

doi:10.19306/j.cnki.2095-8110.2021.05.001

## 基于 DKF 的 IMU 误差预测算法

秦闪闪<sup>1,2</sup>, 陈夏兰<sup>1</sup>, 徐颖<sup>1</sup>, 马满帅<sup>3</sup>, 王莹<sup>3</sup>, 梁任腾<sup>3</sup>, 杨子佳<sup>3</sup>

1. 中国科学院空天信息创新研究院导航系统部, 北京 100094;
2. 中国科学院大学电子电气与通讯工程学院, 北京 100049;
3. 北京信息科技大学信息与通信工程学院, 北京 100192)

**摘要:**作为导航领域常用的组合导航方式,全球导航卫星系统(GNSS)/惯性导航系统(INS)组合导航在 GNSS 信号失锁后,由于惯性测量单元(IMU)误差随时间迅速积累,其定位结果会偏离载体真实位置,导航精度下降。针对此问题,提出了一种长短期记忆网络(LSTM)辅助的算法,称之为深度卡尔曼滤波(DKF)算法。DKF 算法的核心思想是使用 LSTM 训练 IMU 误差模型,然后通过训练出的模型预测 IMU 误差,最后将预测的 IMU 误差代入 IMU 数据以校正导航结果。仿真结果表明:在 200s 测试数据上,DKF 算法将误差从 1.1537m/s 降低到 0.3746m/s。与平均预测、卡尔曼预测和最小二乘估计等方法相比,DKF 算法的误差最小,具有更优越的导航性能。

**关键词:**深度卡尔曼滤波;IMU 误差;GNSS/INS 组合导航;长短期记忆网络;卡尔曼滤波

**中图分类号:**TP391;TP181      **文献标志码:**A      **文章编号:**2095-8110(2021)05-0001-08

## IMU Error Prediction Algorithm Based on DKF

QIN Shan-shan<sup>1,2</sup>, CHEN Xia-lan<sup>1</sup>, XU Ying<sup>1</sup>, MA Man-shuai<sup>3</sup>, WANG Ying<sup>3</sup>, LIANG Ren-teng<sup>3</sup>, YANG Zi-jia<sup>3</sup>

1. Navigation Systems Department, Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China;
2. School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049, China;
3. School of Information and Telecommunication Engineering, Beijing Information Science & Technology University, Beijing 100192, China)

**Abstract:** The combined navigation method of Global Navigation Satellite System(GNSS)/Inertial Navigation System(INS) is commonly used in the navigation field. After the GNSS signal loses, due to the rapid accumulation of Inertial Measurement Unit(IMU) errors over time, the positioning results will deviate from the true position of the carrier and the navigation accuracy will decrease. To solve this problem, a Deep Kalman Filter(DKF) algorithm based on Long Short-Term Memory(LSTM) is proposed. The core idea of the DKF algorithm is to use LSTM to train the IMU error model, and then predict the IMU error through the trained model, and finally bring the predicted IMU error into the IMU data to correct the navigation results. The simulation results show that the DKF algorithm reduces the error from 1.1537m/s to 0.3746m/s for the 200s test data. Compared with the methods of average prediction, Kalman prediction and least square estimation, the DKF algorithm has the smallest error and advanced navigation performance.

**Key words:** Deep Kalman Filter(DKF); IMU error; GNSS/INS integrated navigation; Long

收稿日期:2020-10-17;修订日期:2020-12-02

基金项目:国家自然科学基金(41904033);青促会课题(E03314020D);中国科学院战略性先导专项(XDA17020203)

作者简介:秦闪闪(1995-),女,硕士研究生,主要从事卫星导航信息处理技术方面的研究。

通信作者:陈夏兰(1987-),女,工程师,主要从事卫星导航信号处理、接收机设计等方面的研究。

Short-Term Memory(LSTM); Kalman filter

## 0 引言

全球导航卫星系统(Global Navigation Satellite System,GNSS)/惯性导航系统(Inertial Navigation System,INS)组合导航的核心是如何有效地将 GNSS 观测与惯性测量单元(Inertial Measurement Unit, IMU)测量结果结合得到载体导航结果的最优估计,在目前的组合导航技术中,包括松耦合、紧耦合和超紧耦合<sup>[1]</sup>。其中松耦合在软件层面组合,将 GNSS 接收机导航定位结果和 INS 测量结果进行滤波融合<sup>[2-3]</sup>,当前常用的融合算法是卡尔曼滤波(Kalman Filter,KF)<sup>[4-5]</sup>。KF 利用 GNSS 观测量和 IMU 测量结果解算得到 IMU 误差的估计值,再将估计值反馈给 IMU,IMU 测量结果经过估计值校正后作为导航解输出。GNSS/INS 组合导航系统长时间运行的精度更多地依赖于 GNSS,然而实际中存在各种随机的或复杂的误差源,如可见卫星数目、多径效应和仪器内部的量测噪声等,都会使得卫星导航系统的量测噪声随时发生变化,标准 KF 难以对上述变化进行检测和调整,导致其使用的噪声统计特征与事实发生偏差,无法得到最优滤波结果,甚至会出现滤波发散现象<sup>[6]</sup>。为了克服标准 KF 在组合导航中应用的缺点,研究者们开始针对其设计与应用场景相适应的滤波算法。

针对全球定位系统(Global Positioning System, GPS)测量值发生较大变化时如何提高 KF 的滤波精度和鲁棒性的问题,卞鸿巍利用对实际新息的测量计算直接修正卡尔曼滤波器增益,但需要采用 GPS 测量系统为 INS 提供外部修正信息<sup>[7]</sup>。付梦印研究了应用于惯性技术领域的相关法自适应滤波和 Sage-Husa 自适应 KF,然而带有衰减因子或记忆因子的卡尔曼滤波器系统状态维度增加,计算量加大<sup>[8]</sup>。高为广和杨元喜使用反向传播(Back Propagation, BP)神经网络在线修正自适应滤波器的预测值,该算法提高了滤波精度和可靠性,但算法中提到的“经过复杂函数映射到当前函数的网络预测值”难以获取<sup>[9]</sup>。M. Narasimhappa 等优化了 Sage-Husa 自适应鲁棒 KF 算法,更新了自适应比例因子的计算方法,从而有效降低了估计误差的平均值和标准差,但增大了系统计算的复杂度<sup>[10]</sup>。S. Hosseinyalamdary 提出了一种使用递归神经网络训练组合导航观测模型的方法,从

而克服了因 INS 误差模型的复杂性导致的计算误差,但大大增加了算法的计算量<sup>[11]</sup>。

很多高动态导航载体,如快速运动的无人机,也使用 GNSS/INS 组合系统来导航。由于 GNSS 在高动态下跟踪环路可能失锁,在信号被掩盖及多径效应等场景下测量值不准确甚至没有,导致此时的载体只能依赖 IMU 进行导航,导航结果会在时间积累下迅速失去有效性。本文拟解决的问题就是在 GNSS 接收机输出中断或测量结果不可信时,如何在 IMU 独立导航条件下尽可能保持较高的导航精度。关于这个问题,也有学者进行研究,如德国卡尔斯鲁厄大学的研究者通过在无人机上添加磁强计和高程计以解决组合导航的这个问题<sup>[12]</sup>;荷兰特温特大学的研究者则将深度学习的思想引入 KF,利用循环神经网络和长短期神经网络开展了初步的研究<sup>[11]</sup>。

## 1 KF 算法

KF 估计的未知量为状态向量,表示为  $\mathbf{x} \in \mathbf{R}^n$ ,其是一个时间变量,即  $\mathbf{x}_t$  表示时刻  $t$  的状态向量。其与过去直到现在的观测矢量  $\mathbf{z}_{1:t}$  相关,  $\mathbf{z} \in \mathbf{R}^m$ 。设初始状态为  $\mathbf{x}_0$ ,则  $\mathbf{x}_t$  的概率为  $Pr(\mathbf{x}_t | \mathbf{z}_{1:t}, \mathbf{x}_0)$ 。根据极大似然估计(Maximum Likelihood Estimation, MLE)

$$\hat{\mathbf{x}}_t = \operatorname{argmax}_{\mathbf{x}_t} Pr(\mathbf{x}_t | \mathbf{z}_{1:t}, \mathbf{x}_0) \quad (1)$$

系统当前的状态与过去的状态有关,即

$$\hat{\mathbf{x}}_t = \operatorname{argmax}_{\mathbf{x}_t} \frac{Pr(\mathbf{z}_t | \mathbf{x}_t)Pr(\mathbf{x}_t | \mathbf{z}_{1:t-1}, \mathbf{x}_0)}{Pr(\mathbf{z}_{1:t})} \quad (2)$$

去掉常数

$$\hat{\mathbf{x}}_t = \operatorname{argmax}_{\mathbf{x}_t} Pr(\mathbf{z}_t | \mathbf{x}_t)Pr(\mathbf{x}_t | \mathbf{z}_{1:t}, \mathbf{x}_0) \quad (3)$$

应用前一个状态向量的边缘化得到基于前一个状态向量的状态向量估计,即

$$\hat{\mathbf{x}}_t = \operatorname{argmax}_{\mathbf{x}_t} Pr(\mathbf{z}_t | \mathbf{x}_t) \int Pr(\mathbf{x}_t | \mathbf{x}_{1:t-1}) \cdot Pr(\mathbf{x}_{1:t-1} | \mathbf{z}_{1:t-1}, \mathbf{x}_0) d\mathbf{x}_{1:t-1} \quad (4)$$

基于马尔可夫假设,即

$$\hat{\mathbf{x}}_t = \operatorname{argmax}_{\mathbf{x}_t} Pr(\mathbf{z}_t | \mathbf{x}_t) \int Pr(\mathbf{x}_t | \mathbf{x}_{t-1}) \cdot Pr(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}, \mathbf{x}_0) d\mathbf{x}_{t-1} \quad (5)$$

式中,  $Pr(\mathbf{z}_t | \mathbf{x}_t)$  为系统当前状态的后验概率,而上一时刻系统状态的最优估计为  $\hat{\mathbf{x}}_{t-1} =$

$\operatorname{argmax}_{x_{t-1}} Pr(x_{t-1} | z_{1:t-1}, x_0)$ , 所以

$$\hat{x}_t = \operatorname{argmax}_{x_t} Pr(z_t | x_t) \cdot \int Pr(x_t | x_{t-1}) \hat{x}_{t-1} dx_{t-1} \quad (6)$$

式中,  $\int Pr(x_t | x_{t-1}) \hat{x}_{t-1} dx_{t-1}$  为先验概率。

式(6)表示可以基于系统模型和过去时刻状态向量的后验估计预测当前状态向量。

在 KF 中, 系统状态与上一时刻的状态和系统模型有关, 即

$$x_t = f(x_{t-1}) + \varepsilon_t \quad (7)$$

式中,  $\varepsilon_t$  为系统噪声模型。同时系统状态通过观测方程  $g$  映射到观测量  $z_t \in R^m$ , 即

$$z_t = g(x_t) + \omega_t \quad (8)$$

式中,  $\omega_t$  为观测噪声模型。在 KF 中, 状态模型和观测模型都是线性的, 分别用  $F$  和  $G$  矩阵表示。系统模型为

$$x_t = Fx_{t-1} + \varepsilon_t \quad (9)$$

同理, 观测模型为

$$z_t = Gx_t + \omega_t \quad (10)$$

假设 KF 中系统噪声和观测噪声都服从正态分布

$$\varepsilon_t \sim N(0, Q_t) \quad (11)$$

$$\omega_t \sim N(0, R_t) \quad (12)$$

式(11)和式(12)中,  $Q_t$  和  $R_t$  分别为系统噪声和观测噪声的协方差矩阵。

KF 过程分为预测过程和更新过程。系统当前状态由前一时刻状态预测, 即

$$x_t^- = Fx_{t-1}^+ \quad (13)$$

状态向量的上标“-”表示预测量, 上标“+”表示更新量。采用误差传播法, 根据前一时刻状态向量的协方差矩阵估计当前状态向量的协方差矩阵

$$P_t^- = FP_{t-1}^+ F^T + Q_t \quad (14)$$

式中,  $P_t^-$  为当前状态的协方差矩阵的预测值。

在更新过程中, 当前状态的更新值由当前观测值和预测值得出

$$x_t^+ = x_t^- + K_t(z_t - Gx_t^-) \quad (15)$$

则状态变量更新值的协方差矩阵为

$$P_t^+ = (I - K_t G) P_t^- (I - K_t G)^T + K_t R_t K_t^T \quad (16)$$

式中,  $K_t$  为卡尔曼增益

$$K_t = P_t^- G^T (G P_t^- G^T + R_t)^{-1} \quad (17)$$

## 2 深度卡尔曼滤波(DKF)

为了解决 KF 更新过程中观测量获取不到的问

题, 在 KF 中添加建模步骤, 即在 KF 中加入隐变量。隐变量在状态向量中不可见, 但能决定状态向量, 用  $h_t$  表示, 是时间相关变量。当前系统状态取决于过去  $T$  个时刻隐变量的值  $h_{t-1:t-T}$ 。

假设当前系统状态只与当前隐变量有关, 即不直接依赖于过去系统状态  $x_{t-1:t-T}$ , 马尔可夫假设不成立。新的假设不仅符合很多系统, 而且简化了计算。

设当前隐变量与过去隐变量和系统状态之间的映射关系为  $\phi$ , 即

$$h_t = \phi(x_{t-1:t-T}^+, h_{t-1:t-T}) \quad (18)$$

当前系统状态直接与当前隐变量相关

$$x_t^+ = \lambda(h_t) + \mu_t \quad (19)$$

式中,  $x_t^+$  为模型的后验估计。可以将函数  $\phi$  和  $\lambda$  近似为线性函数和非线性函数的组合, 其中线性函数可以用矩阵乘法表示, 即用参数矩阵  $W$  表示; 非线性函数  $\sigma$  没有参数。所以, 待求解网络表示为

$$h_t = \sigma(W_{xh} x_{t-1:t-T}^+, W_{hh} h_{t-1:t-T}) \quad (20)$$

$$x_t^+ = \sigma(W_{xx} h_t) + \mu_t \quad (21)$$

式中,  $W_h = [W_{xh}, W_{hh}]$ 。建模任务转化为估计  $W_h$  和  $W_{xx}$ 。如图 1 所示, 深度卡尔曼滤波(Deep Kalman Filter, DKF)的上层网络与传统 KF 基本一致, 建模步骤位于下层网络。根据 IMU 随时间积累的特性, 在时间维度上使用深度学习算法进行建模。




图 1 DKF 的概率图模型

Fig. 1 Probability graph model of DKF

### 2.1 模型参数估计

当系统模型的参数未知时, 系统模型和状态向量无法直接估计。此时, 状态向量取决于系统模型的隐变量。为了找到状态向量和隐变量, 可以采用期望最大化(Expectation Maximization, EM)方法。假设隐变量的初始值估计为  $h_t^{(0)}$ , 基于初始隐变量

估计值的系统状态为

$$\hat{\mathbf{x}}_t^{(1)} = \operatorname{argmax}_{\mathbf{x}_t} Pr(\mathbf{x}_t | \mathbf{h}_t^{(0)}, \mathbf{z}_{1:t}, \mathbf{x}_0) \quad (22)$$

基于式(22)的结果估计隐变量

$$\hat{\mathbf{h}}_t^{(1)} = \operatorname{argmax}_{\mathbf{h}_t} Pr(\hat{\mathbf{x}}_t^{(1)} | \mathbf{h}_t, \mathbf{z}_{1:t}, \mathbf{x}_0) \quad (23)$$

根据式(21),计算系统状态可以转化为计算  $\mathbf{W}_{xx}$ ,同理,计算隐变量转化为计算  $\mathbf{W}_h$ 。将式(20)和式(21)代入式(22),则

$$\hat{\mathbf{W}}_{xx}^{(1)} = \operatorname{argmax}_{\mathbf{W}_{xx}} Pr(\mathbf{x}_t | \mathbf{h}_t^{(0)}, \mathbf{z}_{1:t}, \mathbf{x}_0) \quad (24)$$

参数矩阵  $\hat{\mathbf{W}}_{xx}^{(1)}$  估计后,则  $\hat{\mathbf{x}}_t^{(1)}$  可以被计算出来。式(20)的状态矩阵估计公式为

$$\hat{\mathbf{W}}_h^{(1)} = \operatorname{argmax}_{\mathbf{W}_h} Pr(\hat{\mathbf{x}}_t^{(1)} | \mathbf{h}_t, \mathbf{z}_{1:t}, \mathbf{x}_0) \quad (25)$$

隐变量和状态向量的迭代估计一直持续到算法收敛到其解,最后确定系统模型并得出状态向量的估计。P. Mirowski 和 Y. Lecun 的研究表明,EM 算法可以使用递归神经网络训练<sup>[13]</sup>。

EM 算法最终收敛到凸函数的全局最大值,然而对于一些建模为非凸函数的系统,EM 很有可能收敛到局部极大值,所以如何找到式(24)和式(25)中的最大值是一个挑战。

DKF 的建模过程分为两步:通过过去的系统状态和隐变量估计当前隐变量;通过当前隐变量估计当前系统状态。

用隐变量估计重新构造式(6),则

$$\hat{\mathbf{x}}_t = \operatorname{argmax}_{\mathbf{x}_t} Pr(\mathbf{z}_t | \mathbf{x}_t) \cdot \int Pr(\mathbf{x}_t | \mathbf{h}_t) Pr(\mathbf{h} | \mathbf{h}_{t-1:t-T}), \quad (26)$$

$$\mathbf{x}_{t-1:t-T} \hat{\mathbf{x}}_{t-1:t-T} d\mathbf{x}_{t-1:t-T}$$

在 EM 算法的 E 中,依据估计的模型和观测量计算  $\hat{\mathbf{x}}_t$ 。在 GNSS/INS 组合导航系统中,使用 KF 估计系统状态  $\mathbf{x}_t^+$ 。当 GNSS 观测量是精确的,则估计的系统状态也是精确的。在 EM 算法的 M 中,利用估计的模型计算系统状态,这个基于估计模型的近似状态向量用  $\mathbf{x}_t^{+-}$  表示。如果估计模型是正确的,则  $\mathbf{x}_t^{+-}$  应该与  $\mathbf{x}_t^+$  相等或十分接近。用两者差的能量函数  $E$  来衡量模型的准确性,当能量函数最小时模型最准确。能量模型表示为

$$E(\mathbf{W}_h, \mathbf{W}_{xx}) = \frac{1}{2} (\mathbf{x}_t^{+-} - \mathbf{x}_t^+)^2 \quad (27)$$

将式(21)代入式(26),得到

$$E(\mathbf{W}_h, \mathbf{W}_{xx}) = \frac{1}{2} (\sigma(\mathbf{W}_{xx} \mathbf{h}_t) - \mathbf{x}_t^+)^2 \quad (28)$$

则  $\mathbf{W}_{xx}$  的梯度为

$$\frac{\partial E(\mathbf{W}_h, \mathbf{W}_{xx})}{\partial \mathbf{W}_{xx}} = \frac{\partial \sigma(\mathbf{W}_{xx} \mathbf{h}_t)}{\partial \mathbf{W}_{xx}} (\sigma(\mathbf{W}_{xx} \mathbf{h}_t) - \mathbf{x}_t^+) \quad (29)$$

$\mathbf{W}_h$  的梯度为

$$\frac{\partial E(\mathbf{W}_h, \mathbf{W}_{xx})}{\partial \mathbf{W}_h} = \frac{\partial \sigma(\mathbf{W}_{xx} \mathbf{x}_{t-1:t-T}^+ + \mathbf{W}_h \mathbf{h}_{t-1:t-T})}{\partial \mathbf{W}_h} \cdot \frac{\partial \sigma(\mathbf{W}_{xx} \mathbf{h}_t)}{\partial \mathbf{h}_t} (\sigma(\mathbf{W}_{xx} \mathbf{h}_t) - \mathbf{x}_t^+) \quad (30)$$

利用梯度下降方法最小化能量函数。建模系统的参数矩阵  $\mathbf{W}_h$  和  $\mathbf{W}_{xx}$  为

$$\mathbf{W}_{xx}^{(m+1)} = -\frac{\partial E(\mathbf{W}_h, \mathbf{W}_{xx})}{\partial \mathbf{W}_{xx}} \mu + \mathbf{W}_{xx}^{(m)} \quad (31)$$

$$\mathbf{W}_h^{(m+1)} = -\frac{\partial E(\mathbf{W}_h, \mathbf{W}_{xx})}{\partial \mathbf{W}_h} \mu + \mathbf{W}_h^{(m)} \quad (32)$$

式中,  $\mu$  为学习率。参数矩阵被确定后,网络模型也就学习好了,模型状态向量  $\mathbf{x}_t^{+-}$  可以由过去的状态向量  $\mathbf{x}_{t-1:t-T}^+$  利用式(31)和式(32)计算出来。

## 2.2 长短期记忆网络(LSTM)

递归神经网络的缺陷是梯度爆炸和梯度消失<sup>[14]</sup>。当  $T$  比较大且建模时间较长时,梯度会在几层网络中做乘法运算,则较大的梯度乘积更大,最终导致梯度爆炸。反之,如果梯度较小,乘积则趋近于零,从而导致梯度消失。为了抑制递归神经网络中的这种效应,长短期记忆网络(Long Short-Term Memory, LSTM)中采用了门记忆<sup>[15]</sup>,计算单元具体结构如图 2 所示。




图 2 LSTM(Peepphle connection) 结构图

Fig. 2 LSTM(Peepphle connection) structure drawing

LSTM 在递归神经网络中加入了判断信息是否有用的处理器——cell,一个 cell 当中放置了三扇门,分别叫作输入门、遗忘门和输出门。用  $i_t$  表示输入门,  $o_t$  表示输出门,  $f_t$  表示遗忘门,这三种门都可以用线性函数和非线性函数的组合来表示

$$\begin{cases} f_t = \sigma(W_{fx}x_t + W_{fc}c_{t-1} + W_{fh}h_{t-1} + b_f) \\ i_t = \sigma(W_{ix}x_t + W_{ic}c_{t-1} + W_{ih}h_{t-1} + b_i) \\ o_t = \sigma(W_{ox}x_t + W_{oc}c_{t-1} + W_{oh}h_{t-1} + b_o) \end{cases} \quad (33)$$


式中,  $\sigma$  表示非线性函数, 线性函数由参数矩阵表示。cell 的状态  $c_t$  和隐藏层  $h_t$  按如下计算

$$c_t = f_t \circ c_{t-1} + i_t \circ \tanh(W_x x_t + W_h h_{t-1}) \quad (34)$$

$$\begin{cases} h_t = \tan(c_t) \circ o_t \\ x_t^{+-} = W_{xx} h_t \end{cases} \quad (35)$$

式中,  $\circ$  表示按位相乘。对于具有长期相关性的输入数据, 输入门可以保持以前状态向量的信息, 并且可以访问以前状态向量的梯度。因此, 梯度在反向传播过程中不会爆炸或消失。遗忘门控制了模型的复杂性, 并删除了不相关的过去状态向量。

基于 DKF 的导航系统分为训练部分和应用部分。已经知道的是: 如果 GNSS 测量值能够得到, 将其作为观测值输入到 KF 中, 应用系统模型和观测模型来预测和更新系统状态, 同时使用 DKF 对 IMU 模型进行训练, 如图 3(a) 所示; 如果 GNSS 失锁或其他无法获得 GNSS 数据的情况发生时, KF 只能完成预测过程, 此时应用训练好的模型进行导航解算, 如图 3(b) 所示。



(a)DKF 训练模型



(b)DKF 应用模型


图 3 DKF 导航计算模型

Fig. 3 Navigation calculation model based on DKF


GNSS 数据未失锁时进行模型训练, 利用 KF 的输出, 即系统状态的后验估计  $x_t^+$  作为建模过程系统状态的真值。再使用 DKF 来预测系统状态  $x_t^{+-}$ , 然后通过运算获得使两者充分接近的参数矩

阵, 如图 4(a) 所示, 从而建立好模型。值得注意的是, 模型中不需要 GNSS 数据。

在 GNSS 数据失锁时使用训练好的网络, 如图 4(b) 所示, 计算  $x_t^{+-}$ 。如果训练模型足够精确, 则模型计算出的状态向量比 KF 预测过程输出的状态变量  $x_t^+$  更加精确。



(a)DKF 训练网络结构图



(b)DKF 应用网络结构图

图 4 DKF 训练和应用网络结构图

Fig. 4 DKF training and application network structure diagram

### 3 基于 DKF 的仿真分析

以仿真数据为例对算法进行有效性验证, 仿真数据长 400s, 采样频率 1Hz, 包含有两种数据: 第一部分是设定的真实导航数据; 第二部分是仿真输出的 IMU 数据。每一秒都包含有变加速运动导航载体的实时真实速度和 IMU 速度信息。

在 GNSS 失锁时, 作为自主式导航系统, 导航载体上的 INS 仍然正常运行, 其初始导航状态是 GNSS 失锁前最后时刻输出的导航状态。实验所使用的数据是长 400s 的含有标识的 IMU 数据以及在真实导航数据上仿真的 GNSS 数据。在 GNSS 失锁时, INS 单独运行, 其误差迅速增大, 失锁 200s 后, 东北天坐标系下 3 个方向的速度误差已经分别达到 1.1537m/s、1.2146m/s 和 0.3332m/s。

为了评估算法的结果,将 400s 的数据划分为两段:前 200s 数据作为训练集,用来测试和评估;后 200s 数据作为测试集,用来验证模型的有效性。前 200s 训练部分,在真实导航数据上添加噪声作为 GNSS 数据,将其与 IMU 数据组合通过 KF 得到 IMU 误差,该 IMU 误差作为 DKF 的训练数据使用。后 200s 使用训练得到的 IMU 误差模型预测 IMU 误差,用其校正 IMU 数据,并和设定的真实导航数据进行比较,以评估 DKF 的有效性。


DKF 网络设置输入序列长度为 5,中间节点数为 50,迭代 55 次,DKF 模型预测的 IMU 误差结果如图 5(a)和(b)所示。

如图 5(a)所示,在 GNSS 失锁后,使用 DKF 算法训练的模型估计出 IMU 的误差与实际 IMU 误差接近,将其作为校正量代入 IMU 数据中,能够保持一定时间的高精度导航。如图 5(b)所示,如果在 GNSS 失锁后使用 DKF 进行 IMU 误差校正,200s 后速度误差只增长到 0.3746m/s,且 200s 内的平均误差只有 0.1350m/s。与 GNSS 失锁 200s 后的系统误差 1.1537m/s 相比,DKF 对短期内导航解的改善是显而易见的。

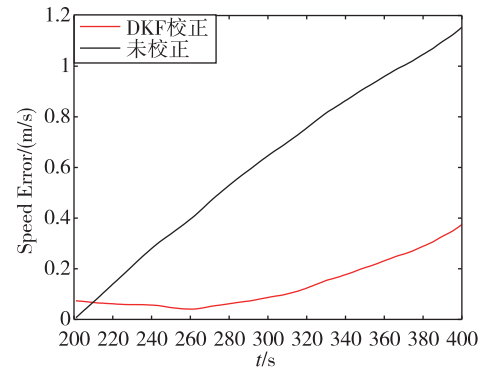
DKF 通过前 5 个时刻预测下一个时刻的 IMU 误差,平均估计使用前 5 个时刻的平均值作为下一个时刻的 IMU 误差,两者的对比实验结果如图 5(c)和(d)所示。如果在 GNSS 失锁后使用平均估计进行 IMU 误差校正,由于平均估计预测的 IMU 误差维持在 GNSS 失锁时刻的数据,在 200s 内误差达到 1.1203m/s,200s 内平均误差为 0.5890m/s。平均误差对于 GNSS/INS 组合系统的持续导航改善不如 DKF。

GNSS 失锁后,GNSS/INS 组合系统由于丢失观测而无法使用 KF,但是基于持续输出的 IMU 数据,可以使用卡尔曼的预测部分对 IMU 误差进行估计,卡尔曼预测和 DKF 的对比实验结果如图 5(e)和(f)所示。如果在 GNSS 失锁后使用卡尔曼预测进行 IMU 误差校正,其估计的 IMU 误差在 200s 内达到 0.7479m/s,200s 内平均估计误差为 0.4421m/s。卡尔曼预测对于 GNSS/INS 组合系统的持续导航改善不如 DKF。

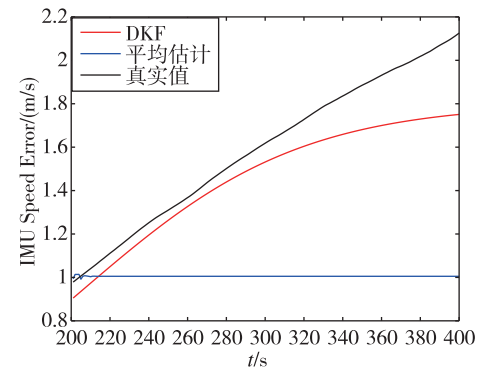
最小二乘估计作为常用的估计方法,在曲线拟合方面效果显著,可以使用最小二乘估计拟合 GNSS 未失锁前的 IMU 误差模型,从而预测 GNSS 失锁后的 IMU 误差。最小二乘估计和 DKF 的对



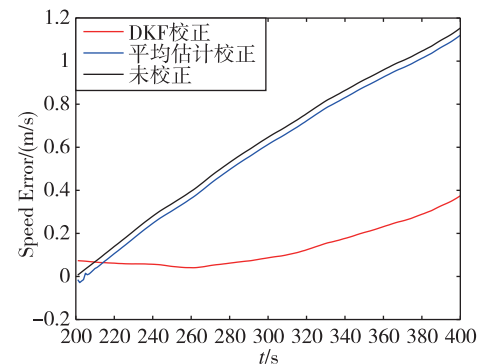
(a)DKF 预测结果图




(b)DKF 校正结果图




(c)预测结果图:DKF vs. 平均估计




(d)校正结果图:DKF vs. 平均估计



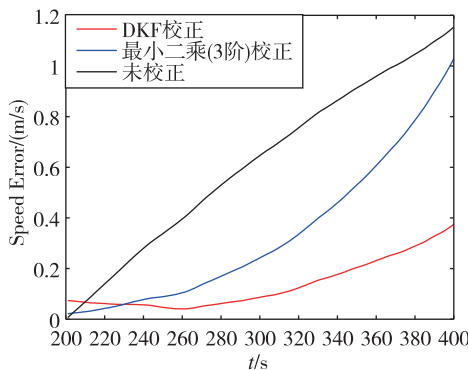
(e) 预测结果图:DKF vs. 卡尔曼预测



(f) 校正结果图:DKF vs. 卡尔曼预测



(g) 预测结果图:DKF vs. 最小二乘估计



(h) 校正结果图:DKF vs. 最小二乘估计

图 5 仿真结果图

Fig. 5 Simulation results

比实验结果如图 5(g)和(h)所示。如果在 GNSS 失锁后使用最小二乘估计进行 IMU 误差校正,其估计的 IMU 误差在 200s 内的估计误差达到 0.9725m/s,200s 内平均估计误差为 0.3352m/s。最小二乘估计对于 GNSS/INS 组合系统的持续导航改善不如 DKF。

为了进一步说明 DKF 算法的有效性和性能,将 DKF 的估计误差与平均估计、卡尔曼预测和最小二乘估计进行对比,结果如图 6 所示。




图 6 四种方法的估计误差对比图

Fig. 6 Comparison of estimation errors of the four methods

如图 6 所示,在 GNSS 失锁 200s 内,对于 GNSS/INS 组合系统的持续导航改善最好的是 DKF,其次是最小二乘估计。

#### 4 结论

针对 GNSS/INS 组合系统中 GNSS 失锁后导航精度的维持问题,本文提出了一种基于 LSTM 的 DKF 算法。首先使用 GNSS 数据和 IMU 数据通过 KF 获取失锁前的高精度导航数据;其次,基于高精度导航数据训练 IMU 误差模型;最后,在 GNSS 失锁后使用 IMU 误差模型进行误差校正。算法分析与实验结果表明:

1)DKF 算法在时间维度上分为 2 个阶段执行,实现了基于历史信息对当前 IMU 误差的校正。因此具有比传统 KF 更高的信息利用率,可以在 GNSS 失锁时维持 GNSS/INS 组合系统的高精度运行。

2)本文提出的 DKF 算法依靠 LSTM 对序列信息的敏感度对 IMU 误差进行建模,而机器学习的本质要求含有大量信息的大数据集进行实验。在实际的复杂环境中如何获取这些数据并且保证算法的实时性,值得做进一步研究。

## 参考文献

- [1] 艾伦, 金玲, 黄晓瑞. GPS/INS 组合导航技术的综述与展望[J]. 数字通信世界, 2011(2): 58-61.  
Ai Lun, Jin Ling, Huang Xiaorui. Overview and prospect of GPS/INS integrated navigation technology [J]. Digital Communication World, 2011(2): 58-61 (in Chinese).
- [2] Farrell J A. The global positioning system & inertial navigation[M]. New York: McGraw-Hill, 1998.
- [3] Cox D B. Integration of GPS with inertial navigation systems[J]. Journal of the Institute of Navigation, 1978, 25(2): 236-245.
- [4] Poh E K, Koh A, Wong G. Evaluation of coupled GPS/INS integration using software GPS receiver model[C]// Proceedings of 15<sup>th</sup> International Technical Meeting of the Satellite Division of the US Institute of Navigation. Portland, Oregon, 2002.
- [5] Brown R G, Hwang P Y C. Introduction to random signal and applied Kalman filtering(3<sup>rd</sup> Edition)[M]. New York: John Wiley & Sons, 1997.
- [6] 岳晓奎, 袁建平. 一种基于极大似然准则的自适应卡尔曼滤波算法[J]. 西北工业大学学报, 2005, 23(4): 469-474.  
Yue Xiaokui, Yuan Jianping. An adaptive Kalman filtering algorithm based on maximum likelihood criterion[J]. Journal of Northwestern Polytechnical University, 2005, 23(4): 469-474(in Chinese).
- [7] 卞鸿巍. 现代信息融合技术在组合导航中的应用[M]. 北京: 国防工业出版社, 2010.  
Bian Hongwei. Application of modern information fusion technology in integrated navigation[M]. Beijing: National Defense Industry Press, 2010(in Chinese).
- [8] 付梦印, 邓志红, 闫莉萍. Kalman 滤波理论及其在导航系统中的应用[M]. 北京: 科学出版社, 2010.  
Fu Mengyin, Deng Zhihong, Yan Liping. Kalman filter theory and its application in navigation system [M]. Beijing: Science Press, 2010(in Chinese).
- [9] 高为广, 杨元喜, 张婷. 神经网络辅助的 GPS/INS 组合导航自适应滤波算法[J]. 测绘学报, 2007, 36(1): 26-30.  
Gao Weiguang, Yang Yuanxi, Zhang Ting. Neural network-assisted GPS/INS integrated navigation adaptive filtering algorithm[J]. Journal of Surveying and Mapping, 2007, 36(1): 26-30(in Chinese).
- [10] Narasimhappa M, Mahindrakar A D, Guizilini V C, et al. An improved Sage Husa adaptive robust Kalman filter for de-noising the MEMS IMU drift signal[C]// Proceedings of Indian Control Conference, 2018: 229-234.
- [11] Hosseinyalamdary S. Deep Kalman Filter: simultaneous multi-sensor integration and modelling; A GNSS/IMU case study[J]. Sensors, 2018, 18(5): 1316.
- [12] Wendel J, Meister O, Schlaile C, et al. An integrated GPS/MEMS-IMU navigation system for an autonomous helicopter[J]. Aerospace Science & Technology, 2006, 10(6): 527-533.
- [13] Mirowski P, Lecun Y. Dynamic factor graphs for time series modeling[C]// Proceedings of European Conference on Machine Learning and Knowledge Discovery in Databases. Bled, Slovenia, 2009, 5782: 128-143.
- [14] Goodfellow I, Bengio I, Courville A. Deep learning [M]. MIT Press: Cambridge, MA, USA, 2016.
- [15] Hochreiter S, Schmidhuber J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.

(编辑:孟彬)