

doi:10.19306/j.cnki.2095-8110.2024.06.005

# 基于时序状态学习模型的行人惯性导航算法

涂哲铭, 潘献飞, 陈昶昊, 吴文启

(国防科技大学智能科学学院, 长沙 410073)

**摘要:** 基于深度学习的行人惯性导航方法具有较强的适应性, 近年来逐渐成为研究热点。然而, 现有方法未充分考虑惯性数据的时序特性, 缺乏时序数据的拟合能力。为进一步抑制微惯性导航系统的误差发散, 建立了基于时序状态学习模型的行人惯性导航算法。与传统的行人航位推算(PDR)算法不同, 此算法不依赖于传统的行人惯性导航框架, 而是利用选择性两层双向状态空间模型结构, 对特征编码后的隐式惯性特征向量进行时序建模, 从而实现位移与不确定性估计。然后, 将神经网络估计结果通过扩展卡尔曼滤波进行融合, 以进一步降低误差漂移。通过行人导航实验, 验证了该方法能够提升定位精度, 有效抑制惯性误差发散, 实现精准的行人导航。相较于紧耦合可学习惯性里程计(TLIO)方法, 绝对轨迹误差和位移漂移率分别降低了32.35%和41.27%。

**关键词:** 惯性导航; 智能自主导航; 深度学习; 行人导航

中图分类号: V249.32+8

文献标志码: A

文章编号: 2095-8110(2024)06-0061-10

## Learning-based pedestrian inertial navigation algorithm with time-series state-space-model

TU Zheming, PAN Xianfei, CHEN Changhao, WU Wenqi

(College of Intelligence Science and Technology, National University of Defense Technology, Changsha 410073, China)

**Abstract:** The pedestrian inertial navigation method based on deep learning has become a major research focus in recent years due to its high adaptability. However, existing approaches do not fully consider the temporal characteristics of the inertial data and lack the ability to fit temporal data. To restrain the error divergence in learning-based micro-inertial navigation systems, a pedestrian inertial navigation algorithm with a learnable time-series state space mode is established. Unlike traditional pedestrian dead reckoning (PDR) algorithms, the proposed algorithm does not rely on the traditional pedestrian inertial navigation framework. Instead, a selective two-layer bi-directional state space model is used to temporally model the implicit inertial feature vectors after feature encoding, and the motion displacement and the uncertainty are estimated. Furthermore, the neural network estimation results are fused by an extended Kalman filter in order to mitigate the error drift. Experiments conducted on wearable pedestrian navigation devices show that the proposed method improves positioning accuracy, effectively suppresses error drift in the inertial system, and achieves reliable pedestrian navigation. Compared to tight learned inertial odometry (TLIO), the absolute trajectory error and displacement drift rate are reduced by 32.35% and 41.27% respectively.

**Key words:** Inertial navigation; Intelligent autonomous navigation; Deep learning; Pedestrian navigation

收稿日期: 2024-08-29; 修订日期: 2024-11-04

作者简介: 涂哲铭(1998—), 男, 博士研究生, 主要从事导航技术方面的研究。

通信作者: 陈昶昊(1992—), 男, 讲师, 主要从事导航技术方面的研究。

## 0 引言

行人导航技术在应急救援、商业购物以及增强现实等多个应用场景中扮演着关键角色<sup>[1]</sup>。伴随着微惯性传感器技术的持续进步,微惯性测量单元(micro-inertial measurement unit, MIMU)在小型化、低能耗及低成本等方面取得了显著成就,为基于微惯性器件的行人导航算法的实现提供了可能。然而,由于器件固有的噪声影响,依赖于微惯性器件的捷联导航算法在短时间内因噪声的累积效应容易导致导航误差的快速发散,这一局限性制约了其在导航领域的深入应用。越来越多的研究开始着眼于利用行人运动状态提供观测信息,从而抑制导航误差发散,例如基于零速检测(zero-velocity update, ZUPT)<sup>[2]</sup>和行人航位推算(pedestrian dead reckoning, PDR)<sup>[3]</sup>两类方法。ZUPT方法通过捕捉行人在行走过程中足部触地时的零速瞬间,提供速度观测数据,从而有效控制定位误差的增长。而PDR算法则借助行人的惯性信息和步长估计模型实现导航定位。行人惯性导航航位推算方法<sup>[4]</sup>的基本框架主要包括步伐监测、航向估计与步长估计3个模块。2015年,韩国科学技术院的Kang等<sup>[5]</sup>提出了基于智能手机的PDR算法,但是在实际应用中需通过限制手机晃动以降低误差。为了减少行人运动状态对步数检测准确性的影响,2018年,拉斐尔先进防御系统公司的Klein等在PDR算法中引入行人运动状态分类模型,对系统阈值参数进行动态调整,从而提高PDR算法对不同运动模式的适应能力。最近,关于PDR技术的研究主要集中在与其他外部信息的融合上,例如与全球卫星导航系统(global navigation satellite system, GNSS)的信息融合<sup>[3]</sup>,与超宽带(ultra wide band, UWB)定位技术的融合<sup>[6]</sup>,以及与气压计、磁力计的融合等<sup>[7]</sup>。这些方法虽然在一定程度上提高了导航精度,但它们往往需要对算法参数进行精确调整,并对行人运动状态进行严格约束,这使得在复杂运动场景下实现高精度导航任务仍面临挑战。此外,微惯性器件的传感器噪声问题,如难以精确建模和上电重复性差,导致传统基于物理模型的导航方法误差迅速发散,难以实现稳定、有效的定位。

因此,通过转向数据驱动的方法优化行人导航算法已成为当前研究的重要趋势。基于深度学习的行人导航算法摆脱了对传统人工设计的物理模

型的依赖,采用数据驱动的统计学模型估计导航状态或相对位移等中间状态,这有望减少由于误差建模不精确而在传统物理模型中导致的误差扩散问题。IONet<sup>[8]</sup>方法首次提出了基于长短期记忆网络(long short-term memory, LSTM)的相对姿态端到端学习框架,能够从分段惯性数据的独立窗口学习极坐标中的运动位移,随后将运动位移与初始位置累加获得载体二维运动位置估计。为进一步提升惯性定位在实际应用中的适应性,Chen等<sup>[9]</sup>在估计位姿的同时,还利用神经网络给出了估计的不确定性。2020年,西蒙弗雷泽大学的Herath等<sup>[10]</sup>提出了鲁棒神经网络惯性导航(robust neural inertial navigation, RoNIN)方法,使用基于残差网络的IMU传感器数据进行运动估计和定位,将惯性测量值和学习到的速度矢量转换为与航向无关的坐标系,并引入了几种新的速度损失以进一步改进定位精度,但RoNIN的局限性在于其依赖方向估计。2020年,宾夕法尼亚大学的Liu等<sup>[11]</sup>提出了紧耦合可学习惯性里程计(tight learned inertial odometry, TLIO)方法,利用残差神经网络从重力对齐的惯性数据序列中学习三维位移和位移估计的协方差,随后将学习到的位移和协方差作为观测状态合并到扩展卡尔曼滤波器中,以估计方位、速度、位置和IMU偏差的完整状态。2021年,卡内基梅隆大学的Sun等<sup>[12]</sup>提出了深度学习习惯性航向估计与定位(inertial deep orientation-estimation & localization, IDOL)方法,将深度方位估计与深度惯性里程计相结合,利用LSTM和扩展卡尔曼滤波形成稳定且准确的定向估计。2023年,武汉大学Wang等<sup>[13]</sup>针对TLIO算法中位移估计神经网络的轻量化问题进行改进,提出了更为轻量的深度学习习惯性里程计方法——轻量化深度学习习惯性里程计(lightweight learned inertial odometer, LLIO),并在手机端进行了部署和相关实验。然而,惯性数据作为一种典型的时序数据,受到时序信息的约束,目前这些方法仍缺乏对惯性数据时序信息的进一步挖掘,在定位精度方面有待进一步提升。

近年来,深度学习在时序信号处理方面展现出了巨大的潜力,其在语音处理、序列学习及图像处理等方面都有着不俗的表现。时序数据学习一直是深度学习领域的一个重要研究方向,常见的时序学习网络结构包括以LSTM为代表的循环神经网络(recurrent neural network, RNN)结构,以时间卷积网络(temporal convo-

lution network, TCN)<sup>[14]</sup>为代表的卷积神经网络结构和以 Transformer<sup>[15]</sup>为代表的注意力机制相关的网络模型结构。时序状态学习模型方法<sup>[16]</sup>是近年来兴起的一种用于捕获长距离依赖信息的基础模型结构,来源于控制理论中利用状态变量对动态系统进行建模的基本思想,将其应用于深度学习领域后,可根据应用需求离散化为 RNN 或者卷积神经网络的形式。例如,具有选择性的状态空间模型 Mamba<sup>[17]</sup>已经应用于语音<sup>[18]</sup>、图像<sup>[19]</sup>和点云<sup>[20]</sup>数据处理等多个领域,均展现出了优越的特征学习和时序建模能力。通过建立具有线性计算复杂性的长度依赖关系,这类模型更适合处理时序建模任务。利用经典状态空间模型的基本原理,可学习隐式状态空间模型已经证明了其在自然语言处理和视觉任务等领域的有效性。鉴于惯性数据是一种长序列数据,因此适用于可学习状态空间模型。目前,利用状态空间模型对运动背景信息进行时序建模的能力还有待进一步探索。

因此,为了进一步提升基于深度学习的惯性导航定位精度,并充分挖掘惯性数据的时序信息,本研究提出了一种基于可学习时序状态模型的惯性

导航算法。该算法构建了一个专门用于导航位移估计的时序状态学习模型网络,该网络以惯性序列数据为输入,输出相对位移和置信度估计。随后,这些网络输出作为观测值被进一步输入到卡尔曼滤波器中,以优化和修正惯性导航算法的性能。通过深度学习模型提取的运动背景特征,有效抑制了惯性导航算法的误差发散。

## 1 算法设计

针对目前基于深度学习的惯性导航方法在时序信息挖掘和定位精度方面存在的局限性,本研究旨在进一步提升行人惯性导航的定位精度。为此,设计了一种基于可学习时序状态模型的惯性导航算法,并构建了基于时序状态学习模型的位移估计模块。如图 1 所示,整体算法架构主要由两部分组成:基于时序状态学习模型的位移估计神经网络模型和位移学习扩展卡尔曼滤波。神经网络模型利用视觉惯性里程计提供的相对位移量作为真值标签进行训练,而在预测阶段则对 IMU 序列的位移量与位移估计的不确定性进行估计。

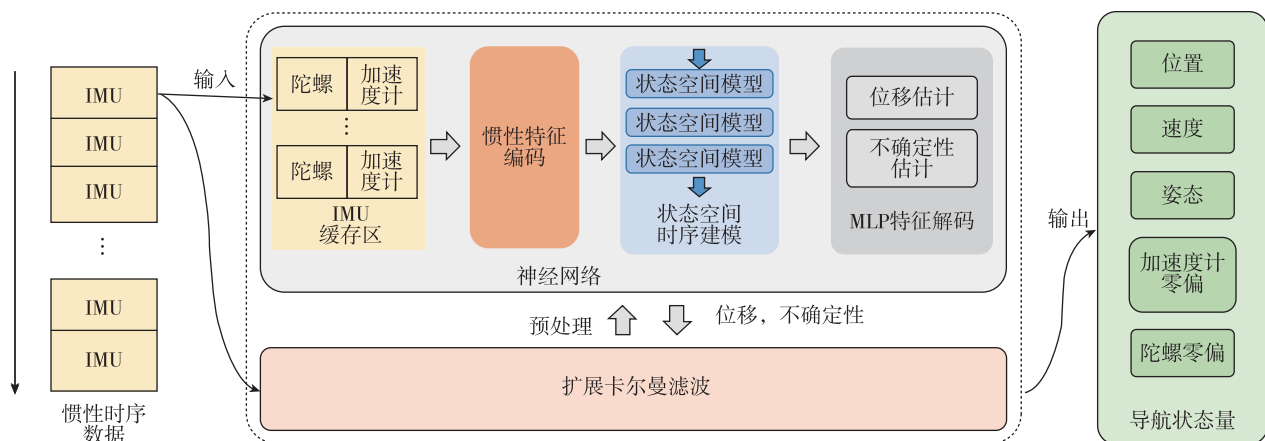


图 1 基于时序状态学习模型的惯性导航算法框架

Fig. 1 Learning-based inertial navigation algorithm framework with time-series state space models

基于时序状态学习模型的位移估计神经网络模型,采用原始 IMU 测量数据序列作为输入,并输出该序列的位移估计及其对应的不确定性。该神经网络模型主要由 3 个部分组成:特征编码、时序建模和特征解码。其中时序建模模块是基于时序状态学习模型构建的,采用可学习状态空间模型方法对时序信息进行建模。在进行位移估计之前,IMU 测量值通过扩展卡尔曼滤波所提供的旋转估计量转换到世界坐标系下,神经网络的输出则是在世界

坐标系下的位移估计量。

卡尔曼滤波通过融合基于物理模型的动力学信息与神经网络提供的基于数据驱动的统计学信息,实现了对实时状态的高效估计,涵盖了载体的三维位置、速度、姿态及惯性传感器的零偏。卡尔曼滤波利用原始 IMU 测量进行传播,并利用神经网络输出进行更新。在实际应用中,原始 IMU 数据经过插值处理以匹配网络输入的频率,并转换至重力向下的重力对齐坐标系,以确保估计的准确性。

## 2 惯性导航状态空间学习模型

### 2.1 状态空间模型方法

为进一步提高神经网络位移估计精度,惯性导航状态空间学习模型采用状态空间模型方法对时序信息进行建模,如图2所示。状态空间模型的基本结构有3种表达形式,分别是连续时间形式、循环表示形式和卷积表示形式。状态空间模型将从神经网络提取的惯性运动特征向量  $U(t)$  经式(1)映射为隐式状态空间中的  $N$  维变量  $X(t)$ ,之后将其投影到输出变量  $y(t)$ ,计算过程为

$$\begin{aligned}\dot{X}(t) &= A(t)X(t) + B(t)U(t) \\ y(t) &= C(t)X(t) + D(t)U(t)\end{aligned}\quad (1)$$

其中,  $X(t) \in \mathbf{R}^n$ ,  $y(t) \in \mathbf{R}^q$ ,  $U(t) \in \mathbf{R}^p$  分别表示状态向量、输出向量和输入向量;  $A(t) \in \mathbf{R}^{n \times n}$ ,  $B(t) \in$

$\mathbf{R}^{n \times p}$ ,  $C(t) \in \mathbf{R}^{q \times n}$ ,  $D(t) \in \mathbf{R}^{q \times p}$  分别表示状态矩阵、输入矩阵、输出矩阵和前馈矩阵。当系统中没有直接的前馈连接时,  $D(t)$  矩阵是零矩阵。因此,式(1)中的状态方程可以简化为

$$\begin{aligned}\dot{X}(t) &= A(t)X(t) + B(t)U(t) \\ y(t) &= C(t)X(t)\end{aligned}\quad (2)$$

经零阶保持离散化后,式(2)可表示为离散系统

$$\begin{aligned}X_t &= \bar{A}X_{t-1} + \bar{B}U_t \\ y_t &= CX_t\end{aligned}\quad (3)$$

其中

$$\begin{aligned}\bar{A} &= \exp(\Phi A) \\ \bar{B} &= (\Phi A)^{-1}(\exp(\Phi A) - I) \cdot \Phi B\end{aligned}\quad (4)$$

其中,  $\Phi$  表示离散步长。系统经过离散化后,模型可以按照式(3)以线性递归的循环表示形式进行推理预测。

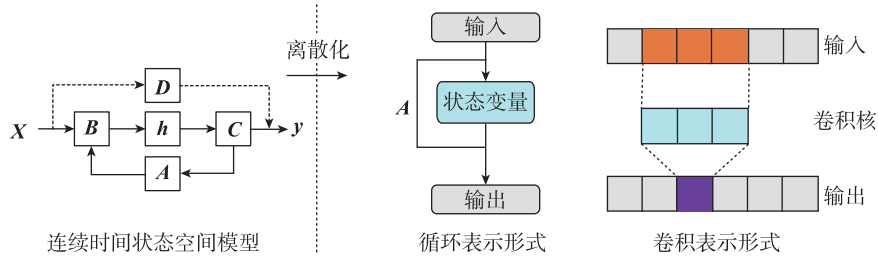


图2 状态空间模型表示

Fig. 2 State space model representation

为使其适用于并行化训练过程,对式(3)进行扩展可以得到

$$\begin{aligned}y_0 &= \bar{C}\bar{A}^0\bar{B}x_0 \\ y_1 &= \bar{C}\bar{A}^1\bar{B}x_0 + \bar{C}\bar{A}^0\bar{B}x_1 \\ y_2 &= \bar{C}\bar{A}^2\bar{B}x_0 + \bar{C}\bar{A}^1\bar{B}x_1 + \bar{C}\bar{A}^0\bar{B}x_2\end{aligned}\quad (5)$$

因此,可以将乘法器视为卷积核  $\bar{K} = \bar{C}\bar{B} \cdot (\bar{A}^0, \bar{A}^1, \bar{A}^2, \dots, \bar{A}^L)$ ,以卷积形式进行并行化训练。

### 2.2 选择性双向状态空间模型单元

由于可学习状态空间模型的前向传播过程只能捕捉历史信息,因而更适用于具有因果关系的序列学习。而惯性数据是非因果的时序数据,需要在状态空间模型的基础上对其进行改进,通过在可学习状态空间模型中构建双向可学习状态空间模型结构<sup>[19]</sup>进行时序建模,以提高神经网络对惯性时序信息的发掘能力。双向可学习状态空间模型结构如图3所示,经特征编码后的  $D$  维惯性特征数据  $U \in \mathbf{R}^{M \times D}$  会在归一化后经线性层映射获得  $x, z \in$

$\mathbf{R}^{M \times E}$ ,然后对  $x$  分别进行正向和反向处理。在正向和反向处理中,首先将输入向量  $x$  进行1维卷积和 Sigmoid 加权线性单元(Sigmoid-weighted linear unit, SiLU)  $Silu = x / (1 + e^{-x})$  激活函数获得输出向量  $x_0$ ,即

$$x_0 = Silu(\text{Conv1d}(x))\quad (6)$$

然后,经过线性层 MLP 分别映射到  $B, C$  和  $\Phi$  矩阵,即

$$B = MLP_B(x_0)$$

$$C = MLP_C(x_0)$$

$$\Phi = \lg(1 + MLP_\Phi(x_0) + P_\Phi)\quad (7)$$

其中,  $P_\Phi$  是  $\Phi$  相关的可优化参数。根据式(3)获得离散化稀疏矩阵  $\bar{A}, \bar{B}$  后,利用正向状态空间模型和反向状态空间模型获得正向输出  $y_+$  和反向输出  $y_-$  后,与门控矩阵  $z$  相加获得模块输出,同时选择性双向状态空间模型可根据任务需求进行堆叠以提高系统的拟合能力。

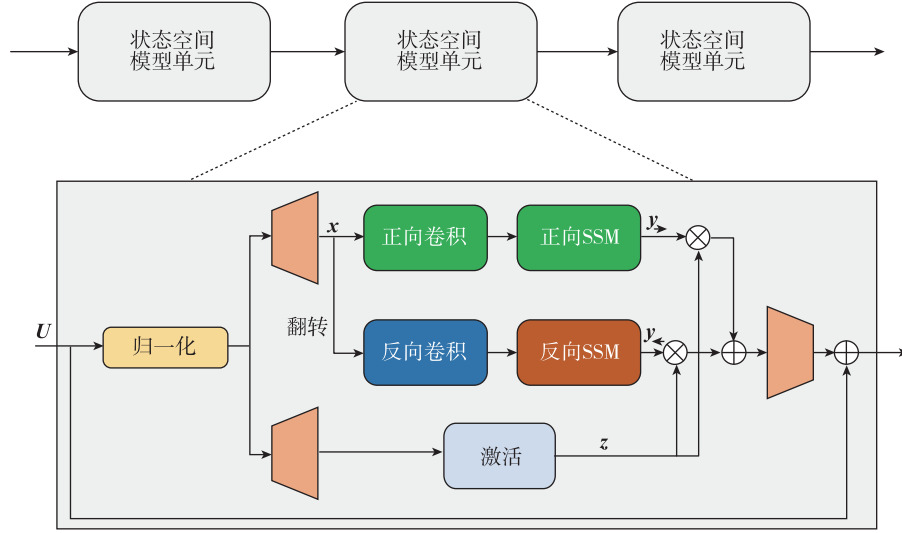


图 3 选择性双向状态空间模型单元

Fig. 3 Selective bi-directional state space model block

### 2.3 位移估计神经网络模型

惯性导航状态空间学习模型主要由特征编码模块、时序建模模块和特征解码模块组成。其中，特征编码模块采用 EfficientNet-B0 网络<sup>[21]</sup> 结构对惯性数据进行特征编码，并映射到隐式状态空间。微惯性数据  $\mathbf{I} \in \mathbf{R}^{6 \times L}$  经过特征编码后得到隐式空间下的惯性特征向量  $\mathbf{U} \in \mathbf{R}^{M \times D}$ ，如式(8)所示。

$$\mathbf{U} = \text{EfficientNet}(\mathbf{I}) \quad (8)$$

其中,  $L$  为 IMU 序列的长度;  $M$  为特征编码后的特征向量长度;  $D$  为特征向量维度。

时序建模模块采用基于选择性双向状态空间模型单元的可学习状态空间模型进行构建。其基本结构如图 3 所示,通过三层可学习状态空间模型堆叠增强对 IMU 数据时序信息的利用。利用特征编码后的特征向量  $\mathbf{U}$  进行时序建模,可表示为

$$\mathbf{Y} = \text{SSM}(\mathbf{U}) \quad (9)$$

最后,利用全连接层进行特征解码,分别输出位移估计  $\mathbf{d}$  和不确定性估计  $\mathbf{u}$ , 如式(10)所示。

$$\mathbf{d}, \mathbf{u} = \text{MLP}(\mathbf{Y}) \quad (10)$$

在训练过程中,使用了均方根误差损失和高斯最大似然损失两类损失函数,在训练集上均方根误差损失的定义为

$$L_{\text{MSE}}(\Delta \mathbf{l}, \Delta \hat{\mathbf{l}}) = \frac{1}{L} \sum_{j=1}^n \|\Delta \mathbf{l}_j - \Delta \hat{\mathbf{l}}_j\|^2 \quad (11)$$

其中,  $\Delta \hat{\mathbf{l}} = \{\Delta \hat{\mathbf{l}}_j\}_{j \leq L}$  是网络模型的三维位移输出值;  $\Delta \mathbf{l} = \{\Delta \mathbf{l}_j\}_{j \leq L}$  是相应的真值标签。

位移估计可以通过视觉惯性里程计提供的真值标签获取。然而,对于不确定性而言,由于缺乏

直接测量真实不确定性的手段,因此无法通过人工方法获得相应的标签。为此,通过将位移估计神经网络模型扩展到贝叶斯模型,从而无监督地估算惯性跟踪的不确定性。在此假设下,位移估计的不确定性遵循正态分布。根据回归高斯分布,将最大似然损失定义为位移的负对数似然函数。

$$L_{\text{ML}}(\Delta \mathbf{l}, \hat{\Sigma}, \Delta \hat{\mathbf{l}})$$

$$= \frac{1}{L} \sum_{j=1}^L -\lg \left( \frac{1}{\sqrt{8\pi^3 \det(\hat{\Sigma}_j)}} e^{-\frac{1}{2} \|\Delta \mathbf{l}_j - \Delta \hat{\mathbf{l}}_j\|_{\hat{\Sigma}_j}^2} \right)$$

$$= \frac{1}{L} \sum_{j=1}^L \left( \frac{1}{2} \lg \det(\hat{\Sigma}_j) + \frac{1}{2} \|\Delta \mathbf{l}_j - \Delta \hat{\mathbf{l}}_j\|_{\hat{\Sigma}_j}^2 \right) + \text{Cst}$$

$$(12)$$

其中,  $\hat{\Sigma} = \{\hat{\Sigma}_j\}_{j \leq L}$  是第  $j$  个位移估计不确定性  $\hat{\mathbf{u}}_j$  所对应的  $3 \times 3$  协方差矩阵。  $\hat{\Sigma}_j$  具有 6 个自由度,并且存在用于估计神经网络不确定性的各种协方差参数。为了增加数值稳定性,可以将协方差矩阵简化为由 3 个系数参数化的对角阵,从而消除损失函数零点附近的奇异值,记为

$$\hat{\Sigma}_j(\hat{\mathbf{u}}_j) = \text{diag}(e^{2\hat{u}_{xj}}, e^{2\hat{u}_{yj}}, e^{2\hat{u}_{zj}}) \quad (13)$$

协方差矩阵表示模型输出的偶然不确定性,通过执行最大后验估推理以优化神经网络权重。在训练过程中,利用 Adam 优化器进行优化,学习率为  $1 \times 10^{-4}$ 。在前 10 轮训练中,将损失函数设定为  $L_{\text{MSE}}$ ,之后再设置为  $L_{\text{ML}}$  直至训练结束。

### 3 惯性/位移学习结果融合的扩展卡尔曼滤波

类似于组合导航算法<sup>[22]</sup>,基于 IMU 机械编排

进行状态递推,并利用扩展卡尔曼滤波器将神经网络模型输出的位移学习结果与惯性导航进行融合。滤波器中维持了  $k$  个位姿向量的窗口以构建相对位移观测,系统的导航状态量可以表示为

$$\mathbf{E} = (\boldsymbol{\epsilon}_1, \dots, \boldsymbol{\epsilon}_k, \mathbf{c}) \quad (14)$$

其中,  $\boldsymbol{\epsilon}_j = ((\mathbf{R}_{i\omega})_j, \mathbf{p}_j), j = 1, \dots, k$  是过去运动状态,只包含了位姿状态量进行优化; $\mathbf{c} = (\mathbf{R}_{i\omega}, \mathbf{v}, \mathbf{p}, \mathbf{b}_\omega, \mathbf{b}_a)$  是当前运动状态; $\mathbf{R}_{i\omega} \in \text{SO}(3)$  表示从惯性坐标系  $i$ -系转化到世界坐标系  $\omega$ -系下的旋转矩阵; $\mathbf{v}$  和  $\mathbf{p}$  分别表示世界坐标系下载体的速度与位置; $\mathbf{b}_\omega$  和  $\mathbf{b}_a$  则分别是微惯性传感器陀螺与加速度计的零偏。

### 3.1 系统运动方程

原始的 IMU 测量包含加速度计测量值  $\hat{\mathbf{a}}$  和陀螺仪测量值  $\hat{\boldsymbol{\omega}}$ ,其输出误差模型可以表示为

$$\begin{aligned} \hat{\mathbf{a}} &= \mathbf{a} + \mathbf{b}_a + \mathbf{n}_a \\ \hat{\boldsymbol{\omega}} &= \boldsymbol{\omega} + \mathbf{b}_\omega + \mathbf{n}_\omega \end{aligned} \quad (15)$$

其中,  $\hat{\mathbf{a}}$  和  $\hat{\boldsymbol{\omega}}$  分别是加速度计和陀螺仪的测量值; $\mathbf{a}$  和  $\boldsymbol{\omega}$  分别是加速度计和陀螺仪的真实值; $\mathbf{n}_a$  和  $\mathbf{n}_\omega$  分别是加速度计和陀螺仪的噪声。由于行人运动范围有限,因此假设均匀重力场下捷联惯性运动学方程可以表示为

$$\begin{aligned} \hat{\mathbf{R}}_{i\omega}(k+1) &= \hat{\mathbf{R}}_{i\omega}(k) \exp_{\text{SO}(3)}((\boldsymbol{\omega}(k) - \hat{\mathbf{b}}_\omega(k))\Delta t) \\ \hat{\mathbf{v}}(k+1) &= \hat{\mathbf{v}}(k) + \mathbf{g}\Delta t + \hat{\mathbf{R}}_{i\omega}(k)(\mathbf{a}(k) - \hat{\mathbf{b}}_a(k))\Delta t \\ \hat{\mathbf{p}}(k+1) &= \hat{\mathbf{p}}(k) + \hat{\mathbf{v}}(k)\Delta t + \frac{1}{2}\Delta t^2(\mathbf{g} + \\ &\quad \hat{\mathbf{R}}_{i\omega}(k)(\mathbf{a}(k) - \hat{\mathbf{b}}_a(k))) \\ \hat{\mathbf{b}}_\omega(k+1) &= \hat{\mathbf{b}}_\omega(k) + \boldsymbol{\eta}_{\omega dk} \\ \hat{\mathbf{b}}_a(k+1) &= \hat{\mathbf{b}}_a(k) + \boldsymbol{\eta}_{adk} \end{aligned} \quad (16)$$

其中,  $\exp_{\text{SO}(3)}$  表示李代数到李群的指数映射; $\mathbf{g}$  表示世界坐标系下的重力加速度; $\boldsymbol{\eta}_{adk}$  和  $\boldsymbol{\eta}_{\omega dk}$  分别是 IMU 模型中 高斯白噪声  $\mathbf{n}_a$  和  $\mathbf{n}_\omega$  的离散化表示。则误差状态线性递推方程可以表示为

$$\tilde{\mathbf{c}}_{k+1} = \mathbf{F}_k^s \tilde{\mathbf{c}}_k + \mathbf{G}_k^s \mathbf{n}_k \quad (17)$$

其中,  $\mathbf{n}_k = [\mathbf{n}_{\omega k}, \mathbf{n}_{ak}, \boldsymbol{\eta}_{\omega dk}, \boldsymbol{\eta}_{adk}]$  表示系统噪声; $\tilde{\mathbf{c}}_{k+1}$  表示  $k+1$  时刻的系统状态; $\mathbf{F}_k^s$  表示  $k$  时刻的状态递推矩阵; $\tilde{\mathbf{c}}_k$  表示  $k$  时刻的系统状态; $\mathbf{G}_k^s$  表示  $k$  时刻的系统噪声矩阵。为实现位移测量预测,需要利用复制的方式对系统状态进行扩维,将位移观测相关联的状态量进行复制扩增到方程中,即

$$\bar{\mathbf{F}}_k = \begin{bmatrix} \mathbf{I}_{6m} & 0 \\ 0 & \mathbf{F}_k^s \\ 0 & \mathbf{F}_k^s \end{bmatrix}, \bar{\mathbf{G}}_k = \begin{bmatrix} 0 \\ \mathbf{G}_k^s \\ \mathbf{G}_k^s \end{bmatrix} \quad (18)$$

其中,  $\mathbf{F}_k^s$  和  $\mathbf{G}_k^s$  是历史关联状态位姿的相关系数矩阵; $\bar{\mathbf{F}}_k$  表示扩维后的系统状态递推矩阵; $\mathbf{I}_{6m}$  表示  $6m$  维单位阵; $\bar{\mathbf{G}}_k$  表示扩维后的系统噪声矩阵。则协方差递推过程可以记为

$$\mathbf{P}_{k+1} = \bar{\mathbf{F}}_k \mathbf{P}_k \bar{\mathbf{F}}_k^T + \bar{\mathbf{G}}_k \mathbf{W} \bar{\mathbf{G}}_k^T \quad (19)$$

### 3.2 量测更新

为避免惯性导航系统航向不可观的影响,选择重力对齐局部坐标系下的三维位移量为观测量,且观测量与第  $k$  个状态相关联,即

$$h(\mathbf{E}) = \mathbf{R}_\gamma^T(j)(\mathbf{p}_k - \mathbf{p}_j) = \hat{\mathbf{d}}_{jk} + \mathbf{n}_{jk} \quad (20)$$

其中,  $\hat{\mathbf{d}}_{jk}$  是惯性导航学习状态空间模型输出的状态  $k$  和  $j$  之间的三维位移量; $\mathbf{R}_\gamma^T(k)$  是  $k$  时刻的航向角  $\gamma$  所对应的旋转矩阵; $\mathbf{n}_{jk}$  是测量的零均值高斯白噪声,其协方差大小由神经网络估计的不确定度  $\hat{\boldsymbol{\Sigma}}_j$  给出。将系统线性化后,观测矩阵记为  $\mathbf{H}$ ,其维数为  $3 \times (6m + 15)$ ,其中与  $\mathbf{R}_k, \mathbf{p}_k$  与  $\mathbf{p}_j$  相关的 3 项是不为 0 的三维方阵,其余位置为 0。其中

$$\begin{aligned} \frac{\partial h(\mathbf{E})}{\partial \mathbf{R}_k} &= \\ \mathbf{R}_\gamma^T[\mathbf{p}_k - \mathbf{p}_j] \times &\begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ \cos(\beta)\tan(\gamma) & \sin(\gamma)\tan(\beta) & 1 \end{bmatrix} \end{aligned} \quad (21)$$

$$\frac{\partial h(\mathbf{E})}{\partial \mathbf{p}_k} = -\mathbf{R}_\gamma^T \quad (22)$$

$$\frac{\partial h(\mathbf{E})}{\partial \mathbf{p}_j} = \mathbf{R}_\gamma^T \quad (23)$$

其中,  $\beta$  表示系统的俯仰角,则更新过程可以记为

$$\mathbf{K} = \mathbf{P}\mathbf{H}^T(\mathbf{H}\mathbf{P}\mathbf{H}^T + \hat{\boldsymbol{\Sigma}}_j)^{-1}$$

$$\mathbf{E} = \mathbf{E} \oplus (\mathbf{K}(h(\mathbf{E}) - \hat{\mathbf{d}}_{jk}))$$

$$\mathbf{P} = ((\mathbf{I} - \mathbf{K}\mathbf{H})\mathbf{P}(\mathbf{I} - \mathbf{K}\mathbf{H})^T + \mathbf{K}\hat{\boldsymbol{\Sigma}}_j\mathbf{K}^T) \quad (24)$$

其中,  $\mathbf{K}$  为卡尔曼滤波增益; $\mathbf{P}$  为系统状态协方差矩阵; $\mathbf{E}$  为运动载体的导航状态量; $\oplus$  为在姿态变量更新时采用  $\text{SO}(3)$  群上的加法,其余状态变量采用普通加法。在进行量测更新后,对历史关联状态进行边缘化处理。

## 4 实验结果与分析

### 4.1 数据集

公开行人导航惯性数据集<sup>[11]</sup>对算法进行验证,该数据集利用 Bosch BMI055 IMU,IMU 加速度计噪声密度为  $150 \mu\text{g}/\sqrt{\text{Hz}}$ ,陀螺零偏稳定性为  $1.6 (^\circ)/\text{h}$ 。传

传感器固定于行人头部以 200 Hz 采集惯性数据。完整的数据集包含了总时长超过 60 h 的行人运动数据, 共计 400 多个序列, 包含了 5 个行人的走路、站立静止、整理厨房、打台球和上下楼梯等动作。采用人体穿戴式设备进行数据采集, 并利用 MSCKF 视觉惯性里程计<sup>[23]</sup>提供的位置真值作为基准。视觉惯性里程计在公开的 Euroc 无人机数据集上的绝对轨迹误差为 0.414 m<sup>[24]</sup>, 满足基准数据要求。在数据集中随机选取 80% 数据用于训练, 10% 的数据用于验证, 剩下 10% 的数据用于测试。为适用于神经网络输入, 数据被分割为重叠的固定 1 s 时间窗口数据, 即神经网络输入维度为  $200 \times 6$ 。真值标签则通过计算时间窗口开始与结束两个时刻位置之差获取。

#### 4.2 实验结果

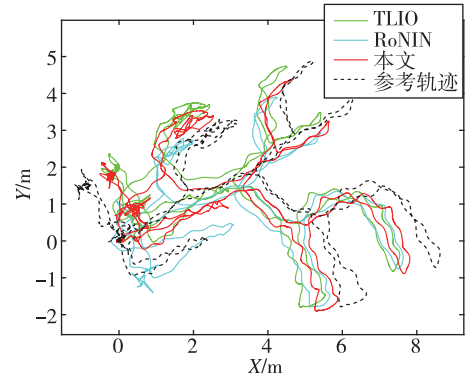
开展 6 组行人导航实验, 每组实验时长约为 3~7 min, 训练和测试都基于 Nvidia RTX 3090 计算平台。实验结果与两种基于深度学习的行人惯性导航方法 RoNIN<sup>[10]</sup> 和 TLIO<sup>[11]</sup> 进行对比。测试评价标准主要是对定位结果进行评估, 评价结果包括绝对轨迹误差 (absolute trajectory error, ATE) 和漂移率 (drift rate, DR) 两个方面的评估, 如式 (25) 及式 (26) 所示。

$$A(m) = \sqrt{\frac{1}{n} \sum_i^n \|\mathbf{p}_i - \hat{\mathbf{p}}_i\|} \quad (25)$$


$$D = (\|\mathbf{p}_n - \hat{\mathbf{p}}_n\|) / L \quad (26)$$

其中,  $\mathbf{p}$  是 IMU 算法的位置估计值;  $\hat{\mathbf{p}}$  是视觉惯性里程计提供的位置真值;  $L$  是轨迹总长度。

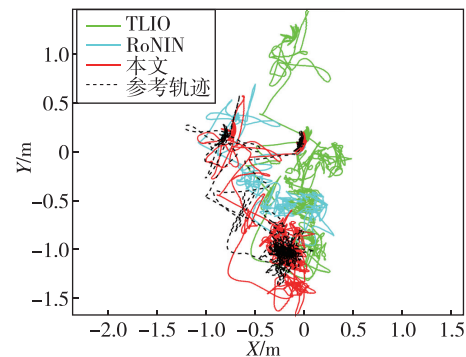
测试数据集中部分序列定位结果如图 4 所示。通过结果可以看出, 基于时序状态学习模型的行人惯性导航算法相较于 TLIO 与 RoNIN 方法, 其轨迹漂移误差更小, 在行人运动过程中能够提供更为准确的位置估计信息。通过将所提出的基于时序状态学习模型的惯性导航算法与 TLIO 和 RoNIN 算法在绝对轨迹误差和漂移率方面进行对比, 由图 5 定位误差累积分布函数 (cumulative distribution function, CDF) 可以看出, 在整个数据集上, 本文算法的绝对轨迹误差和漂移率整体要小于 TLIO 与 RoNIN, 本文算法定位结果精度更高。另外, 通过将本文算法中的扩展卡尔曼滤波部分替换掉, 只利用真值提供的航向进行航位推算, 其误差分布如图 5 中橙色实线所示, 与本文结果对比也可以看出, 算法中滤波模块有效减少了误差, 定位精度得到提高。




(a) 实验 1



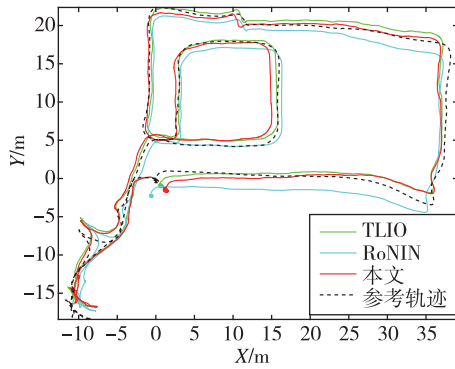
(b) 实验 2



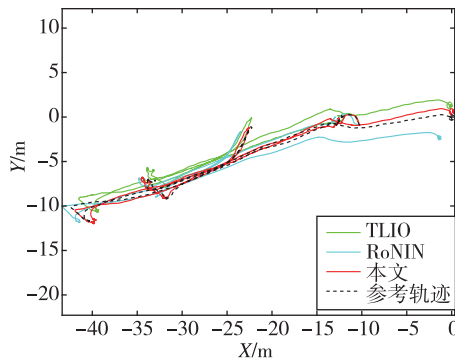
(c) 实验 3



(d) 实验 4




(e) 实验 5




(f) 实验 6

图 4 定位结果对比

Fig. 4 Comparison of positioning results



(a) 绝对轨迹误差 CDF



(b) 漂移率误差 CDF

图 5 定位误差 CDF

Fig. 5 Positioning error CDF

将实验的绝对轨迹误差和位移漂移率取均值可以得到表 1 所示的结果。通过对数值的定量分析可以看到,本文算法的平均绝对轨迹误差为 0.92 m,位

表 1 测试数据集定位误差汇总

Tab. 1 Positioning error summary in test datasets

轨迹总长度/m	绝对轨迹误差均值(ATE)/m			位移漂移率均值(DR)/%		
	RoNIN	TLIO	本文	RoNIN	TLIO	本文
实验 1	76.66	1.12	<b>0.81</b>	1.96	<b>1.21</b>	1.30
实验 2	141.49	2.34	<b>1.36</b>	3.51	1.58	<b>0.72</b>
实验 3	59.80	0.58	<b>0.20</b>	0.59	2.16	<b>0.35</b>
实验 4	213.90	2.59	<b>1.36</b>	1.23	1.05	<b>0.84</b>
实验 5	246.60	1.40	<b>1.17</b>	0.85	<b>0.44</b>	0.63
实验 6	129.21	1.38	<b>0.56</b>	2.08	1.11	<b>0.62</b>
平均	144.61	1.57	<b>0.92</b>	1.70	1.26	<b>0.74</b>

移漂移率为 0.74%, 相较于 TLIO 分别提升了 32.35% 和 41.27%。尤其是在实验 3 中,行人在小范围内不断运动,TLIO 与 RoNIN 算法结果均产生了不同程度上的偏移,而本文算法依然能够对行人运动状态进行有效估计。尽管在实验 5 中本文算法定位误差相对较大,但依然实现了 1.17 m 的绝对定位误差与 0.63 m 的位移漂移率,满足实际需求。

## 5 结论

本文提出了一种新型的基于时序状态学习模型的行人惯性导航算法,通过引入可学习状态空间模型对隐式惯性编码信息进行时序建模,有效提高了基于深度学习的行人惯性导航算法定位精度。

1) 该算法采用具有选择性的隐式状态空间模型对时序惯性数据进行建模,对固定时间窗口内的



运动位移以及不确定性进行估计,并将位移估计量作为观测量输入扩展卡尔曼滤波算法,进而对惯性导航系统状态进行估计。

2)通过实验验证,经时序建模后的里程计模型定位精度进一步提升,相较于 TLIO 绝对轨迹误差和位移漂移率分别提升了 32.35%和 41.27%。

3)后续,可在本文工作的基础上进一步考虑网络模型的轻量化与加速推理等相关工作,以进一步推动基于神经网络的惯性里程计方法在手机、VR 眼镜等实际系统中的部署与应用。

### 参考文献

- [1] 陶幸,俞帆山,宋越杰,等. 基于惯性传感器的免对准动作的人体上肢运动捕捉方法[J]. 飞控与探测, 2024, 7(2): 28-35.  
TAO Xing, YU Fanshan, SONG Yuejie, et al. Method of motion capture of human upper limbs without alignment based on inertial sensors[J]. Flight Control & Detection, 2024, 7(2): 28-35(in Chinese).
- [2] FOXLIN E. Pedestrian tracking with shoe-mounted inertial sensors[J]. IEEE Computer Graphics and Applications, 2005, 25(6): 38-46.
- [3] JIANG C, CHEN Y, CHEN C, et al. Smartphone PDR/GNSS integration via factor graph optimization for pedestrian navigation[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-12.
- [4] MAGSI A H, DÍEZ L E. Comparison of FGO and KF for PDR-GNSS fusion under different PDR errors[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-12.
- [5] KANG W, HAN Y. SmartPDR: smartphone-based pedestrian dead reckoning for indoor localization[J]. IEEE Sensors Journal, 2015, 15(5): 2906-2916.
- [6] GUO S, ZHANG Y, GUI X, et al. An improved PDR/UWB integrated system for indoor navigation applications[J]. IEEE Sensors Journal, 2020, 20(14): 8046-8061.
- [7] LIU H, GAO Z, WANG L, et al. Reliable positioning model of smartphone sensors and user motions tightly enhanced PDR[J]. IEEE Internet of Things Journal, 2024, 11(19): 30925-30938.
- [8] CHEN C, LU X, MARKHAM A, et al. IONet: learning to cure the curse of drift in inertial odometry [C]// Proceedings of 32<sup>nd</sup> AAAI Conference on Artificial Intelligence. New Orleans; AAAI, 2018.
- [9] CHEN C, LU C X, WAHLSTROM J, et al. Deep neural network based inertial odometry using low-cost inertial measurement units[J]. IEEE Transactions on Mobile Computing, 2021, 20(4): 1351-1364.
- [10] HERATH S, YAN H, FURUKAWA Y. RoNIN: robust neural inertial navigation in the wild: benchmark, evaluations, & new methods[C]// Proceedings of 2020 IEEE International Conference on Robotics and Automation (ICRA). Paris: IEEE, 2020: 3146-3152.
- [11] LIU W, CARUSO D, ILG E, et al. TLIO: tight learned inertial odometry[J]. IEEE Robotics and Automation Letters, 2020, 5(4): 5653-5660.
- [12] SUN S, MELAMED D, KITANI K. IDOL: inertial deep orientation-estimation and localization[C]// Proceedings of 35<sup>th</sup> AAAI Conference on Artificial Intelligence. New York; AAAI, 2021: 6128-6137.
- [13] WANG Y, KUANG J, NIU X, et al. LLIO: lightweight learned inertial odometer[J]. IEEE Internet of Things Journal, 2023, 10(3): 2508-2518.
- [14] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [Z]. arXiv preprint arXiv: 1803.01271, 2018.
- [15] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30: 5998-6008.
- [16] GU A, GOEL K, RÉ C. Efficiently modeling long sequences with structured state spaces[C]// Proceedings of International Conference on Learning Representations (ICLR). New Orleans; IEEE, 2022.
- [17] GU A, DAO T. Mamba: linear-time sequence modeling with selective state spaces [J]. arXiv preprint arXiv: 2312.00752, 2024.
- [18] LI K, CHEN G. SPMamba: state-space model is all you need in speech separation [J]. arXiv preprint arXiv: 2404.02063, 2024.
- [19] ZHU L, LIAO B, ZHANG Q, et al. Vision Mamba: efficient visual representation learning with bidirectional state space model [J]. arXiv preprint arXiv: 2401.09417, 2024.
- [20] XIANG Q, CHENG J, LUO J, et al. OverlapMamba: novel shift state space model for LiDAR-based place recognition[J]. arXiv preprint arXiv: 2405.07966, 2024.
- [21] TAN M, LE Q V. EfficientNet: rethinking model scaling for convolutional neural networks[J]. arXiv preprint arXiv: 1905.11946, 2020.
- [22] MOURIKIS A, ROUMELIOTIS S I. A multi-state constraint Kalman filter for vision-aided inertial navigation[C]// Proceedings of IEEE International Con-

- ference on Robotics and Automation. Rome: IEEE, 2007: 3565-3572.
- [23] MOURIKIS A I, ROUMELIOTIS S I. A multi-state constraint Kalman filter for vision-aided inertial navigation[C]//Proceedings of IEEE International Conference on Robotics and Automation. Rome: IEEE, 3565-3572.
- [24] CAMPOS C, ELVIRA R, RODRÍGUEZ J J G, et al. ORB-SLAM3: an accurate open-source library for visual, visual-inertial, and multimap SLAM[J]. IEEE Transactions on Robotics, 2021, 37(6): 1874-1890.

(编辑:孟彬)