引文格式:李晗旭,李昕,黄观文,等.速度分类的LSTM神经网络辅助GNSS/SINS车载定位方法[J].武汉大学学报(信息科学版),2025,50(7):1311-1320.DOI:10.13203/j.whugis20230061

Citation:LI Hanxu,LI Xin,HUANG Guanwen,et al.LSTM Neural Network Assisted GNSS/SINS Vehicle Positioning Based on Speed Classification[J].Geomatics and Information Science of Wuhan University,2025,50(7):1311-1320.DOI:10.13203/j.whugis20230061

速度分类的LSTM神经网络辅助GNSS/SINS车载定位方法

李晗旭[1,2] 李 昕[1] 黄观文[1] 张 勤[1] 陈世鹏[1]

1 长安大学地质工程与测绘学院,陕西 西安,710054

2 信息工程大学地理空间信息学院,河南 郑州,450001

摘 要:车辆非完整性约束(non-holonomic constraint,NHC)是车载全球导航卫星系统(global navigation satellite system,GNSS)/捷联惯性导航系统(strapdown inertial navigation system,SINS)组合定位常用的增强技术,应用机器学习的手段可以建立惯性测量单元输出与NHC伪观测量的复杂映射关系,从观测域直接调整NHC伪观测量大小,在一定程度上提高了传统NHC方法的约束精度。现有的机器学习方法没有考虑车辆运动状态影响,导致NHC预测精度和可靠性不高。最新研究表明机器学习可以预测车辆的前向速度,即虚拟里程计。然而,当前研究主要是将预测虚拟NHC和虚拟里程计分开讨论,没有充分挖掘二者之间的耦合关系以及三维速度对车辆进行全约束。研究了一种基于车辆速度分类的长短期记忆(long short-term memory,LSTM)神经网络用于车辆三维速度的预测,采用三维速度约束新息自适应调整其方差域,通过车载GNSS/SINS松组合验证了所提方法的有效性。实验结果表明,所提方法预测的前向速度的平均精度为0.4 m/s,侧向和垂向速度的平均精度分别为2.4、2.1 cm/s,在模拟GNSS信号完全缺失460 s时,三维速度约束的水平定位精度上相对于惯导推算结果改善了99.40%。

关键词:GNSS/SINS;NHC;车辆里程计;机器学习;LSTM

中图分类号:P228 **文献标识码**:A **收稿日期**:2025-10-25

DOI:10.13203/j.whugis20230061 **文章编号**:1671-8860(2025)07-1311-10

LSTM Neural Network Assisted GNSS/SINS Vehicle Positioning Based on Speed Classification

LI Hanxu[1,2] *LI Xin*[1] *HUANG Guanwen*[1] *ZHANG Qin*[1] *CHEN Shipeng*[1]

1 School of Geology Engineering and Geomatics, Chang'an University, Xi'an 710054, China

2 Institute of Geospatial Information, Information Engineering University, Zhengzhou 450001, China

Abstract: **Objectives**: Vehicle non-holonomic constraint (NHC) is a commonly used enhancement technique for vehicle positioning global navigation satellite system (GNSS)/strapdown inertial navigation system (SINS) combination positioning. A complex mapping relationship between inertial measurement unit (IMU) output and NHC pseudo-observations can be established by applying machine learning methods, and the NHC pseudo-observations can be directly adjusted from the observation domain, which can improve the constraint accuracy compared with traditional NHC methods to a certain extent. Most existing machine learning methods do not consider the influence of vehicle motion state, resulting in low accuracy and reliability of NHC prediction. The latest researches show that machine learning can predict a vehicle forward speed, as a virtual odometer. However, the current research mainly discusses the prediction of virtual NHC and virtual odometer separately, and fails to fully explore the coupling relationship between them and

基金项目:国家自然科学基金委重大科研仪器项目(42127802);国家自然科学基金(42474026)。

第一作者:李晗旭,博士,主要从事GNSS/SINS组合导航研究。2020226074@chd.edu.cn

通信作者:李昕,博士,副教授。lixin2017@chd.edu.cn

the full constraint of three-dimensional velocity on vehicles. **Methods**: We study a long short-term memory (LSTM) neural network based on vehicle speed classification for 3 dimensional (3D) vehicle speed prediction, and adaptively adjust its variance domain by using 3D speed residual. The vehicle GNSS/SINS positioning verifies the effectiveness of the proposed method. **Results and Conclusions**: Experimental results show that the average accuracy of forward velocity predicted by the proposed method is 0.4 m/s, and the average accuracy of lateral and celestial velocity are 2.4 and 2.1 cm/s, respectively. The simulated GNSS signal is completely missing for 460 s, the horizontal positioning accuracy of 3D velocity constraint is improved by 99.40% compared with the inertial navigation results.

Key words: GNSS/SINS; NHC; odometer; machine learning; LSTM

全球导航卫星系统(global navigation satellite system,GNSS)已被证明能够在开阔环境下提供厘米级导航定位服务[1],然而,由于GNSS本质上是一种几何定位技术,这种高精度特性易受户外环境的干扰,为了提高单一传感器的导航服务能力,采用具备自主导航、抗干扰能力强等优点的捷联惯性导航系统(strapdown inertial navigation system,SINS)系统与GNSS组合成为研究热点[2]。该组合同时集成了GNSS和SINS的优势。但是,受限于城市复杂环境下GNSS信号的频繁中断,该组合系统易退变为单一的SINS系统,使得车载GNSS/SINS组合系统性能下降明显[3]。在缺少GNSS信息后,如何有效抑制惯性推算误差的快速累积一直是核心难题,也是实现复杂场景下定位服务连续可用的关键。

得益于车辆里程计(odometer,ODO)、车辆非完整性约束(non-holonomic constraint,NHC)等信息的无源自主、低成本、易获取等优良特性,GNSS/SINS/ODO/NHC多源信息融合是常用的解决方案[4]。传统NHC约束假设车体侧向、垂向速度为零,当作伪观测量,根据经验给定一个相对较为保守的方差,可在一定程度上提高惯导递推位置的精度[5]。实际上,由于车体旋转质心与惯性测量单元(inertial measurement unit,IMU)安装位置存在差异,以及车体侧滑、弹跳等复杂运动,将会使NHC伪观测量为零的假设不再成立[6],另外车体在转弯时,阿克曼转向转动点会偏离理论位置,前向速度也会产生侧向速度分量,大小与转弯幅度有关[7-8]。因此,实际行驶中,准确获取NHC值是一个非常复杂的问题,不仅和IMU安装位置有关,还和车体实际运动状态有关,尤其是前向速度,二者相互耦合[9-10]。

除了上述利用传感器组合以及车辆运动约束之外,也有学者尝试通过神经网络、机器学习等高级算法直接训练惯导输出与定位结果之间的映射关系,当GNSS信号失锁时,利用训练模型输出的位置、速度等虚拟观测值进行融合[10]。文献[11]首次引入基于卷积神经网络的深度学习方法,初步实现了惯导输出与NHC观测方差之间映射关系的智能学习,通过自主化的参数最优配置,提升了惯性推算误差的抑制效果。文献[12]提出了一种基于卷积神经网络的虚拟里程计网络,利用一段IMU数据直接估计车辆的前向速度,辅助组合导航系统,起到轮式里程计的作用,从而满足GNSS复杂环境下的导航定位需求。文献[10]从观测域出发,提出车辆运动约束信息的多元回归和深度学习方法,这种方法更新得到的估值最终接近真实状态,结果具有较好的估计准确度与精度。目前已有的基于机器学习的NHC或者ODO预测一般都是分开进行的,且训练网络没有顾及运动状态,导致了预测精度不是很高,另外随机模型多采用固定方差,导致约束的可靠性不强。

本文将车体三维速度作为整体且考虑不同速度进行网络训练,设计了一种基于速度分类,同时预测NHC和ODO的长短期记忆(long short-term memory,LSTM)神经网络。首先采用具备高精度且足够的历史轨迹数据作为网络训练数据集,根据速度进行分类,然后训练前向、侧向和垂向速度模型,在缺乏GNSS观测时,利用训练好的模型预测的三维速度作为约束信息,在拓展卡尔曼滤波(extended Kalman filter,EKF)量测更新时采用了一种基于三维速度新息自适应调整量测噪声的随机模型。此方法顾及了车辆的运动状态,可以更好地提取三维速度的特征信息,同时因为用了3个方向速度做全约束,且采用了基于新息的自适应随机模型,相较于传统NHC约束,对惯导惯性推算误差的抑制效果更加明显。

1 方法原理

首先介绍了LSTM神经网络的结构,然后构

建了基于速度分类的三维速度约束神经网络方法，最后给出了基于预测的三维速度自适应辅助 GNSS/SINS 松组合定位模型。

1.1　LSTM 神经网络结构

目前，递归神经网络被广泛用于基于预测序列的任务，该研究方向主要集中在惯性基的室内行人导航领域，如移动手机行人航迹推算[13]、足绑式设备零速探测等[14]。与传统的多层感知器神经网络不同，基本的循环神经网络（recurrent neural network，RNN）有一个循环，使信息得以持续。图 1 中，传统链状结构 RNN 与序列和列表有关，缺乏处理长期依赖关系的能力[15]，A 为 RNN 的循环单元，x_t 和 h_t 为当前输入和输出。LSTM 网络是一种特殊的 RNN，具有学习长期依赖的能力，其结构如图 2 所示。

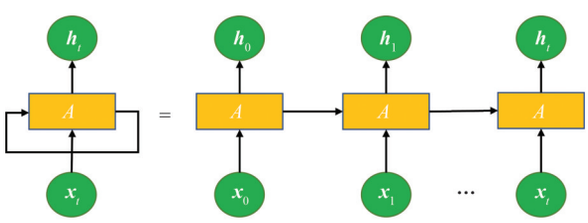


图 1　RNN 链状结构

Fig. 1　RNN Chain Structure

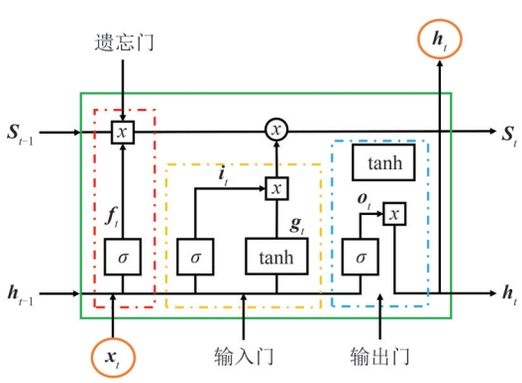


图 2　LSTM 结构

Fig. 2　LSTM Structure

LSTM 网络的基本单元中包含遗忘门、输入门和输出门[16]。遗忘门中输入 $\boldsymbol{x}_t$ 与状态记忆单元 $\boldsymbol{S}_{t-1}$、中间输出 $\boldsymbol{h}_{t-1}$ 共同决定状态记忆单元遗忘部分。输入门中的 $\boldsymbol{x}_t$ 分别经过 sigmoid 和 tanh 函数变化后共同决定状态记忆单元中的保留向量。中间输出 $\boldsymbol{h}_t$ 由更新后的 $\boldsymbol{S}_t$ 与输出 $\boldsymbol{o}_t$ 共同决定，计算公式为：

$$\boldsymbol{f}_t=\sigma\left(\boldsymbol{W}_{fx}\boldsymbol{x}_t+\boldsymbol{W}_{fh}\boldsymbol{h}_{t-1}+\boldsymbol{b}_f\right) \tag{1}$$

$$\boldsymbol{i}_t=\sigma\left(\boldsymbol{W}_{ix}\boldsymbol{x}_t+\boldsymbol{W}_{ih}\boldsymbol{h}_{t-1}+\boldsymbol{b}_i\right) \tag{2}$$

$$\boldsymbol{g}_t=\phi\left(\boldsymbol{W}_{gx}\boldsymbol{x}_t+\boldsymbol{W}_{gh}\boldsymbol{h}_{t-1}+\boldsymbol{b}_g\right) \tag{3}$$

$$\boldsymbol{o}_t=\sigma\left(\boldsymbol{W}_{ox}\boldsymbol{x}_t+\boldsymbol{W}_{oh}\boldsymbol{h}_{t-1}+\boldsymbol{b}_o\right) \tag{4}$$

$$\boldsymbol{S}_t=\boldsymbol{g}_t\odot\boldsymbol{i}_t+\boldsymbol{S}_{t-1}\odot\boldsymbol{f}_t \tag{5}$$

$$\boldsymbol{h}_t=\phi(\boldsymbol{S}_t)\odot\boldsymbol{o}_t \tag{6}$$

式中，$\boldsymbol{f}_t$、$\boldsymbol{i}_t$、$\boldsymbol{g}_t$、$\boldsymbol{o}_t$、$\boldsymbol{h}_t$ 和 $\boldsymbol{S}_t$ 分别表示遗忘门、输入门、输入节点、输出门、中间输出和状态单元的状态；$\boldsymbol{W}_{fx}$、$\boldsymbol{W}_{fh}$、$\boldsymbol{W}_{ix}$、$\boldsymbol{W}_{ih}$、$\boldsymbol{W}_{gx}$、$\boldsymbol{W}_{gh}$、$\boldsymbol{W}_{ox}$ 和 $\boldsymbol{W}_{oh}$ 分别为相应门与输入 $\boldsymbol{x}_t$ 和中间输出 $\boldsymbol{h}_{t-1}$ 相乘的矩阵权重；$\boldsymbol{b}_f$、$\boldsymbol{b}_i$、$\boldsymbol{b}_g$、$\boldsymbol{b}_o$ 分别为相应门的偏置项；$\odot$ 表示向量中元素按位相乘；σ 表示 sigmoid 函数变化；ϕ 表示 tanh 函数变化[17]。

1.2　基于车辆速度分类的 LSTM 神经网络

数据分类式是提高机器学习多元回归精度的常用策略，训练集采用后处理的速度结果作为车辆速度的判定依据，测试集采用惯导机械编排的速度作为判断依据。本文首先将车辆运动前向速度 v_{for} 进行分类，主要包含静态停车、$v_{\text{for}}\leqslant 5$、$5<v_{\text{for}}\leqslant 10$、$10<v_{\text{for}}\leqslant 15$、$v_{\text{for}}>15$，然后基于不同的分类数据集构建了一种基于车辆速度分类的 LSTM 神经网络——3d-Nets。

对于静态检测，本文采用角速度检测（angular rate energy detector，ARDE）方法，通过获取陀螺仪的数据对车体的零速进行判断[18]。ARDE 输出 $T_k(\boldsymbol{\omega})$ 定义为：

$$T_k(\boldsymbol{\omega})=\frac{1}{W}\sum_{n=k}^{k-W+1}\|\boldsymbol{\omega}_n\|^2 \tag{7}$$

式中，W 为窗口大小，本文给定为 10；$\boldsymbol{\omega}$ 为 IMU 角速度，$\boldsymbol{\omega}_n$ 为第 n 个时刻 IMU 的角速度。给定一个经验阈值 γ，判定车辆处于静止停车状态的计算公式为：

$$v_{\text{for}}=0,\text{若}T_k(\boldsymbol{\omega},f)\leqslant\gamma \tag{8}$$

三维速度约束的伪观测量 $\boldsymbol{Z}_{3\text{D}}$ 为载体系（b 系）的前向速度、侧向速度和垂向速度，即 $\boldsymbol{Z}_{3\text{D}}=[v_{\text{for}}\ v_{\text{lat}}\ v_{\text{up}}]$，对于 $v_{\text{for}}=0$ 的状态进行强约束，满足：

$$\boldsymbol{Z}_{3\text{D}}(v_{\text{for}}=0)=[0\ 0\ 0] \tag{9}$$

对于其他速度区间，本文设计了一种 LSTM 神经网络，输入为 IMU 6 轴观测量，即角速度 $\boldsymbol{\omega}$ 和比力 $\boldsymbol{f}$，标签数据为历史数据经过高精度后处理得到的 b 系的前向速度、侧向速度和垂向速度。根据不同训练集进行训练，针对 $v_{\text{for}}\leqslant 5$ 数据集，得到的网络记为 LSTM^1，针对 $5<v_{\text{for}}\leqslant 10$ 数据集得到的网络记为 LSTM^2，针对 $10<v_{\text{for}}\leqslant 15$ 数据集得到的网络记为 LSTM^3，针对 $v_{\text{for}}>15$ 数据集得到的网络记为 LSTM^4，综上，3d-Nets=$\{\text{LSTM}^1,\text{LSTM}^2,\text{LSTM}^3,\text{LSTM}^4\}$。$\boldsymbol{Z}_{3\text{D}}$ 和 3d-Nets 满足如下映射关系：

$$Z_{3D}(v_{for}\leqslant 5)=\mathrm{LSTM}^1(\boldsymbol{\omega}_i,\boldsymbol{f}_i) \tag{10}$$

$$Z_{3D}(5<v_{for}\leqslant 10)=\mathrm{LSTM}^2(\boldsymbol{\omega}_i,\boldsymbol{f}_i) \tag{11}$$

$$Z_{3D}(10<v_{for}\leqslant 15)=\mathrm{LSTM}^3(\boldsymbol{\omega}_i,\boldsymbol{f}_i) \tag{12}$$

$$Z_{3D}(v_{for}>15)=\mathrm{LSTM}^4(\boldsymbol{\omega}_i,\boldsymbol{f}_i) \tag{13}$$

图3说明了所构造的LSTM的内部结构和输入特征，即3d-Nets的内部构造，向量$\boldsymbol{x}(t)$为输入量，其中$\boldsymbol{x}(t)$由特征向量$\boldsymbol{f}_b(t)$、$\boldsymbol{\omega}_b(t)$组成，将最后一层最后的状态值发送到全连接层，经过softmax激活函数之后的输出作为LSTM的输出的最终值，记为$\boldsymbol{v}_b(t)$，由向量$[v_{for}(t)\ v_{lat}(t)\ v_{up}(t)]$组成，其中$N$表示每次输入多少个时刻的训练样本进入网络。图4为3d-Nets预测流程图，$\boldsymbol{v}_{eb}^b$为b系相对于e系的速度在b系下的投影，$\boldsymbol{v}_{eb}^e$为b系相对于e系的速度在e系下的投影，$\boldsymbol{C}_b^e$为b系相对于e系的姿态矩阵。

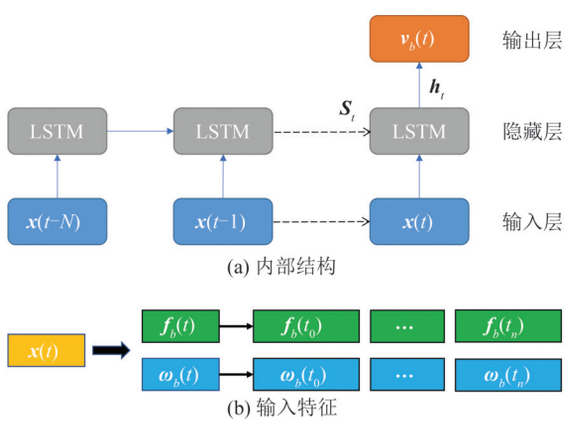


图3 3d-Nets内部结构和输入特征

Fig. 3 3d-Nets Internal Structure and Input Characteristics

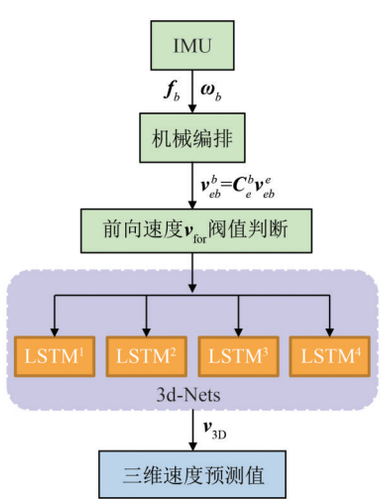


图4 3d-Nets预测流程

Fig. 4 3d-Nets Predictive Flow

本文模型由一个LSTM隐藏层和一个softmax作为激活函数的全连接层组成。在设计3d-Nets网络过程中，需要对隐藏神经元数量和时间步长进行调整。隐藏神经元太多或者时间步长太长，算法会消耗大量时间收敛，还会导致过拟合的现象。本文实验超参数设置见表1。

表1 3d-Nets超参数

Table 1 3d-Nets Hyperparameters

参数	值
学习率	0.005
学习率下降因子	0.5
批量大小	128
历元数	500

1.3 三维速度辅助的GNSS/SINS组合定位模型

EKF常用于组合导航中的参数估计，核心是状态方程和观测方程的确立，其中IMU机械编排、EKF误差反馈等方法和传统GNSS/SINS组合定位一致[19-20]。本小节给出了基于三维速度辅助的GNSS/SINS松组合的状态模型和观测模型。

1.3.1 状态模型

GNSS/SINS松组合定位中，以地心地固系（e系）为导航系，本文采用的定位模型误差状态为$\delta\boldsymbol{x}$：

$$\delta\boldsymbol{x}=\left[\delta\boldsymbol{r}_{eb}^e\quad\delta\boldsymbol{v}_{eb}^e\quad\boldsymbol{\phi}_{eb}^e\quad\delta\boldsymbol{b}_g\quad\delta\boldsymbol{b}_a\right]^{\mathrm{T}} \tag{14}$$

式中，$\delta\boldsymbol{r}_{eb}^e$、$\delta\boldsymbol{v}_{eb}^e$、$\delta\boldsymbol{\phi}_{eb}^e$分别为$b$系相对于$e$系的位置、速度、失准角误差在$e$系的投影；$\delta\boldsymbol{b}_g$、$\delta\boldsymbol{b}_a$分别为陀螺和加速度零偏误差。

误差状态$\delta\boldsymbol{x}$的微分方程为：

$$\delta\dot{\boldsymbol{r}}_{eb}^e=\delta\boldsymbol{v}_{eb}^e+\boldsymbol{\xi}_r \tag{15}$$

$$\delta\dot{\boldsymbol{v}}_{eb}^e=-2\boldsymbol{\omega}_{ie}^e\times\delta\boldsymbol{v}_{eb}^e+\boldsymbol{C}_b^e\boldsymbol{f}^b\times\boldsymbol{\phi}_{be}^e+\boldsymbol{C}_b^e\delta\boldsymbol{b}_a+\delta\boldsymbol{g}^e+\boldsymbol{\xi}_v \tag{16}$$

$$\dot{\boldsymbol{\phi}}_{eb}^e=-\boldsymbol{\omega}_{ie}^e\times\boldsymbol{\phi}_{eb}^e-\boldsymbol{C}_b^e\delta\boldsymbol{b}_g+\boldsymbol{\xi}_\phi \tag{17}$$

$$\delta\dot{\boldsymbol{b}}_g=\boldsymbol{\xi}_{bg} \tag{18}$$

$$\delta\dot{\boldsymbol{b}}_a=\boldsymbol{\xi}_{ba} \tag{19}$$

式中，$\boldsymbol{\omega}_{ie}^e$为地球自转角速度；$\boldsymbol{f}^b$为$b$系加速度；$\boldsymbol{C}_b^e$为$b$系相对于$e$系姿态矩阵；$\delta\boldsymbol{g}^e$为地球重力项；$\boldsymbol{\xi}$为各状态误差的随机游走过程噪声，相应的谱密度参数可通过Allan方差标定或经验给定。

1.3.2 观测模型

松组合GNSS量测更新误差方程为：

$$\boldsymbol{Z}_{GNSS}=\boldsymbol{H}\delta\boldsymbol{x}+\boldsymbol{R}_{GNSS} \tag{20}$$

式中，$\boldsymbol{H}$为设计矩阵；$\boldsymbol{Z}_{GNSS}$为观测新息向量；$\boldsymbol{R}_{GNSS}$为GNSS双差观测值的噪声矩阵，可采用经典高度角随机模型确定。

由于IMU递推位置和GNSS天线往往存在

杆臂，记为 $\boldsymbol{l}^b_{\mathrm{GNSS}}$，表示 GNSS 天线位置相对 IMU 中心在 i 的投影。考虑到杆臂的存在，松组合中观测方程的设计矩阵为：

$$\boldsymbol{H}_P=\begin{bmatrix}\boldsymbol{I} & \boldsymbol{0}_{n\times 3} & (\hat{\boldsymbol{C}}^e_b\boldsymbol{l}^b_{\mathrm{GNSS}})\times & \boldsymbol{0}_{n\times 6} & \boldsymbol{0}_{n\times n}\end{bmatrix} \tag{21}$$

本文在GNSS量测更新的基础上，增加三维速度的量测更新，记 $\boldsymbol{Z}_{3\mathrm{D}}$ 为三维速度量测更新误差，为本文提出的3d-Nets垂向速度和IMU递推出来的速度 $\hat{\boldsymbol{v}}^e_{eb}$ 在 b 系投影的前向、侧向、垂向速度之差，忽略IMU较小安装角影响，IMU在 b 系下前向、侧向、垂向速度即 $\hat{\boldsymbol{v}}^b_{eb}$ 的计算公式为：

$$\hat{\boldsymbol{v}}^b_{eb}=\hat{\boldsymbol{C}}^b_e\hat{\boldsymbol{v}}^e_{eb} \tag{22}$$

NHC量测更新误差方程为：

$$\boldsymbol{Z}_{3\mathrm{D}}=\boldsymbol{H}_{3\mathrm{D}}\delta\boldsymbol{x}+\boldsymbol{R}_{3\mathrm{D}} \tag{23}$$

将式(22)对姿态和速度项进行全微分，可得：

$$\delta\hat{\boldsymbol{v}}^b_{eb}=\boldsymbol{M}_1\delta\boldsymbol{v}^e_{eb}+\boldsymbol{M}_2\boldsymbol{\phi}^e_{eb} \tag{24}$$

式中，$\boldsymbol{M}_1=\hat{\boldsymbol{C}}^b_e$；$\boldsymbol{M}_2=-\hat{\boldsymbol{C}}^b_e\hat{\boldsymbol{v}}^e_{eb}\times$（$\times$ 是反对称阵）。因此，$\boldsymbol{H}_{3\mathrm{D}}$ 的矩阵形式为：

$$\boldsymbol{H}_{3\mathrm{D}}=\begin{bmatrix}\boldsymbol{0}_{1\times 3} & \boldsymbol{M}_1(1,:) & \boldsymbol{M}_2(1,:) & \boldsymbol{0}_{1\times 6}\\ \boldsymbol{0}_{1\times 3} & \boldsymbol{M}_1(2,:) & \boldsymbol{M}_2(2,:) & \boldsymbol{0}_{1\times 6}\\ \boldsymbol{0}_{1\times 3} & \boldsymbol{M}_1(3,:) & \boldsymbol{M}_2(3,:) & \boldsymbol{0}_{1\times 6}\end{bmatrix}$$

式中，$\boldsymbol{M}_1(1,:)$表示 $\boldsymbol{M}_1$ 矩阵第一行，其他类似。

式(23)中 $\boldsymbol{R}_{3\mathrm{D}}$ 为三维速度约束的观测噪声矩阵，依照传统方法通常给定一个经验值。三维速度量测更新时新息 $\boldsymbol{v}_{3\mathrm{D}}$ 为：

$$\boldsymbol{v}_{3\mathrm{D}}=\boldsymbol{H}_{3\mathrm{D}}\hat{\boldsymbol{x}}-\begin{bmatrix}\boldsymbol{v}_{\mathrm{for}}\\ \boldsymbol{v}_{\mathrm{lat}}\\ \boldsymbol{v}_{\mathrm{up}}\end{bmatrix} \tag{25}$$

式中，$\hat{\boldsymbol{x}}$ 为IMU机械编排递推状态；$(\boldsymbol{v}_{\mathrm{for}},\boldsymbol{v}_{\mathrm{lat}},\boldsymbol{v}_{\mathrm{up}})$ 为本文提出的3d-Nets预测三维速度观测值，实际预测结果可能会出现较大的误差，此时传统随机模型鲁棒性较差。本文根据新息 $\boldsymbol{v}_{3\mathrm{D}}$ 可检测出预测值异常，考虑到三维速度约束冗余观测较少，采用不归零的等价权函数来计算三维速度约束噪声自适应调节系数 λ[21]：

$$\lambda_i=\begin{cases}1, |\tilde{\boldsymbol{v}}_{3\mathrm{D}}|_i\leqslant k_0\\ \dfrac{k_0}{|\tilde{\boldsymbol{v}}_{3\mathrm{D}}|_i}, |\tilde{\boldsymbol{v}}_{3\mathrm{D}}|_i>k_0\end{cases} \tag{26}$$

式中，$i=1,2,3$，下标 $i=1$ 对应 $\boldsymbol{v}_{\mathrm{for}}$；$i=2$ 对应 $\boldsymbol{v}_{\mathrm{lat}}$；$i=3$ 对应 $\boldsymbol{v}_{\mathrm{up}}$；$|\tilde{\boldsymbol{v}}_{3\mathrm{D}}|$ 表示标准化新息；k_0 为常数，本文给定为3。自适应动态确定3d-Nets预测三维速度的随机模型为：

$$\boldsymbol{R}_{3\mathrm{D}}[(v_{\mathrm{for}}\leqslant 5),(5<v_{\mathrm{for}}\leqslant 10),(10<v_{\mathrm{for}}\leqslant 15),(v_{\mathrm{for}}>15)]=\gamma\boldsymbol{R}_{3\mathrm{D}} \tag{27}$$

当检测到静态停车状态时，可以对三维速度观测和方差做强约束，进一步提高三维速度约束精度，满足 $\boldsymbol{Z}_{3\mathrm{D}}=0$。相应的随机模型为：

$$\boldsymbol{R}_{3\mathrm{D}}(v_{\mathrm{for}}=0)=\begin{bmatrix}\varepsilon & 0 & 0\\ 0 & \varepsilon & 0\\ 0 & 0 & \varepsilon\end{bmatrix} \tag{28}$$

式中，ε 为三维速度观测噪声，可以给较小值，如0.001。

2　3d-Nets辅助IMU航位推算实验结果和分析

本文采用车载实测数据分别对3d-Nets预测的伪观测量精度以及通过模拟GNSS信号缺失，来验证3d-Nets辅助IMU航位推算性能。

2.1　数据采集

本文采用的设备为NovAtel公司的战术级IMU（iMAR FSAS）和双频GPS接收机（Novatel SPAN-SE），陀螺零偏0.75 °/h，惯导采样频率200 Hz，GNSS采样频率1 Hz。本文的参考结果通过诺瓦泰IE解算软件做GPS RTK/INS紧组合前后向平滑处理获取。

图5给出了IE解算软件紧组合前后向平滑处理获取的轨迹，真值包含了车体高精度的 b 系前向速度、侧向速度和垂向速度，作为训练本文3d-Nets的历史标签数据。

图6给出了本文用于验证3d-Nets以及3d-Nets辅助IMU航位推算性能的车载行驶轨迹，包含多段直行和拐弯状态。

2.2　3d-Nets预测性能

图7给出了3d-Nets验证集数据的预测结果与参考值的对比，包括前向速度 $\boldsymbol{v}_{\mathrm{for}}$、侧向速度 $\boldsymbol{v}_{\mathrm{lat}}$ 和垂向速度 $\boldsymbol{v}_{\mathrm{up}}$。可以看出预测值和参考值均较为符合。此外，在车辆实际行驶中，NHC伪观测量在运动期间并不为零，特别是转弯状态的侧向速度接近0.6 m/s，此时传统NHC约束方法存在较大误差。

对数据集进行分类更有利于不同类的局部特征的提取，本文同时训练了分类和不分类数据集的3d-Nets。图8给出了二者三维速度预测误差的对比，由于考虑车体不同的前向速度，可以更好地捕捉更精细的前向速度的特征信息，所以分类的前向预测结果明显好于未分类的结果，前向预测速度平均精度为0.4 m/s。根据阿克曼旋转定理，NHC和车体运动状态相关，转弯时会产生侧向的速度分量，而且与车体前向速度相互耦

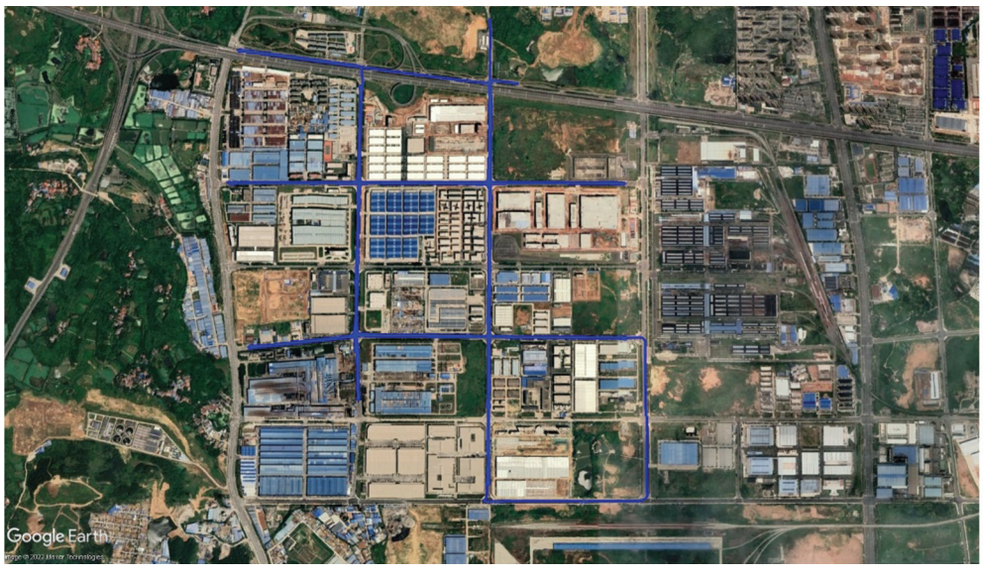


图5 训练集数据对应的车辆行驶轨迹

Fig. 5 Vehicle Trajectory Corresponding to Training Set Data



图6 3d-Nets辅助IMU航位推算的车载行驶轨迹

Fig. 6 Vehicle Travel Trajectory of 3d-Nets-Aided IMU Dead Reckoning

合,所以基于速度分类的3d-Nets侧向预测结果明显好于未分类的结果,侧向预测速度平均精度为2.4 cm/s。对于垂向速度,本文所选路段基本为平整路段,车体没有剧烈的上下震动,所以分类与不分类的结果差异不大,垂向预测平均精度为2.1 cm/s。由于车体前向速度相对于侧向和垂向速度变化更快,所以前向预测误差精度低于侧向和垂向。

2.3 IMU航位推算定位性能验证

为了验证本文提出的3d-Nets自适应辅助IMU航迹推算的优越性,对图4路段模拟了460 s GNSS信号中断,包含多段直行和转弯状态。针对此路段,设计6种不同的实验方案,如表2所示,其中方案1只采用IMU航迹推算;方案2采用了传统NHC约束方法,即侧向和垂向速度假设为0,标准差给定为0.2 m;方案3增加了未进行基于速度分类的3d-Nets预测的侧向和垂向观测量做NHC约束,结合图9反映的NHC预测精度,标准差给定为0.05 m;方案4增加了基于速度分类的3d-Nets预测的侧向和垂向观测量做NHC约束,标准差给定为0.05 m;方案5增加了本文基于速度分类的3d-Nets预测的观测量做三维速度约束,标准差给定为0.05 m;方案6在方案5的基础上,根据了式(26)~(28)自适应调整$\boldsymbol{R}_{3D}$。

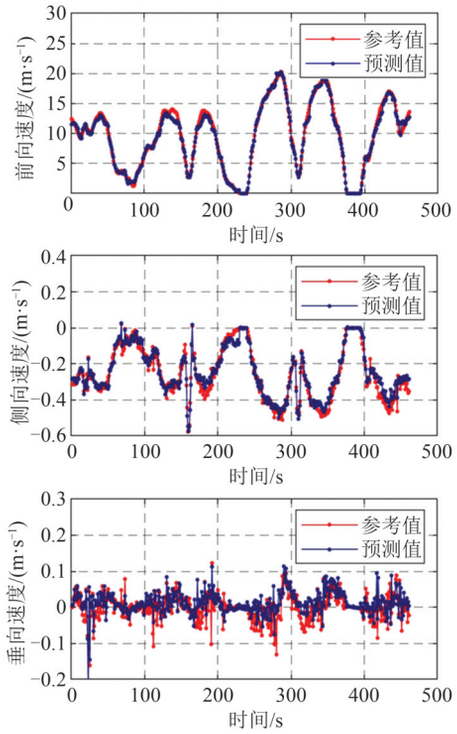


图 7　3d-Nets预测结果和参考结果的比较

Fig. 7　Comparison of 3d-Nets Predictive Results and Reference Value

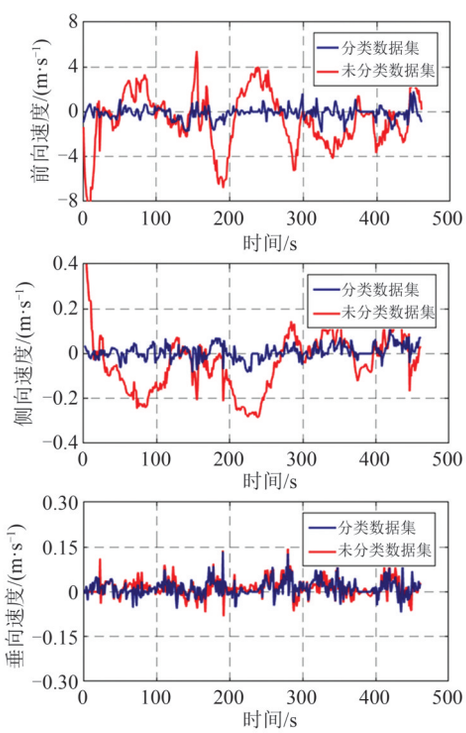


图 8　速度分类预测和直接预测的3d-Nets预测误差比较

Fig. 8　Comparison of Speed Classification-Based and Direct Prediction 3d-Nets Predictive Errors

图 9 给出了 6 种不同方案对应的车辆平面运行轨迹和真值的对比,从运行结束位置对比可以发现:不采用 NHC 约束的方案 1 对应的 IMU 定位结果漂移较大,主要由于长时间卫星失锁,没有外部信息约束,其定位误结果很快发散;而采用 NHC 约束的方案 2 定位性能相较于不采用 NHC 约束有很大提升;方案 3 相对于方案 2 结果验证了利用机器学习预测 NHC 伪观测量,如果预测伪观测量精度比较差,定位性能不如传统直接给 0 的方法;方案 4 相对于方案 3 和方案 2 的结果说明了当利用机器学习进行回归预测时,基于速度分类可进一步提高其预测精度,且利用 3d-Nets 预测 NHC 伪观测量比传统给 0 的方法更合理。图 10 为方案 4、方案 5 和方案 6 的局部放大图,方案 5 相对于方案 4 的结果验证了当利用三维速度进行速度全约束时,由于增加了前向速度的约束,一定程度可以起到 ODO 的作用,可以进一步抑制惯导误差的积累,方案 6 相对于方案 5 结果说明了利用三维速度约束时,采用自适应的随机模型更能反映观测噪声的真实水平,可进一步提高约束性能。

表 2　6种方案数据处理策略

Table 2　Data Processing Strategy of 6 Different Schemes

方案	NHC (0,0)	未分类 NHC(v_{lat},v_{up})	分类 NHC(v_{lat},v_{up})	分类 3d-Nets	$\boldsymbol{R}_{3D}$ 自适应
方案 1	×	×	×	×	×
方案 2	√	×	×	×	×
方案 3	×	√	×	×	×
方案 4	×	×	√	×	×
方案 5	×	×	×	√	×
方案 6	×	×	×	√	√

为了进一步验证基于速度约束的 3d-Nets 和 NHC 的定位性能,图 11 给出了方案 4、方案 5 和方案 6 定位误差对比情况。在卫星失所的 460 s 内,车体在 0～110 s 往西行驶,110～400 s 南北方向行驶,400 s 之后往西行驶。0～110 s 3 种方案都进行了侧向的速度约束,3 种方案在北(north,N)方向上定位误差差距不大。而方案 5 和方案 6 增加了前向的速度约束,车体的前向误差不会快速积累,所以方案 5 和方案 6 相对于方案 4 在东(east,E)方向上的定位性能更好,由于方案 6 采用自适应调整伪观测的方差,方案 6 相比于方案 5 更能抑制惯导误差积累;110～400 s 车体往南北方向行驶,方案 4 缺乏前向的约束,导致 N 方向定位误差积累,而 E 方向由于有侧向速度的约束,所以 E 方向误差发散速度有所缓解;400 s 之后,方案 4 由于车体往西行驶,N 方向有了侧向速度的约束,E 方向由于缺乏前向速度约束,所以 N 方向



图9 6种不同方案和参考的平面轨迹

Fig. 9 Vehicle Plane Trajectory of 6 Different Schemes and Ground Truth



图10 3种不同方案和参考的平面轨迹局部放大图

Fig. 10 Partial Enlarged View of 3 Different Schemes and Reference Plane Trajectories

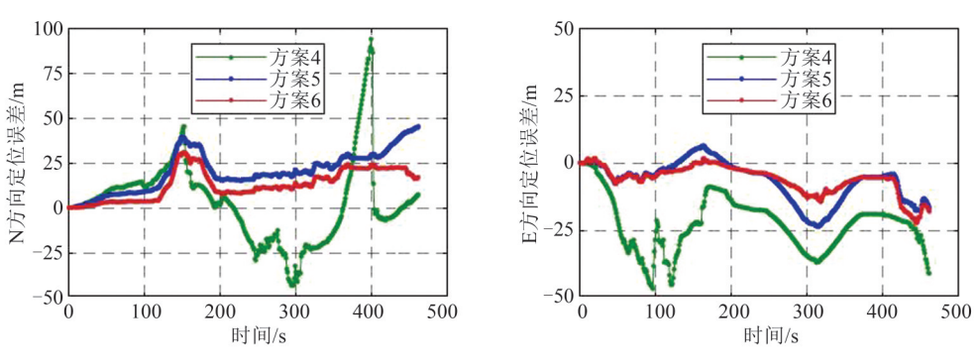


图11 3种不同方案N方向和E方向的定位误差

Fig. 11 Lateral and Forward Positioning Errors for 3 Different Schemes

误差相对于E方向误差发散缓慢。

为了定量地分析以上6种不同数据的处理方案,表3统计6种不同方案对应的车辆平面定位精度以及各种方案提升比率。方案3相对于方案2是负提升,说明如果NHC伪观测预测不准确,会影响组合导航定位精度,细化预测模型具有一定意义;方案4、方案5、方案6效果依次提升;方案6在GNSS信号缺失460 s时,仍保持了34.58 m的定位精度,对于IMU定位性能提升非常显著,较好地抑制了IMU误差发散引起的定位漂移。

表 3　6种不同方案的定位结果

Table 3　Positioning Results of 6 Different Schemes

方案	平面误差/m	提升率/%
方案1	5 828.48	
方案2	94.52	98.37
方案3	116.64	−18.98
方案4	67.97	41.72
方案5	50.06	26.34
方案6	34.58	30.92

3　结　语

本文提出了一种提升车载GNSS/SINS组合定位性能的新方法。首先对车辆速度进行分类，在此基础上研究了一种基于速度分类的3d-Nets，可对车辆行驶过程的三维速度伪观测量进行预测，然后采用三维速度自适应辅助GNSS/SINS车载定位的方法，通过车载实测数据开展了验证，得出如下结论：

1）相对于传统只预测虚拟NHC或者虚拟里程计的方法，本文提出的基于车辆速度分类的3d-Nets，能够同时预测车体的前向、侧向和垂向的速度，因为顾及了车辆的运动状态，LSTM神经网络能够更好地捕捉车辆速度的特征信息，所以预测精度相较于传统的方法有所提高。

2）相对于传统GNSS/SINS车载定位方法，经过本文基于速度分类3d-Nets预测的三维速度自适应约束GNSS/SINS定位方法，通过做速度的全约束以及自适应调整伪观测值的方差，可较好地抑制定位结果发散，保持相对较好的航位推算精度。

参　考　文　献

[1] 雷哲哲，黄观文，杜源，等．低成本U-blox模块的单频GPS/BDS增强PPP定位性能分析[J]．导航定位与授时，2019，6(1)：74-80.
LEI Zhezhe，HUANG Guanwen，DU Yuan，et al. Single Frequency GPS/BDS Enhanced PPP Positioning Performance Analysis of Low Cost U-blox Module[J]. *Navigation Positioning and Timing*，2019，6(1)：74-80.

[2] 李彦杰，杨元喜，何海波．附加约束条件对GNSS/INS组合导航结果的影响分析[J]．武汉大学学报(信息科学版)，2017，42(9)：1249-1255.
LI Yanjie，YANG Yuanxi，HE Haibo. Effects Analysis of Constraints on GNSS/INS Integrated Navigation[J]. *Geomatics and Information Science of Wuhan University*，2017，42(9)：1249-1255.

[3] 高周正．多模GNSS PPP/INS组合系统算法与应用研究[D]．武汉：武汉大学，2016.
GAO Zhouzheng. Reserach on the Methodology and Applicationg of the Intergration Between the Multi-constellation GNSS PPP and Inertial Navigation System[D]. Wuhan：Wuhan University，2016.

[4] NIU X J，NASSAR S，EL-SHEIMY N. An Accurate Land-Vehicle MEMS IMU/GPS Navigation System Using 3D Auxiliary Velocity Updates[J]. *Navigation*，2007，54(3)：177-188.

[5] DISSANAYAKE G，SUKKARIEH S，NEBOT E，et al. The Aiding of a Low-Cost Strapdown Inertial Measurement Unit Using Vehicle Model Constraints for Land Vehicle Applications[J]. *IEEE Transactions on Robotics and Automation*，2001，17(5)：731-747.

[6] NIU X J，LI Y，ZHANG Q，et al. Observability Analysis of Non-holonomic Constraints for Land-Vehicle Navigation Systems[J]. *Journal of Global Positioning Systems*，2012，11(1)：80-88.

[7] 邓玥，余江，郭文飞，等．信号遮挡环境下融合TOA/AOD的5G/SINS组合导航算法模型与精度分析[J]．武汉大学学报(信息科学版)，2022，47(7)：1133-1139.
DENG Yue，YU Jiang，GUO Wenfei，et al. Modeling and Accuracy Analysis of TOA/AOD Based 5G/SINS Integrated Navigation in Case of Signal Blockage[J]. *Geomatics and Information Science of Wuhan University*，2022，47(7)：1133-1139.

[8] VENERI M，MASSARO M. The Effect of Ackermann Steering on the Performance of Race Cars[J]. *Vehicle System Dynamics*，2021，59(6)：907-927.

[9] WEN Z Y，YANG G L，CAI Q Z. An Improved SINS/NHC Integrated Navigation Algorithm Based on Ackermann Turning Geometry[J]. *Measurement*，2022，192：110859.

[10] CHEN Q J，ZHANG Q，NIU X J. Estimate the Pitch and Heading Mounting Angles of the IMU for Land Vehicular GNSS/INS Integrated System[J]. *IEEE Transactions on Intelligent Transportation Systems*，2021，22(10)：6503-6515.

[11] BROSSARD M，BARRAU A，BONNABEL S. AI-IMU Dead-Reckoning[J]. *IEEE Transactions on Intelligent Vehicles*，2020，5(4)：585-595.

[12] TANG H L，NIU X J，ZHANG T S，et al. ODO-Net：Untethered Speed Aiding for Vehicle Navigation Without Hardware Wheeled Odometer[J]. *IEEE Sensors Journal*，2022，22(12)：12197-12208.

[13] FEIGL T，KRAM S，WOLLER P，et al. A Bidirectional LSTM for Estimating Dynamic Human Ve-

locities from a Single IMU[C]//International Conference on Indoor Positioning and Indoor Navigation, Pisa, Italy, 2019.

[14] WAGSTAFF B, KELLY J. LSTM-Based Zero-Velocity Detection for Robust Inertial Navigation [C]//International Conference on Indoor Positioning and Indoor Navigation , Nantes, France, 2018.

[15] SALEH K, HOSSNY M, NAHAVANDI S. Intent Prediction of Vulnerable Road Users from Motion Trajectories Using Stacked LSTM Network [C]//The 20th International Conference on Intelligent Transportation Systems, Yokohama, Japan, 2017.

[16] GRAVES A, MOHAMED A R, HINTON G. Speech Recognition with Deep Recurrent Neural Networks [C]//IEEE International Conference on Acoustics, Speech and Signal Processing, Vancouver, BC, Canada, 2013.

[17] 陆继翔, 张琪培, 杨志宏, 等. 基于CNN-LSTM混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(8): 131-137.
LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-Term Load Forecasting Method Based on CNN-LSTM Hybrid Neural Network Model [J]. *Automation of Electric Power Systems*, 2019, 43(8): 131-137.

[18] SKOG I, HÄNDEL P, NILSSON J O, et al. Zero-Velocity Detection: An Algorithm Evaluation[J]. *IEEE Transactions on Bio-medical Engineering*, 2010, 57(11): 2657-2666.

[19] ZHANG X H, ZHU F, TAO X L, et al. New Optimal Smoothing Scheme for Improving Relative and Absolute Accuracy of Tightly Coupled GNSS/SINS Integration [J]. *GPS Solutions*, 2017, 21(3): 861-872.

[20] 严恭敏, 翁浚. 捷联惯导算法与组合导航原理[M]. 西安: 西北工业大学出版社, 2019.
YAN Gongmin, WENG Jun. Strapdown Inertial Navigation Algorithm and Principle for Integrated Navigation[M]. Xi'an: Northwestern Polytechnical University Press, 2019.

[21] 杨元喜. 自适应动态导航定位[M]. 北京: 测绘出版社, 2006.
YANG Yuanxi. Adaptive Navigation and Kinematic Positioning[M]. Beijing: Sino Maps Press, 2006.