

DOI: 10.19650/j.cnki.cjsi.J2311607

基于双通道 Residual-LSTM 的 SINS/GNSS 组合导航算法*

奔粤阳,王奕霏,李 倩,魏廷梹,周一帆

(哈尔滨工程大学智能科学与工程学院 哈尔滨 150001)

摘 要:针对全球导航卫星系统信号中断情况下 SINS/GNSS 组合导航系统无法持续进行误差校正的问题,提出一种基于双通道 Residual-LSTM 的 SINS/GNSS 组合导航算法。首先,考虑到 SINS 经度、纬度误差传播特性不同所导致的模型输入、输出信息之间的非线性相关性差异化,构建具有不同权重系数的双通道长短期记忆神经网络模型结构,并引入遗忘信息共享机制自适应地利用历史导航数据对经度、纬度信息进行拟合预测。其次,针对深层神经网络存在的模型退化和梯度消失问题,在多层双通道 LSTM 网络之间建立残差高速通道形成 Residual-LSTM 模型结构,以增加不同网络层次之间的信息传播路径。最后,通过实船数据验证本文所提算法的有效性。实验结果表明,与基于常规智能方法的 SINS/GNSS 组合导航算法相比,所提组合导航算法在 GNSS 信号中断期间经度误差降低了 51.97%,纬度误差降低了 31.45%。

关键词: SINS/GNSS 组合导航; GNSS 中断; 双通道结构; 残差长短期记忆神经网络; 深度神经网络

中图分类号: TH39 U675.5

文献标识码: A

国家标准学科分类代码: 420.99

SINS/GNSS integrated navigation algorithm based on dual-channel Residual-LSTM

Ben Yueyang, Wang Yifei, Li Qian, Wei Tingxiao, Zhou Yifan

(School of Intelligent Science and Engineering, Harbin Engineering University, Harbin 150001, China)

Abstract: In response to the issue of the inability of SINS/GNSS integrated navigation system to continuously correct errors in the event of a global navigation satellite system signal interruption, a dual-channel Residual-LSTM based SINS/GNSS integrated navigation algorithm is proposed. First, considering the nonlinear correlation difference between the input and output information of the model caused by the different transmission characteristics of SINS longitude and latitude errors, a dual-channel long and short-term memory neural network model structure with different weight coefficients was constructed. A adaptive forgetting information sharing mechanism was introduced to effectively use historical navigation data to fit and predict the longitude and latitude information. Second, in view of the model degradation and gradient vanishing problems existing in deep neural networks, a Residual-LSTM model structure is formed by establishing a Residual-LSTM high-speed channel between multi-layer and dual-channel LSTM networks to increase the information propagation paths between different network layers. Finally, the effectiveness of the proposed algorithm is verified by the real ship data. The experimental results show that compared with the SINS/GNSS integrated navigation algorithm based on conventional intelligence method, the proposed integrated navigation algorithm reduces the longitude error by 51.97% and latitude error by 31.45% during the GNSS signal interruption period.

Keywords: SINS/GNSS integrated navigation; GNSS interrupt; dual channel structure; residual long short term memory neural network; deep neural network

0 引 言

在惯性基组合导航系统中,作为核心导航设备的捷联式惯性导航系统(strapdown inertial navigation system, SINS)在长航时工作条件下存在误差累积问题,因此需要利用其他辅助导航设备输出校正其误差,从而达到提高系统导航定位性能的目的^[1]。利用全球导航卫星系统(global navigation satellite system, GNSS)输出的位置、速度信息与 SINS 构建 SINS/GNSS 组合导航系统是工程应用中常见的一种组合方式。但是,在桥梁、树木等遮挡环境中以及恶劣天气情况下,GNSS 信号易出现中断不可用情况。GNSS 信号长期中断时,SINS 误差将不断累积,甚至发生超差现象,从而降低 SINS/GNSS 组合导航系统性能。针对 SINS/GNSS 组合导航过程中卫导信号中断问题,Khalaf-Allah 等^[2]提出可以基于方位与距离的航位推算(dead reckoning, DR)在卫导信号丢失时为移动终端提供一种简单的位置信息维护方法。文献[3]提出了基于新息估计的自适应卡尔曼滤波算法,利用实际新息的测量计算直接修正卡尔曼滤波器增益,提高卫导信号失效时卡尔曼滤波器的精度和鲁棒性。近年来,随着人工智能理论的不断突破,有研究人员将相关理论与方法用于解决组合导航系统中的卫星信号拒止问题。文献[4]通过训练径向基函数神经网络(radial basis function neural networks, RBFNN)模拟 INS 位置以及 INS 与 GPS 之间的位置误差。EI-Sheimy 等^[5]提出了一种 INS/GPS 组合方法,通过人工神经网络(artificial neural network, ANN)学习未补偿的 INS 测量值与差分 GPS 测量值之间的关联性,从而在 GPS 信号异常时使用 INS 数据代替 GPS 数据,以实现导航定位的目的。文献[6]分析了反向传播神经网络(backpropagation network, BPN)、全连接概率网络(fully connected probabilistic network, FCPN)、自适应共振理论-互补模式网络(adaptive resonance theory-complementary pattern network, ART-CPN)、卷积神经网络(convolutional neural network, CNN)以及高阶神经网络(higher order neural network, HONN)在 GPS 拒止场景下对 INS 位置误差的预测性能。考虑到 GNSS 测量时间差的变化,文献[7]建立了一种基于多层感知器(multilayer perceptron, MLP)神经网络的智能算法,用于 GNSS 失效时为组合导航系统提供伪 GNSS 位置校正 SINS 误差。除传统神经网络以外,集成模型^[8]、支持向量机(support vector machine, SVM)^[9]与遗传算法^[10]也被用来解决 GNSS 信号拒止时组合导航系统的误差校正问题。

值得注意的是,上述方法均基于静态神经网络而未使用历史信息,因此所构建的神经网络模型缺乏导航时

间序列数据的先前动态,从而使得上述方法无法保证 GNSS 长时间中断时的导航精度。在处理时间序列数据和非线性系统建模方面,递归神经网络(recurrent neural network, RNN)比机器学习方法更有优势^[11]。文献[12]将 RNN 与无迹卡尔曼滤波器(UKF)相结合,估计和补偿 MEMS 陀螺仪的随机漂移。但是,在处理长时间序列数据时,RNN 易出现梯度消失和梯度爆炸的问题^[13]。为解决该问题,研究人员使用基于 RNN 构建的长短期记忆神经网络(long short-term memory neural networks, LSTM)辅助组合导航系统^[14-16]。文献[17]中引入 LSTM 自适应地使用 SINS 历史时刻的比力和角速率信息预测 GPS 中断期间的伪 GPS 信息。需要注意的是,上述文献利用 LSTM 构建组合导航系统时均采用传统的单通道结构,即利用同一套权重系数对 SINS 经度、纬度等不同位置信息输出进行拟合预测。但是,惯性导航系统经度误差与纬度误差传播特性具有明显的差异性,因此其与神经网络模型输入信息之间的非线性相关性也存在一定差异性。所以,传统单通道神经网络结构通常无法令 SINS 经、纬度位置信息同时获得最佳拟合效果。

针对上述问题,本文提出一种基于双通道 Residual-LSTM 模型结构的 SINS 位置预测方法。LSTM 两通道采用相同的模型输入信息,但针对经度与纬度模型输出信息则采用不同的权重系数进行训练与预测。同时,在双通道 LSTM 模型中引入“遗忘信息”,并分别为两通道的遗忘信息赋予权重,将各自遗忘信息融合处理后在两通道中共享以简化模型,从而保证双通道 LSTM 模型泛化能力^[18-19]的同时,使得两通道均可以自适应地利用历史信息更新各自记忆单元状态。除此之外,在传统深层 LSTM 模型中引入残差模块(Residual),即在第 2 层与第 4 层双通道 LSTM 层之间直接建立恒等映射与残差连接,从而在解决梯度消失与模型退化问题的同时提高模型训练效率^[20]。最后,利用实船数据构建算法训练数据集与测试集,验证本文所提算法对于提高 SINS/GNSS 组合导航系统性能的有效性。

1 算法框架设计

本文采用 GNSS 位置增量信息作为模型训练阶段的期望输出,SINS 位置更新公式如下:

$$\Delta \mathbf{P}_k^n = f(\mathbf{v}_k^n) \quad (1)$$

其中, $\Delta \mathbf{P}_k^n$ 为 t_k 时刻位置增量信息, $\mathbf{v}_k^n$ 为 t_k 时刻速度信息, f 为描述两者映射关系的函数,可以由 SINS 位置解算原理得到。

SINS 速度更新过程如下所示:

$$\mathbf{v}_k^n = \mathbf{v}_{k-1}^n + \Delta \mathbf{v}_{sf,k}^n + \Delta \mathbf{v}_{cor/g,k}^n \quad (2)$$

其中, $\Delta \mathbf{v}_{sf,k}^n$ 为 t_k 时刻导航系(n 系)比力速度增量;

$\Delta \mathbf{v}_{cor/g,k}^n$ 为 t_k 时刻有害加速度的速度增量。具体表达式为:

$$\begin{cases} \Delta \mathbf{v}_{sf,k}^n = [\mathbf{I} - (0.5[(\boldsymbol{\omega}_{ie}^n + \boldsymbol{\omega}_{en}^n)(t_k - t_{k-1})] \times \\ \quad)] \mathbf{C}_{b(k-1)}^n \Delta \mathbf{v}_{sf,k}^{b(k-1)} \\ \Delta \mathbf{v}_{sf,k}^{b(k-1)} = \Delta \mathbf{v}_k + 0.5 \Delta \boldsymbol{\theta}_k \times \Delta \mathbf{v}_k + \left(\frac{1}{12}\right) \times \\ \quad (\Delta \boldsymbol{\theta}_{k-1} \times \Delta \mathbf{v}_k + \Delta \boldsymbol{\theta}_k \times \Delta \mathbf{v}_{k-1}) \\ \Delta \mathbf{v}_{cor/g,k}^n = \{[\mathbf{g}^n - (2\boldsymbol{\omega}_{ie}^n + \boldsymbol{\omega}_{en}^n) \times \mathbf{v}^n]\} \times \\ \quad (t_k - t_{k-1}) \end{cases} \quad (3)$$

其中, $\mathbf{g}^n$ 为重力加速度; $\boldsymbol{\omega}_{ie}^n$ 为地球自转角速度在 n

$$\mathbf{C}_b^n = \begin{bmatrix} \cos \theta \cos \psi & -\cos \gamma \sin \psi + \sin \gamma \sin \theta \cos \psi & \sin \gamma \sin \psi + \cos \gamma \sin \theta \cos \psi \\ \cos \theta \sin \psi & \cos \gamma \cos \psi + \sin \gamma \sin \theta \sin \psi & -\sin \gamma \cos \psi + \cos \gamma \sin \theta \sin \psi \\ -\sin \theta & \sin \gamma \cos \theta & \cos \gamma \cos \theta \end{bmatrix} \quad (6)$$

由式(2)~(6)可知, $\mathbf{v}_k^n$ 是关于 $\mathbf{C}_b^n$ 、 $\boldsymbol{\omega}_{ie}^n$ 、 $\boldsymbol{\omega}_{en}^n$ 、 $\mathbf{g}^n$ 、 $\mathbf{v}^n$ 、 $\Delta \mathbf{v}$ 、 $\Delta \boldsymbol{\theta}$ 的函数。除此之外, $\Delta \mathbf{v}$ 和 $\Delta \boldsymbol{\theta}$ 为加速度计和陀螺仪输出信息增量,由下式计算:

$$\Delta \mathbf{v}_k = \int_{t_{k-1}}^{t_k} \mathbf{f}_{ib}^b dt \quad (7)$$

$$\Delta \boldsymbol{\theta}_k = \int_{t_{k-1}}^{t_k} \boldsymbol{\omega}_{ib}^b dt \quad (8)$$

则 $\Delta \mathbf{P}_k^n$ 可以进一步表示为:

$$\Delta \mathbf{P}_k^n = f(\Delta \mathbf{v}_k^n) = f(\mathbf{C}_b^n, \boldsymbol{\omega}_{ie}^n, \boldsymbol{\omega}_{en}^n, \mathbf{v}^n, \mathbf{f}_{ib}^b, \boldsymbol{\omega}_{ib}^b) \quad (9)$$

其中, $\mathbf{f}_{ib}^b$ 为加速度计比力输出; $\boldsymbol{\omega}_{ib}^b$ 为陀螺仪角速度输出。

通过以上分析可知,位置增量 $\Delta \mathbf{P}^n$ 主要受 $\mathbf{f}_{ib}^b$ 、 $\boldsymbol{\omega}_{ib}^b$ 、 $\boldsymbol{\omega}_{ie}^n$ 、 $\boldsymbol{\omega}_{en}^n$ 、 $\mathbf{v}^n$ 、 $\mathbf{C}_b^n$ 影响。其中,捷联姿态矩阵 $\mathbf{C}_b^n$ 与载体纵摇、横摇以及航向有关。考虑到 $\boldsymbol{\omega}_{en}^n$ 与 $\boldsymbol{\omega}_{ie}^n$ 量级过小,因此忽略其对模型训练的影响。综上所述,选择 $\mathbf{f}_{ib}^b$ 、 $\boldsymbol{\omega}_{ib}^b$ 、 $\mathbf{v}^n$ 、 θ 、 γ 和 ψ 作为模型输入特征量。

如图1所示,本文设计的组合导航辅助方法主要分为两个阶段,即训练阶段和预测阶段。图1中 δ 表示卡尔曼滤波器输出的估计误差。

当 GNSS 信号可用时, SINS/GNSS 进行正常组合导航,同时利用 GNSS 提供的位置增量信息作为期望输出,采用 $\mathbf{f}_{ib}^b$ 、 $\boldsymbol{\omega}_{ib}^b$ 、 $\mathbf{v}^n$ 、 θ 、 γ 、 ψ 信息作为双通道 Residual-LSTM 神经网络输入用于网络模型训练。当 GNSS 信号中断时,系统进入预测阶段,即利用已训练完成的模型预测 GNSS 位置增量信息,其本质为模型拟合预测包含 SINS 位置解算误差增量的 SINS 位置增量信息。进一步通过对 GNSS 位置增量信息进行积分处理得到伪 GNSS 位置信息代替 GNSS 信号中断期间的位置参考信息,从而保证组合导航系统在 GNSS 信号中断期间持续工作。

系的投影; $\boldsymbol{\omega}_{en}^n$ 是 n 系相对于地球系(e 系)的旋转角速度在 n 系的投影; $\mathbf{C}_b^n$ 为载体系(b 系)相对于 n 系的捷联姿态矩阵,具体表达式如式(4)所示。其中, $\mathbf{A} = [\theta, \gamma, \psi]^T$ 分别代表纵摇角、横摇角、航向角。

$\boldsymbol{\omega}_{ie}^n$ 和 $\boldsymbol{\omega}_{en}^n$ 可以通过地理纬度(φ)、高度(h)和速度($\mathbf{v}^n$)来计算,公式如下:

$$\boldsymbol{\omega}_{ie}^n = [0, \omega_{ie} \cos \varphi, -\omega_{ie} \sin \varphi]^T \quad (4)$$

$$\boldsymbol{\omega}_{en}^n = \left[\frac{-v_N}{R_M + h}, \frac{v_E}{R_N + h}, \frac{v_E \tan \varphi}{R_N + h} \right]^T \quad (5)$$

其中, R_M 为子午圈曲率半径, R_N 为卯酉圈曲率半径。

$$\begin{bmatrix} \sin \gamma \sin \psi + \cos \gamma \sin \theta \cos \psi \\ -\sin \gamma \cos \psi + \cos \gamma \sin \theta \sin \psi \\ \cos \gamma \cos \theta \end{bmatrix} \quad (6)$$





图1 基于双通道 Residual-LSTM 神经网络的组合导航原理

Fig. 1 The principle of integrated navigation system based on dual-channel Residual-LSTM

2 双通道 Residual-LSTM 设计

2.1 双通道 LSTM 网络模块

SINS 解算位置 $\mathbf{P}_{SINS}$ 可以表示为:

$$\mathbf{P}_{SINS} = \mathbf{P}_{TRUE} + \delta \mathbf{P}_{SINS} \quad (10)$$

其中, $\mathbf{P}_{TRUE}$ 表示真实位置信息; $\delta \mathbf{P}_{SINS}$ 表示 SINS 解算位置误差。

根据式(10),可以得到 t_k 时刻真实位置增量表达式为:

$$\begin{aligned} \Delta \mathbf{P}_{TRUE}(t_k) &= [\mathbf{P}_{SINS}(t_k) - \delta \mathbf{P}_{SINS}(t_k)] - [\mathbf{P}_{SINS}(t_{k-1}) - \delta \mathbf{P}_{SINS}(t_{k-1})] \\ &= \Delta \mathbf{P}_{SINS}(t_k) - [\delta \mathbf{P}_{SINS}(t_k) - \delta \mathbf{P}_{SINS}(t_{k-1})] \end{aligned} \quad (11)$$

根据式(11)可以看出,位置增量 $\Delta \mathbf{P}_{TRUE}(t_k)$ 包含了SINS位置解算误差增量。在忽略GNSS误差的前提下,可以将GNSS位置输出信息近似看作真实位置信息,因此可以认为GNSS输出的位置增量信息能够体现SINS位置解算误差增量,这也是本文在网络模型训练阶段选择GNSS提供的位置增量信息作为期望输出的原因。

SINS误差传播过程本质上是一个复杂的时变系统,其与载体航行机动状态密切相关,因此一般无法求得准确解析解。但是,静基座条件下可将SINS简化为线性定常系统,此时系统误差传播特性相对简单,故可通过求解定常系统解析解了解SINS误差传播的基本特性。

静基座条件下,SINS姿态误差方程如下:

$$\dot{\phi}_E = \omega_U \phi_N - \omega_N \phi_U - \delta v_N / R_M - \varepsilon_E \quad (12)$$

$$\dot{\phi}_N = -\omega_U \phi_E - \omega_U \delta \varphi + \delta v_E / R_N - \varepsilon_N \quad (13)$$

$$\dot{\phi}_U = \omega_N \phi_E + \omega_N \delta \varphi + \delta v_E \tan \varphi / R_M - \varepsilon_U \quad (14)$$

其中, ω_N 和 ω_U 为 ω_{ie}^n 的分量形式; ε_E 、 ε_N 和 ε_U 为陀螺漂移误差; δv_N 和 δv_E 为速度误差。

速度误差方程如下:

$$\delta \dot{v}_E = -g \phi_N + 2\omega_U \delta v_N + \nabla_E \quad (15)$$

$$\delta \dot{v}_N = g \phi_E - 2\omega_U \delta v_E + \nabla_N \quad (16)$$

其中, ∇_E 和 ∇_N 为加速度计零偏误差。

位置误差方程如下:

$$\delta \dot{\varphi} = \delta v_N / R_M \quad (17)$$

$$\delta \dot{\lambda} = \delta v_E \sec \varphi / R_N \quad (18)$$

根据式(12)~(18)分析可知,经度误差 $\delta \lambda$ 仅是东向速度误差 δv_E 的一次积分,其误差传播过程相对独立。与经度误差不同,纬度误差 $\delta \varphi$ 与模型输入信息 $\mathbf{x} = [\mathbf{f}_{ib}^b, \omega_{ib}^b, \mathbf{v}^n, \theta, \gamma, \psi]^T$ 具有更强的非线性相关性。

针对SINS经度、纬度误差传播特性不同所导致的模型输入、输出信息之间非线性相关性差异化的问题,本文在LSTM网络结构中构建双通道模型,如图2所示。

图2中,经度与纬度信号传播通道分别用实线框与虚线框表示。由图2可知,双通道LSTM模型中经度通道与纬度通道具有相同输入 $\mathbf{x}_t$,但两通道使用不同的模型权重矩阵 $\mathbf{W}_x$ 与 $\mathbf{W}_y$,且在模型训练过程中两通道权重矩阵互不干扰。通过以上分析可知,本文提出的LSTM模型采取双通道结构分别拟合预测经、纬度增量信息,因此可以有效解决SINS经度、纬度误差传播特性不同导致的模型输入、输出信息间非线性相关性差异化问题。下




图2 双通道LSTM模型

Fig. 2 Dual channel LSTM module

面对双通道LSTM模型信号前向流通过程进行介绍。

图2中,双通道LSTM模型基本单元包括输入门、遗忘门、遗忘信息和输出门,分别用 i_t 、 f_t 、 g_t 和 o_t 表示。两通道均采用导航参数信息 $\mathbf{x}$ 作为当前时间窗口的模型输入信息,其首先与两通道中前一时间窗口的模型隐藏层单元 $\mathbf{h}_{t-1,x}$ 、 $\mathbf{h}_{t-1,y}$ 经Sigmoid函数(σ)组成各自的遗忘门 $f_{t,x}$ 和 $f_{t,y}$,即:

$$\begin{cases} f_{t,x} = \sigma(\mathbf{W}_{xf,x} \mathbf{x}_t + \mathbf{W}_{hf,x} \mathbf{h}_{t-1,x} + \mathbf{b}_{f,x}) \\ f_{t,y} = \sigma(\mathbf{W}_{yf,y} \mathbf{x}_t + \mathbf{W}_{hf,y} \mathbf{h}_{t-1,y} + \mathbf{b}_{f,y}) \end{cases} \quad (19)$$

其中,下角标 x 和 y 分别代表经度通道参数和纬度通道参数。 $\mathbf{W}_{xf}$ 为遗忘门中输入关于 $\mathbf{x}_t$ 的权重; $\mathbf{W}_{hf}$ 为遗忘门中输入关于 $\mathbf{h}_{t-1}$ 的权重; $\mathbf{b}_f$ 为遗忘门的偏置量。

遗忘门与各自通道前一时间窗口内的模型长时记忆单元 $\mathbf{C}_{t-1,x}$ 、 $\mathbf{C}_{t-1,y}$ 共同确定两通道的遗忘信息 $\mathbf{g}_{t,x}$ 、 $\mathbf{g}_{t,y}$,公式如下:

$$\mathbf{g}_t \begin{cases} \mathbf{g}_{t,x} = f_{t,x} \circ \mathbf{C}_{t-1,x} \\ \mathbf{g}_{t,y} = f_{t,y} \circ \mathbf{C}_{t-1,y} \end{cases} \quad (20)$$

其中, $\circ$ 为向量或矩阵的对应元素相乘。

进一步,模型利用当前时间窗口的模型输入信息 $\mathbf{x}_t$ 与 $\mathbf{h}_{t-1,x}$ 、 $\mathbf{h}_{t-1,y}$ 通过Sigmoid函数组成各通道输入门 $i_{t,x}$ 、 $i_{t,y}$,即:

$$\mathbf{i}_t \begin{cases} i_{t,x} = \sigma(\mathbf{W}_{xi,x} \mathbf{x}_t + \mathbf{W}_{hi,x} \mathbf{h}_{t-1,x} + \mathbf{b}_{i,x}) \\ i_{t,y} = \sigma(\mathbf{W}_{xi,y} \mathbf{x}_t + \mathbf{W}_{hi,y} \mathbf{h}_{t-1,y} + \mathbf{b}_{i,y}) \end{cases} \quad (21)$$

其中, $\mathbf{W}_{xi}$ 为输入门中关于 $\mathbf{x}_t$ 的权重; $\mathbf{W}_{hi}$ 为输入门中关于 $\mathbf{h}_{t-1}$ 的权重; $\mathbf{b}_i$ 为输入门的偏置量。

将加权后的遗忘信息进行张量加和处理,经处理后的遗忘信息在两通道中共享。 $\mathbf{x}_t$ 与 $\mathbf{h}_{t-1,x}$ 、 $\mathbf{h}_{t-1,y}$ 通过tanh函数处理后,同各自通道的输入门与共享的遗忘信息共同更新当前时间窗口的长时记忆单元 $\mathbf{C}_{t,x}$ 、 $\mathbf{C}_{t,y}$,即:

$$\mathbf{C}_t \begin{cases} \mathbf{C}_{t,x} = (\mathbf{W}_{gx,x} \circ \mathbf{g}_{t,x} + \mathbf{W}_{gy,y} \circ \mathbf{g}_{t,y}) + \\ i_{t,x} \circ \tanh(\mathbf{W}_{xc,x} \mathbf{x}_t + \mathbf{W}_{hc,x} \circ \mathbf{h}_{t-1,x} + \mathbf{b}_{c,x}) \\ \mathbf{C}_{t,y} = (\mathbf{W}_{gx,y} \circ \mathbf{g}_{t,x} + \mathbf{W}_{gy,y} \circ \mathbf{g}_{t,y}) + \\ i_{t,y} \circ \tanh(\mathbf{W}_{xc,y} \mathbf{x}_t + \mathbf{W}_{hc,y} \circ \mathbf{h}_{t-1,y} + \mathbf{b}_{c,y}) \end{cases} \quad (22)$$

其中, $\mathbf{W}_g$ 为遗忘信息的权重; $\mathbf{W}_{xc}$ 为 $\tanh$ 层中关于 $\mathbf{x}_t$ 的权重; $\mathbf{W}_{hc}$ 为 $\tanh$ 层中关于 $\mathbf{h}_{t-1}$ 的权重; $\mathbf{b}_c$ 为 $\tanh$ 层的偏置量。

最终,由各自输出门 $\mathbf{o}_{t,x}$ 、 $\mathbf{o}_{t,y}$ 和经 $\tanh$ 函数处理后的 $\mathbf{C}_{t,x}$ 、 $\mathbf{C}_{t,y}$ 确定两通道当前时间窗口的隐藏层单元 $\mathbf{h}_{t,x}$ 、 $\mathbf{h}_{t,y}$ 。具体计算公式如下:

$$\mathbf{o}_t \begin{cases} \mathbf{o}_{t,x} = \sigma(\mathbf{W}_{xo,x}\mathbf{x}_t + \mathbf{W}_{ho,x}\mathbf{h}_{t-1,x} + \mathbf{b}_{o,x}) \\ \mathbf{o}_{t,y} = \sigma(\mathbf{W}_{xo,y}\mathbf{x}_t + \mathbf{W}_{ho,y}\mathbf{h}_{t-1,y} + \mathbf{b}_{o,y}) \end{cases} \quad (23)$$

$$\mathbf{h}_t \begin{cases} \mathbf{h}_{t,x} = \mathbf{o}_{t,x} \odot \tanh(\mathbf{C}_{t,x}) \\ \mathbf{h}_{t,y} = \mathbf{o}_{t,y} \odot \tanh(\mathbf{C}_{t,y}) \end{cases} \quad (24)$$

其中, $\mathbf{W}_{xo}$ 为输出门中关于 $\mathbf{x}_t$ 的权重; $\mathbf{W}_{ho}$ 为输出门中关于 $\mathbf{h}_{t-1}$ 的权重; $\mathbf{b}_o$ 为输出门的偏置量。

在上述双通道 LSTM 前向传播过程中,网络参数是各门结构的权重矩阵和偏置项。反向传播过程中,需要根据输入、输出数据进行误差反向传递以更新网络参数,从而通过学习获得合理的网络参数。在双通道 LSTM 结构中,误差沿 2 个方向进行反向传播。首先,考虑到模型输入时间序列具有一定关联性,所以需要从当前序列位置 t 开始,沿时间向前计算每个时刻的误差项。其次,将误差项向上一隐藏层进行传播。

进一步,本文选择梯度下降法求取误差反向传播过程中更迭后的参数。以双通道 LSTM 中纬度通道为例,首先求取隐藏状态的梯度误差,分别记隐藏状态和记忆单元在序列位置 t 的梯度为 δ_t^h 和 δ_t^c ,将损失函数 $L(t)$ 拆分为序列位置 t 时刻的损失函数 $l(t)$ 和序列位置 t 时刻之后的损失函数 $L(t+1)$,即:

$$L(t) = \begin{cases} l(t) + L(t+1), & t < \tau \\ l(t), & t > \tau \end{cases} \quad (25)$$

最后一个序列位置 τ 时刻的梯度 δ_τ^h 和 δ_τ^c 表示为:

$$\delta_\tau^h = \left(\frac{\partial \mathbf{o}_\tau}{\partial \mathbf{h}_\tau} \right)^T \frac{\partial L_\tau}{\partial \mathbf{o}_\tau} = \mathbf{W}^T(\hat{\mathbf{y}}_\tau - \mathbf{y}_\tau) \quad (26)$$

$$\delta_\tau^c = \left(\frac{\partial \mathbf{h}_\tau}{\partial \mathbf{C}_\tau} \right)^T \frac{\partial L_\tau}{\partial \mathbf{h}_\tau} = \delta_\tau^h * \mathbf{o}_\tau * (1 - \tanh^2(\mathbf{C}_\tau)) \quad (27)$$

其中, $\mathbf{W}$ 为输出层权重矩阵, $\hat{\mathbf{y}}_\tau$ 为模型期望输出, $\mathbf{y}_\tau$ 为模型实际输出。

下面由 δ_{t+1}^h 和 δ_{t+1}^c 反向推导 δ_t^h 和 δ_t^c 。梯度 δ_t^h 由当前层 t 时刻误差和 $t+1$ 时刻误差两部分决定,即:

$$\delta_t^h = \frac{\partial L}{\partial \mathbf{h}_t} = \frac{\partial l(t)}{\partial \mathbf{h}_t} + \left(\frac{\partial \mathbf{h}_{t+1}}{\partial \mathbf{h}_t} \right)^T \frac{\partial l(t+1)}{\partial \mathbf{h}_{t+1}} = \mathbf{W}^T(\hat{\mathbf{y}}_t - \mathbf{y}_t) + \left(\frac{\partial \mathbf{h}_{t+1}}{\partial \mathbf{h}_t} \right)^T \delta_{t+1}^h \quad (28)$$

梯度 δ_t^c 由前一层 $t+1$ 时刻梯度 δ_{t+1}^c 和当前层从 $\mathbf{h}_t$ 传回的梯度两部分组成,即:

$$\delta_t^c = \left(\frac{\partial \mathbf{C}_{t+1}}{\partial \mathbf{C}_t} \right)^T \frac{\partial L}{\partial \mathbf{C}_{t+1}} + \left(\frac{\partial \mathbf{h}_t}{\partial \mathbf{C}_t} \right)^T \frac{\partial L}{\partial \mathbf{h}_t} =$$

$$\left(\frac{\partial \mathbf{C}_{t+1}}{\partial \mathbf{C}_t} \right)^T \delta_{t+1}^c + \delta_t^h \odot \mathbf{o}_t \odot (1 - \tanh^2(\mathbf{C}_t)) =$$

$$\delta_{t+1}^c \odot \mathbf{f}_{t+1} + \delta_t^h \odot \mathbf{o}_t \odot (1 - \tanh^2(\mathbf{C}_t)) \quad (29)$$

遗忘门权重矩阵 $\mathbf{W}_f$ 的迭代更新过程如下所示:

$$\frac{\partial L}{\partial \mathbf{W}_f} = \sum_{t=1}^{\tau} [\delta_t^c * \mathbf{C}_{t-1} * \mathbf{f}_t * (1 - \mathbf{f}_t)] (\mathbf{h}_{t-1})^T \quad (30)$$

式(25)~(30)为纬度通道遗忘门权重矩阵误差反向传播更新过程。经、纬度两通道中的输入门、输出门权重矩阵误差反向传播更新过程与上述纬度通道遗忘门相似,此处不再赘述。

2.2 Residual-LSTM 模块

与传统 LSTM 网络模型一样,本文所设计的双通道 LSTM 网络模型训练也会随着深度的增加而变得更加困难,训练效率降低,主要原因是深层网络中存在的梯度消失与网络退化问题。

为解决上述问题,本文在双通道 LSTM 网络模型的基础上构建残差(Residual)双通道 LSTM 结构,即将指定第 2 层的输出与第 4 层的输出进行加和处理,加和后的结果则作为第 5 层的输入,即网络第 5 层的输入和第 2 层的输出之间有一个恒等映射和残差连接,网络结构如图 3 所示。




图3 Residual-LSTM 模块

Fig. 3 Residual-LSTM module

传统多层神经网络信息前向传播过程中,数据特征逐层抽象,最终提取出完成任务所需的特征或表示。引入残差模块的多层 LSTM 模型前向传播过程中,输入信号可以从第 2 层直接传播到第 5 层,公式表达如下所示:

$$\mathbf{x}^5 = \alpha^{i2} + \alpha^{i4} = \alpha^{i2} + F(\alpha^{i3}) = \alpha^{i2} + F[F(\alpha^{i2})] \quad (31)$$

其中, $F(\cdot)$ 表示双通道 LSTM 模型中的激活函数; $\mathbf{x}^{i2}$ 表示第 i 层的模型输入信号; α^{ij} 表示第 j 层的模型输

出信号。

式(31)表明,第2层与第5层模型之间包含了一个天然的恒等映射,可以保证第2层信号 α^{l^2} 不经过任何非线性映射直接传递至第5层,改变了原本信号只经过多个非线性映射和激活函数的信息传输模式,从而减少了网络退化的概率,加强模型的特征表示能力,进而提高拟合效率。

除此之外,传统深度学习模型反向传播过程中,梯度计算涉及2层参数之间的交叉相乘,因此会在距离输入较近的网络中产生梯度消失现象。假设最终损失为 ε ,加入残差模块以后,由第5层至第2层模型的反向传播公式如下:

$$\frac{\partial \varepsilon}{\partial \alpha^{l^2}} = \frac{\partial \varepsilon}{\partial \alpha^{l^5}} \left(1 + \frac{\partial F[F(\alpha^{l^2})]}{\partial \alpha^{l^2}} \right)$$

(32)

式(32)表明,残差模块反向传播时,第5层模型信号 α^{l^5} 可以不经过任何中间权重矩阵变换直接传播到第2层,此外不论式(32)右边括号内的偏导项多小,常数项的存在都会避免梯度消失,以缓解梯度消失问题,使得信息流更加顺畅和稳定,从而可以进一步提高模型的拟合效率。

3 实船实验验证

本节利用仿真数据和实船数据验证基于双通道Residual-LSTM的SINS/GNSS组合导航算法的有效性和优越性。

3.1 实船实验条件

实验船上配备了自研光纤捷联惯导系统与GPS构建的SINS/GPS组合导航系统,同时以法国iXblue公司研制的光纤捷联惯导系统PHINS作为基准。PHINS处于组合导航状态时可以提供高精度的姿态信息(误差不超过 0.01°)。自研光纤捷联惯导系统性能指标为:陀螺常值漂移约 $0.01^\circ/\text{h}$,加速度计零偏约 $50\text{ }\mu\text{g}$,惯性传感器采样频率为 100 Hz 。船载试验设备如图4所示。



图 4 船载试验设备

Fig. 4 Shipborne test equipment

实验过程中,采集 $18\text{ }000\text{ s}$ 的实船数据对双通道Residual-LSTM模型进行训练。模型训练完成后,采集 $1\text{ }500\text{ s}$ 时长GPS信号中断期间的数据对本文所提算法进行性能验证。为对比分析,同时利用BP智能辅助算法^[21]、传统LSTM智能辅助算法^[22]和单通道Residual-LSTM智能辅助算法进行数据处理。为保证公平性,各对比算法采用相同模型深度以及模型超参数。

3.2 实验结果与分析

为了进行定量比较分析,选择绝对均值(AMV)与均方根误差(RMSE)作为评价指标。前者反映误差的整体大小,后者反映误差的稳定性。AMV与RMSE的计算公式如下:

$$\left\{ \begin{aligned} \text{AMV} &= (|x_1| + |x_2| + \dots + |x_n|)/n \\ \text{RMSE} &= \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \end{aligned} \right.$$

(33)

其中, $|x_i|$ 表示第 i 个数据点误差的绝对值; n 表示数据集中总数据点数; y_i 表示模型期望输出; $\hat{y}_i$ 表示模型输出。

不同算法得到的轨迹图以及相应位置误差曲线图如图5~6所示。





图 5 不同算法航迹图

Fig. 5 Track of different algorithms



(a) 经度误差图

(a) Longitude error graph




图 6 位置误差曲线图
Fig. 6 Position error graph

从图 5~6 与表 1 可以发现,在 GPS 信号中断期间,由于缺少 GPS 位置信息辅助导致纯惯性导航解算误差快速累积,从而无法满足导航定位精度需求。就智能辅助方法而言,常规 LSTM 方法、单通道 Residual-LSTM 方法和双通道 Residual-LSTM 方法均比 BP 方法具有更好的拟合预测性能,主要原因在于 LSTM 网络属于动态模型,利用了导航时间序列数据的先前动态,从而保证了 GPS 信号长时间中断情况下的导航定位精度。结合图 6 和表 1 对传统 LSTM 方法和单通道 Residual-LSTM 模型进行对比分析,可以发现单通道 Residual-LSTM 模型对经度信息的拟合效果略逊于传统 LSTM 方法,原因归结于单通道 Residual-LSTM 模型本身的模型复杂度更高,而过高的模型复杂度会造成模型过拟合,降低了对经度信

表 1 实验结果分析
Table 1 Analysis of experimental results

误差项	BP		LSTM		单通道 Residual-LSTM		双通道 Residual-LSTM	
	RMSE	AMV	RMSE	AMV	RMSE	AMV	RMSE	AMV
经度/m	34.328 8	30.456 8	10.848 5	10.228 6	14.761 5	13.988 6	7.621 5	6.234 1
纬度/m	18.958 8	15.781 3	13.170 1	12.230 1	12.663 4	11.937 2	9.903 3	6.915 4

息的拟合精度。结合上述分析和表 1 可知,在双通道 Residual-LSTM 模型中设计遗忘信息共享机制的必要性和有效性。对比传统 LSTM、单通道 Residual-LSTM 和双通道 Residual-LSTM 三种智能辅助组合导航方法可以发现,传统 LSTM 方法对经度信息的拟合效果优于其对纬度信息的拟合效果,而单通道 Residual-LSTM 方法对纬度信息的拟合效果更佳,这是由于 SINS 经度、纬度误差传播特性不同而导致的神经网络模型输入、输出信息间非线性相关性差异化,相比之下双通道 Residual-LSTM 方法对经、纬度信息都有着 3 种智能辅助方法中最优的拟合精度,实验结果说明双通道 Residual-LSTM 模型中的双通道结构设计可以对性地对两通道中经、纬度进行拟合预测,进而证明了双通道结构的有效性。

根据表 1 可知,双通道 Residual-LSTM 算法与传统 BP、LSTM 和单通道 Residual-LSTM 算法相比,经度误差分别降低了 77.80%、29.75% 与 48.37% (平均为 51.97%),纬度误差分别降低了 47.76%、24.80% 与 21.80% (平均为 31.45%)。实验结果证明了本文所提出的双通道 Residual-LSTM 算法的有效性,可以有效提高对经纬度信息的拟合预测精度。

除此之外,为了评价残差模块对多层双通道 LSTM 模型性能改进的有效性,基于上述实船数据对双通道 LSTM 模型和双通道 Residual-LSTM 模型进行对比实验。实验过程中使用模型训练时的损失函数值作为对比对象。实验结果分别如图 7 所示。




图 7 模型损失函数值
Fig. 7 The model loss function value

由图 7 可以看出,双通道 LSTM 模型在训练过程中损失函数值波动较大,在训练轮次达到 20 轮后才趋于平缓,这说明双通道 LSTM 模型出现了模型退化和梯度消失的问题。而双通道 Residual-LSTM 模型在训练过程中其损失函数值并未出现波动,平缓迅速下降,在训练轮次 12 轮时趋于平稳,并且平缓后的损失函数值明显低于双通道 LSTM 的收敛损失函数值,由此可见双通道 Residual-LSTM 模型有着更佳模型训练效率和收敛效果。

结合上述分析可知,在双层 LSTM 网络中引入残差 (Residual) 模块,解决了网络模型训练时发生的模型退化和梯度消失问题,使得模型训练更加顺畅和稳定,可以进一步提高模型的拟合效率。

4 结 论

本文提出了一种基于双通道 Residual-LSTM 的 SINS/GNSS 组合导航算法,即在 GNSS 信号拒止时利用构建的双通道 Residual-LSTM 网络模型对 SINS 经度信息与纬度信息分别进行拟合预测,从而保证 SINS/GNSS 组合导航系统在 GNSS 信号中断期间仍然可以正常工作。由于具有不同权重系数的双通道 LSTM 网络模块可以更好的解决 SINS 经度、纬度误差传播特性不同所导致的模型输入、输出信息之间非线性相关性差异化问题,因此本文所提算法较基于传统 BP、LSTM 网络模型的智能辅助导航算法具有更高的定位精度。除此之外,本算法在多层双通道 LSTM 网络之间建立了残差高速通道,从而形成 Residual-LSTM 模型结构增加不同层次之间的信息传播路径,有效解决了复杂多层网络中存在的梯度消失与网络退化问题,从而进一步提高拟合预测性能。最后,利用实船实验数据构建 Residual-LSTM 网络模型数据训练集与测试集,实验结果表明本文所提算法可以在 GNSS 信号中断期间有效抑制 SINS/GNSS 组合导航定位累积误差。

参考文献

- [1] 李倩, 奔粤阳, 于飞, 等. 基于参考椭球体的极区车辆横向捷联惯性导航系统. 汽车工程技术[J]. 汽车工程学报, 2016, 65: 7791-7795.
- LI Q, BEN Y Y, YU F, et al. Transversal strapdown INS based on reference ellipsoid for vehicle in the polar region[J]. IEEE Transactions on Vehicular Technology, 2016, 65: 7791-7795.
- [2] KHALAF-ALLAH M, KYAMAKYA K, IEEE. Position tracking and global localization of mobile terminals in cellular networks [C]. 8th IEEE Workshop on Signal Processing Advances in Wireless Communications, Helsinki, FINLAND, 2007: 51.
- [3] 卞华伟, 金仲和, 田蔚风. 自适应卡尔曼滤波辅助惯性导航系统的研究[J]. 测量科学技术, 2005, 16: 2072-2079.
- BIAN H W, JIN ZH H, TIAN W F. Study on GPS attitude determination system aided INS using adaptive Kalman filter[J]. Measurement Science and Technology, 2005, 16: 2072-2079.
- [4] SHARAF R, NOURELDIN A, OSMAN A, et al. Online INS/GPS integration with a radial basis function neural network [J]. IEEE Aerospace and Electronic Systems Magazine, 2005, 20: 8-14.
- [5] EL-SHEIMY N, CHIANG K W, NOURELDIN A. The utilization of artificial neural networks for multisensor

system integration in navigation and positioning instruments [J]. IEEE Transactions on Instrumentation and Measurement, 2006, 55: 1606-1615.

- [6] MALLESWARAN M, VAIDEHI V, SARAVANASELVAN A, et al. Performance analysis of various artificial intelligent neural networks for GPS/INS integration [J]. Applied Artificial Intelligence, 2013, 27: 367-407.
- [7] 张月新, 王立辉. GNSS 中断时 GNSS/INS 集成的混合智能算法 DGP-MLP [J]. 航海杂志, 2019, 72(2): 375-388.
- ZHANG Y X, WANG L H. A hybrid intelligent algorithm DGP-MLP for GNSS/INS integration during GNSS outages [J]. Journal of Navigation, 2019, 72(2): 375-388.
- [8] 张小跃, 林志立, 张春熹. 基于捷联惯导系统和激光雷达的自主组合导航方法 [J]. 光学工程, 2014, 53(7): 074112.
- ZHANG X Y, LIN ZH L, ZHANG CH X. Autonomous integrated navigation method based on the strapdown inertial navigation system and Lidar [J]. Optical Engineering, 2014, 53(7): 074112.
- [9] 徐田来. 基于支持向量机的 INS/GPS 无缝集成 [C]. 第二届国际测量仪器与自动化会议 (ICMIA 2013), 2013: 277-280.
- XU T L. Seamless INS/GPS integration based on support vector machines [C]. 2nd International Conference on Measurement, Instrumentation and Automation (ICMIA 2013), 2013: 277-280.
- [10] 刘建娟. 基于遗传算法的模糊神经网络在组合导航系统中的应用 [C]. 第二届智能计算技术与自动化国际学术会议, 2009: 656-659.
- LIU J J. Application of fuzzy neural networks based on genetic algorithms in integrated navigation system [C]. 2nd International Conference on Intelligent Computation Technology and Automation, 2009: 656-659.
- [11] 戴海发, 卞鸿巍, 王荣颖, 等. 基于递归神经网络的 INS/GNSS 组合导航 [J]. 国防科技, 2020, 16: 334-340.
- DAI H F, BIAN H W, WANG R Y, et al. An INS/GNSS integrated navigation in GNSS denied environment using recurrent neural network [J]. Defence Technology, 2020, 16: 334-340.
- [12] 李定华, 周珺, 刘莹莹. 基于递归神经网络的无气味卡尔曼滤波实时估计和补偿 MEMS 陀螺仪的随机漂移 [J]. 机械传动系统的设计与应用, 2021, 147: 107057.
- LI D H, ZHOU J, LIU Y Y. Recurrent-neural-network-

- based unscented Kalman filter for estimating and compensating the random drift of MEMS gyroscopes in real time[J]. Mechanical Systems and Signal Processing, 2021, 147:107057.
- [13] 叶强强, 杨雪芹, 陈超波, 等. 基于 LSTM-RNN 模型的河流水质参数预测方法[C]. 第 31 届中国控制与决策会议, 2019: 3024-3028.
- YE Q Q, YANG X Q, CHEN CH B, et al. River water quality parameters prediction method based on LSTM-RNN model[C]. 31st Chinese Control And Decision Conference (CCDC), 2019: 3024-3028.
- [14] 陈怀宇, 尹达一, 张泉. LSTM 网络提高 MEMS 惯导定位精度的分析及验证[J]. 中国惯性技术学报, 2018, 26(5): 610-615.
- [15] 杨璐宁, 刘正华, 温暖. 面向多元未知环境的基于深度高斯过程组合导航轨迹预测方法[J]. 系统工程与电子技术, 2023, 45(11): 3632-3639.
- [16] 刘东亮, 成芳, 沈朋礼, 等. LSTM 辅助车载 GNSS/INS 组合导航算法及性能分析[J]. 全球定位系统, 2023, 48(5): 21-31.
- [17] 张月新. 一种用于 INS/GPS 组合导航系统的 GPS 中断桥接融合方法[J]. 通信技术, 2019, 7: 61296-61306.
- ZHANG Y X. A fusion methodology to bridge GPS outages for INS/GPS integrated navigation system[J]. IEEE Access, 2019, 7: 61296-61306.
- [18] BARTLETT P L, MENDELSON S. Rademacher and gaussian complexities: Risk bounds and structural results[C]. D. HELMBOLD, B. WILLIAMSON. Computational Learning Theory, Proceedings, 2001: 224-240.
- [19] ZHANG C, BENGIO S, HARDT M, et al. Understanding deep learning (still) requires rethinking generalization[J]. Communications of the Acm, 2021, 64: 107-115.
- [20] KIM J, EL-KHAMY M, LEE J, et al. Residual LSTM: design of a deep recurrent architecture for distant speech recognition[C]. 18th Annual Conference of the International-Speech-Communication-Association (INTERSPEECH 2017), 2017: 1591-1595.
- [21] ZHOU Y M, WAN J, LI ZH F, et al. GPS/INS integrated navigation with BP neural network and Kalman filter[C]. IEEE International Conference on Robotics and Biomimetics (ROBIO), 2017: 2515-2520.
- [22] ZHI ZH, LIU D T, LIU L SH. A performance compensation method for GPS/INS integrated navigation system based on CNN-LSTM during GPS outages[J]. Measurement, 2022, 188.

作者简介



奔粤阳 (通信作者), 2003 年于哈尔滨工程大学获得学士学位, 2006 年于哈尔滨工程大学获得硕士学位, 2008 年于哈尔滨工程大学获得博士学位, 2020 年成为哈尔滨工程大学教授/博士生导师, 现任教育部导航仪器工程中心副主任, 负责中心惯性导航研究方向建设。现为教育部学科评估专家, 国家自然科学基金项目同行评议专家, 主要研究方向为惯性导航、智能导航、多传感器信息融合。

E-mail: byy@hrbeu.edu.cn

Ben Yueyang (Corresponding author), received his bachelor's degree from Harbin Engineering University in 2003, master's degree from Harbin Engineering University in 2006, and doctorate degree from Harbin Engineering University in 2008. He became a professor/doctoral supervisor of Harbin Engineering University in 2020, and is currently Deputy Director of Navigation Instrument Engineering Center of the Ministry of Education. Responsible for the construction of the center's inertial navigation research direction. He is now a subject evaluation expert of the ministry of education and a peer review expert of the National Natural Science Foundation project. His main research directions are inertial navigation, intelligent navigation and multi-sensor information fusion.