



武汉大学学报(信息科学版)

Geomatics and Information Science of Wuhan University

ISSN 1671-8860, CN 42-1676/TN

## 《武汉大学学报(信息科学版)》网络首发论文

题目: 基于速度分类的 LSTM 神经网络辅助 GNSS/SINS 车载定位方法  
作者: 李晗旭, 李昕, 黄观文, 张勤, 陈世鹏  
DOI: 10.13203/j.whugis20230061  
收稿日期: 2023-12-25  
网络首发日期: 2024-01-24  
引用格式: 李晗旭, 李昕, 黄观文, 张勤, 陈世鹏. 基于速度分类的 LSTM 神经网络辅助 GNSS/SINS 车载定位方法[J/OL]. 武汉大学学报(信息科学版).  
<https://doi.org/10.13203/j.whugis20230061>



**网络首发:** 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

**出版确认:** 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

DOI:10.13203/j.whugis20230061

引用格式：李晗旭，李昕，黄观文，等. 基于速度分类的 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),2024,DOI: 10.13203/j.whugis20230061 (LI Hanxu, LI Xin, HUANG Guanwen, et al.TU Jianguang,et al. LSTM Neural Network Assisted GNSS/SINS Vehicle Positioning Based on Speed Classification [J].Geomatics and Information Science of Wuhan University,2024,DOI: 10.13203/j.whugis20230061)

## 基于速度分类的 LSTM 神经网络辅助 GNSS/SINS 车载定位方法

李晗旭<sup>1</sup> 李昕<sup>1</sup> 黄观文<sup>1</sup> 张勤<sup>1</sup> 陈世鹏<sup>1</sup>

<sup>1</sup> 长安大学 地质工程与测绘学院, 陕西 西安, 710054

**摘要：**在车载 GNSS/SINS 组合导航中，为了增强定位效果，车辆非完整性约束(NHC)是常用的增强方法。通过应用机器学习的方法来建立 IMU 输出与 NHC 伪观测量之间的复杂映射关系，并直接在观测域对 NHC 伪观测量的大小进行调整，可以提升传统 NHC 方法的约束效果。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 (ODO)。然而，当前研究主要是将预测虚拟 NHC 和虚拟 ODO 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的能力。因此，本文的研究针对这一问题进行了深入探讨，提出了一种基于车辆速度分类的 LSTM 神经网络，用于预测车辆的三维速度，并采用三维速度约束新息来自适应调整其方差域。为了验证本文方法的有效性，进行了车载 GNSS/SINS 组合导航的实验测试。根据实验结果显示，本文方法在前向速度预测方面的平均精度约为 0.4 m/s，在侧向和垂向速度预测方面平均精度约为 2 cm/s，此外，在模拟 GNSS 信号失锁 460 秒的情况下，相较于惯导推算结果，本文方法在三维速度约束下的水平定位精度改善了 99.40%。

**关键词：**GNSS/SINS, NHC, ODO, 机器学习, LSTM

中图法分类号：P228

文献标识码：A

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

LI Hanxu<sup>1</sup> LI Xin<sup>1</sup> HUANG Guanwen<sup>1</sup> ZHANG Qin<sup>1</sup> CHEN Shipeng<sup>1</sup>

<sup>1</sup> School of Geological Engineering and Geomatics, Chang'an University, Xi'an 710054, China

**Abstract:** Vehicular Non-holonomic constraint (NHC) is a commonly used enhancement technique in combined vehicle-mounted GNSS/SINS navigation in order to enhance the positioning effect. The constraint effect of traditional NHC methods is enhanced by applying machine learning methods to establish a complex mapping relationship between IMU outputs and NHC pseudo-observations, and to adjust the size of NHC pseudo-observations directly in the observation domain. Existing machine learning methods do not consider the influence of vehicle motion state, resulting in poor NHC prediction

收稿日期：2023-12-25

项目资助：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 (42004023)；科技部重点研发计划 (2021YFB2600603)。

第一作者：李晗旭，硕士，主要从事 GNSS/SINS 组合导航。957188494@qq.com

通讯作者：李昕，博士，副教授。lixin2017@chd.edu.cn

accuracy and reliability. Recent studies have shown that machine learning can predict the forward speed of vehicles, i.e., virtual odometry(ODO). However, current research mainly discusses predicting virtual NHC and virtual odometry separately, without fully exploring the coupling relationship between the two and the ability of 3D speed to fully constrain the vehicle. Therefore, the study in this paper addresses this issue in depth and proposes an LSTM neural network based on vehicle speed classification for predicting the 3D speed of a vehicle and self-adaptively adjusting its variance domain using 3D speed constraints on the new interest. In order to verify the effectiveness of this paper's method, an experimental test of vehicle-mounted GNSS/SINS combined navigation is carried out. According to the experimental results, the average accuracy of this paper's method in forward velocity prediction is about 0.4 m/s, and the average accuracy in lateral and vertical velocity prediction is about 2 cm/s. In addition, in the case of simulated GNSS signals being out-of-lock for 460 seconds, compared with the inertial derivation results, this paper's method improves the horizontal localization accuracy under the three-dimensional velocity constraint by 99.40%.

**Key words:**GNSS/SINS, NHC, ODO, machine learning, LSTM

## 0. 引言

研究表明, 全球卫星导航系统 (GNSS) 可以在广阔环境中提供厘米级的导航定位服务<sup>[1]</sup>, 由于 GNSS 本身特点, 单一传感器容易受到周围环境的干扰, 为了提高其定位性能, 目前研究集中在将具备自主导航和强抗干扰能力的 SINS 与 GNSS 进行组合, 这种组合具有很大的研究价值<sup>[2]</sup>. 该组合系统实现了优势互补. 然而, 在高楼林立的城市环境中, 由于频繁失锁的 GNSS 信号, 该组合系统也会频繁退化为 SINS 独立工作的系统, 导致载体定位效果明显变差<sup>[3]</sup>. 在缺乏 GNSS 辅助的情况下, 如何有效提高 IMU 的递推效果是一个即要解决的问题, 也是实现各种场景无缝切换的重要一步. 得益于 ODO、NHC 低成本和易获取等优点, 为解决这个问题提供了思路<sup>[4]</sup>. 以往的研究通常将载体侧向速度和垂直速度置为零, 并将其视为虚拟观测数据. 根据经验, 我们可以为其分配一个相对保守的方差值, 从而在某种程度上提升惯性导航递推位置的准确性<sup>[5]</sup>. 实际上由与 IMU 安装角的存在, 以及车体在进行复杂的动作, 例如侧滑和弹跳等, 载体侧向速度与垂向速度并不为零<sup>[6]</sup>. 此外, 依据阿克曼原理, 载体在转弯过程中不可避免的会引起侧向速度分量, 而且这与前向速度和转弯幅度有一定的相关性<sup>[7,8]</sup>. 因此, 载体运行过程中, 要获得准确的 NHC 伪观测值不仅与要考虑 IMU 的安装位置, 还要考虑载体的实际运动状态, 特别是载体的前向速度的变化<sup>[9-10]</sup>.

除了以上提到的传感器组合和车辆运动约束的方法, 学者们还尝试使用智能算法直接通过惯导特征来预测位置误差, 通过在 GNSS 观测条件良好的情况下训练生成模型, 在 GNSS 观测缺失的场景用生成模型的预测位置误差用于补偿惯导推算结果, 进一步提升复杂场景定位的可靠性<sup>[10]</sup>. 文献<sup>[11]</sup>首次尝试采用智能算法, 智能学习 IMU 输出与 NHC 观测方差之间的复杂映射关系. 通过自动配置最优参数, 成功有效抑制了惯性递推误差的积累. 在文献<sup>[12]</sup>中, 尝试了一种基于卷积神经网络构建虚拟里程计网络的方法, 该网络利用历史 IMU 数据进行估计, 以获取车辆的前向速度, 其扮演真实里程计的角色, 在复杂环境下辅助 GNSS 导航定位. 从观测域的角度分析, 文献<sup>[10]</sup>提出了一种多元回归和深度学习方法对载体信息预测, 再次充分挖掘载体本身的约束信息, 使其最终接近真实状态, 具有较好的效果. 目前的研究主要着眼于独立讨论预测虚拟 NHC 和虚拟 ODO 的方法, 且训练网络没有顾及载体运动状态, 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.

基于上述背景，本文旨在训练一个综合考虑前向速度影响且能同时预测 NHC 和 ODO 的 LSTM 模型。为了建立该模型，本文对历史数据进行高精度后处理，其结果作为训练集。首先，根据不同的前向速度进行分类，针对不同的分类结果训练载体三维速度网络模型。在 GNSS 观测缺失的场景，利用已经生成的模型预测虚拟 NHC 和 ODO 观测值为载体提供三维约束信息。这种方法考虑到载体运动状态的影响，能够更好地提取三维速度的特征信息，并且采用了三维速度全约束的方式，并且在此基础上，又采用基于新息残差的自适应随机模型，与传统的 NHC 约束对比，惯导递推误差的抑制效果更加显著。

## 1. 方法介绍

在本节中，首先对 LSTM 神经网络的结构进行了介绍。随后，提出了一种基于速度分类的 LSTM 神经网络，并描述了其设计过程。最后，提出了一种基于预测的三维速度自适应辅助 GNSS/SINS 组合定位模型。

### 1.1 LSTM 神经网络结构

当前，递归神经网络在基于预测序列的任务中得到广泛应用。该领域研究多集中在基于惯性原件的行人导航方面，如行人运动模式的智能识别，行人运动模式识别辅助行人航迹推算 (PDR) 算法等<sup>[13-14]</sup>。相较于最基本的前馈神经网络模型，基本的 RNN 在结构上与其不同。RNN 通过循环的方式实现信息的持续传递。在图 1 中，传统的链式结构 RNN 与处理序列和列表相关，但在处理长期依赖关系方面存在一定的不足<sup>[15]</sup>。作为一种特殊类型的 RNN 长短记忆神经网络 (LSTM) 具有解决长期依赖性问题的能力，其结构如图 2 所示。

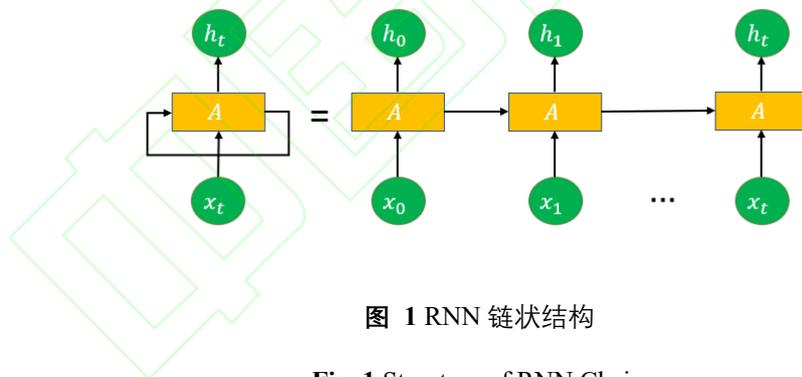


图 1 RNN 链状结构

Fig. 1 Structure of RNN Chain

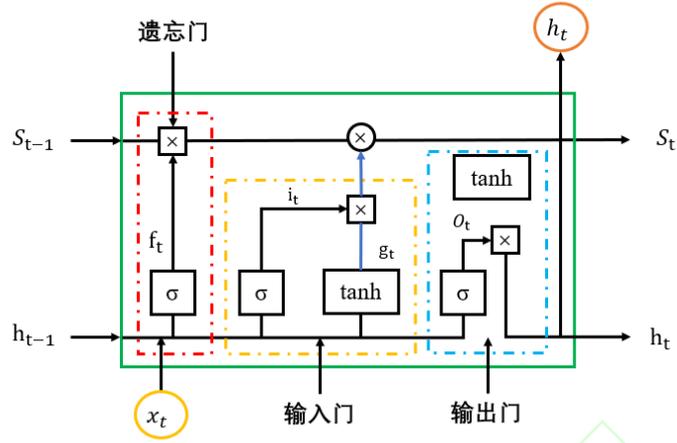


图 2 LSTM 结构

Fig. 2 Structure of LSTM

LSTM 的核心思想是引入门控机制来控制信息的流动和记忆的更新，它通过三个主要的门控单元来实现，图 2 中红色虚线部分  $f_t$  代表遗忘门， $S_t$  代表单元状态值， $x_t$  代表输入向量， $h_t$  代表中间状态；黄色虚线部分  $i_t$  代表输入门， $g_t$  代表输入节点， $\sigma$  和  $\tanh$  代表激活函数，其有助于避免梯度爆炸或梯度消失等问题；蓝色虚线部分  $g_t$  为输出门； $t$  和  $t-1$  代表当前时刻和上一时刻<sup>[16-17]</sup>。综上所述可以将 LSTM 单元内部计算公式总结如式(1)-(6)。

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \quad (1)$$

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \quad (2)$$

$$g_t = \phi(W_{gx}x_t + W_{gh}h_{t-1} + b_g) \quad (3)$$

$$o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (4)$$

$$S_t = g_t \odot i_t + S_{t-1} \odot f_t \quad (5)$$

$$h_t = \phi(S_t) \odot o_t \quad (6)$$

## 1.2 基于车辆速度分类的 LSTM 神经网络(3d-Nets)

为了提高机器学习多元回归的准确性，一般采用对数据进行分类的方法。在本文中，我们采用高精度后处理的速度结果作为训练集，以及采用 SINS 编排的结果作为测试集车辆速度判定的依据。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、 $v_{for} \leq 5$ 、 $5 < v_{for} \leq 10$ 、 $10 < v_{for} \leq 15$ 、 $v_{for} > 15$ ，根据不同分类结果来构建一种基于车辆速度分类的 LSTM 神经网络。

本文为了提高零速检测的正确率采用角速度幅值检测、加速度幅值检测 (ARDE、AMD) 两种方法同时进行静态检测，根据陀螺和加速度计的输出只有同时通过两个检测器的检验，才能对车体的零速状态做出判断<sup>[18]</sup>，其中两个检测器  $T_k$  和  $T_m$  的表达式如下

$$\begin{cases} T_k(\boldsymbol{\omega}) = \frac{1}{W} \sum_{i=k}^{k-W+1} \|\boldsymbol{\omega}_i\|^2 \\ T_m(\mathbf{a}) = \frac{1}{\sigma_a^2 W} \sum_{i=k}^{k-W+1} \left( \frac{1}{\sigma_a^2} \left\| \mathbf{a}_i - \mathbf{g} \frac{\bar{\mathbf{a}}}{\|\bar{\mathbf{a}}\|} \right\| \right) \end{cases} \quad (7)$$

上式中,  $W$ 表示窗口大小, 在本文中给 10,  $\boldsymbol{\omega}$ 和 $\mathbf{a}$ 分别表示 IMU 速度和比力输出,  $\bar{\mathbf{a}}$ 窗口内平均加速度值,  $\sigma_a^2$ 为比力观测值方差,  $\mathbf{g}$ 为当地重力加速度,  $\gamma$ 、 $\xi$ 通常给一个固定的阈值, 如果上式同时满足如下要求, 则认为载体处于静止状态。

$$v_{for} = 0 \quad , \quad if: T_k(\boldsymbol{\omega}) \leq \gamma \quad and \quad T_m(\mathbf{a}) \leq \xi \quad (8)$$

载体系 (b 系) 的三维速度 $\mathbf{V}_{3d} = (v_{for}, v_{lat}, v_{up})$ 为对载体做速度全约束的虚拟观测值, 当系统检测到静态时 ( $v_{for} = 0$ ), 采用如下公式对速度状态进行强约束。

$$\mathbf{V}_{3d}(v_{for} = 0) = (0, 0, 0) \quad (9)$$

本文设计了以惯导 6 轴观测量为输入的 LSTM 网络, 通过对历史数据做高精度后处理得到载体系的前向速度、侧向速度和垂向速度, 将其作为数据标签。根据不同训练集得到网络 3d-Nets= $\{LSTM^1, LSTM^2, LSTM^3, LSTM^4\}$ 。其中,  $LSTM^1$ 对应于 $v_{for} \leq 5$ 的数据集训练的网络,  $LSTM^2$ 对应于 $5 < v_{for} \leq 10$ 的据集训练的网络,  $LSTM^3$ 对应于 $10 < v_{for} \leq 15$ 的数据集训练的网络,  $LSTM^4$ 对应于 $v_{for} > 15$ 的数据集训练的网络。 $\mathbf{V}_{3d}$ 和 3d-Nets 的关系如下。

$$\mathbf{V}_{3d}(v_{for} \leq 5) = LSTM^1(\{\boldsymbol{\omega}_i, \mathbf{f}_i\}) \quad (10)$$

$$\mathbf{V}_{3d}(5 < v_{for} \leq 10) = LSTM^2(\{\boldsymbol{\omega}_i, \mathbf{f}_i\}) \quad (11)$$

$$\mathbf{V}_{3d}(10 < v_{for} \leq 15) = LSTM^3(\{\boldsymbol{\omega}_i, \mathbf{f}_i\}) \quad (12)$$

$$\mathbf{V}_{3d}(v_{for} > 15) = LSTM^4(\{\boldsymbol{\omega}_i, \mathbf{f}_i\}) \quad (13)$$

图 3 展示了所构建 LSTM 模型的内部结构和输入特征, 即 3d-Nets 的内部构造, 向量 $x(t)$ 为输入量, 由特征向量 $\{f_b(t), \omega_b(t)\}$ 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。然后将隐藏层最后一层的状态值传递到全连接层, 经过 softmax 激活函数, 输出最终结果, 记为  $v_b(t)$ , 由向量 $\{v_{for}(t), v_{lat}(t), v_{up}(t)\}$ 组成。图 4 为 3d-Nets 预测流程图。

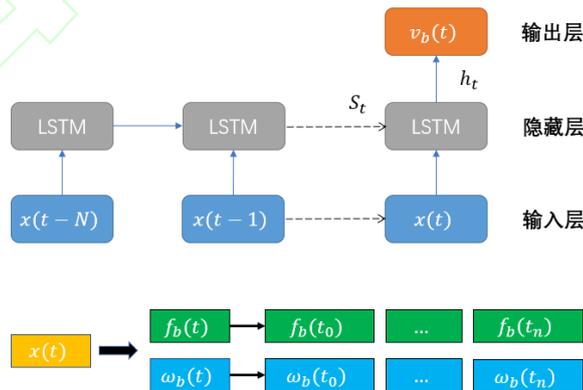


图 3 3d-Nets 内部结构和输入特征

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

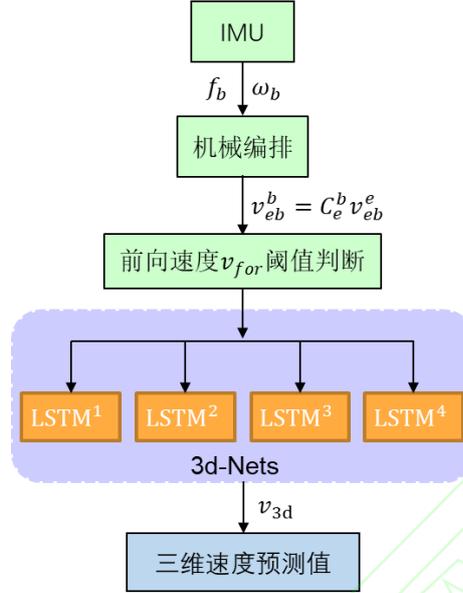


图 4 3d-Nets 预测流程

Fig. 4 3d-Nets Predictive Flow

在本文的模型中，采用了一个 LSTM 隐藏层和一个全连接层，其中激活函数为 softmax。在设计 3d-Nets 模型时，需要仔细调整隐藏神经元的数量和时间步长。如果隐藏神经元数量过多或时间步长过长，算法会花费更多时间来收敛，而且可能会导致过拟合问题。为了避免这些情况，本研究进行了一系列实验，调整了超参数的设置，具体设置可参见表 1。

表 1 3d-Nets 超参数

Tab.1 3d-Nets Hyperparameters

Parameters	Value
Learning rate	0.005
Learning rate decay factor	0.5
Batch size	128
Epochs	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 误差反馈等方法与传统 SINS/GNSS 组合定位一致<sup>[19-20]</sup>。本小节重点给出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 组合导航算法通常采用误差状态扩展卡尔曼滤波，通常将导航信息误差来作为卡尔曼滤波的状态，其状态向量为  $\delta \mathbf{x}$ ，具体包括

$$\delta \mathbf{x} = [\delta \mathbf{r}_{eb}^e \quad \delta \mathbf{v}_{eb}^e \quad \delta \boldsymbol{\phi}_{eb}^e \quad \delta \mathbf{b}_g \quad \delta \mathbf{b}_a]^T \quad (14)$$

其中， $\delta \mathbf{r}_{eb}^e, \delta \mathbf{v}_{eb}^e, \delta \boldsymbol{\phi}_{eb}^e$  分别代表载体的位置、速度、失准角误差相对于 b 系在 e 系下的投影， $\delta \mathbf{b}_g, \delta \mathbf{b}_a$  分别代表陀螺和加速度零偏误差。

$\delta \mathbf{x}$  的微分方程表示如下：

$$\delta \mathbf{r}_{eb}^e = \delta \mathbf{v}_{eb}^e + \boldsymbol{\xi}_r \quad (15)$$

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

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

$$\delta \mathbf{b}_g = \boldsymbol{\xi}_{bg} \quad (18)$$

$$\delta \mathbf{b}_a = \boldsymbol{\xi}_{ba} \quad (19)$$

上式中， $\boldsymbol{\omega}_{ie}^e$ 为e系相对于i系的角速度，即地球自转角速度在e系下的投影， $\mathbf{f}^b$ 为IMU加速度计测量的比力信息， $\delta \mathbf{g}^e$ 代表地球重力加速度误差在e系下的投影， $\mathbf{C}_b^e$ 为代表b系到e系的旋转矩阵， $\boldsymbol{\xi}$ 为各状态误差的随机游走过程噪声。

### 1.3.2 观测模型

一般情况，松组合观测误差方程可表示为

$$\mathbf{Z}_{GNSS} = \mathbf{H} \delta \mathbf{x} + \mathbf{R}_{GNSS} \quad (20)$$

其中， $\mathbf{H}$ 为设计系数矩阵， $\mathbf{Z}_{GNSS}$ 为观测新息向量。 $\mathbf{R}_{GNSS}$ 为松组合观测噪声向量。GNSS/SINS 松组合的设计系数矩阵可表示为

$$\mathbf{H}_P = [\mathbf{I} \quad \mathbf{0}_{n \times 3} \quad (\hat{\mathbf{C}}_b^e \mathbf{l}_{GNSS}^b) \times \quad \mathbf{0}_{n \times 6} \quad \mathbf{0}_{n \times n}] \quad (21)$$

其中， $\mathbf{l}_{GNSS}^b$ 表示在b系中GNSS解算结果参考中心相对IMU量测中心的位置误差，称为组合导航中的杆臂误差。

本文在GNSS/SINS做完EKF融合后，继续用所预测的三维速度与滤波后的结果融合，该过称为三维速度量测更新，其误差方程如下式

$$\mathbf{Z}_{3d} = \mathbf{H}_{3d} \delta \mathbf{x} + \mathbf{R}_{3d} \quad (22)$$

上式中， $\mathbf{Z}_{3d}$ 为三维速度量测更新误差。该误差是由本文提出的3d-Nets预测的前向、侧向和垂向速度与IMU递推得到的速度 $\hat{\mathbf{v}}_{eb}^e$ 在b系投影的前向、侧向和垂向速度之差，在载体行驶过程中考虑较小安装角的影响，所以IMU在b系中的速度 $\hat{\mathbf{v}}_{eb}^b$ 可以通过下式求得

$$\hat{\mathbf{v}}_{eb}^b = \hat{\mathbf{C}}_e^b \hat{\mathbf{v}}_{eb}^e \quad (23)$$

通过对上式求偏导

$$\delta \hat{\mathbf{v}}_{eb}^b = \mathbf{M}_1 \delta \mathbf{v}_{eb}^e + \mathbf{M}_2 \boldsymbol{\phi}_{eb}^e \quad (24)$$

其中， $\mathbf{M}_1 = \hat{\mathbf{C}}_e^b$ ， $\mathbf{M}_2 = -\hat{\mathbf{C}}_e^b \hat{\mathbf{v}}_{eb}^e \times$ ，因此设计系数矩阵 $\mathbf{H}_{3d}$ 表示为

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

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

在式(22)中 $\mathbf{R}_{3d}$ 为噪声矩阵，依照传统方法一般设定为一个较小的固定的经验值。三维速度量测更新时新息残差 $\mathbf{v}_{3d}$ 表示为

$$\mathbf{v}_{3d} = \hat{\mathbf{v}}_{eb}^b - \mathbf{V}_{3d} \quad (25)$$

上式中, 用 3d-Nets 模型对  $V_{3d}$  预测时可能会出现较大的误差, 那么传统设定随机模型的方法将不再适用。本文通过新息残差  $v_{3d}$  来检测预测值的异常, 由于三维速度约束冗余观测量比较少, 采用两段权函数模型调节  $\lambda_i$  [21]

$$\lambda_i = \begin{cases} 1 & |\tilde{v}_{3d}| \leq k_0 \\ \frac{k_0}{|\tilde{v}_{3d}|} & |\tilde{v}_{3d}| > k_0 \end{cases} \quad (26)$$

上式中,  $|\tilde{v}_{3d}|$  表示标准化新息残差,  $k_0$  为判定因子, 一般取 2.5~3.0。下式为 3d-Nets 预测三维速度的随机模型, 可通过  $\gamma$  变化实现自适应动态调整。

$$R_{3d}[(v_{for} \leq 5), (5 < v_{for} \leq 10), (10 < v_{for} \leq 15), (v_{for} > 15)] = \gamma R_{3d} \quad (27)$$

车辆行驶过程中, 零速检测器如果判定其为静止状态, 即  $v_{for} = 0$  时, 采用对三维速度观测和其方差做强约束的方式增强定位效果, 满足  $Z_{3d} = \mathbf{0}$ , 其对应的随机模型表示为

$$R_{3d}(v_{for} = 0) = \begin{bmatrix} \varepsilon & 0 & 0 \\ 0 & \varepsilon & 0 \\ 0 & 0 & \varepsilon \end{bmatrix} \quad (28)$$

其中,  $\varepsilon$  表示所预测三维速度的噪声, 在实验过程中可以给小值, 本文给 0.001。

## 2. 实验结果和分析

为了验证 3d-Nets 所预测的伪观测量精度和三维速度辅助的 GNSS/SINS 组合定位性能, 本文采用实测数据通过模拟 GNSS 信号缺失的情况进行分析验证。

### 2.1 数据采集

实验设备使用了 Novatel 的战术级 IMU (iMAR FSAS), 其中陀螺仪零偏稳定性为 0.75deg/h, GNSS 接收机为 Novatel SPAN-SE, IMU 采样率 200HZ。

本文参考结果的准确值根据 IE 软件进行紧组合前后向平滑处理获得, 运行轨迹如图 5 所示。将高精度后处理的 b 系下载体速度结果作为真值, 并将其作为本文 3d-Nets 训练的历史标签数据。在图 6 中展示了本文实验分析验证所使用的轨迹, 该段轨迹中包括了多个直行和拐弯状态。



图 5 训练集数据对应的车辆行驶轨迹

Fig.5 Vehicle Trajectory Corresponding to the Training Set Data



图 6 测试集数据对应的车辆行驶轨迹

Fig.6 Vehicle Trajectories Corresponding to the Test Set Data

## 2.2 3d-Nets 预测性能

在图 7 中，展示了基于速度分类的 3d-Nets 模型预测的结果与参考结果之间的差异。可以观察到，预测结果和参考结果差异较小。此外，需要注意的是，载体的侧向观测值的确不等于零，在转弯状态下甚至接近 0.6 m/s，且前向速度与侧向速度之间的确存在一定耦合关系，这种情况如果还照搬传统方法，则会引起车辆轨迹的发散。

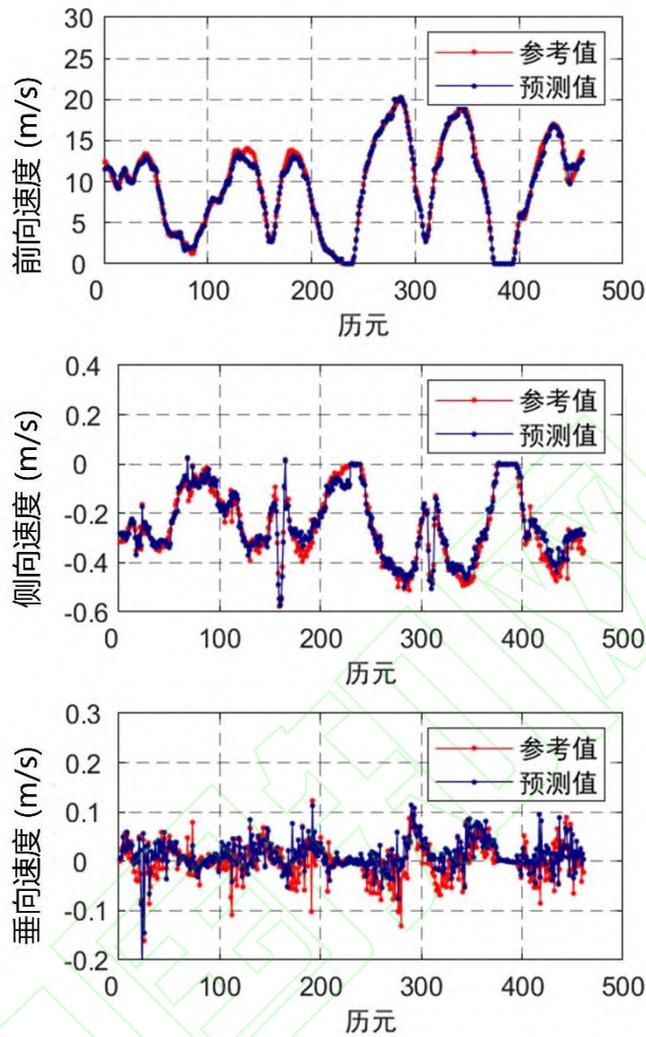


图 7 基于速度分类的 3d-Nets 模型预测的结果值与参考值之间的差异

Fig.7 Discrepancies Between Resultant and Reference Values Predicted by the 3d-Nets Model Based on Velocity Classification

为了验证本文基于速度分类方法能够提取更高精度的特征信息，分别对分类数据集和未分类数据集进行训练。在图 8 中通过对比两种方法三维速度预测的误差发现，由于考虑了前向速度的影响，进行速度分类的数据预测的误差明显好于未进行速度分类的数据集预测的误差，说明了进行速度分类后能够捕捉更精细的特征信息。其中前向速度误差约为 0.4 m/s，表明运用速度分类的方法，能够明显提高前向速度预测的效果。根据阿克曼旋转定理，车辆不同程度的转弯，会造成不同的侧向速度分量，并且会受到前向速度的影响，说明两者相互耦合。因此，分类后的数据集在预测侧向速度的效果也比较明显，平均误差约为 2.4 cm/s。由于本文所选的行驶路段基本平整，没有上下的起伏，所以在垂向速度预测方面两种方法差异不明显，平均误差约为 2.1 cm/s。车体在行驶过程中前向速度变化率明显大于侧向和垂向，所以其误差也比较大。

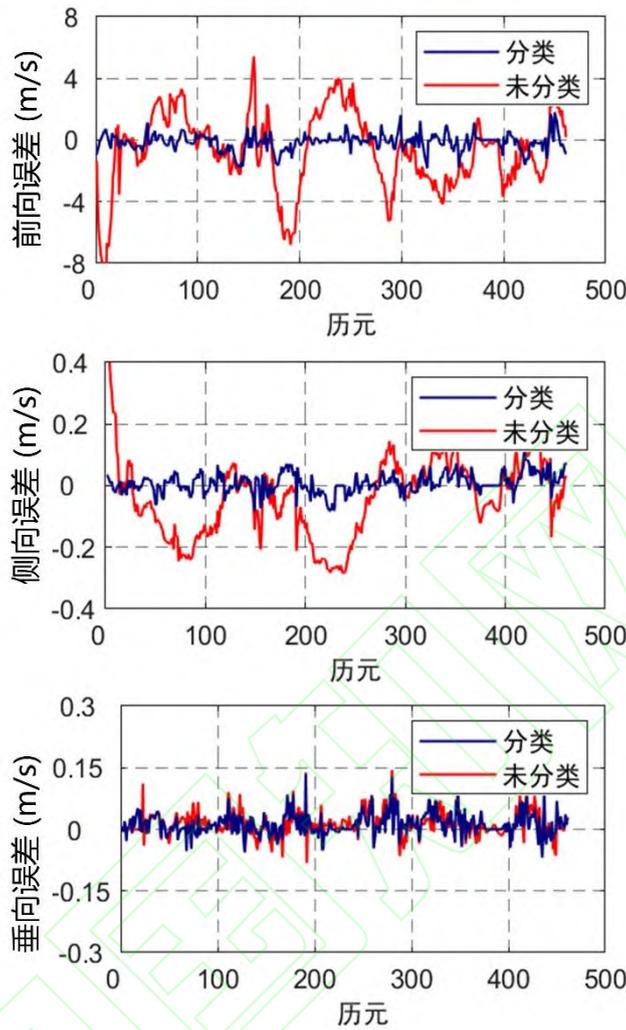


图 8 两种方法三维速度预测的误差对比

Fig.8 Comparison of Errors in 3D Velocity Prediction Between Two Methods

### 2.3 IMU 航位推算定位性能验证

为了验证本文所提算法的优越性，选择图 4 中的路段进行实验，对其 460s 数据模拟 GNSS 信号中断，仅靠 IMU 的航位推算，设计了如表 2 所示的 6 种实验方案，其中方案 1 完全靠惯导机械编排推算；方案 2 假设侧向和垂向速度为 0 对载体做非完整性约束，标准差设定为 0.2m；方案 3 用未分类的数据集生成的 3d-Nets 预测侧向和垂向速度，然后用其对载体做非完整性约束；方案 4 在方案 2 的基础上，用分类的数据生成的 3d-Nets 预测侧向和垂向速度，并对载体做非完整性约束；方案 5 用分类的数据生成 3d-Nets 预测三维速度，并对载体做速度的全约束；根据图 8 所示的速度预测精度，上述三种方案标准差都设定为 0.05m。方案 6 根据公式 (26) - (28) 在方案 5 的基础上自适应调整  $R_{3d}$ 。

表 2 六种方案数据处理策略

Tab.2 Data Processing Strategy of Five 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	$R_{3d}$ 自适应
方案 1	×	×	×	×	×
方案 2	✓	×	×	×	×
方案 3	×	✓	×	×	×
方案 4	×	×	✓	×	×
方案 5	×	×	×	✓	×
方案 6	×	×	×	✓	✓

图 8 展示了 6 种不同方案下车辆运行轨迹与参考值的对比。从图中可以看出，方案 1 定位结果很快发散，主要是由于长时间卫星失锁缺乏外部信息约束造成；方案 2 由于采用 NHC 约束，其定位性能相比于方案 1 有显著提升；方案 3 智能预测虚拟 NHC，但是由于预测值相较于参考值存在一定差距，导致其定位性能比传统 NHC 方法略差；方案 4 利用速度分类后的数据集生成 3d-Nets 模型，由于进一步提高了伪观测量的预测精度，定位性能得到改善，证明了基于速度分类方法的合理性；图 9 为方案 4、方案 5 和方案 6 的局部放大图，方案 5 定位效果优于方案 4，验证了采用三维速度进行全约束时，因为有了前向速度的约束，相当于提供了一个虚拟里程计，可一定程度抑制惯导误差的积累；方案 6 则进一步验证了通过动态调整随机模型能更好地反映真实的观测噪声水平，以进一步提高约束性能。



图 9 六种不同方案和参考的平面轨迹

Fig.9 Vehicle Plane Trajectory of Five Different Scheme and Ground Truth



图 10 三种不同方案和参考的平面轨迹局部放大图

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

为了进一步验证所提算法的优越性，图 10 展示了在 GNSS 信号缺失的环境中三种方案的定位误差。在 0-110 秒期间，车体向西行驶，三种方案都有侧向速度约束，因此三种方案在北向定位误差差距较小。由于方案 4 缺乏前向速度约束，所以方案 4 东方向定位效果明显差于方案 5 和 6。方案 6 采用了自适应动态调整三维速度预测值方差的方法，所以更能有效的抑制惯导的推算误差。在 110-400 秒期间，车体朝南北方向行驶，方案 5 和 6 有了前向约束，北向误差缓慢发散，而方案 4 的北向误差迅速发散。在 400 秒之后，车体向西行驶，方案 4 有了侧向速度的约束，因此北向误差相对于东向误差的发散速度较慢，而东向误差由于缺乏前向速度约束而较大。

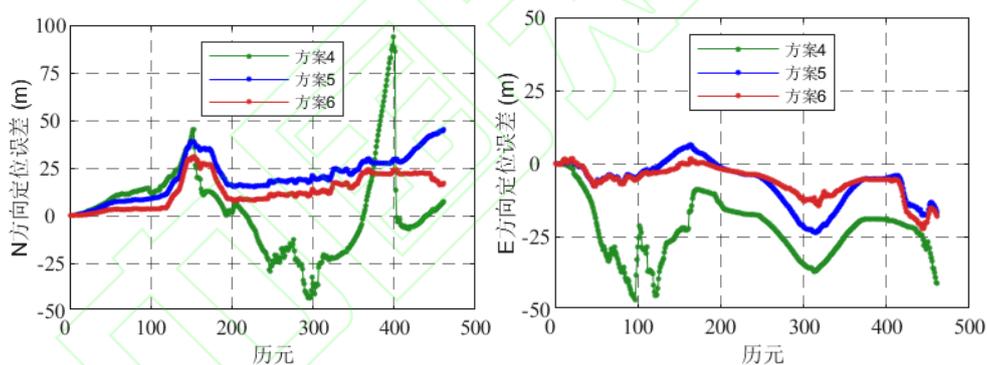


图 11 三种不同方案 N 方向和 E 方向的定位误差

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

表 3 统计了上述 6 种方案的平面位置误差和提升率，以便于对实验结果的定量分析。方案 3 表现为负提升，这说明如果 NHC 的伪观测预测不准确，将会对组合导航定位精度产生影响。进一步细化预测模型具有一定的意义。方案 4、方案 5 和方案 6 的效果逐步提升，其中方案 6 在 GNSS 信号失锁 460s 的情况下，平面精度仍然未 34.58 米，说明本文提出的方法对于 IMU 航位推算误差抑制效果较为显著，有效抑制了由 IMU 误差发散引起的定位漂移问题。

表 3 三种不同方案的定位结果

Tab.3 Statistical Positioning Results of Three Different Scheme

指标	方案 1	方案 2	方案 3	方案 4	方案 5	方案 6
平面误差(m)	5828.48	94.52	116.64	67.97	50.06	34.58
提升率 (%)	/	98.37%	-18.98%	41.72%	26.34%	30.92%

### 3. 结论

本文设计了一种基于速度分类的 3d-Nets 模型，能够同时预测虚拟 NHC 和虚拟 ODO，在量测更新阶段采用了一种动态调整所预测三维速度的噪声的方法，通过对车载实测数据进行验证，得出了以下结论。

(1) 相较于独立讨论预测虚拟 NHC 和虚拟 ODO 的方法，本文所提方法因为考虑了载体运动状态，所以智能算法能更好地捕捉车辆速度的细节特征，使得所预测的三维速度精度更高。

(2) 本文所提方法实现了三维速度自适应约束的 GNSS/SINS 组合定位，相较于传统车载运动约束方法，能够较好的保持 IMU 航位推算性能，在定位精度方面取得了显著的改进。

### 参考文献

- [1] LI Lan, ZHU Feng, LIU Wanke, et al. GNSS Pseudorange Stochastic Model for Urban Classification Scenes and Its Positioning Performance[J]. Geomatics and Information Science of Wuhan University. (李岚, 朱锋, 刘万科, 等. 城市分类场景的 GNSS 伪距随机模型构建及其定位性能分析[J]. 武汉大学学报(信息科学版). DOI: 10.13203/j.whugis20220598).
- [2] Fu Shuaizhi, Chen Wei, Wu Di, et al. A GNSS/INS Vehicle Integrated Navigation System Based on LSTM-EKF[J]. Geomatics And Information Science of Wuhan University, 2023:1-11 (傅率智, 陈伟, 吴迪等. 一种基于 LSTM-EKF 的车载 GNSS/INS 组合导航系统[J/OL]. 武汉大学学报(信息科学版), 2023:1-11).
- [3] Zhang Hongping, Gao Zhouzheng, Niu Xiaoji, et al. Research on GPS Precise Point with Undifferential and Un-combined Observations[J]. Geomatics And Information Science of Wuhan University, 2013, 38(12):1396-1399 (章红平, 高周正, 牛小骥, 伍岳. GPS 非差非组合精密单点定位算法研究[J]. 武汉大学学报 (信息科学版), 2013, 38(12):1396-1399).
- [4] Niu X, 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 & Automation, 2001, 17(5):731-747.
- [6] Niu X, You L, Quan Z, et al. Observability Analysis of Non-Holonomic Constraints for Land-Vehicle Navigation Systems[J]. GPS Solutions, 2012, 11(1):80-88.
- [7] Liu W, Nong Q, Tao X, et al. OD/SINS adaptive integrated navigation method with non-holonomic constraints[J]. Acta Geodaetica et Cartographica Sinica, 2022, 51(1): 9-17.
- [8] Veneri M, Massaro M. The effect of Ackermann steering on the performance of race cars. Vehicle system dynamics[J]. 2021, 59(6):907-27.
- [9] Wen Z, Yang G, Cai Q. An improved SINS/NHC integrated navigation algorithm based on Ackermann turning geometry[J]. Measurement. 2022, 192:110859.

- [10] Chen Q, Zhang Q, Niu X. Estimate the pitch and heading mounting angles of the IMU for land vehicular GNSS/INS integrated system[J]. IEEE transactions on intelligent transportation systems. 2020, 22(10):6503-15.
- [11] Brossard M, Barrau A, Bonnabel S. AI-IMU dead-reckoning. IEEE Transactions on Intelligent Vehicles[J]. 2020, 5(4):585-95.
- [12] Tang H, Niu X, Zhang T, et al. OdoNet: 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 velocities from a single IMU[C]// In2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN). IEEE, 2019, Pisa, Italy.
- [14] Wagstaff B, Kelly J. LSTM-based zero-velocity detection for robust inertial navigation[C]// In2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN). IEEE ,2018, Nantes, France.
- [15] Saleh K, Hossny M, Nahavandi S. Intent prediction of vulnerable road users from motion trajectories using stacked LSTM network[C]// 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2017, Yokohama, Japan,.
- [16] Graves A, Mohamed A R, Hinton G. Speech recognition with deep recurrent neural networks[C]// IEEE International Conference on Acoustics. IEEE, 2013, Vancouver, Canada.
- [17] HE Yi, YAO Sheng, CHEN Yi, et al. Spatio-temporal prediction of time-series InSAR Land subsidence based on ConvLSTM neural network[J]. *Geomatics and Information Science of Wuhan University*.(何毅,姚圣,陈毅,等.ConvLSTM 神经网络的时序 InSAR 地面沉降时空预测[J].武汉大学学报(信息科学版)).
- [18] Skog I, Handel P, Nilsson JO, Rantakokko J. Zero-velocity detection—An algorithm evaluation. IEEE transactions on biomedical engineering[J]. 2010 Jul 26;57(11):2657-66.
- [19] Zhang X , Zhu F , Tao X , 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] Yan Gongmin, Weng Jun. Strapdown inertial navigation algorithm and principle for integrated navigation[M]. Xi'an: Northwestern Polytechnical University Press, 2019(严恭敏, 翁浚. 捷联惯导算法与组合导航原理[M].2019,西北工业大学出版社).
- [21] YANG Yuanxi. Adaptive navigation and kinematic positioning[M]. Beijing: Surveying and Mapping Press, 2006.(杨元喜. 自适应动态导航定位[M]. 北京:测绘出版社, 2006).

#### 网络首发:

标题: 基于速度分类的 LSTM 神经网络辅助 GNSS/SINS 车载定位方法

作者: 李晗旭, 李昕, 黄观文, 张勤, 陈世鹏

收稿日期: 2023-12-25

DOI:10.13203/j.whugis20230061

#### 引用格式:

李晗旭, 李昕, 黄观文, 等. 基于速度分类的 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),2024,DOI: 10.13203/j.whugis20230061 (LI Hanxu, LI Xin, HUANG Guanwen, et al.TU Jianguang,et al. LSTM Neural Network Assisted GNSS/SINS Vehicle

Positioning Based on Speed Classification [J].Geomatics and Information Science of Wuhan University,2024,DOI: 10.13203/j.whugis20230061)

**网络首发文章内容和格式与正式出版会有细微差别，请以正式出版文件为准!**

---

**您感兴趣的其他相关论文:**

**一种城市环境下 GNSS/MEMS IMU 车载实时精密定位方法**

祝浩祈, 王甫红, 张万威, 栾梦杰, 程雨欣

武汉大学学报(信息科学版), 2023, 48(7): 1232-1240.

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20220491>

**城市环境下智能手机车载 GNSS/MEMS IMU 紧组合定位算法**

王甫红, 栾梦杰, 程雨欣, 祝浩祈, 赵广越, 张万威

武汉大学学报(信息科学版), 2023, 48(7): 1106-1116.

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20230010>

**城市场景智能手机 GNSS/MEMS 融合车载高精度定位**

张小红, 陶贤露, 王颖喆, 刘万科, 朱锋

武汉大学学报(信息科学版), 2022, 47(10): 1740-1749.

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20220611>