

(12) 发明专利申请

(10) 申请公布号 CN 103079269 A

(43) 申请公布日 2013. 05. 01

(21) 申请号 201310029536. 1

(22) 申请日 2013. 01. 25

(71) 申请人 哈尔滨工业大学

地址 150001 黑龙江省哈尔滨市南岗区西大直街 92 号

(72) 发明人 马琳 周才发 徐玉滨 秦丹阳
孟维晓 崔扬

(74) 专利代理机构 哈尔滨市松花江专利商标事
务所 23109

代理人 张宏威

(51) Int. Cl.

H04W 64/00 (2009. 01)

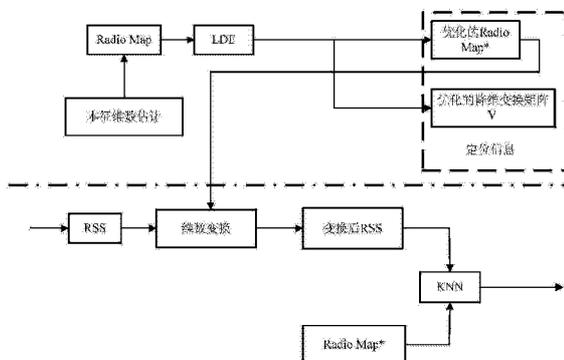
权利要求书2页 说明书7页 附图1页

(54) 发明名称

基于 LDE 算法的 WiFi 室内定位方法

(57) 摘要

基于 LDE 算法的 WiFi 室内定位方法, 涉及一种室内定位方法。它为了解决现有的 WiFi 室内定位方法的定位的实时性差的问题。该方法的实现过程分为两个阶段: 离线阶段: WiFi 网络的构建, 测量 RSS, 构建 Radio Map; 采用本征维数估计方法对 Radio Map 的本征维数进行估计; 采用 LDE 算法对 Radio Map 降维处理, 得出降维后的 Radio Map 及特征变换矩阵得出最优的降维结果及相应的特征变换矩阵作为在线阶段的匹配数据库及相应的 RSS 变换矩阵。在线阶段: 对测试点处接收到的 RSS 进行特征变换, 并采用 KNN 算法与降维后的 Radio Map 进行的匹配得出测试点的预测坐标。本发明适用于室内定位。



1. 基于 LDE 算法的 WiFi 室内定位方法,其特征是:它由以下步骤实现:

步骤一、针对室内环境布置 N 个接入点 AP,确保所述环境中任意一点被一个或一个以上的接入点 AP 发出的信号覆盖,所述 N 个接入点 AP 组成 WiFi 网络;在所述室内环境中均匀设置 N_{RP} 个参考点;N 和 N_{RP} 均为正整数;

步骤二、选取一个参考点为坐标原点建立二维直角坐标系,获得 N_{RP} 个参考点在该二维直角坐标系中的坐标位置,在离线阶段中在每个参考点上利用信号接收机采集来自每一个接入点 AP 的信号强度 RSS 值,并作为该接入点 AP 的位置特征信息;并根据 N 个接入点 AP 的位置特征信息构建室内信号覆盖图 Radio Map;

步骤三、采用本征维数估计算法对步骤二获得的室内信号覆盖图 Radio Map 进行本征维数分析,获得本征维数分析结果;

步骤四、根据步骤三获得的本征维数分析结果采用 LED 算法将室内信号覆盖图 RadioMap 内的所有参考点降维至本征维数,获得特征变换矩阵,并生成降维后的信号覆盖图 Radio Map*;

步骤五、在在线阶段,测量室内环境中欲定位点的信号强度 RSS 值,并将该信号强度 RSS 值与步骤四获得的特征变换矩阵相乘,获得信号强度变换值 RSS^* ;

步骤六、采用 KNN 算法对步骤五获得的信号强度变换值 RSS^* 与步骤四生成的降维后的信号覆盖图 Radio Map* 进行位置匹配,获得欲定位点的位置坐标,完成欲定位点的室内定位。

2. 根据权利要求 1 所述的基于 LDE 算法的 WiFi 室内定位方法,其特征在于步骤三中采用本征维数估计算法为特征值估计法。

3. 根据权利要求 1 所述的基于 LDE 算法的 WiFi 室内定位方法,其特征在于步骤三中采用本征维数估计算法为包数估计法。

4. 根据权利要求 1 所述的基于 LDE 算法的 WiFi 室内定位方法,其特征在于步骤三中采用本征维数估计算法为测地线最小生成树算法。

5. 根据权利要求 4 所述的基于 LDE 算法的 WiFi 室内定位方法,其特征在于采用测地线最小生成树算法对步骤二获得的室内信号覆盖图 Radio Map 进行本征维数分析是通过公式:

$$d_{\text{intrinsic dim}} = \frac{1}{1-a}$$

实现的;式中: $d_{\text{intrinsic dim}}$ 为本征维数分析结果;a 表示最小生成树的线性拟合表达式的斜率。

6. 根据权利要求 1 所述的基于 LDE 算法的 WiFi 室内定位方法,其特征在于步骤四中获
得特征变换矩阵 V' 与生成降维后的信号覆盖图 Radio Map* 之间的关系为:

$$\text{Radio Map}^* = V' \cdot \text{Radio Map}.$$

7. 根据权利要求 1 所述的基于 LDE 算法的 WiFi 室内定位方法,其特征在于采用 KNN 算法对步骤五获得的信号强度变换值 RSS^* 与步骤四生成的降维后的信号覆盖图 RadioMap* 进行位置匹配的方法是通过公式:

$$(x', y') = \frac{1}{K} \sum_{i=1}^K (x_i, y_i)$$

实现的；

式中： (x', y') 为欲定位点的坐标， (x_i, y_i) 为第 i 个近邻点的坐标， i 为正整数； K 为 KNN 算法中近邻点的总数。

基于 LDE 算法的 WiFi 室内定位方法

技术领域

[0001] 本发明涉及一种室内定位方法。

背景技术

[0002] 随着无线局域网络在世界范围的飞速发展和移动终端设备的广泛普及,近年来出现了许多室内定位相关的技术和应用。由于多径效应、信号衰减及室内定位环境的复杂性,基于传统的信号传播模型的室内定位方法难以达到高精度的室内定位要求。基于到达时间 (Time of Arrival)、到达时间差 (Time Difference of Arrival) 或到达角度 (Angles of Arrival) 等定位方法虽然可以基本满足定位精度需求,然而都需要定位终端有额外的硬件设备支持,具有较大局限性,从而导致基于上述几类定位方法的室内定位系统没有得到普及。

[0003] 目前,基于 WLAN 位置指纹 (Finger Print) 的 WiFi 室内定位方法得到了广泛应用。该方法的网络构建方法成本低廉,其使用 2.4GHz ISM (Industrial Science Medicine) 公共频段且无需在现有设施之上添加定位测量专用硬件。只需要通过移动终端的无线网卡及相应软件测量接收到的接入点 (Access Point, AP) 的信号强度 (Received Signal Strength, RSS), 由此来构建网络信号覆盖图 (Radio Map), 进而通过匹配算法来预测移动用户所处位置的坐标,或相对位置。

[0004] 然而通过该方式建立的 Radio Map 包含有庞大的数据信息,且随着定位区域扩大, Radio Map 可能 (依据定位匹配方式及算法选择) 呈指数形势增长。获得尽可能多的相关数据特征信息对于整个系统来说会提升定位精度,但是处理大量的特征信息增加算法开销,定位算法无法在处理能力有限的移动终端上有效运行,同时某些特征信息可能是对于定位没有作用甚至有负面作用,致使匹配效率降低,从而导致匹配定位算法的实现变得更加复杂,并且定位精度下降。

[0005] 当 AP 的数目增加及定位的参考点 (Reference Point) 增加时, Radio Map 的数据信息增加。此时, Radio Map 中代表的 AP 数目的信息表示了数据的维数。因此,当 AP 数目增加, Radio Map 就变成了高维数据。为减轻处理高维数据的负担,降维算法是有效的解决方法之一。高维数据可能包含很多特征,这些特征都在描述同一个事物,这些特征一定程度上是紧密相连的。如当从各个角度对同一个物体同时拍照时,得到的数据就含有重叠的信息。如果能得到这些数据的一些简化的不重叠的表达,将会极大地提高数据处理运行的效率并一定程度上提高准确度。降维算法的目的也正是在于提高高维数据的处理效率。

[0006] 除了可以简化数据使其能够高效处理外,降维方法还可以实现数据可视化。由于很多统计学的和机器学习算法对于最优解的准确性很差,降维的可视化应用可以令用户能够实际看到高维数据的空间结构和算法输出的能力,具有很强的应用价值。

[0007] 目前有很多基于不同目的的降维算法,包括有线性与非线性降维算法。其中 PCA (Principal Component Analysis) 和 LDA (Linear Discriminant Analysis) 是典型的线性降维算法。这一类算法对于具有线性结构的高维数据有着良好的处理结果,但对

于非线性结构的高维数据没有好的结果。典型的非线性降维算法以流形学习 (Manifold Learning) 算法。2000 年 Science 杂志上同一期发表了 3 篇有关于流形学习算法中提出了 2 种经典的流形学习算法 :LLE (Local Linear Embedding) 及 ISOMAP (Isometric Mapping)。由此,各种基于不同的准则的流形学习算法被提出并有一部分流形学习算法应用于图像处理方面。

[0008] 目前的 WiFi 室内定位方法存在的 Radio Map 数据库大、在线定位阶段计算复杂度高难以在移动终端实现、定位的实时性差等问题。

发明内容

[0009] 本发明是为了解决现有的 WiFi 室内定位方法的定位的实时性差的问题,从而提供一种基于 LDE 算法的 WiFi 室内定位方法。

[0010] 基于 LDE 算法的 WiFi 室内定位方法,它由以下步骤实现:

[0011] 步骤一、针对室内环境布置 N 个接入点 AP,确保所述环境中任意一点被一个或一个以上的接入点 AP 发出的信号覆盖,所述 N 个接入点 AP 组成 WiFi 网络;在所述室内环境中均匀设置 N_{RP} 个参考点;N 和 N_{RP} 均为正整数;

[0012] 步骤二、选取一个参考点为坐标原点建立二维直角坐标系,获得 N_{RP} 个参考点在该二维直角坐标系中的坐标位置,在离线阶段中在每个参考点上利用信号接收机采集来自每一个接入点 AP 的信号强度 RSS 值,并作为该接入点 AP 的位置特征信息;并根据 N 个接入点 AP 的位置特征信息构建室内信号覆盖图 Radio Map;

[0013] 步骤三、采用本征维数估计算法对步骤二获得的室内信号覆盖图 Radio Map 进行本征维数分析,获得本征维数分析结果;

[0014] 步骤四、根据步骤三获得的本征维数分析结果采用 LED 算法将室内信号覆盖图 Radio Map 内的所有参考点降维至本征维数,获得特征变换矩阵,并生成降维后的信号覆盖图 Radio Map*;

[0015] 步骤五、在在线阶段,测量室内环境中欲定位点的信号强度 RSS 值,并将该信号强度 RSS 值与步骤四获得的特征变换矩阵相乘,获得信号强度变换值 RSS^* ;

[0016] 步骤六、采用 KNN 算法对步骤五获得的信号强度变换值 RSS^* 与步骤四生成的降维后的信号覆盖图 Radio Map* 进行位置匹配,获得欲定位点的位置坐标,完成欲定位点的室内定位。

[0017] 步骤三中采用本征维数估计算法为特征值估计法。

[0018] 步骤三中采用本征维数估计算法为包数估计法。

[0019] 步骤三中采用本征维数估计算法为测地线最小生成树算法。

[0020] 采用测地线最小生成树算法对步骤二获得的室内信号覆盖图 Radio Map 进行本征维数分析是通过公式:

$$[0021] \quad d_{\text{intrinsic dim}} = \frac{1}{1-a}$$

[0022] 实现的;式中: $d_{\text{intrinsic dim}}$ 为本征维数分析结果;a 表示最小生成树的线性拟合表达式的斜率。

[0023] 步骤四中获得特征变换矩阵与生成降维后的信号覆盖图 Radio Map* 之间的关系

为：

[0024] $\text{Radio Map}^* = V' \cdot \text{Radio Map}$ 。

[0025] 采用 KNN 算法对步骤五获得的信号强度变换值 RSS^* 与步骤四生成的降维后的信号覆盖图 Radio Map^* 进行位置匹配的方法是通过公式：

$$[0026] \quad (x', y') = \frac{1}{K} \sum_{i=1}^K (x_i, y_i)$$

[0027] 实现的；

[0028] 式中： (x', y') 为欲定位点的坐标， (x_i, y_i) 为第 i 个近邻点的坐标， i 为正整数； K 为 KNN 算法中近邻点的总数。

[0029] 本发明的 WiFi 室内定位实时性高。同时，本发明采用 LDE 算法将 Radio Map 降维至本征维数，降低了现有 WiFi 室内定位方法中存在的 Radio Map 数据量大，以及降低了在线定位阶段计算复杂度，使其易于在移动终端实现。

附图说明

[0030] 图 1 是具体实施方式一中所述的实验场景示意图。图 2 是本发明方法的信号流程示意图。

具体实施方式

[0031] 具体实施方式一、结合图 2 说明本具体实施方式，基于 LDE 算法的 WiFi 室内定位方法，它由以下步骤实现：

[0032] 步骤一、针对室内环境布置 N 个接入点 AP，确保所述环境中任意一点被一个或一个以上的接入点 AP 发出的信号覆盖，所述 N 个接入点 AP 组成 WiFi 网络；在所述室内环境中均匀设置 N_{RP} 个参考点； N 和 N_{RP} 均为正整数；

[0033] 步骤二、选取一个参考点为坐标原点建立二维直角坐标系，获得 N_{RP} 个参考点在该二维直角坐标系中的坐标位置，在离线阶段中在每个参考点上利用信号接收机采集来自每一个接入点 AP 的信号强度 RSS 值，并作为该接入点 AP 的位置特征信息；并根据 N 个接入点 AP 的位置特征信息构建室内信号覆盖图 Radio Map；

[0034] 步骤三、采用本征维数估计算法对步骤二获得的室内信号覆盖图 Radio Map 进行本征维数分析，获得本征维数分析结果；

[0035] 步骤四、根据步骤三获得的本征维数分析结果采用 LED 算法将室内信号覆盖图 Radio Map 内的所有参考点降维至本征维数，获得特征变换矩阵，并生成降维后的信号覆盖图 Radio Map^* ；

[0036] 步骤五、在在线阶段，测量室内环境中欲定位点的信号强度 RSS 值，并将该信号强度 RSS 值与步骤四获得的特征变换矩阵相乘，获得信号强度变换值 RSS^* ；

[0037] 步骤六、采用 KNN 算法对步骤五获得的信号强度变换值 RSS^* 与步骤四生成的降维后的信号覆盖图 Radio Map^* 进行位置匹配，获得欲定位点的位置坐标，完成欲定位点的室内定位。

[0038] 步骤三中采用本征维数估计算法为特征值估计法、包数估计法或测地线最小生成树算法。

[0039] 采用测地线最小生成树算法对步骤二获得的室内信号覆盖图 Radio Map 进行本征维数分析是通过公式：

$$[0040] \quad d_{\text{intrinsic dim}} = \frac{1}{1-a}$$

[0041] 实现的；式中： $d_{\text{intrinsic dim}}$ 为本征维数分析结果； a 表示最小生成树的线性拟合表达式的斜率。

[0042] 步骤四中获得特征变换矩阵 V' 与生成降维后的信号覆盖图 Radio Map* 之间的关系为：

$$[0043] \quad \text{Radio Map}^* = V' \cdot \text{Radio Map}.$$

[0044] 采用 KNN 算法对步骤五获得的信号强度变换值 RSS^* 与步骤四生成的降维后的信号覆盖图 Radio Map* 进行位置匹配的方法是通过公式：

$$[0045] \quad (x', y') = \frac{1}{K} \sum_{i=1}^K (x_i, y_i)$$

[0046] 实现的；

[0047] 式中： (x', y') 为欲定位点的坐标， (x_i, y_i) 为第 i 个近邻点的坐标， i 为正整数； K 为 KNN 算法中近邻点的总数。

[0048] 本实施方式中，Radio Map 的本征维数的获取通过下述步骤实现：

[0049] 本征维数对于高维数据进行本征空间维数及空间重建所需最小的独立变量的个数。在具体实际计算中，由于高维数据的本征并不明显，通常不是寻求得到确切的本征维数，而是寻求估计本征维数的可信取值。具体的说，给定一个来自高维空间的样本，本征维数估计算法的中心任务和重要内容就是通过这些样本数据来确定这个高维结构的本征维数。

[0050] Radio Map 的本征维数的估计是 LDE 算法的重要输入参数，这关系到降维的结果是否能够代表 Radio Map 的高维空间的特征，因此准确有效的本征维数的估计至关重要。目前，常用本征维数估计算法分为两类：局部估计与全局估计。在本专利中，采用全局部算法估计对 Radio Map 的本征维数进行估计，并作为 LDE 算法的输入变量。本专利中采用测地距最小生成树算法 (Geodesic Minimum Spanning Tree, GMST) 对 Radio Map 的本征维数进行估计。下面对 GMST 算法的理论进行分析。

[0051] 测地线最小生成树 (GMST) 估计是基于测地线最小生成树的长度函数强烈依赖于本征维数 d 的。GMST 是指定义在数据集 X 上的近邻曲线的最小生成树。GMST 的长度函数是在测地线最小生成树中所有边缘对应的欧氏距离之和。

[0052] 与 ISOMAP 相似，GMST 估计在数据集 X 上构造一条近邻曲线 G ，其中，在 X 内每一个数据点 x_i 都和它的 k 个近邻 x_{i_j} 相连接。测地线最小生成树 T 定义为 X 上的最小曲线，它具有长度：

[0053]

$$L(X) = \min_{T \in \mathcal{T}} \sum_{e \in T} g_e \quad (1)$$

[0054] 其中， \mathcal{T} 是曲线 G 的所有子树集合， e 是树 T 的一个边缘， g_e 是边缘 e 对应的欧氏距离。在 GMST 估计中，一些子集 $A \subset X$ 由各种大小 m 组成，并且子集 A 的 GMST 的长度 $L(A)$

也需要计算。

[0055] 理论上, $\frac{\log L(A)}{\log m}$ 是线性的, 从而可以由 $y = ax+b$ 这种形式的函数来估计, 通过最小二乘法可以估算出变量 a 和 b 。

[0056] 可以证明: 由 a 的估算值和 $\hat{d} = \frac{1}{1-a}$ 能够得到本征维数的估计。

[0057] 由 GMST 算法给出本征维数 d 的表达式为式 (2) 所示。本征维数 d 是 LDE 算法的另一个重要的输入参数。

$$[0058] \quad d = \frac{1}{1-a} \quad (2)$$

[0059] 运用 LDE 算法实现对 Radio Map 进行降维并获取特征权值矩阵过程通过下述步骤实现:

[0060] LDE 算法是基于类间散度及类内散度最大化的一种流形学习算法。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。

[0061] 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。下面结合错误! 未找到引用源。所示的 LDE 算法流程来对其算法理论进行推导。

[0062] 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。

[0063] 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) 所示。公式 (3) 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 之间的范数距离, 采用矩阵方式计算范数距离, t 为权值归一化参数。

$$[0064] \quad \begin{cases} w_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2 / t); & \text{if } x_i, x_j \in G \\ 0; & \end{cases} \\ w'_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2 / t); & \text{if } x_i, x_j \in G' \\ 0; & \end{cases} \end{cases} \quad (3)$$

[0065] 计算嵌入结果: 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。

$$[0066] \quad \begin{cases} \text{Maximize } J(V) = \sum_{i,j} \|V^T x_i - V^T x_j\|^2 w'_{ij} \\ \text{subject to } \sum_{i,j} \|V^T x_i - V^T x_j\|^2 w'_{ij} = 1 \end{cases} \quad (4)$$

[0067] 根据式 (4) 给出的优化目标函数作以下分析：

[0068] 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 (4) 可以表示为矩阵的迹的计算方式：

$$[0069] \quad J(V) = \sum_{i,j} \left\{ \text{tr} \left[(V^T x_i - V^T x_j)(V^T x_i - V^T x_j)^T w'_{ij} \right] \right\} \quad (5)$$

[0070] 式 (5) 可以简化为：

$$[0071] \quad J(V) = \sum_{i,j} \left\{ \text{tr} \left[V^T (x_i - x_j)(x_i - x_j)^T V \right] w'_{ij} \right\} \quad (6)$$

[0072] 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 (6) 简化为：

$$[0073] \quad J(V) = \text{tr} \left\{ V^T \sum_{i,j} \left[(x_i - x_j) w'_{ij} (x_i^T - x_j^T) \right] V \right\} \quad (7)$$

[0074] 根据简单的数学关系，可以将式 (7) 简化为：

$$[0075] \quad J(V) = 2 \text{tr} \{ V^T [X(D' - W')X^T] V \} \quad (8)$$

[0076] 式 (8) 中： X 为输入数据， λ ， 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 (9) 表示。

$$[0077] \quad \begin{cases} d_{ii} = \sum_j w_{ij} \\ d'_{ii} = \sum_j w'_{ij} \end{cases} \quad (9)$$

[0078] 根据式 (8) 的推导方式，同理可以将 (4) 中的约束条件写成如式 (8) 相似的形式，由此，可以将 (4) 表示为如下形式：

$$[0079] \quad \begin{cases} \text{Maximize } J(V) = 2 \text{tr} \{ V^T [X(D' - W')X^T] V \} \\ \text{subject to } 2 \text{tr} [X(D - W)X^T] = 1 \end{cases} \quad (10)$$

[0080] 对式 (10) 应用拉格朗日 (Lagrange) 乘法，可以得出式 (11) 所示：

$$[0081] \quad X(D' - W')X^T v = \lambda X(D - W)X^T v \quad (11)$$

[0082] 对式 (11) 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：

$$[0083] \quad z_i = V^T x_i \quad (12)$$

[0084] 式 (12) 中, z_i 表示输入高维数据点 x_i 变换后的低维输出数据。

[0085] 上述的分析是根据 LDE 算法流程给出的理论分析及说明。

[0086] 由式 (5) ~ (11) 给出 LDE 算法的理论推导。通过 LDE 算法可以得出降维后的信号覆盖图及特征变换矩阵, 分别记为 Radio Map* 和 V' 。

[0087] 在线定位阶段对 RSS 及 KNN 匹配定位通过下述步骤实现:

[0088] 结合图 2 的在线阶段所示的流程图对具体实施方式四进行详细说明。在线阶段, 测试点处接收的 $RSS = [AP_1, AP_2, \dots, AP_n]$, 与特征变换矩阵 V' 相乘, 从而得出降维后的 $RSS' = [AP_1, AP_2, \dots, AP_d]$, 其中 d 表示本征维数。再采用 KNN 算法实现 RSS' 与 Radio Map* 的匹配。采用与 RSS' 最近的 K 个参考点的坐标的平均值作为测试点 (x', y') , 其表达式为:

$$[0089] \quad (x', y') = \frac{1}{K} \sum_{i=1}^K (x_i, y_i) \quad (13)$$

[0090] AP 在具体的室内布置及实验过程如下例所示: 图 1 示为哈尔滨工业大学科学园 2A 栋 12 层的平面图示意, 基于 WiFi 的室内定位系统就是基于该实验环境下建立。在实验环境中, 总共布置 27 个 AP, AP 离房间地面高度为 2 米。在离线阶段, 在联想 V450 笔记本上安装 NetStumbler 软件, 在所有参考点的四个不同的方位上连续采样记录 AP 的 100 个 RSS 值, 以及 AP 的相关信息。将所有的采样点的物理坐标及相应的物理坐标及 RSS 值存储为定位过程所调用的数据, 建立 Radio Map。在实验环境共有 900 个参考点, 其采样密度为 0.5 米 \times 0.5 米。Radio Map 作为 LDE 算法的输入参数及本征维数估计算法的输入数据。

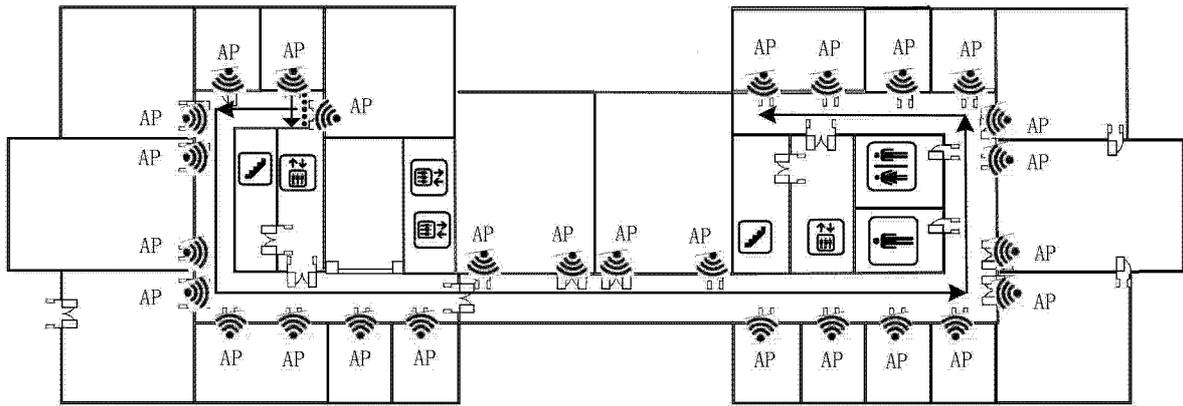


图 1

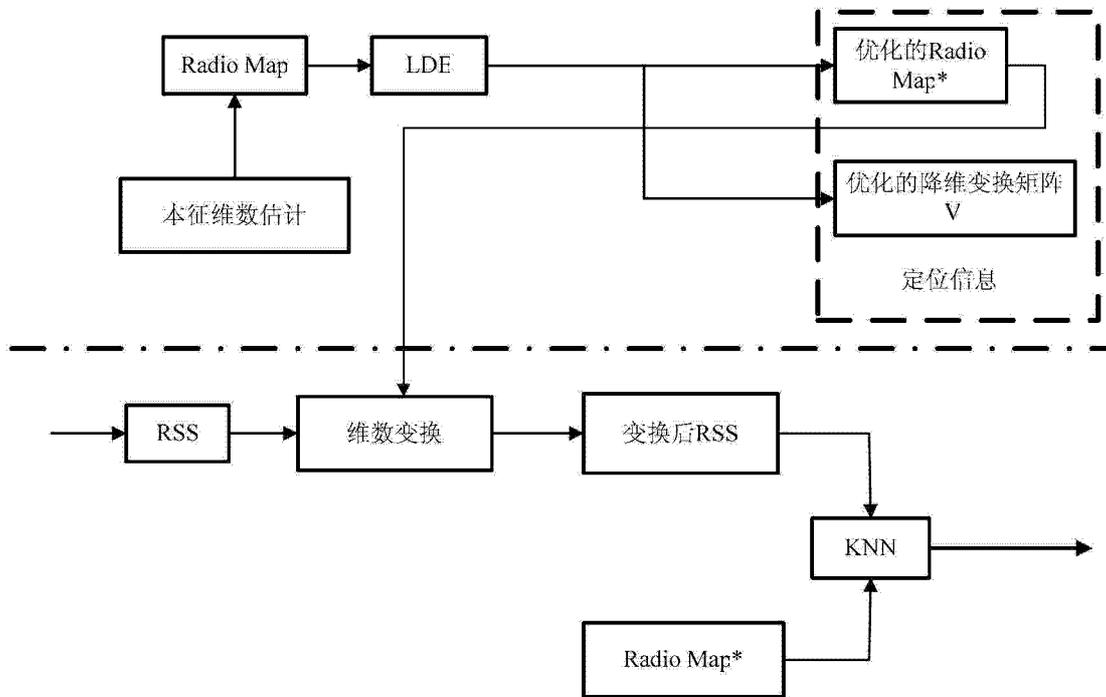


图 2