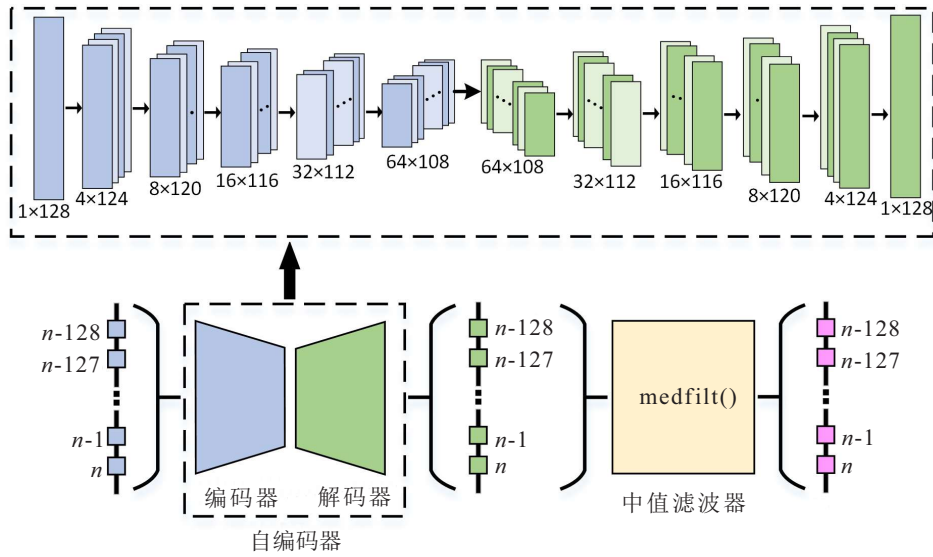


图3 速度预处理模块

自动编码器是一种无监督深度学习算法,通过学习输入数据的编码表示,以重构与输出相同的输入. 具体为:自编码器由编码器和解码器两个网络组成. 编码器将高维输入压缩成低维潜在,以提取相关信息,解码器则解压缩编码数据并重新创建原始输入. 同时,自编码器是一种可滤除噪声的神经网络. 编码器将噪声输入转换为隐藏层低维表示,在去除噪声的同时捕获重要数据特征;然后,解码器将其映射回原始输入层. 降噪自编码器的目的是学习如何从受损的输入数据中恢复出干净输出数据.

在自编码器中,输入数据为经加噪处理的包含128个原始速度读数的小序列,每侧包括6个一维卷积序列,卷积核大小为7. 在编码器侧,输入噪声数据通道数为1,随后每层通道数量从4逐层扩大2倍直至编码器最后一层. 解码器结构与编码器镜像分布,并且通道的数量逐层减少,直到在最后一层中实现单个通道,最后一层中预测的真实速度序列与输入数据长度保持一致. 每个卷积层后面跟着一个批归一化层和一个GELU激活层,这是一个相对较小的神经网络. 在神经网络末端,使用大小为3的滑动窗口进行中值滤波,以去除可能存在的异常值.

### 2.1.3 训练细节

在训练期间,首先给原始数据加上噪声,得到噪声数据,然后将成对的原始数据和噪声数据提供给自编码器,用自编码器中的编码器将噪声数据压缩成低维表示,用自编码器中解码器将低维表示恢复成原始

数据,最后训练网络使得解码器的输出尽可能接近原始数据,即最小化解码输出与原始输入之间的差异,同时从噪声中学习特征. 通过迭代地调整编码器和解码器参数,自编码器提高了去除噪声和重构原始输入的能力.

该模型基于pytorch实现,使用采集的数据训练,在超过16000个真实数据中,按7:3比例划分训练和测试集,将添加高斯白噪声的数据作为含噪声数据. 此外,将数据划分为128个读数的子序列,经历400轮训练,使用RAdam作为优化器,损失函数定义为

$$\mathcal{L} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2. \quad (2)$$

其中: $N$ 是观测的总数, $y_i$ 是第*i*个观测的实际值, $\hat{y}_i$ 是第*i*次观测的预测值.

### 2.2 融合滤波

本节采用InEKF融合多源信息实现高精度定位. 首先,对所使用的传感器和滤波方式构建模型,包括基于陀螺仪加轮速计构建状态传递模型,基于GNSS的位置观测构建观测模型;然后,在这两个模型的基础上使用InEKF通过预测和更新传递状态.

#### 2.2.1 状态传递模型

陀螺仪的测量过程建模为

$$\tilde{\omega}_t = \omega_t + b_t^\omega + w_t^\omega. \quad (3)$$

其中: $\tilde{\omega}_t$ 为角速度测量值, $\omega_t \in R^3$ 为角速度的实际值, $b_t^\omega \in R^3$ 为陀螺仪的零偏, $w_t^\omega \in R^3$ 为测量过程中

的高斯噪声. 零偏可被建模为随机游走过程

$$b_{t+1}^\omega = b_t^\omega + w_t^{b^\omega}, \quad (4)$$

其中  $w_t^{b^\omega} \in R^3$  表示高斯噪声.

轮速计测量的速度经速度预处理模块后, 噪声大幅下降, 但无法完全去除噪声, 仍然保留一部分. 速度预处理模块输出的速度建模为

$$\tilde{v}_t = v_t + w_t^v. \quad (5)$$

其中:  $\tilde{v}_t$  表示经过处理的速度;  $v_t$  表示速度的真实值;  $w_t^v$  表示残存的速度测量噪声, 该噪声建模为均值为0的高斯噪声.

所要估计的车辆状态有位置  $p$ 、速度  $v$ 、姿态  $R$  以及陀螺仪的零偏  $b^\omega$ , 这些状态的微分方程为

$$\begin{aligned} \dot{R}_t &= R_t[\tilde{\omega}_t - b_t^\omega - w_t^\omega]_\times, \\ \dot{p}_t &= \tilde{v}_t - w_t^v, \quad \dot{b}_t^\omega = w_t^{b^\omega}. \end{aligned} \quad (6)$$

其中:  $[x]_\times$  表示向量的反对称矩阵, 由于速度直接通过速度预处理模块得到, 不必对速度求微分方程. 所求状态的位置和姿态可构成一个 SE(3) 群, 将这两个状态嵌入李群中, 可表示为

$$\chi_t = \begin{bmatrix} R_t & p_t \\ 0 & 1 \end{bmatrix}. \quad (7)$$

状态的估计值  $\hat{\chi}_t$  与真值  $\chi_t$  之间误差有两种形式, 即

$$\eta_t = \chi_t^{-1} \hat{\chi}_t, \quad (8a)$$

$$\eta_t = \hat{\chi}_t \chi_t^{-1}. \quad (8b)$$

式(8a)为左不变误差(left-invariant), 式(8b)为右不变误差(right-invariant), 本文采用右不变误差

$$\eta_t = \hat{\chi}_t \chi_t^{-1} = \begin{bmatrix} \hat{R}_t R_t^T & \hat{p}_t - \hat{R}_t R_t^T p_t \\ 0 & 1 \end{bmatrix}. \quad (9)$$

令

$$\hat{R}_t R_t^T = \eta_{R_t}, \quad \hat{p}_t - \hat{R}_t R_t^T p_t = \xi_{p_t}. \quad (10)$$

设  $\eta_{R_t}$  对应的李代数为  $\xi_{R_t}$ , 即  $\eta_{R_t} = \text{Exp}(\xi_{R_t})$ , 由于  $\eta_{R_t}$  是小量, 可用指数函数的一阶泰勒展开做近似化为  $\eta_{R_t} \approx I + [\xi_{R_t}]_\times$ , 则右不变误差  $\eta_t$  的导数为

$$\dot{\eta}_t \approx \begin{bmatrix} [\dot{\xi}_{R_t}]_\times & \dot{\xi}_{p_t} \\ 0 & 0 \end{bmatrix} = \frac{d}{dt} \wedge \begin{bmatrix} \xi_{R_t} \\ \xi_{p_t} \end{bmatrix}. \quad (11)$$

其中:  $\wedge(\cdot)$  表示将向量空间映射到李代数空间的向量同构, 经推导得矩阵中元素如下:

$$\begin{aligned} [\dot{\xi}_{R_t}]_\times &\approx \dot{\eta}_{R_t} = [\hat{R}_t w_t^\omega]_\times, \\ \dot{\xi}_{p_t} &= [v_t]_\times \xi_{R_t} + w_t^v + [p_t]_\times \hat{R}_t w_t^\omega. \end{aligned} \quad (12)$$

综上, 有

$$\frac{d}{dt} \wedge \begin{bmatrix} \xi_{R_t} \\ \xi_{p_t} \end{bmatrix} =$$

$$\begin{aligned} &\begin{bmatrix} [\hat{R}_t w_t^\omega]_\times & [v_t]_\times \xi_{R_t} + w_t^v + [p_t]_\times \hat{R}_t w_t^\omega \\ 0 & 0 \end{bmatrix} = \\ &\wedge \left[ \begin{bmatrix} 0 & 0 \\ [v_t]_\times & 0 \end{bmatrix} \begin{bmatrix} \xi_{R_t} \\ \xi_{p_t} \end{bmatrix} + \begin{bmatrix} \hat{R}_t w_t^\omega \\ w_t^v + [p_t]_\times \hat{R}_t w_t^\omega \end{bmatrix} \right] = \\ &\wedge \left[ \begin{bmatrix} 0 & 0 \\ [v_t]_\times & 0 \end{bmatrix} \begin{bmatrix} \xi_{R_t} \\ \xi_{p_t} \end{bmatrix} + \begin{bmatrix} \hat{R}_t & 0 \\ [p_t]_\times \hat{R}_t & I \end{bmatrix} \begin{bmatrix} w_t^\omega \\ w_t^v \end{bmatrix} \right], \end{aligned} \quad (13)$$

则

$$\frac{d}{dt} \begin{bmatrix} \xi_{R_t} \\ \xi_{p_t} \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ [v_t]_\times & 0 \end{bmatrix} \begin{bmatrix} \xi_{R_t} \\ \xi_{p_t} \end{bmatrix} + \begin{bmatrix} \hat{R}_t & 0 \\ [p_t]_\times \hat{R}_t & I \end{bmatrix} \begin{bmatrix} w_t^\omega \\ w_t^v \end{bmatrix}. \quad (14)$$

根据陀螺仪零偏误差  $\xi_{b_t^\omega}$  及零偏噪声  $w_t^{b^\omega}$ , 将陀螺仪零偏的微分方程纳入方程(14), 令误差状态向量为  $\xi_t = (\xi_{R_t} \ \xi_{p_t} \ \xi_{b_t^\omega})$ , 噪声向量为  $w_t = (w_t^\omega \ w_t^v \ w_t^{b^\omega})$ , 噪声向量的协方差矩阵为  $Q = [w_t \ w_t^T]$ , 则总的微分方程为

$$\dot{\xi}_t = F_t \xi_t + G_t w_t,$$

$$\frac{d}{dt} \begin{bmatrix} \xi_{R_t} \\ \xi_{p_t} \\ \xi_{b_t^\omega} \end{bmatrix} =$$

$$\begin{bmatrix} 0 & 0 & 0 \\ [v_t]_\times & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} \xi_{R_t} \\ \xi_{p_t} \\ \xi_{b_t^\omega} \end{bmatrix} + \begin{bmatrix} \hat{R}_t & 0 & 0 \\ [p_t]_\times \hat{R}_t & I & 0 \\ 0 & 0 & I \end{bmatrix} \begin{bmatrix} w_t^\omega \\ w_t^v \\ w_t^{b^\omega} \end{bmatrix}. \quad (15)$$

其中  $F_t$  和  $G_t$  具体为

$$F_t = \begin{bmatrix} 0 & 0 & 0 \\ [v_t] & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, \quad G_t = \begin{bmatrix} \hat{R}_t & 0 & 0 \\ [p_t]_\times \hat{R}_t & I & 0 \\ 0 & 0 & I \end{bmatrix}. \quad (16)$$

根据线性系统理论将微分方程(15)离散化处理为状态传递方程

$$\xi_{t+1} = \Phi_{t+1|t} \xi_t + W_t,$$

$$\Phi_{t+1|t} = \exp\left(\int_t^{t+1} F(t) dt\right),$$

$$W_t = \int_t^{t+1} \Phi_{t+1|t} G(t) w_t dt. \quad (17)$$

其中:  $W_t$  表示离散时间的噪声协方差;  $\Phi_{t+1|t}$  表示从  $t$  时刻到  $t+1$  时刻的状态转移矩阵. 由于陀螺仪的采样频率较高, 认为采样时间间隔很小, 在此假设下, 通过泰勒展开将状态转移矩阵近似为

$$\Phi_{t+1|t} = \exp\left(\int_t^{t+1} F(t) dt\right) \approx I + F(t) \Delta t. \quad (18)$$

通过模型(17), 可对误差状态做先验估计, 在此过程中, 除了需要陀螺仪测量信息, 还需要轮速计速度信息. 然而, 轮速计采样频率低于陀螺仪, 因此, 在两帧轮速计数据之间存在多个陀螺仪数据, 规定按陀

螺仪采样频率进行状态递推时,所需速度信息采用陀螺仪最近一帧速度信息.

### 2.2.2 观测模型

采用GPS对车辆位置观测,位置观测过程可描述为

$$y = \chi_t b + S_t, \\ \begin{bmatrix} \tilde{p}_t \\ 1 \end{bmatrix} = \begin{bmatrix} R_t & p_t \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 0_{3 \times 3} \\ 1 \end{bmatrix} + \begin{bmatrix} S_t^p \\ 0 \end{bmatrix}. \quad (19)$$

其中:  $y$  表示观测向量,该向量中第1项元素  $\tilde{p}_t$  为车辆位置的观测值,第2项元素置1;  $S_t$  表示观测噪声向量,其中第1项  $S_t^p$  表示位置观测噪声. 观测误差定义如下:

$$Z_{\xi_{p_t}} = \chi_t^{-1} y - b \approx H_t^X \xi_t^X + s_{\xi_{p_t}}, \\ [Z_{\xi_{p_t}}] = [0 \quad I] \begin{bmatrix} \xi_{R_t} \\ \xi_{p_t} \end{bmatrix} + [s_{\xi_{p_t}}]. \quad (20)$$

其中:  $Z_{\xi_{p_t}}$  为位置观测误差,  $H_t^X = [0 \quad I]$  为位置观测误差的雅可比矩阵,  $\xi_t^X = [\xi_{R_t} \quad \xi_{p_t}]^T$  表示误差状态向量中与李群相关的子向量,  $s_{\xi_{p_t}}$  表示位置观测误差的噪声.

考虑误差状态向量中与陀螺仪偏置相关的子向量,并将其纳入观测方程,总的观测方程为

$$Z_t = H_t \xi_t + s_t, \\ \begin{bmatrix} Z_{\xi_{p_t}} \\ Z_{\xi_{b_t^\omega}} \end{bmatrix} = \begin{bmatrix} 0 & I & 0 \\ 0 & 0 & I \end{bmatrix} \begin{bmatrix} \xi_{R_t} \\ \xi_{p_t} \\ \xi_{b_t^\omega} \end{bmatrix} + \begin{bmatrix} s_{\xi_{p_t}} \\ w_t^{b_t^\omega} \end{bmatrix}. \quad (21)$$

其中:  $s_t$  表示总的观测误差的噪声向量,其协方差矩阵为  $V_t = E(s_t s_t^T)$ .

GPS对车辆位置的观测频率同样低于陀螺仪采样频率,当使用模型(17)按陀螺仪采样频率时,对每次GPS观测进行一次状态更新.在两次GPS观测之间则只进行状态递推而不更新,直到GPS观测到来.

### 2.2.3 不变拓展卡尔曼滤波

假设误差状态向量在  $t-1$  时刻的后验估计为  $\xi_{t-1}^+$ ,其协方差矩阵为  $P_{t-1}^+$ .在预测阶段,通过状态传递方程预测  $t$  时刻的先验估计和协方差矩阵

$$\xi_t^- = \Phi_{t|t-1} \xi_{t-1}^+, \\ P_t^- = \Phi_{t|t-1} P_{t-1}^+ \Phi_{t|t-1}^T + G_t Q_t G_t^T. \quad (22)$$

在更新阶段,考虑由GPS观测到的位置信息,对预测的先验状态和协方差矩阵校正,首先计算  $t$  时刻的卡尔曼增益

$$K_t = P_t^- H_t^T (H_t P_t^- H_t^T + V_t)^{-1}. \quad (23)$$

$t$ 时刻后验误差状态向量和其协方差矩阵更新为

$$\xi_t^+ = \xi_t^- + K_t Z_t, \\ P_t^+ = (I - K_t H_t) P_t^-. \quad (24)$$

对于车辆状态,位置、姿态的标称状态通过4阶龙格库塔法积分得到,速度的标称状态通过速度预处理模块直接获取.然后通过上述卡尔曼增益和观测误差对位置、姿态和陀螺仪零偏更新,有

$$\chi_t^+ = \chi_t^- \exp[(K_t Z_t)_\chi], \\ b_t^{\omega+} = b_t^{\omega-} + (K_t Z_t)_b, \quad (25)$$

其中  $(K_t Z_t)_\chi$  和  $(K_t Z_t)_b$  分别是  $K_t Z_t$  关于矩阵李群和陀螺仪偏置的子向量.

### 2.3 算法流程

整个定位算法可分为速度预处理和融合滤波两个部分,其具体过程如算法1所示.

#### 算法1 基于InEKF和深度学习的定位算法

输入: 陀螺仪测量的角速度  $\tilde{\omega}_t$ , 轮速计测量的原始速度

$\tilde{v}_{\text{wheel}}$ , GNSS的位置观测  $\tilde{p}_t$ , 初始状态  $\xi_0$ ;

输出: 车辆状态估计.

1) for  $t = 0, 1, 2, \dots$

2) 通过速度预处理模块处理原始速度  $\tilde{v}_{\text{wheel}}$ , 得到预测的真实速度  $\tilde{v}_t$ ;

3) 由角速度  $\tilde{\omega}_t$  和预测的真实速度  $\tilde{v}_t$ , 通过状态转移方程(17), 预测下一时刻先验状态  $\xi_{t+1}^-$  和协方差  $P_{t+1}^-$ ;

4) 通过式(23)计算  $t+1$  时刻卡尔曼增益  $K_{t+1}$ ;

5) 由GNSS的位置观测  $\tilde{p}_{t+1}$ , 通过观测方程(21)更新下一时刻后验状态  $\xi_{t+1}^+$  和协方差  $P_{t+1}^+$ ;

6) 通过4阶龙格库塔法计算下一时刻标称状态, 并通过式(25)与后验状态  $\xi_{t+1}^+$  相加, 得到车辆的状态估计.

7) end for

## 3 仿真与实验

本部分给出实验结果与讨论. 首先对速度预处理模块进行实验仿真, 以验证所设计的网络具备良好的速度处理效果和合理的网络架构; 然后对使用InEKF进行车辆定位进行实验仿真, 以验证高精度的定位效果.

### 3.1 速度预处理数值仿真

速度预处理模块使用pytorch实现, 实验采用Legion Y7000, Intel(R) Core(TM) i5-8300H CPU @ 2.30 GHz和NVIDIA GeForce GTX 1050 Ti 4 GB显卡, 运行环境为PyCharm2023. 将大约16000个速度数据分为128个读数的小序列. 经历400轮训练, 使用RAdam作为优化器.

图4给出所提出的速度预处理模块与Savitzky-

Golay滤波器的性能比较,原始数据由真实值加高斯噪声生成.在本例中可以看出,使用速度预处理模块生成的降噪值整体上更贴近真实值,Savitzky-Golay滤波器只能以较为平滑的速度拟合真实值,无法在速度变化较快的时刻重构出真实值.




图4 速度预处理效果比较

为了量化评价所提出的速度预处理模块与信号处理中的Savitzky-Golay滤波器之间的性能比较,给出了3种评价指标.3种评价指标分别为平均绝对误差(mean absolute error, MAE)、均方误差(mean square error, MSE)和均方根误差(root mean square error, RMSE),这些值越小说明从原始数据预测真实值的预测精度越高.3种评价指标的具体计算公式为

$$\begin{aligned} \text{MAE} &= \frac{1}{M} \sum_{t=1}^M |\tilde{v}_t - v_t^{\text{wheel}}|, \\ \text{MSE} &= \frac{1}{M} \sum_{t=1}^M |\tilde{v}_t - v_t^{\text{wheel}}|^2, \\ \text{RMSE} &= \sqrt{\frac{1}{M} \sum_{t=1}^M |\tilde{v}_t - v_t^{\text{wheel}}|^2}. \end{aligned} \quad (26)$$

通过这3个指标,所提出的速度预处理模块与Savitzky-Golay滤波器之间的性能比较如表1所示.本文提出的基于深度学习的速度预处理模块与信号处理中常用的Savitzky-Golay滤波器相比,速度预处理模块的真实速度预测精度在上述3个指标中的表现均优于Savitzky-Golay滤波器.

表1 真实速度预测精度比较

	MAE/(m/s)	MSE/(m <sup>2</sup> /s <sup>2</sup> )	RMSE/(m/s)
速度预处理模块	<b>0.0024</b>	<b>0.0158</b>	<b>0.1256</b>
Sav-Gol滤波器	0.0148	0.0377	0.1943

为了验证速度预处理模块中架构安排的合理性,将其中的自编码器和中值滤波器排列组合,共组成4种排布方式,仅自编码器,仅中值滤波器,自编码器+中值滤波器(本文提出),中值滤波器+自编码器.对这4种排布方式的网络分别进行数值仿真,比较从原始

数据预测真实值的预测精度,结果如图5所示,仍然采用上述3个评价指标来量化,结果如表2所示.




图5 不同组合速度预处理效果比较

表2 不同组合真实速度预测精度比较

	MAE/(m/s)	MSE/(m <sup>2</sup> /s <sup>2</sup> )	RMSE/(m/s)
仅自编码器	0.0501	0.0319	0.1786
仅中值滤波	1.2911	2.4008	1.5492
中值滤波+自编码器	0.0121	0.1154	0.3397
自编码器+中值滤波	<b>0.0024</b>	<b>0.0158</b>	<b>0.1256</b>

如图5所示,在4种组合中,仅中值滤波的组合效果最差,剩下3种组合都能预测出真实速度的大致范围,但在速度波动较大的情况下仍与真实速度之间存在着较大误差;如表2所示,仅中值滤波的组合预测精度最差,并与其他3个组合有着较大差距,其原因为中值滤波的作用是滤除可能存在的外点,而对从原始速度还原到真实速度无明显帮助;剩下3组中,中值滤波+自编码器组合的效果好于仅自编码器组合,自编码器+中值滤波效果最好,量化指标MAE、MSE和RMSE均是最低.通过该数值仿真实验,验证了所提出的速度预处理模块安排的合理性.

### 3.2 定位结果道路测试

首先,将InEKF与误差状态的扩展卡尔曼滤波(error-state extended Kalman filter)作仿真比较<sup>[6]</sup>,以验证InEKF的优越性.由于ESKF融合的是IMU与GPS而非与本文类似的定位框架,可将ESKF误差状态传递方程中与速度误差、加速度计测量噪声和加速度计零偏有关的矩阵元素置0,直接使用真实速度,仿真时长为10s.

图6和图7分别为使用InEKF和ESKF融合多传感器信息的横向误差和纵向误差,红色线条和蓝色曲线分别代表InEKF和ESKF的误差曲线.可以看出,InEKF的横向误差和纵向误差均小于ESKF,InEKF的横向误差和纵向误差分别为0.095m和0.024m,而ESKF的横向误差和纵向误差达到了0.263m和0.053m.分别减少了63.88%和54.71%,由此可以看出,本文开发的SE2(3)下的InEKF的估计精度显著

高于ESKF.




图6 InEKF和ESKF的横向位置误差比较




图7 InEKF和ESKF的纵向位置误差比较

为了验证所提出方法的定位效果,结合真实道路数据,与仅使用IMU航位推算算法和文献[25]中提出的RIDR (radar inertial dead-reckoning) 定位算法比较. 使用的IMU采样频率为200 Hz, GPS信号为1 Hz, 轮速计采用频率为50 Hz. 数据采集于城市环境,采集数据过程中车况稳定,行驶道路平整度均匀一致,因此产生速度测量噪声符合高斯噪声假设. 整个数据集时长为62 s,如图8中黑色虚线所示,前25 s是在空旷且GPS无遮挡的路况下进行的,其中在开始后有一次避障动作;大约在30 s到达岔路口,随后为包含多车及楼群的复杂路况.

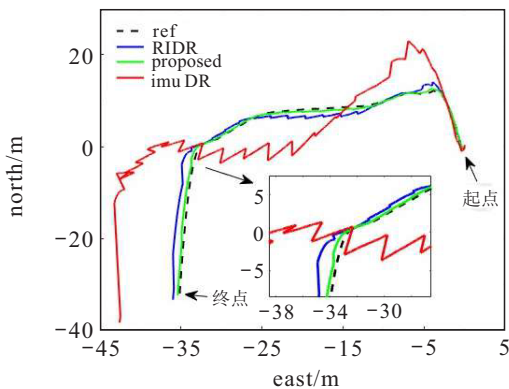


图8 不同定位方法定位结果比较

不同定位方法在数据集中的定位结果如图8所示,黑色虚线为真实轨迹,红色实线为仅使用IMU航位推算的轨迹,蓝色实线为文献[25]中RIDR的轨迹,绿色实线为本文所提出方法的轨迹. 可以看出,仅使用IMU航位推算的轨迹发散最快,定位误差最大,尤

其是在转弯处(如图中放大处所示),巨大漂移也造成最终并未达到终点,这主要是因为IMU求解位置需对加速度进行二次求积. 本文所提出的方法与文献[25]中的RIDR相比,结果更贴近真实轨迹,定位终点也更接近真实终点,定位精度更好.

3种定位方法定位误差如图9所示. IMU-DR定位结果误差最大,其平均位置误差达1.346 5 m, RIDR平均位置误差为0.478 6 m,本文所提出方法平均位置误差最小,为0.143 5 m. 相比RIDR,本文方法位置误差减小了70.02%;相比IMU-DR,本文方法的位置误差减小了89.34%. 值得注意的是,图6中IMU-DR与真实轨迹有两次明显交错,图7中对应位置误差并无两次归零,这主要是因为虽然轨迹出现交错,但并非在同一时间到达该点,存在时间差.




图9 不同定位方法定位误差比较

### 4 结论

本文提出了一种基于InEKF和深度学习的车辆定位算法,以解决由IMU二次求积引起的位置信息显著漂移,提高车辆定位精度. 引入轮速计测量模型,尝试探索一种基于深度学习的速度解算方法;同时,推导并开发了基于InEKF的多源融合算法. 实验结果表明,所提出的车辆定位系统能够使用低成本传感器实现高精度的车辆定位,与现有先进定位算法相比可显著减少定位误差.

### 参考文献(References)

[1] Schwarting W, Alonso-Mora J, Rus D. Planning and decision-making for autonomous vehicles[J]. Annual Review of Control, Robotics, and Autonomous Systems, 2018, 1: 187-210.

[2] Suhr J K, Jang J, Min D, et al. Sensor fusion-based low-cost vehicle localization system for complex urban environments[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(5): 1078-1086.

[3] 郭戈, 刘佳庚, 孙晓峥. 融合5G/GNSS的车辆高精度鲁棒安全定位: 进展与展望[J]. 控制与决策, 2023, 38(2): 289-303.

(Guo G, Liu J G, Sun X Z. Secure robust precise vehicle localization with 5G/GNSS fusion: Advances and prospects[J]. Control and Decision, 2023, 38(2):

- 289-303.)
- [4] Guo G, Liu J G. A stochastic model-based fusion algorithm for enhanced localization of land vehicles[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-10.
- [5] Liu J G, Guo G, Zhang R. Residual-based fault detection and exclusion with enhanced localization integrity[J]. IEEE Transactions on Vehicular Technology, 2023, 72(5): 5798-5808.
- [6] Liu J G, Guo G. Vehicle localization during GPS outages with extended Kalman filter and deep learning[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.
- [7] 刘铮轩, 王亮, 李和平, 等. 融合双目视觉和2D激光雷达的室外定位[J]. 控制与决策, 2023, 38(7): 1861-1868.  
(Liu Z X, Wang L, Li H P, et al. Fusion of stereo vision and 2D LiDAR for outdoor localization[J]. Control and Decision, 2023, 38(7): 1861-1868.)
- [8] 彭道刚, 欧阳海林, 威尔江, 等. 结合改进密集模块深度估计网络和多视几何的视觉里程计[J]. 控制与决策, 2023, 38(4): 980-988.  
(Peng D G, Ouyang H L, Qi E J, et al. Visual odometry combined with depth estimation network of improved dense block and multi-view geometry[J]. Control and Decision, 2023, 38(4): 980-988.)
- [9] 吴启宇, 谢非, 黄磊, 等. 基于深度/单目融合视觉及强化学习的机器人定位棋局与行棋策略[J]. 控制与决策, 2022, 37(12): 3278-3288.  
(Wu Q Y, Xie F, Huang L, et al. Chess positioning and playing strategy of robot based on integrated depth/mono vision and reinforcement learning[J]. Control and Decision, 2022, 37(12): 3278-3288.)
- [10] 王童, 李骛, 宋海萃, 等. 基于分层深度强化学习的移动机器人导航方法[J]. 控制与决策, 2022, 37(11): 2799-2807.  
(Wang T, Li A, Song H L, et al. Navigation method for mobile robot based on hierarchical deep reinforcement learning[J]. Control and Decision, 2022, 37(11): 2799-2807.)
- [11] Guo G, Liu J G, Sun X Z. A model decomposition Kalman filter for enhanced localization of land vehicles[J]. IEEE Transactions on Vehicular Technology, 2023, 72(8): 10013-10023.
- [12] Jo K, Lee M, Sunwoo M. Road slope aided vehicle position estimation system based on sensor fusion of GPS and automotive onboard sensors[J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(1): 250-263.
- [13] Julier S J, Durrant-Whyte H F. On the role of process models in autonomous land vehicle navigation systems[J]. IEEE Transactions on Robotics and Automation, 2003, 19(1): 1-14.
- [14] Brossard M, Barrau A, Bonnabel S. AI-IMU dead-reckoning[J]. IEEE Transactions on Intelligent Vehicles, 2020, 5(4): 585-595.
- [15] Or B, Klein I. A hybrid model and learning-based adaptive navigation filter[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-11.
- [16] Xu J, Xiang L, Liu Q S, et al. Stacked sparse autoencoder (SSAE) for nuclei detection on breast cancer histopathology images[J]. IEEE Transactions on Medical Imaging, 2016, 35(1): 119-130.
- [17] Cai Y J, Santos R B, Givigi S N, et al. A pipeline leak classification and location estimation system with convolutional neural networks[J]. IEEE Systems Journal, 2020, 14(3): 3072-3081.
- [18] Bonnabel S. Left-invariant extended Kalman filter and attitude estimation[C]. The 46th IEEE Conference on Decision and Control. New Orleans, 2007: 1027-1032.
- [19] Barrau A. Non-linear state error based extended Kalman filters with applications to navigation[D]. Paris: Mines Paristech, 2015: 33-55.
- [20] Zhang T, Wu K Z, Song J W, et al. Convergence and consistency analysis for a 3-D invariant-EKF SLAM[J]. IEEE Robotics and Automation Letters, 2017, 2(2): 733-740.
- [21] Potokar E, Norman K, Mangelson J. Invariant extended Kalman filtering for underwater navigation[J]. IEEE Robotics and Automation Letters, 2021, 6(3): 5792-5799.
- [22] Hartley R, Ghaffari M, Eustice R M, et al. Contact-aided invariant extended Kalman filtering for robot state estimation[J]. International Journal of Robotics Research, 2020, 39(4): 402-430.
- [23] Heo S, Park C G. Consistent EKF-based visual-inertial odometry on matrix lie group[J]. IEEE Sensors Journal, 2018, 18(9): 3780-3788.
- [24] Zhang Z H, Zhao J T, Huang C Y, et al. Learning visual semantic map-matching for loosely multi-sensor fusion localization of autonomous vehicles[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(1): 358-367.
- [25] de Araujo P R M, Elhabiby M, Givigi S, et al. A novel method for land vehicle positioning: Invariant Kalman filters and deep-learning-based radar speed estimation[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(9): 4275-4286.

## 作者简介

郭戈(1972—), 男, 教授, 博士生导师, 主要研究方向为信息物理融合系统、智能交通出行系统, E-mail: geguo@yeah.net;

林皓栋(2000—), 男, 硕士生, 主要研究方向为多传感器融合车辆定位、激光惯性里程计, E-mail: 1071513591@qq.com;

刘佳庚(1987—), 男, 博士生, 主要研究方向为车辆定位, E-mail: liu331453318@163.com;

李增勃(1999—), 男, 硕士生, 主要研究方向为车辆定位, E-mail: 15548307627@163.com.