引文格式：王长栓,鲍烨青,李伟. 一种基于PC-LSTM的GNSS场景识别方法[J]. 地理空间信息, 2025, 23(8):110-113. doi:10. 3969/j.issn. 1672-4623.2025.08.023

# 一种基于PC-LSTM的GNSS场景识别方法

王长栓[1]，鲍烨青[2*]，李　伟[3]
（1. 广西壮族自治区地理信息测绘院，广西 柳州 545006；2. 中国电力工程顾问集团中南电力设计院有限公司，湖北 武汉 430071；
3. 广西科之新科技有限公司，广西 南宁 530007）

**摘　要：**基于全球导航卫星系统（GNSS）的定位服务在城市中得到广泛应用，但不同信号遮挡场景下定位精度差异较大，准确快速的场景识别是开发自适应GNSS定位算法的关键。为提高场景识别准确率和鲁棒性，提出一种基于并联长短期记忆网络（PC-LSTM）的GNSS场景识别方法。首先，将城市静态定位环境细分为五类遮挡场景；然后，以原始观测数据和站星几何关系构建特征向量并分析各特征在不同场景识别中的表现；最后，提出一种基于PC-LSTM的GNSS定位场景识别模型。实验结果表明，该模型识别准确率可达99.27%；同时，每轮次训练时间和每样本预测时间低至0.68 s和2.07 ms，在丢失部分观测数据的情况下识别准确率仍可达到最大98.87%，具有良好的实时性和鲁棒性。

**关键词：**GNSS场景识别；城市静态定位；深度学习；长短期记忆网络
**中图分类号：**P228　　**文献标志码：**B　　**文章编号：**1672-4623（2025）08-0110-04

## GNSS Scene Recognition Method Based on Parallel-connected Long Short-term Memory

WANG Changshuan[1], BAO Yeqing[2], LI Wei[3]
(1. Geographic Information Surveying and Mapping Institute of Guangxi Zhuang Autonomous Region, Liuzhou 545006, China;
2. Central Southern Electric Power Design Institute Co., Ltd., CPECC, Wuhan 430071, China;
3. Guangxi Kezhixin Science and Technology Co., Ltd., Nanning 530007, China)

**Abstract:** Positioning services based on global navigation satellite system (GNSS) are widely applied in cities, but positioning accuracy varies greatly under different signal obstruction scenes. Accurate and fast scene recognition is the key to developing adaptive GNSS positioning algorithms. In order to improve the accuracy and robustness of GNSS scene recognition model, we proposed a new method based on parallel-connected long short-term memory network (PC-LSTM). Firstly, we subdivided the urban static positioning environment into five types of occlusion scenes. Then, we constructed the feature vector based on the original observation data and the station-satellite geometric relationship, and analyzed the performance of each feature in different scenes in detail. Finally, we proposed a GNSS positioning scene recognition model based on PC-LSTM. Experimental results show that the recognition accuracy of this model can reach 99.27%. At the same time, the training time of each epoch and the prediction time of each sample are as low as 0.68 s and 2.07 ms, and the recognition accuracy can still reach a maximum of 98.87% even if part of the observation data is lost, which shows that the proposed model has good real-time performance and robustness.

**Key words:** GNSS scene recognition, urban static positioning, deep learning, long short-term memory network

近年来，出现了一系列GNSS定位精度提升算法，如：阵列信号处理[1-2]，抗多径算法[3-4]和高灵敏度跟踪算法等[5-6]。然而，上述方法都具有场景依赖性，其实际应用时需要以快速准确地识别场景为前提，否则易因为算法场景间不匹配而产生较大定位误差。

针对场景识别问题，研究人员主要聚焦于2种技术途径：基于多传感器融合技术和基于GNSS信号的技术。在多传感器融合领域，相机、激光雷达以及加速度计和陀螺仪等信号传感器被用来探测GNSS接收机周围的环境特征，进而完成定位场景的识别[7]。尽管借助其他环境传感器设备可以实现精确、直观的场景识别，但这类方法的应用规模受高算力需求和昂贵设备成本的限制。基于GNSS信号的方法则利用不同的观测数据构造特征数据，借助统计分析或机器学习等工具，在无需额外传感器观测的条件下准确、快速地辅助场景识别的实现[8-9]。然而，统计特征分析依赖于原始数据分布，而现有基于机器学习的方法往往直接应用现有成熟神经网络，这种空间转移策略容易造成特征退化，原始观测数据利用率仍有待提升。

本文以共享单车定位为实际应用案例，旨在设计

项目来源：国家自然科学基金资助项目（41961063）；中央引导地方科技发展资金专项资助项目（2022SRZ0101）。
第一作者简介：王长栓（1980—），本科，高级工程师，从事测绘地理信息应用工作，E-mail：9798727@qq.com。
通信作者：鲍烨青（1998—），硕士研究生，助理工程师，从事工程测量工作，E-mail：1020844841@qq.com。

一种适应城市复杂环境的 GNSS 定位场景识别方法。该方法充分考虑城市中细粒度定位遮挡场景，从神经网络角度出发分析不同特征对不同场景的敏感性，提出一种基于并联长短期记忆网络（parallel-connected long short-term memory，PC-LSTM）的 GNSS 场景识别方法，并从实时性和鲁棒性的角度验证其实际应用潜力。

## 1　基于 PC-LSTM 的 GNSS 场景识别网络设计

模型总体设计思路如图 1 所示。观测数据首先被构造成不同的特征向量，然后将这些特征向量输入并联长短期记忆网络（PC-LSTM）中来识别 5 个场景。

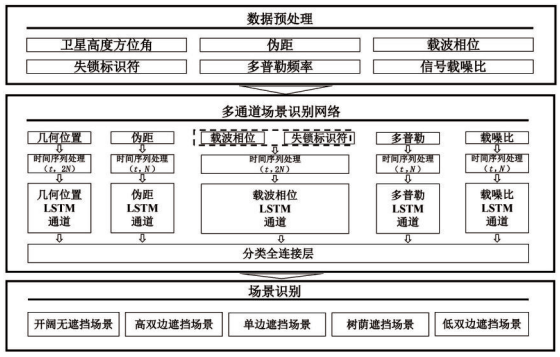



图 1　研究思路

### 1.1　观测特征分析和特征向量构造

#### 1.1.1　GNSS 接收机原始观测值

全球导航卫星系统通常由三部分组成：空间卫星星座、地面控制站和用户终端。用户可以通过各种终端（接收机）接收空间卫星发射的载波信号，接收机可以将其处理为不同的观测数据，包括伪距、载波相位、多普勒频率和载噪比[10]。

为了统一数据尺度，将原始观测值标准化如下：

$$d_{\text{norm}}=\frac{d-d_{\min}}{d_{\max}-d_{\min}} \tag{1}$$

式中，$d_{\max}$ 和 $d_{\min}$ 为某一时间步长内特定类型观测数据的最大值和最小值；$d$ 为原始观测数据。归一化仅要求简单的四则运算，但对辅助神经网络快速收敛具有重要意义[11]。除此之外，将站星几何位置关系作为观测特征之一，使用卫星高度角和方位角构建特征向量。

#### 1.1.2　特征向量定义

本文使用特征向量作为场景识别模型的输入，既考虑原始观测数据，也考虑卫星和接收机之间的几何位置关系。以固定长度的序列向量来表示接收机对特定卫星导航系统的观测情况。

此外，将卫星高度角和方位角合并为一个几何位置特征，使用一个长度为 $2N$ 的向量来存储归一化高度、方位角（其中 $N$ 表示导航卫星系统的最大 PRN）。本文对特征向量的定义总结如表 1。

表 1　特征向量定义

| 特征信息 | 向量维度 |
|---|---|
| 卫星高度角和方位角 | $2N$ |
| 伪距 | $N$ |
| 载波相位 | $N$ |
| 载波相位和失锁标识符 | $2N$ |
| 多普勒频率 | $N$ |
| 载噪比 | $N$ |

### 1.2　基于 PC-LSTM 的场景识别模型

#### 1.2.1　LSTM 神经网络和单特征场景识别模型

LSTM 网络主要用于学习和预测数据序列中的时间特征。实际上，在 GNSS 定位场景识别领域，LSTM 已被证明是众多机器学习模型中最有效的网络模型[12]。该网络由众多如图 2 所示的 LSTM 单元组成，这些单元用于确定信息是否值得被网络记忆保留。每个单元输出一个隐藏状态向量 $\boldsymbol{h}_{t-1}$ 和传递到下一个单元的记忆 $C_t$。LSTM 单元的关键表达式如下[13]：

$$I_t=\sigma\left(X_t\boldsymbol{W}_{xi}+\boldsymbol{h}_{t-1}\boldsymbol{W}_{hi}+b_i\right) \tag{2}$$

$$F_t=\sigma\left(X_t\boldsymbol{W}_{xf}+\boldsymbol{h}_{t-1}\boldsymbol{W}_{hf}+b_f\right) \tag{3}$$

$$O_t=\sigma\left(X_t\boldsymbol{W}_{xo}+\boldsymbol{h}_{t-1}\boldsymbol{W}_{ho}+b_o\right) \tag{4}$$

$$\hat{C}_t=\tanh\left(X_t\boldsymbol{W}_{xc}+\boldsymbol{h}_{t-1}\boldsymbol{W}_{hc}+b_c\right) \tag{5}$$

$$C_t=F_t\odot C_{t-1}+I_t\odot\hat{C}_t \tag{6}$$

式中，$\odot$ 为点积运算；$\sigma$ 为 Sigmoid 激活函数；$I_t$、$F_t$、$O_t$ 为输入门、遗忘门和输出门的输出；$\boldsymbol{W}_{xi}$，$\boldsymbol{W}_{hi}$、$\boldsymbol{W}_{xf}$、$\boldsymbol{W}_{hf}$、$\boldsymbol{W}_{xo}$、$\boldsymbol{W}_{ho}$ 为输入门、遗忘门、输出门的权重矩阵；$\boldsymbol{W}_{xc}$、$\boldsymbol{W}_{hc}$ 为候选记忆的权重矩阵；$b_i$、$b_f$、$b_o$、$b_c$ 为人为偏置。隐藏状态 $\boldsymbol{h}_t$ 计算如下：

$$\boldsymbol{h}_t=O_t\otimes\tanh\left(C_t\right) \tag{7}$$

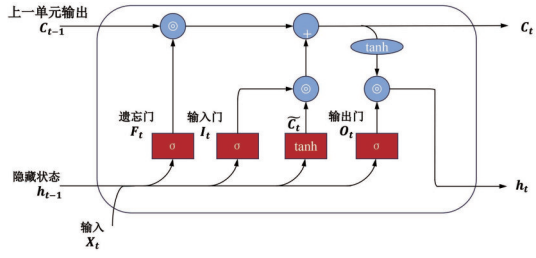



图 2　LSTM 单元结构图

本实验首先搭建适用于单特征输入的传统 LSTM 场景识别网络，为了保证算法的实时性，仅添加 3 个串联的 LSTM 层来处理单一类型的特征向量。序列时间步长为 10 s。滑动窗口为 1 s，使用交叉熵损失函数并用 Adam 优化网络参数。每个单特征网络经历 500 轮

次的训练。学习率为0.000 01。

1.2.2 定位场景划分与特征敏感性分析

通常GNSS定位场景由室外和室内2个主要部分组成[14]。城市峡谷和林荫大道是城市环境中典型的定位场景[8]。为了提升场景识别的精细化程度，进一步将城市峡谷细分为高双边遮挡、低双边遮挡和单边遮挡。由于室内场景可以根据卫星信号的存在性判断，不在本文考虑范围。综上，将定位场景分为空旷无遮挡、单边遮挡、高双边遮挡、树荫遮挡和矮双边遮挡5类。

以6种GNSS信号观测特征分别作为网络的输入，使用1.2.1小节提到的训练设置训练并验证单特征场景识别模型，结果如图3所示。分析混淆矩阵可以发现，不同的特征数据对不同场景的识别具有不同的敏感度。卫星几何位置分布的总体效果最好，而其余特征在特定类别的分类效果较好。如图4所示，一般来说，模型收敛速度与权重更新速度正相关，而权重更新程度主要由反馈的误差梯度大小决定，多普勒在所有观测值中变化最快，误差反馈梯度较大，因此单多普勒模型收敛速度最快；而载波相位通常由接收机连续跟踪输出，其标准差一般为几个毫米，在无周跳的条件下变化较慢，因此单载波相位模型收敛最慢。

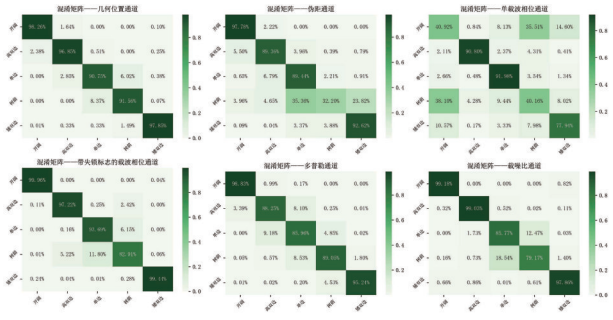


图3 不同特征输入场景识别的混淆矩阵

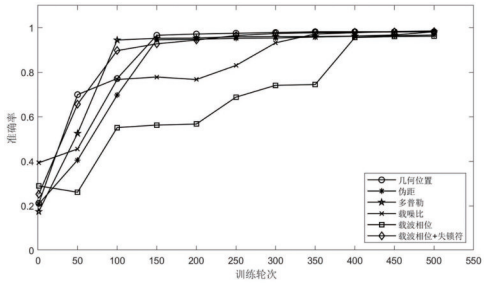



图4 不同特征通道间收敛速度比较

1.2.3 PC–LSTM网络设计

为了提高模型在所有场景下的识别精度和收敛速度，通过并联设计集成来自不同特征向量的信息，提出一种基于并联长短期记忆网络（PC–LSTM）的场景识别模型，如图5所示。该模型由通道层和融合分类层组成。不同的特征向量被输入到相应的LSTM通道中。

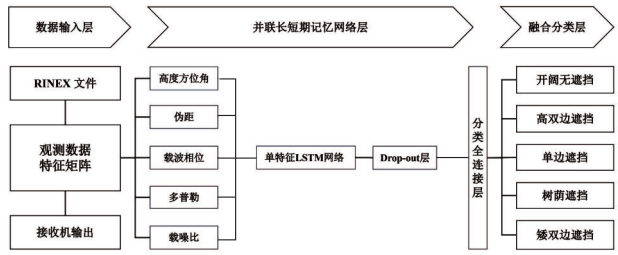



图5 基于PC–LSTM的GNSS定位场景识别模型

## 2 实验与结果分析

### 2.1 设备和数据集

本文实验数据由基于深圳华大导航HD8020系列芯片组的接收机采集。为尽可能模拟共享单车停车情景，在不改变自行车定位系统的结构（GNSS模块+天线）的前提下，直接通过串口将单车内置模块输出数据导入到计算机中。为了确保本文所提模型的泛化性，在每个时间段连续采集各个定位场景下持续10 min的GNSS观测数据，利用总计3个同样的时间段搭建了实验数据集。此外，本文使用交叉验证策略（70%用于训练，30%用于验证）。数据集分布如表2所示。

表2 数据集分布

| 场景 | 观测起始时间 | 持续时长/min |
|---|---|---|
| 空旷 | 10:34/12:11/13:54 | 10 |
| 高双边 | 10:46/12:29/14:15 | 10 |
| 单边 | 10:59/12:38/14:23 | 10 |
| 树荫 | 11:39/13:18/15:02 | 10 |
| 矮双边 | 11:52/13:35/15:15 | 10 |

### 2.2 实验结果

为评估模型的应用效果，本文使用CPU（Intel（R）Core（TM）Ultra 7155H 3.80 GHz）对模型进行训练。模型的训练过程与验证集上的表现如图6所示。模型在所有类别中的平均准确率达99.27%，且在每个单独类别的识别准确率至少为97.45%。从损失函数和准确率的变化中容易发现：仅经过少量训练轮次（大约70个），模型就已经达到了90%以上的识别准确率，这说明它在完成识别任务和控制训练消耗上都具有良好的表现。PC–LSTM可以在全部类别的场景识别中达到更高的准确率。除识别准确率外，模型收敛速度也通常是评故模型性能的重要指标，如图7所示，PC–LSTM的与单特征输入的LSTM相比，收敛速度具有明显优势。综上，PC–LSTM在实现对不同特征信息有效融合的基础上，模型收敛速度也显著提升。值得

注意的是，本文提出的模型设计策略避免直接使用现有成熟的神经网络，是当前相关研究中为数不多的专门针对GNSS定位场景设计的网络结构之一。

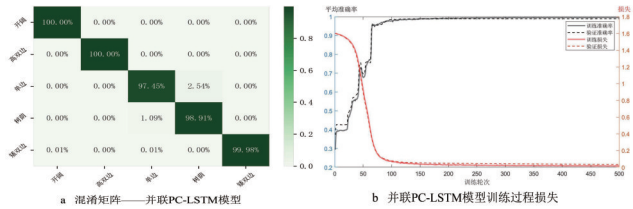



图6　PC-LSTM场景识别模型训练结果

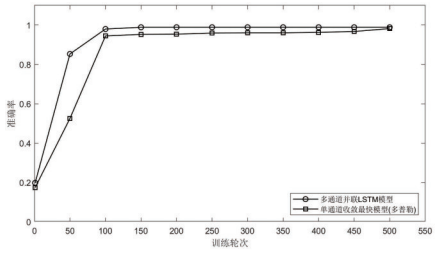



图7　PC-LSTM和单通道LSTM模型收敛速度比较

### 2.3　模型实时性分析

为验证模型在实际应用中的可行性，本节分析PC-LSTM的实时性能，包括模型训练和模型预测的时间消耗。从训练数据集中随机选择了3 000 s（共计2 950个时间序列样本）的数据来评估模型的实时性能。选取每轮次的训练时间（training time per epoch, TPE）和每样本预测时间（prediction time per data, PPD）。如表3所示，每轮次对2 950个序列训练的时间最长为0.68 s，一次完整预测仅需2.07 ms，且上述时间消耗可通过减少特征数量的方式进一步缩短。这表明PC-LSTM的实时性能优异，具有实际部署应用的潜力。

表3　模型的实时性分析

| 特征数量 | TPE/s | PPD/ms |
|---|---|---|
| 1 | 0.344 6 | 1.276 8 |
| 2 | 0.452 0 | 1.518 8 |
| 3 | 0.544 1 | 1.736 0 |
| 4 | 0.641 2 | 1.772 6 |
| 5 | 0.682 7 | 2.068 0 |

### 2.4　观测丢失情况下的算法鲁棒性分析

由于接收机观测通道数量的限制，场景识别模型的实际应用往往面临部分观测数据缺失的问题。因此，本文对PC-LSTM模型在数据缺失情况下的鲁棒性进行验证和评估。首先，卫星方位角和高度角的计算依赖接收机位置，而伪距观测值是计算接收机位置的最低要求。因此，研究将通道分为4组来测试模型的鲁棒性，即第①组：伪距、方位角和高度角，第②组：载波相位和失锁标识符，第③组：多普勒频率，第④组：载噪比。鲁棒性验证结果如表4所示，即使在1到2个观测特征缺失的情况下，模型识别准确率也可达到80%以上。值得注意的是，仅多普勒观测值和伪距观测值有效的①③组合的识别准确率明显低于其他观测故障缺失组合。

表4　模型特征缺失的鲁棒性分析

| 特征组合 | 识别准确率/% | PPD/ms |
|---|---|---|
| ①② | 94.12 | 1.736 0 |
| ①③ | 86.55 | 1.736 0 |
| ①④ | 97.97 | 1.736 0 |
| ①②③ | 94.01 | 1.772 6 |
| ①②④ | 98.87 | 1.772 6 |
| ①③④ | 97.40 | 1.772 6 |

## 3　结　语

本文提出一种基于并联长短期记忆网络（PC-LSTM）的GNSS场景识别方法。将GNSS接收机接收到的观测数据组织成5个不同维度的特征向量。分析不同特征向量的性能后，提出一种针对GNSS场景识别任务的PC-LSTM网络模型。实验结果表明，本研究提出的模型在所有场景中的平均准确率可达99.27%，在单个场景中至少可以达到97.45%。与此同时，该模型在CPU上的训练和预测的耗时仅为每轮次0.75 s，每样本2.07 ms，具备实际部署到实时应用的潜力。此外，本文所提模型在部分观测数据丢失的情况下也能保持较高识别精度，单特征丢失最高98.87%，双特征丢失最高97.97%，具备复杂观测环境和接收机跟踪故障等意外条件下的鲁棒性。

## 参考文献

[1] 吴涛，胡艳霞，田甜，等. GNSS干扰定位技术分析[J]. 全球定位系统，2023，48(5):103-111

[2] Xu P，Zhang G，Yang B，et al. Machine Learning in GNSS Multipath/NLOS Mitigation: Review and Benchmark[J]. IEEE Aerospace and Electronic Systems Magazine，2024，10(1):1-17

[3] 罗保林，金飞，罗亮. 自适应卡尔曼滤波在GNSS沉降监测中的应用[J]. 地理空间信息，2023，21(10):73-75

[4] 夏炎. 面向室内外卫星定位的多径检测与抑制技术研究[D]. 南京:东南大学，2021

[5] Yang H，Zhou B，Wang L，et al. Performance and Evaluation of GNSS Receiver Vector Tracking Loop Based on Adaptive Cascade Filter[J]. Remote Sensing，2021，13(7):

（下转第127页）