基于 RNN 的智能网联汽车高精度定位方法

李晓晖1,方芳2,邓天民2

(1. 重庆西部汽车试验场管理有限公司, 重庆 408300; 2. 重庆交通大学 交通运输学院, 重庆 400074)

摘 要:针对智能网联汽车行驶过程中 GPS 信号丢失引起定位失效的问题,提出基于 RNN 的高精度定位方法。采用数据驱动建模方法建立汽车行驶过程中基于 RNN 的定位模型,利用 GPS、INS 和 RTK 等技术,设计了高精度定位数据采 集系统。对基于 BP 和 RNN 的定位模型性能进行比较,同时分析了基于 RNN 的定位模型在不同 GPS 信号失效时长下模型的定位精度。试验表明,基于 RNN 的高精度定位模型性能更佳,当 GPS 信号失效时长 30 s 时,其 98% 定位精度误差小于 40 cm。

关键词:高精度定位;循环神经网络;数据驱动;全球定位系统 中图分类号: P228.4 文献标识码: A DOI: 10.3969/j.issn.2095-1469.2019.04.04

Method of Global High-Precision Positioning for Intelligent Connected Vehicle Based on RNN

LI Xiaohui¹, FANG Fang², DENG Tianmin²

Chongqing Xibu Automobile Proving Ground Management Co., Ltd, Chongqing 408300, China;
 School of Transportation, Chongqing Jiaotong University, Chongqing 400074, China)

Abstract: In view of the positioning failure caused by GPS signal loss during driving the intelligent connected vehicles, a positioning model based on RNN was proposed. Using GPS, INS, RTK and other technologies, a data acquisition system was designed for high-precision positioning when driving an intelligent connected vehicle. The performance of the positioning models based on BP neural network and RNN was compared, and the positioning accuracy of the RNN model was analyzed under different durations of GPS signal loss. The experimental results show that the performance of the high-precision positioning model based on the RNN is better than the one based on the BP network. When the GPS signal is lost for 30 s, the 98% positioning accuracy error is less than 40 cm.

Keywords: high-precision positioning; recurrent neural network; data-driven; GPS

智能网联汽车作为"互联网+"在汽车上的 应用,具有安全、舒适、节能、高效行驶、可替代 人操作等优点。然而智能网联汽车的运行环境复 杂,运行过程多变,对高精度定位提出了更高的要求。因此,组合导航定位是未来智能出行的关键因素之一。

收稿日期: 2018-09-26 改稿日期: 2019-03-04

基金项目:"基于宽带移动互联网的智能汽车和智慧交通应用示范工程及产品工程化公共服务平台"工信部重点项目资助(0714-EMTC02-5593/20);重庆市科技人才培养计划(cstc2013kjrc-qnrc0148)

参考文献引用格式:

李晓晖, 方 芳, 邓天民. 基于 RNN 的智能网联汽车高精度定位方法 [J]. 汽车工程学报, 2019, 9(4): 260-267.

LI Xiaohui, FANG Fang, DENG Tianmin. Method of Global High-Precision Positioning for Intelligent Connected Vehicle Based on RNN [J]. Chinese Journal of Automotive Engineering, 2019, 9(4): 260–267. (in Chinese)

组合导航是非线性系统,针对非线性系统问题, 熊剑等^[1]、王硕等^[2]利用高斯滤波算法提高了定 位精度, 增强了预测的实时性, 但是没有针对噪声 进行具体分析。针对组合导航过程噪声和量测噪声 的不确定性问题,王维等^[3]、王慧丽等^[4]、房德君^[5] 分别运用了无迹卡尔曼滤波方法、不确定融合估计 的 GPS/INS (Global Positioning System and Inertial Navigation System) 滤波算法和自适应卡尔曼滤波 方法进行试验验证,证明了其实用性和良好的鲁棒 性,但是缺少对 INS 滤波的具体分析。针对 GPS/ INS 组合导航中 INS 建模的问题,李增科等^[6]、徐 爱功等^[7]分别提出了一种基于牛顿插值的 GPS/INS 组合导航惯性动力学多阶建模算法和基于小波降噪 的 GPS/INS 紧组合方法,提高了系统的精度和稳定 性,但是缺乏对 GPS 信号失效定位精度的分析。针 对 GPS 中断问题,谭兴龙等^[8]、胡方强等^[9] 针对 GPS/INS 组合系统中 GPS 中断时,导航性能会急剧 降低的情况,分别提出了改进径向基神经网络结合 自适应滤波辅助的组合系统导航算法和改进的自适 应卡尔曼滤波方法,试验证明了其有效性。

卡尔曼滤波的相关方法较为成熟、性能良好, 但是针对 GPS 失效问题,卡尔曼滤波方法在定位高 精度性和实时性上效果有待提高。周邵磊等^[10]提 出了单目视觉 ORB-SLAM/INS 组合导航方法,通过 初始化阶段利用 ORB-SLAM 方法计算的尺度因子 修正惯导系统的误差。焦雅林等^[11]提出了基于改进 粒子滤波算法的 GPS/DR 车辆组合导航信息融合技 术,其滤波性能明显优于扩展卡尔曼滤波(Extended Kalman Filter, KEF)。李士心等^[12]利用非线性滤 波方法,强跟踪滤波渐消因子加入容积卡尔曼滤 波中,提出了捷联惯导/里程计组合导航的自适应 强跟踪滤波算法,达到了惯性原件的理论精度。

但是,随着人工智能的发展和计算机水平的 提高,神经网络方法用于导航定位成为研究重点与 热点。循环神经网络(Recurrent Neural Network, RNN)具有极强的非线性动态映射能力和动态记忆 功能,适用于动态过程建模,实现动态系统预测。

冯永等^[13]提出一种携带历史元素的 RNN 推

荐模型负责用户短期动态兴趣建模,并结合前馈神 经网络(Feedforward Neural Networks, FNN)构建 了多神经网络混合动态推荐模型(Hybrid Dynamic Recommendation Model Based on Multiple Neural Networks, MN-HDRM),在多项评价指标上具有 优越的性能。张国兴等^[14]将 SDZ(Surprisal-Driven Zoneout)应用于 RNN 并提出了基于 SDZ-RNN 的 出租车目的地预测方法。该方法有效地缩短了训练 时间,提高了预测精度。ORDÓÑEZ等^[15]分析了 森林环境中 GPS 测量的准确性,应用 RNN 建立一 个将观测误差与 GPS 信号相关联的数学模型, RNN 网络效果良好。NAKHAEI等^[16]比较3种类型的人 工神经网络,即径向基函数神经网络(Radial Basis Function Neural Network, RBFNN)、RNN 以及多 变量非线性回归(Multiple Non-Linear Regression, MNLR)模型来预测浮选柱的冶金性能,对比了其 训练能力和准确性。

因此,本文提出了一种基于 RNN 的高精度定 位模型,该模型通过大量精确的 GPS/INS 数据进行 训练。当 GPS 失效时,训练好的模型预测失效时的 定位信息,有效提高了组合导航的定位效果。

1 高精度定位方法

1.1 RNN 网络模型

RNN 是传统前馈神经网络(FNN)的一种变体。 RNN 和 FNN 之间的区别在于 FNN 的神经元仅通过 层和层之间的连接来传递信息。虽然 RNN 在网络 中引入了环形结构,但它建立了神经元与自身的连 接。通过这种连接 RNN 可以将网络中最后一个时 间点的输入存储为"存储器",并在下一步中影响 网络输出。对于 FNN,只能将输入通过隐藏层映射 到输出层,而 RNN 可以将整个历史记录映射到每 个输出神经元。因此,在输入和输出都是序列数据 的预测问题中, RNN 比 FNN 具有更好的性能^[17]。

RNN的预测过程类似于 FNN,其由前向传播 算法完成。FNN的训练过程是通过反向传播实现的, 而 RNN 需要通过时间维度和反向传播时间(Back Propagation Through Time, BPTT)叠加反向传播的 结果,因为不同时间步长之间会相互影响。通常,循环神经网络是推测或完成信息的不错选择。因此,本文采用基于 RNN 的状态空间模型来描述智能联网车辆的驱动过程。RNN 的结构如图 1 所示。它有3 层,即输入层、隐藏层和输出层^[18]。



图 1 RNN 网络结构

RNN 的数学模型为:

$$h^{(t)} = \phi(Ux^{(t)} + Wh^{(t-1)} + b) \circ$$
(1)

$$o^{(t)} = V h^{(t)} + c$$
 (2)

$$\hat{y}^{(t)} = \sigma(o^{(t)}) \circ \tag{3}$$

$$\phi(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}}$$
 (4)

$$\hat{y}^{(t)} = o^{(t)} \circ \tag{5}$$

式中: t 表示 t 时刻; $x^{(0)}$ 表示输入层输入; $h^{(0)}$ 、 $h^{(t-1)}$ 分别表示 t 时刻和 t-1 时刻的隐含层输出; ϕ 为隐含 层激活函数, 一般选择 tanh 函数; $o^{(t)}$ 表示输出层输 入; $\hat{y}^{(t)}$ 表示输出层输出; σ 为输出层激活函数, 这里 采用纯线性 Pureline 函数; U表示输入层到隐含层的 连接权值; W、b 分别为隐含层之间的连接权值和偏 置; V、c 分别为隐含层与输出层连接权值和偏置。

1.2 基于 RNN 的训练模型

(1) 样本集预处理

采用最大最小归一化方法对投影处理后的样本 进行归一化处理,如式(6)所示。

$$y = \frac{2 \times (x - x_{\min})}{x_{\max} - x_{\min}} - 1 \circ \tag{6}$$

式中: x, y 分别表示原始数据和归一化后的数据;

*x*_{max}, *x*_{min} 分别表示 *x* 的最大值和最小值。训练数据 通过归一化后保留其最大值、最小值、平均值等信息,用于失效预测模型中神经网络输入数据的归一 化及其输出数据的反归一化。

(2)对 RNN 模型进行训练,训练过程如下。 输入层的输入、输出分别为:

$$\begin{cases} X_i^{(t)}(1) = x_i^{(t-1)}, \\ Y_i^{(t)}(1) = X_i^{(t)}(1) & (7) \end{cases}$$

隐含层的输入、输出分别为:

$$\begin{cases} X_{j}^{(t)}(2) = \sum_{i=1}^{r} w_{ji}^{1} Y_{i}^{(t)}(1) + \sum_{j=1}^{s} w_{jj}^{2} Y_{j}^{(t)}(c) , \\ Y_{j}^{(t)}(2) = \tanh(X_{j}^{(t)}(2)) = \frac{e^{I_{j}^{(t)}(2)} - e^{-I_{j}^{(t)}(2)}}{e^{I_{j}^{(t)}(2)} + e^{-I_{j}^{(t)}(2)}} \circ \quad (8) \end{cases}$$

输出层的输入、输出分别为:

$$\begin{cases} X_{k}^{(t)}(3) = \sum_{j=1}^{s_{1}} w_{kj}^{3} Y_{j}^{(t)}(2), \\ \hat{y}_{k}(t) = Y_{k}^{(t)}(3) = g(X_{k}^{(t)}(3)) \circ \end{cases}$$
(9)

式(7)~(9)中: \hat{y}_k 表示智能网联汽车的实时经 纬度的预测增量; $j = 1, 2, \dots, s$, s表示隐含层神经元 个数。

1.3 基于 RNN 的 GPS 失效定位模型

假设 GPS 失效时,该时刻记为 t_0 ,前一时刻经 纬度为 $\alpha(t_0 - 1)$, $\beta(t_0 - 1)$,令 T 为失效时长,f 为数 据采集频率,则预测步数 $\eta = T \times f$,预测轨迹及误 差为:

$$\begin{cases} \hat{\alpha}^{(t_0+\eta)} = \alpha^{(t_0-1)} + \sum_{t=t_0}^{t_0+\eta} \Delta \hat{\alpha}^{(t)}, \\ \hat{\beta}^{(t_0+\eta)} = \beta^{(t_0-1)} + \sum_{t=t_0}^{t_0+\eta} \Delta \hat{\beta}^{(t)} \end{cases}$$
(10)

$$\begin{cases} \Delta \alpha^{(t_0+\eta)} = \hat{\alpha}^{(t_0+\eta)} - \alpha^{(t_0+\eta)} ,\\ \Delta \beta^{(t_0+\eta)} = \hat{\beta}^{(t_0+\eta)} - \beta^{(t_0+\eta)} & \circ \end{cases}$$
(11)

$$e^{(t_0+\eta)} = \sqrt{\left(\Delta \hat{\alpha}^{(t_0+\eta)}\right)^2 + \left(\Delta \hat{\beta}^{(t_0+\eta)}\right)^2} \quad (12)$$

式(10)~(12)中: $\hat{\alpha}^{(t_0+\eta)}$, $\hat{\beta}^{(t_0+\eta)}$ 分别为 t_0 时刻失 效时长T对应的预测纬度、经度; $\Delta \hat{\alpha}^{(t_0+\eta)}$, $\Delta \hat{\beta}^{(t_0+\eta)}$ 为 预测增量; $e^{(t_0+\eta)}$ 为预测误差。

2 试验

2.1 数据采集系统

本文基于 GPS/INS 组合导航系统,结合 RNN 模型来实现智能网联汽车全域的高精度定位,其系 统结构如图 2 所示。



图 2 GPS/INS 定位系统结构

定位系统通过 BD/GPS 天线接收卫星,然后通 过①的放大和变频处理传输到 BD/GPS 接收机中, 通过接收机结合 RTK 基站的差分信号得到时间、经 度、纬度、高程等定位信息;然后通过②将定位数 据中的经度、纬度以及 INS 采集的速度和姿态角进 行归一化处理,作为神经网络的输入,通过③进行 模型训练得到预测的经度、纬度增量;结合④中的 上一时刻真实的定位数据,通过⑤输出预测的下一 时刻定位数据。在卫星信号正常阶段,针对模型进 行训练,⑤输出的预测定位经纬度与⑥传输的当前 时刻真实定位经纬度相对比,得到其误差,从而不 断修正神经网络的参数。当不能正常接收到卫星信 号时,通过②~⑤即可得到预测的高精度定位数据。

2.2 试验数据及模型

数据采集使用 Vbox 系统,自建 Vbox-RTK 差 分基站,使用 48 MHz 电台通讯,数据采样率为 100 Hz,经过整理后约有 37 万组有效数据。

根据数据的特性,构建两种不同的神经网络



图 3 数据采集区域卫星图

模型,其中模型1使用 BP 神经网络,模型2使用 RNN。两个模型输入均为速度、航向角、俯仰角和 横滚角,输出为经度增量和纬度增量,隐含层为含 有15个神经元的网络结构。模型结构如图4所示。



图 4 BP 神经网络和 RNN 的模型结构

3 讨论与分析

3.1 预测误差分析

基于训练完成的 BP 神经网络和 RNN 高精度定 位模型,使用 40 000 余组测试样本分别进行测试, 从而获得预测纬度增量和预测经度增量。将预测经 纬度增量与测试样本经纬度增量分别进行比较,其 经纬度增量误差曲线如图 5 所示,误差数据统计量 对比见表 2。





图 5 预测经纬度增量误差曲线

表 2 网络预测误差指标对比

网络	类型	误差指标						
		$< 0.1 {\rm ~cm}$	< 0.2 cm	MAE/cm	RMSE	MAPE/%		
BP	纬度	55.19%	85.51%	0.105 1	0.138 1	1.75		
	经度	62.57%	91.56%	0.089 5	0.111 2	7.43		
RNN	纬度	66.76%	93.75%	0.082 3	0.103 8	1.52		
	经度	89.74%	100%	0.031 8	0.043 8	1.43		

由图 5 和表 2 可知, BP 神经网络绝对误差均 小于 0.5 cm, 85% 绝对误差小于 0.2 cm; RNN 经 纬度绝对误差均小于 0.3 cm, 90% 绝对误差小于 0.2 cm, RNN 预测结果与 BP 神经网络相比波动较 平稳,预测效果更好。

对于平均绝对误差(Mean Absolute Error, MAE) 指标, RNN 相比于 BP 神经网络纬度减少了 14.8%, 经度减少了 64.5%,则 RNN 预测经纬度更接近真 实值。对于均方根误差(Root Mean Square Error, RMSE)指标, RNN 相比于 BP 神经网络纬度减少了 24.8%,经度减少了 60.6%,RNN 的 RMSE 低于 BP 神经网络,预测值偏离真实值的程度得到改善,预 测精度高于 BP 神经网络。对于平均绝对百分比误差 (Mean Absolute Percent Error, MAPE)指标,RNN 相比于 BP 神经网络纬度减少了 13.1%,经度减少了 80.7%, RNN 模型优于 BP 预测模型。

RNN 相比于 BP 神经网络预测经纬度更接近真 实值,预测误差波动范围也更小,模型预测精度更 高,基于 RNN 的定位方法整体性能更佳。

3.2 不同失效时长误差分析

根据模型对比分析,选择性能更优的 RNN 模型进行不同 GPS 失效时长的车辆预测轨迹误差讨论。本文选取了试验中采集的 4 段连续的汽车行驶轨迹,21 000 余组试验数据,分别假定 GPS 失效时长为 1 s、2 s、5 s、10 s、30 s,预测车辆运动轨迹。

图 6 为试验路径的一段,数据采集点 5 800 余组。 图中 9 条线段分别表示车辆实际行驶轨迹和 GPS 失 效 1 s、2 s、5 s、10 s、30 s 的预测轨迹,图 7 为整 体误差,图中的红色方框区域为图 6 中轨迹的对应 误差。



图 7 GPS 不同失效时间整体误差分布

以时间排序的误差序号

图 6 展示了预测轨迹与实际轨迹的投影平移曲 线,从局部放大图可以看出,失效 1 ~ 2 s 短时间时, 轨迹基本重合,即预测值与实际值吻合得较好,模 型对测试样本有较好的预测能力,具有较强的泛化 能力;随着失效时间的增加,预测轨迹偏离实际轨 迹逐渐增大,偏离程度增强。

由图 7 可知,随着 GPS 失效时间的增加,误 差随之增大,但是不是呈现比例的增大。失效时 间 30 s 的预测值误差最大,但均在 4 m 范围内。对 GPS 不同失效时长的预测数据进行细化分析,表 3 为不同误差范围内的数量及比例,表 4 为误差指标 分析。

失效	范围内所占比例 / %									
时间	< 3 cm	< 5 cm	< 10 cm	< 30 cm	< 40 cm	< 50 cm	$< 100 \mathrm{~cm}$	$< 200 {\rm ~cm}$	< 300 cm	< 400 cm
1 s	65.8	79.06	85.97	97.17	99.84	100				
2 s	19.5	41.68	70.04	86.10	88.82	92.55	98.58	100		
5 s	6.88	11.90	46.79	79.74	82.94	84.65	91.76	99.70	100	
10 s	2.91	7.85	16.88	68.73	72.72	74.76	86.31	94.08	100	
30 s	0.15	0.71	7.26	36.28	53.00	64.55	73.76	87.10	91.49	100

表 3 GPS 不同失效时长的误差分析

表 4 GPS 不同失效时长的误差指标分析

生动时间		误差指标						
大双凹问		MAX/cm	MAE/cm	VAR	RMSE			
1	原始	47.546 9	4.995 5	7.680 7	9.162 1			
1 \$	优化后	44.353 9	3.363 1	4.844 0	5.896 9			
2	原始	128.906 3	14.157 4	22.051 6	26.204 6			
2.8	优化后	107.401 1	8.661 0	11.031 5	14.024 9			
-	原始	202.113 2	26.177 2	39.073 5	47.031 0			
5.8	优化后	105.548 6	14.544 8	15.538 6	21.283 4			
10 -	原始	269.880 4	46.763 3	61.582 9	77.324 6			
10 \$	优化后	108.165 8	23.963 3	20.793 1	31.726 5			
20 a	原始	356.476 2	81.027 0	95.375 9	125.14 6			
30 S	优化后	113.550 8	39.808 2	28.713 0	49.082 6			

GPS 失 效 误 差 1 s、2 s、5 s、10 s 和 30 s 的 90% 以上误差分别小于 30 cm、50 cm、100 cm、 200 cm 和 300 cm, 50% 以上误差分别小于 3 cm, 10 cm、30 cm 和 50 cm。基于 RNN 的 预测模型在 失效 30 s 内, 90% 的误差在 300 cm 内,特别是在 失效 10 s 内,精度可以达到 10 cm 内。随着失效时 长的增加,预测精度下降,但整体预测效果良好。

对于最大值(MAX)指标,GPS失效1s、 2s、5s、10s和30s分别约为47cm、129cm、 202cm、270cm和356cm,整体误差值小;平均 绝对误差(MAE)分别约为5cm、14cm、26cm、 47cm和81cm,预测值偏离真实值小,失效时间 1~30s时预测精度高。对于方差(VAR)和均方 根误差(RMSE),1s、2s、5s、10s和30s的 VAR分别约为4.84、11.03、15.54、20.79、61.58和 95.38; RMSE分别约为9.16、26.20、47.03、77.32 和125.15,失效时长低于30s时,预测较为稳定, 随着失效时长的增加,稳定性急剧下降。 在图7中的1200~1600条数据范围内, 误差值远高于平均值,结合表4中误差的VAR和 RMSE偏大情况,主要是由于该时间内定位卫星数 较少。此数据占总体数据的20%,去除该数据,剩 余近1700条卫星数较多情况下的数据,表4中优 化后的数据为其误差指标分析。

对比可知,关于 MAX 和 MAE 指标,失效1s 时分别低于 44 cm 和 4 cm,比原来有少量减少; 对于失效2s、5 s、10 s 和 30 s,MAX 分别约为 107 cm、105 cm、108 cm 和 113 cm,减少较多, 但 4 个失效时间 MAX 相差较小,表明随着失效时 间的增加,预测位置增量叠加增大,预测偏差程度 趋于稳定。MAE 分别约为9 cm、15 cm、24 cm 和 40 cm,表明预测值接近实际值,预测精度较高, 随着失效时间的增加,定位精度降低。VAR 指标均 低于 30,RMSE 指标均低于 50,表明预测波动平稳, 预测系统较为稳定,但随着失效时长的增加,稳定 性下降。 266

4 结论

本文提了一种全域 GPS/INS 高精度定位方法, 该方法基于 GPS/INS 组合导航的定位数据,结合循 环神经网络建立了一种机器学习模型。试验表明, 该模型的输出结果能够高精度逼近 GPS/INS 组合导

参考文献(References)■

 [1] 熊剑,郭杭,熊智,等.GPS/INS 组合导航系统中的高 斯粒子滤波混和算法 [J].中国惯性技术学报,2012, 20(2):225-229.

XIONG Jian, GUO Hang, XIONG Zhi, et al. Gaussian Particle Filtering Hybrid Algorithm for GPS/INS Integrated Navigation System [J]. Journal of Chinese Inertial Technology, 2012, 20(2): 225–229.(in Chinese)

[2] 王硕, 宋申民, 于浛, 等. 基于组合导航系统的非线性 高斯滤波算法 [J]. 控制与决策, 2016, 31(9): 1645-1653.

WANG Shuo, SONG Shenmin, YU Han, et al. Gaussian Non-Linear Filter Algorithm Based on Integrated Navigation System [J]. Control and Decision, 2016, 31(9): 1645–1653. (in Chinese)

[3] 王维,胡高歌,高社生,等.基于极大似然准则的 INS/GNSS 组合导航自适应 UKF 滤波算法 [J].中国惯性技术学报,2017,25(5):656-663.
 WANG Wei, HU Gaoge, GAO Shesheng, et al. Maxi-

mum Likelihood Principle Based Adaptive Unscented Kalman Filter for INS/GNSS Integration [J]. Journal of Chinese Inertial Technology, 2017, 25(5): 656–663. (in Chinese)

- [4] 王慧丽,史忠科.基于不确定融合的 GPS/INS 组合导航 滤波算法 [J]. 控制与决策, 2015, 30(7): 1201-1206.
 WANG Huili, SHI Zhongke. GPS/INS Integrated Navigation Filtering Algorithm Based on Uncertain Fusion [J]. Control and Decision, 2015, 30(7): 1201-1206.(in Chinese)
- [5] 房德君.改进自适应 Kalman 滤波的 SINS/GPS 紧组合导航 [J]. 电光与控制, 2017, 24(10): 102-105, 118.
 FANG Dejun. SINS/GPS Tightly Integrated Navigation Based on Improved Adaptive Kalman Filter [J]. Electronics Optics & Control, 2017, 24(10): 102-105, 118. (in Chinese)

航系统的定位值,在 GPS 信号失效 30 s 时,定位 误差低于 40 cm。本文提出的定位方法为组合导航 系统应用中 GPS 信号失锁问题的解决提供了一种有 效的方法。

[6] 李增科,高井祥,王坚,等.利用牛顿插值的 GPS/INS 组合导航惯性动力学模型 [J].武汉大学学报(信息科 学版),2014,39(5):591-595.

LI Zengke, GAO Jingxiang, WANG Jian, et al. Inertial Dynamic Model of GPS/INS Integrated Navigation Based on Newton Interpolation [J]. Geomatics and Information Science of Wuhan University, 2014, 39(5): 591–595. (in Chinese)

[7] 徐爱功,刘韬,隋心,等.一种低动态高抖动环境下的GPS/INS 紧组合方法 [J]. 测绘科学, 2018, 43 (2): 1-5, 29.

XU Aigong, LIU Tao, SUI Xin, et al. A Method GPS/INS Tightly Coupled in Low Dynamic High Jitter Environment [J]. Science and Surveying and Mapping, 2018, 43 (2): 1–5, 29. (in Chinese)

[8] 谭兴龙,王坚,韩厚增,等.改进神经网络辅助的 GPS/ INS 组合导航算法 [J].中国矿业大学学报,2014, 43 (3): 526-533.
TAN Xinglong, WANG Jian, HAN Houzeng, et al. Improved Neural Network Aided GPS/INS Integrated

Navigation Algorithm [J]. Journal of China University of Mining & Technology, 2014, 43(3): 526–533. (in Chinese)

- [9] 胡方强,吕涛,包亚萍.改进的自适应 Kalman 滤波在 SINS/GPS 组合导航中的应用 [J]. 计算机工程与应用, 2018,54(5):253-257,264.
 HU Fangqiang, LYU Tao, BAO Yaping. Application of Modified Adaptive Kalman Filter to SINS/GPS Integrated Navigation System [J]. Computer Engineering and Applications, 2018,54(5):253-257,264.(in Chinese)
- [10] 周绍磊, 吴修振, 刘刚, 等. 一种单目视觉 ORB-SLAM/INS 组合导航方法 [J]. 中国惯性技术学报, 2016, 24(5): 633-637.
 ZHOU Shaolei, WU Xiuzhen, LIU Gang, et al. Inte-

grated Navigation Method of Monocular ORB-SLAM/ INS [J]. Journal of Chinese Inertial Technology, 2016, 24(5): 633-637. (in Chinese)

 [11] 焦雅林,高社生,薛丽.GPS/DR 车辆组合导航改进的 粒子滤波算法研究[J].西北工业大学学报,2011, 29(1): 39-43.

JIAO Yalin, GAO Shesheng, XUE Li. An Improved Particle Filtering Algorithm Based on GPS/DR Vehicle Integrated Navigation [J]. Journal of Northwestern Polytechnical University, 2011, 29(1): 39–43. (in Chinese)

[12] 李士心,黄凤荣,邱时前,等.基于自适应强跟踪滤波
 的捷联惯导/里程计组合导航方法 [J].中国惯性技术学报,2018,26(2):156-161.

LI Shixin, HUANG Fengrong, QIU Shiqian, et al. SINS/Odometer Integrated Navigation Method Based on Adaptive Strong Tracking Filter [J]. Journal of Chinese Inertial Technology, 2018, 26(2): 156–161. (in Chinese)

[13] 冯永,张备,强保华,等.MN-HDRM:长短兴趣多 神经网络混合动态推荐模型[J].计算机学报,2019, 42(1):16-28.

FENG Yong, ZHANG Bei, QIANG Baohua, et al. MN-HDRM: a Novel Hybrid Dynamic Recommendation Model Based on Long-Short-Term Interests Multiple Neural Networks [J]. Chinese Journal of Computers, 2019, 42(1): 16–28. (in Chinese)

[14] 张国兴, 李亚东, 张磊, 等. 基于 SDZ-RNN 的出租车 出行目的地预测方法 [J]. 计算机工程与应用, 2018, 54(6): 143-149. ZHANG Guoxing, LI Yadong, ZHANG Lei, et al. Taxi Travel Destination Prediction Based on SDZ-RNN [J]. Computer Engineering and Applications, 2018, 54(6): 143-149. (in Chinese)

- [15] ORDÓÑEZ G C, RODRÍGUEZ PÉREZ J R, CORTÉSA S G, et al. Analysis of the Influence of Forestry Environments on the Accuracy of GPS Measurements by Means of Recurrent Neural Networks [J]. Mathematical and Computer Modelling, 2013: 57(7-8): 2016–2023.
- [16] NAKHAEI F, IRANNAJAD M. Application and Comparison of RNN, RBFNN and MNLR Approaches on Prediction of Flotation Column Performance[J]. International Journal of Mining Science and Technology, 2015, 25(6): 983–990. (in Chinese)
- [17] 范竣翔,李琦,朱亚杰,等.基于RNN的空气污染
 时空预报模型研究[J].测绘科学,2017,42(7):76-83,120.

FAN Junxiang, LI Qi, ZHU Yajie, et al. Aspatio-Temporal Prediction Framework for Air Pollution Based on Deep RNN[J]. Science of Surveying and Mapping, 2017, 42(7): 76-83, 120. (in Chinese)

[18] 朱群雄,孙锋. RNN 神经网络的应用研究 [J]. 北京化 工大学学报(自然科学版), 1998, 25(1): 88-92.
ZHU Qunxiong, SUN Feng. Study on Application of Recurrent Neural Network [J]. Journal of Beijing University of Chemical Technology (Natural Science Edition), 1998, 25(1): 88-92.(in Chinese)

作者介绍



责任作者:李晓晖(1987-),男,重庆市人。 博士,工程师,主要研究方向为智能汽车 测试研发。

Tel: 18696742546 E-mail: lixiaohui@caeri.com.cn



通讯作者: 方芳(1994-), 女,四川自贡 人。硕士研究生,主要研究方向为智能交通、 人工智能、交通信息工程及控制。 Tel: 15923172138 E-mail: 1336261072@qq.com