



(12) 发明专利

(10) 授权公告号 CN 110830939 B

(45) 授权公告日 2021.04.27

(21) 申请号 201910810666.6

H04W 64/00 (2009.01)

(22) 申请日 2019.08.29

G06N 3/06 (2006.01)

G06F 16/22 (2019.01)

(65) 同一申请的已公布的文献号

申请公布号 CN 110830939 A

(56) 对比文件

(43) 申请公布日 2020.02.21

CN 107037399 A, 2017.08.11

US 2018114056 A1, 2018.04.26

(73) 专利权人 天津大学

CN 109151727 A, 2019.01.04

CN 108540929 A, 2018.09.14

地址 300072 天津市南开区卫津路92号

CN 109633530 A, 2019.04.16

(72) 发明人 杨晋生 杨雁南 刘斌

干建勇. 基于ZigBee位置指纹匹配法的室内定位算法研究.《中国优秀硕士学位论文全文数据库信息科技辑》.2018,

(74) 专利代理机构 天津市北洋有限责任专利代理事务所 12201

代理人 刘国威

审查员 刘媛

(51) Int. Cl.

H04W 4/33 (2018.01)

H04W 4/021 (2018.01)

H04W 4/02 (2018.01)

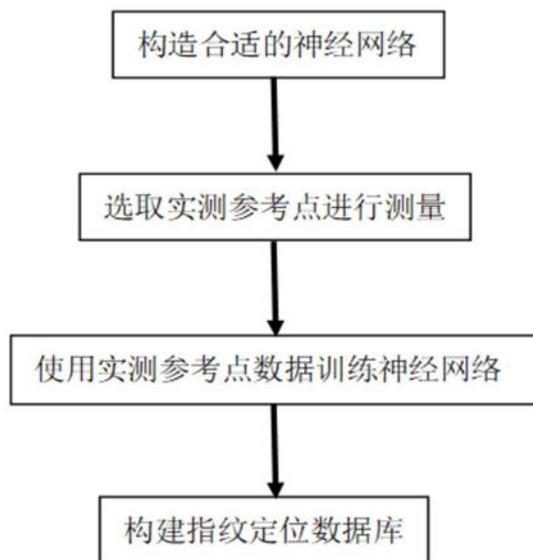
权利要求书3页 说明书7页 附图2页

(54) 发明名称

基于改进的CPN-WLAN指纹定位数据库的定位方法

(57) 摘要

本发明涉及WLAN指纹室内定位技术,为通过对对神经网络进行改进,提出一种给予改进的CPN的WLAN指纹定位数据库构建算法,降低WLAN指纹定位的离线阶段的工作量,本发明,基于改进的CPN-WLAN指纹定位数据库的定位方法,步骤如下:步骤1:在需要进行定位的区域中选取实测参考点并进行数据的测量;步骤2:使用自编码器对参考点指纹信息进行降维;步骤3:构造合适的神经网络结构;步骤4:使用实测点测得的数据训练神经网络;步骤5:使用训练好的神经网络构建指纹定位数据库。本发明主要应用于WLAN指纹室内定位场合。



1. 一种基于改进的CPN-WLAN指纹定位数据库的定位方法,其特征是,步骤如下:

步骤1: 在需要进行定位的区域中选取实测参考点并进行数据的测量

在待定位区中大致均匀的选取实测参考点,测量其位置坐标和RSS指纹,实测参考点数量应明显少于参考点的总数,减少离线阶段工作量;

步骤2: 使用自编码器对参考点指纹信息进行降维

(1) 构造合适的自编码器,将自编码器的输入层和输出层神经元数量设置为与待定位区内的接入点AP (Access Point) 数量相同,隐藏层神经元数量设置为64个;

(2) 将参考点指纹数据输入自编码器进行迭代训练;

步骤3: 构造合适的神经网络结构

(1) 修改对传神经网络CPN的输入层,将神经元数量设置为二维空间坐标与自编码器隐藏层神经元数量之和;

(2) 对于CPN的Kohonen层部分,设置激活层中输入最大的2个神经元,并使用Softmax函数获得对应的激活权重;

步骤4: 使用实测点测得的数据训练神经网络

将实测点指纹信息输入自编码器进行降维,然后与参考点空间坐标共同输入CPN,进行迭代训练;

步骤5: 使用训练好的神经网络构建指纹定位数据库

(1) 预测剩余参考点的指纹信息

将剩余参考点的二维位置坐标按规定形式输入训练好的神经网络中,则输出值中对应部分即为对应参考点的指纹信息;

(2) 构建完整的指纹定位数据库

将剩余参考点的指纹信息与实测参考点的指纹信息进行合并,从而完成WLAN指纹定位数据库的构建用于定位。

2. 如权利要求1所述的基于改进的CPN-WLAN指纹定位数据库的定位方法,其特征是,用Softmax函数改进Kohonen层中神经元的激活策略,每次激活2个输入最大的神经元,Softmax函数将一组数据映射到(0,1)区间内,得到的数值相加和为1,各个数据对应于其大小的分类概率,对于一个数组V,包含n个元素, V_i 表示V中的第i个元素,那么这个元素的Softmax值就是:

$$S_{V_i} = \frac{e^{V_i}}{\sum_{j=1}^n e^{V_j}}$$

3. 如权利要求1所述的基于改进的CPN-WLAN指纹定位数据库的定位方法,其特征是,还包括验证步骤:采用实测得到的WLAN指纹定位数据集UJIIndoorLoc,该数据集主要包括training数据集和validation数据集2个文件,信息如表1所示:

表1 UJIIndoorLoc数据集内容形式表

列数	标题	内容
----	----	----

001-520	WAP001-520	各 AP 的 RSS 值
521-522	LONGITUDE&LATITUDE	UTM 位置坐标
523	FLOOR	楼层标号
524	BUILDINGID	楼宇标号
525	SPACEID	空间标号
526	RELATIVEPOSITION	相对位置
527	USERID	测试者标号
528	PHONEID	手机标号
529	TIMESTAMP	Unix 时间

使用BUILDINGID为0、FLOOR为0处的数据:training数据集中共有在54个RP处的1059组数据,取其中10个RP处的数据作为训练集,看作离线阶段实测数据,剩余数据作为验证集;validation数据集中共有在78个RP处的78组数据,作为测试集;

训练集、验证集和测试集处于同一平面空间;

神经网络训练完成后,将验证集中的RP坐标输入神经网络中,其中改进的CPN和传统CPN输入数据为(0,0,……,0,0, LONGITUDE, LATITUDE),输出前520项为RSS的预测值;BPNN输入数据为(LONGITUDE, LATITUDE),输出为RSS预测值,与训练集数据合并,完成指纹定位数据库的构建,在构建后的数据库上使用KNN、WKNN对测试集RP进行定位,所有实验数据均重复10次,取平均值进行记录;对比预测验证集中全部RP、31个RP、16个RP处的RSS指纹时的数据库构建情况;

改进的CPN训练完成后,将验证集中RP的坐标值输入神经网络中,输出对应RSS指纹的预测值,并与训练集数据合并,对指纹定位数据库进行构建,将测试集的RP作为待定位点,在构建后的指纹定位数据库上使用最近邻KNN(K Nearest Neighbors)、加权K最近邻WKNN(Weighed K Nearest Neighbors)算法对构建效果进行评估,算法训练时间由TensorFlow交互界面得到,重复实验10次,取平均值进行记录,分别对比以下几种指纹数据库的构建情况:构建验证集中全部RP处的RSS指纹;构建验证集中31个RP处的RSS指纹;构建验证集中16个RP处的RSS指纹,实验数据对比见表2:

表2 实验数据对比表

	KNN/m	WKNN/m	K	time/s
Original-54	10.0067	9.9035	5	null
Original-41	10.4359	10.3067	11	null
Original-26	10.9445	10.8008	2	null
IPCPN-54	10.1361	10.0022	5	106.3
IPCPN-41	10.5543	10.4043	5	106.3
IPCPN-26	10.8846	10.8655	5	106.3
CPN-54	14.9412	14.9412	1	108.6
CPN-41	15.1749	15.1749	1	108.6
CPN-26	15.2058	15.2058	1	108.6

BPNN-54	12.4438	12.4438	1	108.5
BPNN-41	13.1565	13.1565	1	108.5
BPNN-26	13.5464	13.5464	1	108.5

表2中数据均在同一数据集上得到Original、IPCPN、CPN、BPNN分别代表实测数据库和由改进的CPN、传统CPN、BPNN构建后的数据库,横线后数字代表构建后的数据库中RP的数量,KNN、WKNN代表这两种方法的平均定位误差,K代表误差最小时K的取值,time为神经网络训练时间。

基于改进的CPN-WLAN指纹定位数据库的定位方法

技术领域

[0001] 本发明涉及WLAN指纹室内定位技术,具体讲,涉及基于改进的对传神经网络(Counter Propagation Network,CPN)的WLAN指纹定位数据库构建及定位方法。

背景技术

[0002] 伴随着手机、平板电脑等智能移动终端的快速发展,基于位置的服务(Location Based Service,LBS)增长很快,尤其是室内定位需求增长很快。现阶段基于室内定位的方法主要包括射频识别(Radio Frequency Identification,RFID)、蓝牙(Bluetooth,BT)、无线局域网(Wireless Local Area Networks,WLAN)、Zigbee和超宽带无线电(Ultra Wide Band,UWB)等方案。由于不需要额外设备、成本较低等优势使得WLAN指纹定位技术得到了社会广泛的认可。然而由于在离线阶段需要对大量参考点(Reference Point,RP)进行测量,耗费人力物力,使得WLAN指纹定位技术的普及存在一定的难度。

[0003] 对于离线阶段数据库的建立,目前主要有以下解决方法:

[0004] 通过统计信号特征,剔除非必要的RP,降低在线阶段的计算复杂度;通过设计平滑过滤器和加尾过滤器,使用少量RP扩充指纹定位数据库,但应用场景较为有限;缩短RP的信号采集时间,使用kriging插值构建指纹定位数据库,但并未实质上减少离线阶段工作量;将神经网络应用于预测未知RP的RSS(Received Signal Strength,接收信号强度)指纹,减少离线阶段工作量,但只适用于对精度要求较低的情况;通过终端持有者主动提交指纹信息的方法构建数据库,但是仍然需要将其作为额外任务来做;通过运用群智感知的理念,让用户不需特别关注即可完成对指纹信息的采集,但存在隐私信息泄露的风险;利用神经网络减少离线阶段测量面积,减轻工作负荷,但定位效果不佳。

[0005] 针对上述问题,并且为了降低离线阶段工作量,对WLAN指纹定位数据库的构建提出了新的更高的要求。基于此,开展了对WLAN指纹定位数据库构建算法的研究。

发明内容

[0006] 为克服现有技术的不足,本发明旨在通过对对传神经网络(Counter Propagation Network,CPN)进行改进,提出一种给予改进的CPN的WLAN指纹定位数据库构建算法,降低WLAN指纹定位的离线阶段的工作量。为此,本发明采取的技术方案是,基于改进的CPN-WLAN指纹定位数据库的定位方法,步骤如下:

[0007] 步骤1:在需要进行定位的区域中选取实测参考点并进行数据的测量

[0008] 在待定位区中大致均匀的选取实测参考点,测量其位置坐标和RSS指纹,实测参考点数量应明显少于参考点的总数,减少离线阶段工作量;

[0009] 步骤2:使用自编码器对参考点指纹信息进行降维

[0010] (1) 构造合适的自编码器,将自编码器的输入层和输出层神经元数量设置为与待定位区内的接入点AP(Access Point)数量相同,隐藏层神经元数量设置为64个;

[0011] (2) 将参考点指纹数据输入自编码器进行迭代训练。

[0012] 步骤3:构造合适的神经网络结构

[0013] (1) 修改对传神经网络CPN的输入层,将神经元数量设置为二维空间坐标与自编码器隐藏层神经元数量之和;

[0014] (2) 对于CPN的Kohonen层部分,设置激活层中输入最大的2个神经元,并使用Softmax函数获得对应的激活权重;

[0015] 步骤4:使用实测点测得的数据训练神经网络

[0016] 将实测点指纹信息输入自编码器进行降维,然后与参考点空间坐标共同输入CPN,进行迭代训练;

[0017] 步骤5:使用训练好的神经网络构建指纹定位数据库

[0018] (1) 预测剩余参考点的指纹信息

[0019] 将剩余参考点的二维位置坐标按规定形式输入训练好的神经网络中,则输出值中对应部分即为对应参考点的指纹信息;

[0020] (2) 构建完整的指纹定位数据库

[0021] 将剩余参考点的指纹信息与实测参考点的指纹信息进行合并,从而完成WLAN指纹定位数据库的构建用于定位。

[0022] 用Softmax函数改进Kohonen层中神经元的激活策略,每次激活2个输入最大的神经元,Softmax函数将一组数据映射到(0,1)区间内,得到的数值相加和为1,各个数据对应于其大小的分类概率,对于一个数组V,包含n个元素, V_i 表示V中的第i个元素,那么这个元素的Softmax值就是:

$$[0023] \quad S_{V_i} = \frac{e^{V_i}}{\sum_{j=1}^n e^{V_j}}。$$

[0024] 还包括验证步骤:采用实测得到的WLAN指纹定位数据集UJIIndoorLoc。该数据集主要包括training数据集和validation数据集2个文件,信息如表1所示:

[0025] 表1UJIIndoorLoc数据集内容形式表

列数	标题	内容
001-520	WAP001-520	各 AP 的 RSS 值
521-522	LONGITUDE&LATITUDE	UTM 位置坐标
523	FLOOR	楼层标号
524	BUILDINGID	楼宇标号
[0026] 525	SPACEID	空间标号
526	RELATIVEPOSITION	相对位置
527	USERID	测试者标号
528	PHONEID	手机标号
529	TIMESTAMP	Unix 时间

[0027] 使用BUILDINGID为0、FLOOR为0处的数据:training数据集中共有在54个RP处的1059组数据,取其中10个RP处的数据作为训练集,看作离线阶段实测数据,剩余数据作为验证集;validation数据集中共有在78个RP处的78组数据,作为测试集;

[0028] 训练集、验证集和测试集处于同一平面空间；

[0029] 神经网络训练完成后，将验证集中的RP坐标输入神经网络中，其中改进的CPN和传统CPN输入数据为(0,0,……,0,0, LONGITUDE, LATITUDE)，输出前520项为RSS的预测值；BPNN输入数据为(LONGITUDE, LATITUDE)，输出为RSS预测值，与训练集数据合并，完成指纹定位数据库的构建，在构建后的数据库上使用KNN、WKNN对测试集RP进行定位，所有实验数据均重复10次，取平均值进行记录；对比预测验证集中全部RP、31个RP、16个RP处的RSS指纹时的数据库构建情况；

[0030] 改进的CPN训练完成后，将验证集中RP的坐标值输入神经网络中，输出对应RSS指纹的预测值，并与训练集数据合并，对指纹定位数据库进行构建，将测试集的RP作为待定位点，在构建后的指纹定位数据库上使用最近邻KNN(K Nearest Neighbors)、加权K最近邻WKNN(Weighed K Nearest Neighbors)算法对构建效果进行评估，算法训练时间由TensorFlow交互界面得到，重复实验10次，取平均值进行记录，分别对比以下几种指纹数据库的构建情况：构建验证集中全部RP处的RSS指纹；构建验证集中31个RP处的RSS指纹；构建验证集中16个RP处的RSS指纹，实验数据对比见表2：

[0031] 表2实验数据对比表

	KNN/m	WKNN/m	K	time/s	
	Original-54	10.0067	9.9035	5	null
	Original-41	10.4359	10.3067	11	null
	Original-26	10.9445	10.8008	2	null
	IPCPN-54	10.1361	10.0022	5	106.3
	IPCPN-41	10.5543	10.4043	5	106.3
[0032]	IPCPN-26	10.8846	10.8655	5	106.3
	CPN-54	14.9412	14.9412	1	108.6
	CPN-41	15.1749	15.1749	1	108.6
	CPN-26	15.2058	15.2058	1	108.6
	BPNN-54	12.4438	12.4438	1	108.5
	BPNN-41	13.1565	13.1565	1	108.5
	BPNN-26	13.5464	13.5464	1	108.5

[0033] 表2中数据均在同一数据集上得到Original、IPCPN、CPN、BPNN分别代表实测数据库和由改进的CPN、传统CPN、BPNN构建后的数据库，横线后数字代表构建后的数据库中RP的数量，KNN、WKNN代表这两种方法的平均定位误差，K代表误差最小时K的取值，time为神经网络训练时间。

[0034] 本发明的特点及有益效果是：

[0035] 本发明提供了一种基于改进的CPN的WLAN指纹定位数据库构建算法，通过使用稀疏自编码器改进RBM部分，然后使用稀疏性限制改进BPNN部分，能够较大的降低离线阶段需要实测的测量点的数目，同时获得较好的定位精度，从而有效地降低WLAN指纹定位离线阶段的工作量。

附图说明：

- [0036] 图1训练集和验证集中RP空间分布图。
[0037] 图2测试集RP空间分布图。
[0038] 图3步骤流程图。

具体实施方式

[0039] 本发明通过对对传神经网络 (Counter Propagation Network, CPN) 进行改进, 提出一种给予改进的CPN的WLAN指纹定位数据库构建算法, 降低WLAN指纹定位的离线阶段的工作量。具体技术方案如下:

[0040] 步骤1: 在需要进行定位的区域中选取实测参考点并进行数据的测量

[0041] 在待定位区中大致均匀的选取实测参考点, 测量其位置坐标和RSS指纹, 实测参考点数量应明显少于参考点的总数, 减少离线阶段工作量

[0042] 步骤2: 使用自编码器对参考点指纹信息进行降维

[0043] (1) 构造合适的自编码器, 将自编码器的输入层和输出层神经元数量设置为与待定位区内的接入点 (Access Point, AP) 数量相同, 隐藏层神经元数量设置为64个。

[0044] (2) 将参考点指纹数据输入自编码器进行迭代训练。

[0045] 步骤3: 构造合适的神经网络结构

[0046] (1) 修改CPN的输入层, 将神经元数量设置为二维空间坐标与自编码器隐藏层神经元数量之和。

[0047] (2) 对于CPN的Kohonen层部分, 设置激活层中输入最大的2个神经元, 并使用Softmax函数获得对应的激活权重。

[0048] 步骤4: 使用实测点测得的数据训练神经网络

[0049] 将实测点指纹信息输入自编码器进行降维, 然后与参考点空间坐标共同输入CPN, 进行迭代训练。

[0050] 步骤5: 使用训练好的神经网络构建指纹定位数据库

[0051] (1) 预测剩余参考点的指纹信息

[0052] 将剩余参考点的二维位置坐标按规定形式输入训练好的神经网络中, 则输出值中对应部分即为对应参考点的指纹信息;

[0053] (2) 构建完整的指纹定位数据库

[0054] 将剩余参考点的指纹信息与实测参考点的指纹信息进行合并, 从而完成WLAN指纹定位数据库的构建。

[0055] 下面结合附图和具体实例进一步详细说明本发明。

[0056] 本发明技术方案如下:

[0057] 1) 使用自编码器对参考点指纹信息进行降维。对于分类问题, 提取输入的特征信息十分重要。在传统CPN中, 输入层直接将数据输入CPN中, 没有对输入数据做任何的处理。而指纹定位中的RSS指纹是由不同RP的RSS值组成, 在其他条件不变的情况下, RSS指纹中包含的RP数量越多, 也即RSS指纹的维数越高, 定位效果一般也会越好。室内定位中存在墙体等障碍物, 环境复杂, 会对RP的RSS值产生较大的衰减作用, 使RSS值变得比较小甚至衰减为0, 因而在RSS指纹当中并不是每一维数据都对分类有着重要作用。若不处理输入的RSS指纹

数据,把指纹值中的特征信息提取出来,就将造成不必要的算力损耗,还会降低分类的准确率。

[0058] 针对以上问题,本发明采用自编码器对输入数据进行处理。自编码器(Autoencoder,AE)是一种无监督学习算法,通过反向传播算法使输入和输出相同^[53],即用自身的高阶特征编码自己,来获得输入数据的高阶特征信息,结构包含编码器(encoder)和解码器(decoder)。顾名思义,数据从输入层传递到隐藏层的过程可以看作是对信息的编码的过程,而从隐藏层传递到输出层的过程可以看作是对信息的解码的过程。通常AE隐藏层的维数小于输入层,从而可以学习到输入数据的压缩表示和降维后的特征信息。

[0059] 如图1所示,输入层的数据经过压缩得到隐藏层数据,隐藏层数据经过解压缩得到输出数据。为了能够使输入和输出相等,隐藏层就需要学习输入数据的压缩表达,即提取出输入数据当中的特征信息。因此可以使用AE对RSS指纹进行降维,将RSS指纹作为输入数据输入到AE中,经过训练,隐藏层数据即为RSS指纹降维后所获得的高阶特征信息。

[0060] 2) 使用Softmax函数改进Kohonen层激活策略。传统的CPN中,Kohonen层根据输入数据,只激活层中的某一个节点,使其输出为1。这就使得Grossberg层只能根据Kohonen层中激活的唯一节点进行预测。一旦Kohonen层分类产生偏差,将导致Grossberg层输入产生偏差。即使Kohonen层分类正确,将特征信息相近的多组数据归为一类,则它们的输出数据将完全相同,无法区分其中各组数据。而不同测试点的坐标即使被划分为同一类坐标,其各自的RSS指纹也不可能完全相同,因此不同坐标得到相同的RSS指纹预测值将产生较大的误差。

[0061] 针对以上问题,本算法用Softmax函数改进Kohonen层中神经元的激活策略,每次激活2个输入最大的神经元。Softmax函数可将一组数据映射到(0,1)区间内,得到的数值相加和为1,因此可以理解为各个数据对应于其大小的分类概率。假设有一个数组V,包含n个元素, V_i 表示V中的第i个元素,那么这个元素的Softmax值就是

$$[0062] \quad S_{V_i} = \frac{e^{V_i}}{\sum_{j=1}^n e^{V_j}}$$

[0063] 通过公式可以看出Softmax值的大小与元素本身的大小有关,与竞争性规则相比,值较小的元素也有一定的概率可以取到。与只激活输入最大的神经元不同,应用Softmax函数对输入最大的2个神经元进行处理,并得到对应的分类概率。因为不同的输入数据可以激活不同的2个神经元,而每个神经元对CPN的输出影响各不相同,所以不同的输入可以获得不同的输出。

[0064] 步骤1:在需要进行定位的区域中选取实测参考点并进行数据的测量

[0065] 在待定位区中大致均匀的选取实测参考点,测量其位置坐标和RSS指纹,实测参考点数量应明显少于参考点的总数,减少离线阶段工作量

[0066] 步骤2:使用自编码器对参考点指纹信息进行降维

[0067] (1) 构造合适的自编码器,将自编码器的输入层和输出层神经元数量设置为与待定位区内的接入点(Access Point,AP)数量相同,隐藏层神经元数量设置为64个。

[0068] (2) 将参考点指纹数据输入自编码器进行迭代训练。

[0069] 步骤3:构造合适的神经网络结构

[0070] (1) 修改CPN的输入层,将神经元数量设置为二维空间坐标与自编码器隐藏层神经元数量之和。

[0071] (2) 对于CPN的Kohonen层部分,设置激活层中输入最大的2个神经元,并使用Softmax函数获得对应的激活权重。

[0072] 步骤4:使用实测点测得的数据训练神经网络

[0073] 将实测点指纹信息输入自编码器进行降维,然后与参考点空间坐标共同输入CPN,进行迭代训练。

[0074] 步骤5:使用训练好的神经网络构建指纹定位数据库

[0075] (1) 预测剩余参考点的指纹信息

[0076] 将剩余参考点的二维位置坐标按规定形式输入训练好的神经网络中,则输出值中对应部分即为对应参考点的指纹信息;

[0077] (2) 构建完整的指纹定位数据库

[0078] 将剩余参考点的指纹信息与实测参考点的指纹信息进行合并,从而完成WLAN指纹定位数据库的构建。

[0079] 本发明依据上述基于改进的CPN的WLAN指纹定位数据库构建算法,选取了WLAN指纹定位数据集UJIIndoorLoc的部分数据进行了实验,并将实验结果与其他算法进行了对比,对本发明的有效性进行验证如下:

[0080] 在本次实验中采用实测得到的WLAN指纹定位数据集UJIIndoorLoc。该数据集主要包括training数据集和validation数据集2个文件,文件的主要信息如表1所示。

[0081] 表1 UJIIndoorLoc数据集内容形式表

列数	标题	内容
001-520	WAP001-520	各 AP 的 RSS 值
521-522	LONGITUDE&LATITUDE	UTM 位置坐标
[0082] 523	FLOOR	楼层标号
524	BUILDINGID	楼宇标号
525	SPACEID	空间标号
526	RELATIVEPOSITION	相对位置
527	USERID	测试者标号
528	PHONEID	手机标号
[0083] 529	TIMESTAMP	Unix 时间

[0084] 本算法使用BUILDINGID为0、FLOOR为0处的数据:training数据集中共有在54个RP处的1059组数据,取其中10个RP处的数据作为训练集,看作离线阶段实测数据,剩余数据作为验证集;validation数据集中共有在78个RP处的78组数据,作为测试集。训练集和验证集中RP的空间分布如图1所示。

[0085] 图1中白点即为训练集中的RP。测试集中RP的空间分布如图2所示。由图1、图2可知,本次实验的训练集、验证集和测试集基本处于同一平面空间,可以用于本实验。

[0086] 神经网络训练完成后,将验证集中的RP坐标输入神经网络中,其中改进的CPN和传统CPN输入数据为(0,0,……,0,0, LONGITUDE, LATITUDE),输出前520项为RSS的预测值;BPNN输入数据为(LONGITUDE, LATITUDE),输出为RSS预测值。与训练集数据合并,完成指纹定位数据库的构建,在构建后的数据库上使用KNN、WKNN对测试集RP进行定位。所有实验数据均重复10次,取平均值进行记录。本文对比预测验证集中全部RP、31个RP、16个RP处的RSS指纹时的数据库构建情况。实验数据对比见表2:

[0087] 改进的CPN训练完成后,将验证集中RP的坐标值输入神经网络中,输出对应RSS指纹的预测值,并与训练集数据合并,对指纹定位数据库进行构建。将测试集的RP作为待定位点,在构建后的指纹定位数据库上使用KNN(K Nearest Neighbors, K最近邻)、WKNN(Weighed K Nearest Neighbors, 加权K最近邻)算法对构建效果进行评估。算法训练时间由TensorFlow交互界面得到。所有实验数据均重复实验10次,取平均值进行记录。分别对比以下几种指纹数据库的构建情况:构建验证集中全部RP处的RSS指纹;构建验证集中31个RP处的RSS指纹;构建验证集中16个RP处的RSS指纹。实验数据对比见表2。

[0088] 表2实验数据对比表

	KNN/m	WKNN/m	K	time/s
Original-54	10.0067	9.9035	5	null
Original-41	10.4359	10.3067	11	null
Original-26	10.9445	10.8008	2	null
IPCPN-54	10.1361	10.0022	5	106.3
IPCPN-41	10.5543	10.4043	5	106.3
[0089] IPCPN-26	10.8846	10.8655	5	106.3
CPN-54	14.9412	14.9412	1	108.6
CPN-41	15.1749	15.1749	1	108.6
CPN-26	15.2058	15.2058	1	108.6
BPNN-54	12.4438	12.4438	1	108.5
BPNN-41	13.1565	13.1565	1	108.5
BPNN-26	13.5464	13.5464	1	108.5

[0090] 表2中数据均在同一数据集上得到Original、IPCPN、CPN、BPNN分别代表实测数据库和由改进的CPN、传统CPN、BPNN构建后的数据库,横线后数字代表构建后的数据库中RP的数量。KNN、WKNN代表这两种方法的平均定位误差,K代表误差最小时K的取值,time为神经网络训练时间。可知:

[0091] 1) 相比于传统CPN和BPNN,改进的CPN构建的数据库的定位精度均为最高,误差仅比原始数据库大不到0.1米,差距仅为约1%;BPNN构建效果差于改进的CPN,与原数据库对比误差均超过2.5米;传统CPN构建效果最差,与原数据库对比误差均超过4米。

[0092] 2) 改进的CPN训练时间短于传统的BPNN和传统CPN。

[0093] 3) IPCPN-26的定位效果强于CPN-54和BPNN-54,因此IPCPN可以通过构建更少的RP来达到比传统CPN和BPNN更好的效果,减少了构建数据库的工作量。

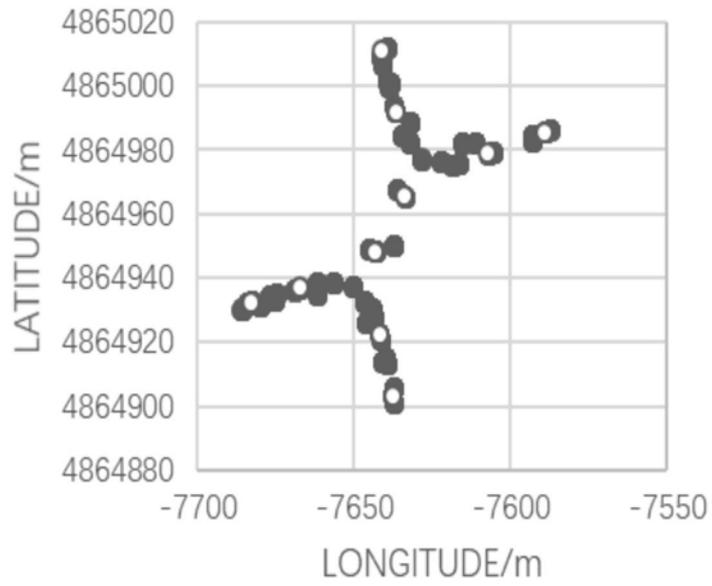


图1

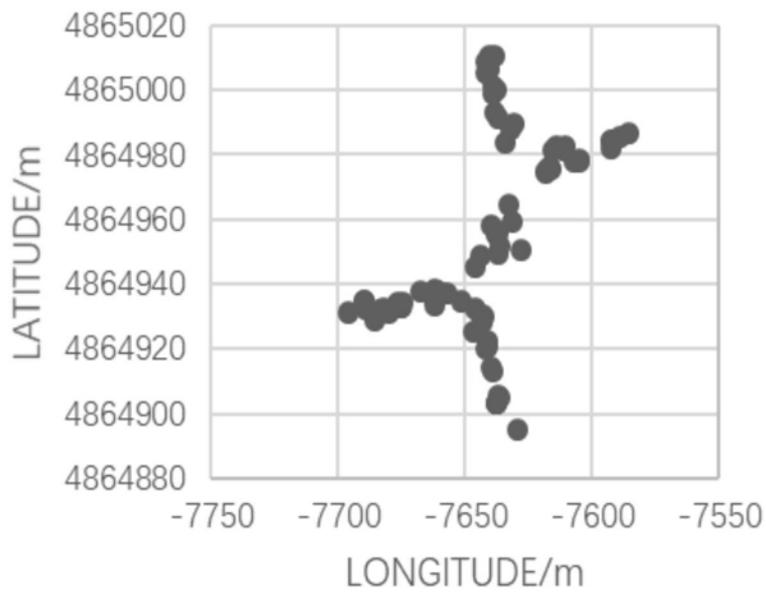


图2

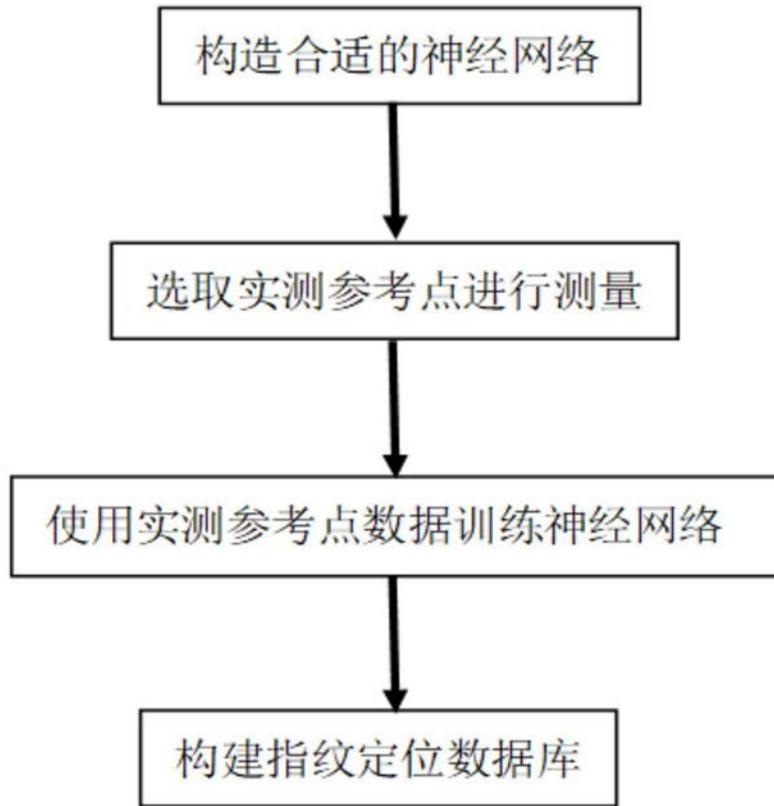


图3