

文章编号: 1674-8190(XXXX)XX-001-11

基于 K-LSTM 模型的卫星定位误差估计方法

刘瑞华¹, 刘志阳¹, 马赞², 郑智明³, 钟科林⁴

(1. 中国民航大学 电子信息与自动化学院, 天津 300300)

(2. 中国民航大学 安全科学与工程学院, 天津 300300)

(3. 上海飞机设计研究院 航电事业部, 上海 201210)

(4. 上海飞机设计研究院 起落架液压部, 上海 201210)

摘要: 随着全球卫星导航系统(GNSS)的发展,基于卫星的定位技术已成为航空导航的重要数据来源。然而,在无人驾驶城市空中交通(UAM)应用场景下,卫星定位易受多径(MP)和非视距(NLOS)信号的影响导致定位精度恶化,影响飞行安全。为了解决这一问题,提出K-LSTM模型的卫星定位误差估计方法,采用K-means聚类方法检测MP/NLOS信号,研究在不同环境下卫星观测数据与定位误差之间的关系,并在长短时记忆(LSTM)神经网络的基础上增加丢弃层、ReLU层、全连接层和回归层来扩展网络模型,使用基于扩展LSTM模型预测MP/NLOS信号的定位误差并进行改正。结果表明:在静态城市峡谷和动态地面反射环境中,MP/NLOS信号经扩展LSTM模型校正后东、北、天方向定位误差与校正前相比明显减小,定位精度显著提升。

关键词: 卫星定位; K-means聚类; 多径和非视距; 扩展长短时记忆神经网络模型; 误差校正

中图分类号: V249.4; TN965.5

文献标识码: A

DOI: 10.16615/j.cnki.1674-8190.XXXX.XX.01

Positioning error estimation method based on K-LSTM model

LIU Ruihua¹, LIU Zhiyang¹, MA Zan², ZHENG Zhiming³, ZHONG Kelin⁴

(1. College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

(2. College of Safety Science and Engineering, Civil Aviation University of China, Tianjin 300300, China)

(3. Avionics Department, Shanghai Aircraft Design & Research Institute, Shanghai 201210, China)

(4. Landing Gear Hydraulics Department, Shanghai Aircraft Design & Research Institute, Shanghai 201210, China)

Abstract: With the development of Global Navigation Satellite System (GNSS), satellite-based positioning technology has become an important data source for aviation navigation. However, in scenarios involving unmanned urban air mobility (UAM) applications, satellite positioning is susceptible to multipath (MP) and non line of sight (NLOS) signals leading to deterioration in positioning accuracy, posing a challenge to aircraft safety. To address this problem, a proposed method utilizes the K-LSTM model for satellite positioning error estimation. Firstly, the K-means clustering method is used to detect MP/NLOS signals. Secondly, investigating the relationship between satellite observations and positioning errors in different environments and extending the network model. This extension involves adding a dropout layer, a ReLU layer, a fully-connected layer, and a regression layer on top of the Long Short-Term Memory (LSTM) neural network. Finally, using the extended LSTM model to estimate and correct the localization error caused by MP/NLOS signals. The experimental results show that in static urban canyon and dynamic ground reflection environments, the positioning errors in the east, north, and up directions of MP/NLOS signals corrected by the extended LSTM model are significantly reduced compared to before corrections, and the positioning accuracy is significantly improved.

Key words: satellite positioning; K-means clustering; multipath and non line of sight; extended long short-term memory model; error correction

收稿日期: 2024-03-24; 修回日期: 2024-07-13

基金项目: 国家重点研发计划(2022YFB3904304)

通信作者: 马赞(1984-), 男, 硕士, 副研究员。E-mail: mazan_84@163.com

引用格式: 刘瑞华, 刘志阳, 马赞, 等. 基于K-LSTM模型的卫星定位误差估计方法[J]. 航空工程进展, XXXX, XX(XX): 1-11.

LIU Ruihua, LIU Zhiyang, MA Zan, et al. Positioning error estimation method based on K-LSTM model[J]. Advances in Aeronautical Science and Engineering, XXXX, XX(XX): 1-11. (in Chinese)

0 引言

全球卫星导航系统(Global Navigation Satellite System,简称GNSS)是现代航空运输业中不可或缺的一部分,但在无人驾驶城市空中交通(Urban Air Mobility,简称UAM)等复杂环境下,多径(Multipath,简称MP)效应和非视距(Non Line of Sight,简称NLOS)信号仍是制约卫星定位的主要因素。多径信号包括视距(Line of Sight,简称LOS)信号和反射/散射信号,通常会引起几米的伪距误差,而NLOS信号只包括反射/散射信号,在密集城市地区可能造成高达100 m的定位误差^[1]。因此应当有效地避免MP和NLOS信号对GNSS定位精度和准确性的影响^[2-3]。研究如何消除或者抑制MP和NLOS信号对卫星定位精度的影响,已经成为该领域的一个研究热点,如针对天线设计方面,研究了扼流圈天线^[4-5]和双极化天线^[6-7];在信号处理设计方面,开发了先进的接收机算法^[8-10]和传感器融合技术^[11-13];在导航处理器方面,构建了3D城市建筑模型^[14-15]。鉴于实际空间环境中MP和NLOS信号的复杂性,依靠昂贵的外部硬件或者高精度地图的方法成本太高,在实际生活中不现实,且仅依靠单一的检测算法无法取得令人满意的效果。

随着机器学习算法应用的日益广泛,一些研究人员提出采用机器学习方法来提高定位的准确性。Phan等^[16]提出利用支持向量机(Support Vector Machine,简称SVM)预测多径误差来校正全球定位系统(Global Positioning System,简称GPS)测量精度,然而预测模型易受环境的影响,计算效率和定位精度有待提高;Li Z等^[17]提出将模糊神经网络(Fuzzy Neural Network,简称FNN)应用于GPS/惯性导航系统(Inertial Navigation System,简称INS)/里程计的集成系统中,实验结果表明该方法能够在GPS信号长时间丢失的情况下提高集成系统的位置、速度和姿态精度,但其结果在很大程度上依赖INS性能;Navidi等^[18]通过将FNN集成到自适应滤波技术中,证实了二者的复合结构在信号丢失环境中的有效性,然而该方法在计算上较为复杂,且在泛化性能上存在局限;Smolyakov等^[19]提出了一种基于GNSS多路径环境预测和检测的双重架构,利用信号质量检测技术检测和排除多径干扰的GNSS信号,同时通过随机森林

(Random Forest,简称RF)模型来解决地图可用性問題,架构性能与传统卡尔曼滤波(Kalman Filter,简称KF)相比,精度提高了13%~17%,但该方法依赖额外传感器和地图模型;Quan等^[20]提出了一种基于卷积神经网络(Convolutional Neural Network,简称CNN)的载波相位多径检测技术,该方法可以检测到约80%的MP误差,同时通过降低检测MP的权重,实现了18%~30%的定位精度改进;Sun R等^[21]提出通过梯度提升树算法(Gradient Boosting Decision Tree,简称GBDT)训练伪距数据,实现修正NLOS伪距误差以及筛选NLOS卫星,提高了城市环境中的GPS卫星定位精度,但该方法需要事先对MP和NLOS信号进行辅助标记,过程复杂;Kanhare等^[22]提出了基于集合的深度神经网络(Deep Neural Network,简称DNN)方法,将该方法应用于初始位置的GNSS定位校正,有效改善了初始定位误差,但受到其对初始位置猜测和初始化范围的敏感性的限制;王冠宇^[23]提出了基于GBDT的城市多径环境下的GPS定位算法,该方法通过训练伪距误差并进行预测修正,能够有效提高定位精度,但其对所提出的算法只进行了静态定位测试。

针对目前GNSS卫星在复杂环境下导航定位算法依赖额外信息源、成本高、易受环境影响的问题,本文提出一种基于K-LSTM模型的卫星定位误差估计方法,使用K-means聚类算法检测MP/NLOS信号,扩展长短时记忆(Long Short-Term Memory,简称LSTM)神经网络模型估计其定位误差,并对不同应用场景下的静态和动态通航飞机的定位误差进行校正,旨在不增加额外硬件或软件需求的情况下提高定位精度,降低设备成本。

1 基于K-means算法的MP/NLOS信号检测

1.1 特征分析

NMEA-0183是美国国家海洋电子协会为海用电子设备制定的标准格式,它包含定位时间、卫星数、精度因子(Dilution of Precision,简称DOP)、卫星的高度角、载噪比和伪距残差等信息。在原始NMEA-0183数据中,伪距、载波相位、多普勒频移、卫星高度角和载噪比等参数都与GNSS信号

的类型有着密切的关系,使用K-means算法检测MP/NLOS信号的关键是从NMEA-0183数据中提取主要特征。然而,任何单一的数据信息都无法有效地区分MP/NLOS信号,因此需要综合考虑通过组合不同特征值来进行准确分类^[24]。

1) 载噪比。通常情况下,LOS信号的载噪比高于MP/NLOS信号,但是当信号受到建筑物或者其他物体表面反射后,所接收到的NLOS信号强度可能与LOS信号强度相当,因此,仅依赖载噪比来区分难以得到准确的分类结果^[25]。

2) 卫星高度角。一般情况下,卫星的高度角越大,接收到的信号越有可能是LOS信号,然而在城市多径环境下,由于建筑物遮挡和反射的影响,高度角较小的卫星仍然有可能是LOS。

3) 伪距残差。伪距残差的大小和分布可以反映信号的质量和导航系统的性能。理论上,如果观测条件较理想,那么伪距残差较大的信号就是NLOS信号,但在观测条件不理想,可见星数量少于4颗的情况下,伪距残差为0,则该特征不足以作为区分的指标。

上述的每一个特征对于MP/NLOS信号的检测都具有不确定性。本文选用载噪比、卫星高度角和伪距残差这三个参数作为聚类分析的输入特征,并对这些数据进行标准化,以消除它们之间由于量纲和单位差异所引起的影响。

1.2 K-means 聚类算法

在城市多径等复杂环境下,GNSS接收信号都

与载噪比、卫星高度角和伪距残差之间存在特定的关联。基于这一特性,本文运用K-means算法对GPS接收信号进行分类,数据集中的每组样本为 $S = \{x_1, x_2, \dots, x_n\}$,其中, n 代表样本的数量,将数据集中的样本进行标准化,每个样本 $x_n = \{c_n, el_n, \rho_n\}$ 由标准化后的载噪比、卫星高度角和伪距残差构成。K-means算法的目标是将样本数据划分为指定的 k 个簇 $C = \{C_1, C_2, \dots, C_k\}$,当样本点距离聚类中心点最近时,就划分为该类,使得每个样本点到其最近聚类中心的欧氏距离之和最小,数学表达式为

$$E(m_1, m_2, \dots, m_k) = \sum_{i=1}^n \sum_{j=1}^k I(x_i \in C_k) \|x_i - m_k\|^2 \quad (1)$$

式中: x_i 为样本数据点; I 为每个簇中选取的样本数据集; m_k 为簇 C_k 的质心,即簇 C_k 中所有样本的均值。

$$m_k = \frac{1}{|C_k|} \sum_{x_i \in C_k} x_i \quad (2)$$

2 扩展 LSTM 误差估计模型

2.1 GNSS 的观测特征提取

伪距定位的误差源包括时钟误差、电离层误差、对流层误差和多径效应引起的误差。NEMA-0183数据的卫星信息、定位信息和地面速度信息等,它们都与误差源相关联。本文选择的观测特征如表1所示。

表1 观测量和位置误差的关系

Table 1 Relationship between observations and location error

观测量	位置误差影响
经度(lat)、纬度(lon)、高度(alt)	观测定位信息的准确性和精度会直接影响到位置误差
载噪比(c)	卫星载噪比代表了接收到的卫星信号质量
高度角(el)	卫星高度角越大,受到障碍物遮挡的概率越低,GNSS信号质量就相对越好
方位角(az)	卫星方位角的分布与DOP值有直接的关系,方位角分布不均匀会造成定位精度下降
卫星数($sats$)	卫星数目越多,定位精度就越高
精度因子(Dop)	DOP值越大,定位误差越大,定位精度越低
地面速度(v)	较高的地面速度会导致多普勒效应显著,增大定位误差

2.2 扩展 LSTM 模型

循环神经网络(Recurrent Neural Network, 简

称RNN)适用于处理和分析具有时间依赖性的数据序列,具有一定的记忆性,适用于对时间序列数据建模。LSTM网络是RNN的一种特殊形式,在

RNN的基础上引入了门控结构和状态单元,与RNN相比具有更新和删除上一时刻信息的功能。它能够学习长期序列的依赖关系,解决了RNN网络在处理长时序数据上存在的梯度消失和爆炸问题。网络结构如图1所示。

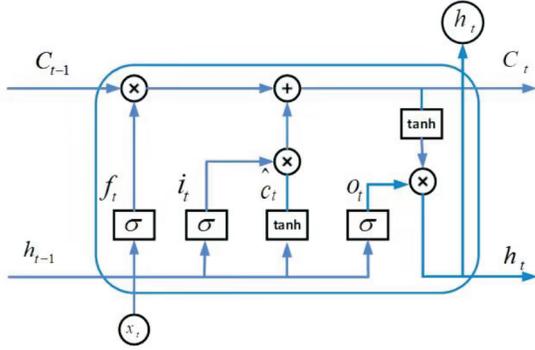


图1 LSTM模型结构

Fig. 1 LSTM model structure

遗忘门 f_t 表示为

$$f_t = \sigma(w_f[h_{t-1}, x_t] + b_f) \quad (3)$$

输入门 i_t 表示为

$$i_t = \sigma(w_i[h_{t-1}, x_t] + b_i) \quad (4)$$

输出门 o_t 表示为

$$o_t = \sigma(w_o[h_{t-1}, x_t] + b_o) \quad (5)$$

t 时刻 LSTM 网络的状态单元 c_t 表示为

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \hat{c}_t \quad (6)$$

t 时刻候选状态信息 \hat{c}_t 表示为

$$\hat{c}_t = \tanh(w_c[h_{t-1}, x_t] + b_c) \quad (7)$$

t 时刻隐藏状态信息 h_t 表示为

$$h_t = o_t \cdot \tanh(c_t) \quad (8)$$

式中: x_t 为当前输入; i_t 为输入门值; w_f, w_i, w_o, w_c 分别为各个状态的循环权重; b_f, b_i, b_o, b_c 分别为各个状态的偏置; h_{t-1}, c_{t-1} 为上一时刻的隐藏状态和

候选状态; σ 和 \tanh 为 LSTM 网络的激活函数, 激活函数 σ, \tanh 分别表示 sigmoid 函数和双曲正切函数。

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (9)$$

$$\tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (10)$$

f_t 控制上一时刻的状态单元 c_{t-1} 中的信息是否传递到当前时刻, 决定了上一时刻输出信息量的保留比重; i_t 控制当前时刻的输入 x_t 和隐藏状态 h_{t-1} 从而选择性地获取当前输入信息; o_t 则能根据新输入的信息与上一时刻输出的信息计算出当前时刻的输出, c_t 用来存储和传输时间序列信息。

虽然 LSTM 网络在处理时间序列数据和长期依赖关系方面具有很多优势, 但当训练数据不足或网络过于复杂时, 容易出现过拟合, 导致模型性能下降。为了网络模型具有更好的泛化性能, 本文在 LSTM 的基础上增加了丢弃层、ReLU 层、全连接层和回归层。丢弃层在训练过程中随机丢弃一部分神经元及其连接输出, ReLU 层具有激活稀疏性的特性, 可以使得神经网络更加稀疏, 减少参数的冗余性, 有助于缓解梯度消失的情况。全连接层可以通过多个神经元之间的连接和权重学习, 增加网络的深度, 使其能够学习更复杂的特征和模式。回归层用于学习输入特征与输出定位误差之间的映射关系, 有助于提高模型的预测能力和实用性。

扩展 LSTM 模型架构如图 2 所示, 输入数据的维度为 (N, X_{dim}) , 数据将逐步输入到 LSTM 网络中, 在每个时间步长中输入数据的维度是 $(1, H_{dim})$ 。

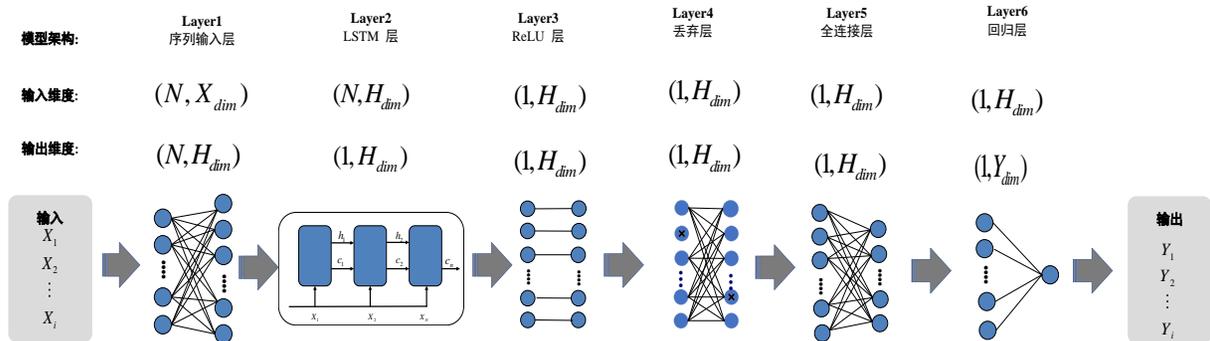


图2 扩展LSTM模型架构

Fig. 2 Extended LSTM model architecture

在 LSTM 网络中,状态单元信息 c_t 和隐藏状态信息 h_t 的维数都是 $(1, H_{dim})$ 。因此,在完成所有时间步长的计算之后,由 LSTM 网络输出的数据维度是 $(1, H_{dim})$ 。然后,数据将被馈送到 ReLU 层、丢弃层和全连接层。最后在回归层数据维度将转换为 $(1, Y_{dim})$ 。这就是整个神经网络的预测结果。网络设计参数如表 2 所示。

表 2 网络设计的参数
Table 2 Parameters used to design the network model

参数	含义	设置
X_{dim}	LSTM 输入数据的维度	10
H_{dim}	LSTM 隐含层的维度	30
Y_{dim}	LSTM 输出数据的维度	1
N	训练数据的时间步长	300
σ	LSTM 层门函数	Sigmoid

在本文中,扩展 LSTM 模型的目标是学习一个目标函数 $\hat{\phi}$,通过输入特征 X_i 来输出预测的定位误差 $\Delta\hat{y}_i$,可表示为

$$\Delta\hat{y}_i = \hat{\phi}(X_i) \forall i \in \{1, \dots, M\} \quad (11)$$

$$X = \{lat, lon, alt, sats, el, az, c, Dop, v\} \quad (12)$$

$$\Delta\hat{y} = \{\Delta\hat{y}_e, \Delta\hat{y}_n, \Delta\hat{y}_u\} \quad (13)$$

式中: i 为第 i 行历元数据; M 为历元总数; $\Delta\hat{y}_e$ 、 $\Delta\hat{y}_n$ 、 $\Delta\hat{y}_u$ 分别为东、北、天方向的预测误差。 $\Delta\hat{y}_i$ 包括了很难建模分析的 MP/NLOS 信号造成的定位误差。

3 实验仿真

3.1 静态观测数据聚类

R&S®SMBV100A 数字信号源的 GPS 模块通过加载预定义的城市峡谷环境和真实导航数据的历书文件模拟在该场景下的卫星定位,采用 NovAtel ProPak6 接收机接收 GPS 卫星观测数据,实验设备如图 3 所示。模拟的城市峡谷环境如图 4 所示,存在遮挡和多径效应,因此接收机接收到的卫星信号除了 LOS 信号外,还包括 NLOS 和 MP 信号。观测时间为 3 h,采样频率为 2 Hz,真实位置已知。

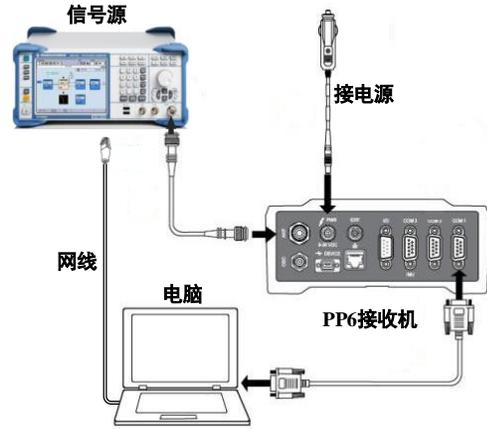


图 3 实验设备图
Fig. 3 Diagram of experimental equipment

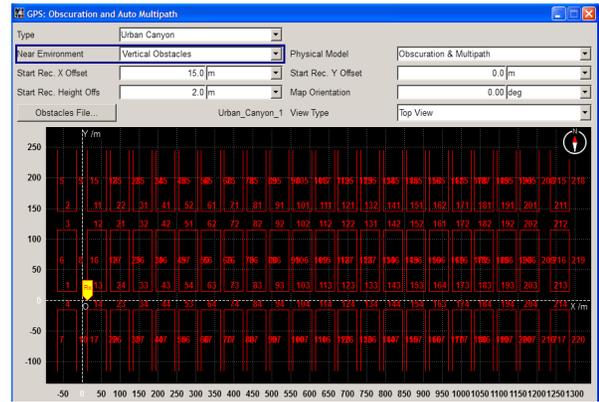


图 4 城市峡谷环境
Fig. 4 Urban canyon environment

为了确保卫星高度角特征值的完整性,将卫星高度角的截止角设置为 0° ,通过卫星高度角、载噪比和伪距残差三个特征值作为样本学习的特征向量,以信号源实时天空图和伪距误差将数据集分类为 MP/NLOS 信号和 LOS 信号。

分别采用 K-means 聚类算法与 RF、GBDT 和 K-最近邻 (K-Nearest Neighbor, 简称 KNN) 进行性能比较,其中 RF 分类树节点分裂标准为 Gini 指数,决策树数量为 100,数的最大深度为 10;GBDT 的最大迭代次数为 100,学习率为 0.1,叶节点数为 50,决策树最大深度为 10;KNN 的 K 值为 5,采用欧氏距离算法计算距离。分类算法对比如表 3 所示。

表 3 中分类算法的正确率表示每个类别中被正确分类的样本数与该类别总样本数的比例,通过不同算法之间的分类正确率、错误率比较表明,K-means 聚类算法与 RF、GBDT 和 KNN 算法在处

理分类任务时的性能区别,K-means算法不需要划分数据集,不用训练学习,且K-means算法的总体分类性能相较最优。

表3 分类算法对比

Table 3 Comparison of classification algorithms

算法	LOS分类 准确率/%	MP/NLOS分 类准确率/%	正确率/%	错误率/%
K-means	92.03	97.04	94.54	5.45
RF	87.65	98.70	93.17	6.83
GBDT	87.50	93.55	90.53	9.47
KNN	87.48	89.12	88.30	11.70

卫星定位的准确度受到观测数据的质量和卫星在空间中的分布形态的共同作用。当排除MP/NLOS信号后,可见卫星和参与定位解算卫星的数目都会减少,这将导致位置精度因子(Position Dilution of Precision,简称PDOP)增大。为了保证有足够的可用卫星,不能完全剔除MP/NLOS信号。为了进一步减小定位误差,将K-means算法聚类后的MP/NLOS信号,通过使用扩展LSTM模型预测并改正其定位误差。

3.2 静态城市峡谷定位分析

扩展LSTM模型输入采取minmax归一化处理,训练集和测试集按照0.8:0.2的比例划分,初始学习率设置为0.01,梯度阈值步长设置为1,丢弃率设置为0.1,选用RMSProp优化器。损失函数是网络的预测值和观测值之间的均方误差(Mean Squared Error,简称MSE),其表示为

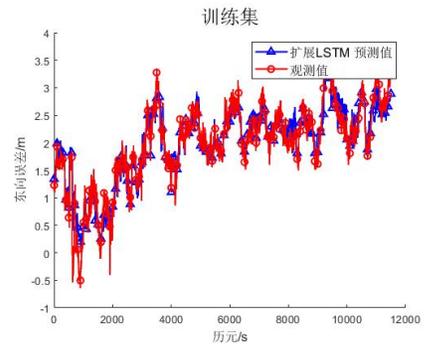
$$MSE = \frac{1}{N} \sum_{n=1}^N (y_n - \hat{y}_n)^2 \quad (14)$$

使用决定系数(R^2)评估神经网络预测模型的准确性,其表示为

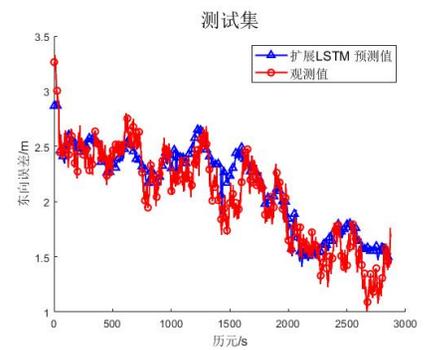
$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

式中: y_i 为实际测量值; \hat{y}_i 为模型预测值; \bar{y} 为预测值的平均值。

使用扩展LSTM模型预测静态城市峡谷环境下目标定位的东、北、天向误差,训练和测试结果如图5所示,训练集和测试集的MSE和 R^2 如表4所示。由 R^2 可知扩展LSTM模型的预测误差能够遵循真实观测误差的趋势。

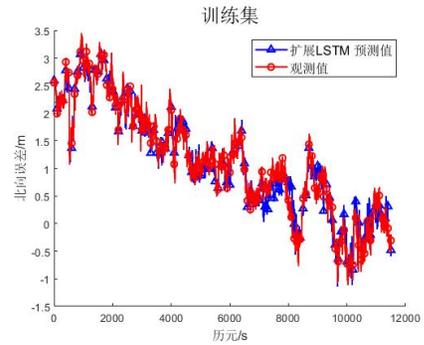


(a1) 训练集

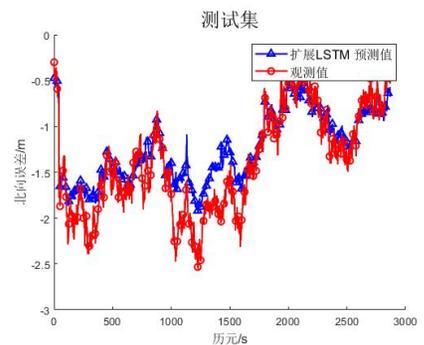


(a2) 测试集

(a) 东向

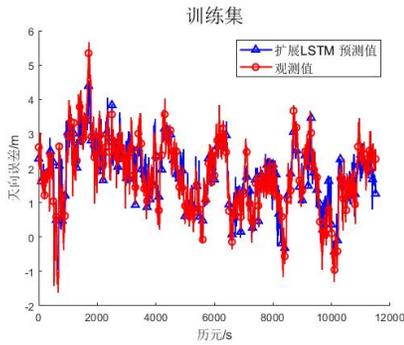


(b1) 训练集

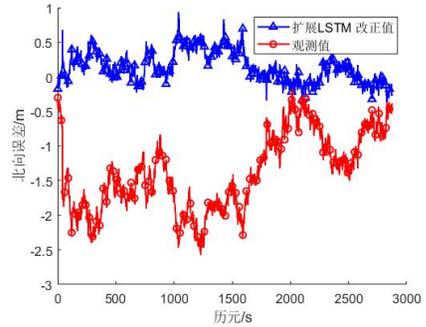


(b2) 测试集

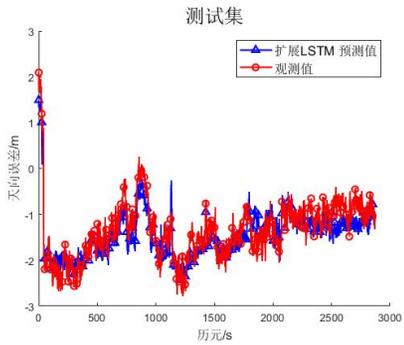
(b) 北向



(c1) 训练集

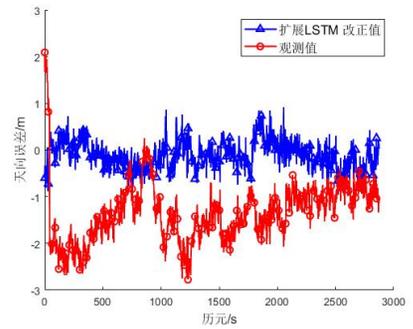


(b) 北向



(c2) 测试集

(c) 天向



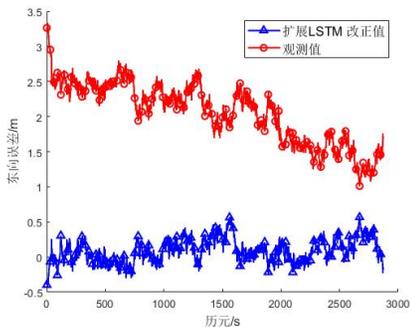
(c) 天向

图 5 扩展 LSTM 模型的训练和测试
Fig. 5 Training and test of the extended LSTM model

表 4 扩展 LSTM 模型的训练和测试指标
Table 4 Training and test metrics for the extended LSTM model

方向	MSE_{train}	R^2_{train}	MSE_{test}	R^2_{test}
东	0.0484	0.9732	0.0360	0.8125
北	0.0297	0.9534	0.0561	0.8195
天	0.1748	0.8410	0.1033	0.7491
平均值	0.0843	0.9225	0.0651	0.7937

经扩展 LSTM 模型改正后的东、北、天向误差如图 6 所示。



(a) 东向

图 6 扩展 LSTM 模型改正 MP/NLOS 数据前后定位误差
Fig. 6 Positioning error before and after correction of extended LSTM model in test MP/NLOS set

从图 6 可以看出:在静态城市峡谷环境中,测试集数据东、北、天 3 个方向的定位误差分别为 0.6、0.9、1.0 m。

3.3 动态反射环境定位分析

为了验证本文方法在动态场景中的适用性,进行了一组动态飞机模拟飞行测试。使用 R&S®SMBV100A 数字信号源模拟飞机在地面反射环境飞行,模拟的地面反射环境如图 7 所示,飞行轨迹如图 8 所示。接收 3 hGPS 卫星观测数据,频率为 2 Hz。

为了验证扩展 LSTM 模型的普适性,飞机在反射环境下飞行的所有观测数据采用 K-means 算法对 MP/NLOS 信号数据进行聚类,使用该扩展模型预测 MP/NLOS 信号的定位误差,模型的训练和测试结果训练和测试结果如图 9 所示,训练集和测试集的 MSE 和 R^2 如表 5 所示。

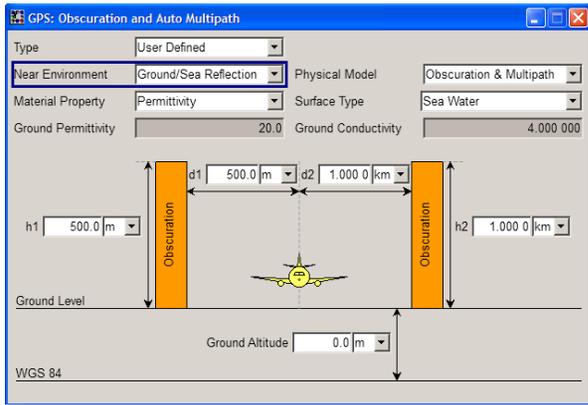


图 7 地面反射环境
Fig. 7 Ground reflection environment

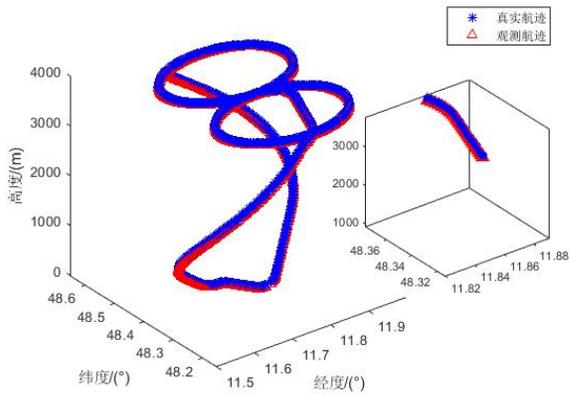
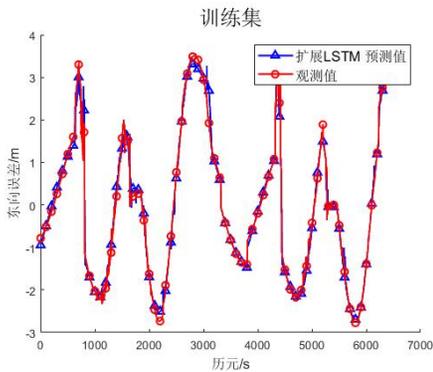
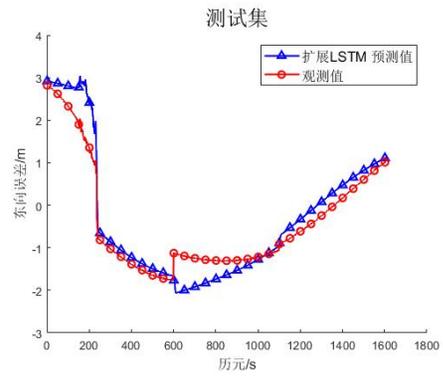


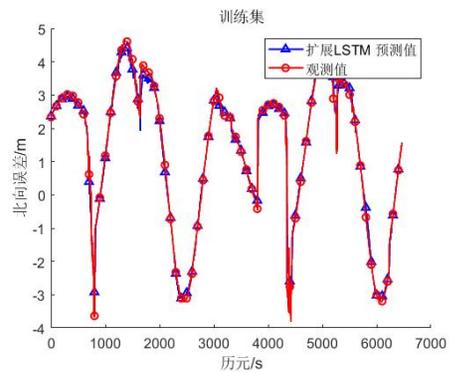
图 8 飞机飞行轨迹
Fig. 8 Dynamic airplane flight trajectory



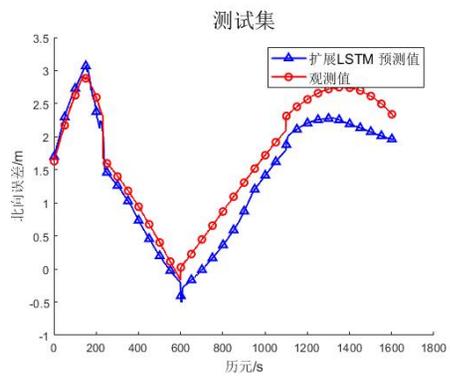
(a1) 训练集



(a2) 测试集
(a) 东向



(b1) 训练集



(b2) 测试集
(b) 北向

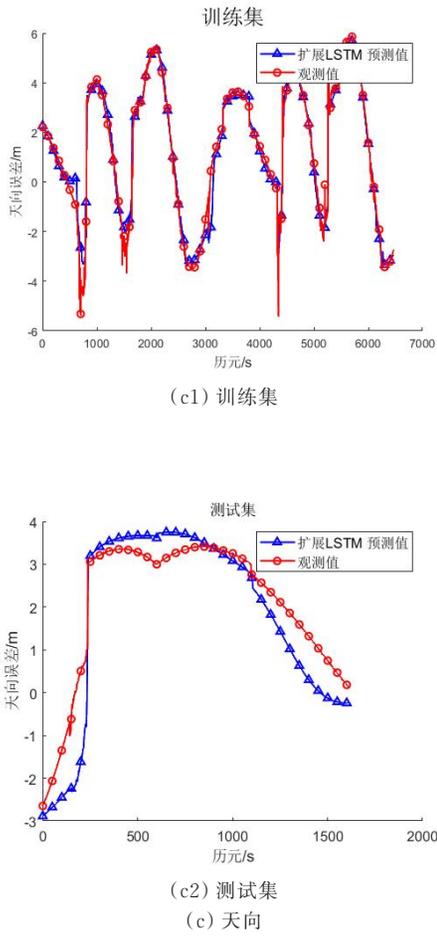


图9 扩展LSTM模型的训练和测试

Fig. 9 Training and test of the extended LSTM model

表5 扩展LSTM模型的训练和测试指标

Table 5 Training and test metrics for the extended LSTM model

方向	MSE_{train}	R^2_{train}	MSE_{test}	R^2_{test}
东	0.0302	0.9897	0.1754	0.8874
北	0.0496	0.9652	0.1302	0.8451
天	0.2114	0.9711	0.4283	0.8335
平均值	0.0971	0.9753	0.2446	0.8553

在动态反射环境中,经扩展LSTM模型改正后的东、北、天向定位误差如图10所示,测试集数据东、北、天3个方向的定位误差分别为1.5、1.0、2.5 m。

从静态实验和动态实验中可以看出,扩展LSTM模型预测的定位误差值大致遵循观测误差值的趋势,改正过后的定位误差得到了显著的改

善。但在不同的环境场景需要训练不同的特征数据,尽管采用正则化方法处理,模型仍然依赖训练集的训练结果。

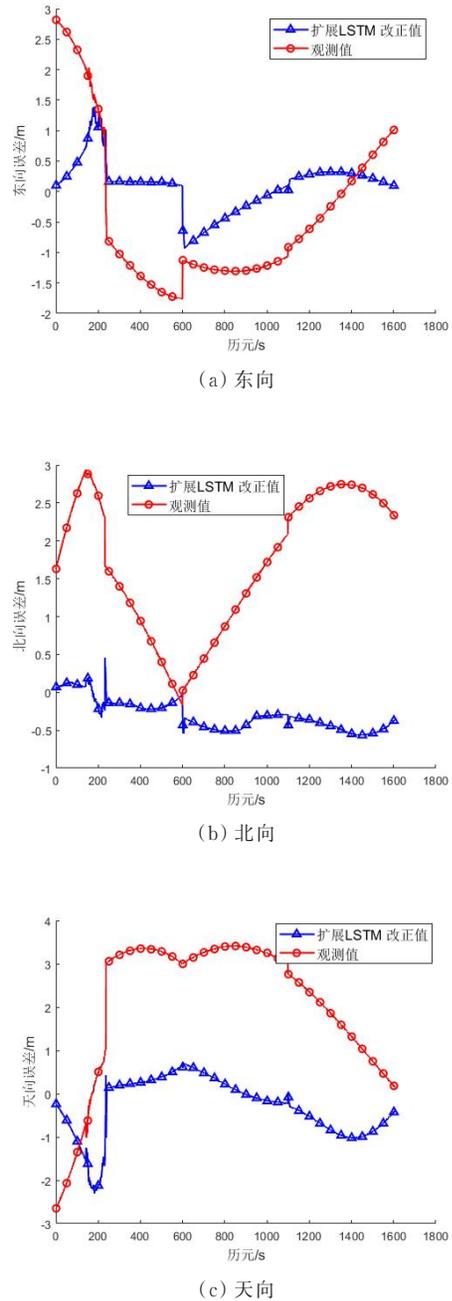


图10 扩展LSTM网络改正测试集MP/NLOS前后定位误差

Fig. 10 Positioning error before and after correction of extended LSTM model in test MP/NLOS set

4 结 论

1) 本文采用 K-means 算法检测 MP/NLOS 信号,并用扩展 LSTM 模型对其定位误差进行改正。在静态城市环境中,改正后的东、北、天方向的定位误差分别为 0.6、0.9、1.0 m;在动态反射环境中东、北、天方向的定位误差分别为 1.5、1.0、2.5 m。

2) 机器学习的优势在于能够通过训练来学习测量环境对数据的影响,自动集成 GNSS 接收机的几种测量数据用作神经网络模型的输入来估计位置误差。本文所提的算法模型能够学习定位误差数据集中的长期趋势,无需依赖高精度的惯性导航系统等昂贵的传感器设备,同时也避免了使用 3D 城市模型等额外的信息源,该方法能够在较低的成本下有效地提高定位的准确性。

3) 本文探讨了机器学习方法在卫星定位领域的运用,由于机器学习算法对数据集的场景依赖性较强,不同场景通常需要专属的数据集。因此,在应用机器学习方法时,需要深入研究实时变化的环境场景对定位精度的具体影响。同时,鉴于 GNSS 信号传播的特性和信号的统计特性,如何选取更加合适的特征向量也是未来研究的一个重要方向。

参 考 文 献

- [1] FILHO V, MORAES A. Modeling multifrequency GPS multipath fading in land vehicle environments[J]. *GPS Solutions*, 2021, 25(1): 1-14.
- [2] GROVES P D, JIANG Z, WANG L, et al. Intelligent urban positioning using multi-constellation GNSS with 3D mapping and NLOS signal detection[C]// *Proceedings of ION GNSS*. Nashville, TN, USA: IEEE, 2012: 458-472.
- [3] MIURA S, HISAKA S, KAMIJO S. GPS multipath detection and rectification using 3D maps[C]// *16th International IEEE Conference on Intelligent Transportation Systems*. Netherlands: IEEE, 2013: 1528-1534.
- [4] 王春华, 吴文平, 王晓辉, 等. 3D 扼流圈天线设计[J]. *数字通信世界*, 2014(8): 15-18.
WANG Chunhua, WU Wenping, WANG Xiaohui, et al. Design of 3D choke ring antenna[J]. *Digital Communication World*, 2014(8): 15-18. (in Chinese)
- [5] 高玉平, 刘子懿, 徐劲松, 等. 单频 GPS 接收机天线扼流圈的研制与测试[J]. *时间频率学报*, 2006(1): 53-59.
GAO Yuping, LIU Ziyi, XU Jinsong, et al. An antenna choke ring for single-frequency GPS receiver[J]. *Journal of Time and Frequency*, 2006(1): 53-59. (in Chinese)
- [6] 王冠宇, 孙蕊, 程琦. 城市峡谷中基于 GPS 双极化天线的定位方法[J]. *导航定位学报*, 2020, 8(4): 13-19.
WANG Guanyu, SUN Rui, CHENG Qi. Positioning method based on GPS dual-polarized antenna in urban canyon environment[J]. *Journal of Navigation and Positioning*, 2020, 8(4): 13-19. (in Chinese)
- [7] XIE L, CUI X, ZHAO S, et al. Mitigating multipath bias using a dual-polarization antenna: theoretical performance, algorithm design, and simulation [J]. *Sensors*, 2017, 17(2): 359.
- [8] ZIEDAN N I. Improved multipath and NLOS signals identification in urban environments[J]. *Journal of the Institute of Navigation*, 2018, 65(3): 449-462.
- [9] GROVES P. Shadow matching: a new GNSS positioning technique for urban canyons [J]. *Journal of Navigation*, 2010, 64(3): 417-430.
- [10] NG H F, ZHANG G, YANG K Y, et al. Improved weighting scheme using consumer-level GNSS L5/e5a/b2a pseudorange measurements in the urban area[J]. *Advances in Space Research*, 2020, 66(7): 1647-1658.
- [11] WEN W, ZHANG G, HSU L. Exclusion of GNSS NLOS receptions caused by dynamic objects in heavy traffic urban scenarios using real-time 3D point cloud: an approach without 3D maps[C]// *2018 IEEE/ION Position, Location and Navigation Symposium (PLANS)*. Monterey: IEEE, 2018: 158-165.
- [12] LEE M J L, LEE S, NG H F, et al. Skymask matching aided positioning using sky-pointing fisheye camera and 3d city models in urban canyons[J]. *Sensors*, 2020, 20(17): 4728.
- [13] BAI X, WEN W, HSU L T. Using sky-pointing fish-eye camera and lidar to aid GNSS single-point positioning in urban canyons[J]. *IET Intelligent Transport Systems*, 2020, 14(8): 908-914.
- [14] YUAN Y, SHEN F, LI X D. GPS multipath and NLOS mitigation for relative positioning in urban environments[J]. *Aerospace Science and Technology*, 2020, 107(12): 106-128.
- [15] KBAYER N, SAHMOUDI M. Performances analysis of GNSS NLOS bias correction in urban environment using a 3D city model and GNSS simulator[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2018, 54(4): 1799-1814.

- [16] PHAN Q H, TAN S L, MCLOUGHLIN I, et al. A unified framework for GPS code and carrier-phase multipath mitigation using support vector regression [J]. *Advances in Artificial Neural Systems*, 2013, 112: 1-14.
- [17] LI Z, WANG J, LI B, et al. GPS/INS/Odometer integrated system using fuzzy neural network for land vehicle navigation applications [J]. *Journal of Navigation*, 2014, 67(6): 967-983.
- [18] NAVIDI N, LANDRY R J. A new survey on self-tuning integrated low-cost GPS/INS vehicle navigation system in harsh environment [J]. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2015, 58: 75-81.
- [19] SMOLYAKOV I, REZAEI M, LANGLEY R. Resilient multipath prediction and detection architecture for low-cost navigation in challenging urban areas [J]. *Navigation*, 2020, 67(2): 397-409.
- [20] QUAN Y, LAU L, ROBERET S, et al. Convolutional neural network based multipath detection method for static and kinematic GPS high precision positioning [J]. *Remote Sensing*, 2018, 10(12): 1-19.
- [21] SUN R, WANG G, CHENG Q, et al. Improving GPS code phase positioning accuracy in urban environments using machine learning [J]. *IEEE Internet of Things Journal*, 2021, 8(8): 7065-7078.
- [22] KANHERE A V, GUPTA S, SHETTY A, et al. Improving GNSS positioning using neural-network-based corrections [J]. *Journal of the Institute of Navigation*, 2022, 69(4): 548-560.
- [23] 王冠宇. 城市多径环境下的导航定位技术及其应用研究 [D]. 南京: 南京航空航天大学, 2021.
- WANG Guanyu. Research on positioning and navigation technologies and its applications in urban multipath environments [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2021. (in Chinese)
- [24] 夏炎, 潘树国, 赵鹏飞, 等. 基于无监督学习的卫星 NLOS 信号检测方法 [J]. *东南大学学报(自然科学版)*, 2019, 49(3): 565-572.
- XIA Yan, PAN Shuguo, ZHAO Pengfei, et al. Unsupervised learning based satellite NLOS signal detection method [J]. *Journal of southeast university (Natural Science Edition)*, 2019, 49(3): 565-572. (in Chinese)
- [25] 侯宁宁, 李灯熬, 赵菊敏. 基于无监督学习和粒子滤波的非视距信号检测 [J]. *北京航空航天大学学报*, 2022, 48(11): 2250-2258.
- HOU Ningning, LI Deng'ao, ZHAO Jumin. Non-line-of-sight signal detection based on unsupervised learning and particle filtering [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2022, 48(11): 2250-2258. (in Chinese)

(编辑:马文静)