

硕士学位论文

**基于流形对齐的 WLAN 室内定位方法  
研究**

RESEARCH ON WLAN INDOOR LOCALIZATION  
APPROACHES BASED ON MANIFOLD  
ALIGNMENT

周才发

哈尔滨工业大学

2015 年 7 月

国内图书分类号：TN929.5  
国际图书分类号：621.396

学校代码：10213  
密级：公开

工学硕士学位论文

# 基于流形对齐的 WLAN 室内定位方法 研究

硕士研究生：周才发

导师：谭学治教授

申请学位：工学硕士

学科：信息与通信工程

所在单位：电子与信息工程学院

答辩日期：2015年7月

授予学位单位：哈尔滨工业大学

Classified Index: TN929.5

U.D.C: 621.396

Dissertation for the Master's Degree in Engineering

RESEARCH ON WLAN INDOOR LOCALIZATION  
APPROACHES BASED ON MANIFOLD  
ALIGNMENT

Candidate :	Zhou Caifa
Supervisor :	Prof. Tan Xuezhi
Academic Degree Applied for :	Master of Engineering
Specialty :	Information and Communication Engineering
Affiliation:	School of Electronics and Information Engineering
Date of Defence:	July, 2015
Degree-conferring-Institution:	Harbin Institute of Technology

## 摘要

随着可移动计算终端及无线技术的发展，定位导航系统受到越来越多研究人员的关注，其应用也越来越广泛。在室外，可以利用卫星信号进行定位导航；在室内，由于可见卫星数目不足，卫星定位导航方法并不适用于室内。近年来，多种基于不同方式的室内定位系统被提出，包括基于红外线、超声波、以及射频等信号的室内定位系统。基于 WLAN 的室内定位系统（WLAN based Indoor Localization System, WILS）利用已有的无线局域网的基础设施来完成室内定位系统的构建，不需要增加硬件设备，因此受到许多研究人员的重视。

针对基于 WLAN 的室内定位系统中存在的 Radio Map 建立效率低、工作量大、RSS 与 Radio Map 处理及定位算法的多样性等问题，本文提出以流形对齐为核心的 Radio Map 快速建立及 WLAN 室内定位方法：直接映射定位（DML）及基于重建 Radio Map 的 KNN 算法（reKNN）。

本文介绍了典型的 WILS 的用户端、无线接入点及定位服务器等三个核心层次及其系统工作流程，并对确定型及概率型位置指纹定位算法进行了详细分析；本文详细介绍了位置指纹数据库的建立方式及其无线电地图（Radio Map）的组成，并采用了 OPPO T29、Google Nexus5、Samsung Note II 及联想 V450 笔记本电脑等四种移动终端对部署在哈尔滨工业大学通信技术研究所内两个 WLAN 室内定位系统（HIT-WILS10、HIT-WILS12）进行了数据采集。为了提高位置指纹定位方法的实时性能及其对不同实验环境的适应性，本文提出了基于仿射聚类（AP）方法的位置指纹定位方法（AP-KNN），并以 HIT-WILS12 所在走廊实验区域的实测数据进行了性能测试。仿真结果表明，AP-KNN 不仅可以可以在单次采样 Radio Map 时有效地保持 KNN 的定位性能，同时也可以适应不同重采样次数的 Radio Map。AP-KNN 在 3 米及 4 米内定位精度达到了 83%及 93%。

本文分析了流形理论的基本概念及典型的流形学习方法，并对流形学习中的耦合度量学习进行了详细地分析；然后从基于相关关系的耦合度量学习及基于 Fisher 准则的耦合度量学习出发，推导了统一耦合度量学习（UCML）方法。在此基础上，本文提出了基于 UCML 的流形对齐方法（UCML-MA）及基于流形对齐的超分辨率分析（SRA-MA）算法。在 UCML-MA 及 SRA-MA 的理论基础上，本文提出了基于流形对齐的 WLAN 室内定位系统的总体方

案，包括基于流形对齐 Radio Map 建立及 WLAN 室内定位模块。本文基于 SRA-MA 算法提出了 Radio Map 超分辨率重建方法，即从稀疏 Radio Map 实现高采样分辨率 Radio Map 建立，从而实现 Radio Map 快速建立。同时，基于 UCML-MA 方法提出了两种 WLAN 室内定位方法：DML 及 reKNN 算法。

通过采用四种不同终端对 HIT-WILS10/12 系统的实测及性能仿真结果表明，本文提出的 Radio Map 建立方法及 DML、reKNN 可以有效地解决了 Radio Map 建立效率低、RSS、Radio Map 及定位方法多样等问题，并实现 Radio Map 建立与 WLAN 室内定位方法的统一。仿真结果表明：随着 Radio Map 的重采样次数的增加，KNN 算法的整体性能的影响无明显变化，而对于 DML 及 reKNN 算法，随着重采样次数的增加，其 3 米及 4 米内定位精度均有 5%左右的提升，分别从 55%及 75%提升至 60%及 80%，达到与 KNN 算法定位性能一致。

从等分辨率及超分辨率的整体定位结果来看，基于 SRA-MA 的 Radio Map 重建方法可以有效地降低 Radio Map 建立的工作量的同时，维持不同算法的定位性能。仿真结果表明，采用的 SRA-MA 算法的 Radio Map 重建方法可以在至少降低一半 Radio Map 建立工作量的前提下，保持 WLAN 室内定位系统的性能不变，并可以在一定程度上提升定位精度。Radio Map 建立的效率的提高幅度最高可达 16 倍，即采样分辨率从 0.25 提升至 4，而 WLAN 室内定位系统的性能与原系统可比拟。

**关键词：** WLAN 室内定位系统；流形对齐；直接映射定位；超分辨率分析；无线电地图；

## Abstract

With the development of portable computational devices and wireless technology, position and navigation systems are attracted more and more attention of researchers and its applications are more and more comprehensive. Satellites are used to position and navigation in outdoor environment, however, satellite positioning navigation systems cannot adapt to indoor environment for lacking of available satellites. Recent years, several indoor positioning systems based on different standards were proposed, including infrared-based, ultrasonic-based and radio frequency (RF) –based. Among them, WLAN based indoor positioning system(WILS) is a hotspot for its realization is depended on the available WLAN without additional infrastructure.

To tackle the problems of low efficient and high workload in constructing Radio Map and multi-approaches in processing received signal strengthen(RSS), Radio Map and localizing, algorithms which are cored with manifold alignment(MA) for fast construction of Radio Map and WLAN based indoor localization: direct mapping localization(DML) and KNN jointed with reconstructed Radio Map(reKNN) are proposed in this paper.

A brief introduction to the three stratum: ultimate, wireless access points, and positioning servers and its procedures of WILS is presented first. And then Detailed information about fingerprint based localization algorithms(FLAs), both techniques based on matching and probability distribution are formulated. In this essay, methods to build Radio Map are also presented and four mobile devices: OPPO T29, Google Nexus5, Samsung Note II and Lenovo V450 are selected as sampling and performance testing ultimate to collect all RSS information in HIT-WILS10/12, two WILSs deployed in Communication Research Center, Harbin Institute of Technology(CRC, HIT). And to facilitate the real-time performance of online positioning, AP-KNN algorithm, KNN jointed with affinity propagation(AP), is proposed. According to simulating results in passageway environment in HIT-WILS12, AP-KNN achieved comparable performance with KNN, and it gained stable performance with single-sample Radio Map as well as the multi-sample Radio Map. Taking localizing accuracy in 3 and 4 meters for example, it is up to 83% and 93% respectively.

As for the theoretical analysis, basic conceptions about manifold learning, and typical algorithms, such as LLE, ISOMAP, LDE, and SDE are described at the first

place. Then detailed introduction to the theory of coupled metric learning is presented. Starting from the analysis on correlation based and Fisher criterion based coupled metric learning, theoretical descriptions on universal coupled metric learning(UCML) are illustrated. On the basis of UCML, a novel manifold alignment algorithm(UCML-MA) and super resolution analysis based on UCML-MA(SRA-MA) are proposed. By applying UCML-MA and SRA-MA approaches into WILS, schemes for WLAN indoor positioning and fast construction of Radio Map are showed in this paper. On the one hand, an approach based on SRA-MA for reconstructing high sampling resolution Radio Map from sparsed Radio Map is proposed; on the other hand, two methods for indoor positioning based on UCML are proposed: DML and reKNN.

To certify the performance of proposed approaches, four difference mobile devices applied in two WILSs are used. According to simulating consequences, proposed SRA-MA, DML, and reKNN solved problems of current WILS, and realized the combination of core theory of constructing Radio Map and indoor localization. As to the influences of different samples of Radio Map, it has little influenced on the overall performance of KNN, however, the localizing accuracy of DML and reKNN increased by 5%, from 55% and 75% to 60% and 80% when the error radius is within 3 and 4 meters respectively and almost achieved the same performance of original KNN.

From the perspective of equal resolution analysis and SRA, the proposed approach for constructing Radio Map via SRA-MA achieved stable performance of DML and reKNN under the condition that the workload of building Radio Map reduced significantly. From the results, SRA-MA method obtained comparable and superb overall performance when sampling only half of reference points(RPs) in the indoor environment, which means the workload reduced at least 50%. As to the highest SRA, it gained comparable performance of DML and reKNN while only taking 1/16 RPs, reconstructing a high resolution Radio Map which is up to 4 RPs/m<sup>2</sup> from 0.25 RPs/m<sup>2</sup>.

**Keywords:** WLAN based indoor localization system, manifold alignment(MA), direct mapping localization(DML), super resolution analysis(SRA), Radio Map

## 目 录

摘 要 .....	I
Abstract.....	III
第 1 章 绪 论 .....	1
1.1 课题来源及目的意义 .....	1
1.1.1 课题来源 .....	1
1.1.2 课题目的及意义 .....	2
1.2 室内定位系统及其定位方法的研究现状 .....	5
1.2.1 室内定位系统研究现状 .....	5
1.2.2 室内定位方法研究现状 .....	7
1.3 Radio Map 建立方法的研究现状 .....	7
1.3.1 手动建立 Radio Map 方法研究现状.....	8
1.3.2 Radio Map 的无监督建立方法的研究现状 .....	8
1.3.3 Radio Map 的半监督建立方法的研究现状 .....	9
1.4 流形对齐的研究现状 .....	10
1.5 本文研究结构及主要内容 .....	11
第 2 章 WLAN 室内定位系统概述.....	14
2.1 WILS 的组成及其实现流程.....	14
2.1.1 系统结构 .....	14
2.1.2 系统工作流程 .....	15
2.2 WLAN 室内定位方法.....	15
2.2.1 确定型 FLA 算法 .....	16
2.2.2 概率型 FLA 算法 .....	17
2.3 Radio Map 的建立及其特征 .....	18
2.3.1 基于固定终端的 Radio Map 特征分析.....	18
2.3.2 基于移动终端的 Radio Map 特征分析.....	19
2.4 基于仿射聚类的位置指纹定位方法 .....	23
2.4.1 基于仿射传播聚类的分区方法 .....	23
2.4.2 基于位置指纹的子区域匹配方法 .....	24
2.4.3 AP-KNN 算法的性能分析.....	24
2.5 本章小结 .....	28
第 3 章 流形对齐及超分分辨分析 .....	30



3.1 流形及典型流形学习方法 .....	30
3.1.1 基本理论 .....	30
3.1.2 典型流形学习方法 .....	32
3.2 耦合度量学习及流形对齐的基本概念 .....	40
3.2.1 耦合度量学习简介 .....	40
3.2.2 流形对齐简介 .....	41
3.3 基于 UCML 的流形对齐方法 .....	42
3.3.1 统一耦合度量学习 .....	42
3.3.2 基于 UCML 的流形对齐算法 .....	45
3.4 SRA-MA .....	48
3.5 本章小结 .....	50
<b>第 4 章 基于流形对齐的 WILS 及其性能分析 .....</b>	<b>51</b>
4.1 WILS 的系统架构及其部署 .....	51
4.1.1 基于流形对齐的 WILS 的基本框架 .....	51
4.1.2 WILS 的部署 .....	52
4.2 基于流形对齐的 WLAN 室内定位方法 .....	55
4.2.1 基于流形对齐的 Radio Map 的建立 .....	55
4.2.2 基于流形对齐的 WLAN 室内定位方法 .....	56
4.3 多终端情形下 DML 及 reKNN 的性能分析 .....	57
4.4 HIT-WILS12 中 DML 及 reKNN 的性能分析 .....	61
4.5 本章小结 .....	64
<b>结 论 .....</b>	<b>65</b>
<b>参考文献 .....</b>	<b>67</b>
<b>攻读学位期间发表的学术论文 .....</b>	<b>73</b>
<b>哈尔滨工业大学学位论文原创性声明和使用权限 .....</b>	<b>74</b>
<b>致 谢 .....</b>	<b>75</b>
<b>附录 A .....</b>	<b>76</b>
A.1 采样分辨率对照表 .....	76
A.2 Google Nexus 5 及 Samsung Note II 的性能测试结果 .....	76
A.3 不同参数下 HIT-WILS12 系统性能分析结果 .....	79

# 第1章 绪论

## 1.1 课题来源及目的意义

### 1.1.1 课题来源

本课题来自于国家自然科学基金项目《基于绿色 AP 的 WLAN 室内定位算法研究》(NSFC 项目编号: 61101122)。

从目前基于 WLAN (wireless local area network, WLAN) 的室内定位系统 (WLAN based indoor localization system, WILS) 来看, 主要采用基于位置指纹的定位的方法, 其实现过程包含两个阶段: 离线阶段 (Offline) 与在线 (Online) 阶段。离线阶段: 主要是完成在线定位阶段的数据的采集, 包括参考点的坐标信息、各个参考点接收到不同无线接入点 (wireless access point, WAP) 的信号强度 (received signal strength, RSS) 等。上述所采用的数据信息通常称之为位置指纹图, 即 Radio Map。在线阶段的目标是估计移动终端的位置。

目前, WILS 中存在以下三个方面的问题。首先, 从目前建立 Radio Map 的方法来看, 几乎都是采用人工方式来完成。这一现状主要是由缺少有效的室内传播模型、缺少自动采集设备并且没有完整有效的室内地理信息系统 (indoor geographic information system, I-GIS) 的支持。因此, 现今的 Radio Map 的建立主要由人工来完成。第二, 室内定位及 RSS 处理方法过于多样。这一多样性主要指的是对 Radio Map 的建立与分析算法, 与在线阶段实现室内定位的算法一般都是不同的。对于 Radio Map 的分析主要是围绕于降噪及奇异值处理, 并没有考虑到与在线定位方法的统一。第三, Radio Map 的建立方法存在局限性, 主要是针对室内定位环境提出的一些方法, 甚至仅针对于特定的室内环境, 如走廊、办公区等。

为了有效地解决以上问题, 本文拟基于流形对齐 (Manifold Alignment, MA) 的方法实现对 Radio Map 建立, 并将这一方法推广至不同的定位环境: 包括不同的室内定位环境。同时, 通过对算法参数及指标的改变采用流形对齐方法实现室内定位。

### 1.1.2 课题目的及意义

随着可移动计算终端和无线技术的发展，定位导航系统受到越来越多地研究人员的关注，其应用也越来越广泛。在移动终端上集成用户的位置信息可以为用户提供诸如个人安全，旅游及物流等基于位置的服务（Location Based Service, LBS）<sup>[1~2]</sup>。在室外，可以利用卫星信号进行定位导航，如全球卫星定位导航系统（Global Positioning Systems, GPS）、北斗卫星导航系统（Beidou Satellite Navigation System, BDS）等。基于卫星的定位导航系统在室外定位导航中占据了主导地位，而且其发展状况日趋完善。但当用户携带移动终端进入室内时，由于可见的卫星数量少，无法提供基于卫星的定位导航服务。因此，基于室内定位系统（Indoor Positioning Systems, IPSs）服务的需求也越来越迫切。

从目前情况来看，已有多种基于不同方式的 IPS，包括：基于红外信号的 Active Badge 系统<sup>[3~4]</sup>、基于超声波的 Active Bat 系统<sup>[3~4]</sup>、基于视频图像<sup>[5]</sup>、基于射频（Radio Frequency, RF）信号<sup>[6~15]</sup>等室内定位系统，典型的室内定位系统如表 1-1 所示。基于 RF 的典型 IPS 代表有：基于 RFID 的 LANDMARC 系统以及众多 WILS，如 RADAR 系统、HORUS 系统。WILS 的优越性在于可以利用已有的基础设施来完成室内定位系统的构建，并不需要增加硬件设备；对于移动终端来说，目前很多智能手机上都有 WiFi（Wireless Fidelity）接入模块，可以方便地接收不同 WAP 的信号强度值。正是这一优点，使得 WILS 越来越流行。

表 1-1 典型 IPS 的技术指标

室内定位技术	典型定位精度	典型覆盖范围 (m)	典型定位方法	典型应用
基于视觉	mm~dm	1~10	三角测量	计量学，机器人导航
基于红外线	cm~m	1~5	信标信号/ 热成像	人体检测，跟踪
基于接触式技术	μm~mm	3~2000	机械式定位	计量学，车载定位
基于声学（可闻）	cm	2~10	到达时间	医院，跟踪
基于 WLAN/WiFi	m	20~50	指纹定位	行人导航，LBS
基于射频识别	dm~m	1~50	近邻检测	行人导航

续表 1-1

基于超宽带	cm~m	1~50	到达时间/ 无线反射	机器人及车载导航
基于高敏感 GNSS	10 m	全球	并行相关/ 增强型 GPS	LBS
基于伪卫星	cm~dm	10~1000	载波相位测距	无 GNSS 覆盖的矿区
基于其它无线技术	m	10~1000	指纹定位/ 近邻传播	行人跟踪
基于惯性导航	1%	10~100	航迹推测法	行人导航
基于地磁系统	mm~cm	1~20	指纹定位/测距	医院, 矿区
基于基础设施 (Infrastructure System)	cm~m	仅限于某 一建筑	指纹定位	生活辅助及改善

本文主要针对基于 WLAN 室内定位系统中存在的 Radio Map 的建立的时间效率低、RSS 处理及定位方法多样且通用性差的问题, 采用基于流形对齐算法的实现 WLAN 室内中的 Radio Map 的建立, 并基于该方法实现 WLAN 室内定位, 从而通过流形对齐方法实现对 Radio Map 建立及定位方法的统一。通过将本文提出方法应用于不同的定位环境, 从而来验证这一方法的通用性。因此, 本文的目的与意义主要包含三个方面:

### (1) Radio Map 的快速高效建立

在 WILS 中, Radio Map 的建立主要包括两个部分: 参考点的坐标的标识及各个参考点处 WAP 的 RSS 的采集。从目前的情况来看, 参考点的坐标标识都是手动标识, 特别是室内办公环境中。由于在室内环境中, 缺少有效的 I-GIS 的支持, 使得大范围应用 WILS 产生了困难。手动标识的坐标通常都是一个楼层的相对坐标, 甚至对于每个位置只是一个简单的序号, 并没有达到地理坐标系统的要求, 也无法与目前的经纬度相对应。因此, 提高参考点坐标标识的有效方法就是建立有效的 I-GIS 数据库, 从而建立室内定位地图。这一方式可以从两方面改善 WILS 的性能: 一是可以有效地解决参考点的坐标标识的问题; 二是可以使得基于 WILS 的应用更为方便。基于 WILS 的应用必不可少的就是室内地图。有了室内地图, 可以使得 WLAN 室内定位导航更好地提供基于位置服务。

Radio Map 建立的第二部分, 也是最为关键的部分就是 RSS 的采集。其工作量的取决于: 参考点 (Reference Point, RP) 的数目, WAP 的数目, RSS 重

采样次数。参考点的数目通常是可变的，取决于对于定位精度的要求，通常是可控的因素。而 WAP 的数目要求取决于 WILS 中可见的接入点的数目。但是对于 RSS 的采集来说，这一点并不可控。可见的 WAP 的数目并不可以由采集软件来限制，因为这会影响整个系统应用。WAP 的数目由 WLAN 通信系统的通信要求（Quality of Service, QoS）决定。WILS 的优势在于不影响 WLAN 通信系统正常通信要求下实现室内定位的功能。

现有的数据表明，在一个 WLAN 通信系统覆盖的区域内，WAP 的数量和密度（单位面积内可接入 WAP 的数目）均呈指数级的增加<sup>[16]</sup>，从而保证为更多的用户提供服务。通常情况下，为了满足良好的通信质量，WAP 部署的数量大大地超过了区域覆盖的要求。例如，微软总部更是在其公司所在科技园区内部署了近 5000 个 WAP<sup>[17~18]</sup>。这一种冗余部署使得可见的 WAP 远远超过了 WLAN 室内定位系统本身所需要的 WAP 的数目，使得 Radio Map 采集工作量大大增加。

各个 RP 处采集 RSS 样本数也决定了 Radio Map 建立的工作量。以哈尔滨工业大学科学园 2A 栋 12 楼所部署的 WLAN 室内定位系统（HIT-WILS12）为例，实验环境为走廊，面积约为 260 m<sup>2</sup>，参考点数目为 900，部署 WAP 的数目为 27 个，满足区域内通信要求。对每个参考点从四个不同的方向共采集 400 个 RSS 样本，其工作量为一个月（每天 8 小时，不包含后期数据处理、参考点的标识及 WILS 的部署等工作量）。当参考点数和 RSS 采样数增加时，Radio Map 的采集和参考点的标识的工作量呈指数增长。当 WAP 数量远远冗余时，大量的参考点及 WAP 会导致对于 RSS 数据的后期处理会花费大量的时间。以上因素都会导致 Radio Map 建立的工作量增大。

为了提高 Radio Map 建立的效率，本文采用基于流形对齐算法，并结合 WILS 的定位区域中参考标识的分析方法，提出一种基于半监督的流形对齐的快速建立 Radio Map 的方法。

## （2）WLAN 室内定位方法普适性

从数学方法来分，WLAN 室内定位方法主要有两大类：确定型方法与概率型方法。确定型方法主要是以近邻点法，如最近邻点法（Nearest Neighbor, NN）、 $k$ -近邻点法（ $k$ -Nearest Neighbors, KNN）及加权  $k$ -近邻点法（Weighted  $k$ -Nearest Neighbors, WKNN）等。概率型方法则以最大后验概率为核心，包括最大似然法（Maximum Likelihood, ML）及朴素贝叶斯（Naive

Bayesian, NB)。

而 WILS 的 Radio Map 的建立方法主要是滤波及奇异值处理。解决这一问题的方法主要包括：插值及自相关滤波等。从 Radio Map 的建立的方法来看，除了大量采用手动建立之外，还有基于插值、基于可移动计算平台，如智能手机，以及基于多传感器平台。以上这些方法都没有应用于 WILS 中。

将 Radio Map 建立与定位方法联合的方法很少，典型的是基于智能平台的多传感器的粒子滤波方法<sup>[19]</sup>以及基于压缩感知 (Compressive Sensing, CS) 方法的 WLAN 室内定位方法<sup>[20]</sup>。前者主要是基于智能手机的多种传感器器件，包括：加速度计、电子罗盘、WiFi 模块等器件实现对 Radio Map 建立，并通过粒子滤波 (Particle Filtering, PF) 方法实现定位。总的来说，这是一种概率型定位方法，其定位过程复杂、需要有先验概率并且定位精度不足。后者是采用压缩感知方法实现定位，其中包括在稀疏 Radio Map 条件下对 Radio Map 进行重建，其 Radio Map 重建与 WLAN 定位方法均采用压缩感知方法。这种方法重建 Radio Map 的要求有一个原始的 Radio Map。基于 CS 方法的 Radio Map 的快速建立是一种半监督方法。由于压缩感知算法的过程较为复杂，且在线阶段与离线阶段的复杂度有着较大的差别，且在线阶段的数据处理过程多于离线阶段，导致在线定位的实时性下降。

针对目前这一现状，本文提出一种基于流形对齐的 WLAN 室内定位与 Radio Map 的建立均可以采用的方法，且主要的工作集中在离线阶段。离线阶段通过流形对齐方法实现对 Radio Map 的特征提取及 RSS 与位置之间的映射向量提取。在线阶段，通过测试所得的 RSS 以及特征映射向量实现 WLAN 室内定位及 Radio Map 的重建。

## 1.2 室内定位系统及其定位方法的研究现状

如同 GNSS 两大关键部分，IPS 同样包括两大部分：硬件基础以及其定位方法，以下分别对室内定位系统及室内定位方法的研究现状进行概述。

### 1.2.1 室内定位系统研究现状

与 GNSS 的成熟应用不同，室内定位导航系统既有优势，又面临的复杂的应用环境的挑战。一方面，室内定位系统的覆盖区域通常比室外定位系统小得多，通常是对建筑物覆盖，或者仅对室内的某一楼层或若干楼层进行覆盖；室

内的气流循环较慢，温度差别小，定位系统受到“气候”因素影响小；地理环境相对单一，通常的平面或者垂直墙面；易于部署定位所需要的设备；并且行动终端的运动速度相对较慢。另一方面，室内环境狭小，通常导致复杂的多径效应以及信号的反射、透射及衍射现象；室内环境墙体材料及结构复杂，造成严重的非视距（Non Line of Sight, N-LoS）现象；室内的物品等偶然导体对 RSS 有极大衰减；并且室内行人及环境的部署变化很快，导致室内的信号波动大；并且室内定位范围小，位置估计的精度要求高。

目前室内定位系统通常都需要额外部署相应的设备，包括基于视觉室内定位技术，如基于图片匹配的室内定位<sup>[21~23]</sup>，通常用于机器人导航的 SLAM（Simultaneous Localization and Mapping, SLAM）技术、基于已编码标记<sup>[24~25]</sup>、基于投影标记的 CLIPS（Camera and Laser based Indoor Positioning System, CLIPS）系统<sup>[26]</sup>；基于红外信号的 Active Badge 系统<sup>[3~4]</sup>；基于超声波的 Active Bat 系统<sup>[3~4]</sup>；基于接触式及极化系统的室内定位系统，其设备包括激光扫描、激光跟踪、激光雷达等，其价格昂贵，精度较高，并不适用于普通的场景<sup>[27~29]</sup>；基于 RFID 技术的 LANDMARC 室内定位系统等。上述这些系统都需要增加额外的基础设施以达到室内定位的目的，因此并没有得到广泛的应用。

另一类受到的广泛应用的 IPS 是 WILS。这一类室内定位系统可以直接使用目前广为应用的 WAP 以及智能移动终端的 WiFi 模块，因而受到许多研究人员的关注。从国内外研究现状来看，WILS 都有许多研究机构在进行研究。从国外的情况来看，最早研究 WILS 都有微软公司和马里兰大学。这两所大学分别提出的 RADAR 室内定位系统<sup>[6]</sup>及 HORUS 室内定位系统<sup>[8]</sup>。这两个系统分别采用 WLAN 室内定位系统中最为典型的两种定位方法：KNN 及 MAP 方法。随着 WLAN 通信系统以及智能移动终端的普及，WILS 逐渐的开始商业应用。2008 年，以谷歌等为十几家通信公司组成的室内定位联盟，明确指出 WILS 将要商业运营。从目前的发展情况来看，商业 WLAN 指纹定位系统有 Skyhook 公司提出的 XPS WLAN 指纹定位系统，为密集型商业区提供精度可达 10~20 米的 WLAN 室内外定位服务，但其室内定位精度不够高<sup>[30~31]</sup>；以及 Ekahau 公司提出的 Ekahau 实时定位系统，其室内跟踪定位精度可达 1~3 米<sup>[32]</sup>。目前，苏黎世联邦理工大学、多伦多大学以及新南威尔士大学等国外高校都在研究 WILS 的进一步应用。

从国内的研究情况来看，国内同样有多所大学对基于 WLAN/WiFi 的室内定位系统进行了大量研究，包括香港科技大学（HKUST）、北京交通大学、北京航空航天大学、清华大学及哈尔滨工业大学等。与国外的研究相比，国内的起步较晚，目前并没有商业应用的 WILS。

### 1.2.2 室内定位方法研究现状

室内定位系统可以采用的方法与室外卫星定位导航系统可以采用的方法大部分都相似。IPS 采用的定位方法通常与其测量的参数息息相关。目前室内定位系统中常测量的指标包括：到达时间（Time of Arrival, TOA/Time of Flight, TOF）、到达时间差（Time Difference of Arrival, TDOA）、环路时延（Round Trip Time, RTT/Roundtrip Time-of-Flight, RToF/Two Way Ranging, TWR）、到达相位（Phase of Arrival, POA/Phase Difference, PD）、近地电磁分布（Near-Field Electromagnetic Ranging, NFER）、到达角（Angle of Arrival, AOA/Direction Based Positioning）以及多普勒频移（Doppler Ranging）<sup>[33]</sup>。

最为常见的近似法（Proximity of Detection, PoD/Cell of Origin）。这种方法几乎适用于所有测量方式，其定位方式是未知位置取决于最佳信号源的位置。与之相似的是中心点定位（Centroid Determination），其定位结果为多个参考源的位置的平均。与室外定位方法相似的是三角定位法（Triangulation）。根据信号测量结果，直接得出未知位置与信号源的距离，并采用三角关系定位。极点法（Polar Point Method）是将测距与测角的方式相组合，其复杂度较高。目前 WILS 中应用最为广泛的是基于位置指纹的定位方法（Fingerprinting/ Scene Analysis/Pattern Matching）。这种方法是通过已有的测量变量与未知位置测量进行匹配分析，从而得出最佳的定位结果。另外三种常见方法是：航迹融合（Dead Reckoning, DR）、卡尔曼滤波方法（Kalman Filtering, KF/Extended Kalman Filtering, EKF）及地图匹配（Map Matching, MM）<sup>[33]</sup>。

### 1.3 Radio Map 建立方法的研究现状

WILS 大多数均采用基于位置指纹的定位方法，如 RADAR 及 HORUS 系统。这一种方法分为两个：离线阶段及在线阶段。离线阶段最为重要工作是建立位置指纹数据库，即 Radio Map。目前 Radio Map 的建立包括三大类：手动建立、半手动建立和全自动建立（又分别称为监督、半监督、无监督方法）。



这三类方法的主要工作都采集室内定位区域的参考点的坐标及各个参考点接收到的 WAP 的 RSS。

### 1.3.1 手动建立 Radio Map 方法研究现状

手动建立 Radio Map 的过程如下：首先，在室内定位区域内部署足够的 WAP 并标记出相应的参考点。虽然 WILS 是利用已有的 WAP 来进行定位，但就目前而言，用于室内定位的 WAP 都是预先部署，并不能直接应用所有的 WAP。第二步，采集各个参考点上的接收到的 WAP 的 RSS 值，一般采集四个不同方向的 RSS。通常后者的工作量远远大于前者。手动建立 Radio Map 是一个费时且采样准确度受限的工作。以 HIT-WILS12 系统为例，其实验环境为走廊，其面积约为  $260\text{m}^2$ ，参考点数目为 900，部署 WAP 数目为 27 个，满足区域内通信要求。对每个参考点从四个不同的方向共采集 400 个 RSS 样本，其工作为一个月（每天 8 小时，不包含后期数据处理、参考点的标识及 WLAN 室内定位系统的部署）。

由于设备、环境的动态变化及人体遮挡等因素的影响，手动采集的 Radio Map 并不是很精确。而且由于建立的时间太长，不同时段测试的 RSS 的环境并不相同。这些因素都会导致 Radio Map 的误差。但是由于缺乏适当的方法来改变现状，目前手动建立 Radio Map 仍然广泛采用。

### 1.3.2 Radio Map 的无监督建立方法的研究现状

Radio Map 的无监督建立方法是有效地提高 Radio Map 建立效率的方式之一。其主要思路是结合智能移动终端的惯性导航等传感器、WiFi 模块、额外的测绘设备等，实现对 Radio Map 的自动建立。

文献[34]中，Kim 等提出了一种基于改进的 RSS 室内传播模型的 Radio Map 的无监督建立方法，这一方法中包括了稀疏参考点的测量的卡尔曼滤波以及基于克莱金（Kriging）算法的位置指纹数据的密集处理。其 RSS 的测量采用了文献[35]中提出用户辅助（Client-Assistant, CA）方式。这种方式的测量效率高，但带来的问题是多种不同的设备采集的 RSS 数据并不一致，特别是由于硬件的灵敏度不同。

另外几种无监督方式建立 Radio Map 的方法均基于惯性器件（Inertial Devices）及额外的硬件设备。文献[19]及[36]中提出了采用移动终端的惯性器

件建立 Radio Map 的算法。前者仅研究 Radio Map 的建立，并没有考虑定位方法，后者在改进 Radio Map 采集的基础上，分析了不同房间内的 Radio Map 的衰落特征，提出一种基于 Radio Map 衰落特征的定位方式，其精度可以区分每个房间。Scholl 等提出另外一种基于惯性器件与其它硬件设备相结合的 Radio Map 的建立方法<sup>[37]</sup>。这一种方法同样是结合智能移动终端的惯性等传感器、WiFi 模块、额外的测绘设备等，实现 Radio Map 的建立，同时可以对室内建筑环境进行测绘，得到室内定位区域的建筑结构图。但是以上方法采用了诸如激光扫描等高精密设备，导致可应用这一方法范围狭窄。

Radio Map 的无监督建立方法是一种工作量最小的方法，但这种方法的缺点是 Radio Map 的精确度低。但这是一种可以选择方案。本文中除了采用人工方式采集 Radio Map，也会采用智能移动终端测试 Radio Map 并验证算法的有效性。

### 1.3.3 Radio Map 的半监督建立方法的研究现状

为了减少建立 Radio Map 的工作量，同时保证 Radio Map 的准确度，国内外许多学者提出了采用半监督方法建立 Radio Map，主要从稀疏的 Radio Map 中得出高密度 RP 的 Radio Map。

文献[38~39]主要从减少参考点的数目以及每个参考点的 RSS 重采样数入手，从而降低 Radio Map 建立的工作量。二者均通过插值的方法从稀疏的 Radio Map 中重建其它未采样参考点处的 RSS 值。不同之处在于：[38]采用的是基于核函数的插值（Kernel Based Interpolation）方法来重建 Radio Map，而[39]采用的是线性插值（Linear Interpolation）方法来重建 Radio Map。但通过插值方法得出的 Radio Map 精度都不高。后者结合隐马尔科夫模型（Hidden Markov Model）挖掘已采样参考点与未采样参考之间的关系。而文献[40~42]分别从概率估计的角度进行 Radio Map 的重建。其中[40]采用是层次化贝叶斯估计模型（Hierarchical Bayesian Model）将标记的 RSS 及参考点的特征推广至未采样 RSS 的参考。另两篇文献采用的标签传播（Label Propagation）学习已标记 RSS 与未标记 RSS 之间的映射关系，从而实现 Radio Map 重建。虽然上述算法都可以重建 Radio Map，但这些算法并没有用来实现室内定位。

另外两篇值得一提的有关于 Radio Map 建立文献均来自于多伦多大学。冯晨等在文献[20]提出了基于 CS 的 WLAN 室内定位方法及 Radio Map 重建方

法。其定位及 Radio Map 的重建过程都归结为  $l$ -范数最优化问题。在定位过程中，定位描述为稀疏 RSS 的重构问题，因而 WILS 仅根据移动终端的少量 RSS 测试，应用 CS 原理及  $l$ -范数最小化求解实现位置估计。Radio Map 的重建过程是：将来自每个 WAP 的 RSS 视为一张二维图像，根据稀疏 RP 处的 RSS，利用 CS 理论及  $l$ -范数最小化的求解实现 Radio Map 的重构。

另一篇文献是 Sorour 等基于流形对齐提出的 Radio Map 的快速建立方法<sup>[43]</sup>。Sorour 等提出基于室内传播模型的密集 RSS 实现对 Radio Map 的建立。首先对室内定位区域进行室内传播模型建模，预测不同位置点上的 RSS 值，然后通过流形对齐来学习 RSS 与参考点之间的特征映射关系。最后根据流形对齐特征矩阵变换实现 Radio Map 的建立。但这篇文献的缺陷在于：室内传播模型并不明确。采用室内传播模型估计时，对室内定位区域的建筑特征、建筑材料与区域内 WAP 的个数及位置要求很高。实际上，这三点都不能明确，因此预测得到的 RSS 精度很低，不符合室内区域的实际特征。另一不足在于文献中并没对得出的 Radio Map 进行室内定位测试及流形对齐方法定位/更新测试。在文献<sup>[44]</sup>中，孙卓等采用 LuMA 算法解决不同设备采集的 RSS 的融合与更新的问题，其核心方法为流形对齐。但这一种更新方式要求有完整的 Radio Map 为学习样本，导致这种方法并未广泛使用。

从已有的 Radio Map 的半监督建立方法来看，流形对齐是一种可以实现 Radio Map 快速建立的方法，但有一些有待解决的问题，包括：（1）如何使用 RSS 指纹数据与流形对齐算法进行 Radio Map 的重建；（2）如何采用流形对齐实现 WILS 的室内定位。本文将从流形对齐方法出发，解决上述问题。

## 1.4 流形对齐的研究现状

流形对齐 (manifold alignment, MA) 是一种广泛应用于机器学习、数据挖掘及特征提取等领域的高维数据处理方法<sup>[45~46]</sup>，可以实现分离数据空间的对齐与特征映射。现有的流形对齐方法可以分为无监督流形对齐 (unsupervised manifold alignment, USMA) 与半监督流形对齐 (semi-supervised manifold alignment, SSMA)。USMA 方法包括基于流向图的流形对齐<sup>[47]</sup>及基于普式分析 (Procrustes Analysis, PA) 的流形对齐<sup>[48]</sup>。这类流形对齐算法的实现包括两个过程：首先采用降维算法，如主成分分析法 (Principle Component Analysis, PCA)、局部线性嵌入 (Local Linear Embedding, LLE)、等距映射 (Isometric

Mapping, ISOMAP) 等, 对高维数据进行维度分析; 然后对降维的数据集的特征空间进行匹配, 从而实现流形对齐。

第二类对齐算法包括半监督对齐 (Semi-supervised Alignment, SA)<sup>[45]</sup>、流形投影 (Manifold Projection, MP)<sup>[49]</sup>和半正定对齐 (Semi-definite Alignment, SDA)<sup>[50]</sup>。半监督对齐首先创建代表给定流形的联合流形, 然后将联合流形映射到一个低维空间, 并保持每个流形的局部几何, 然后实现流形对齐。半正定对齐解决类似的问题, 采用半正定算法, 并非奇异值分解算法。而流形投影的线性近似实现的半监督对齐方法。

本文将采用流形对齐算法实现 WILS 的 Radio Map 的快速建立及室内定位。通过结合无监督与半监督型流形对齐方法, 分多步实现不同 RSS 空间、地理坐标空间的特征映射, 从而实现 Radio Map 的建立及其室内定位。

## 1.5 本文研究结构及主要内容

本毕业论文主要针对 WILS 中存在的 Radio Map 建立时间效率低、RSS 处理及定位方法多样且通用性差等问题, 提出基于 MA 算法实现对 Radio Map 的快速建立并采用改进后的 MA 算法实现室内定位。本文从基本理论分析入手, 奠定理论基础; 然后根据理论分析, 提出基于 MA 的 WLAN 室内定位方法、Radio Map 建立的应用方案及理论分析; 再对已有的 WLAN 室内定位系统进行实际测量, 包括定位区域内的 RSS 采集、多平台 Radio Map 的分析; 最后对本文提出的 Radio Map 快速建立及室内定位方法的性能进行仿真分析。

本文的研究方案如图 1-1 所示, 分为四个层次: 第一, 基本理论研究, 包括流形对齐理论、多流形对齐理论及维度变换理论, 其研究目标为: 实现对流形对齐算法理论的深入了解, 分析维度变换理论, 并基于 MATLAB 实现算法; 第二, 基于流形对齐方法的 WILS 的理论分析与算法实现, 包括基于流形对齐方法的 WLAN 室内定位方法及 Radio Map 建立方法并得出相应的应用方案; 第三, 分析 HIT-WILS10/12 的部署方案, 并采用多种终端采样 RSS, 建立算法性能分析所需要的 RSS 数据库及 Radio Map 数据库; 第四, 根据实测数据及 MATLAB 对 Radio Map 快速建立及室内定位方法进行性能分析。

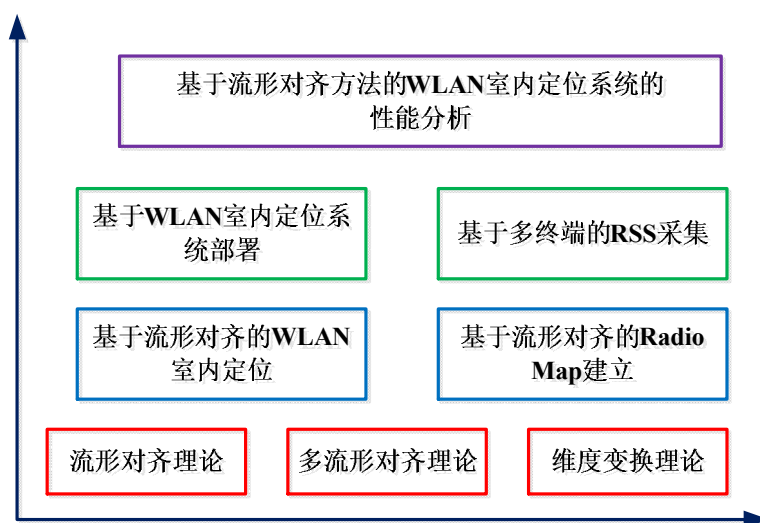


图 1-1 本文研究方案

本文篇章结构如下：

第 2 章对一个典型的 WILS 的各个组成部分进行了分析。首先对 WILS 的基本结构、组成部分及功能实现进行了概述，然后以 FLA 为例，对 WILS 的工作流程进行了说明。然后分别对 WILS 中的关键技术：定位方法及 Radio Map 的建立进行了分析。在对比确定型及概率型指纹定位方法后，本文采用以 KNN 为代表的确定型指纹定位算法进行系统性能分析的定位方法。本章重点对 Radio Map 的建立过程进行了分析，并以目前 HIT-WILS10 及 HIT-WILS12 等两个 WLAN 室内定位系统为实验环境，采用联想 V450、OPPO T29、Google Nexus 5 及 Samsung Note II 等四种不同的终端采集了 Radio Map 及性能测试数据库，并对其特征进行了分析。为改进 KNN 算法的定位性能及在流形对齐中的应用，本章提出了 AP-KNN 算法并对其性能进行了对比分析，为后文的整体性能分析奠定了基础。

第 3 章首先流形的基本理论进行了简单的介绍，明确了微分流形、黎曼流形及等距流形的基本数学条件，并定义了流形距离衡量及流形学习。然后介绍了 LLE、ISOMAP、LDE 及 SDE 等四种常用的流形学习方法的基本理论及其实现过程，为后续统一耦合度量流形对齐方法的分析奠定了理论基础。接下来分析了耦合度量学习及流形对齐方法的基本概念，并对流形对齐中对应关系的实现进行了详细分析。从基于相关关系及 Fisher 准则的耦合度量学习方法出发，对耦合度量学习的理论及实现过程进行了分析，并采用了奇异值分解方

法实现特征变换过程的优化求解。在此基础上，推导出了统一耦合度量学习方法，从而将耦合度量学习方法推广至多类不同数据集的耦合度量学习及流形对齐方法。本章实现了从物理空间与 RSS 信号的对应关系重建出稀疏 Radio Map 的超分辨率分析理论及算法流程。本章提出的 UCML-MA 及 MA-SRA 算法将应用于 HIT-WILS10 及 HIT-WISL12 等基于 WLAN 的室内定位系统中

第 4 章在第 3 章的理论分析的基础上，首先对 HIT-WILS10 及 HIT-WILS12 等两个典型室内环境内部署的 WILS 进行了描述，并对本文采用的多种测试方法及终端进行简要的说明。结合 WILS，本章提出了基于流形对齐的 Radio Map 的建立方法及基于流形对齐的 WLAN 室内定位方法，并在此基础上提出了两种 WLAN 室内定位方法：DML 及 reKNN。根据不同的终端、不同环境的实测的 RSS 及 Radio Map，分析了本文提出的 Radio Map 建立及室内定位方法的性能。仿真表明，本文提出的基于流形对齐的 Radio Map 建立及定位方法可以在大幅度降低（至少降低一倍工作量，最高可达 16 倍）Radio Map 建立的工作量前提下，有效地保持定位算法的性能，并对不同系统及移动终端有良好的适应性。

## 第2章 WLAN 室内定位系统概述

从系统组成来看，WILS 中包括用户终端、覆盖定位区域的无线接入点及定位所用服务器；从功能模块来看，基于匹配定位的 WILS 核心模块为：定位方法及 Radio Map 的建立。以 KNN 为代表的确定型指纹定位算法是一种常用的室内定位方法，也将作为性能分析的基础算法之一。本章重点分析 RSS 的室内传播模型及数据库的建立过程，并以目前 HIT-WILS10 及 HIT-WILS12 等两个 WILS 为实验环境，采用联想 V450、OPPO T29、Google Nexus 5 及 Samsung Note II 等四种不同的终端建立 Radio Map 及测试灵气，并对其特征进行分析。同时，为改进 KNN 算法的定位性能及在流形对齐背景下的应用，本章提出 AP-KNN 算法，为后文的整体性能分析奠定了基础。

### 2.1 WILS 的组成及其实现流程

#### 2.1.1 系统结构

基于位置指纹的 WILS 主要由三部分组成：用户终端、WAP 及定位服务器（Localizing Servers, LSs），该系统如图 2-1 所示。

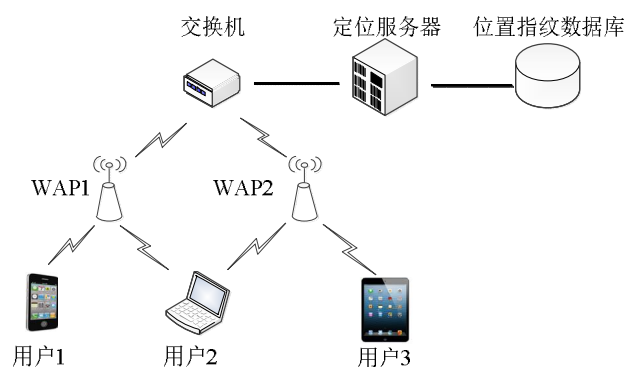


图 2-1 基于位置指纹的 WILS

(1) WAP: 定时发送带有 RSS 的信标帧，广播当前无线网络的状态，定位终端通过接收信标帧，测量各 WAP 的 RSS 值，从而 Radio Map，并根据 RSS 实现在线阶段的位置估计。

(2) 用户终端: 包括 PDA、手机、笔记本电脑等带有 WiFi 模块的便携式移动设备。用户终端可以接收来自 WAP 的 RSS，并可以通过 WAP 接入 Internet。在线阶段中，用户终端通过测试待定位处各个 WAP 的 RSS，采用匹配

算法处理，实现位置估计。

(3) LS: LS 具有储存及定位等功能。用户终端接收到的 RSS 等信息发送至 LS, LS 运用定位算法实现 RSS 与 Radio Map 的位置估计, 再将定位结果发送至待定位用户终端, 从而实现定位服务。同时, 用户终端也可以与 LS 通信, 从而给用户提供基于位置的服务。

### 2.1.2 系统工作流程

基于位置指纹的 WILS 主要可以分为两个阶段: 离线阶段 (offline stage) 和在线阶段 (online stage) 如图 2-2 所示。离线阶段的主要工作是: 建立 RSS 与各个 RP 组成的 Radio Map。首先在室内定位环境中确定 RP 的密度, 然后采样所有 RP 处各个 WAP 的 RSS, 存储于 Radio Map 中。在线阶段的核心工作是: 实现待定位用户的位置估计。位置估计可以有两种方式: 第一, 基于 LS 定位; 待定位用户通过接收不同 WAP 的 RSS, 然后将 RSS 上传至 LS, LS 运用定位算法实现 RSS 与 Radio Map 的位置估计, 再将定位结果发送至待定位用户终端; 第二, 基于用户终端定位; 待定位用户通过 LS 下载相应定位区域的 Radio Map。在线定位时, 用户通过接收不同 WAP 的 RSS, 在本地使用特征匹配算法实现定位。

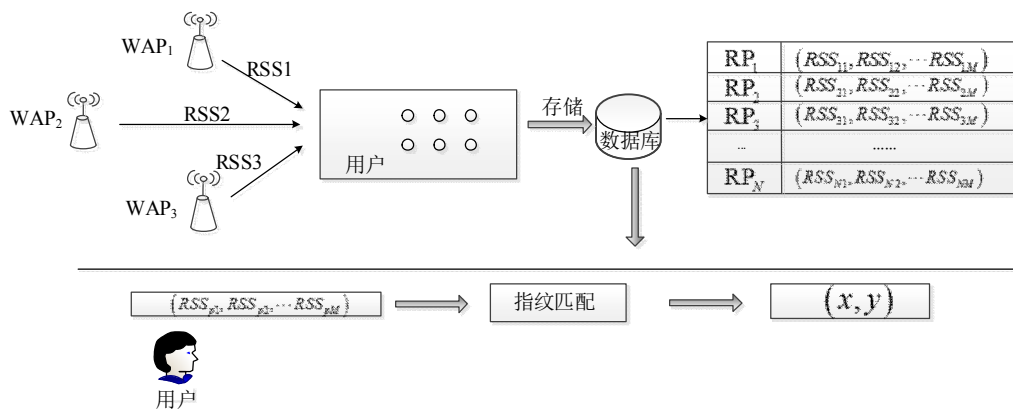


图 2-2 基于位置指纹的 WILS 的实现流程

## 2.2 WLAN 室内定位方法

从目前基于位置指纹的 WLAN 室内定位方法 (Fingerprint based localization algorithms, FLAs) 来看, 可以分为两类: 一类是确定型算法, 即定位过程中不考虑 Radio Map 的概率分布, 仅通过比较 RSS 信号空间的特征来实现定位, 包括最近邻法 (Nearest Neighbors, NN)、KNN、WKNN。另一方法是概率型算



法，即通过对 RSS 空间的分布进行概率统计，采用最大后验概率等方法实现室内定位，包括朴素贝叶斯法、最大似然概率法。

### 2.2.1 确定型 FLA 算法

基于 Radio Map 的 FLA 方法是通过在线阶段的 RSS 与离线阶段的 Radio Map 的特征匹配实现位置估计。FLA 方法通过计算在线阶段的 RSS 与离线阶段的 Radio Map 的欧氏距离 (Euclidean Distance, ED)，抑或估计相似度最高的  $k$  个 RSS 及其对应的 RPs。本节对 NN, KNN 及 WKNN 算法等三种方法基本原理进行分析。近邻法通过计算在线阶段 RSS 与离线阶段的 Radio Map 的 ED，寻找  $k$  个 ED 最小的 RP 的物理坐标的均值实现位置估计。

#### (1) NN

NN 算法是 FLA 方法中的基本算法之一。这一方法通过计算在线 RSS 与 Radio Map 中各 RP 的 RSS 的 ED，并得出与在线阶段 RSS 的 ED 最近的 RP 的物理坐标，以此作为待定位用户位置的估计。采用式(2-1)所示计算该 TP 与各个 RP 的 ED，选择 ED 最小的 RP 的物理坐标作为 TP 的位置的估计。

$$d_{gp} = \left( \sum_{i=1}^M |RSS_{gi} - RSS_{pi}|^2 \right)^{1/2} \quad (2-1)$$

其中  $d_{gp}$  表示测试点  $p$  与参考点  $g$  之间的欧式距离。第  $p$  ( $p=1,2,\dots,P$ ) 个测试点 (Test Point, TP) 测得  $M$  个 WAP 的 RSS 为  $RSS_p = (RSS_{p1}, RSS_{p2}, \dots, RSS_{pM})$ ,  $P$  代表参考点总数。Radio Map 数据库中，第  $g$  ( $g=1,2,\dots,N$ ) 个参考点的 RSS 为  $RSS_g = (RSS_{g1}, RSS_{g2}, \dots, RSS_{gM})$ 。

#### (2) $k$ NN

KNN 是 NN 方法的改进算法。其基本思想是在 Radio Map 中匹配出与在线阶段 RSS 的  $k$  个最近的 RP，然后根据  $k$  个最近 RP 的物理坐标的平均得到待定位用户位置的估计值。KNN 算法定位过程如下：

(a) 建立 Radio Map: 在离线阶段，对每个 RP 处测量的  $n$  次 RSS 取平均 (本文中以单次测量为主)，得到一个  $1 \times (M+2)$  的向量，其中前两个元素代表 RP 位置坐标 ( $x-y$ )，剩下的元素代表在该 RP 处来自  $M$  个 WAP 的 RSS 均值；

(b) 计算第  $p$  个 TP 的 RSS 与第  $g, g=(1,2,\dots,N)$  个 RP 的

RSS( $RSS_{g1}, RSS_{g2}, \dots, RSS_{gM}$ )之间的欧氏距离  $d_{gp}$ , 计算公式如式(2-1)所示:

(c) 从 (b) 中得到的  $N$  个  $d_{gp}$  中选择  $k$  个与 TP 的 RSS 距离最小的 RPs。根据  $k$  个参考点的坐标, 采用式(2-2)所示估计 TP 的坐标, 式中  $(x_p, y_p)$  代表第  $p$  个测试位置点的估计值,  $(x_g, y_g)$  代表第  $g$  个参考点的物理位置坐标。

$$(x_p, y_p) = \frac{1}{K} \sum_{g=1}^K (x_g, y_g) \quad (2-2)$$

### (3) WkNN

考虑到 KNN 方法中边缘 TP 的定位性能差, WKNN 以在线阶段 RSS 与 Radio Map 的 ED 倒数的归一化作为权值, 从而估计在线阶段 TP 的物理位置。WKNN 方法的前两个步骤均与 KNN 相同, 仅在计算在线阶段 TP 的估计坐标时引入归一化权值, 如式(2-3)所示。其中  $d_{gp}$  表示在线阶段 RSS 与 Radio Map 中第  $g$  个 RP 之间的 ED。

$$(x_p, y_p) = \frac{1}{K} \sum_{g=1}^K \left( \frac{1/d_{gp}}{\sum_{g=1}^K 1/d_{gp}} x_g, \frac{1/d_{gp}}{\sum_{g=1}^K 1/d_{gp}} y_g \right) \quad (2-3)$$

## 2.2.2 概率型 FLA 算法

概率型 FLA 方法的核心思想: 根据在线阶段接收到的 RSS, 计算其最大条件概率或最大后验概率, 以最大后验概率所对应的 RP 的位置作为定位结果。以最大后验概率定位方法为例, 对概率型位置指纹定位算法理论进行分析。

在线阶段, 记第  $i$  个测试点接收到  $M$  个无线接入点的 RSS 值为:  $RSS_i = [RSS_{i1}, RSS_{i2}, \dots, RSS_{iM}]$ , 其位置坐标记为  $P_i$ 。其目标函数可以表示为:

$$P_i = \arg \max p(P | RSS_i) \quad (2-4)$$

根据贝叶斯公式, 其后验概率计算可以转化为先验概率, 如式(2-5)所示。

$$p(P | RSS_i) = \frac{p(RSS_i | P) p(P)}{\int_D p(RSS_i | P) p(P) dP} \quad (2-5)$$

通过已建立的 Radio Map, 通过对其分布及概率统计分析, 可以计算先验

概率。这一方法也由加州大学洛杉矶分校的研究人员应用于 Nibble 室内定位系统。从定位方法的性能来说，概率型定位方法一般要求离线阶段对每个 WAP 进行大量采样，即建立长时的 Radio Map。建立 Radio Map 的工作量大，且在线阶段定位的计算复杂度高，一般需由在服务器实现定位，不适用于移动终端的实时定位解算。

## 2.3 Radio Map 的建立及其特征

本节重点对 Radio Map 的建立过程进行了分析，并以目前 HIT-WILS10 及 HIT-WILS12 等两个 WLAN 室内定位系统为实验环境。采用联想 V450、OPPO T29、Google Nexus 5 及 Samsung Note II 等四种不同的终端采集 Radio Map 及 RSS，并对其特征进行分析。

### 2.3.1 基于固定终端的 Radio Map 特征分析

根据固定终端联想 V450，在 Windows XP SP3 操作系统下安装 Netstumbler 软件对 HIT-WILS12 系统所在室内定位区域的 RSS 的采样结果，可以得到走廊区域内 Radio Map 特征。




图 2-3 固定 RP 处某 WAP 的 RSS 值及统计概率图

由于 Radio Map 所存储的是各个 RP 处的来自不同 WAP 的 RSS。在室内定位区域中，由图 2-3(a)可知在同一 RP 处的来自同一 WAP 的 RSS 呈现时变性。为提高室内定位的准确率，应适当地增加待定位区域内 RP 的数目。待定位区域中 RP 数目增加时，Radio Map 也将成指数形式增长，导致匹配定位的实时性能下降。如图 2-3(b)所示为图 2-3(a)的 RSS 分布的统计，通过在某一

RP 处多次测量从同一 WAP 的 RSS，分析 RSS 特性可得出该 RP 处 WAP 的概率信息。

如图 2-4 所示为在同一 RP 处使用 V450 测量时，其天线朝向不同，RSS 的统计分布各不相同。V450 的天线分别朝东、南、西、北等四个不同方向，采样速率 1/s，共计 100 个样本。由图可知，随着 V450 的天线方向不同，其 RSS 的均值不同，并且表现出不同的相关统计特性。因此，建立 Radio Map 时，V450 的天线朝向需要固定。

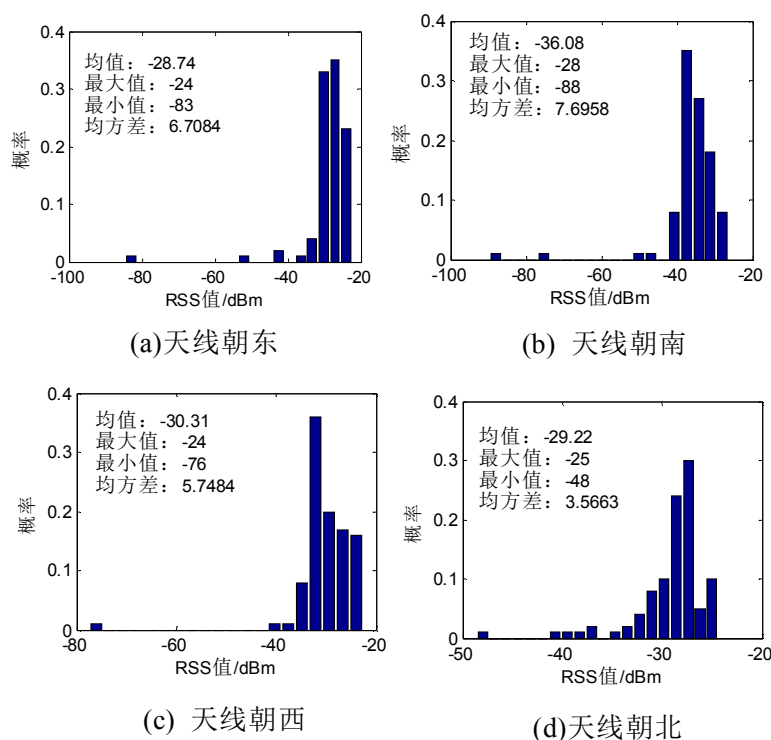



图 2-4 天线朝向不同时 RSS 的概率分布图

对于同一个参考点，不同 WAP 的 RSS 值的概率分布不同。如图 2-5 所示为固定 RP 及测量方向时，不同的 WAP 的 RSS 值的概率分布。

### 2.3.2 基于移动终端的 Radio Map 特征分析


除了对固定终端的 Radio Map 进行分析之外，本文重点对移动终端的 Radio Map 进行详细分析，并以移动终端及其 Radio Map 为重点，对本文提出的方法进行性能验证。为了对不同移动终端的 Radio Map 进行对比分析，本文采用三种不同的移动终端：OPPO T29、Google Nexus 5 及 Samsung Note II 进行实际测试。采用上述三种不同的终端对固定位置的 RSS 进行实际，并分析

不同俯仰角及终端差异性等因素的影响。本小节分析的 Radio Map 来自于 HIT-WILS10 系统的 RSS 数据。




(a) 接收到 WAP1 的 RSS (b) 接收到 WAP2 的 RSS  
图 2-5 固定 RP 处不同 WAP 的 RSS 的概率统计

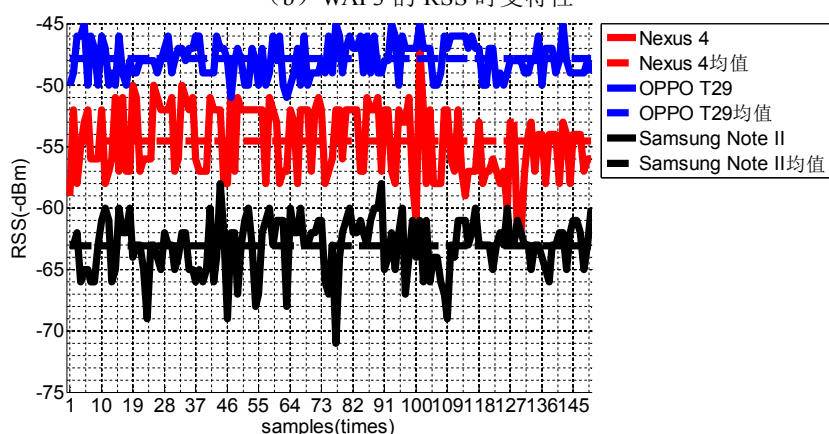
图 2-6 所示为不同的移动终端的 RSS 的时变特性对比，分别对同一参考点上，采用不同移动终端测试定位区域内 RSS，每个终端测试 150 次 RSS。从图中可以得出 RSS 的以下特征：首先，在同一位置，同一移动终端测试的不同的 WAP 的 RSS 有明显的差别，并且对于同一移动终端在同一位置测试同一 WAP 的 RSS 也表现出极大的波动性；其次，在同一位置，不同的移动终端测试同一 WAP 的 RSS 有着明显的差异性。从选择的四个 WAP 的测试结果可以得出，不同移动终端测试到的同一 WAP 的 RSS 的波动范围及其均值有着明显的区别，其 RSS 差值可达 30dB。



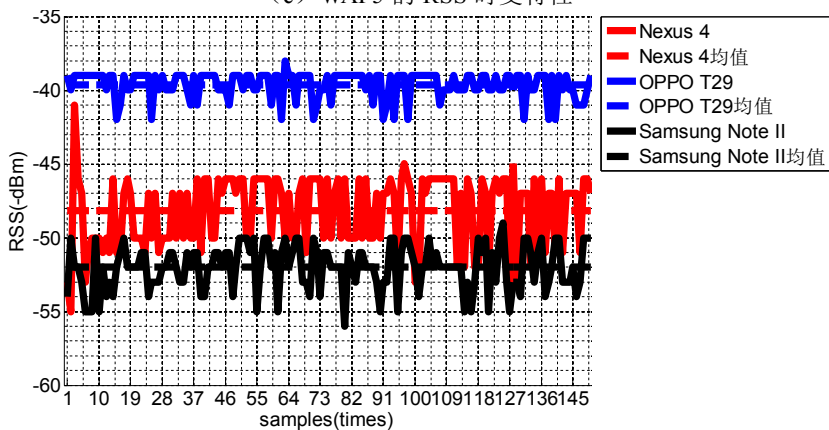
(a) WAP1 的 RSS 时变特性



(b) WAP3 的 RSS 时变特性



(c) WAP5 的 RSS 时变特性

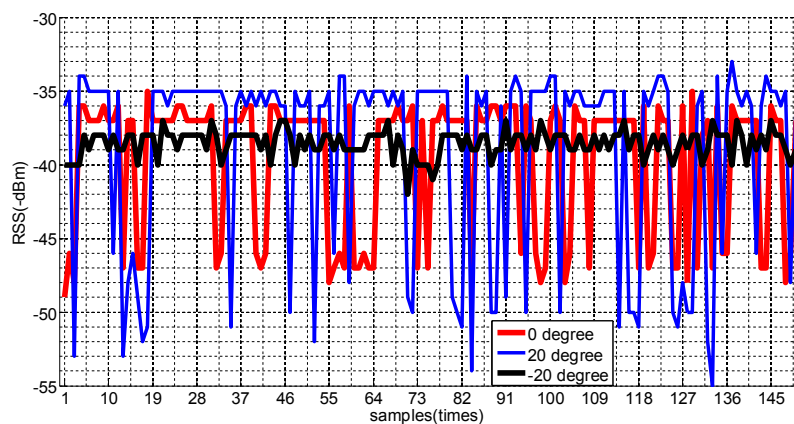


(d) WAP8 的 RSS 时变特性


图 2-6 不同移动终端的 RSS 时变特性对比

除了终端差异性带来的影响外，对 RSS 测试产生影响的是终端的位置，包括：天线方位、终端与偶然导体的相对距离及俯仰角。上节中已经对天线方位的影响进行了分析，而在 RSS 测试中，偶然导体的影响是不可避免的，是环境对测试过程的一种影响。以下主要分析俯仰角对 RSS 测试的影响。从图 2-7

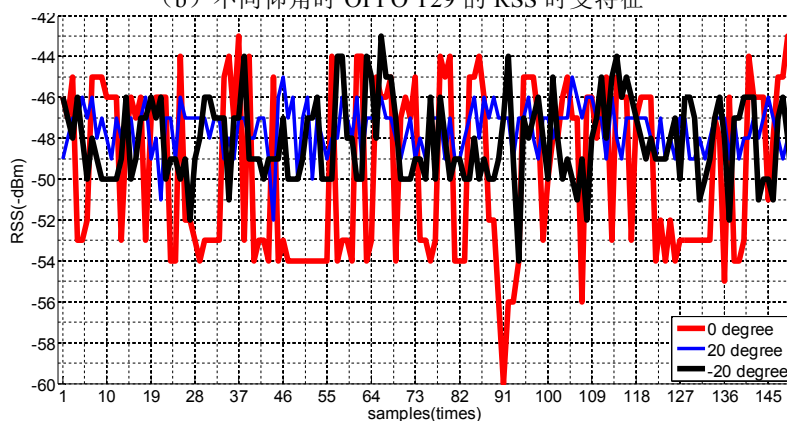
中可以看出，同一移动终端在不同仰角下测试的 RSS 并没有明显的差异，其均值与波动范围均相近。在 RSS 采集过程中，将移动终端固定在三角架上，并将仰角固定于 20 度，从而降低仰角及偶然导体相对距离等因素对其测试的影响。



(a) 不同仰角时 Nexus 5 的 RSS 时变特征



(b) 不同仰角时 OPPO T29 的 RSS 时变特征



(a) 不同仰角时 Note II 的 RSS 时变特征

图 2-7 终端仰角对 RSS 测试的影响

## 2.4 基于仿射聚类的位置指纹定位方法

为了提高在线定位阶段的实时定位性能并降低流形对齐方法实现的空间复杂度，可以对整个室内定位区域进行分区，从而减少在线定位阶段的匹配定位次数。其基本原则是：分区后，各个参考点之间尽可能实现物理位置的连续，即各个聚类之间的过渡参考点数目尽可能地少，同时要保证各个聚类的稳定性。本文采用仿射传播聚类（Affinity propagation, AP）算法及近邻类别匹配方法对传统位置指纹定位方法进行改进。

### 2.4.1 基于仿射传播聚类的分区方法

#### (1) AP 算法基本原理

与  $k$ -均值（K Means）聚类相比，AP 则不必指定聚类数，同时也不需要指定初始聚类中心<sup>[51]</sup>。AP 算法是多伦多大学的 Frey 和 Dueck 提出的，其实现过程：（1）将所有 RSS 都作为聚类中心，并将每个 RSS 的物理坐标都当作一个节点；（2）递归迭代将实际 RSS 的分类信息通过各个节点近邻关系进行传递，直至得出满足条件的类中心。AP 算法以  $s(i, k)$  代表第  $k$  个 RP 作为第  $i$  个 RP 的类中心时的相似度（Similarity）。当 AP 的目标函数达到最小化均方误差时， $s(i, k)$  可以用式(2-6)所示的 RP 之间的 ED 的负值来表示。

$$s(i, k) = -\left( (x_{i1} - x_{k1})^2 + (x_{i2} - x_{k2})^2 + \cdots + (x_{id} - x_{kd})^2 \right)^{1/2}, i \neq k \quad (2-6)$$

其中， $x_i = (x_{i1}, x_{i2}, \cdots, x_{id})$ ， $x_k = (x_{k1}, x_{k2}, \cdots, x_{kd})$ ， $d$  为 RP 的属性的数目。

为了便于计算，AP 算法以  $s(i, k), i \neq k$  的统计值来衡量点  $k$  作为类中心的可能性， $s(k, k)$  的值。 $s(k, k)$  值越大时，则第  $k$  个 RP 作为类中心的可能性越高。迭代时，其关键在于计算在参考点间支撑度（Reference）及可信度（Accreditation）的计算。支撑度  $r(i, k)$  表示将其以第  $k$  个 RP 作为第  $i$  个 RP 的类中心时累加信息；可信度  $a(i, k)$  代表若第  $i$  个 RP 作为第  $k$  个 RP 作为类中心的累加信息时，第  $k$  个 RP 作为类中心的支撑度。第一步，假设  $a(i, k)=0$ ，支撑度  $r(i, k)$  的计算如式(2-7)所示，可信度  $a(i, k)$  的计算如式(2-8)和(2-9)所示。

$$r(i, k) = s(i, k) - \max_{k' \neq k} \{a(i, k') + s(i, k')\} \quad (2-7)$$



$$a(i, k) = \min \left\{ 0, r(k, k) + \sum_{i' \in \{i, k\}} \max \{0, r(i', k)\} \right\}, i \neq k \quad (2-8)$$

$$a(k, k) = \sum_{i' \neq k} \max \{0, r(i', k)\} \quad (2-9)$$

通过对可信度与支撑度两者进行相加能够确定的聚类中心，对于第  $i$  个 RP，若第  $k$  个 RP 使得  $a(i, k) + r(i, k)$  最大，则若  $k = i$ ，点  $i$  既是聚类中心，若  $k \neq i$ ，则第  $i$  个 RP 的聚类中心即为第  $k$  个 RP。采用迭代方法得到稳定的聚类结果。为了保证迭代的收敛性（Convergence），引入一个阻尼参数  $\lambda$ ，每次迭代后的数据信息表示如式(2-10)和(2-11)所示。

$$r(i, k) = \lambda \cdot r'(i, k) + (1 - \lambda) \cdot r(i, k) \quad (2-10)$$

$$a(i, k) = \lambda \cdot a'(i, k) + (1 - \lambda) \cdot a(i, k) \quad (2-11)$$

需要说明的是，对于定位区域的分工工作在离线阶段实现，并对各个参考点的分区属性进行标记，从而减少在线定位阶段的工作量，提高实时定位性能。在进行分区之后，在线阶段首先要完成的工作是区域匹配。通过准确地匹配在线接收到 RSS 的区域，可以提高定位精度、降低在线定位阶段的复杂度，从而在提高定位精度的同时，提高算法的实时性能。

#### 2.4.2 基于位置指纹的子区域匹配方法

采用 AP 算法对定位区域进行分区后，在线阶段的首要工作是要实现子区域的准确匹配。假设定位区域分为  $c$  个区域，各个区域中心为  $v = [v_1, v_2, \dots, v_c]$ ，其值为各个区域内所有 RSS 的均值。在线阶段接收到的 RSS，其属于第  $i(1 \leq i \leq c)$  个区域，当满足式(2-12)所示条件。

$$RSS \in v_i \Leftrightarrow \min_{1 \leq k \leq c, k \neq i} (l^2 = \|RSS - v_k\|) \quad (2-12)$$

在已给定的子区域中心的前提下，式(2-12)表示将接收到 RSS 判定为距离子区域中心最近的子区域。由于判定后的区域并不能保证准确，因此并不能准确地更新相应的区域的中心。

#### 2.4.3 AP-KNN 算法的性能分析

基于仿射聚类的特征匹配定位算法（AP-KNN）的过程如图 2-8 所示。与一般地基于 WLAN 的室内定位系统相比，同样包含两个阶段，只是增加了仿射传播聚类的过程，同时在线阶段增加了相应的聚类选择算法。仿射传播聚类的主

要过程比较复杂，但其计算及分析过程均在离线阶段完成，可以采用性能较好的服务器等终端来实现，并将聚类信息存储于 Radio Map 中。而在线阶段的聚类选择方法十分简洁，与指纹匹配过程相比，其时间复杂度可以忽略不计。

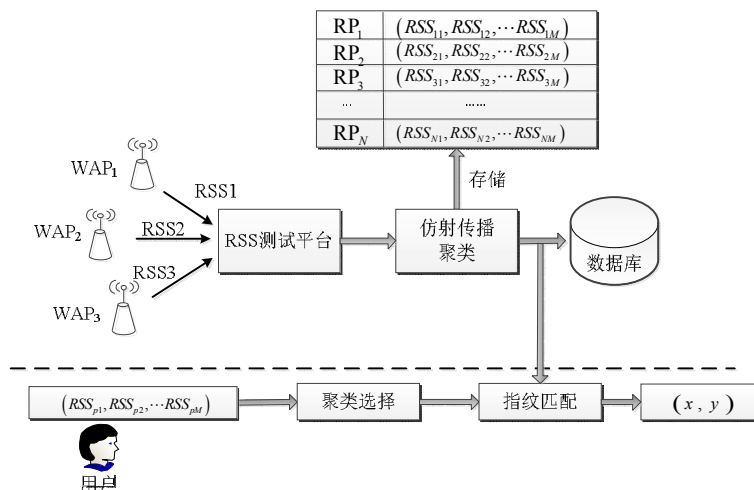



图 2-8 基于仿射聚类的特征匹配定位算法


本文提出 AP-KNN 的目的是：首先，降低在线定位阶段指纹匹配的复杂度，提高算法的实时性能；其次，降低流形对齐算法的离线及在线阶段的实现的复杂度，便于整体性能的提高；最后，在引入分区后，对指纹匹配定位方法（以 KNN 为例）没有明显的影响，至少其定位性能不降低。由于 HIT-WILS10 系统中的有效定位区域比较小，并不能有效的实施区域划分，因此对 AP-KNN 算法及相应子算法的性能分析以 HIT-WILS12 系统为例（有关 HIT-WILS12 详见第 5 章）。

### （1）偏置度对 AP 算法的性能影响

虽然 AP 算法不需要给出聚类中心及其数目，但其核心参数——偏置度（Preference）中可以控制聚类数目及迭代收敛的速度。图 2-9 所示为偏置度取值对 AP 算法的影响。从图（a）可以看出，随着偏置度的取值不断地增加，聚类数目逐渐减小。理论上偏置度的聚类可以在整个正实数范围内取值，但由于偏置度太小时，仿射聚类传播算法的收敛速度特别慢，且聚类数目极大；当偏置度太大时，仿射聚类收敛速度快，无法对数据集进行有效地聚类分析。因此，在选择偏置度时要结合聚类数目的基本要求来确定。



(a) 偏置度对 AP 聚类数目的影响



(b) 聚类选择准确率与偏置度的关系

图 2-9 偏置度对 AP 算法的性能影响

除考虑聚类数目合理外，也要兼顾其聚类选取的准确率。图（b）中给出偏置度取值不同时，测试数据得出聚类选择准确率。从图中可以看出，聚类选择的准确率不仅与偏置度（实质上决定了聚类数目）有关，而且与聚类中心的选取有关。一方面随着偏置度的取值的增加，聚类选择的准确率不断提高，且最终必然达到 100% 的准确率（图（b）中矩形框内所示）。这一方面实际上是随着聚类数目的增加，其聚类选择的准确率会不断地降低，与实际情况相吻合。另一方面，聚类选择的准确率并不是随着聚类数目的变化而单调变化的。图（b）中红色椭圆区域内，其聚类数目均为 3（由图（a）中得出），但其聚类选择的准确有着明显的波动。这是因为当聚类数目相同时，不同取值的偏置度会对聚类中心产生影响，其聚类选择准确率最高的区域集中于 45~130 之间。同时从聚类中心的角度来看，采用平均聚类中心可以提高聚类中心选择的

准确率。本文中，选取的偏置度分别为 25、35、50。在将 AP 算法与流形对齐算法联合时，也以上述偏置度为参考值进行整体性能仿真分析，并采用以平均聚类中心为基准的聚类选择方法。

表 2-1 不同位置指纹数据库下 KNN 及 AP-KNN 算法性能对比

无分区情况下 KNN 算法性能								
位置 指纹		定位误	定位误	定位误	定位误	定位误	定位误	
		差平均	差标准	差在 2m	差在 3m	差在 4m	差在 5m	差在 6m
		值 (m)	差 (m)	内概率	内概率	内概率	内概率	
KNN	RM1	1.865335	1.294674	0.637681	0.826389	0.924215	0.972826	0.98913
	RM2	1.727585	1.293816	0.688104	0.852053	0.933575	0.974638	0.988527
	RM3	1.689912	1.270546	0.704106	0.855072	0.934783	0.977053	0.990036
采用 AP 算法分区情况下 KNN 算法性能								
偏置度 (Preference=25)								
AP-KNN	RM1	1.914818	1.320496	0.625302	0.813708	0.916969	0.968297	0.987621
	RM2	1.780845	1.329959	0.67029	0.837258	0.925121	0.972524	0.987923
	RM3	1.729994	1.27857	0.686896	0.844203	0.930857	0.977959	0.991546
偏置度 (Preference=35)								
AP-KNN	RM1	1.921854	1.342157	0.624094	0.812198	0.913949	0.967391	0.986715
	RM2	1.780845	1.329959	0.67029	0.837258	0.925121	0.972524	0.987923
	RM3	1.753672	1.309744	0.684783	0.837862	0.9218	0.97494	0.991244
偏置度 (Preference=50)								
AP-KNN	RM1	1.897506	1.295743	0.622585	0.819143	0.923611	0.972222	0.98913
	RM2	1.770445	1.317547	0.673309	0.843599	0.928744	0.971014	0.987319
	RM3	1.729716	1.297171	0.690821	0.846618	0.929952	0.974034	0.988829

(2) 指纹定位算法的性能对比

本文在 HIT-WILS12 所覆盖的实验区域内采集了 900 个样本点，其中有效样本点 826 个，基本覆盖整个实验区域。以 KNN 算法为核心的指纹定位算法是目前常用的匹配定位算法之一，本文也采用这一算法来进行性能分析。从 RSS 的数据中，分别提取以固定方位上单次采用 Radio Map、50 次采样均值 Radio Map 及 100 次采样均值的 Radio Map 作为位置指纹数据库，分别表示为 RM1、RM2、RM3。其测试数据分别为不同位置上四个不同方位的单次采样，共计 6624 次测试样本点。

从表 2-1 中可以得出以下结论：(1) 从 KNN 及 AP-KNN 定位算法的分析来看，随着采样次数的增加，定位算法的性能都会有一定程度的提高（不足 1%），但其提高程度很小。从采样次数角度来看，单次测量的位置指纹数据库可以达到多次采样均值的位置指纹数据库的性能，可以有效地减少数据库建立

所需的工作量；(2) 从 KNN 及 AP-KNN 定位结果的误差的均值及标准差来看，引入分区算法后，会造成误差均值的增加及波动性的增大。在应用分区算法要考虑这一因素的影响。从仿真结果来看，当偏置度为 50 时，误差均值及标准差的增加都在 0.01 米的量级（厘米级），其对结果影响完全对整体性能影响较小。

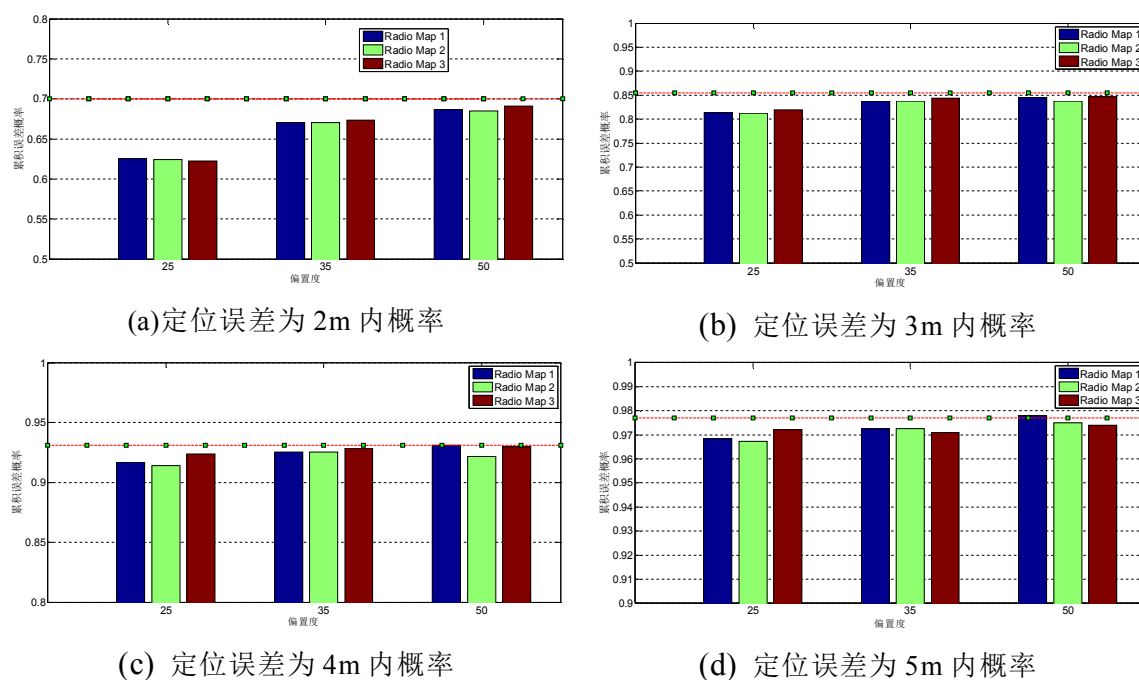


图 2-10 不同偏置度下 AP-KNN 算法的定位性能对比

结合图 2-10 及表 2-1 所示的 KNN 及 AP-KNN 的性能仿真结果，可以得出在不同的偏置度的情况下，不同的指纹数据下，定位误差在 2 米、3 米、4 米及 5 米内的概率有小幅的增加，但增幅有限。定位准确率提升最大的区间为定位误差在 2 米内及定位误差在 3 米内，从 65%提升至 84%左右。从仿真结果来看，本文提出的 AP-KNN 算法可以有效地保持 KNN 的算法定位性能，同时也能在单次采样的条件下实现稳定的定位性能。从保持 KNN 算法的定位性能稳定的角度来看，AP-KNN 算法达到相应的要求。

## 2.5 本章小结

本章对一个典型的 WILS 的各个组成部分进行了分析。首先对 WILS 的基本结构、组成部分及功能实现进行了概述。然后以 FLA 为例，对 WLAN 室内定位系统的工作流程进行了说明。再对 WILS 中的关键技术：定位方法及

Radio Map 的建立进行了分析。在对比确定型及概率型指纹定位方法后，本文采用以 KNN 为代表的确定型指纹定位算法进行系统性能分析的定位方法。本章重点对 Radio Map 的建立过程进行了分析，并以目前 HIT-WILS10 及 HIT-WILS12 等两个 WLAN 室内定位系统为实验环境，采用联想 V450、OPPO T29、Google Nexus 5 及 Samsung Note II 等四种不同的终端采集了 Radio Map 及性能测试数据库，并对其特征进行了分析。为改进 KNN 算法的定位性能及在流形对齐中的应用，本章提出了 AP-KNN 算法并对其性能进行了对比分析，为后文的整体性能分析奠定了基础。

## 第3章 流形对齐及超分辨率分析

流形是拓扑学的一个子范畴。从严格的数学定义来讲，流形及光滑的条件十分严苛。本章对流形及流形学习的基本理论及概念进行简要研究，并对 LLE、ISOMAP、LDE 及 SDE 等四种常用的流形学习方法的基本理论及其实现过程进行分析，为后续统一耦合度量流形对齐方法的分析奠定理论基础。然后介绍耦合度量学习及流形对齐方法的基本概念、流形对齐中的对应关系的实现方法。在此基础上，从基于相关关系及 Fisher 准则的耦合度量学习方法出发，分析耦合度量学习的理论及实现过程，并采用奇异值分解方法实现特征变换过程的优化求解，并在前述方法的基础上推导统一耦合度量学习方法的理论，从而将耦合度量学习方法推广至多类不同数据集的耦合度量学习及多流形对齐方法。同时，在本章中还将分析从物理空间与信号空间的对应关系中重建稀疏 Radio Map 的超分辨率分析理论及算法流程。

### 3.1 流形及典型流形学习方法

#### 3.1.1 基本理论

拓扑学是以拓扑空间为研究对象的一个数学分支。假设  $X$ 、 $Y$  是 2 个拓扑空间，且  $f: X \rightarrow Y$  是满足连续映射条件。若  $f$  存在逆映射，而且其逆映射是连续的，则称  $f$  是一个同胚映射。有关于流形的基本理论来自于文献[52]。

拓扑空间  $M$  在满足以下条件时，称  $M$  为  $m$  维流形 (manifold)，即：

(1)  $M$  为豪斯多夫 (Hausdorff) 空间。Hausdorff 空间是数学拓扑学中的一个分离空间，满足分离定理：即拓扑空间  $M$  中任意不同的点  $x$  和  $y$ ，存在  $x$  的邻域  $U$  和  $y$  的邻域  $V$ ，满足  $U \cap V = \Phi$ 。

(2) 对于  $\forall p \in M$ ，存在包含的  $m$  维坐标邻域  $(U, \Phi)$ ，坐标邻域是拓扑空间中的开集与其在 Euclidean 空间中的映射  $\Phi$  有序对。流形是拓扑学中的概念，其表示一个局部处为 Euclidean 的拓扑空间，局部 Euclidean 性质意味着对于空间上任一点都有一个邻域，在这个邻域中的拓扑与  $R^m$  空间中的开放单位圆相同， $R^m$  表示  $m$  维 Euclidean 空间，从拓扑空间的一个开集 (邻域) 到欧式空间的开子集的同胚映射，使得每个局部可坐标化。它的本质是分段线性处

理。根据流形的上述定义及特征，对不同特殊的流形给出以下定义：

微分流形： $d$  维  $C^k$  流形存在同胚映射对  $(M, \Lambda)$ ，其中  $M$  为  $d$  维流形， $\Lambda = \{(U_\alpha, \varphi_\alpha)\}_{\alpha \in A}$  为一阶  $C^k$  的微分结构，满足以下条件：

(1) (局部欧式性)  $\{U_\alpha : \alpha \in A\}$  构成  $M$  的一个开覆盖， $\varphi_\alpha : U_\alpha \rightarrow \varphi_\alpha(U_\alpha) \subset R^d$  为同胚映射；

(2) ( $C^k$  相容性) 若  $U_\alpha \cap U_\beta \neq \Phi$ ，则双射

$$\varphi_\alpha \varphi_\beta^{-1} : \varphi_\beta(U_\alpha \cap U_\beta) \rightarrow \varphi_\alpha(U_\alpha \cap U_\beta) \quad (3-1)$$

及其逆映射都是  $k$  次可微的，则称流形  $(U_\alpha, \varphi_\alpha)$  和流形  $(U_\beta, \varphi_\beta)$  是相容的；

(3) (最大性) 若  $U$  为  $M$  中的开集， $\varphi : U \rightarrow \varphi(U) \subset R^d$  与  $\Lambda$  中的每个  $(U_\alpha, \varphi_\alpha)$  都相容，则  $(U, \varphi) \in \Lambda$ 。

从上述条件可以得出，微分流形满足连续、光滑及其几何空间不存在跳跃等基本特征。

切向量和切空间：流形  $M$  是光滑，点  $x$  处切向量即：映射  $v_x : C^\infty(M)$  (光滑映射)  $\rightarrow R$ ，且对  $\forall g, h \in C^\infty(M), a, b \in R$  满足：

$$v_x(ag + bh) = av_x(g) + bv_x(h) \quad (3-2)$$

$$v_x(gh) = v_x(g)h(x) + g(x)v_x(h) \quad (3-3)$$

若  $(U, \varphi)$  为  $x$  点的一个坐标系，则存在

$$\left(\frac{\partial}{\partial x_i}\right)_x : g \rightarrow \left(\frac{\partial g}{\partial x_i}\right)_x \equiv \left(\frac{\partial(g\varphi^{-1})}{\partial x_i}\right)(\varphi(x)), \quad g \in C^\infty(M) \quad (3-4)$$

式(3-4)为  $x$  点的一个切向量。 $X$  点处切向量全体记为  $T_x(M)$ ，是一个实线性空间，称之为  $M$  在点  $x$  的切空间。黎曼流形：若光滑流形  $M$  的切空间  $T_x(M)$  的给内积，则称  $M$  为黎曼流形。

欧式距离：也称欧几里得距离，它是一个通常采用的距离定义，表示  $m$  维欧式空间中两点的真实距离。在一个  $m$  维欧式空间中，表示两个点的欧式距离的数学表达式为  $d = \sqrt{\sum_{i=1}^m (x_i - x'_i)^2}$ 。

测地距离：设  $p$ 、 $q$  是黎曼流形  $M$  中任何两点，则这两点间的测地距离  $d_M(p, q)$  为  $M$  中连接  $p$ 、 $q$  的所有分段光滑曲线的弧长的下确界。

有了对流形的定义，就可以形式化地概括流形学习这一维数约简过程：



用数学语言可以这样描述:对于高维数据  $X = \{x_1, x_2, x_3, \dots, x_n\}$  是高维的光滑流形, 假设其本征低维空间为  $Y \subset R^d$  且  $f: Y \rightarrow R^D$  是一个光滑的嵌套, 一般情况  $D \gg d$ 。流形学习 (manifold learning, ML) 的目标: 在  $R^D$  上的一个被给定被观测的数据集合  $\{x_i\}$  去恢复  $Y$  与  $f$ 。在  $Y$  中隐藏的数据  $\{y_i\}$  被随机地产生, 然后被  $f$  映射到观测空间, 使得  $\{x_i = f(y_i)\}$ 。

### 3.1.2 典型流形学习方法

从上述对流形基本理论及耦合度量学习的定义和基本概念的分析可以看出: 维度变换与耦合度量学习有着的本质的联系。本文目标是实现低维物理空间与高维 RSS 空间的耦合度量学习, 当高维 RSS 空间映射至物理空间时, 其过程即为降维; 反之, 这一过程则是维度升高的过程。为了便于对耦合度量学习的分析, 以下针对典型的流形学习算法进行分析, 包括: 局部线性嵌入 (Local Linear Embedding, LLE)、等距映射 (Isometric Mapping, ISOMAP)、线性鉴别嵌入 (Local Discriminant Embedding, LDE) 及半监督鉴别嵌入 (Semi-supervised Discriminant Embedding, SDE) 等四种典型的流形学习算法。

#### (1) LLE

局部线性嵌入<sup>[53]</sup>降维算法的目标函数为:

$$\min \varepsilon(y) = \sum_{i=1}^m \left\| y_i - \sum_{j=1}^k W_{ij} y_{i,j} \right\|^2 \quad (3-5)$$

式(3-5)中,  $y_i$  表示降维结果,  $W_{ij}$  表示权重。LLE 算法流程如下所述:

- (1) 邻域的确定和局部邻域点的搜索和确定;
- (2) 计算重构权值矩阵  $W$ ;
- (3) 由特征映射计算低维嵌入;

一般情况下, 采用  $k$ -近邻算法来计算相应的邻域大小。在确定好点  $x_i$  的邻域后, 也就是确定  $x_i$  的  $k$  个邻域点, 对这  $k$  个邻域点进行加权, 定义权重系数  $W_{ij}, j=1, 2, \dots, k$ 。首先根据样本点的近邻关系计算样本点的局部重构权值矩阵。为了实现线性重构, 采用式(3-6)定义代价函数使得重构误差最小计算的权

值:

$$\min \varepsilon(W) = \sum_{i=1}^m \left\| x_i - \sum_{j=1}^k W_{ij} x_{i,j} \right\|^2 \quad (3-6)$$

为了保证计算过程不出现发散的情况, 要对权值矩阵归一化, 即式所示:

$$\sum_{j=1}^k W_{ij} = 1 \quad (3-7)$$

采用拉格朗日乘数 (Lagrange Multiplier) 法得出构造函数:

$$F(W) = \sum_{j=1}^k \sum_{l=1}^k w_{jl} w_{il} Q_{jl}^{(i)} + \lambda \left( \sum_{j=1}^k w_{ij} - 1 \right) \quad (3-8)$$

其中  $Q_{jl}^{(i)}$  的计算式为:

$$Q_{jl}^{(i)} = (x_i - x_{i,j})^T (x_i - x_{i,l}) \quad (3-9)$$

由此, 得出权值矩阵的计算式为:

$$W_{ij} = \frac{\sum_{l=1}^k (Q_{jl}^{(i)})^{-1}}{\sum_{p=1}^k \sum_{q=1}^k (Q_{pq}^{(i)})^{-1}} \quad (3-10)$$

计算得出权值矩阵后, 代入式(3-10)中, 对式(3-11)特征分解:

$$My^T = \lambda y^T \quad (3-11)$$

其中  $M$  为:

$$M = (I - W)^T (I - W) \quad (3-12)$$

为了满足上述条件,  $y$  是  $M$  的特征向量, 显然使代价函数最小,  $y^T$  是  $M$  的最小  $d$  个非零特征值对应的特征向量。需要注意的是, 如果从  $m$  维降到  $d$  维, 需要取  $d+1$  个特征向量, 并舍去其中的 0 向量, 这样就得到最后的低维嵌入  $y$ , 实现从  $n$  维降到  $d$  维的过程。

## (2) ISOMAP

等距映射法<sup>[54]</sup>算法是在多尺度变换 (Multi-Dimensional Scaling, MDS) 算法基础上, 保持数据点的内部几何性质, 即保持两点间的测地距离。ISOMAP 算法是一种非线性的学习方法, 它适用于学习内部平坦的低维流形, 在算法中需要确定两个参数, 一个是邻域的大小, 一个是维度变换的目标维数。

ISOMAP 算法与 MDS 算法的主要区别就是, MDS 用欧式距离来构成关系矩阵, 而 ISOMAP 算法是利用两点间的测地距离来代替 MDS 算法中的欧

式距离，从而构造关系矩阵，得到高维流形中的低维数据关系。

ISOMAP 算法的基本步骤：

(1) 首先建立邻接图，有两种方法确定邻域： $k$  邻域法和  $\varepsilon$  邻域法，其中  $k$  邻域法是取与  $x_i$  点欧式距离最短的  $k$  个点作为  $x_i$  点的邻近点；而  $\varepsilon$  邻域法是以  $x_i$  为球心  $\varepsilon$  为半径的球面内的点为  $x_i$  的邻近点。这里的算法只讨论  $k$  邻近法。

(2) 讨论测地距离的算法：若点  $x_j$  在  $x_i$  的邻域内，则其欧式距离  $\Delta_{ij}$  表示它们的测地距离  $d_M(x_i, x_j)$ ；基点  $x_j$  不在  $x_i$  的邻域内，则利用 Dijkstra 算法（或 Floyd 算法）计算它们之间的最短路径来表示它们的测地距离  $d_M(x_i, x_j)$ ，进而构造距离矩阵  $D$ 。

(3) 第三步至最后嵌入实现与 MDS 算法一致。对  $D$  进行中心化，再奇异化分解，最后得到  $X$  的目标低维数据  $Y = \sqrt{\Lambda}U$ 。

ISOMAP 是一种全局维数变换方法，其嵌入结果可以体现高维数据之间的流形距离。因此，如果高维数据所在的低维流形与 Euclidean 空间的子集是等距，则 ISOMAP 可以得到理想的流形学习。但 ISOMAP 计算量大，容易出现空洞，是它的不足之处。

### (3) LDE

LDE 算法是基于类间散度及类内散度最大化的监督型流形学习算法<sup>[55]</sup>。在对 LDE 算法进行理论分析之前对 LDE 算法给定的输入数据做如下说明：输入高维数据点  $\{x_i\}_{i=1}^m \in R^n$ ，数据点  $x_i$  的类标记为  $y_i \in \{1, 2, \dots, P\}$ ，其中  $P$  表示将高维数据划分为  $P$  个子流形，即将输入的高维数据分成  $P$  类。将输入的高维数据表示成矩阵的形式： $X = [x_1, x_2, \dots, x_m] \in R^{n \times m}$ 。从矩阵表示的形式来看，矩阵中的列代表一个高维数据点。LDE 算法实现过程如下所述：

- (1) 构造邻接图。根据高维数据点的类标记信息及其近邻关系构造无方向图  $G$  及  $G'$ 。其中近邻关系是采用 KNN 算法给出的准则，即选择数据点最近的  $K$  个点作为其邻居， $G$  表示当  $x_i$  与  $x_j$  的类标记信息  $y_i = y_j$  时且  $x_i$ 、 $x_j$  互为  $K$  近邻关系； $G'$  示当  $x_i$  与  $x_j$  的类标记信息  $y_i \neq y_j$  时且  $x_i$ 、 $x_j$  互为  $K$  近邻关系。
- (2) 计算权值矩阵。根据 (1) 构造的邻接图采用类高斯函数进行权值矩阵

的计算。其表达式为(3-13)所示。公式(3-13)中  $w_{ij}$  表示近邻点  $x_i$  与  $x_j$  之间的权值， $\|x_i - x_j\|^2$  为近邻点  $x_i$  与  $x_j$  之间的范数（Frobenius）距离<sup>[56]</sup>，采用矩阵方式计算范数距离， $t$  为权值归一化参数。

$$\begin{cases} w_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2 / t); & \text{if } x_i, x_j \in G \\ 0; \end{cases} \\ w'_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2 / t); & \text{if } x_i, x_j \in G' \\ 0; \end{cases} \end{cases} \quad (3-13)$$

(3) 计算嵌入结果。对式(3-15)进行广义特征值分解，得出其特征值分解的特征值及特征向量，表示为： $\lambda = [\lambda_1, \lambda_2, \dots, \lambda_n]^T$ ，其对应的特征向量为： $v = [v_1, v_2, \dots, v_n]^T$ 。取前  $d$  个最大的特征值对应的特征向量构成变换矩阵  $V = [v_1, v_2, \dots, v_d]$ 。由 LDE 算法的输出数据变换方法可以得出，降维后数据为：有关式(3-15)的推导及证明在后续的分析中给出。

$$z_i = V^T \cdot x_i \quad (3-14)$$

式(3-14)中， $z_i$  表示输入高维数据点  $x_i$  变换后的低维输出数据，

$$X(D' - W')X^T v = \lambda X(D - W)X^T v \quad (3-15)$$

式(3-15)中： $X$  为输入数据， $\lambda, v$  为特征值与特征向量， $W, W'$  分别为  $G$  及  $G'$  对应的权值矩阵， $D$  及  $D'$  均为对角阵，其对角元素可以由式(3-16)表示。

$$\begin{cases} d_{ii} = \sum_j w_{ij} \\ d'_{ii} = \sum_j w'_{ij} \end{cases} \quad (3-16)$$

上述的三步即为根据 LDE 算法流程给出的理论分析及说明。对于根据 LDE 算法的目标——最大化类间散度地同时最小化类内散度。散度采用表示同类数据点及不同类的范数距离表示。由 LDE 算法的目标可以得出其相应的优化目标函数，如式所示。

$$\begin{cases} \text{Maximize } J(V) = \sum_{i,j} \|V^T x_i - V^T x_j\|^2 w'_{ij} \\ \text{subject to } \sum_{i,j} \|V^T x_i - V^T x_j\|^2 w_{ij} = 1 \end{cases} \quad (3-17)$$

根据式(3-17)给出的优化目标函数推导式(3-15)。根据矩阵范数的计算式：

$\|A\|^2 = \sum_{i,j} a_{ij}^2$ ，计算式表示为矩阵  $A$  的矩阵范数的计算方法，计算式给出的方法与矩阵的迹的计算式一致，即： $\|A\|^2 = \text{tr}(AA^T)$ 。由此式(3-17)可以表示为矩阵的迹的计算方式：

$$J(V) = \sum_{i,j} \left\{ \text{tr} \left[ (V^T x_i - V^T x_j)(V^T x_i - V^T x_j)^T w'_{ij} \right] \right\} \quad (3-18)$$

式(3-18)可以简化为：

$$J(V) = \sum_{i,j} \left\{ \text{tr} \left[ V^T (x_i - x_j)(x_i - x_j)^T V \right] w'_{ij} \right\} \quad (3-19)$$

由矩阵迹的计算的标量性质及权值元素均为实数，可以将式(3-19)简化为：

$$J(V) = \text{tr} \left\{ V^T \sum_{i,j} \left[ (x_i - x_j) w'_{ij} (x_i^T - x_j^T) \right] V \right\} \quad (3-20)$$

将式(3-20)展开：

$$J(V) = \text{tr} \left\{ V^T \sum_{i,j} \left[ (x_i w'_{ij} x_i^T) + (x_j w'_{ij} x_j^T) - (x_i w'_{ij} x_j^T) - (x_j w'_{ij} x_i^T) \right] V \right\} \quad (3-21)$$

式(3-21)可以简化为：

$$J(V) = \text{tr} \left\{ V^T \left[ \left( \sum_i x_i x_i^T \sum_j w'_{ij} \right) + \left( \sum_j x_j x_j^T \sum_i w'_{ij} \right) - 2 \left( \sum_j x_j^T \sum_i x_i w'_{ij} \right) \right] V \right\} \quad (3-22)$$

对于式(3-22)中：

$$\begin{cases} \sum_i x_i x_i^T = XX^T \\ \sum_j w'_{ij} = d'_i \\ \sum_{i,j} x_i w'_{ij} x_j = XW'X \end{cases} \quad (3-23)$$

根据式(3-23)中变换关系，可以将式(3-22)简化为：

$$J(V) = 2\text{tr} \left\{ V^T \left[ X(D' - W')X^T \right] V \right\} \quad (3-24)$$

根据式(3-24)的推导方式，同理可以将(3-17)中的约束条件写成如式(3-24)相似的形式，由此，可以将(3-17)表示为如下形式：

$$\begin{cases} \text{Maximize } J(V) = 2\text{tr}\{V^T [X(D' - W')X^T]V\} \\ \text{subject to } 2\text{tr}[X(D - W)X^T] = 1 \end{cases} \quad (3-25)$$

对式(3-25)应用拉格朗日 (Lagrange) 乘数法, 可以得出式(3-26)所示:

$$X(D' - W')X^T v = \lambda X(D - W)X^T v \quad (3-26)$$

以上给出 LDE 算法的理论推导。

#### (4) SDE

半监督鉴别嵌入 (Semi-supervised Discriminant Embedding, SDE) 算法<sup>[57]</sup>是基于标记数据与未标记数据的类间散度及类内散度最大化的一种流形学习算法。SDE 算法进行理论分析之前, 对 SDE 算法给定的输入数据做如下说明: 输入高维数据点  $\{x_i\}_{i=1}^m \in R^n$ , 数据点  $x_i$  的类标记为  $y_i \in \{1, 2, \dots, P\}$ , 其中  $P$  表示将高维数据划分为  $P$  个子流形, 即将输入的高维数据分成  $P$  类, 记  $P$  类的聚类中心为  $V = \{v_1, v_2, \dots, v_P\}$ 。将输入的高维数据表示成矩阵的形式:  $X = [x_1, x_2, \dots, x_m] \in R^{n \times m}$ 。从矩阵表示的形式来看, 矩阵中的列代表一个高维数据点。

对于包含 RSS 未分类的  $RadioMap_{ul}$ , 其中所有的未分类数据  $X_u = [x_{u1}, x_{u2}, \dots, x_{uk}] \in R^{n \times k}$  进行类别匹配, 同时已标记数据记为  $X_l = [x_{l1}, x_{l2}, \dots, x_{lc}] \in R^{n \times c}$ 。对于  $X_u$  中的所有数据进行类别匹配。采用式(3-27)计算类的归属  $x_{ui}$ , 并采用式更新相应的聚类中心, 依次将所有的未分类数据进行类别匹配

$$x_{ui} \in G_j \Leftrightarrow \arg \min_{1 \leq j \leq P} D(x_{ui}, v_j) \quad (3-27)$$

SDE 算法的目标函数为:

$$\begin{cases} \text{minimize} & \frac{X^T S_w X}{X^T S_t X} \\ \text{maximize} & \frac{X^T S_b X}{X^T S_t X} \end{cases} \quad (3-28)$$

式(3-28)中  $S_w$ 、 $S_b$ 、 $S_t$  分别表示类内散度、类间散度及总散度可以由式(3-29)计算:

$$\begin{cases} S_w = \sum_{i=1}^P \left( \sum_{x_k \in G_i} (x_k - m^{(i)})(x_k - m^{(i)})^T \right) \\ S_w = \sum_{i=1}^P (m - m^{(i)})(m - m^{(i)})^T \\ S_t = S_w + S_b \end{cases} \quad (3-29)$$

式(3-29)中,  $m^{(i)} = \sum_{k=1}^{l_i} x_k / l_i$  为第  $i$  类的数学均值,  $l_i$  为第  $i$  类的采样点的数目;  $m = \sum_{k=1}^N x_k / N$  为全体采样点的均值,  $N$  为采样点的数目。

对于式(3-30)所示的目标函数同样可以表示局部鉴别嵌入流形学习算法的目标函数形式, 其表达式为:

$$\begin{cases} \text{Maximize } J(V) = \sum_{i,j} \|V^T x_i - V^T x_j\|^2 w'_{ij} \\ \text{subject to } \sum_{i,j} \|V^T x_i - V^T x_j\|^2 w_{ij} = 1 \end{cases} \quad (3-30)$$

式(3-30)中,  $w_{ij}$  表示同类数据间的权重分配,  $w'_{ij}$  表示不同类数据间的权重分配, 分别表示为  $W_{N \times N}$  和  $W'_{N \times N}$ 。权值矩阵过程由分为以下两个步骤: (1) 构造邻域图。根据高维数据点的类标记信息及其近邻关系构造无方向图  $G$  及  $G'$ 。其中近邻关系是采用 KNN 算法给出的准则, 即选择数据点最近的  $K$  个点作为其邻居,  $G$  表示当  $x_i$  与  $x_j$  的类标记信息  $y_i = y_j$  时且  $x_i$ 、 $x_j$  互为  $K$  近邻关系;  $G'$  示当  $x_i$  与  $x_j$  的类标记信息  $y_i \neq y_j$  时且  $x_i$ 、 $x_j$  互为  $K$  近邻关系; (2) 计算权值矩阵。根据第一步构造的邻接图采用类高斯函数进行权值矩阵的计算。其表达式(3-31)、(3-32)为所示。公式中  $w_{ij}$  表示近邻点  $x_i$  与  $x_j$  之间的权值,  $\|x_i - x_j\|^2$  为近邻点  $x_i$  与  $x_j$  之间的距离, 采用矩阵方式计算距离,  $t$  为权值归一化参数,  $U$ 、 $L$  分别表示未分类和已分类的 RP 的数目。根据分析可以知道,  $W_{N \times N}$  和  $W'_{N \times N}$  可以由三部分构成, 分别是: 已分类 RSS 与已分类 RSS 之间的权值、已分类 RSS 与未分类 RSS 之间的权重及未分类 RSS 与未分类 RSS 之间的权值, 分别表示为:  $W_{L \times L} = \{w_{ij}^{ll}\}$ 、 $W_{L \times U} = \{w_{ij}^{lu}\}$ 、 $W_{U \times U} = \{w_{ij}^{uu}\}$ 。

$$W_{N \times N} = \begin{cases} w_{ij}^{ll} = \begin{cases} \exp(-\|x_i - x_j\|^2 / t); & \text{if } x_i, x_j \in G; x_i \in X_l, x_j \in X_l \\ 0; & \end{cases} \\ w_{ij}^{lu} = \begin{cases} \exp(-\|x_i - x_j\|^2 / t); & \text{if } x_i, x_j \in G; x_i \in X_l, x_j \in X_u \\ 0; & \end{cases} \\ w_{ij}^{uu} = \begin{cases} \exp(-\|x_i - x_j\|^2 / t); & \text{if } x_i, x_j \in G; x_i \in X_u, x_j \in X_u \\ 0; & \end{cases} \end{cases} \quad (3-31)$$

$$W'_{N \times N} = \begin{cases} w'_{ij}{}^{ll} = \begin{cases} \exp(-\|x_i - x_j\|^2 / t); & \text{if } x_i, x_j \in G'; x_i \in X_l, x_j \in X_l \\ 0; & \end{cases} \\ w'_{ij}{}^{lu} = \begin{cases} \exp(-\|x_i - x_j\|^2 / t); & \text{if } x_i, x_j \in G'; x_i \in X_l, x_j \in X_u \\ 0; & \end{cases} \\ w'_{ij}{}^{uu} = \begin{cases} \exp(-\|x_i - x_j\|^2 / t); & \text{if } x_i, x_j \in G'; x_i \in X_u, x_j \in X_u \\ 0; & \end{cases} \end{cases} \quad (3-32)$$

由上述计算公式及矩阵的性质可以得： $W_{L \times L}^T = W_{L \times L}$ 、 $W_{U \times U}^T = W_{U \times U}$ 、 $W_{L \times U}^T = W_{L \times U} = W_{U \times L}^T = W_{U \times L}$ 。由此可以推导出  $W_{N \times N}$  和  $W'_{N \times N}$  表示为分块矩阵的形式，如式(3-33)所示。

$$\begin{cases} W_{N \times N} = \begin{bmatrix} W_{L \times L} & W_{L \times U} \\ W_{L \times U}^T & W_{U \times U} \end{bmatrix} \\ W'_{N \times N} = \begin{bmatrix} W'_{L \times L} & W'_{L \times U} \\ W'_{L \times U}^T & W'_{U \times U} \end{bmatrix} \end{cases} \quad (3-33)$$

与 LDE 算法推导过程可以得出，可以将(3-30)表示为如下形式：

$$\begin{cases} \text{Maximize } J(V) = 2\text{tr} \left\{ V^T \left[ X (D' - W'_{N \times N}) X^T \right] V \right\} \\ \text{subject to } 2\text{tr} \left[ X (D - W_{N \times N}) X^T \right] = 1 \end{cases} \quad (3-34)$$

对式(3-34)应用拉格朗日 (Lagrange) 乘数法，可以得出式(3-35)所示：

$$X (D' - W'_{N \times N}) X^T v = \lambda X (D - W_{N \times N}) X^T v \quad (3-35)$$

对式(3-35)进行广义特征值分解，得到式(3-35)的特征值及其特征向量，表示为： $\lambda = [\lambda_1, \lambda_2, \dots, \lambda_n]^T$ ，其对应的特征向量为： $v = [v_1, v_2, \dots, v_n]^T$ 。取前  $d$  个



最大的特征值对应的特征向量构成变换矩阵  $V = [v_1, v_2, \dots, v_d]$ 。由 SDE 算法可知，维度变换后结果为：

$$z_i = V^T x_i \quad (3-36)$$

式(3-36)中， $z_i$ 表示输入高维数据点  $x_i$ 变换后的低维输出数据。

## 3.2 耦合度量学习及流形对齐的基本概念

### 3.2.1 耦合度量学习简介

在流形学习及对齐中，核心目标是衡量不同的集合的距离度量。距离度量是聚类、分类及检索等研究问题的核心。通常情况下，仅仅研究定义在原始数据空间的距离度量方法（如欧氏距离）无法满足实际情况的需要。距离度量学习方法的目標就是通过学习来实现距离的计算的一类方法。从不同维度来分，距离度量包括两个层次的内容：一是等维度空间的距离度量；二是不同维度空间的距离度量。前者可以通过欧式距离等传统的距离度量方法来进行计算，而后者无法直接进行计算。解决多维度及多集合的距离度量是耦合度量学习的核心内容。

对于两个不同集合： $X \subset \mathfrak{R}^{D_x}$ ， $Y \subset \mathfrak{R}^{D_y}$ ， $d(x, y)$ 表示不同集合中的数据点  $x \in X$ ， $y \in Y$ 之间的距离度量函数。以本文研究核心为例，假设  $x \in X$ 表示定位中的物理位置，通常为二维或者三维的低维物理空间； $y \in Y$ 表示 RSS 空间，其维度通常远远大于低维物理空间。当  $D_x = D_y$ 时，可以采用传统的距离度量函数来计算二者的距离，但通常无法找到其表示的物理意义；当  $D_x \neq D_y$ 时， $d(x, y)$ 没有定义。若可以将不同数据集映射到同一维度，则可以采用类似于传统距离度量的方法来计算距离。若存在以下耦合映射函数，即对  $X \subset \mathfrak{R}^{D_x}$ ， $Y \subset \mathfrak{R}^{D_y}$ 有：

$$D^c : \mathfrak{R}^{D_x} \times \mathfrak{R}^{D_y} \rightarrow \mathfrak{R} \quad (3-37)$$

通过耦合距离度量学习（Coupled Metric Learning, CML）实现不同集合的距离度量包括以下三个步骤：首先，通过映射目标函数  $f_x$ 及  $f_y$ 分别将数据集  $X$ 、 $Y$ 耦合到空间  $D^c$ ，分别记作： $\tilde{X} \subset \mathfrak{R}^{D^c}$ 和  $\tilde{Y} \subset \mathfrak{R}^{D^c}$ ；其次，在耦合空间的耦合距离度量定义为：

$$d_A = \mathfrak{R}^{D^c} \times \mathfrak{R}^{D^c} \rightarrow \mathfrak{R} \quad (3-38)$$

第三步，定义耦合距离度量，如式(3-39)所示。

$$d(x, y) = d_A^c(\tilde{x}, \tilde{y}) = d_A(f_x, f_y) \quad (3-39)$$

由上述步骤可以得出，其关键在于引入并计算出耦合空间，从而使得不同的集合之间的距离度量得出实现。从上述步骤可以得出，耦合度量学习需要确定的参数包括：映射函数  $f_x$  和  $f_y$  以及定义耦合度量的变换矩阵  $A$ 。为进一步优化耦合度量学习，从传统距离度量方法出发，可以得出如式(3-40)所示的距离度量公式。本文以线性映射为主，分析 CML 的一般形式。

$$d(x, y) = \|f_x(x) - f_y(y)\|_A = \sqrt{(f_x(x) - f_y(y))^T A (f_x(x) - f_y(y))} \quad (3-40)$$

与传统欧氏距离度量类似，可以将度量矩阵表示为实对称矩阵，记作  $A = Z_a Z_a^T$ ，将映射函数表示为线性变换。从而可以将式(3-40)简化为：

$$d(x, y) = \sqrt{(P_x^T x - P_y^T y)^T (P_x^T x - P_y^T y)} \quad (3-41)$$

从上式可以得出，CML 仅与两个线性变换相关。通过简化后，耦合度量学习的优化仅仅与线性变换有关，不必计算串联地多个变换过程，包括：降维与学习，使得算法更容易优化与更稳定。

### 3.2.2 流形对齐简介

流形对齐 (manifold learning, ML) 是研究不同流形上的多个采样或数据的集合。以下从两个流形的流形对齐为例，对流形对齐的基本理论进行说明。不同空间两个流形  $M_1 \in \mathbb{R}^{D_1}$  及  $M_2 \in \mathbb{R}^{D_2}$ 。两个流形的分别得到两个数据集合，记为式(3-42)。

$$\begin{aligned} X &= \{x_1, x_2, \dots, x_{N_1}\} \\ Y &= \{y_1, y_2, \dots, y_{N_2}\} \end{aligned} \quad (3-42)$$

流形对齐算法的目标函数的基本形式如式(3-43)所示。式(3-43)中从表达式上展现了流形对齐所包含的两个目标：一是最小两个流形映射的距离；二是尽可能保持原流形的结构。其中， $f, g$  分别表示流形的映射； $L^x, L^y$  分别表示广义拉普拉斯矩阵； $\mu$  为正则化因子。

$$L(f, g) = \mu \sum_{i \in N} \|f_i - g_i\|^2 + f^T L^x f + g^T L^y g \quad (3-43)$$

式(3-43)中，广义拉普拉斯矩阵可由相似矩阵 (Similarity Matrix) 来相互

转换，其关系如式(3-44)所示。式(3-44)中， $S_{ij}$ 表示相似度因子。

$$f^T L^x f = \sum_{i,j} (f_i - f_j)^2 S_{ij} \quad (3-44)$$

文献[49]中将式(3-43)所示的问题转化为最小化广义瑞利商（Rayleigh Quotient）的问题。其形式如式(3-45)所示。其中 $h = [f^T \ g^T]^T$ 。其中， $e$ 是元素个数为 $(N_1+N_2)$ 的全1的列向量。最小化广义瑞利商的问题最终可以通过特征值分解的来解析的求解。

$$\begin{aligned} \min_h L(h) &= \frac{L(f, g)}{f^T f + g^T g} \\ \text{s.t. } & h e^T = 0 \end{aligned} \quad (3-45)$$

上述为无监督流形对齐算法的基本理论。对于无监督流形对齐，没有指定不同的流形之间的对应关系，并不能有效地保持流形的结构，通常只用于存在仿射变换关系（如线性关系、旋转关系等）的流形之间的对齐。对应关系保持目标方程可以直观表达为式(3-46)所示。其中，符号上方“ $\sim$ ”表示两个流形的低维流形， $N$ 为样本点的数目。

$$\min_{(\tilde{X}, \tilde{Y})} J(\tilde{X}, \tilde{Y}) = \frac{1}{N} \sum_{i,j} \|\tilde{x}_i - \tilde{y}_j\|^2 \quad (3-46)$$

另一方面，为了流形对齐方法的统一，在实现不同 Radio Map 的更新时，需要实现多流形对齐，而关键在于将每一个数据集找到对应的映射。

### 3.3 基于 UCML 的流形对齐方法

#### 3.3.1 统一耦合度量学习

为了便于分析耦合度量学习算法，可以将上述多种耦合度量学习方法进行统一，提出一种统一的耦合度量学习方法（Universal Coupled Manifold Learning, UCML）。耦合度量学习的目标函数如式所示，即最小化耦合空间的不同数据集之间的距离。式中 $P_x, P_y$ 表示耦合空间的线性变换矩阵， $C$ 表示耦合关系矩阵。

$$\min_{P_x, P_y} J_c(P_x, P_y) = \sum_{i,j \in C} \|P_x^T x_i - P_y^T y_j\|^2 \quad (3-47)$$

##### (1) 基于相关关系的耦合度量学习

首先对基于相关关系的耦合度量学习（Relation Coupled Manifold

Learning, RCML) 方法进行分析。在 RCML 方法中, 其耦合矩阵可以简单的表示为:

$$C_{ij} = \begin{cases} 1 & (i, j) \in \mathbb{C} \\ 0 & \text{其它} \end{cases} \quad (3-48)$$

式(3-48)中,  $\mathbb{C}$  表示耦合空间。根据式(3-48)中的定义, 耦合度量的目标可以表示为:

$$J_c(P_x, P_y) = \sum_{i,j \in \mathbb{C}} \|P_x^T x_i - P_y^T y_i\|^2 C_{ij} \quad (3-49)$$

与式(3-47)的分析过程与似, 式(3-50)可以简化为:

$$J_c(P_x, P_y) = \text{Tr} \left( \begin{bmatrix} P_x \\ P_y \end{bmatrix}^T \begin{bmatrix} X & O \\ O & Y \end{bmatrix} \begin{bmatrix} C_h & -C \\ -C^T & C_v \end{bmatrix} \begin{bmatrix} X & O \\ O & Y \end{bmatrix}^T \begin{bmatrix} P_x \\ P_y \end{bmatrix} \right) \quad (3-50)$$

其中,  $C_h$ 、 $C_v$  均为对角阵, 其对角线元素可以表示为:

$$\begin{cases} C_h = \text{Diag} \left( \sum_i C_{i,j} \right) \\ C_v = \text{Diag} \left( \sum_j C_{i,j} \right) \end{cases} \quad (3-51)$$

引入尺度不变约束及平移不变约束后, RCML 方法的目标函数表示为:

$$\begin{aligned} \min \quad & \text{Tr}(P^T Z \Lambda Z^T P) \\ \text{s.t.} \quad & P^T Z Z^T P = I, P^T Z e = 0 \end{aligned} \quad (3-52)$$

其中,  $P = \begin{bmatrix} P_x \\ P_y \end{bmatrix}$ ,  $Z = \begin{bmatrix} X & O \\ O & Y \end{bmatrix}$ ,  $\Lambda = \begin{bmatrix} C_h & -C \\ -C^T & C_v \end{bmatrix}$ 。I 为单位矩阵,  $e$  为全为

1 的列向量。如式(3-50)所示的优化问题可以采用广义特征值分解求解, 其特征方程如式(3-52)所示, 其中  $\lambda$ 、 $p$  分别表示特征值与特征向量。其解为最小的  $D^c$  个非零特征值所对应的特征向量构成特征变换矩阵  $P$ 。至于在广义特征值分解存在的奇异值会在后续分析进行优化。

$$Z \Lambda Z^T p = \lambda Z Z^T p \quad (3-53)$$

## (2) 基于 Fisher 准则的判别耦合度量学习

基于 Fisher 准则的判别耦合度量学习 (Discriminant Coupled Manifold Learning based on Fisher Criterion, DCML-FC) 方法是基于类别信息的判别耦合度量学习方法的一种。判别耦合度量学习是在 RCML 方法上进行的改进,

其不仅考虑了集合间的相似关系，而且还引入集合的不相似有关系。一种直观的考虑是尽可能保持集合间的相似关系的同时保证集合的不相似关系最大化。相似与不相似的概念是一种二元分类的方法，可以扩展到多个类别的情况。为便于分析，引入两个耦合关系矩阵分别表示集合中的相似与不相似关系： $C^+$ 、 $C^-$ ，其耦合关系矩阵定义如式(3-48)所示。由判别耦合度量矩阵的目标，其目标函数如式(3-54)所示。

$$\begin{aligned}\min J_c^+(P_x^+, P_y^+) &= \sum_{i,j \in C^+} \|P_x^+ x_i - P_y^+ y_j\|^2 \\ \max J_c^-(P_x^-, P_y^-) &= \sum_{i,j \in C^-} \|P_x^- x_i - P_y^- y_j\|^2\end{aligned}\quad (3-54)$$

引入加权系数 $\alpha$ ，可以将式(3-54)所示的两个目标函数简化为一个目标函数，即如式(3-55)所示。

$$\min J_c(P_x, P_y) = J_c^+ - \alpha J_c^- \quad (3-55)$$

与 RCML 方法分析过程一致，在引入尺度不变约束与平移不变约束后，其目标函数形式与式(3-50)一致，仅其中的耦合关系矩阵由下式计算：

$$C = C^+ - \alpha C^- \quad (3-56)$$

以上为二元分类关系时，基于判别的耦合度量方法的过程，而在多种类别的情况下，采用散度矩阵来衡量相似度。DCML-FC 方法中，其目标函数为最小化 Fisher 准则的值，如式(3-57)所示。其中， $\Gamma_w$ 、 $\Gamma_b$  分别表示类内散度（within-scatter）矩阵和类间散度（between-scatter）矩阵。

$$\min J_p = \text{Tr} \left( \frac{P^T \Gamma_w P}{P^T \Gamma_b P} \right) \quad (3-57)$$

假设集合共分为 $\gamma$ 类，给定如式(3-52)中的矩阵 $P$ 及 $Z$ 的定义，散度矩阵可以表示为式(3-58)，其中， $z_k^\gamma$ 是第 $\gamma$ 类中的第 $k$ 个元素， $\bar{z}^\gamma$ 是第 $\gamma$ 类的均值。 $N_\gamma$ 为第 $\gamma$ 类中元素的个数， $\bar{z}$ 为数据集合元素的均值。

$$\begin{aligned}\Gamma_w &= \sum_{\gamma} \sum_k (z_k^\gamma - \bar{z}^\gamma)(z_k^\gamma - \bar{z}^\gamma)^T \\ \Gamma_b &= \sum_{\gamma} N_\gamma (\bar{z}^\gamma - \bar{z})(\bar{z}^\gamma - \bar{z})^T\end{aligned}\quad (3-58)$$

而 UCML 方法可以将现有的耦合度量学习方法进行统一，其核心方法是引入加权散度矩阵：

$$\Gamma = \frac{1}{2} \sum_{i,j} (x_i - x_j)(x_i - x_j)^T w_{ij} \quad (3-59)$$

可以证明，当权值矩阵取值为集合中元素个数的倒数时，式(3-59)的值与 Fisher 准则的散度矩阵一致<sup>[58]</sup>。首先，证明 RCML 方法与 UCML 方法的一致性。令  $w_{ij} = 2C_{ij}$ ，式(3-59)可以简化为：

$$\Gamma = \frac{1}{2} \sum_{i,j} (P_x x_i - P_y y_i)(P_x x_i - P_y y_i)^T 2C_{ij} \quad (3-60)$$

从式(3-60)的基本形式可以看出，与 RCML 方法的目标函数一致。为了证明 UCML 方法与 DCML 方法的一致性，先引入耦合度量学习的准则：

$$\min J = \text{Tr} \left( \frac{\Gamma^+}{\Gamma^-} \right) \quad (3-61)$$

式(3-61)中， $\Gamma^+$ 、 $\Gamma^-$  均为加权散度矩阵。令权值矩阵分别与  $2C^+$ 、 $2C^-$  相等，式(3-59)可以表示为：

$$\min J = \text{Tr} \left( \frac{P^T Z \Lambda^+ Z^T P}{P^T Z \Lambda^- Z^T P} \right) \quad (3-62)$$

式(3-62)与尺度不变约束及平移不变约束条件相结合，可以采用广义特征分解来优化该目标函数。需要进一步说明的是，在广义特征值分解中，存在奇异值的情况，导致解不稳定。目前有三种常见的方法，一是对待分解矩阵正则化处理，二是将数据集矩阵进行主成分分析后，再进行广义特征值分解。前两种方法都会引入额外的参数，会导致整个优化过程并非达到最优。而更为稳定求解的方法是采用奇异值分解（Singular Vector Decomposition, SVD），具体分析详见文献[59]。

### 3.3.2 基于 UCML 的流形对齐算法

在对基于 UCML 的流形对齐算法分析之前，先对流形对齐的基本思想进行分析。流形对齐包含两个层次的目标，一方面保证不同流形之间的对应关系，即不同的集合相对应的数据点在耦合空间同样保持关系对应，这一目标由 UCML 方法来实现。其目标函数可以表示为式(3-63)，其中  $1/N_c$  为归一化系数。

$$\min J_c(f_x, f_y) = \frac{1}{N_c} \sum_{i,j \in C} \|f_x(x_i) - f_y(y_i)\|^2 \quad (3-63)$$

另一方面，流形对齐同样要保持各自数据集合的流形的结构在耦合空间的稳定性与一致性。这一目标主要通过保持原始集合的近邻及相似关系来实现。其目标函数可以表示为式，其中 $1/N_x$ 、 $1/N_y$ 为归一化系数， $S_{ij}^x$ 、 $S_{kl}^y$ 分别表示集合 $X$ 、 $Y$ 的近邻关系。

$$\begin{aligned}\min J_X(f_x) &= \frac{1}{N_x} \sum_{i,j} \|f_x(x_i) - f_x(x_j)\|^2 S_{ij}^x \\ \min J_Y(f_y) &= \frac{1}{N_y} \sum_{k,l} \|f_y(y_k) - f_y(y_l)\|^2 S_{kl}^y\end{aligned}\quad (3-64)$$

根据 MA 的目标函数，可以得出其加权目标函数：

$$\min J(f_x, f_y) = J_c(f_x, f_y) + \alpha_x J_X(f_x) + \alpha_y J_Y(f_y) \quad (3-65)$$

在两个流形集合的元素一一对应时，式(3-65)可以分为三项分别简化，第一部分，在引入单位矩阵作为耦合关系矩阵条件下，可以简化为式(3-52)所示。第二与第三部分在结构与形式上是一致的。

$$\begin{aligned}J_X &= 2/N_x \left( \text{Tr}(P_x^T X L^x X^T P_x) \right) \\ J_Y &= 2/N_y \left( \text{Tr}(P_y^T Y L^y Y^T P_y) \right)\end{aligned}\quad (3-66)$$

式(3-65)中两项可以简化为式(3-66)，其中 $L^x$ 、 $L^y$ 为广义拉普拉斯矩阵，其定义为如式。

$$L_{ij}^x = \begin{cases} \sum_i S_{ij} - S_{ij}, & i = j \\ -S_{ij}, & i \neq j \end{cases} \quad (3-67)$$

由上述分析，其 UCML 的流形对齐算法的目标函数可以表示为：

$$\min J(f_x, f_y) = \min J(P_x, P_y) = \text{Tr}(P^T \Lambda Z \Lambda Z^T P) \quad (3-68)$$

式(3-68)中， $\Lambda$ 的表达式为：

$$\Lambda = \begin{bmatrix} I/N_c + 2L^x/N_x & -I/N_c \\ -I/N_c & I/N_c + 2L^y/N_y \end{bmatrix} \quad (3-69)$$

在引入尺度不变约束及平移不变约束等条件下，其目标函数可以由广义特征值分解来求解。而在实际中，不同集合间的数据并非全都一一对应，且明确标记，因此在实际应用于多采用基于 UCML 的半监督流形对齐算法。这种半监督流形学习算法将根据集合间的对应关系引入相似关系耦合矩阵，使得式(3-68)重新定义为：

$$\Lambda' = \begin{bmatrix} C_h/N_c + 2L^x/N_x & -C/N_c \\ -C^T/N_c & C_v/N_c + 2L^y/N_y \end{bmatrix} \quad (3-70)$$

以下对基于 UCML 的 MA 算法的基本流程进行说明：

表 3-1 基于 UCML 的 MA 算法流程

输入：数据集合： $X$ 、 $Y$
输出：流形对齐矩阵： $P_x$ 、 $P_y$
第一步：根据输入数据估计耦合关系矩阵 $C$ 及相似关系矩阵 $S^x$ 、 $S^y$ ，并给出归一化系数； 第二步：计算广义拉普拉斯矩阵 $L^x$ 、 $L^y$ ，并计算矩阵 $\Lambda'$ ； 第三步：对矩阵 $Z^T \Lambda' Z$ 、 $Z^T Z$ 进行奇异值分解，得出 $Z^T Z = HVH^T$ ， $(HV^{-1/2})^T Z^T \Lambda' Z (HV^{-1/2}) = U \Sigma U^T$ ； 第四步：由第三步 SVD 结果，可以计算出广义特征分解的特征向量： $HV^{-1/2}U$ ； 第五步：根据耦合空间的维度，由第四步结果计算 $P_x$ 、 $P_y$ 。

本文采用流形对齐方法实现不同的移动终端的 Radio Map 的对齐，因此需要实现多流形的对齐。多流形对齐是双流形对齐方法的平行推广，其理论基础及分析前者均一脉相承。以下对多流形对齐方法的理论及其算法流程进行简要分析。假设有  $M$  个流形，分别属于不同的集合空间： $Q_1 \subset \mathfrak{R}^{D_1}, Q_2 \subset \mathfrak{R}^{D_2}, \dots, Q_M \subset \mathfrak{R}^{D_M}$ ，不同的集合间的耦合关系矩阵表示为  $C_{ij}$ ，其含义为  $Q_i$  与  $Q_j$  之间的耦合有关系矩阵。在流形对齐中，其耦合空间的映射是由线性映射变换矩阵  $P$  来实现的。从基于 UCML 的 MA 算法的分析推广可以知，多流形对齐的目标函数可以简化为：

$$J(P_1, P_2, \dots, P_M) = \text{Tr}(P^T Z \Lambda Z^T P) \quad (3-71)$$

$$\text{其中， } P = \begin{bmatrix} P_1 \\ P_2 \\ \vdots \\ P_M \end{bmatrix}, \quad Z = \text{diag}(Q_1, Q_2, \dots, Q_M),$$



$$\Lambda = \begin{pmatrix} \sum_j \frac{1}{N_{1j}} C_{1j}^h + \sum_i \frac{1}{N_{i1}} C_{i1}^v + \frac{L^1}{N_1} & \cdots & -\frac{1}{N_{1M}} C_{1M} \\ \vdots & \ddots & \vdots \\ -\frac{1}{N_{1M}} C_{1M}^T & \cdots & \sum_j \frac{1}{N_{Mj}} C_{Mj}^h + \sum_i \frac{1}{N_{M1}} C_{M1}^v + \frac{L^M}{N_1} \end{pmatrix}。$$

在引入尺度不变约束及平移不变约束后，多流形对齐的目标函数的优化及求解可以采用与基于 UCML 方法的流形对齐算法相同的方法来实现。

### 3.4 SRA-MA

超分辨率分析 (Super Resolution Analysis, SRA) 技术是图像处理 (Image Processing) 领域的一项关键技术。这一技术的应用前景广泛，包括在图像处理、数字电视、视频监控及图像压缩等。SRA 技术在诸如 Photoshop 之类的商业软件中已经开始使用，但其为满足这一目标，通常采用较为基于平滑性假设的方法，如双线性、双立方、样条插值及其改进的自适应插值等<sup>[60~62]</sup>。由于基于平滑性先验假设，其通常导致图像模糊等问题，整体性能不高。

为了改善 SRA 技术的性能，后续提出了基于重构及学习算法的 SRA。基于重构的 SRA 的目标是经退化后的高分辨率的图像尽可能与低分辨率目标相似。这一类从低分辨率到高分辨率的重构问题通常属于典型的病态问题。基于重构的超分辨率算法的代表性算法包括：迭代反投影算法<sup>[63]</sup>、凸集影射算法<sup>[64]</sup>。这一类方法的缺点在于容易丢失高频信息。基于学习的超分辨率算法恰好能够突破前两类的约束和局限。这一方法的核心是采用学习算法从训练集得到高低分辨率目标之间的映射关系。早期的代表性算法有基于样例及基于图像基元的超分辨率分析<sup>[65~66]</sup>。这两种方法是基于原始数据域的学习型 SRA 技术，另一类代表性的基于学习的 SRA 技术是在变换域实现的，包括基于离散余弦变换的 SRA 技术、基于特征脸域的 SRA 技术、基于稀疏表达的 SRA 技术。这一种方法各自在不同的变换域实现 SRA。

本文采用基于流形对齐的 SRA 技术实现不同的分辨率下的 Radio Map 的学习。一方面，这一方法的基本理论与流形对齐算法理论一致；另一方面，这一方法可以有效的学习不同分辨率及不同的空间的 Radio Map 的特征。在分析算法之前，对不同的分辨率的 Radio Map 进行简要定义。Radio Map 的分辨率是由单位面积内参考点的数目决定的，即参考点的密度。一般情况下，随着参考点的数目增加，Radio Map 的定位分辨率增加。这一种 Radio Map 的超分辨

率分析主要是实现稀疏 Radio Map 的超分辨率分析，从而实现 Radio Map 的快速建立。

基于流形对齐的超分辨率（SRA-MA）算法同样包括三个层次：第一，使得高低分辨率目标在耦合流形上尽可能相似；第二，在耦合空间，尽可能保持高分辨率目标的重构关系；第三，在耦合率，尽可能保持低分辨率目标的重构关系。因此，SRA-MA 的目标函数由三部分组成：

$$\min J(f_h, f_l) = J_c(f_h, f_l) + \alpha_h J_H(f_h) + \alpha_l J_L(f_l) \quad (3-72)$$

式(3-72)， $f_h$ 、 $f_l$  表示高低分辨的映射函数，由线性变换矩阵  $P_h$ 、 $P_l$  实现。 $J_c(f_h, f_l)$  表示高、低分辨率目标之间的对应，可以表示为式(3-73)，其简化结果与式(3-52)一致。

$$J_c(f_h, f_l) = \frac{1}{N_c} \sum_i \|P_h h_i - P_l l_i\|^2 \quad (3-73)$$

$J_H(f_h)$ 、 $J_L(f_l)$  表示高、低分辨率目标的重构关系的保持，其目标函数与 LLE 算法的目标函数一致。以下将  $J_H(f_h)$ 、 $J_L(f_l)$  分别表示为：

$$\begin{aligned} J_H(f_h) &= \frac{1}{N_h} \sum_i \left\| P_h h_i - \sum_{j \in \mathcal{N}(i)} w_{ij}^h P_h h_j \right\|^2 \\ J_L(f_l) &= \frac{1}{N_l} \sum_m \left\| P_l l_m - \sum_{n \in \mathcal{N}(m)} w_{mn}^l P_l l_n \right\|^2 \end{aligned} \quad (3-74)$$

式(3-74)的简化过程与 LLE 算法的分析一致，以  $J_H(f_h)$  为例，其目标函数可以简化为：

$$J_H(f_h) = \frac{1}{N_h} \text{Tr} \left( H^T P_h (I - W^h)^T (I - W^h) P_h^T H \right) \quad (3-75)$$

令  $M^h = (I - W^h)^T (I - W^h)$ ，结合式(3-75)与式(3-74)，SRA-MA 算法的目标函数可以简化为：

$$J_c(f_h, f_l) = \text{Tr} (P^T Z \Lambda Z^T P) \quad (3-76)$$

$$\text{其中， } P = \begin{bmatrix} P_h \\ P_l \end{bmatrix}, \quad Z = \begin{pmatrix} H & 0 \\ 0 & L \end{pmatrix}, \quad \Lambda = \begin{pmatrix} \frac{I}{N_c} + \frac{M^h}{N_h} & -\frac{I}{N_c} \\ -\frac{I}{N_c} & \frac{I}{N_c} + \frac{M^l}{N_l} \end{pmatrix}。 \text{在引入尺度及}$$

平移不变约束后，可以通过求解广义特征值来优化 SRA-MA 的目标函数。以下对 SRA-MA 的算法基本流程进行分析：

表 3-2 SRA-MA 算法流程

输入：数据集合： $H$ 、 $L$
输出：流形对齐矩阵： $P_h$ 、 $P_l$
第一步：根据输入数据估计耦合关系矩阵 $C$ 及重构矩阵 $W^h$ 、 $W^l$ ，并给出归一化系数；
第二步：计算矩阵 $M^h = (I - W^h)^T (I - W^h)$ 、 $M^l = (I - W^l)^T (I - W^l)$ ，并计算矩阵 $\Lambda$ ；
第三步：对矩阵 $Z^T \Lambda Z$ 、 $Z^T Z$ 进行奇异值分解，得出 $Z^T Z = HVH^T$ ， $(HV^{-1/2})^T Z^T \Lambda Z (HV^{-1/2}) = U \Sigma U^T$ ；
第四步：由第三步 SVD 结果，可以计算出广义特征分解的特征向量： $HV^{-1/2}U$ ；
第五步：根据耦合空间的维度，由第四步结果计算 $P_h$ 、 $P_l$ 。

### 3.5 本章小结

本章首先流形的基本理论进行了简单的介绍，明确了微分流形、黎曼流形及等距流形的基本数学条件，并定义了流形距离衡量及流形学习。然后介绍了 LLE、ISOMAP、LDE 及 SDE 等四种常用的流形学习方法的基本理论及其实现过程，为后续统一耦合度量流形对齐方法的分析奠定了理论基础。接下来分析了耦合度量学习及流形对齐方法的基本概念，并对流形对齐中对应关系的实现进行了详细分析。从基于相关关系及 Fisher 准则的耦合度量学习方法出发，对耦合度量学习的理论及实现过程进行了分析，并采用了奇异值分解方法实现特征变换过程的优化求解。在此基础上，推导出了统一耦合度量学习方法，从而将耦合度量学习方法推广至多类不同数据集的耦合度量学习及流形对齐方法。本章实现了从物理空间与 RSS 信号的对应关系重建出稀疏 Radio Map 的超分辨率分析理论及算法流程。本章提出的 UCML-MA 及 MA-SRA 算法将应用于 HIT-WILS10 及 HIT-WISL12 等基于 WLAN 的室内定位系统中。

## 第4章 基于流形对齐的 WILS 及其性能分析

在第 3 章的理论分析的基础上，本章首先对 HIT-WILS10 及 HIT-WILS12 等两个典型室内环境中部署的 WILS 进行分析，并对本文采用的多种测试方法及终端进行简要说明。结合 WILS 及流形对齐理论，提出基于流形对齐的 Radio Map 的建立及基于流形对齐的 WLAN 室内定位方法的系统架构及算法框图，并在此基础上提出了两种 WLAN 室内定位方法：DML 及 reKNN 方法。最后根据不同的终端、不同环境的实测 RSS 及 Radio Map，对本文提出的 Radio Map 建立及室内定位方法的性能进行定位性能仿真分析。仿真结果表明，本文提出的基于流形对齐的 Radio Map 建立及室内定位方法可以在大幅度降低 Radio Map 建立的工作量的前提下，有效地保持定位算法的性能，并对不同系统及终端有良好的适应性。

### 4.1 WILS 的系统架构及其部署

#### 4.1.1 基于流形对齐的 WILS 的基本框架

基于流形对齐方法的 WLAN 室内定位系统（MA-WILS）总体功能模块包括：RSS 测试平台、I-GIS 数据库、Radio Map 数据库、Radio Map 建立模块、Radio Map 更新模块以及室内定位模块，其关系示意图如图 4-1 所示。各个模块的功能为：RSS 测试平台中包括笔记本、平台电脑、智能手机等可以用来测试 RSS 的设备。本文采用安装有 NetStumbler 软件的笔记本上测试 RSS，开发用于智能手机的软件平台实现对 RSS 测试，其输出数据将用于 Radio Map 的建立及在线室内定位；I-GIS 数据库存储室内定位区域的地理信息，特别是定位区域内的坐标；Radio Map 数据库存储建立的 Radio Map，并用于在线定位。在实际测试时，Radio Map 将存储在仿真平台中，模拟数据库运行；Radio Map 建立模块、Radio Map 更新模块以及室内定位模块分别完成 Radio Map 的建立及室内定位。

图 4-1 所示的 MA-WILS 的工作流程包括两个部分：第一，Radio Map 的建立。RSS 测试平台采集的 RSS 及参考点的坐标传输至 Radio Map 建立模块，结合 I-GIS 数据实现 Radio Map 建立；第二：在线阶段，RSS 测试平台采集的 RSS，与 Radio Map 相结合。采用基于流形对齐方法的 WLAN 室内定位方法

实现定位，其核心方法是通过将在线得到的 RSS 与离线得到的低维空间的特征映射向量相乘并与低维 Radio Map 空间进行对齐实现定位。

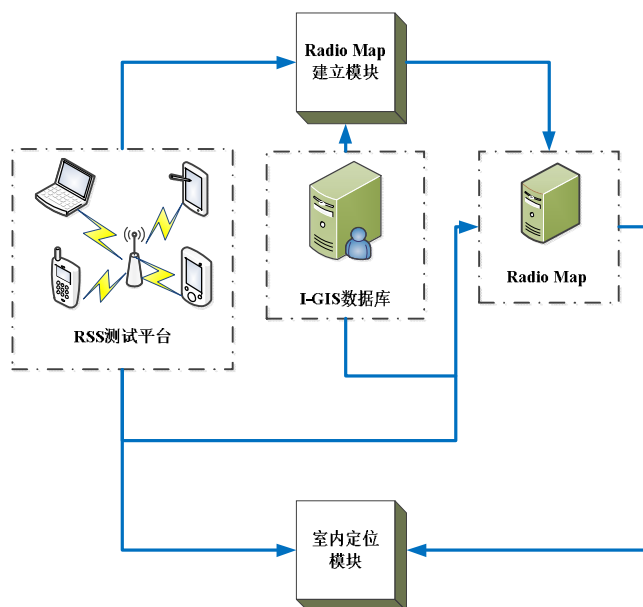


图 4-1 基于流形对齐的 WILS 的总体框架

## 4.1.2 WILS 的部署

基于 WLAN 的室内定位系统的部署包括三个方面的工作：WAP 的配置与部署、室内定位区域的 RP 的标识及各个 RP 处的 RSS 的采集。从目前来看，WAP 的部署主要在满足区域内通信要求的前提下，兼顾 WILS 的要求。室内定位区域内的 RP 的标识主要对 RP 的密度、分布特点及标记特征进行说明。本文并不考虑 WAP 的部署时通信要求与 WILS 的要求的平衡问题。本文主要针对几种已有的实验环境内 WAP 的部署情况、参考点的标识进行说明，并对不同场景内的 RSS 测试进行分析。以下对部署在哈尔滨工业大学科学园 2A 栋的两个系统进行说明——HIT-WILS10 和 HIT-WILS12。

### (1) HIT-WILS12 的定位区域

HIT-WILS12 部署在哈尔滨工业大学科学园 2A 栋 12 楼，定位区域为走廊环境，其面积约为  $260 m^2$ ，如图 4-2 所示。定位区域内每间隔  $0.5 m$  设置一个 RP，共计 900 个参考点，均匀分布在整個定位区域（其标识与坐标均由实验室成员完成，其均匀采样网格示意如图 4-3 所示）。在定位区域内，依托于各个门框部署了 27 个 WAP，离地面高度为  $2 m$ 。采用 27 个 WAP 可以实现对整

个实验区域的全面覆盖，且每个参考点的可见的 WAP 的个数都有 13 个以上，满足且 WAP 的数目大大超过了 WILS 系统的要求。

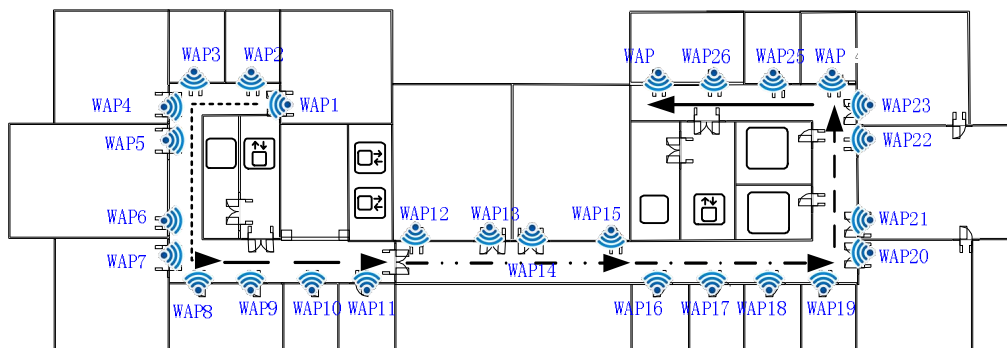


图 4-2 哈尔滨工业大学科学园 2A 栋 12 层定位区域示意图

目前已经建立的 Radio Map 由联想 V450 电脑（操作系统为 XP SP3）安装 NetStumbler 软件采集相应位置的 RSS，且每个参考点分四个方向各采样 100 个 RSS 值。由于 NetStumbler 软件输出的文档除了 RSS 外，还有大量 WAP 的设置信息，因此需要在采集后对数据进一步的提取得出相应的 RSS。

#### (2) HIT-WILS10 的定位区域

图 4-5 所示为哈尔滨工业大学科学园 2A 栋 10 层所部署的 WLAN 室内定位系统，其定位区域包含学生实验室、联合实验室（目前已无法正常采集数据）及其部分走廊。在定位区域内，依托于各个门框及墙壁共部署了 8 个 WAP，离地面高度为 2m。HIT-WILS10 所在的定位区域比前者的环境更为复杂，其定位区域内动态变化复杂，区域内设备、人员从多，对室内定位带来一定的挑战，同时也较为真实的再现了实际的办公环境内的情况。




图 4-3 均匀采样网格示意图




图 4-4 非均匀采样示意图

目前已建立的部分 Radio Map 是采用智能手机平台实现的。由于实验环境的限制，其采样密度比较随机，且比较稀疏。但其 RSS 的采样同样是由人工完成，且参考点分布均匀。




图 4-5 哈尔滨工业大学科学园 2A 栋 10 层定位区域示意图

### (3) 测试平台及 Radio Map 采样分辨率

除了对定位区域进行均匀采样，其参考点的标识还会进行非均匀采样分析。结合 RSS 测试方案，本文将采用多种不同的平台，采集建立 Radio Map 所需的样本。第一，从已有的均匀采样网络改变为非均匀采样网格（如图 4-4 所示），特别是对靠近墙壁的参考点的省略。因为根据实际情况，很少有人会贴着墙壁行走。并且尝试从非均匀 RSS 对均匀参考点条件下的 RSS 进行预测，以测试本文提出算法的有效性；第二，采用不同的测试平台，包括：多种型号笔记本、多种型号的智能手机对 RSS 进行测试。目前已有的 Radio Map 采用联想 V450、OPPO T29、Google Nexus 5 及 Samsung Note II 等四种平台进行测试。

目前可以采用的 RSS 的测试趋于多样化，包括：笔记本及其它智能移动终端，如智能手机、平板电脑等。本文将采取两种不同的测试方案来建立 Radio Map。第一：根据单一测试终端测试各个参考点的 RSS 值，并经过初步数据提取形成原始的 Radio Map，用于本文算法建立 Radio Map 及本文提出的定位方法的性能的对比较分析；第二：根据不同型号的笔记本、不同的型号的智能手机终端手动采集的部分参考点的 RSS 并记录相应的参考点的坐标，用于测试本文提出方法从稀疏 RSS 建立 Radio Map 的性能并与原始的 Radio Map 进行对比分析。

Radio Map 的采样分辨率设置方面，实测数据中共设置了 16 种不同形式的分辨率，其采样网格从  $0.5m \times 0.5m$  增加  $2m \times 2m$ ，包括矩形采样网格和方形

采样网格。为了降低数据采集的工作量，整个数据采集仅进行一次。通过在 HIT-WILS10 和 HIT-WILS12 等两个系统中以  $0.5m \times 0.5m$  间隔建立最高分辨率 Radio Map，并在每个参考点上进行多达 400 次采样。在此基础上，根据不同的分辨率要求，从原始 Radio Map 稀疏化提取出相应采样网格的 Radio Map，从而生成 16 种不同分辨率的 Radio Map。性能测试数据均为随机采样：通过在测试点以随机姿态（终端方位、终端高度及偶然导体等因素均随机设置）测试 RSS，并存储为测试数据库。

## 4.2 基于流形对齐的 WLAN 室内定位方法

基于流形对齐方法的 WLAN 室内定位方法中，包括对 Radio Map 的建立及基于流形对齐方法的 WLAN 室内定位方法的实现。

### 4.2.1 基于流形对齐的 Radio Map 的建立

从上述分析可以看出，Radio Map 建立是 WILS 实现的基础。本文将采用流形对齐与多流形对齐方法相结合，实现 Radio Map 的建立。图 4-6 所示为基于流形对齐方法的 Radio Map 建立的总体方案。Radio Map 的建立过程为：采用单一 RSS 测试平台对稀疏参考点及非均匀分布的参考点进行 RSS 采样，并进行初步数据的预处理，形成 Radio Map；然后采用 SRA-MA 算法对稀疏 Radio Map 进行超分辨率分析；根据 I-GIS 数据库及 Radio Map 的采样密度要求，由 I-GIS 提供的高分辨率地理信息数据，用 SRA-MA 输出进行 RSS 空间对齐，从而实现 Radio Map 的建立。

在基于流形对齐方法的 Radio Map 建立中，其中的核心概念为分辨率。与图像处理领域概念不同，本文采用的分辨率的定义为：在物理空间内，单位面积内的参考点的数目。例如，稀疏 Radio Map 的采样密度的为  $2m \times 2m$  的网格，则其分辨率为 0.25；而重建时，I-GIS 系统生成的高分辨率地理信息的  $0.5m \times 0.5m$ ，则其分辨率为 4。而从超分辨率的角度来看，重建后的 Radio Map 的分辨率是稀疏 Radio Map 的分辨率的 16 倍。从单次采样的 Radio Map 来对比，其 Radio Map 建立的工作量仅为高分辨率 Radio Map 建立工作量的  $1/16$ ，从而极大程度地提高 Radio Map 建立效率。



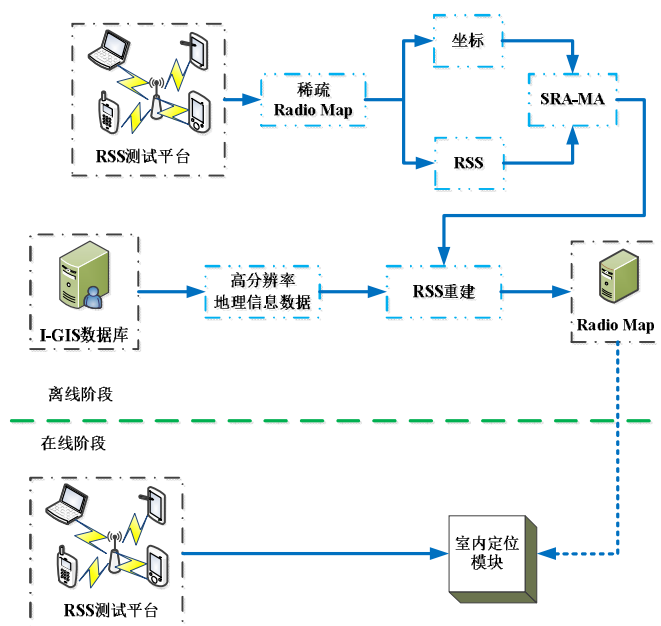


图 4-6 基于流形对齐的 Radio Map 建立方法

#### 4.2.2 基于流形对齐的 WLAN 室内定位方法

基于流形对齐方法的 WLAN 室内定位方法实现的是：离线阶段提取 Radio Map 中 RSS 及其对应参考点的之间流形对齐映射特征向量。基本假设是 Radio Map 中的 RSS 所处的信号空间的低维本征空间且与物理空间的位置存在对应关系。本文采用的基于流形对齐的 WLAN 室内定位方法的方案如图 4-7 所示。离线阶段时，采用 UCML-MA 算法对 Radio Map 中的进行 RSS 空间与物理空间的流形对齐，得出相应的流形对齐向量，构成在线定位数据库（Online Localization Database, OLB），并用于在线定位阶段的直接映射定位算法（Direct Mapping Localization, DML）中。需要进一步说明的是，在使用 UCML-MA 算法时，其输入 Radio Map 既可以是稀疏 Radio Map，也可以是重建后的高分辨率的 Radio Map。

本文提出了两种 WLAN 室内定位方法。在线阶段时，待定位的终端采集 RSS，然后采用 DML 或 reKNN 算法，从而实现位置估计。其定位过程的运算量小，主要是数值乘法，在线定位算法复杂度低。需要进一步说明的是：在仿真分析中，将在线定位数据库，与 Radio Map 及 RSS 均存储在同一台 PC 机中，数据存取与调用。在实际定位过程中，在线定位数据库需要从服务器端传输至本地用户，且在线定位数据库根据 Radio Map 的更新动态变化。

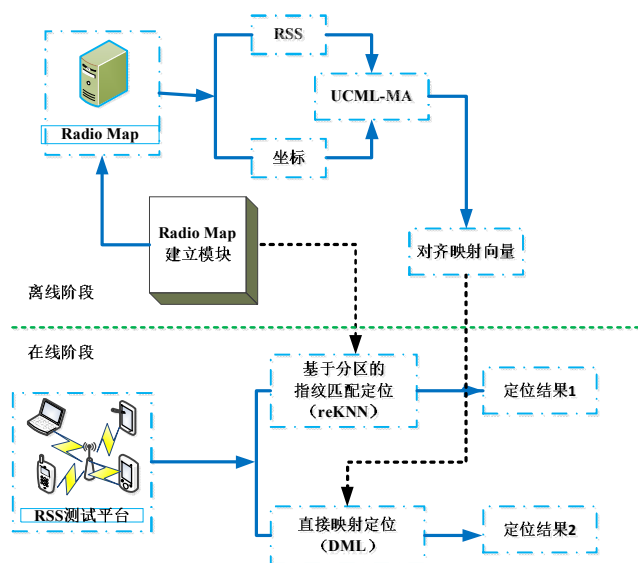


图 4-7 基于流形对齐的 WLAN 室内定位方法

以下对 DML 算法工作流程进行详细说明。第一步：根据 Radio Map 分辨率及重建 Radio Map 的超分辨率建立重建后的 Radio Map，作为 UCML-MA 算法的输入；第二步：采用 UCML-MA 算法对 Radio Map 进行分析，得出优化后的映射变换矩阵；第三步：根据在线接收到的 RSS 估计测试平台的位置。将 RSS 与映射变换矩阵相乘，将 RSS 直接映射至物理空间，实现室内定位。

本文采用 DML 及 reKNN 等两种室内定位方法的目的在于提高定位效率。当测试平台仅有少数参考点数据，且作为一个新的终端进行待定位区域时，DML 算法的离线学习过程需要消耗一定的时间，为降低这一学习过程对实时性能的影响，可以先采用 reKNN 算法实现匹配定位，然后再通过 DML 算法来更新定位结果。同时，两种定位结果可以采用数据融合及滤波等算法作进一步分析。


### 4.3 多终端情形下 DML 及 reKNN 的性能分析

本文采用了三种不同的移动终端：OPPO T29、Google Nexus 5 及 Samsung Note II 对 HIT-WILS10 系统中所在定位区域内进行了完整的 RSS 测试，并建立了 16 种不同分辨率下的 Radio Map。RSS 采集使用的安装在 Android 平台上的 RSS 测试应用程序（程序由孟维晓教授实验组开发）实现。根据 Radio Map 采样次数不同，三个终端均分别采集了单次采样 Radio Map、10 次采样均值 Radio Map 及 15 次采用均值 Radio Map 等三种不同的 Radio Map（记为 RM1、RM2 及 RM3）。为了对比 DML 及 reKNN 算法对不同终端的通用性，


在进行 Radio Map 重建及定位性能测试过程中，不同的 Radio Map 及不同终端的性能分析时，均采用了通用的参数设置。

本节以 OPPO T29 为代表终端，对不同采样分辨率下多种不同定位方法的定位性能进行对比分析。图 4-8 所示为不同采样分辨率条件下，OPPO T29 的定位误差均值分析。在图中，分别对三种不同的 Radio Map 指纹数据库、三种不同的定位方法进行性能对比分析。需要指出的是：等分辨率指的是稀疏 Radio Map 与重建 Radio Map 的采样分辨率相等，无超分辨率重建；超分辨率是指重建 Radio Map 的采样分辨率与稀疏 Radio Map 之比。这个比值通常大于 1，表示重建 Radio Map 的采样分辨率比稀疏 Radio Map 的采样分辨率高，从而实现 Radio Map 的快速建立，并且可以实现给定采样分辨率的 Radio Map 的建立。


从等分辨率的角度分析，随着采样分辨率的增加，DML、KNN 及 reKNN 算法的误差均值都呈下降的趋势，但存在奇异点，特别是对 DML 算法，在三种不同 Radio Map 条件下都出现了奇异点。这一直接映射的稳定性有关，并不能有效地克服原始数据中的波动性。从 DML 算法的奇异值分布来看，随着 Radio Map 采样次数的增加，反而这一波动性表现得更加明显。这一现象在超分辨率中也有，趋势一致。相对地，KNN 及 reKNN 算法的误差均值就更加稳定。




(a-1) 等分辨率下 RM1 误差均值




(a-2) 超分辨率下 RM1 误差均值




(b-1) 等分辨率下 RM2 误差均值



(b-2) 超分辨率下 RM2 误差均值



(c-1) 等分辨率下 RM3 误差均值




(c-2) 超分辨率下 RM3 误差均值


图 4-8 不同采样分辨率下 OPPO T29 的定位误差均值分析

而从采样次数，即三种不同的 Radio Map 来看，重采样次数的增加对定位误差均值的改善并不明显。因此，单纯地增加重采样次数并不能改善性能。从不同定位算法来看，KNN 算法的整体性能比 DML 及 reKNN 算法好，但其前提条件是其 Radio Map 的采样分辨率要维持 4（实验中采用的最高分辨率）。KNN 算法只有在高采样分辨才可以达到较好的定位性能。


从图 4-8 中可以看出，采用超分辨率重建 Radio Map 的方法可以在有效减少 Radio Map 建立的工作量的前提下，使得 DML 及 reKNN 算法的定位误差均值与原 Radio Map 的定位误差均值可比拟。从图中同样可以看出，采用重建后 Radio Map 进行定位时，并不是超分辨率越低，定位误差均值越小，而是存在优化的超分辨率情况。根据图 4-8 中仿真结果，从中优选出定位误差均值最小的等分辨率及超分辨率的情形，并对其定位性能进行分析。




(a-1) 等分辨率=4 时 RM1 整体性能



(a-2) 超分辨率=2 时 RM1 整体性能



(b-1) 等分辨率=4 时 RM2 整体性能



(b-2) 超分辨率=3 时 RM2 整体性能

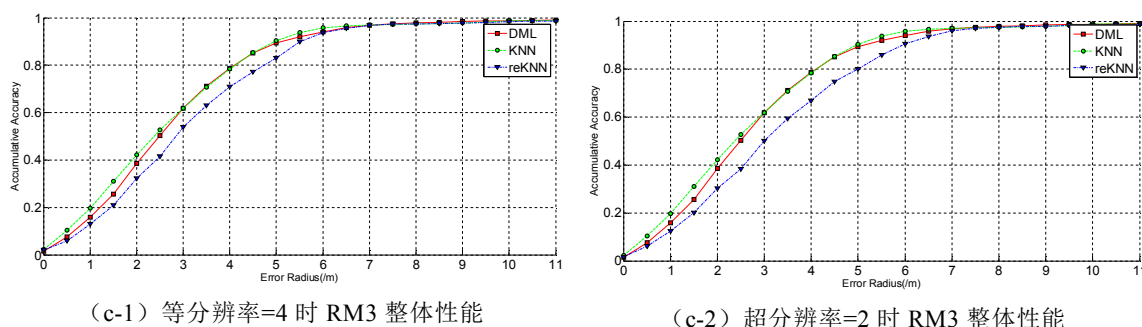


图 4-9 多种室内定位算法在 OPPO T29 上仿真分析结果


图 4-9 所示为多种室内定位算法在 OPPO T29 上的仿真结果，其仿真参数为等分辨率及超分辨率重建的优选参数。从重采样的角度来看，随着 Radio Map 的重采样次数的增加，三种算法的定位性能各有不同。重采样次数的增加对 KNN 算法的整体性能的影响并不明显，反而在 RM2 时，其 3 米及 4 米内定位精度稍微下降。而对于 DML 算法，随着重采样次数的增加，其 3 米及 4 米内定位精度均有 5%左右的提升，分别从 55%及 75%提升至 60%及 80%，达到与 KNN 算法定位性一致。随着重采样次数的增加，reKNN 算法的整体性能也有近 10%有提升，但其 3 米及 4 米内的定位精度与 KNN 及 DML 算法仍有 5%的差值。

从等分辨率及超分辨率的整体定位结果来看，本文提出的超分辨率重建方法可以有效地降低 Radio Map 建立的工作量的同时，维持不同算法的定位性能。从 RM1 指纹数据库的定位结果来看，当超分辨率为 2 时，即稀疏 Radio Map 分辨率仅为重建 Radio Map 的一半时，本文提出的 DML 及 reKNN 算法的定位性能均可以保持，且从 3 米及 4 米内定位精度来看，DML 及 reKNN 有微小幅度的提高；从 RM2 及 RM3 指纹数据库的超分辨率分析来看，仅在工作量三分之一时，DML 算法的定位性能比 reKNN 算法的定位有着明显的提升，特别是采用 RM3 时，DML 算法在 3 米及 4 米内定位精度均比 reKNN 算法高出 10%，比等分辨率时再多提高 5%的定位精度。从 Radio Map 建立及定位性能来看，本文提出的 DML 及 reKNN 可以仅在原工作量三分之一时达到 KNN 算法可比拟的性能。


本文同样对 Google Nexus 5 及 Samsung Note II 等两种终端进行实际测试并应用 DML 及 reKNN 算法对其性能进行分析，相应的仿真结果见附录 A.2。

## 4.4 HIT-WILS12 中 DML 及 reKNN 的性能分析


HIT-WILS12 系统所处的场景为办公楼走廊，这也是目前作为室内定位系统实际测试最为常用的环境。由于缺乏足够的硬件设备，无法采用多个平台对 HIT-WILS12 系统进行多终端测试（目前部分 WAP 出现的硬件故障，无法正常工作）。本文采用的 Radio Map 为 2013 年采集的位置指纹数据库，并在原始高分辨率数据库基础进行稀疏化处理得出本文所用的多分辨率位置指纹数据库，其具体生成方式详见第二章第四节。HIT-WILS12 系统采用联想 V450 电脑，结合 NetStumbler 软件测量 RSS 值，并根据设置转换为信噪比。本节性能分析中不仅引入了 DML 及 reKNN 算法，同时将 AP 算法引入至整体性能分析中（有关于 AP-KNN 算法详见第二章第四节）。本节将以偏置度为 25 为例，对 HIT-WILS12 系统的定位误差均值及整体性能进行分析。




(a-1) 等分辨率下 RM1 误差均值




(a-2) 超分辨率下 RM1 误差均值




(b-1) 等分辨率下 RM2 误差均值



(b-2) 超分辨率下 RM2 误差均值



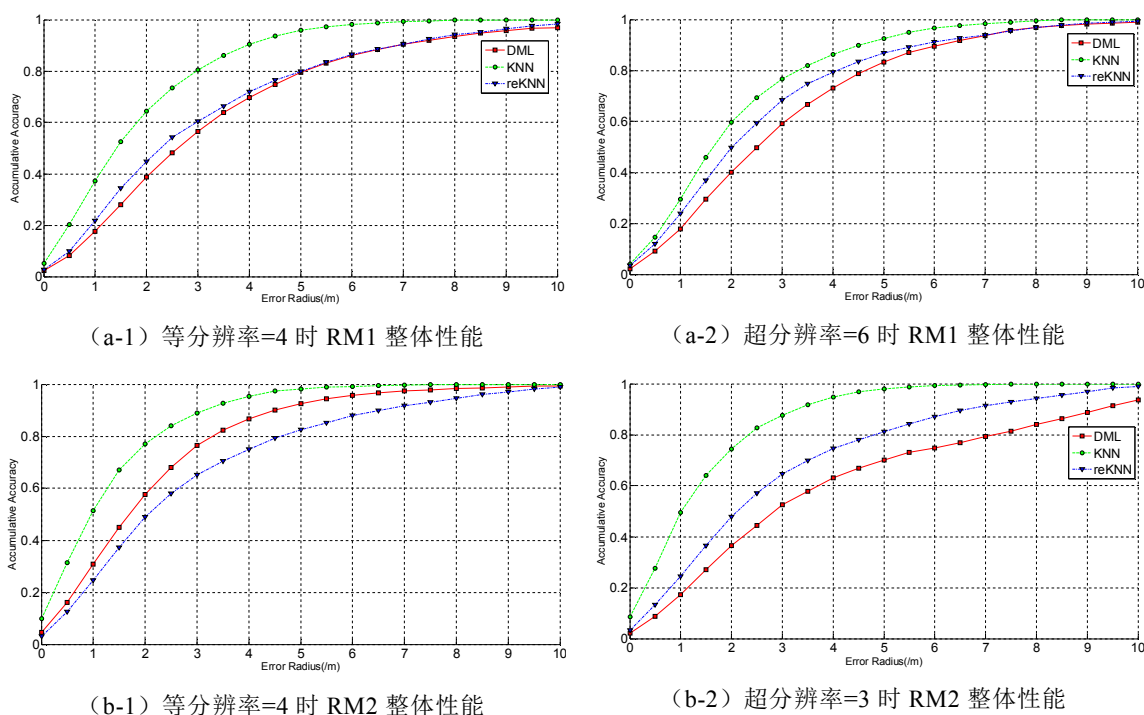
(c-1) 等分辨率下 RM3 误差均值



(c-2) 超分辨率下 RM3 误差均值

图 4-10 不同采样分辨率下 HIT-WILS12 系统的定位误差均值分析

图 4-10 所示为不同采样分辨率下 HIT-WILS12 系统的定位误差均值。与 HIT-WILS10 系统不同的是，在对 HIT-WILS12 进行系统性能分析时，引入了 AP 算法，因此不同的 Radio Map 的等分辨率时的情形就会变得很少。从等分辨率角度来看，采样分辨率对三种不同的定位算法影响各不相同。对于 KNN 算法，采样分辨率对其定位误差均值影响很小，几乎没有影响；对 DML 算法，采样分辨率的影响最大，其波动性也最为明显；采样分辨率对 reKNN 算法影响比较居中，一般来说，采样分辨率越高，其定位误差均值越小。从超分辨率角度来看，超分辨率对三种不同的定位算法的影响与采样分辨率相似，对三种算法有着相同趋势的影响。从不同采样次数的 Radio Map 来看，重采样次数对定位误差的均值影响较小，三种定位算法中，KNN 算法定位误差均值对重采样次的敏感度最小。根据不同采样分辨率及超分辨的定位误差均值的变化，可以得出：当采样分辨率与超分辨率不同时，不同的定位算法的定位性能会有明显的差别，其中存在优化的分辨率。






图 4-11 多种室内定位算法在 HIT-WILS12 系统中仿真分析结果

图 4-11 所示为根据不同优选的采样分辨率及超分辨率选择的仿真参数得出的 HIT-WILS12 系统中不同的算法的整体定位性能分析。从等分辨率的角度来看，三种不同算法的整体性能相差明显。KNN 算法对高采样分辨率 Radio Map 的定位性能非常高，以其 3 米内定位精度达 90%左右，且随着重采样次数的增加其 3 米内定位精度从 80%提高至 90%；对 DML 算法，其定位整体性能波动性很大。当采用 RM1 时，其整体性能与 reKNN 算法的整体性能相近，但 3 米内定位精度仅为 KNN 算法 3 米定位精度的 75%，相近较大。当定位精度至 9 米时，三种算法的定位性能可比拟；对于 RM2 及 RM3，DML 及 reKNN 算法的定位性能有着不同的变化。采用 RM2 数据库时，DML 算法的性能有着明显的提升，而采用 RM3 数据库时，DML 算法的定位性能出现大幅度下降。从这一点来看，重采样次数的增加对不能有效地提高 DML 算法的定位性能。在通用参数的前提下，DML 及 reKNN 并不能有效地用于 HIT-WILS 的环境，需要进一步的参数优化，特别 DML 算法中的流形对齐参数。

从超分辨率的角度来看，DML 算法可以在重建 Radio Map 的工作量仅为稀疏 Radio Map 的六分之一时，其定位性能可以达到高分辨率时相应算法的定位性能。从图中可以看出，当重建 Radio Map 的超分辨率为 6 时，KNN 算法 3 米内定位精度约下降了 5%，而 DML 算法 3 米内定位精度提升了 5%，reKNN 算法 3 米内定位精度提升了 10%。对于 RM2 及 RM3 情形时，reKNN 算法的定位都有着小幅度的提升。

本文同样对不同偏置度时 HIT-WILS12 系统的定位性能进行实际测试并应用 DML 及 reKNN 算法对其性能进行分析，相应的仿真结果见附录 A.3。



## 4.5 本章小结

本章在第 3 章的理论分析的基础上, 首先对 HIT-WILS10 及 HIT-WILS12 等两个典型室内环境内部署的 WILS 进行了描述, 并对本文采用的多种测试方法及终端进行简要的说明。结合 WILS, 本章提出了基于流形对齐的 Radio Map 的建立方法及基于流形对齐的 WLAN 室内定位方法, 并给出了相应的系统框图、算法框图, 并在此基础上提出了两种 WLAN 室内定位方法: DML 及 reKNN 方法。根据不同的终端、不同环境的实测的 RSS 及 Radio Map, 分析了本文提出的 Radio Map 建立及室内定位方法的性能。仿真表明, 本文提出的基于流形对齐的 Radio Map 建立及定位方法可以在大幅度降低 (至少降低一倍工作量, 最高可达 16 倍) Radio Map 建立的工作量前提下, 有效地保持定位算法的性能, 并对不同系统及终端有良好的适应性。

## 结 论

针对 WILS 中存在的 Radio Map 建立效率低、工作量大、RSS 与 Radio Map 处理及定位算法的多样性等问题, 本文提出以流形对齐为核心的 Radio Map 快速建立及室内定位方法: 直接映射定位 (DML) 及基于重建 Radio Map 的 KNN 算法 (reKNN)。本文实现了 WILS 的 Radio Map 的快速建立与室内定位方法的统一。仿真结果表明, 本文提出的基于流形对齐的 Radio Map 的超分辨率重建方法可以在至少降低一倍 Radio Map 建立的工作量的前提下保持 DML 及 reKNN 算法定位性能与高采样分辨率的 Radio Map 的定位性能可比拟。同时, 本文提出的基于流形对齐的 Radio Map 建立及 WLAN 室内定位方法对不同的终端、不同定位系统有良好的适应性。

(1) 本文采用了 OPPO T29、Google Nexus5、Samsung Note II 及联想 V450 笔记本电脑等四种移动终端对部署在哈尔滨工业大学通信技术研究所内的 HIT-WILS10 及 HIT-WILS12 进行 RSS 采集及性能测试。测试结果表明, 不同终端的 RSS 特征有着明显的差异, 并且 RSS 采样受到终端方位、天线仰角及偶然导体等因素的影响。本文采用多种终端对室内定位区域采集多次数据, 并依次建立单次采样、重采样 Radio Map 及实时性能测试数据库, 为算法性能分析提供有效、真实的原始数据。

(2) 本文采用 KNN 算法为例对 Radio Map 快速建立及 WLAN 室内定位方法进行性能对比分析。为提高 FLA 的实时性能及对不同实验环境的适应性, 本文提出了 AP-KNN 并以 HIT-WILS12 所在走廊实验区域的实测数据进行了性能测试。测试结果表明, AP-KNN 算法可以在单次采样及不同重采样的 Radio Map 条件下有效地保持 KNN 的定位性能, 其 3 米及 4 米内定位精度达到了 83% 及 93%, 与原 KNN 算法性能可比拟。

(3) 本文分析了流形理论的基本概念及典型的流形学习方法, 并对耦合度量学习进行了详细的分析。从基于相关关系及基于 Fisher 准则的耦合度量学习出发, 推导统一耦合度量学习 (UCML) 方法。在此基础上, 本文提出了基于 UCML 的流形对齐方法 (UCML-MA), 并对其算法流程进行了分析。为了将流形对齐方法应用于 Radio Map 的快速建立, 本文提出了基于流形对齐的超分辨率分析 (SRA-MA) 算法。

(4) 在 UCML-MA 及 SRA-MA 算法的基础上, 本文提出了基于流形对

齐的 WLAN 室内定位系统的总体方案，包括基于流形对齐 Radio Map 快速建立及 WLAN 室内定位方法。本文基于 SRA-MA 算法提出了从稀疏 Radio Map 实现高采样分辨率 Radio Map 建立，从而实现 Radio Map 的快速建立。同时，本文基于 UCML-MA 方法提出了两种 WLAN 室内定位方法：DML 及 reKNN 算法。

(5) 通过采用四种不同终端对 HIT-WILS10/12 的性能测试及仿真结果表明，本文提出的 Radio Map 快速建立方法可以有效地提高 Radio Map 的建立效率。随着 Radio Map 的重采样次数的增加，KNN 的整体性能的影响无明显变化，而对于 DML 及 reKNN 算法，随着重采样次数的增加，其 3 米及 4 米内定位精度均有 5%左右的提升，分别从 55%及 75%提升至 60%及 80%，达到与 KNN 的定位性一致。

(6) 从等分辨率及超分辨率的定位结果来看，基于 SRA-MA 的 Radio Map 重建方法可以在有效地降低 Radio Map 建立的工作量前提下，维持不同算法的定位性能。仿真结果表明，基于 SRA-MA 的 Radio Map 重建方法可以在至少降低一半 Radio Map 建立的工作的前提下，保持 WILS 的性能不变，并可以在一定程度上提升定位精度。Radio Map 建立的效率的提高幅度最高可达 16 倍，即可以从采样分辨率为 0.25 提升至 4，且 WILS 的定位性能稳定。

本文有待进一步研究问题包括三个方面：(1) 将 Radio Map 建立与更新进行融合。本文仅对 Radio Map 的快速建立与 WLAN 室内定位方法进行一融合，无法对整个系统进行完整的仿真与运行；(2) 进一步优化不同算法的参数。在仿真过程中，为了避免由于参数不同带来的性能波动，UCML-MA 及 SRA-MA 算法的核心参数均没有优化，不同系统及终端采用的是同一参数，因此性能并不是最佳；(3) 将本文提出的系统架构及 WLAN 室内定位方法移植至手持及移动终端。虽然本文采用了四种移动终端进行 Radio Map 及 RSS 采集，但其定位及性能分析均在台式电脑上完成，并不能在移动终端上运行。

## 参考文献

- [1] Axel K. Location-based Services: Fundamentals and Operation[M]. New York: Wiley: 2005: 28-56.
- [2] Kolodziej K W, Hjelm J. Local Positioning Systems: LBS Applications and Services[M]. New York: Taylor & Francis: 2006: 78-94.
- [3] Want R, Hopper A, Falcao V, Gibbons J. The Active Badge Location System[J]. ACM Trans. Inf. Syst., ACM, 1992, 10: 91-102.
- [4] Hightower J, Borriello G. Location Systems for Ubiquitous Computing[J]. IEEE Computer, 2001: 34(8): 57-66.
- [5] Darrell T, Gordon G, Harville M, Woodfill J. Integrated Person Tracking Using Stereo, Color, and Pattern Detection[J]. International Journal of Computer Vision, 2000: 37:175-185.
- [6] Bahl P, Padmanabhan V N. RADAR: An In-building RF-based User Location and Tracking System[C]//In: INFOCOM 2000. Proceedings of IEEE Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies. 2002: 775-784.
- [7] Bahl P, Padmanabhan V N, Balachandran A. Enhancements to the RADAR: User Location and Tracking System[R]. Microsoft Research Technical Report: MSR-TR-00-12, Fed., 2000.
- [8] Roos T, Myllymaki P, Tirri H, Misikangas P, Sievänen J. A Probabilistic Approach to WLAN User Location Estimation[J]. International Journal of Wireless Information Networks. 2002: (9) 155-164.
- [9] Martínez E A, Cruz R, Favela J. Advances in Artificial Intelligence-IBERAMIA[M]. Springer Berlin Heidelberg, 2004:737-746.
- [10] Pan J J, Kwok J T, and Yang Q. et al. Multidimensional Vector Regression for accurate and Low-cost Location Estimation in Pervasive Computing[J]. IEEE Transactions on Knowledge and Data Engineering. 2006(18): 1181-1193.
- [11] Kushki A, Plataniotis K N, Venetsanopoulos A N. Kernel-based Positioning in Wireless Local Area Networks[J]. IEEE Transaction on Mobile Computing. 2007(6): 689-705.
- [12] Kim Y, Shin H, Cha H. Smartphone-based Wi-Fi Pedestrian-Tracking System Tolerating the RSS Variance Problem[C]//Pervasive Computing and

- Communications(PerCom), 2012 IEEE International Conference on. IEEE, 2012: 11-19.
- [13] Oreshkin B, Coates M. Bootstrapping Particle Filters using Kernel Recursive Least Squares[C]//Aerospace Conference, 2007 IEEE. IEEE, 2007:1-7.
- [14] Gentile C, Klein-Berndt L. Robust Location Using System Dynamics and Motion Constraints[C]//Communications, 2004 IEEE International Conference on. IEEE, 2004(3):1360-1364.
- [ 15 ] Niculescu D, Nath B. VOR Base Stations for Indoor 802.11 Positioning[C]//Proceedings of the 10th Annual International Conference on Mobile Computing and Networking, ACM, 2004, 58-69.
- [16] Jardosh A P, Papagiannaki K, Belding E M, Almeroth K C, Iannaccone G, Vinnakota B. Green WLANs: On-Demand WLAN Infrastructures[J]. Mobile Networks and Applications. 2009, 14(6): 798-814.
- [17] Aruba Selected by Microsoft for Next Generation Wireless LAN[EB]. <http://www.arubanetworks.com/company/press/2005/06/13>.
- [18] 温三宝. 密集覆盖下无线局域网的动态资源分配研究[D]. 西安: 西安电子科技大学通信与信息系统硕士学位论文, 2012.
- [19] Shin H, Chon Y, Cha H. Unsupervised Construction of An Indoor Floor Plan Using A Smart Phone[J]. Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on, 2012(42): 889-898.
- [20] Feng C, Au W, Valaee S, Tan Z. Received-Signal-Strength-Based Indoor Positioning Using Compressive Sensing[J]. Mobile Computing, IEEE Transactions on, 2012(11): 1983-1993.
- [21] Ido J, Shimizu Y, Matsumoto Y, Ogasawara T. Indoor Navigation for a Humanoid Robot Using a View Sequence[J]. The International Journal of Robotics Research February 2009, 28(2): 315-325.
- [22] Gandhi T, Trivedi M. Parametric Ego-Motion Estimation for Vehicle Surround Analysis Using An Omnidirectional Camera[J]. Machine Vision and Applications, 2005(16): 85-95.
- [23] Kim J, Jun H S. Vision Based Location Positioning Using Augmented Reality for Indoor Navigation[J]. Consumer Electronics, IEEE Transaction on. 2008, 54(3): 954-962.
- [24] Sky-Trax Inc. (2011): <http://www.sky-trax.com/>, last accessed 22. October 2011.

- [25] Li X, Wang J, Olesk A, et al. Indoor Positioning within a Single Camera and 3D Maps[C]//Ubiquitous Positioning Indoor Navigation and Location Based Service (UPINLBS), 2010. IEEE, 2010:1-9.
- [26] Tilch S, Mautz R. Development of a New Laser-Based, Optical Indoor Positioning System[C]//Proceedings of the ISPRS Commission V Mid - Term Symposium Close Range Image Measurement Techniques. 2010, 98(5): 575-580.
- [27] Depenthal C. Path tracking with iGPS[C]//Indoor Positioning and Indoor Navigation (IPIN), 2010 International Conference on IEEE, 2010: 1-6.
- [28] Schmitt R, Nisch S, Schönberg A, Demeester F, Renders S. Performance Evaluation of iGPS for Industrial Applications[C]//Indoor Positioning and Indoor Navigation (IPIN), 2010 International Conference on IEEE, 2010:1-8.
- [29] Nikon Metrology (2011): <http://www.nikonmetrology.com>[EB], last accessed 1. March 2011.
- [30] Skyhook (2011): [www.skyhookwireless.com](http://www.skyhookwireless.com)[EB], last accessed 15. November 2011.
- [31] Montillet J, W. Roberts G, Hancock C, et al. Deploying A Locate Network to Enable Precise Positioning in Urban Canyons[J]. Journal of Geodesy, 2009(83): 91-103.
- [32] Gallagher T J, Li B, Dempster A G. A Sector-Based Campus Wide Indoor Positioning System[C]//Indoor Positioning and Indoor Navigation (IPIN), 2010 International Conference on IEEE, 2010:1-8.
- [33] Mautz R. Indoor Positioning Technologies[D]. ETH, Zurich, Department of Civil, Environmental and Geomatic Engineering, Institute of Geodesy and Photogrammetry (2012). <http://dx.doi.org/10.3929/ethz-a-007313554>.
- [34] Kim H S, Li B, Choi W S, Sung S K, Lee H K. Spatiotemporal Location Fingerprint Generation Using Extended Signal Propagation Model[J]. Journal of Electrical Engineering and Technology. 2012, 7(5): 789-796. [http:// dx. doi. org/ 10.5370/JEET .2012.7.5.789](http://dx.doi.org/10.5370/JEET.2012.7.5.789).
- [35] Pandey S, Kim B, Anjum F, Agrawal P. Client Assisted Location Data Acquisition Scheme for Secure Enterprise Wireless Networks[C]//Wireless Communications and Networking Conference, 2005 IEEE. IEEE, 2005(2): 1174-1179.
- [36] Wu C, Yang Z, Liu Y, et al. WILL: Wireless Indoor Localization without Site Survey[C]//Proceedings of IEEE INFOCOM, 2012. IEEE. 2012: 64-72.

- [37] Scholl P M, Kohlbrecher S, Sachidananda V, et al. Fast Indoor Radio-map Building for RSSI-based Localization Systems[C]//Networked Sensing Systems (INSS), 2012 Ninth International Conference on. IEEE, 2012:1-2.
- [38] Tsai T, Li C, Lin T. Reducing Calibration Effort for WLAN Location and Tracking System using Segment Technique[C]//Sensor Networks, Ubiquitous, and Trustworthy Computing, 2006. IEEE International Conference on, IEEE, 2006: 46-51.
- [39] Chai X, Yang Q. Reducing the Calibration Effort for Probabilistic Indoor Location Estimation[J]. Mobile Computing, IEEE Transactions on, 2007(6): 649-662.
- [40] Savazzi S, Nicoli M, Carminati F. A Bayesian Approach to Device-Free Localization: Modeling and Experimental Assessment[J]. Selected Topics in Signal Processing, IEEE Journal of, 2014(8): 16-29.
- [41] Liu S, Luo H, Zou S. A Low-Cost and Accurate Indoor Localization Algorithm Using Label Propagation Based Semi-supervised Learning[C]//Mobile Ad-hoc and Sensor Networks, 2009, MSN 09, 5th International Conference on, IEEE, 2009: 108-111.
- [42] Tao J, Hu W, Wang S. Sparsity Regularization Label Propagation for Domain Adaptation Learning[J]. Neurocomputing, 2014: 202-219.
- [43] Sorour S, Lostanlen Y, Valaee S. Reduced-Effort Generation of Indoor Radio Maps Using Crowdsourcing and Manifold Alignment[C]//6th International Symposium on Telecommunications(IST'2012), 2012: 354-358.
- [44] Sun Z, Chen Y, Qi J, Liu J. Adaptive Localization through Transfer Learning In Indoor Wi-Fi Environment[C]//Proceeding ICMLA '08 Proceedings of the 2008 Seventh International Conference on Machine Learning and Applications, 2008: 331-336.
- [ 45 ] Ham J, Lee D, Saul L. Semisupervised Alignment of Manifolds[C]//Proceedings of the Annual Conference on Uncertainty in Artificial Intelligence, Z. Ghahramani and R. Cowell, Eds. 2005(10): 120-127.
- [46] Ma Y, Fu Y. Manifold Alignment in Manifold Learning: Theory and Applications[M]. Boca Raton, FL, USA: CRC Press, 2011.
- [47] Lafon S, Keller Y, Coifman R R. Data Fusion and Multicue Data Matching by Diffusion Maps[J]. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2006(28): 1784-1797.

- [48] Tufiş D. Intercultural Collaboration[M]. Springer Berlin Heidelberg, 2007: 103-117.
- [49] Wang C, Mahadevan S. Manifold Alignment without Correspondence[J]. In Proceedings of the 21st International Joint Conferences on Artificial Intelligence, 2009: 1273-1278.
- [50] Xiong L, Wang F, Zhang C. Machine Learning: ECML 2007[M]. Springer Berlin Heidelberg, 2007:773-781.
- [51] J. MacQueen. Some Methods for Classification and Analysis of Multivariate Observations[J]. in Proc. 5th Berkeley Symp. Math. Statist. Probability, 1967, 1: 281-297
- [52] 李养成, 郭瑞之, 崔登兰. 微分流形基础[M]. 北京: 科学出版社, 2011.
- [53] Roweis S T, Saul L K. Nonlinear Dimensionality Reduction by Locally Linear Embedding[J]. Science, 2000, 290(5500):2323-2326.
- [54] Tenenbaum J B. Mapping A Manifold of Perceptual Observations[M]. In Advances in Neural Information Processing Systems, MA, USA. The MIT Press. 1998: (10)682-688.
- [55] Chen H, Chang H, Liu T. Local Discriminant Embedding and Its Variants[J]. in Proc. IEEE Conf. Computer Vision and Pattern Recognition, 2005, 2:846 - 853.
- [56] 吴勃英, 王佳明, 丁效华, 李道华. 数值分析原理[M]. 北京: 科学出版社, 2003: 39-45.
- [57] Zhou C F, Ma L, Tan X. Joint Semi-supervised RSS Dimensionality Reduction and Fingerprint Based Algorithm for Indoor Localization[J]. Proceedings of the 27th International Technical Meeting of the Satellite Division of the Institute of Navigation (ION GNSS+ 2014). 2014, 3201-3211.
- [58] Pedagadi S, Orwell J, Velastin S, et al. Local Fisher Discriminant Analysis for Pedestrian Re-identification[J]. Computer Vision and Pattern Recognition, IEEE Conference on, 2013, 9(4):3318-3325.
- [59] Bai-ling W, Zhi-hong T, Yong-zheng Z. Optimization of Singular Vector Decomposition Algorithm[J]. Acta Electronica Sinica, 2010, 38(10):2234-2239.
- [60] Shen H, Li S. Hallucinating Faces by Interpolation and Principal Component Analysis[C]//Computational Intelligence and Design, 2009. ISCID09. 2th International Symposium on. IEEE, 2009:295-298.
- [61] Cristina F, Dapoto S, Russo C, et al. High Resolution Images from Low Resolution Video Sequences[J]. Journal of Computer Science and Technology,



- 2005, (1).
- [62] Wang L, Xiang S, Meng G. Edge-Directed Single-Image Super-Resolution via Adaptive Gradient Magnitude Self-Interpolation[J]. *Circuits and Systems for Video Technology, IEEE Transactions on*, 2013, 23(8):1289-1299.
- [63] 郭伟伟, 章品正. 基于迭代反投影的超分辨率图像重建[J]. *计算机科学与探索*, 2009, 3(3):321-329. DOI:10.3778/j.issn.1673-9418.2009.03.010.
- [64] 庞亚红, 舒培翔. 一种基于凸集映射的高分辨率图像恢复算法[J]. *信息技术*, 2004:7-9. DOI:10.3969/j.issn.1009-2552.2004.06.003.
- [65] 拉杰斯, 葛海燕. Meta-analysis of the Resolution Rate of Type 2 Diabetes Mellitus in Patients Undergoing Roux-en-Y Gastric Bypass Surgery[J]. *中国医学文摘外科学分册: 英文版*, 2011:140-147.
- [66] Laursen B. A Developmental Meta-Analysis of Peer Conflict Resolution[J]. *Developmental Review*, 2001, 21(4):423-449(27).

## 攻读学位期间发表的学术论文

- 1、**Zhou C F**, Ma L, Tan X. Joint Semi-supervised RSS Dimensionality Reduction and Fingerprint Based Algorithm for Indoor Localization[J]. Proceedings of the 27th International Technical Meeting of The Satellite Division of the Institute of Navigation (ION GNSS+ 2014). 2014, 3201-3211. (已发表, EI)
- 2、Ma L, **Zhou C F**, Qin D, et al. Green Wireless Local Area Network Received Signal Strength Dimensionality Reduction and Indoor Localization Based on Fingerprint Algorithm[J]. International Journal of Communication Systems, 2014, 27(12):4527-4542(16). (SCI 检索号: 000345917800065, IF: 1.106)
- 3、Ma L, **Zhou C F**, Liu X, et al. Adaptive Neighboring Selection Algorithm Based on Curvature Prediction in Manifold Learning[J]. 哈尔滨工业大学学报(英文版), 2013, 20(3): 119-123. (EI 检索号: 20133116559347)
- 4、夏颖, 张中兆, 马琳, **周才发**. 基于半监督流形学习的 WLAN 室内定位算法[J]. 系统工程与电子技术, 2014, 36(7): 1422-1427. (EI 检索号: 20143218048493)
- 5、**Zhou C F**; Deng, Z.; Tan, X.-Z. & Meng, W. Direct Mapping Scheme Applied in WLAN Indoor Localization System 2015 IEEE Global Communications Conference: Wireless Communications (GC' 15 - WCS), 2015.(在审)
- 6、谭学治, **周才发**, 马琳, 邓仲哲, 何晨光, 迟永刚, 魏守明. 一种基于类别匹配的半监督流形学习的 WiFi 室内定位方法。(申请号: 201310750528.6)
- 7、马琳, **周才发**, 徐玉滨, 强蔚, 孟维晓. 基于 LDE 算法的 WiFi 室内定位方法。(申请号: 201310029536.1)
- 8、马琳, **周才发**, 刘曦, 马欣如, 徐玉滨, 强蔚. 基于曲率预测的流形学习自适应邻域选择算法。(申请号: 201210325652.3)
- 9、马琳, 马欣如, 刘曦, **周才发**, 徐玉滨, 强蔚. 基于分区信息熵的 WLAN 室内定位方法。(申请号: 201210329662.4)
- 10、马琳, 邓仲哲, 徐玉滨, 孟维晓, **周才发**. 一种卫星辅助信号覆盖图建立/更新的 WiFi 室外定位方法。(申请号: 201310073032.X)
- 11、石硕, 梁楠, 顾学迈, 叶亮, 刘通, **周才发**, 王泽蒙, 田斯, 朱师姐《一种基于凸优化方法的认知异构网络联合资源分配的方法》。(申请号: 2014104146017)



## 致 谢

在论文的最后，首先要衷心地感谢我的导师谭学治教授，在本论文完成期间，谭老师给我提供了完成论文的一切条件，并在研究生就读期间在生活及学习给我提供了不可或缺的指导及帮助。

我要衷心地感谢谭学治老师给我的耐心指导和无微不至的关怀，在论文完成期间，谭学治老师给了我很多建议和帮助，尤其是在课题遇到重大困难的时候，他总能给我带来最及时的指导和帮助；特别是在发表国际会议论文方面，给予了极大的帮助。此外，谭老师在我担任通信技术研究所网络管理员期间给了极大的指导，让我能在学习、科研及工作之间找到良好的平衡点，给我未来科研工作及留学深造提供了明确的参考。特别是在我身体出现不良状况时，谭老师亲自送我就医，让我在异乡感受到了如家人般的关怀与照顾。在此，我再次向谭学治老师表达崇高的谢意。

同时，哈尔滨工业大学通信技术研究所就读研究生期间，所内各位老师都在学习及工作上给了我极大关怀，在此我要特别感谢张中兆老师、孟维晓老师。

感谢家人在生活及学习上给予的大力支持，正是有了父母无私的关怀及家人不时地鼓励，让我能够在学习道路走得坚定顺利。此外，实验组的各位同学也在学习和科研上给了极大的帮助，为我论文的完成提供良好的建议，在此我要感谢邓仲哲同学、陈雷师兄、邹德跃师兄、殷聪师兄、莫云师兄在论文完成过程中建议和帮助。对在我学习、工作及生活中帮助及关心我的各位老师、同学及好友一并致以谢意，正是你们的帮助，让我能够顺利地完成大学及研究生学习，为今后的学习及工作奠定良好的基础。

## 附录 A

### A.1 采样分辨率对照表


表 A-1 采样分辨率及超分辨率对照表

序号	1	2	3	4
采样间隔 ( $m \times m$ )	$0.5 \times 0.5$	$0.5 \times 1.0$	$0.5 \times 1.5$	$0.5 \times 2.0$
分辨率	4	2	1.33	1
序号	5	6	7	8
采样间隔 ( $m \times m$ )	$1.0 \times 0.5$	$1.0 \times 1.0$	$1.0 \times 1.5$	$1.0 \times 2.0$
分辨率	2	1	0.67	0.5
序号	9	10	11	12
采样间隔 ( $m \times m$ )	$1.5 \times 0.5$	$1.5 \times 1.0$	$1.5 \times 1.5$	$1.5 \times 2.0$
分辨率	1.33	0.67	0.44	0.33
序号	13	14	15	16
采样间隔 ( $m \times m$ )	$2.0 \times 0.5$	$2.0 \times 1.0$	$2.0 \times 1.5$	$2.0 \times 2.0$
分辨率	1	0.5	0.33	0.25


注：分辨率表示单位面积内参考的数目

### A.2 Google Nexus 5 及 Samsung Note II 的性能测试结果

#### (1) Google Nexus 5



(a-1) 等分辨率下 RM1 误差均值



(a-2) 超分辨率下 RM1 误差均值


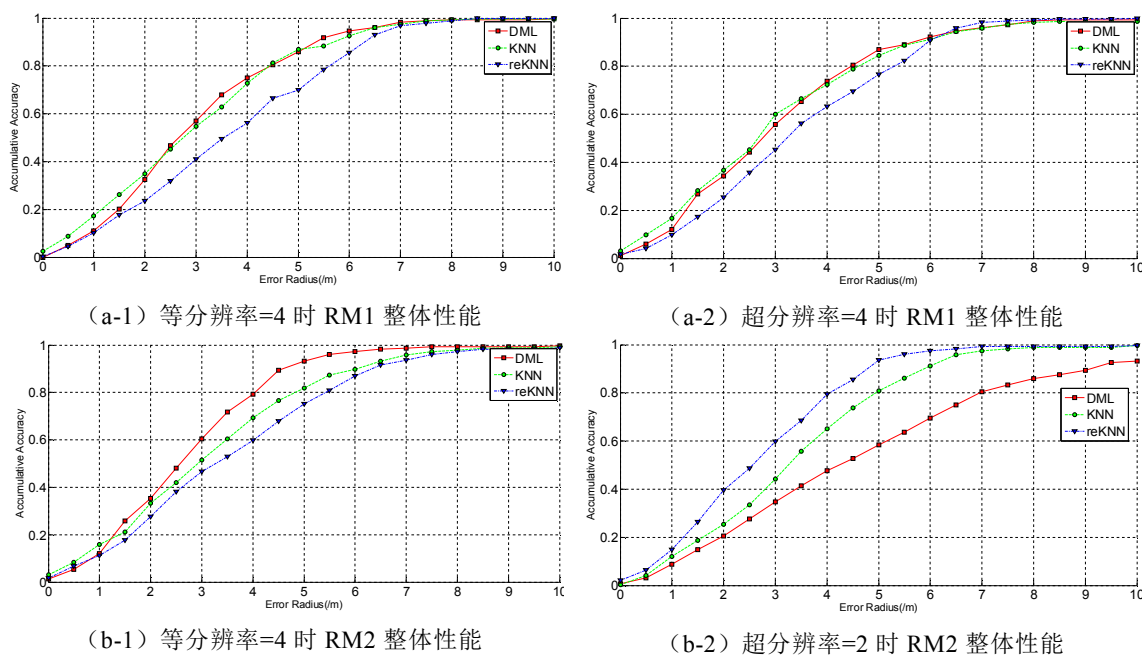


图 A-1 不同采样分辨率下 Google Nexus 5 的定位误差均值分析



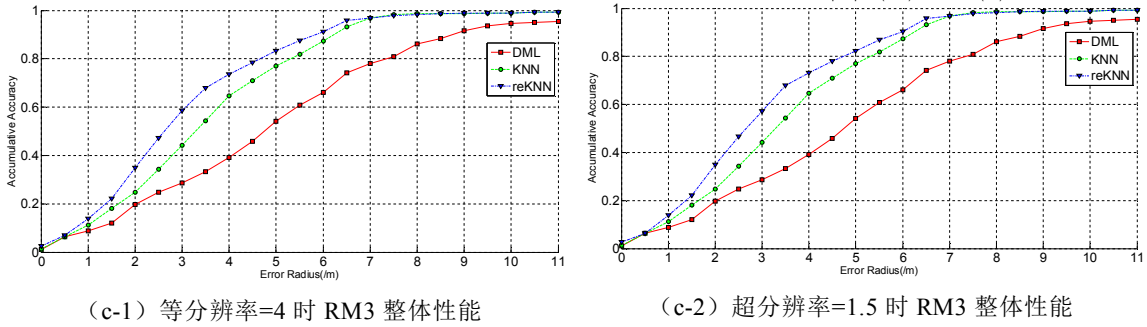


图 A-2 多种室内定位算法在 Google Nexus 5 上仿真分析结果

(2) Samsung Note II

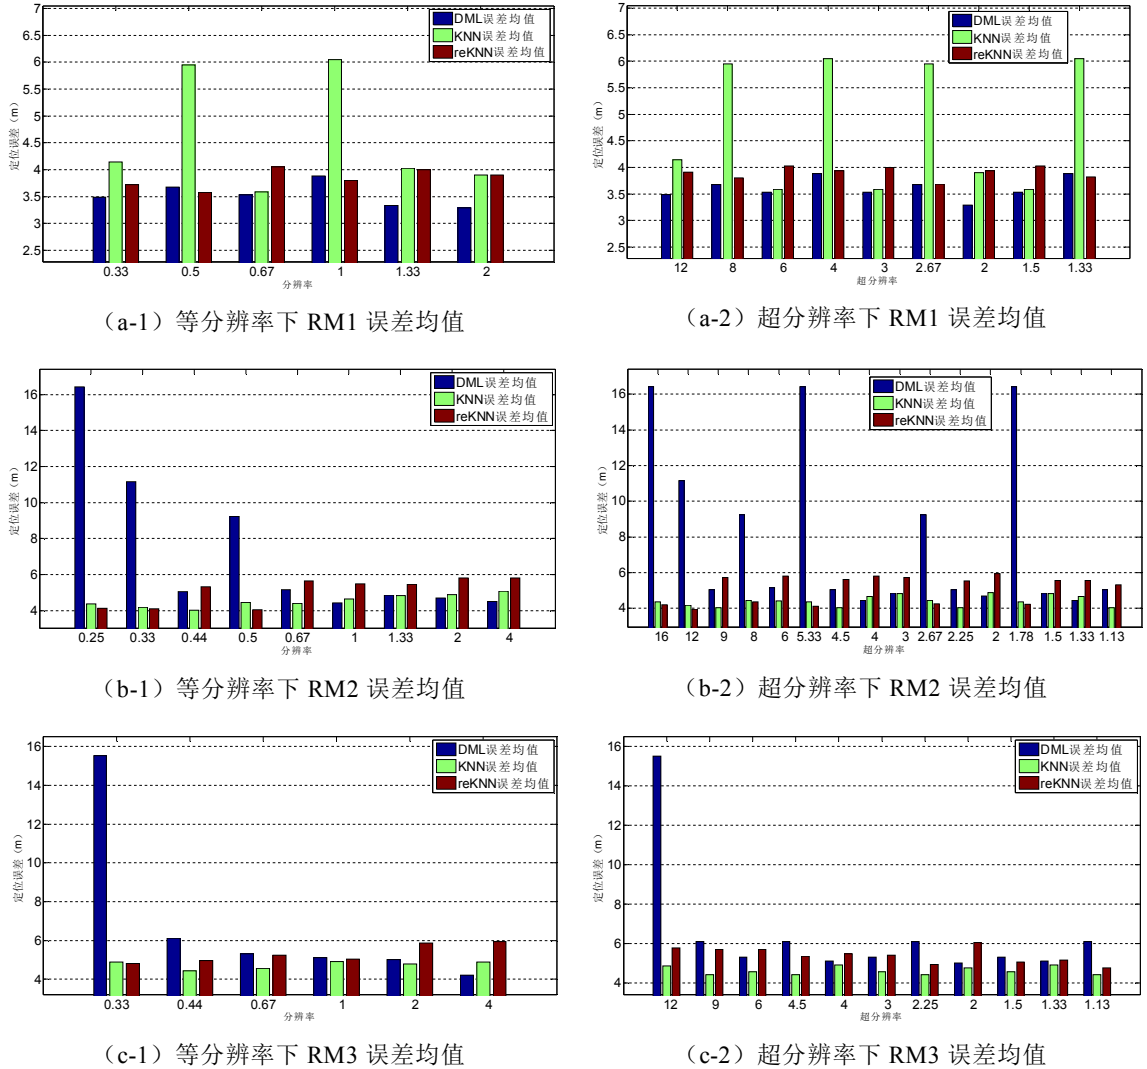





图 A-3 不同采样分辨率下 Samsung Note II 的定位误差均值分析




(a-1) 等分辨率=4 时 RM1 整体性能




(a-2) 超分辨率=3 时 RM1 整体性能




(b-1) 等分辨率=4 时 RM2 整体性能



(b-2) 超分辨率=3 时 RM2 整体性能




(c-1) 等分辨率=4 时 RM3 整体性能




(c-2) 超分辨率=9 时 RM3 整体性能

图 A-4 多种室内定位算法在 Samsung Note II 上仿真分析结果

### A.3 不同参数下 HIT-WILS12 的性能分析结果




(a-1) 等分辨率下 RM1 误差均值




(a-2) 超分辨率下 RM1 误差均值







(b-1) 等分辨率下 RM2 误差均值



(b-2) 超分辨率下 RM2 误差均值




(c-1) 等分辨率下 RM3 误差均值




(c-2) 超分辨率下 RM3 误差均值


图 A-5 不同采样分辨率下 HIT-WILS12 的定位误差均值分析




(a-1) 等分辨率=4 时 RM1 整体性能



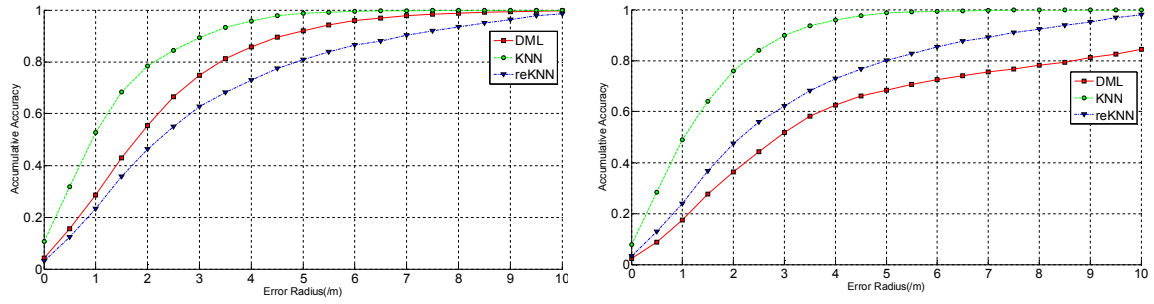
(a-2) 超分辨率=2 时 RM1 整体性能



(b-1) 等分辨率=4 时 RM2 整体性能



(b-2) 超分辨率=3 时 RM2 整体性能



(c-1) 等分辨率=4 时 RM3 整体性能

(c-2) 超分辨率=1.5 时 RM3 整体性能

图 A-6 多种室内定位算法在 HIT-WILS12 系统中仿真分析结果