车路协同背景下基于RSSI的位置感知与出行模式甄别方法研究

答辩人：黄紫林

导师： 许伦辉教授

2021/06/06

原创声明

本人郑重声明：所呈交的论文是本人在导师的指导下独立进行研究所取得的研究成果。除了文中特别加以标注引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写的成果作品。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本人完全意识到本声明的法律后果由本人承担。

作者签名：黄紫林

盲审意见

专家一	专家意见	整改措施
优秀 (90分)	1. 前言建议直接给出用 WIFI 和 Bluetooth 信号强度的原因	✓ 已对第一章引言部分进行了增删修改
	2. 应用 RSSI 进行相关研究必须对采样率进行研究	✓ 已增加实测数据，见2.4.3小节
	3. 所有英文缩写首次出现时应给出对应中文和英文全称	✓ 已对全文进行修改
	4. 定义论文中指出的小范围、大范围到底是多少	✓ 已增加定义，见1.4小节
	5. 第二章应对中速和较高车速也进行验证	✓ 已增加实验分析，见2.4.2小节
	6. P52，为什么样本量会是 5000 呢	✓ 已进行补充说明，见第52页
	7. 请论证进行滤波降低波动性的合理性	✓ 已增加论证滤波合理性，见3.4.1小节与3.5.2小节
	8. 识别的精度仍需说明	✓ 已补充不足之处，见6.3小节

专家二	专家意见	整改措施
优秀 (87分)	1. 缺乏技术在交通系统中具体应用的方式和方案	✓ 已增加具体应用场景分析，见6.2小节
	2. 本文的技术与室外定位技术的差异性和互补性需要分析	✓ 已增加了详细描述，见1.1小节和1.3小节
	3. RSSI 在这类出行模式的局限性如何，需要进行分析	✓ 已补充不足之处，见6.3小节
	4. RSSI 技术的弱点，本文需要讨论解决方案或者应用局限	✓ 已补充不足之处，见6.3小节
	5. 论文对国内文献关注较少，需要适当补充和梳理	✓ 已适当增加国内相关文献



目录

1 绪论

2 基于半监督学习的小范围目标RSSI指纹定位方法

3 基于分段拟合的大范围目标RSSI快速定位方法

4 基于GRNN的大范围目标RSSI鲁棒定位方法

5 基于单点检测数据的出行模式甄别方法

6 总结与展望

绪论-研究背景及意义

- **中国科协发布2020年20个重大科学问题和工程技术难题**

  数字交通基础设施如何推动自动驾驶与车路协同发展？

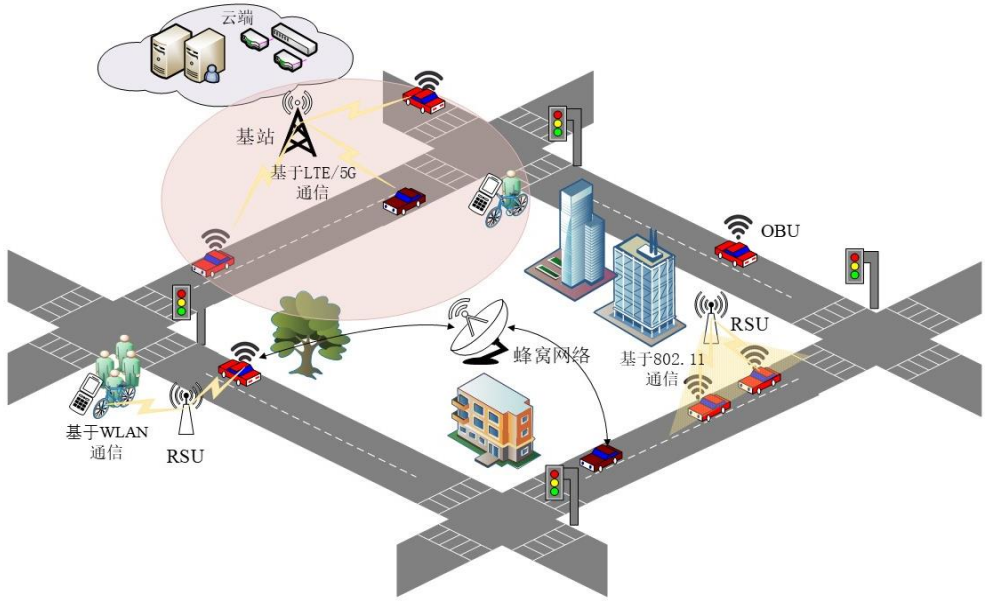


图1 车路协同系统
（Cooperative Vehicle Infrastructure System）



图2 智慧公路与自动驾驶.
悉尼科技大学, *IEEE Fellow*, 毛国强教授

行业关键技术难题：多交通目标低成本、高实时、高精准的全息感知！

绪论-研究背景及意义

➢ 新ITS的基础——全息数据

□ 传统交通检测器

- **侵入式检测器**（环形感应线圈、压电传感器、磁阻等）
- **悬挂式检测器**（视频摄像头、微波雷达等）

□ 弊端不足

- 安装和维护**费用较为昂贵**，严重干扰正常运营
- 非量身定做，**性能较难满足车路协同标准要求**

□ 解决措施

- 车辆协同系统中**广泛布设的泛在信号**
- 低成本、高精度的**无线传感网络技术**

图3 传统交通检测器

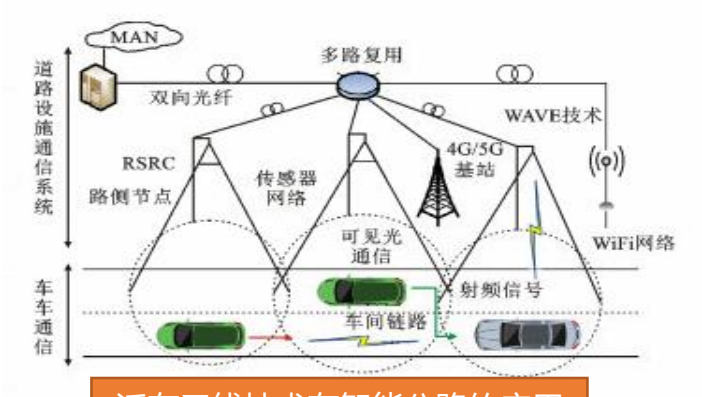


表1 各类交通检测器对比一览表

检测手段		优缺点
GPS		定位精度高，**需用户主动配合、盲区范围大(地铁、隧道、高楼等)**
蜂窝网络		只要有信号的地区都可进行监测，**但定位精度低**
雷达、地磁		**无个体标识性信息**、数据内容少、破路建设难、数据质量控制难
计算机视觉		获取信息多，部署成本高(**800像素约3万**)，性能易受天气、光线影响
通讯波	蓝牙/WiFi	信号较稳定，具备个人标识，但定位精度有待提高
	DSRC	实时性强，但不具备个人标识

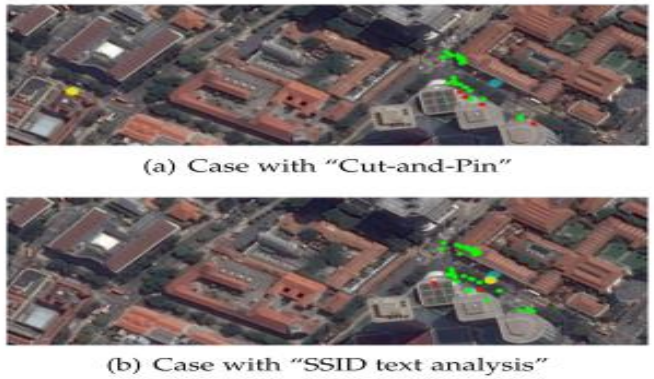
绪论-国内研究现状及分析

➢ 将无线传感定位技术应用于车联网领域是当前一大热门方向



泛在无线技术在智能公路的应用

智能公路发展现状与关键技术, 中国公路学报. 长安大学, 赵祥模、徐志刚教授课题组

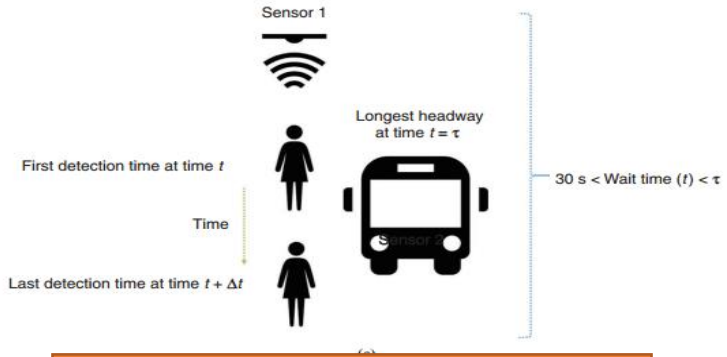


(a) Case with "Cut-and-Pin"

(b) Case with "SSID text analysis"

基于WiFi检测的热点区域及轨迹识别

Wang, J ., et.al. Learning-based outdoor localization exploiting crowd-labeled WiFi hotspots. IEEE Transactions on Mobile Computing, 18(4), 896-909.



基于WiFi检测的公交站等待时间、密度

Kurkcu, A., & Ozbay, K. (2017). Estimating pedestrian densities, wait times, and flows with wi-fi and bluetooth sensors. Transportation Research Record, 2644(1), 72-82.



基于WiFi检测的公交上下车人数识别技术

Hidayat, A., et.al. WiFi scanner technologies for obtaining travel data about circulator bus passengers: case study in Obuse, Nagano prefecture, Japan. Transportation Research Record, 2672(45), 45-54.



基于WiFi检测的人车避障技术

P. Ho and J. Chen, "WiSafe: Wi-Fi Pedestrian Collision Avoidance System," in IEEE Transactions on Vehicular Technology, vol. 66, no. 6, pp. 4564-4578.



基于WiFi-蓝牙检测的行人计数、模式分类技术

Lesani, A., et.al. Development and testing of a real-time wifi-bluetooth system for pedestrian network monitoring, classification, and data extrapolation. IEEE Transactions on Intelligent Transportation Systems.

绪论-国内研究现状及分析

➢ （1）基础问题：如何设计适用于城市复杂道路环境的噪声实时处理方法？

RSSI信号易受周围环境影响，如**信号衰减、多路径效应**等。即使在同一位置，也会有较大的信号波动。

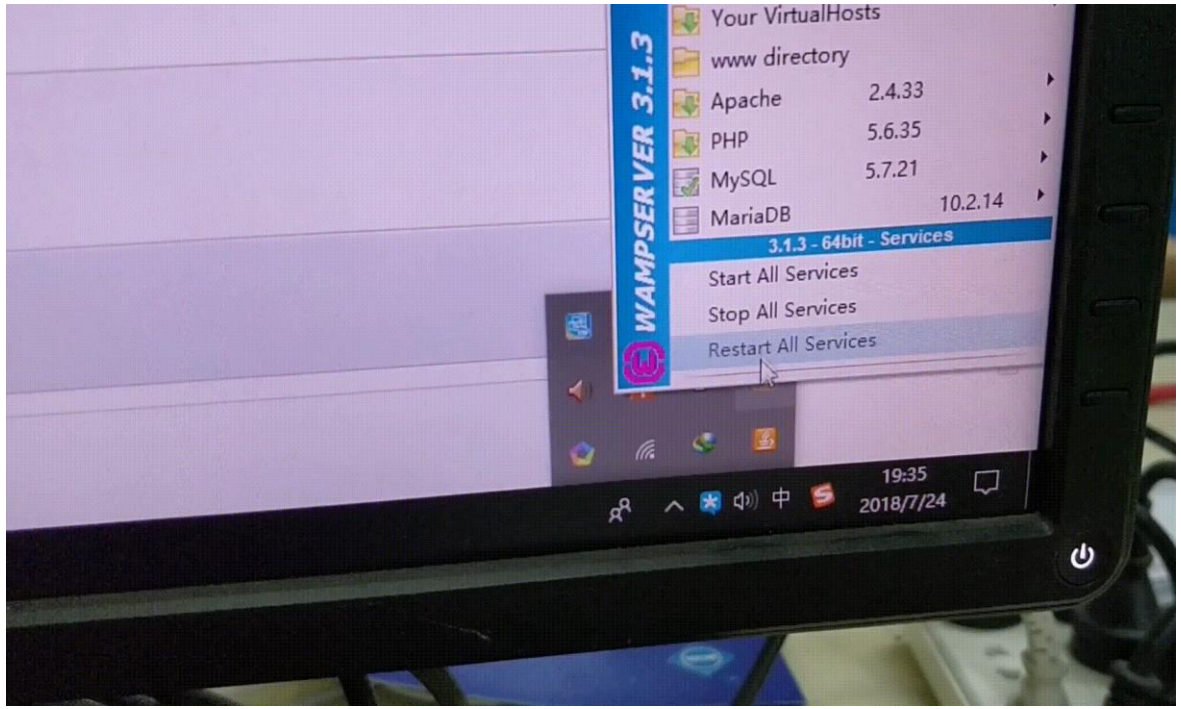


图4 信号采集基本流程

同一位置仍存在噪声

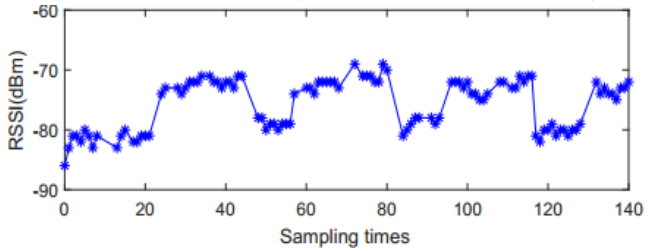


图5 同一距离RSSI跳动

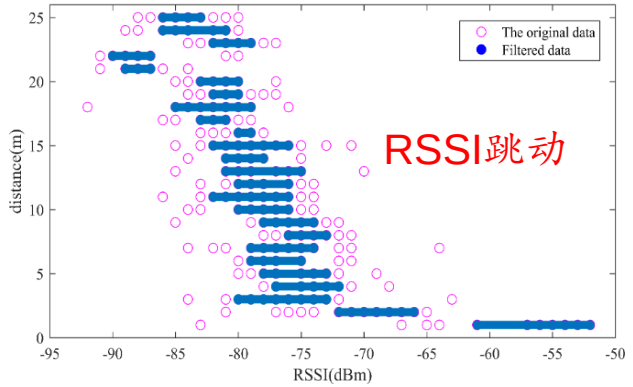


图6 不同距离RSSI跳动

相比于室内环境，**城市道路环境更为错综复杂（天气、建筑遮挡、温度等）**，传统的室内滤波算法不能直接应用于城市道路环境。此外，用户的坐标是**动态的、不可预测的**，这就需要滤波算法适应频谱随时间变化。

绪论-国内研究现状及分析

➢ （2）核心问题：如何设计适用于广域复杂环境下的**多目标、高精度定位方法？**

应用场景：**盲区** (十字路口、高架桥底、隧道等)、**室内**(地铁站、商场、停车场、多层楼宇等)、**户外**(广场等)。

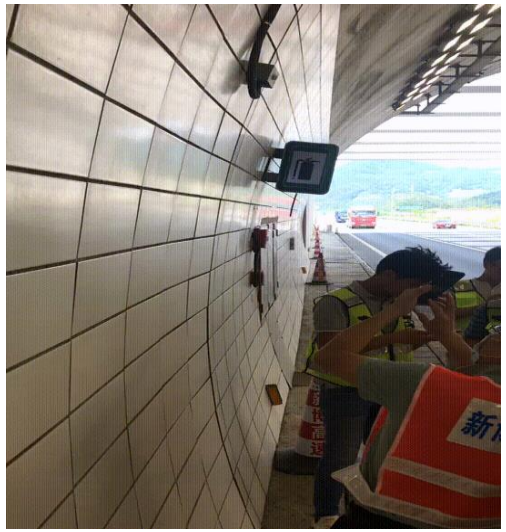


图7 隧道等GPS信号盲区应用场景

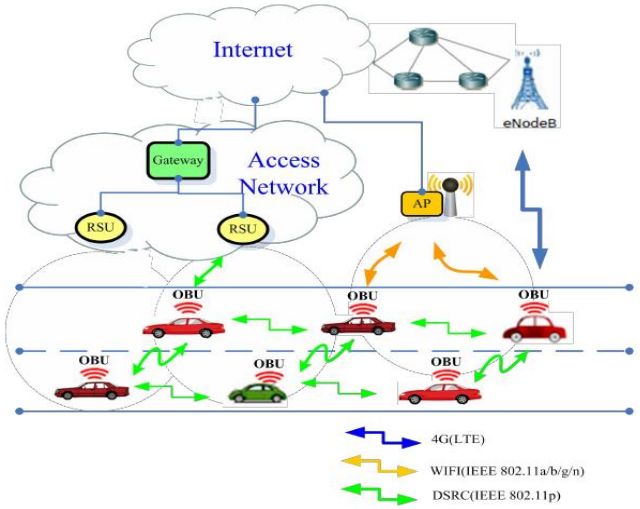


图8 智能车路协同无线通信网络结构图
清华大学, 胡坚明老师课题组

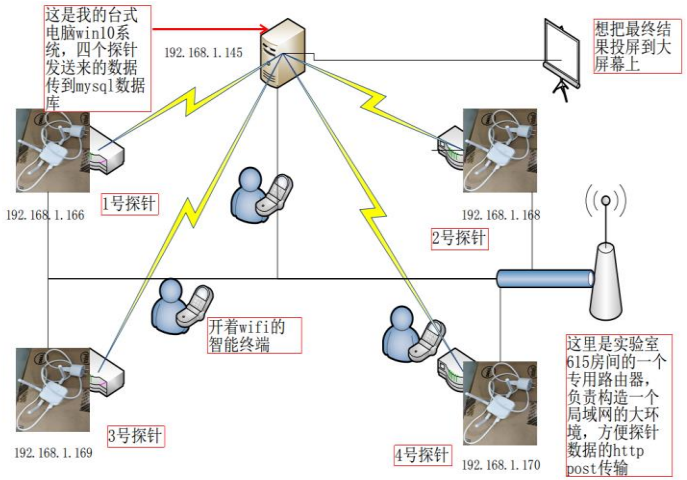


图9 基于RSSI定位的基本框架图

传统的RSSI信号传播模型难以在城市道路环境中获得准确的距离；**常用的指纹定位模型**需要耗费大量的时间进行离线训练，无法在城市道路环境中广泛应用。

绪论-国内研究现状及分析

➢ （3）关键问题：如何设计基于时空采样信息的交通出行方式智能分类方法？

基于位置感知数据的甄别技术可依据数据源划分为两类：以**用户**为中心的方法；以**网络**为中心的方法。

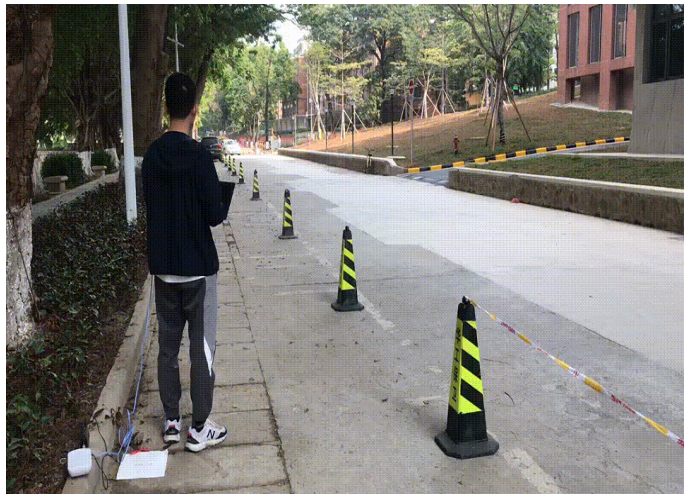


图10 基于路侧单元的无线信号通讯检测试验
华南理工大学，五山校区



图11 基于RSSI位置感知基本实验设备

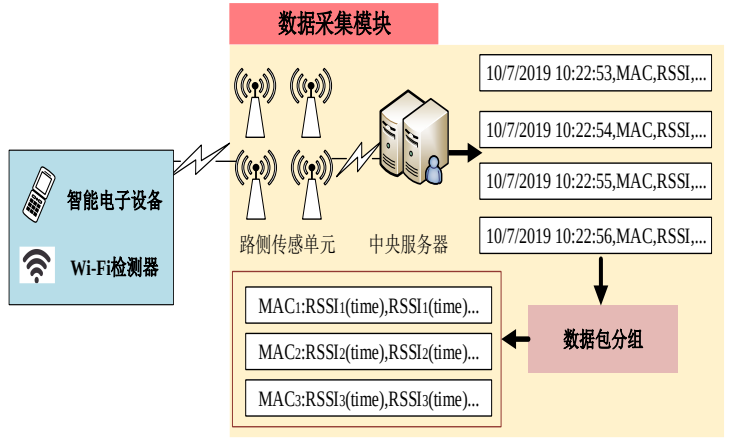


图12 基于RSSI位置感知数据采集架构图

RSSI信号移动点序列**并不能直接表达个体**的交通出行模式、出行目的等人们可以理解的语义信息；

此外，基于多检测器协同定位方案的部署成本仍较高，如何**基于单检测器数据**构建模式甄别系统意义重大。

绪论-研究框架

➢ 具体研究内容

第一章：问题提炼及目标解析

- 常用无线位置感知手段、无线传感定位基本方法和出行模式甄别技术

第二章：面向小范围目标精准定位需求

- 探究如何在降低对训练样本依赖的同时实现较高的定位精度

第三章：面向大范围目标定位快速需求

- 探究如何在保持多项式拟合快速性的同时实现较高的定位精度

第四章：面向大范围目标定位稳定需求

- 探究如何在适当提高计算复杂度情况下实现广域场景鲁棒定位

第五章：面向低成本出行模式甄别需求

- 探究如何仅用检测器数据源情况下实现出行模式的细粒度甄别

第六章：总结及展望

- 总结全文，应用前景，研究展望

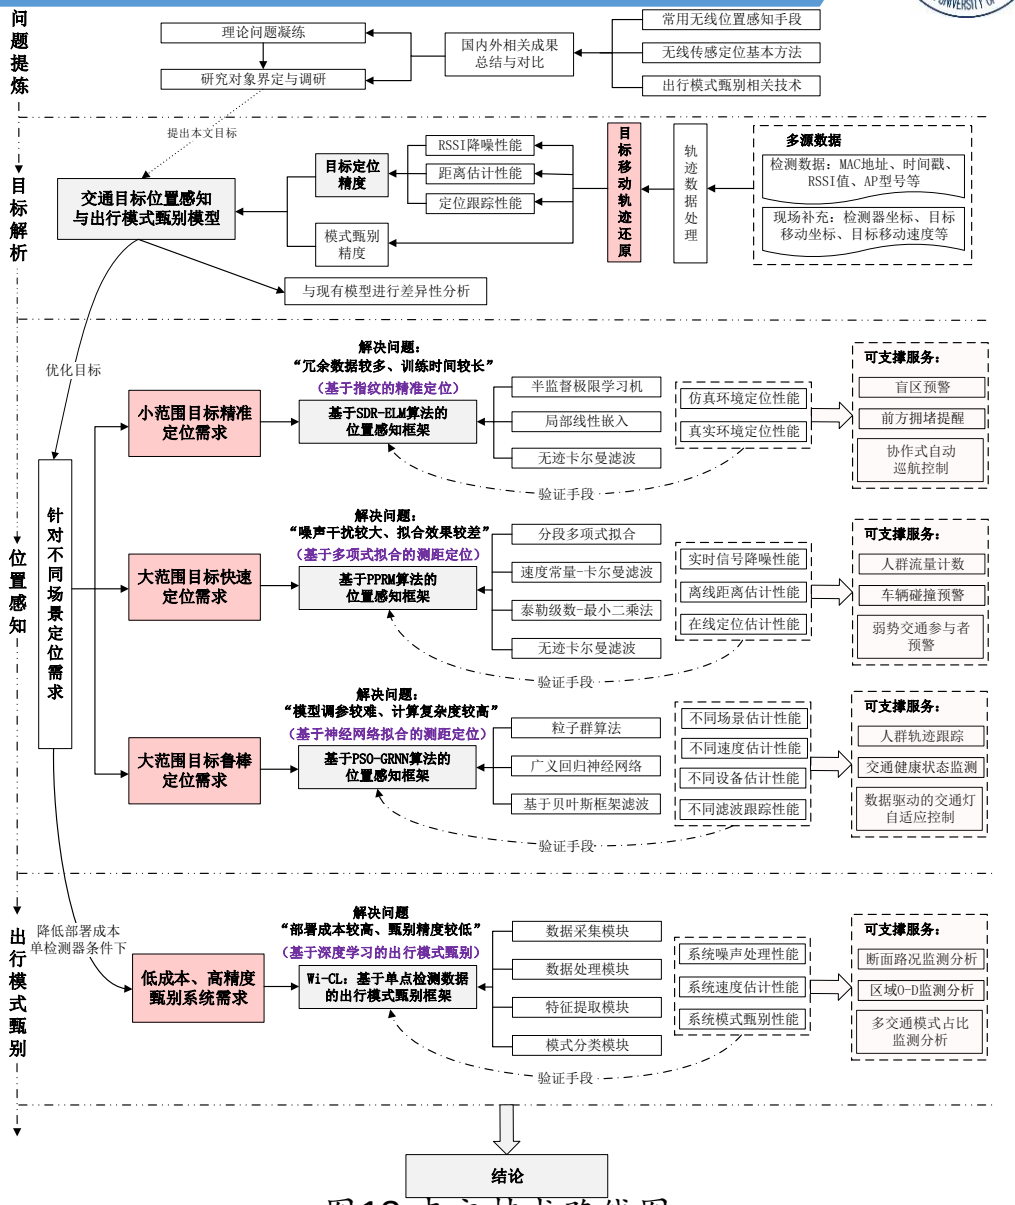


图13 本文技术路线图

➢ 问题描述

针对小范围场景精准定位需求，基于指纹的定位是一种更为合适的技术方案。然而，传统指纹定位方法存在“**冗余数据较多、训练时间较长**”的问题。

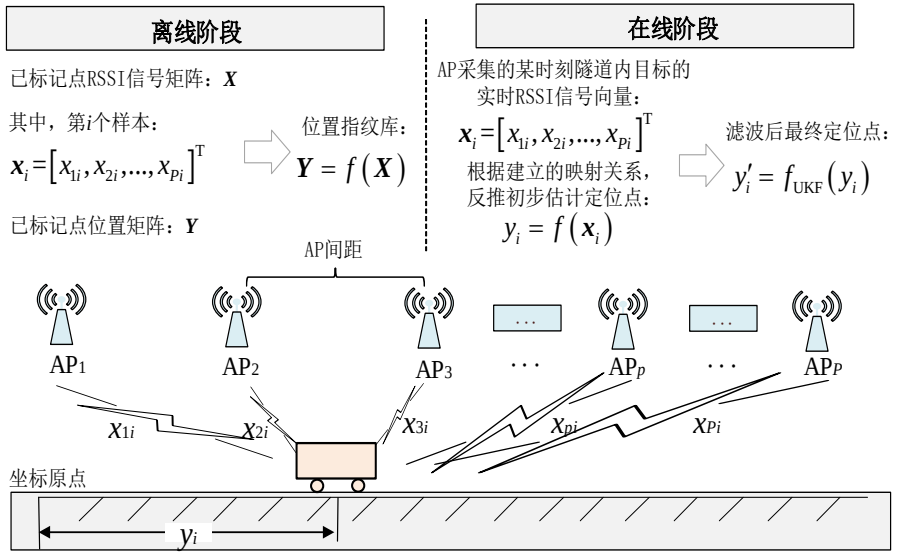


图14 传统指纹定位方法示意图

小范围场景信号传播特点

- **RSSI波动相对较小**
- **衰减因子变化相对较小**

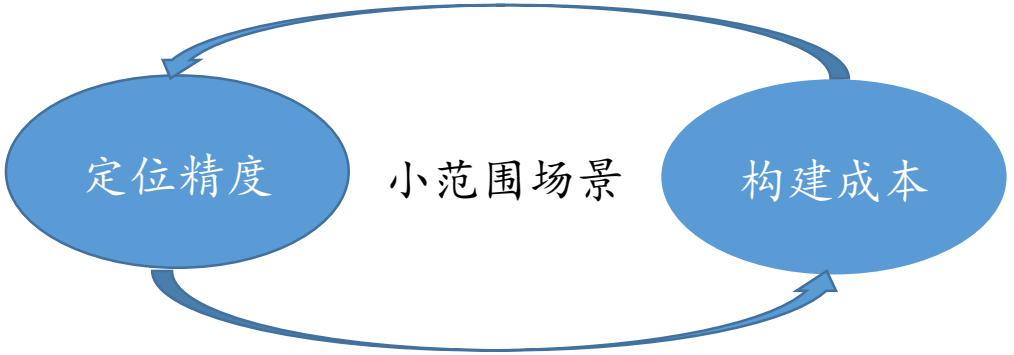
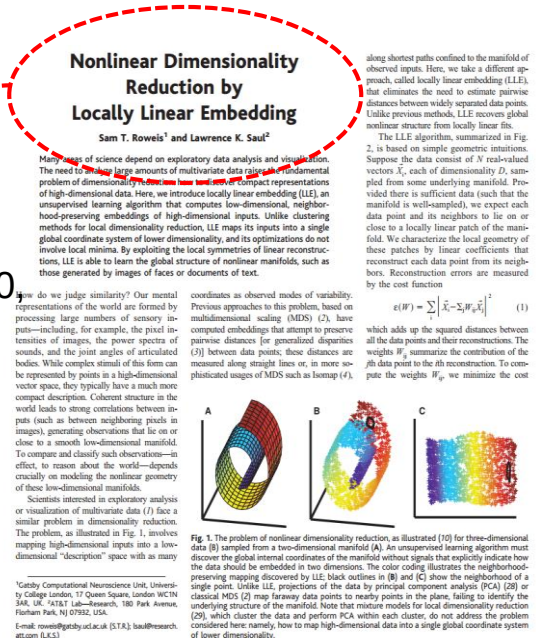


图15 本章所研究的基本问题

➢ 本文所提：基于SDR-ELM算法的位置感知框架

2014年，Huang等人提出SEELM模型，相比于监督学习，其训练速度快、泛化能力强。然而，在智慧公路场景中，部分特征对于定位**可能没有作用甚至影响定位性能**、且**无法消除高阶RSSI信号相关性及冗余信息**。

Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. ***Science***, 2000, 290(5500): 2323–2326



Nonlinear Dimensionality Reduction by Locally Linear Embedding

Sam T. Roweis[1] and Lawrence K. Saul[2]

Many areas of science depend on exploratory data analysis and visualization. The need to analyze large amounts of multivariate data raises the fundamental problem of dimensionality reduction: how can we discover compact representations of high-dimensional data. Here, we introduce locally linear embedding (LLE), an unsupervised learning algorithm that computes low-dimensional, neighborhood-preserving embeddings of high-dimensional inputs. Unlike clustering methods for local dimensionality reduction, LLE maps its inputs into a single global coordinate system of lower dimensionality, and its optimizations do not involve local minima. By exploiting the local symmetries of linear reconstructions, LLE is able to learn the global structure of nonlinear manifolds, such as those generated by images of faces or documents of text.

How do we judge similarity? Our mental representations of the world are formed by processing large numbers of sensory inputs—including, for example, the pixel intensities of images, the power spectra of sounds, and the joint angles of articulated bodies. While complex stimuli of this form can be represented by points in a high-dimensional vector space, they typically have a much more compact description. Coherent structure in the world leads to strong correlations between inputs (such as between neighboring pixels in images), generating observations that lie on or close to a smooth low-dimensional manifold. To compare and classify such observations—in effect, to reason about the world—depends crucially on modeling the nonlinear geometry of these low-dimensional manifolds.

Scientists interested in exploratory analysis or visualization of multivariate data (1) face a similar problem in dimensionality reduction. The problem, as illustrated in Fig. 1, involves mapping high-dimensional inputs into a low-dimensional "description" space with as many coordinates as observed modes of variability. Previous approaches to this problem, based on multidimensional scaling (MDS) (2), have computed embeddings that attempt to preserve pairwise distances [or generalized disparities (3)] between data points; these distances are measured along straight lines or, in more sophisticated usages of MDS such as Isomap (4), along shortest paths confined to the manifold of observed inputs. Here, we take a different approach, called locally linear embedding (LLE), that eliminates the need to estimate pairwise distances between widely separated data points. Unlike previous methods, LLE recovers global nonlinear structure from locally linear fits.

The LLE algorithm, summarized in Fig. 2, is based on simple geometric intuitions. Suppose the data consist of N real-valued vectors $\vec{X}_i$, each of dimensionality D, sampled from some underlying manifold. Provided there is sufficient data (such that the manifold is well-sampled), we expect each data point and its neighbors to lie on or close to a locally linear patch of the manifold. We characterize the local geometry of these patches by linear coefficients that reconstruct each data point from its neighbors. Reconstruction errors are measured by the cost function

$$\varepsilon(W) = \sum_i \left| \vec{X}_i - \sum_j W_{ij} \vec{X}_j \right|^2 \quad (1)$$

which adds up the squared distances between all the data points and their reconstructions. The weights W_{ij} summarize the contribution of the jth data point to the ith reconstruction. To compute the weights W_{ij}, we minimize the cost

Fig. 1. The problem of nonlinear dimensionality reduction, as illustrated (10) for three-dimensional data (B) sampled from a two-dimensional manifold (A). An unsupervised learning algorithm must discover the global internal coordinates of the manifold without signals that explicitly indicate how the data should be embedded in two dimensions. The color coding illustrates the neighborhood-preserving mapping discovered by LLE; black outlines in (B) and (C) show the neighborhood of a single point. Unlike LLE, projections of the data by principal component analysis (PCA) (28) or classical MDS (2) map faraway data points to nearby points in the plane, failing to identify the underlying structure of the manifold. Note that mixture models for local dimensionality reduction (29), which cluster the data and perform PCA within each cluster, do not address the problem considered here: namely, how to map high-dimensional data into a single global coordinate system of lower dimensionality.

[1]Gatsby Computational Neuroscience Unit, University College London, 17 Queen Square, London WC1N 3AR, UK. [2]AT&T Lab—Research, 180 Park Avenue, Florham Park, NJ 07932, USA.

E-mail: roweis@gatsby.ucl.ac.uk (S.T.R.); lsaul@research.att.com (L.K.S.)

图16 LLE流形降维模型

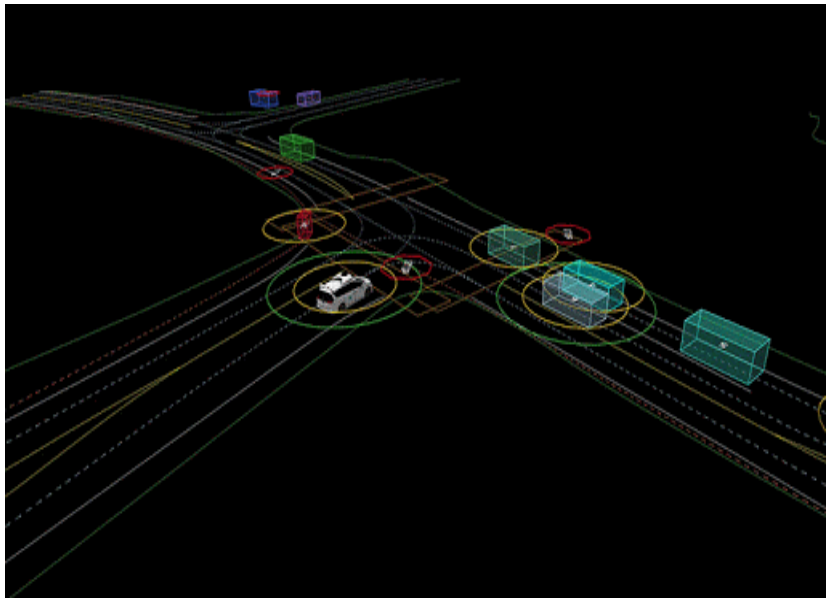


图17 道路环境车辆行驶特性

本文将Roweis等在《Science》上提出的**局部线性嵌入方法（LLE）**扩展到SSELM模型中，结合**道路环境中车辆行驶特性**，提出了一种**基于流形降维的半监督极限学习机定位方法（SDR-ELM）**。

➢ 本文所提：基于SDR-ELM算法的位置感知框架

LLE流形降维特征提取—无标签数据标定—基于SSELM模型建立映射—初步位置估计—无迹卡尔曼滤波。

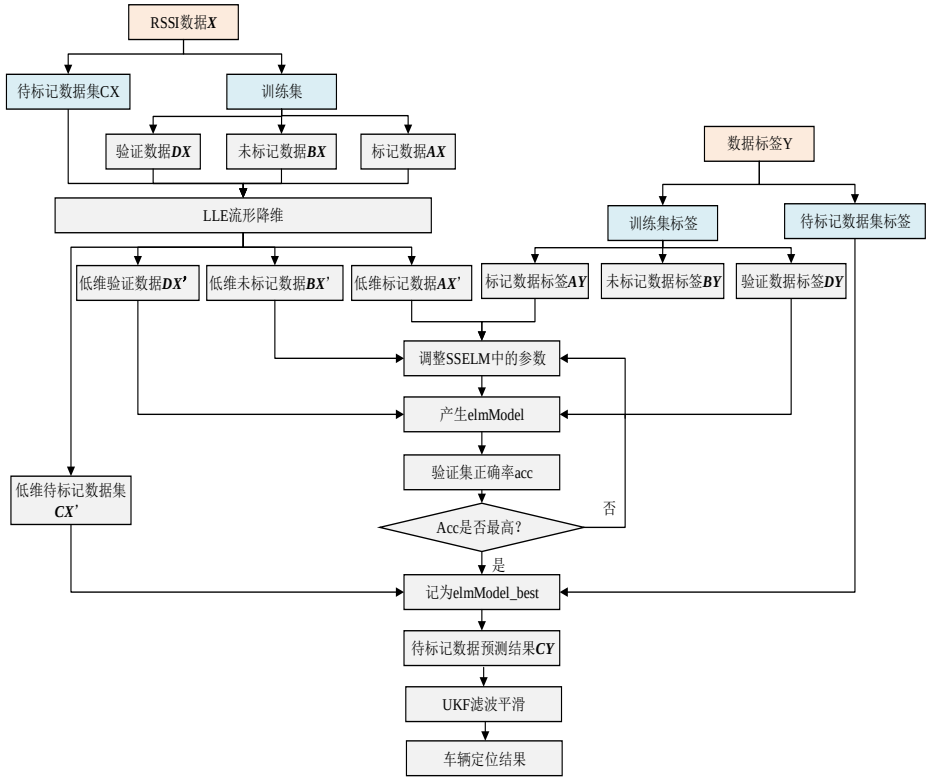


图18 带有流形降维的半监督极限学习机定位算法流程

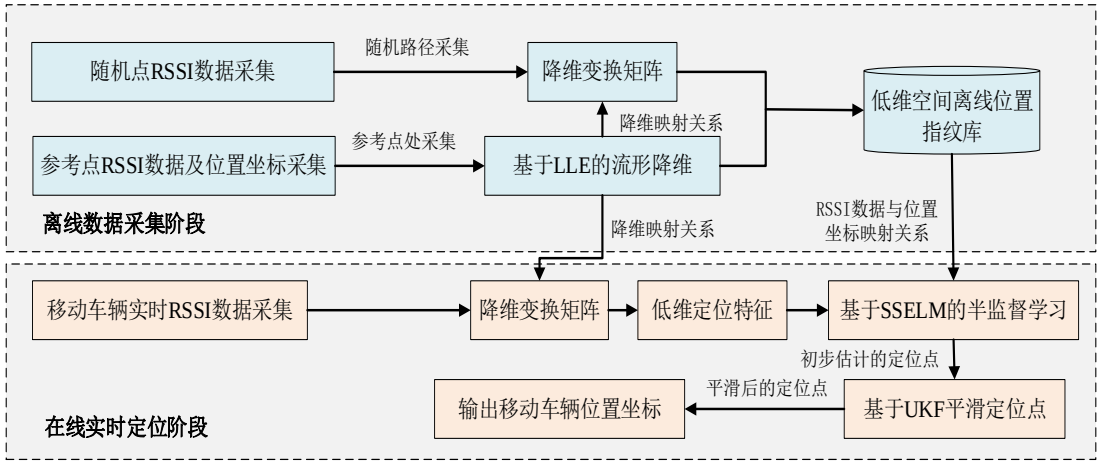


图19基于SDR-ELM算法的车辆定位流程

与其他指纹定位方法类似，本文提出的定位方法也包含**离线数据采集训练**和**在线实时定位**两个阶段。

第二章-小范围目标RSSI指纹定位方法

➢ 实验与结果分析

□ 仿真环境定位性能分析

- **定位准确度分析**

表2 四类定位算法的性能对比

指标 \ 方法		KNN	SSELM	PCA-SSELM	本文方法
18km/h	平均定位误差	4.74	5.73	4.02	3.09
	最大误差	11.10	14.80	14.00	10.11
	最小误差	1.80	1.00	0.10	0.25
	误差中值	2.39	3.67	3.51	2.26
36km/h	平均定位误差	5.14	5.60	4.84	3.38
	最大误差	14.27	13.76	12.00	11.80
	最小误差	1.04	2.06	1.00	0.19
	误差中值	3.38	3.22	3.10	2.82
54km/h	平均定位误差	5.42	5.62	4.64	4.06
	最大误差	11.10	12.00	15.00	14.00
	最小误差	1.80	1.80	1.00	0.34
	误差中值	3.67	2.81	3.80	2.39
90km/h	平均定位误差	5.31	7.02	5.11	4.88
	最大误差	11.00	16.12	15.00	14.00
	最小误差	1.80	1.80	1.00	1.80
	误差中值	3.44	4.10	4.98	3.22

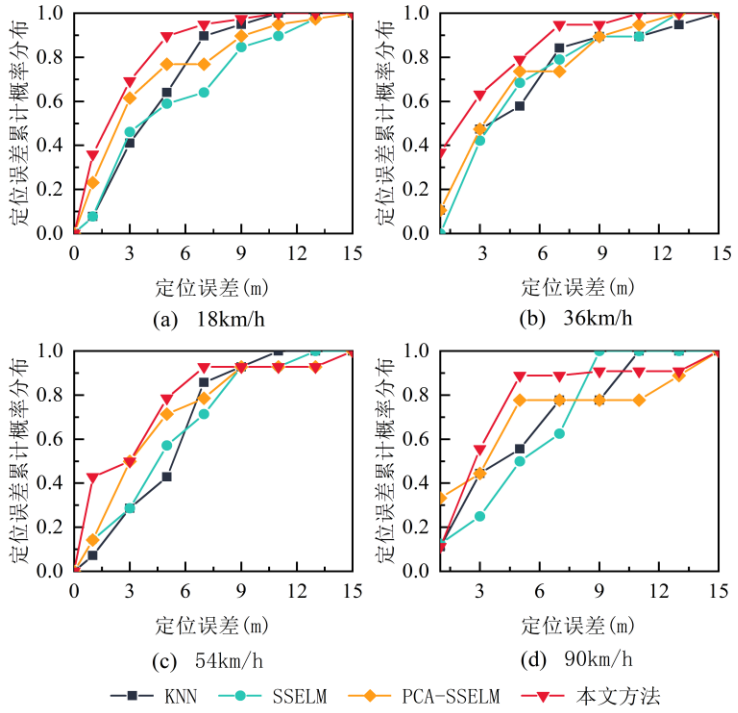


图20 四种场景下不同算法的定位误差累积概率分布

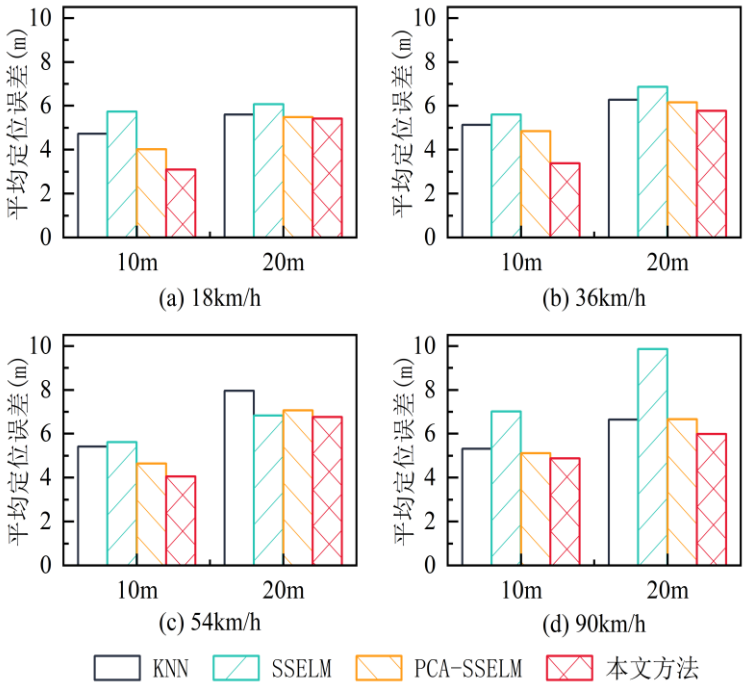


图21 AP间距对四类方法定位误差的影响

■ **实验结论：**

1. 在**四种不同车辆速度**的环境中，本文方法均能最快达到90%分位数；
2. 无论是稀疏还是密集部署AP环境，本文方法**均具有更优的定位精度。**

➢ 实验与结果分析

□ 仿真环境定位性能分析

- **定位鲁棒性分析**

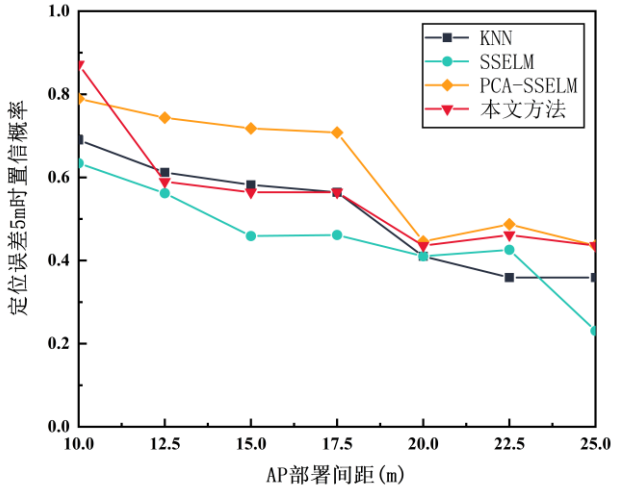


图22 AP间距对与模型定位精度的影响

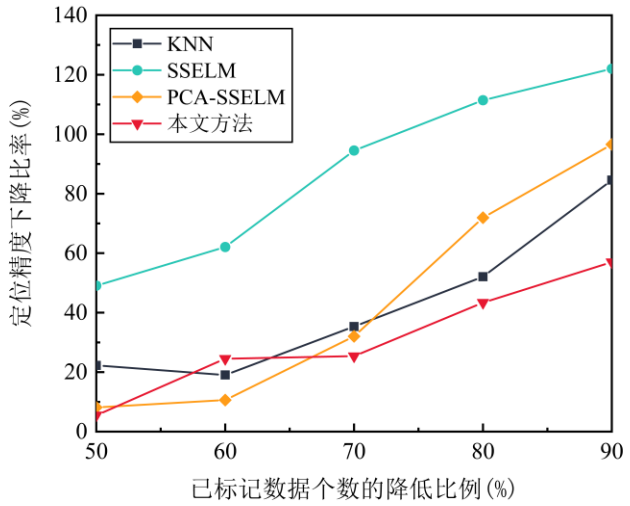


图23 标记数据样本占比对模型定位精度的影响

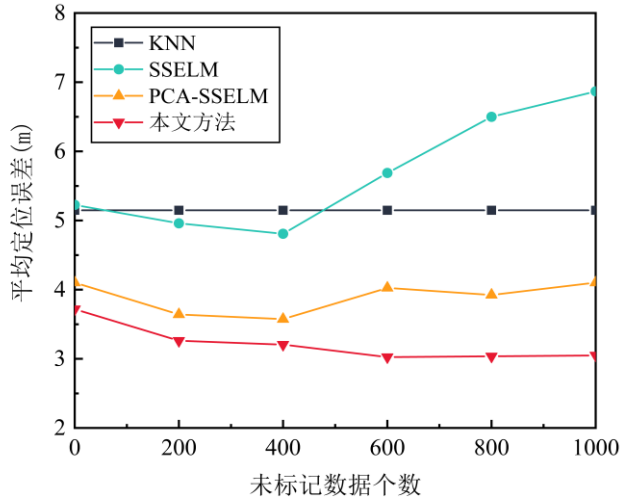


图24 未标记数据样本数对与模型定位精度的影响

■ **实验结论：**

1. 本文方法**能显著减少对参考点标记数量的依赖性**，具有较好的鲁棒性；
2. 本文方法在大量无标记数据集的训练过程中，仍能**保持较好的稳定性；**
3. **AP部署间距选择17.5m**，是综合考虑定位精度和部署成本后的可行方案。

➢ 实验与结果分析

□ 仿真环境定位性能分析

- **算法复杂度及参数敏感性分析**

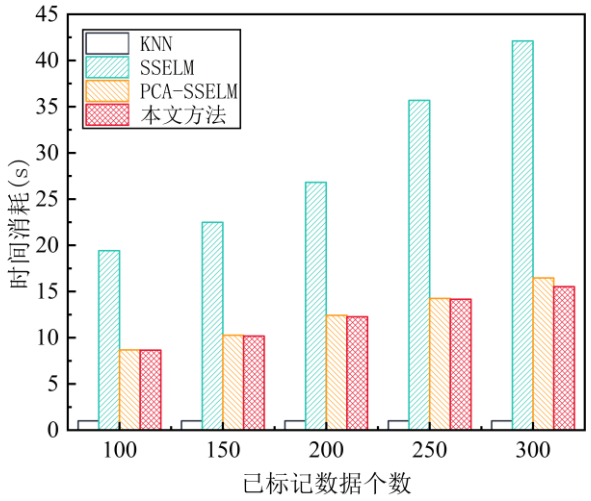


图25 四类定位算法的训练时间

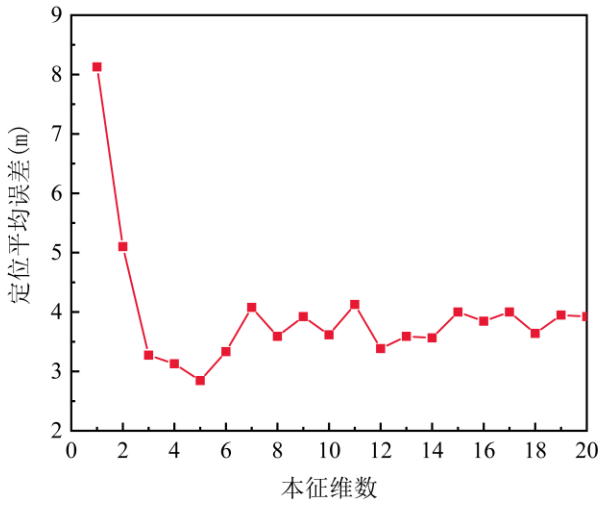


图26 本征维数对定位误差的影响

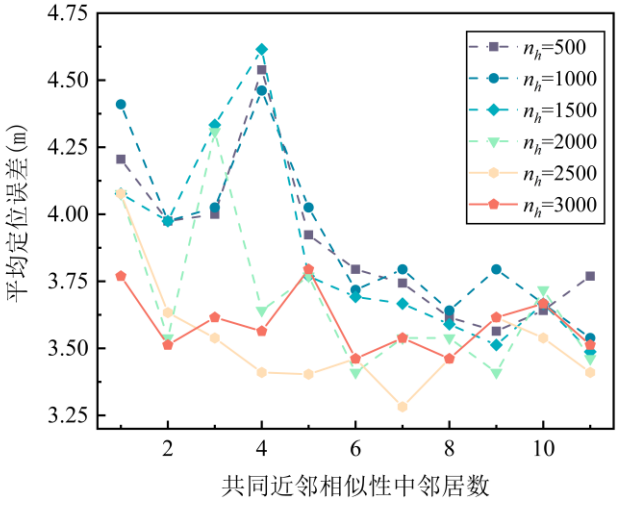


图27 其他参数对定位误差的影响

■ **实验结论：**

1. 本文方法低于传统SSELM，但高于KNN，**适当的复杂度增加是可接受的；**
2. 当*d*值由1增加为2时，定位性能得到较大提高，因此**建议本征维数d值取5；**
3. **当设置为*nh*=2500且*N*=7时，能在计算成本和定位精度上取得较好的平衡。**

➢ 实验与结果分析

□ 真实环境定位性能分析

本人于2020年1月7日在广州市湖滨南路进行了 “**车联网环境下RSSI连通性实验**”，证明AP具较高可用性。进一步地，于2020年5月16日夜间在广州市一般道路五山路道路内进行了**现场实测**。

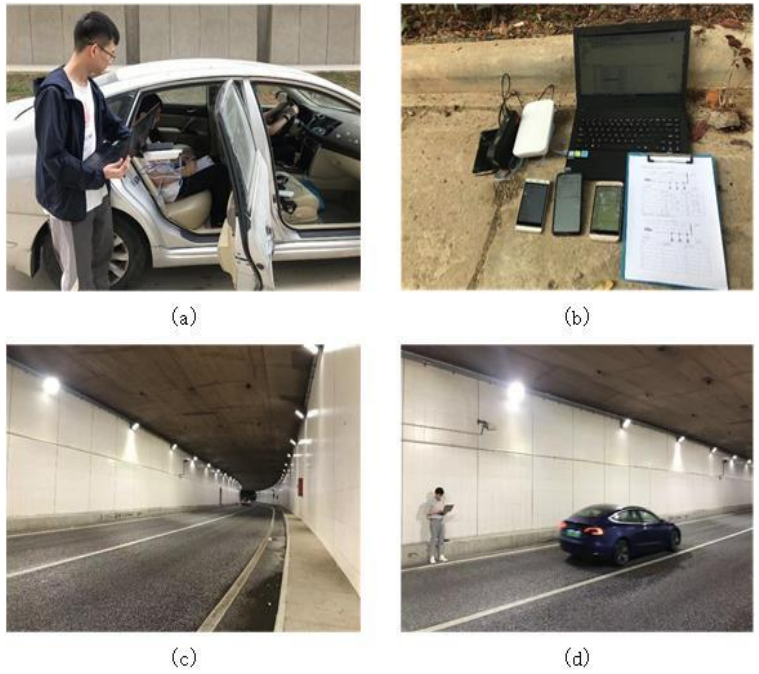


图28 RSSI连通性实验

表3 四类方法对真实道路内静止车辆的定位误差对比

方法 / 测试点	KNN	SSELM	PCA-SSELM	本文方法
1	13.01	11.10	4.05	5.79
2	12.11	7.01	15.20	13.87
3	6.18	17.00	11.48	11.10
4	3.64	8.02	5.04	4.09
5	7.02	8.03	6.10	5.24
6	10.31	11.51	10.03	8.15
平均定位误差	8.70	10.45	8.65	8.04

■ **实验结论：**

1. **定位误差普遍偏大**，可能是随机噪声干扰更复杂和本征维数偏小导致；
2. 无论仿真环境或真实道路环境，**本文方法均能取得更高的定位性能**。

➢ 问题描述

针对大范围场景快速定位需求，基于曲线拟合的测距定位是一种更为合适的技术方案。然而，传统对数正态阴影模型存在“**噪声干扰较大、拟合效果较差**”的问题。

同一类型大范围场景信号传播特点

- **衰减因子变化相对较小**
- **但不同距离下拟合规律差别较大**

● **对数距离路径损耗模型（Propagation Model）**

$$PL(d) = PL_{d_0} - 10\gamma \log(d/d_0) + N(0,\sigma^2)$$

- 在拥挤的城市道路环境中，由于摩天大楼、隧道、车辆、混凝土墙等建筑材料的信号反射、阴影和多路径过渡，**无法获得准确的距离。**

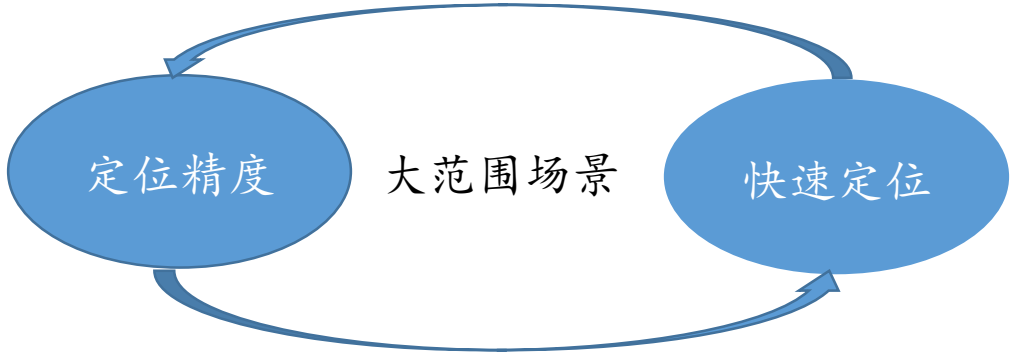


图29 本章所研究的基本问题

黄紫林, Lunhui Xu, and Yongjie Lin*. “Multi-stage pedestrian positioning using filtered WiFi scanner data in an urban road environment.” ***Sensors.*** 20.11 (2020): 3259.

➢ 本文所提：基于PPRM算法的位置感知框架

近年来，国内外研究学者们相继提出了改进方法。

1. 回归神经网络(GRNN)
   - *Jondhale, S.R., et.al. Kalman Filtering Framework-Based Real Time Target Tracking in Wireless Sensor Networks Using Generalized Regression Neural Networks. IEEE Sens. J. 2019, 19, 224–233.*
2. **多项式回归（PRM）**
   - *Zhuang, Y., et.al. Smartphone-based indoor localization with bluetooth low energy beacons. Sensors 2016, 16, 596.*
3. 曲线拟合（CF）
   - *Wang, B., et.al. Indoor localization based on curve fitting and location search using received signal strength. IEEE Trans. Ind. Electron. 2015, 62, 572–582.*
4. 分割拟合（SF）
   - *Jianyong, Z., et.al. RSSI based Bluetooth low energy indoor positioning. In Proceedings of the 2014 IPIN, Busan, Korea, 27–30 October 2014; pp. 526–533.*

实时性强！

定位精度高！

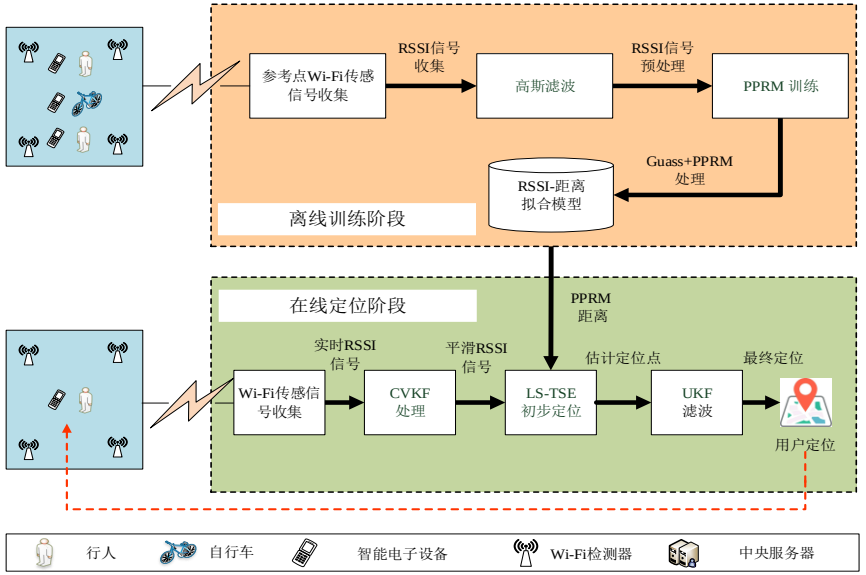


图30 基于PPRM算法的位置感知框架

本文提出一种**基于PPRM算法的位置感知框架**，由分段多项式拟合、速度常量-卡尔曼滤波、泰勒级数展开最小二乘法和无迹卡尔曼滤波组成。

第三章-大范围目标RSSI快速定位方法

➢ 本文所提：基于PPRM算法的位置感知框架

离线训练阶段

$$\hat{d} = \Phi(s) = \sum_{k=1}^{K}\left[\lambda(\sum_{i=0}^{n} a_i \bullet s_j^i)\right]_k, \ i < n \text{ and } k < K$$

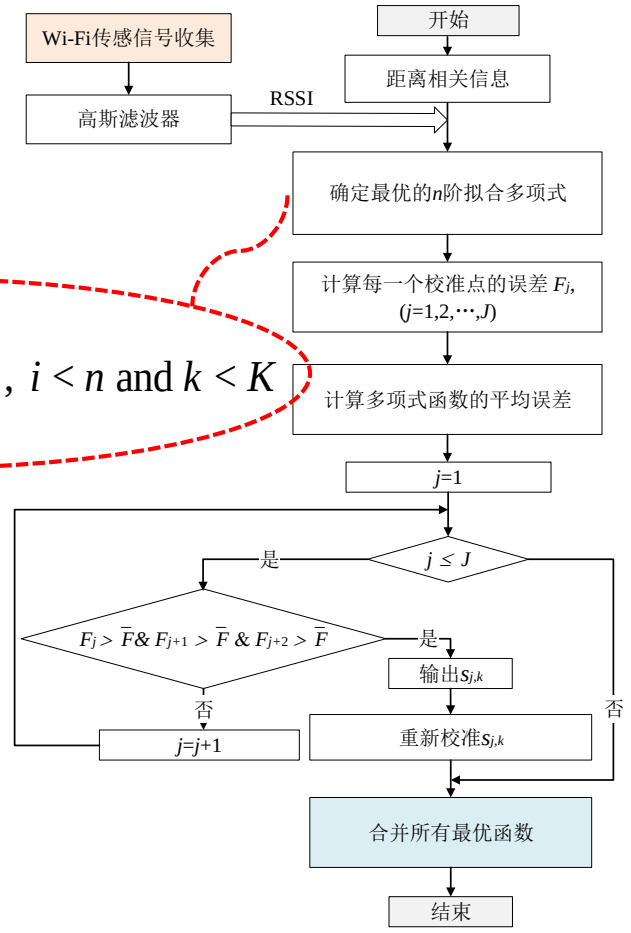


图31 所提分段多项式回归算法流程

在线定位阶段

速度常量-卡尔曼滤波

泰勒级数展开最小二乘法

无迹卡尔曼滤波

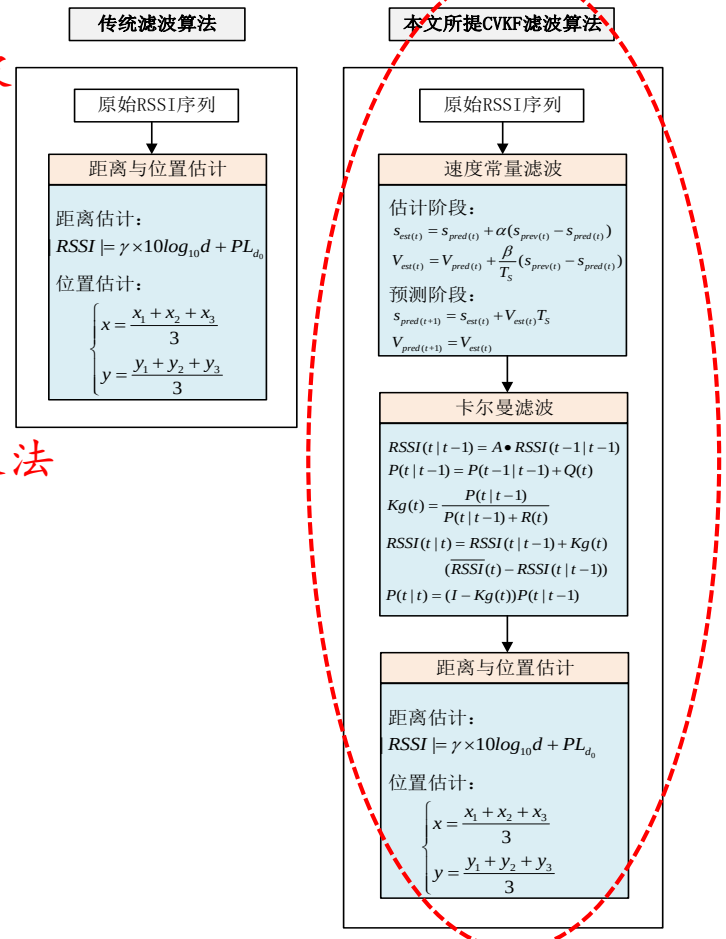


图32 速度常量-卡尔曼滤波算法框架

第三章-大范围目标RSSI快速定位方法

➢ 实验与结果分析

□ 实时信号降噪性能分析

本人于2019年1月23日在广州华南理工大学五山校区进行了现场实验。场地位于珠江南路周围。

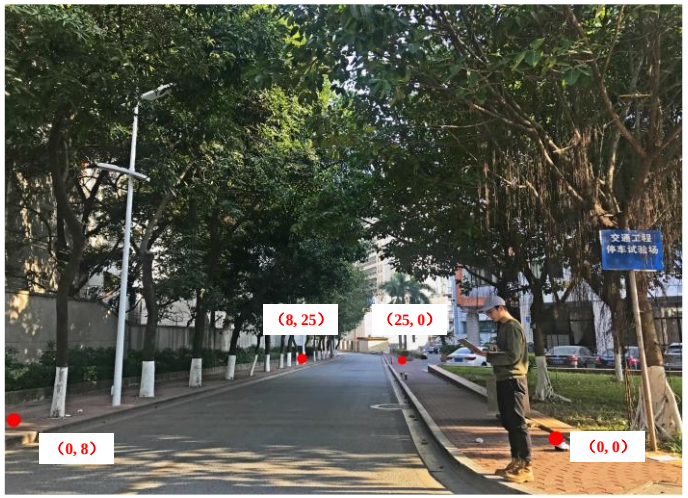


图33 实验环境

■ **实验结论：**

在线阶段使用CVKF滤波，**是一种行之有效的手段。**

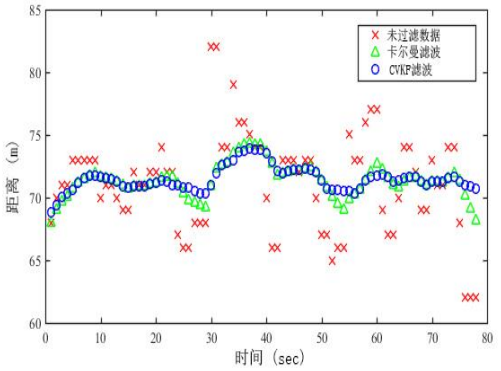


图34 静态环境下的RSSI滤波结果

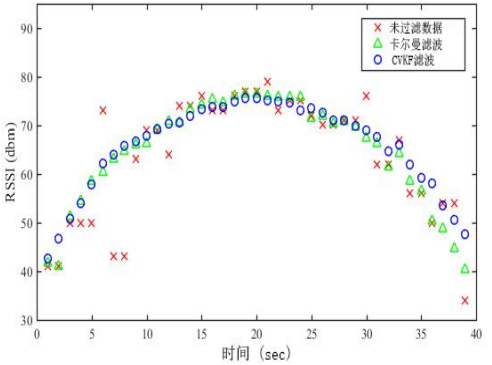


图35 动态环境下的RSSI滤波结果

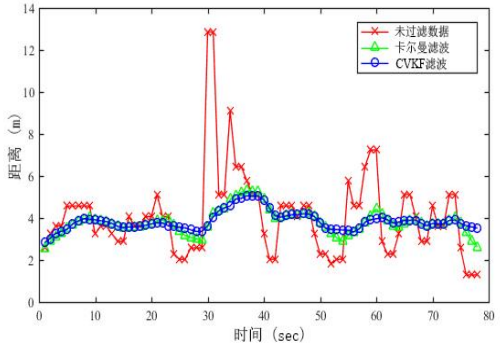


图36 静态环境距离估计

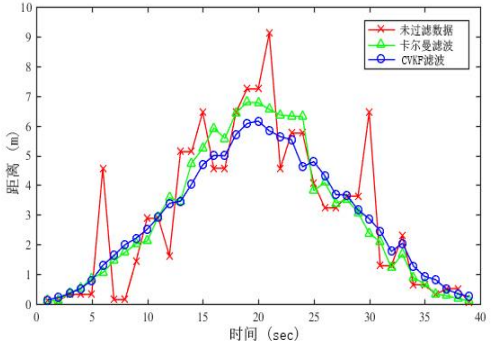


图37 动态环境距离估计

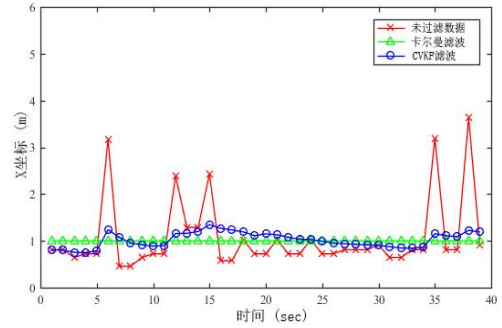


图38 基于三边定位法的X轴误差

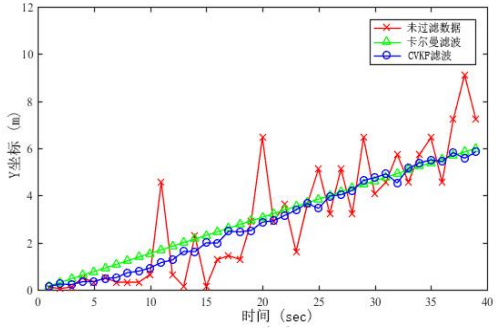


图39 基于三边定位法的Y轴误差

➢ 实验与结果分析

□ 离线距离估计性能分析

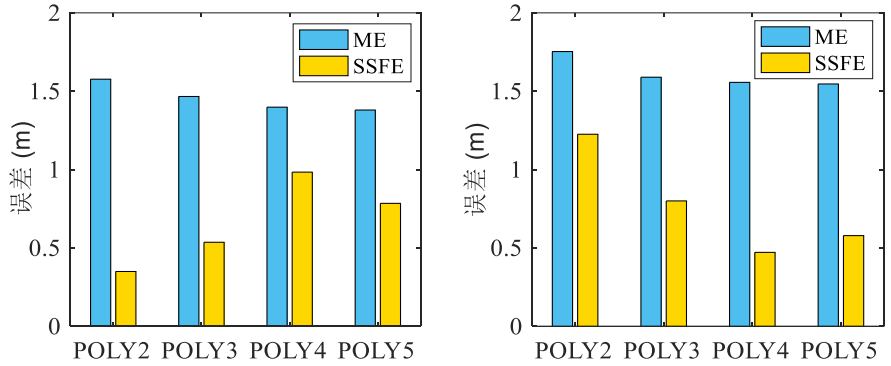


图40 两次拟合函数平均误差与平方和波动误差对比

表4 第一次拟合各点的误差

真实距离	拟合距离	误差	真实距离	拟合距离	误差
25	23.57	1.43	12	9.12	2.88
24	22.78	1.22	11	11.14	0.14
23	24.98	1.98	10	9.94	0.06
22	22.13	0.13	9	11.09	2.09
21	22.57	1.57	8	6.10	1.90
20	21.68	1.68	7	7.32	0.32
19	19.54	0.54	6	8.38	2.38
18	16.52	1.48	5	7.23	2.23
17	16.09	0.91	4	5.47	1.47
16	15.17	0.83	3	7.95	4.95
15	11.42	3.58	2	2.23	0.23
14	11.30	2.70	1	0.35	0.65
13	10.92	2.08	平均误差	1.58	

$$d=\begin{cases}0.00071\times s^4+0.19118\times s^3+19.22231\times s^2+854.76607\times s+14173.091, s>-78.57\\ 0.02297\times s^2+2.6\times s+73.84, s<-78.57\end{cases}$$

表5 第二次拟合各点的误差

真实距离	拟合距离	误差	真实距离	拟合距离	误差
15	13.36	1.64	7	6.06	0.94
14	13.01	0.99.	6	7.06	1.06
13	11.91	1.09	5	6.00	1.00
12	8.06	3.84	4	5.10	1.10
11	12.52	1.52	3	6.60	3.60
10	9.56	0.44	2	2.03	0.03
9	12.37	3.37	1	1.00	0.01
8	5.37	2.63	平均误差	1.56	

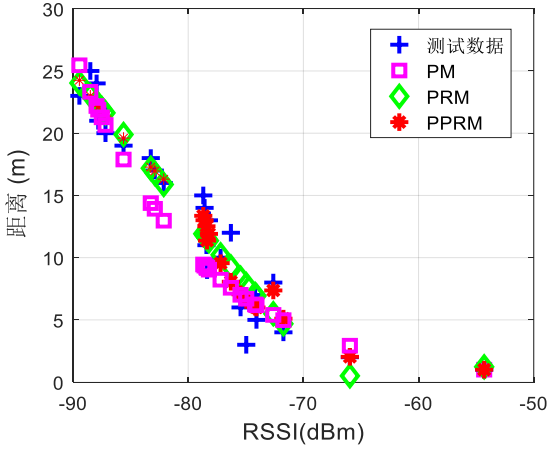


图41 三类模型的离线拟合结果

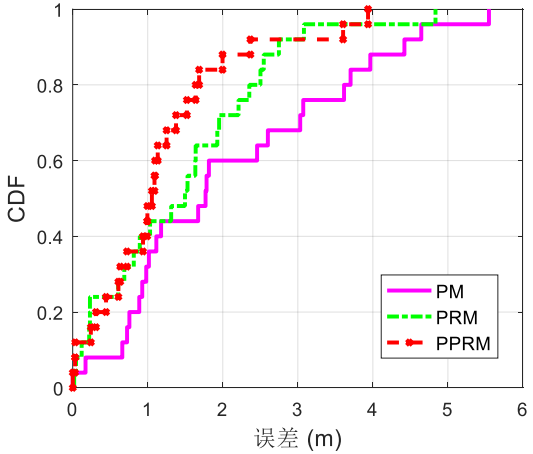


图42 三类模型的距离估计误差

■ **实验结论：**

PPRM在城市道路环境中**可以提供更高的距离估计精度。**

➢ 实验与结果分析

□ 在线定位估计性能分析

- **基于实时数据的欧氏距离估计**

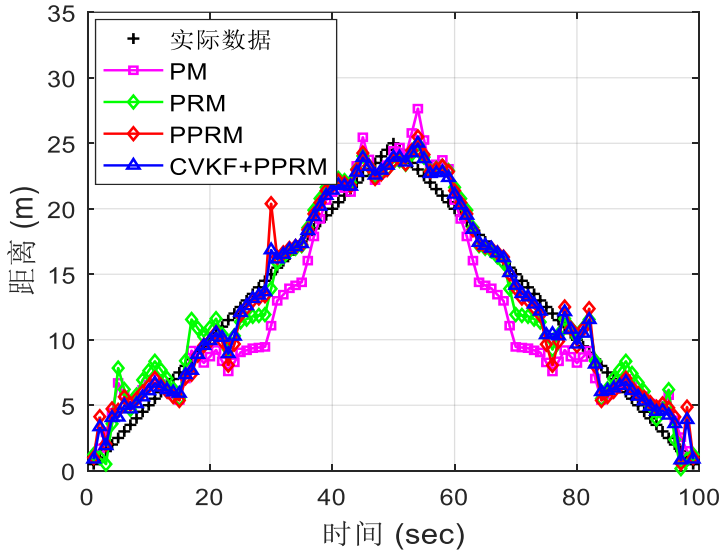


图43 四种模型的实时欧氏距离估计

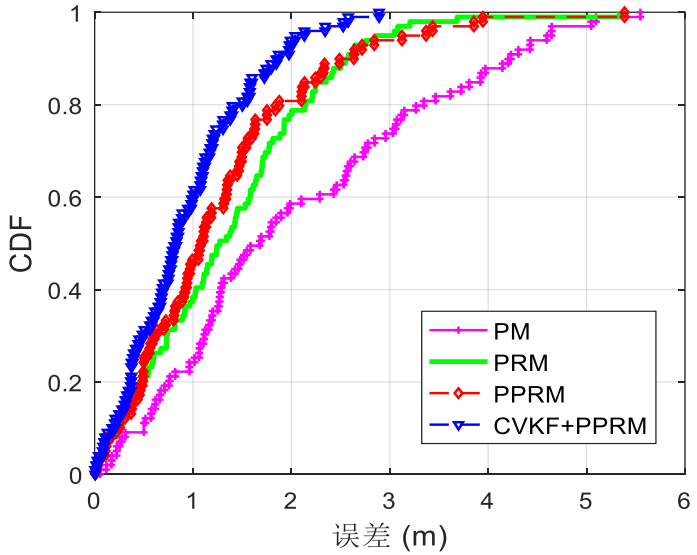


图44 四种模型的实时距离估计误差

■ 实验结论：

在目标持续运动的情况下，**所提出的CVKF+PPRM实时数据欧氏距离估计性能优于其他三种模型。**

第三章-大范围目标RSSI快速定位方法

➢ 实验与结果分析

□ 在线定位估计性能分析

- **基于多检测器的目标定位估计**

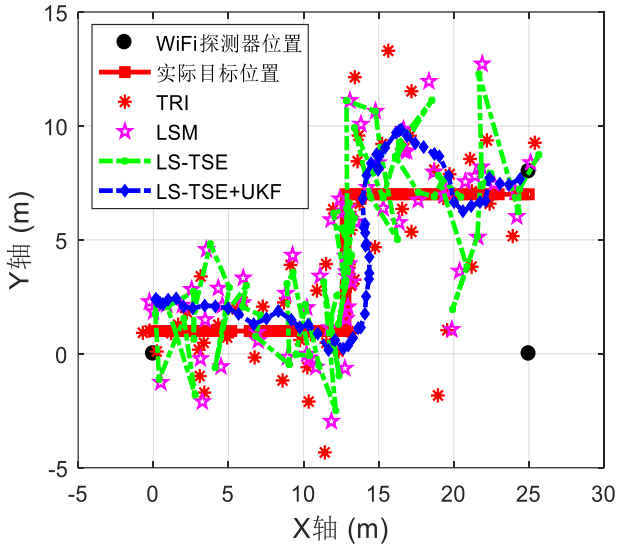


图45 四类模型估计轨迹对比

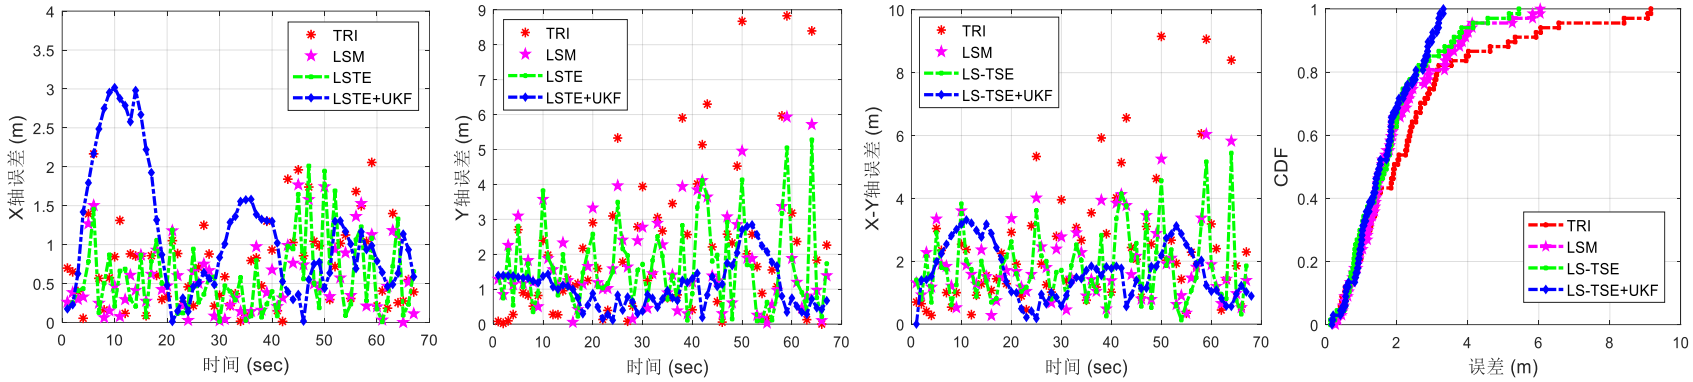


图46 四类模型估计误差对比

表6 四类模型误差对比

定位算法	最小误差	最大误差	平均误差	X轴的RMSE	Y轴的RMSE	X-Y轴的RMSE
TRI	0.28	9.15	2.44	0.97	3.00	1.99
LSM	0.27	6.04	1.96	0.73	2.23	1.48
LS-TSE	0.13	5.44	1.82	0.74	2.03	1.39
LS-TSE+UKF	0.18	3.32	1.67	1.40	1.24	1.32

■ 实验结论：

1. 本文所提算法具有**紧跟实际目标轨迹的能力；**
2. 本文提出的LS-TSE + UKF算法**在城市道路环境下的定位性能优于其他算法。**

➢ 问题描述

针对大范围场景鲁棒定位需求，基于神经网络的测距定位是一种更为合适的技术方案。然而，传统神经网络算法存在“**模型调参较难、计算复杂度较高**”的问题。

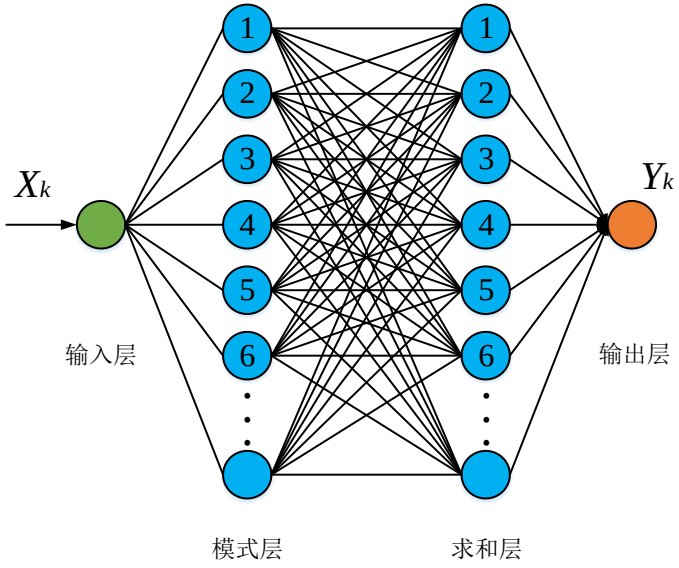


图47 GRNN神经网络

不同类型大范围场景信号传播特点

- **不同环境衰减因子取值差异较大**
- **但同类障碍物条件下波动较为相似**

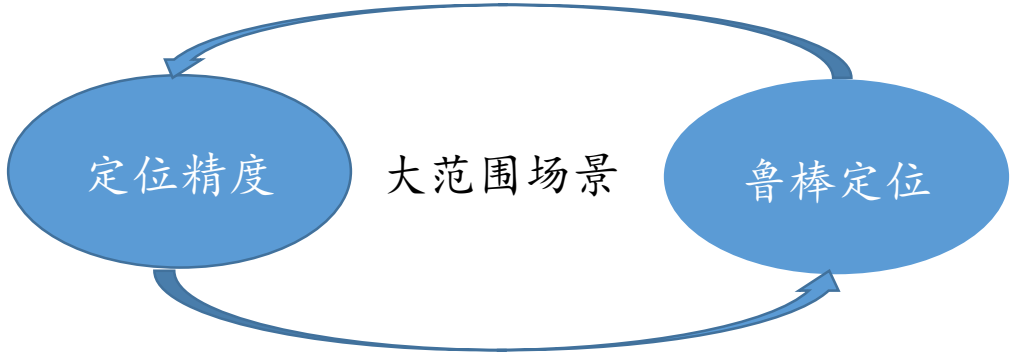


图48 本章所研究的基本问题

➢ 本文所提：基于PSO-GRNN算法的位置感知框架

传统GRNN模型模型参数（即光滑因子）的选择主要**依赖于经验知识**，无法克服**RSSI信号波动随距离变化而变化**，且处理位置估计中**高度非线性问题**的能力还有待提高。

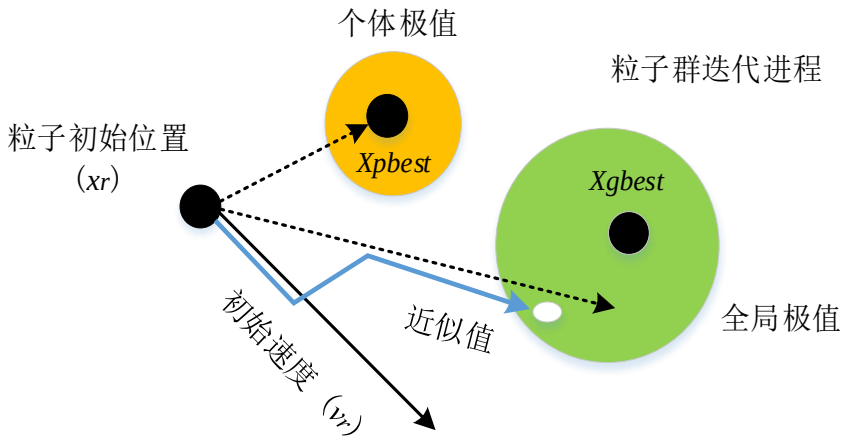


图49 PSO算法的迭代

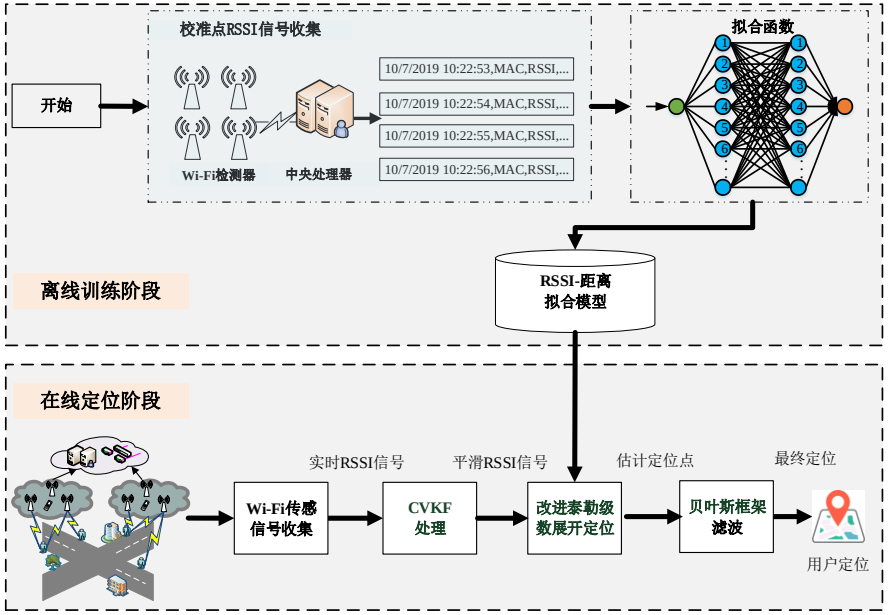


图50 基于PSO-GRNN算法的位置感知框架

在继承GRNN模型计算复杂度较低的优势基础上，本文提出一种**基于粒子群优化回归神经网络（PSO-GRNN）的测距定位方案。**

➢ 本文所提：基于PSO-GRNN算法的位置感知框架

离线训练阶段

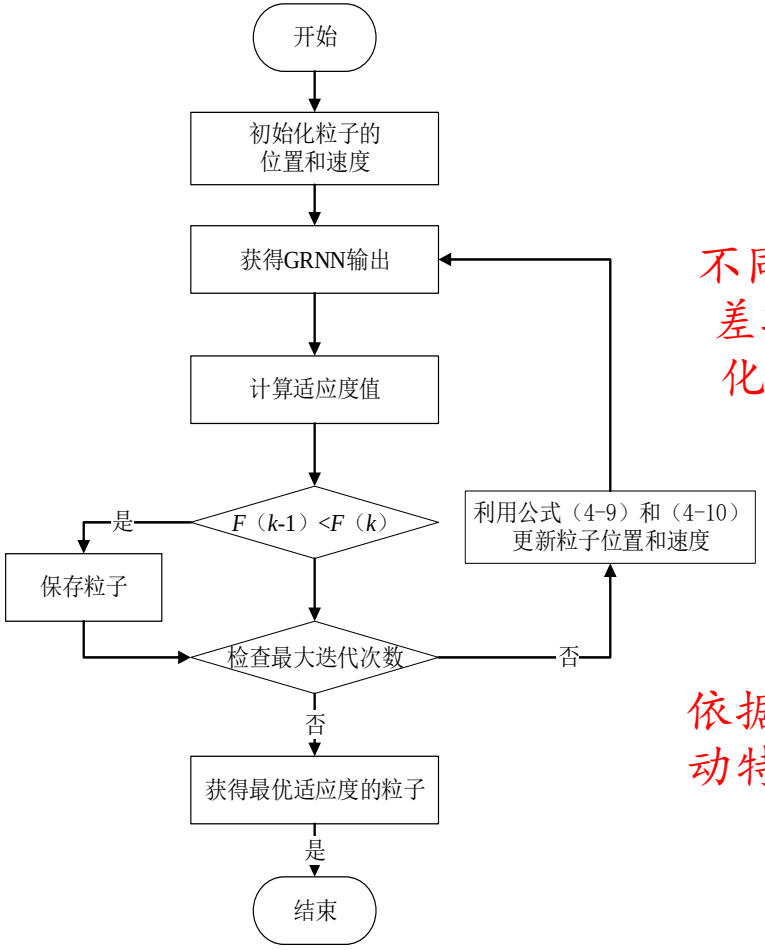


图51 基于PSO优化GRNN的流程

在线定位阶段

$$Q=\frac{1}{(N-1)^2}\begin{pmatrix} T-d_1 & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & T-d_N \end{pmatrix}$$

$$T=\sum_{i=1}^{N} d_i$$

$$\Delta=\left(Y^{\mathrm{T}}Y\right)^{-1}Y^{\mathrm{T}}QU$$

不同类型大范围环境下，衰减因子相差较大，且RSSI信号波动随距离变化而变化的影响将会被进一步放大

改进泰勒级数展开定位法

$$X_t=f_t\left(X_{t-1},u_{k-1},w_{k-1}\right)$$

$$z_t=h\left(X_t\right)+v_t$$

依据道路交通环境中行人和车辆的运动特性，可对移动目标设置运动约束

基于贝叶斯框架的轨迹滤波

图52 在线定位基本流程

第四章-大范围目标RSSI鲁棒定位方法

➢ 实验与结果分析

□ 不同场景距离估计性能分析



(a) 城市峡谷的传播环境



(b) 多类型遮蔽物的传播环境



(c) 单类型遮蔽物的传播环境



(d) 空旷的传播环境

图53 四种实验场景环境

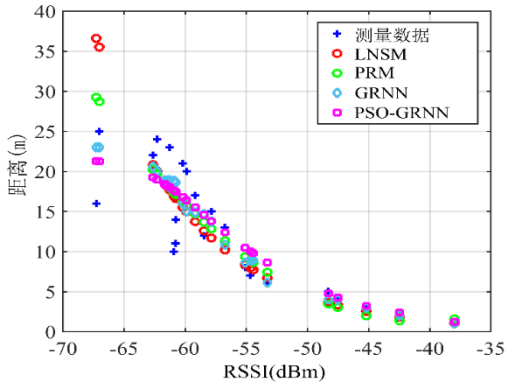


图54 四类算法的离线拟合效果

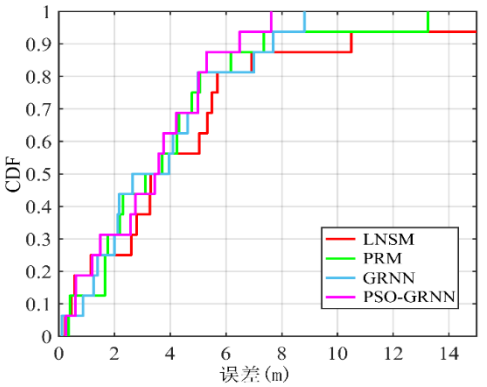


图55 四类算法的离线距离估计误差CDF

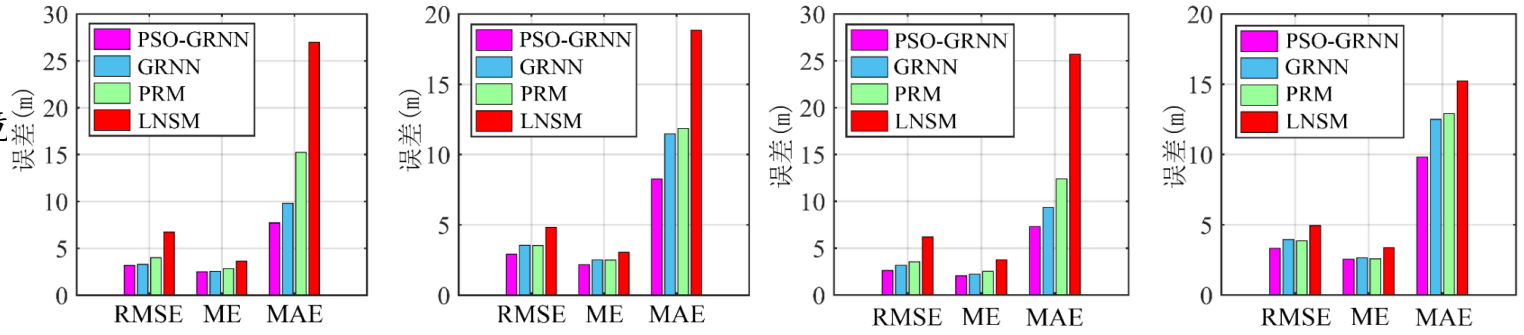


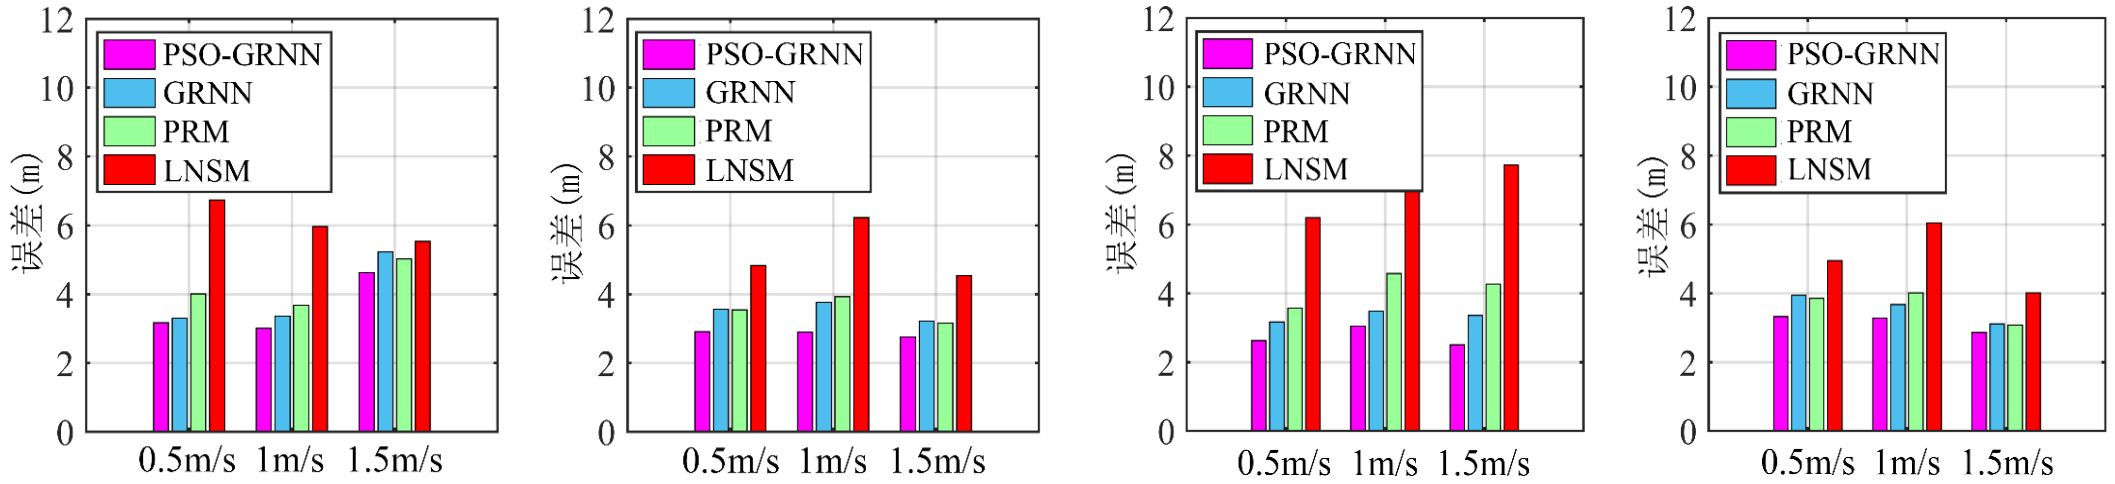
图56 不同场景下的距离估计误差

■ **实验结论：**

1. 综合场景（a）~（d）来看，**本文算法三项指标较为最低；**
2. 表明其能较好地**克服不同类型场景衰减因子波动较大**的问题。

➢ 实验与结果分析

□ 不同速度距离估计性能分析



(a) 城市峡谷的传播环境　(b) 多类型遮蔽物的传播环境　(c) 单类型遮蔽物的传播环境　(d) 空旷的传播环境

图57 不同移动速度下的距离估计误差

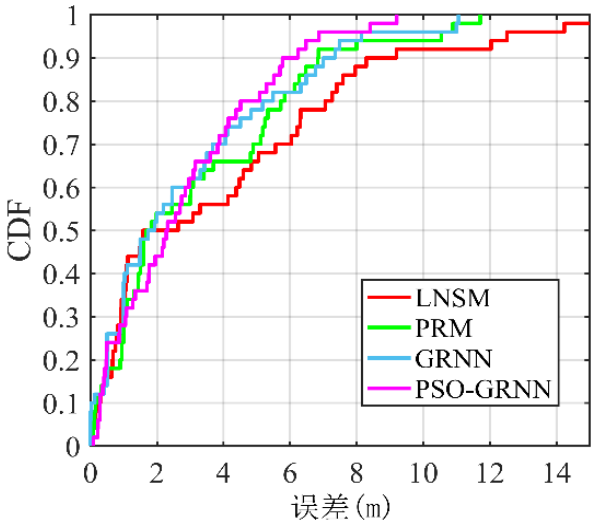
■ **实验结论：**

1. 随着速度的增加，四类模型的距离估计性能都有着**不同程度的下降；**

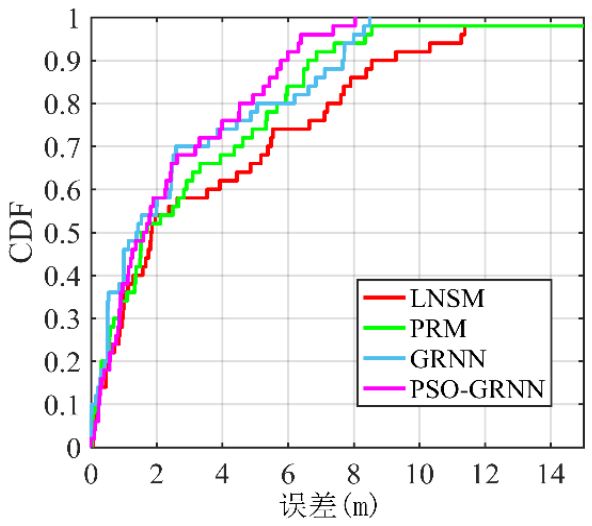
2. **本文所提PSO-GRNN算法的估计误差都是最小的**，这反映了其能在不同的移动速度下保持较好的鲁棒性。

➢ 实验与结果分析

□ 不同设备距离估计性能分析



(a) Galaxy Note 2手机



(b) Xiaomi 1S手机

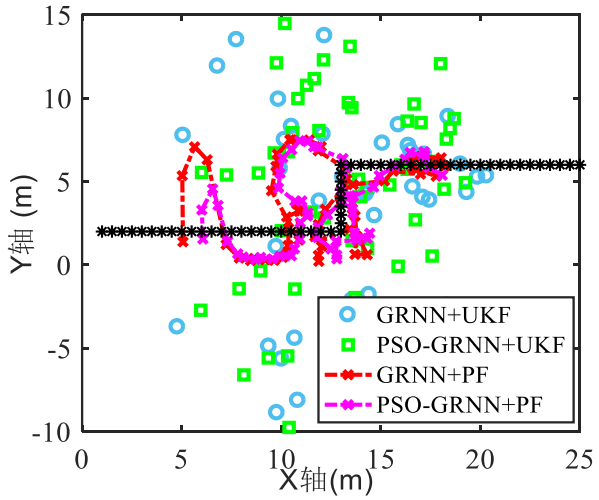
图58 不同设备的距离估计误差

■ **实验结论：**

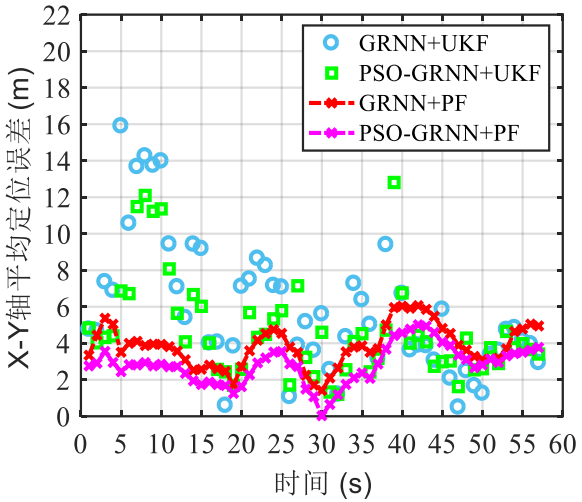
本方法对于**不同硬件设备差异具有较好的鲁棒性和普适性**，具备大规模应用推广的潜能。

➢ 实验与结果分析

□ 不同滤波算法跟踪性能分析



(a) 轨迹对比



(b) X-Y轴平均定位误差对比

图59 两类贝叶斯滤波算法定位性能

表7 四类模型计算时间一览表

	模型名称			
	GRNN+UKF	PSO-GRNN+UKF	GRNN+PF	PSO-GRNN+PF
计算时间	8.63s	14.23s	11.08s	18.45s

■ **实验结论：**

1. **PSO-GRNN+PF的组合算法**在估计RSSI信号与运动目标二维位置之间的非线性映射方面是较优的方案；
2. PSO-GRNN模型经过PSO优化性能提升时付出了计算时间的代价，而**PF框架相较于UKF框架耗时较多。**

➢ 问题描述

针对城市交通信息检测系统“部署成本较低、实时性较高”的检测要求，基于WSNs的被动式检测是一种更为合适的技术方案。然而，现有出行模式甄别算法存在“**部署成本较高、甄别精度较低**”的问题。

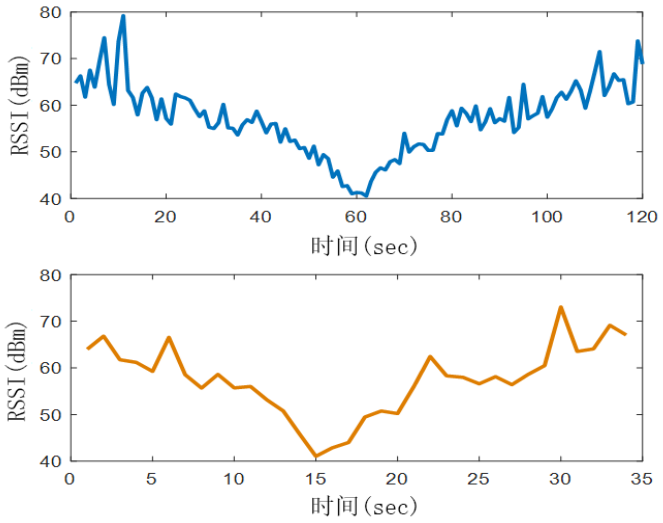


图60 不同交通出行方式下RSSI信号时域对比

无线信号数据检测特点

- **被动式、低成本**
- **不包含个体直接信息**

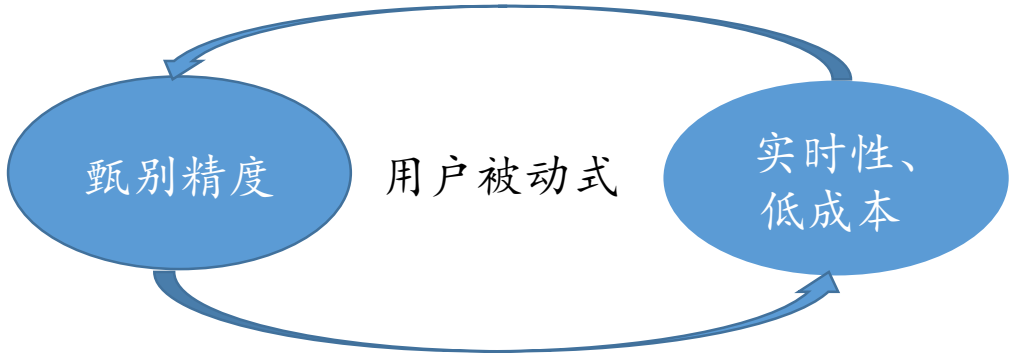


图61 本章所研究的基本问题

黄紫林, Yongjie Lin*, Lunhui Xu, et al. “WiFi-based Traffic Monitoring System for Tracking and Classification of Non-Motorized Traffic.” ***TRB Annual Meeting 2020 (TRB).***

➢ 本文所提：基于Wi-CL系统的模式甄别框架

□ 现存不足：

- 主要挑战是在区分速度、加速度或路线相似的两种模式时不够准确，**特别是非机动交通；**
- 以往研究大多**不考虑RSSI信号中的噪声，**且没有对估计的移动速度进行验证；
- 传统的机器学习方法，不能很好地适应城市道路复杂环境，**甄别精度还有待提高。**

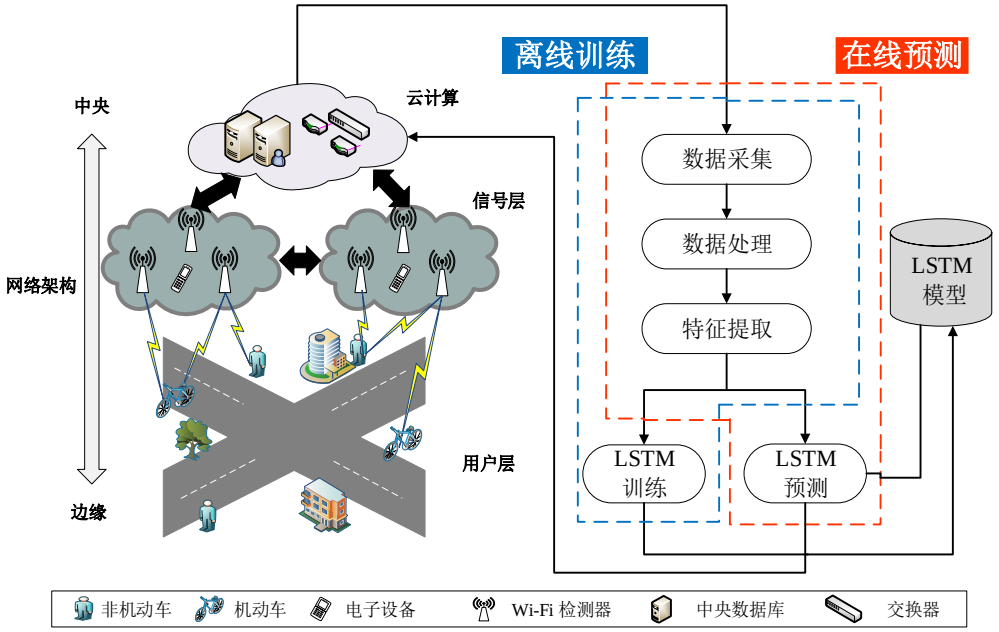


图62 Wi-CL的系统架构

为降低城市交通信息检测系统的部署成本，本文提出了一种**低成本、易部署、高精度的出行模式甄别系统(Wi-CL)**，仅用单个Wi-Fi检测器作为数据源情况下实现出行模式的细粒度甄别。

第五章-基于单点检测数据的出行模式甄别方法

➢ 本文所提：基于Wi-CL系统的模式甄别框架

数据采集模块

（记录其MAC地址、RSSI、时间戳等数据包）

$$\Delta t_k^m = t_{k,2}^m - t_{k,1}^m$$

$$G_k^m = \begin{bmatrix} 00:16:EA:AE:3C:40,7/10//2019\ 10:20:30,-68 \\ 00:16:EA:AE:3C:40,7/10//2019\ 10:20:31,-70 \\ 00:16:EA:AE:3C:40,7/10//2019\ 10:20:35,-74 \end{bmatrix}$$

数据处理模块

（数据粗粒度分类，恢复丢包数据，消除信号噪声功能）

$$v_k^m = \frac{\Delta l_k^m}{\Delta t_k^m}$$

$$\Delta l_k^m = \begin{cases} l_{k,2}^m + l_{k,1}^m, n_k^m \geq \varepsilon^m \\ 0, n_k^m < \varepsilon^m \end{cases}$$

$$s_{k,i}^{ff} = \begin{cases} \dfrac{s_{k,i-w}^{ff} + \ldots + s_{k,i-1}^{ff}}{w}, s_{k,i}^{ff} \in \text{NULL} \\ s_{k,i}^{ff}, s_{k,i}^{ff} \notin \text{NULL} \end{cases}$$

CVKF滤波算法

特征提取模块

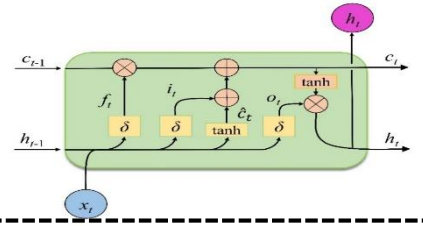
（移动速度、连接数、RSSI信号时间序列的一阶导数等）

符号	特征向量	含义
$v_{k,t}^{vff}$	移动速度	检测区域内设备 k 在时刻 t 的移动速度
n_k^{nff}	连接数	检测区域内检测器采集到设备 k 的连接数
$s_{k,t}^{sff}$	RSSI 信号一阶导数	检测区域内检测器采集到设备 k 的 RSSI 信号一阶导数

$$v_{k,t}^{rff} = \frac{d_{k,t+\tau}^{eff} - d_{k,t}^{eff}}{\tau}$$

模式分类模块

（LSTM训练和LSTM预测两部分）



➢ 实验与结果分析

□ 真实实验环境描述

在华南理工大学五山校区特定区域（由四条街道组成的圆圈）安装了4个DS-007 Wi-Fi检测器，采集测试者步行或骑车时的移动轨迹。



图63 用于数据采集的硬件设备



图64 预实验测试环境

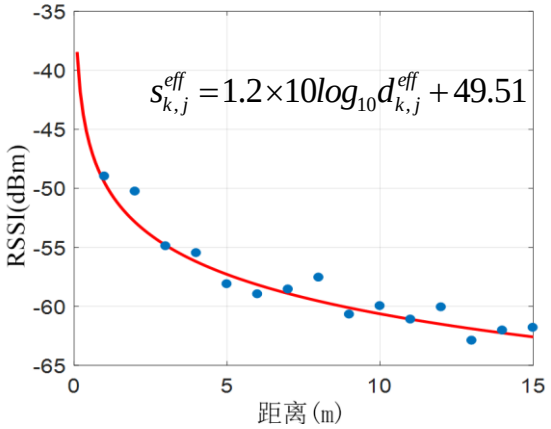


图65 预实验中RSSI-距离分布



图66 检测器位置及测试者移动方向

➢ 实验与结果分析

□ 系统噪声处理性能分析

CVKF滤波器可以有效地抑制由RSSI信号波动引起的定位发散，无论行人是处于静止还是低速运动状态。然而，无法确定CVKF滤波器是否同样适用于骑车，因为骑车的速度比走路快得多。

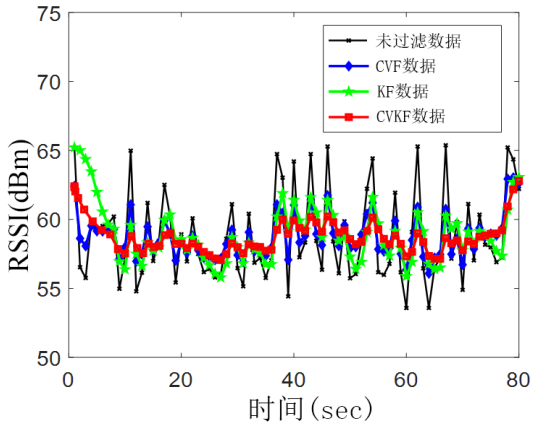


图67 静止场景

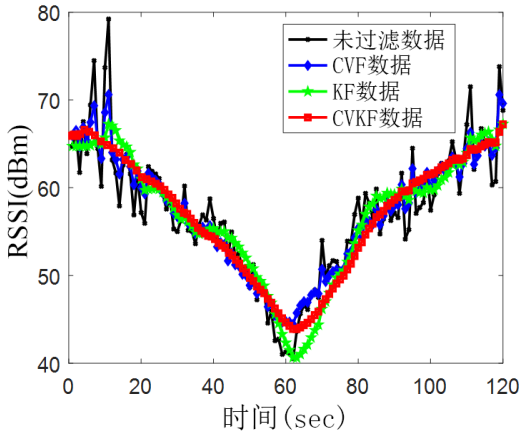


图68 步行场景

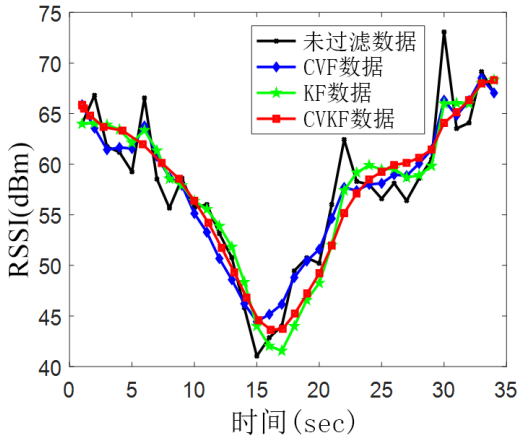


图69 骑车场景

表8 比较三种情况下的估计距离误差

滤波算法		未滤波	CVF 算法	KF 算法	CVKF 算法
静止	平均误差	5.89	3.62	4.07	3.46
	均方根误差	3.91	1.51	2.68	1.21
步行	平均误差	15.01	7.94	6.21	5.74
	均方根误差	45.04	7.68	3.43	2.90
骑车	平均误差	11.31	6.89	6.80	5.53
	均方根误差	18.02	4.63	4.35	4.45

■ **实验结论：**

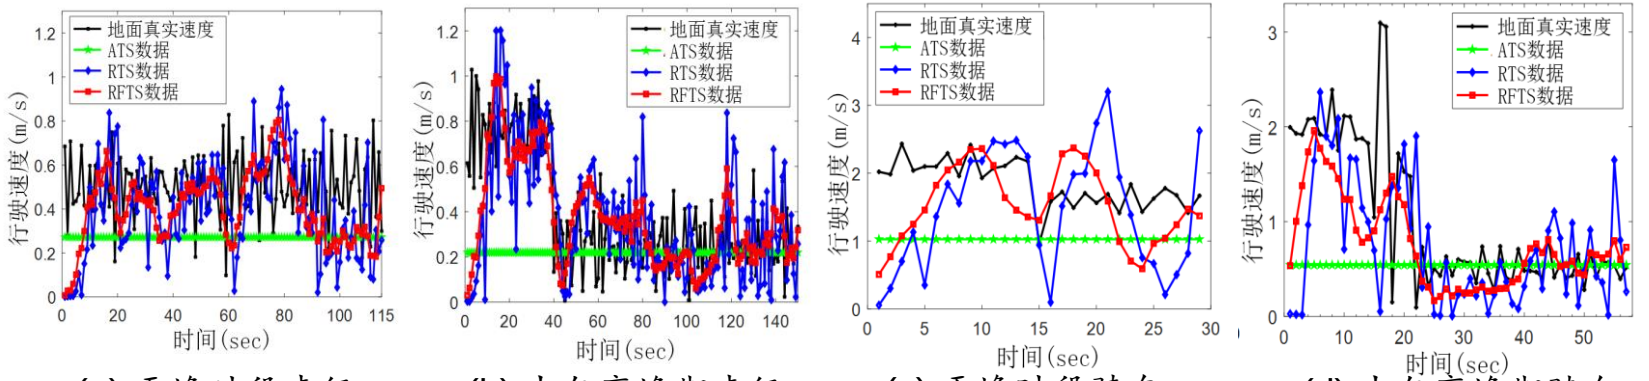
1. 运动环境下的平均误差和RMSE都**比较大；**
2. CVKF算法即使在骑车速度较快的环境也**能保持较好的滤波性能。**

➢ 实验与结果分析

□ 系统速度估计性能分析

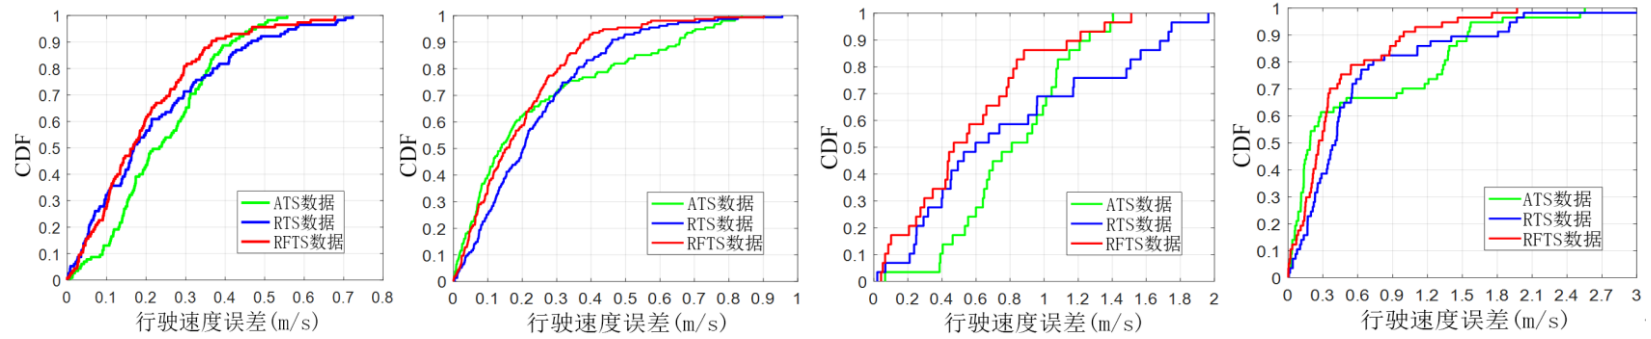
表9 比较四种情况下的估计速度误差

滤波算法		ATS 算法	RTS 算法	RFTS 算法
场景（a）	平均误差	0.24	0.22	1.94
	均方根误差	0.13	0.18	0.15
场景（b）	平均误差	0.24	0.23	0.19
	均方根误差	0.23	0.18	0.16
场景（c）	平均误差	0.82	0.80	0.57
	均方根误差	0.33	0.58	0.40
场景（d）	平均误差	0.60	0.58	0.42
	均方根误差	0.69	0.62	0.44



(a) 平峰时段步行　(b) 中午高峰期步行　(c) 平峰时段骑车　(d) 中午高峰期骑车

图70 四种情况下三种方法的估计速度



(a) 平峰时段步行　(b) 中午高峰期步行　(c) 平峰时段骑车　(d) 中午高峰期骑车

图71 四种情况下三种方法的速度估计误差 CDF

■ **实验结论：**

与本文讨论的其他算法相比，RFTS算法在四种场景下更稳定，**估计的移动速度更接近真实移动速度。**

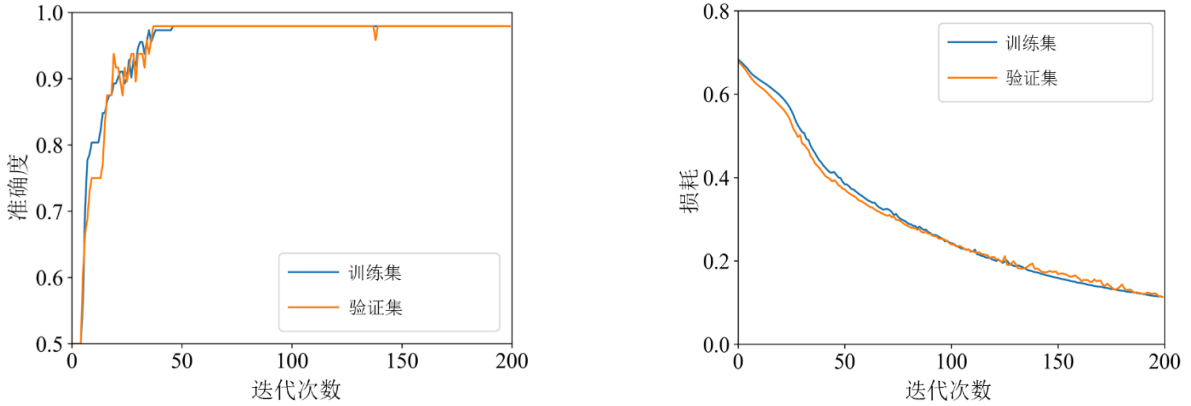
➢ 实验与结果分析

□ 系统模式甄别性能分析

实验在一台Lenovo G40计算机上Linux系统中进行，CPU型号为Intel（R） Core（TM） i5-4258U CPU @ 2.40GHz，Python版本为2.7.15，TensorFlow版本为1.12.0。

表10 四类模型预测结果的混沌矩阵

分类模型	真实交通出行模式	预测交通出行模式		召回率	准确度
		步行	骑车		
LR	步行	21	3	87.50%	72.92%
	骑车	10	14	59.33%	
	精确率	65.63%	82.35%	-	
SVM	步行	24	0	100.00%	79.14%
	骑车	10	14	58.33%	
	精确率	70.59%	100%	-	
MLP	步行	24	0	100.00%	89.58%
	骑车	5	19	79.17%	
	精确率	82.76%	100%	-	
LSTM	步行	24	0	100.00%	97.92%
	骑车	1	23	95.83%	
	精确率	96.00%	100%	-	



(a) 准确度　　(b) 损耗

图72 LSTM模型不同迭代次数的分类性能

■ **实验结论：**

1. 对于非机动交通的分类，**LSTM模型取得最优的性能；**
2. **骑车是召回率较低的模式，**LSTM模型的召回率仍然更为精确；
3. **前50次**迭代时准确率达95%，**第200 次**迭代时损耗已经变化不大。

总结与展望

1 传统指纹定位算法
“冗余数据较多、训练时间较长”

◆ 厘清道路环境下RSSI信号波动特性，**提出面向小范围目标精准定位需求的RSSI指纹定位方法**，能在降低对训练样本依赖的同时实现较高的定位精度。

2 传统对数正态阴影模型
“噪声干扰较大、拟合效果较差”

◆ 剖析道路环境下RSSI-距离内在联系，**提出面向大范围目标快速定位需求的RSSI快速定位方法，**能在保持多项式拟合快速性的同时实现较高的定位精度。

3 传统神经网络算法
“模型调参较难、计算复杂度较高”

◆ 聚焦不同道路场景拟合模型泛化性能，**提出面向大范围目标鲁棒定位需求的RSSI鲁棒定位方法，**能在适当提高计算复杂度情况下实现广域场景鲁棒定位。

4 传统出行模式甄别算法
“部署成本较高、甄别精度较低”

◆ 挖掘路侧单元检测数据隐含交通信息，**提出基于单点检测数据的出行模式甄别方法，**仅用单个Wi-Fi检测器作为数据源情况下实现出行模式的细粒度甄别。

➢ 应用前景

针对不同的定位需求，本文所提的四类方法

各具特点、互补互成。

中国道路环境！

噪声滤波

距离估计

位置检测

出行模式甄别

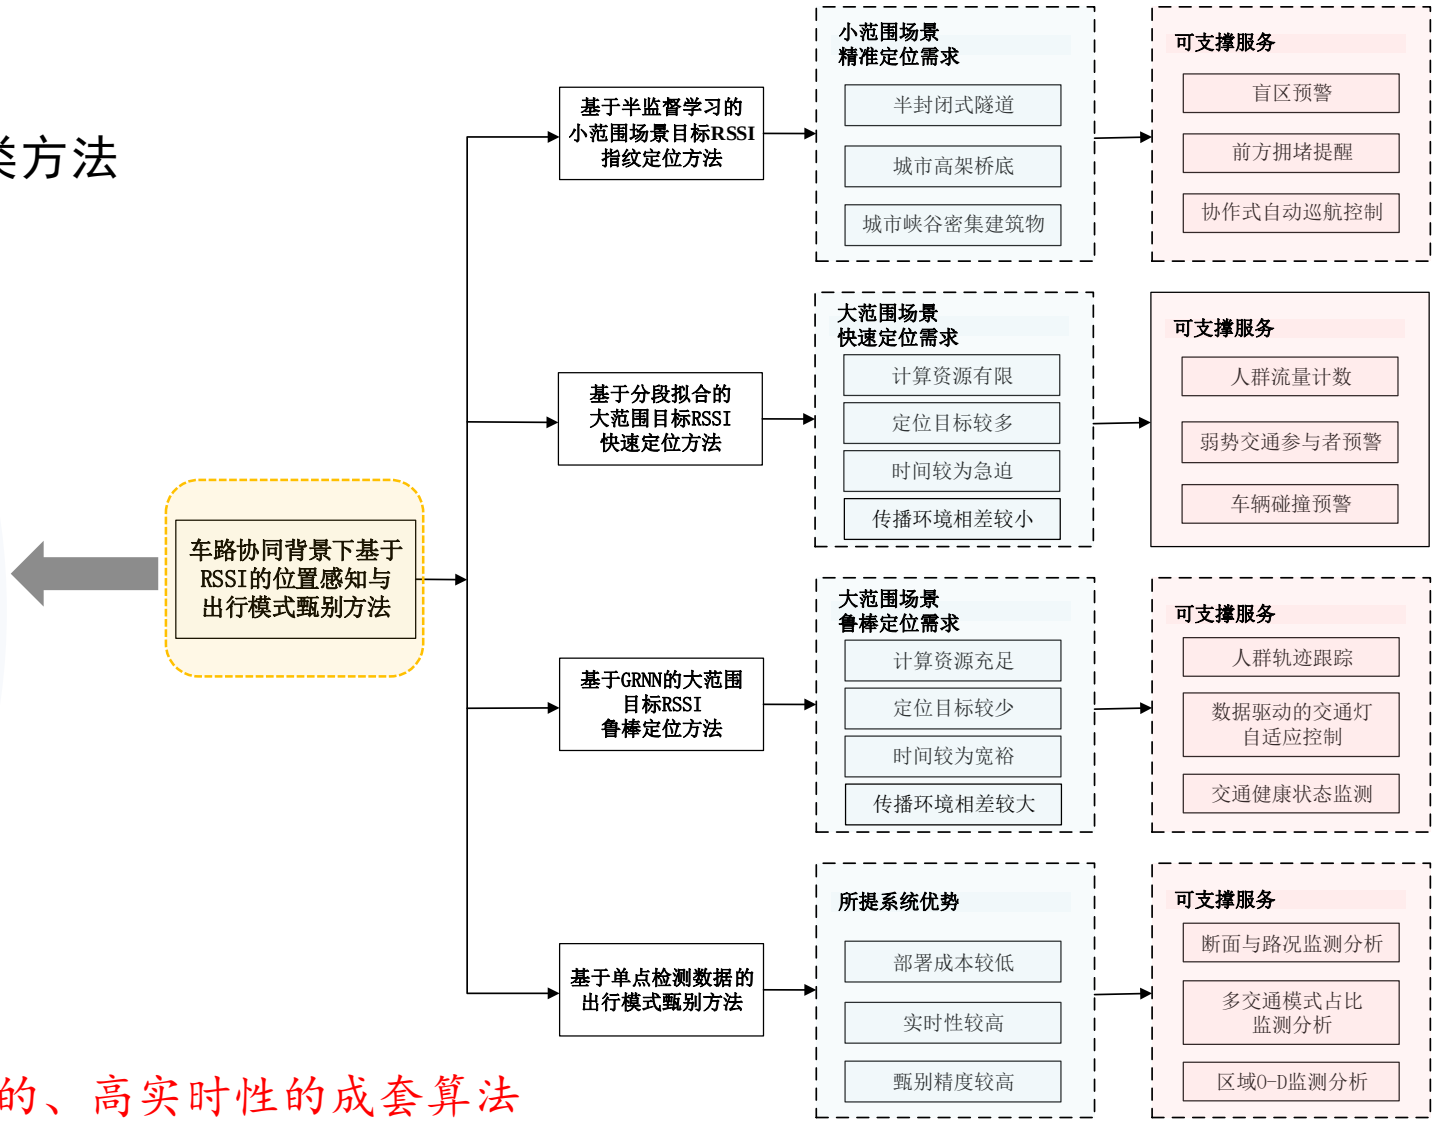


图73 本文所提方法的具体应用场景

有机集合形成了适用于C-ITS领域的、高精准度的、高实时性的成套算法

研究生期间学术成果

➢ 已发表与学位论文相关的学术论文（**SCI检索3篇、EI检索2篇、TRB检索1篇、北大核心检索1篇**）：

1. **黄紫林,** Lunhui Xu, and Yongjie Lin*. “Multi-stage pedestrian positioning using filtered WiFi scanner data in an urban road environment.” ***Sensors.*** 20.11 (2020): 3259. **(SCI/EI检索, IF: 3.275, JCR Q1)**
2. **黄紫林,** Lunhui Xu, Yongjie Lin*, et al. "Citywide metro-to-bus transfer behavior identification based on combined data from smart cards and GPS." ***Applied Sciences.*** 9, no. 17 (2019): 3597. **(SCI/EI检索, IF: 2.474, JCR Q2)**
3. Pan Wu, **黄紫林*,** Yuzhuang Pian, Lunhui Xu, et al. "A Combined Deep Learning Method with Attention-Based LSTM Model for Short-Term Traffic Speed Forecasting." ***Journal of Advanced Transportation.*** 2020 (2020). **(SCI/EI,检索IF: 1.67, JCR Q3)**
4. 林永杰, **黄紫林*,** 吴 攀, 许伦辉. “基于半监督极限学习机的隧道内车辆 RSSI 定位方法.” *交通运输工程学报*. 2021年第2期. **(EI检索, IF: 1.678, 入选中国科技期刊卓越行动计划)**
5. **黄紫林,** Xianyuan Zhu, Yongjie Lin*, Lunhui Xu, et al. "A novel WIFI-oriented RSSI signal processing method for tracking low-speed pedestrians." ***In 2019 5th International Conference on Transportation Information and Safety (ICTIS),*** pp. 1018-1023. IEEE, 2019. **(EI检索, Liverpool UK, Oral Presentation)**
6. **黄紫林,** Yongjie Lin*, Lunhui Xu, et al.“WiFi-based Traffic Monitoring System for Tracking and Classification of Non-Motorized Traffic.” ***TRB Annual Meeting 2020 (TRB).*** **(TRB检索, Washington USA, Poster)**
7. Pan Wu, Lunhui Xu*, **黄紫林.** " Imputation Methods Used in Missing Traffic Data: A Literature Review.” ***In International Symposium on Intelligence Computation and Applications (ISICA).*** Springer, 2019, pp. 662-677. **(EI检索, Guangzhou CHINA, Poster)**
8. 林焰, 杜锦涛, **黄紫林,** 丁为建*. 基于多模块模糊贝叶斯网络的恐怖袭击事件量化分析. *数学的实践与认识*. 2019, 16. **(北大核心期刊检索)**

研究生期间学术成果

➢ 已申请国家发明/实用新型专利18项（**第一发明人/第一学生发明人15项**）：

1. 林永杰, **黄紫林,** 赵胜, 许伦辉, 唐善宇. “一种用于跟踪低速移动车辆的 RSSI 拟合方法”，**中国发明专利, 已授权.**
2. 林永杰, **黄紫林.** “一种基于 RSSI 定位移动目标的微型装置”，**中国实用新型专利, 已授权.**
3. 林永杰, **黄紫林.** “一种基于 RSSI 和惯性导航的车载定位装置”，**中国实用新型专利, 已授权.**
4. 林永杰, **黄紫林,** 许伦辉. “一种用于辅助无人驾驶小车的视觉导航系统”，**中国实用新型专利, 已授权.**
5. 林永杰, **黄紫林,** 许伦辉. “一种基于机器视觉与红外传感器的无人驾驶小车避障系统”，**中国实用新型专利, 已授权.**
6. **黄紫林,** 许伦辉. “一种便携式公交车上下车乘客数量计数装置”，**中国实用新型专利, 已授权.**
7. 骈宇庄, **黄紫林,** 林永杰, 詹煜清, 吴攀. “一种基于RSSI的两客一危车辆预警装置”，**中国实用新型专利, 已授权.**
8. **黄紫林,** 许伦辉. “地铁换乘公交行为识别方法、系统、计算机设备及存储介质”，**中国发明专利, 实质审查 (201910051795.1).**
9. **黄紫林,** 许伦辉. “地铁乘客下车时间识别方法、系统、计算机设备及存储介绍”，**中国发明专利, 实质审查 (201910051795.8).**
10. **黄紫林,** 许伦辉. “一种基于 IC 卡数据的热点换乘枢纽识别方法”，**中国发明专利, 实质审查(201910339482.6).**
11. **黄紫林,** 林永杰, 许伦辉. “一种地铁车站客流监测方法及系统”，**中国发明专利, 实质审查(201910338991.7).**
12. **黄紫林,** 骈宇庄, 林永杰, 吴攀, 詹煜清. “一种基于RSSI的道路交通拥堵检测及疏导装置”，**中国实用新型专利, 实质审查**
13. 林永杰, **黄紫林,** “一种基于无线信号的交通出行模式识别方法”，**中国发明专利, 实质审查(201910339482.6).**
14. 林永杰, **黄紫林,** 许伦辉. “一种用于跟踪低速移动车辆的 RSSI 拟合方法”，**中国发明专利, 实质审查 (201811368105.7).**
15. 林永杰, **黄紫林,** 许伦辉. “一种基于无线通信信号的目标入侵检测装置”，**中国实用新型专利, 实质审查 (202020965272.6).**
16. 林永杰, 曾维嘉, 杨彦青, 程禹铭, 刘宇恒, 管海霞, **黄紫林.** “一种基于生态指数的城市交通运行评价方法”，**中国发明专利, 实质审查 (201911419439.7).**
17. 何超, 骈宇庄, **黄紫林.** “一种智慧城市用基于RSSI的行人流量采集装置”，**中国实用新型专利, 实质审查.**
18. 饶斌, 叶志宏, 林永杰, 钟浩川, **黄紫林.** “一种基于RSSI的隧道内交通事故实时检测及预警系统”，**中国实用新型专利, 实质审查.**

未来展望

➢ 本研究下一步的主要工作将围绕以下几个方面开展

- 在**不同道路环境下**进一步验证算法的有效性；
- 在**不同检测器设备条件下**进一步完善融合感知方案；
- **5G车联网环境下**的实时位置感知技术研究。

➢ 已投稿或拟投稿的学术论文

1. 黄紫林, Yongjie Lin* and Lunhui Xu. “RSS-based Localization via improved Taylor Series and Weighted Centroid Localization.” ***IEEE Sensors Journal.*** **(已投稿)**
2. 黄紫林, Yongjie Lin* and Lunhui Xu, et al. “Robust federated learning approach for RSS-based pedestrian trajectory estimation.” ***IEEE Transactions on Network Science and Engineering.*** **(拟投稿)**
3. 黄紫林, Yongjie Lin* and Lunhui Xu, et al. “WiCL: Low-cost WiFi-based Detection System for Non-motorized Traffic Monitoring and Mode Recognition.” ***IEEE Transactions on Intelligent Transportation Systems.*** **(拟投稿)**
4. Jinlong Li, Lunhui Xu*, Pan Wu, 黄紫林. “Deep Spatial-Temporal Bi-directional Residual Optimization Based on Tensor Decomposition for Traffic Data Imputation on Urban Road Network.” ***Applied Intelligence.*** **(已投稿)**
5. Pan Wu, Lunhui Xu, Mingyang Pei*, 黄紫林. “Deep Spatial-Temporal Bi-directional Residual Optimization Based on Tensor Decomposition for Traffic Data Imputation on Urban Road Network.” ***Journal of Transport Geography.*** **(已投稿)**
6. 许伦辉*, 骈宇庄, 林永杰, 黄紫林. “基于累积前景理论的人车冲突演化博弈模型研究.” *中国公路学报*. **(已投稿)**



致谢



感谢许伦辉老师

给予我宝贵的读研机会！

请各位老师多多批评指正！