



(12) 发明专利申请

(10) 申请公布号 CN 117062001 A

(43) 申请公布日 2023. 11. 14

(21) 申请号 202310957627.5

(22) 申请日 2023.08.01

(71) 申请人 哈尔滨工程大学

地址 150000 黑龙江省哈尔滨市南岗区南通大街145号

(72) 发明人 李伟 刘芷含 孟祥旭 赵铮
郑文祺 蔡易楠

(74) 专利代理机构 哈尔滨市阳光惠远知识产权代理有限公司 23211

专利代理师 张宏威

(51) Int. Cl.

H04W 4/029 (2018.01)

H04W 4/33 (2018.01)

H04W 4/02 (2018.01)

权利要求书2页 说明书9页 附图6页

(54) 发明名称

一种基于可解释的深度学习的5G NR室内定位方法及系统

(57) 摘要

一种基于可解释的深度学习的5G NR室内定位方法及系统,涉及计算机技术领域,特别涉及计算机中的深度学习技术领域。解决现有室内指纹定位方法定位精度与效率较低、难以部署以及成本较高的问题。方法为:采用CSI与序列类型数据转换模块对三维的CSI数据转换为二维的序列类型数据;采用单信道内的子载波的建模模块对所述二维的序列类型数据进行处理,获得输出数据;采用多信道内的子载波建模模块对所述输出数据进行处理,获得最后的输出数据;采用位置映射模块对所述最后的输出数据进行位置定位,获得映射位置。本发明适用于计算机中的基于可解释的深度学习的5G NR室内定位方法。



1. 一种基于可解释的深度学习的5G NR室内定位方法,其特征在于,所述方法为:

S1、采用CSI与序列类型数据转换模块对三维的CSI数据转换为二维的序列类型数据;

S2、采用单信道内的子载波的建模模块对所述二维的序列类型数据进行处理,获得输出数据;

S3、采用多信道内的子载波建模模块对所述输出数据进行处理,获得最后的输出数据;

S4、采用位置映射模块对所述最后的输出数据进行位置定位,获得映射位置。

2. 根据权利要求1所述的一种基于可解释的深度学习的5G NR室内定位方法,其特征在于,所述步骤S1中CSI与序列类型数据转换模块的处理流程为:

S11、采用重塑操作Re对三维的CSI数据进行重塑操作,获得二维数据 H_{in} ;

S12、将所述二维数据 H_{in} 进行线性映射,获得二维的序列类型数据 H_{in} 。

3. 根据权利要求2所述的一种基于可解释的深度学习的5G NR室内定位方法,其特征在于,所述三维的CSI数据表示为:

$$H \in \mathbb{R}^{C \times W \times L};$$

所述重塑操作Re表示为:

$$H_{in} \in \mathbb{R}^{\left(\frac{W}{P_w} \times \frac{L}{P_l}\right) \times (C \times P_w \times P_l)} = \text{Re}\left(H \in \mathbb{R}^{C \times W \times L}\right);$$

其中,C为输入通道的数量,W为输入宽度,L为输入长度, P_w 为图像块的宽度, P_l 为图像块的长度。

4. 根据权利要求1所述的一种基于可解释的深度学习的5GNR室内定位方法,其特征在于,所述步骤S2中单信道内的子载波的建模模块的处理流程为:

S21、定义可学习的参数矩阵W;

S22、采用LayerNorm将所述二维的序列类型数据 H_{in} 进行层归一化处理,获得处理后的二维的序列类型数据;

S23、将所述处理后的二维的序列类型数据输入到所述参数矩阵W的参数为 W_1 的全连接层中,获得 W_1 的全连接层输出数据;

S24、将所述 W_1 的全连接层输出数据输入到Drop层中进行正则化处理,获得正则化处理数据;

S25、将所述正则化处理数据输入到所述参数矩阵W的参数为 W_1 的全连接层中,获得 W_2 的全连接层输出数据;

S26、将所述 W_2 的全连接层输出数据与所述二维的序列类型数据 H_{in} 相加,获得最后的输出数据 X' 。

5. 根据权利要求4所述的一种基于可解释的深度学习的5G NR室内定位方法,其特征在于,所述可学习的参数矩阵W表示为:

$$W = [w_1, w_2, w_3, w_4]^T。$$

6. 根据权利要求4所述的一种基于可解释的深度学习的5G NR室内定位方法,其特征在于,所述步骤S3中多信道内的子载波建模模块的处理流程为:

S31、采用LayerNorm对所述输出数据 X' 进行层归一化处理,获得处理后的数据 X' ;

S32、将所述处理后的数据 X' 输入到所述参数矩阵W的参数为 W_3 的全连接层中,获得 W_3 的

全连接层输出数据;

S33、将所述 W_3 的全连接层输出数据输入到Drop层中进行正则化处理,获得正则化处理数据;

S34、将所述正则化处理数据输入到所述参数矩阵 W 的参数为 W_4 的全连接层中,获得 W_4 的全连接层输出数据;

S35、将所述 W_2 的全连接层输出数据与所述二维的序列类型数据 H_{in} 相加,获得最后的输出数据 X ”。

7.根据权利要求1所述的一种基于可解释的深度学习的5G NR室内定位方法,其特征在于,所述步骤S4的位置映射模块采用基于深度学习的映射方法实现。

8.一种基于可解释的深度学习的5G NR室内定位系统,其特征在于,所述系统为:

用于采用CSI与序列类型数据转换模块对三维的CSI数据转换为二维的序列类型数据的存储装置;

用于采用单信道内的子载波的建模模块对所述二维的序列类型数据进行处理,获得输出数据的存储装置;

用于采用多信道内的子载波建模模块对所述输出数据进行处理,获得最后的输出数据的存储装置;

用于采用位置映射模块对所述最后的输出数据进行位置定位,获得映射位置的存储装置。

9.一种计算机可读存储介质,其特征在于,该计算机可读存储介质上存储有计算机程序,该计算机程序被处理器运行时执行权利要求1-7任意一项所述的一种基于可解释的深度学习的5G NR室内定位方法。

10.一种计算机设备,其特征在于:该设备包括存储器和处理器,所述存储器中存储有计算机程序,当所述处理器运行所述存储器存储的计算机程序时,所述处理器执行权利要求1-7任意一项所述的一种基于可解释的深度学习的5G NR室内定位方法。

一种基于可解释的深度学习的5G NR室内定位方法及系统

技术领域

[0001] 本发明涉及计算机技术领域,特别涉及计算机中的深度学习技术领域。

背景技术

[0002] 基于信道状态信息(Channel State Information,CSI)的室内指纹定位在室内导航、人员追踪等相关领域得到了广泛的应用。5G利用其多进多出(multiple input multiple output,MIMO)技术、高频段和大规模天线阵列,为基于CSI的指纹定位带来了新的特点和挑战。

[0003] 目前,在工程实践中有所应用的室内指纹定位方法主要可分作以下两类:

[0004] (1)基于机器学习的方法,如2020年12月29日公开的专利文献:CN112153569A,公开了一种基于室内指纹定位的优化方法,该方法采用低分辨率无线CSI或接收信号强度指示,存在不能有效利用5G CSI提供的更高的信息丰富度和特征分辨率的问题。随着高分辨率5GCSI的出现,基于深度学习的方法正逐渐取代基于机器学习的方法。

[0005] (2)基于深度学习的方法,如2021年06月25日公开的专利文献:CN113038595A,公开了一种基于PQ和CNN的快速指纹定位方法,该方法采用基于CNN的快速定位算法得到的输出即为待定位向量的二维坐标,虽然建模范围的扩大和建模有效性的提高带来了更高的定位精度,但这些尖端技术的引入也带来了实际指纹定位中参数成本和计算成本的挑战。

发明内容

[0006] 本发明解决现有室内指纹定位方法定位精度与效率较低、难以部署以及成本较高的问题。

[0007] 为实现上述目的,本发明提供了如下方案:

[0008] 本发明提供一种基于可解释的深度学习的5G NR室内定位方法,所述方法为:

[0009] S1、采用CSI与序列类型数据转换模块对三维的CSI数据转换为二维的序列类型数据;

[0010] S2、采用单信道内的子载波的建模模块对所述二维的序列类型数据进行处理,获得输出数据;

[0011] S3、采用多信道内的子载波建模模块对所述输出数据进行处理,获得最后的输出数据;

[0012] S4、采用位置映射模块对所述最后的输出数据进行位置定位,获得映射位置。

[0013] 进一步,还有一种优选实施例,上述步骤S1中CSI与序列类型数据转换模块的处理流程为:

[0014] S11、采用重塑操作Re对三维的CSI数据进行重塑操作,获得二维数据 H_{in} ;

[0015] S12、将所述二维数据 H_{in} 进行线性映射,获得二维的序列类型数据 H_{in} 。

[0016] 进一步,还有一种优选实施例,上述三维的CSI数据表示为:

[0017] $H \in \mathbb{R}^{C \times W \times L}$;

[0018] 上述重塑操作Re表示为：

$$[0019] \quad H_{in} \in \mathbb{R}^{\left(\frac{W}{P_w} \times \frac{L}{P_l}\right) \times (C \times P_w \times P_l)} = \text{Re}\left(H \in \mathbb{R}^{C \times W \times L}\right);$$

[0020] 其中,C为输入通道的数量,W为输入宽度,L为输入长度, P_w 为图像块的宽度, P_l 为图像块的长度。

[0021] 进一步,还有一种优选实施例,上述步骤S2中单信道内的子载波的建模模块的处理流程为:

[0022] S21、定义可学习的参数矩阵W;

[0023] S22、采用LayerNorm将所述二维的序列类型数据 H_{in} 进行层归一化处理,获得处理后的二维的序列类型数据;

[0024] S23、将所述处理后的二维的序列类型数据输入到所述参数矩阵W的参数为 W_1 的全连接层中,获得 W_1 的全连接层输出数据;

[0025] S24、将所述 W_1 的全连接层输出数据输入到Drop层中进行正则化处理,获得正则化处理数据;

[0026] S25、将所述正则化处理数据输入到所述参数矩阵W的参数为 W_1 的全连接层中,获得 W_2 的全连接层输出数据;

[0027] S26、将所述 W_2 的全连接层输出数据与所述二维的序列类型数据 H_{in} 相加,获得最后的输出数据 X' 。

[0028] 进一步,还有一种优选实施例,上述可学习的参数矩阵W表示为:

$$[0029] \quad W = [w_1, w_2, w_3, w_4]^T。$$

[0030] 进一步,还有一种优选实施例,上述步骤S3中多信道内的子载波建模模块的处理流程为:

[0031] S31、采用LayerNorm对所述输出数据 X' 进行层归一化处理,获得处理后的数据 X'' ;

[0032] S32、将所述处理后的数据 X'' 输入到所述参数矩阵W的参数为 W_3 的全连接层中,获得 W_3 的全连接层输出数据;

[0033] S33、将所述 W_3 的全连接层输出数据输入到Drop层中进行正则化处理,获得正则化处理数据;

[0034] S34、将所述正则化处理数据输入到所述参数矩阵W的参数为 W_4 的全连接层中,获得 W_4 的全连接层输出数据;

[0035] S35、将所述 W_4 的全连接层输出数据与所述二维的序列类型数据 H_{in} 相加,获得最后的输出数据 X'' 。

[0036] 进一步,还有一种优选实施例,上述步骤S4的位置映射模块采用基于深度学习的映射方法实现。

[0037] 本发明所述的一种基于可解释的深度学习的5G NR室内定位方法可以全部采用计算机软件实现,因此,对应的,本发明还提供一种基于可解释的深度学习的5G NR室内定位系统,所述系统为:

[0038] 用于采用CSI与序列类型数据转换模块对三维的CSI数据转换为二维的序列类型数据的存储装置;

[0039] 用于采用单信道内的子载波的建模模块对所述二维的序列类型数据进行处理,获得输出数据的存储装置;

[0040] 用于采用多信道内的子载波建模模块对所述输出数据进行处理,获得最后的输出数据的存储装置;

[0041] 用于采用位置映射模块对所述最后的输出数据进行位置定位,获得映射位置的存储装置。

[0042] 本发明还提供一种计算机可读存储介质,该计算机可读存储介质上存储有计算机程序,该计算机程序被处理器运行时执行上述任意一项所述的一种基于可解释的深度学习的5G NR室内定位方法。

[0043] 本发明还提供一种计算机设备,该设备包括存储器和处理器,所述存储器中存储有计算机程序,当所述处理器运行所述存储器存储的计算机程序时,所述处理器执行上述任意一项所述的一种基于可解释的深度学习的5G NR室内定位方法。

[0044] 本发明的有益效果为:

[0045] 本发明提供一种基于可解释的深度学习的5G NR室内定位方法,采用CSI与序列类型数据转换模块将单个和多个基站的建模数据从复杂的三维的CSI数据转换为二维的序列类型数据,使得CSI数据能够适应注意力机制的输入,便于后续注意力的计算过程。同时采用单信道内的子载波的建模模块和多信道内的子载波建模模块,这两个模块通过使用不同的全连接层进行建模可以完全模拟单个和多个基站的子载波数据,通过这两个模块可以提取到丰富的特征数据,能够有效地提高室内定位方法的精度以及效率。最后采用位置映射模块,该模块通过将得到的CSI特征表示映射到坐标的定位器组成的线性层,以获得位置推断。该模块可以将得到的数据输出为更加直观的位置数据表示,便于后续的观察与对比。

[0046] 本发明适用于计算机中的基于可解释的深度学习的5G NR室内定位方法。

附图说明

[0047] 图1是实施方式一所述的一种基于可解释的深度学习的5G NR室内定位方法的流程图;

[0048] 图2是实施方式二所述的CSI与序列类型数据转换模块的处理流程图;

[0049] 图3是实施方式四所述的单信道内的子载波的建模模块的处理流程图;

[0050] 图4是实施方式六所述的多信道内的子载波建模模块的处理流程图;

[0051] 图5(a)是实施方式十一所述的在SNR20数据集下不同方法的结果对比图;

[0052] 图5(b)是实施方式十一所述的在SNR50数据集下不同方法的结果对比图。

[0053] 图6为实施方式十一所述的基于可解释的深度学习的5G NR室内定位方法与现有定位方法的误差大小对比图。

[0054] 其中,SNR为信噪比。

具体实施方式

[0055] 下面结合附图和实施例对本发明的具体实施方式作进一步详细说明。以下实施例将有助于本领域的技术人员进一步理解本发明,但不以任何形式限制本发明。应当指出的是,对本领域的普通技术人员来说,在不脱离本发明构思的前提下,还可以做出若干变化和

改进,这些都属于本发明的保护范围。

[0056] 实施方式一.参见图1说明本实施方式,本实施方式提供一种基于可解释的深度学习的5G NR室内定位方法,所述方法为:

[0057] S1、采用CSI与序列类型数据转换模块对三维的CSI数据转换为二维的序列类型数据;

[0058] S2、采用单信道内的子载波的建模模块对所述二维的序列类型数据进行处理,获得输出数据;

[0059] S3、采用多信道内的子载波建模模块对所述输出数据进行处理,获得最后的输出数据;

[0060] S4、采用位置映射模块对所述最后的输出数据进行位置定位,获得映射位置。

[0061] 本实施方式在实际应用时,包括CSI与序列类型数据转换模块、单信道内的子载波的建模模块、多信道内的子载波建模模块以及位置映射模块。首先通过由用户设备对接收到的信号执行频分复用解调和时间偏移校正来获得接收到的资源网格rxGrid,rxGrid被定义为接收到的资源网格,而已知导频被定义为refGrid,每个天线可以表示为k维列向量,即,可以表示为:

[0062] $H_{\text{raw}} = (\text{rxGrid})_{k \times 1} / (\text{refGrid})_{k \times 1}$;

[0063] 其中,k表示子载波的数量, H_{raw} 表示信道脉冲响应。

[0064] 单个天线的子载波可以表示为 $h_i \in \mathbb{R}^{1 \times k}$,而具有多输入多输出的5G基站的总体子载波可以表示为 $H' \in \mathbb{R}^{n \times k}$,其中n表示天线的数量。在典型的室内定位任务中,会涉及多个基站,所以总体CSI数据可以表示为 $H \in \mathbb{R}^{b \times n \times k}$,其中b表示基站的数量。

[0065] 基于指纹的室内定位总体框架由两个阶段组成,分别是离线和在线,也就是训练和测试。该框架的目标是通过使用训练数据集 $C_{\text{train}} = \{(csi_1, loc_1), (csi_2, loc_2), \dots, (csi_n, loc_n)\}$ 使得可以在测试数据 $C_{\text{query}} = \{(csi_{n+1}, loc_{n+1}), (csi_{n+2}, loc_{n+2}), \dots, (csi_m, loc_m)\}$ 上实现最佳的定位性能,从而学习具有良好泛化性能的映射方法。其中训练数据和测试数据都是由一组成对的数据组成的,在一对数据中, csi_i 表示CSI数据, loc_i 表示位置数据。

[0066] 在训练阶段,利用基于深度学习的映射方法来最小化损失函数,其中预测位置由映射方法的输出表示,并且实际位置表示为地面实况。

[0067] 本实施方式提供一种基于可解释的深度学习的5G NR室内定位方法,采用CSI与序列类型数据转换模块将单个和多个基站的建模数据从复杂的三维的CSI数据转换为二维的序列类型数据,使得CSI数据能够适应注意力机制的输入,便于后续注意力的计算过程。同时采用单信道内的子载波的建模模块和多信道内的子载波建模模块,这两个模块通过使用不同的全连接层进行建模可以完全模拟单个和多个基站的子载波数据,通过这两个模块可以提取到丰富的特征数据,能够有效地提高室内定位方法的精度以及效率。最后采用位置映射模块,该模块通过将得到的CSI特征表示映射到坐标的定位器组成的线性层,以获得位置推断。该模块可以将得到的数据输出为更加直观的位置数据表示,便于后续的观察与对比。

[0068] 实施方式二.参见图2说明本实施方式,本实施方式是对实施方式一所述的一种基于可解释的深度学习的5G NR室内定位方法中步骤S1的CSI与序列类型数据转换模块的处

理流程作举例说明,所述CSI与序列类型数据转换模块的处理流程为:

[0069] S11、采用重塑操作Re对三维的CSI数据进行重塑操作,获得二维数据 H_{in} ;

[0070] S12、将所述二维数据 H_{in} 进行线性映射,获得二维的序列类型数据 H_{in} 。

[0071] 本实施方式在实际应用时,如图2所示,对于给定的CSI输入三维数据 $H \in \mathbb{R}^{C \times W \times L}$,利用重塑操作Re进行重塑操作,得到二维数据 H_{in} ;

[0072] 例如考虑2个基站,每个基站具有2个天线,每个天线具有4个子载波,这两个CSI矩阵如下所示:

$$[0073] \quad H_{0,:} = \begin{bmatrix} x_{11} & x_{12} & x_{13} & x_{14} \\ x_{21} & x_{22} & x_{23} & x_{24} \end{bmatrix}$$

$$[0074] \quad H_{1,:} = \begin{bmatrix} y_{11} & y_{12} & y_{13} & y_{14} \\ y_{21} & y_{22} & y_{23} & y_{24} \end{bmatrix};$$

[0075] 再重新排列之后,可以获得矩阵 H_{in} 如下所示:

$$[0076] \quad H_{in} = \begin{bmatrix} x_{11} & y_{11} & x_{12} & y_{12} \\ x_{13} & y_{13} & x_{24} & y_{14} \\ x_{21} & y_{21} & x_{22} & y_{22} \\ x_{23} & y_{23} & x_{24} & y_{24} \end{bmatrix};$$

[0077] 在垂直方向上,元素值都来自同一基站的子载波特征表示。在水平方向,组合来自来自不同基站的不同贴片的聚合。

[0078] 对于得到的输出矩阵 H_{in} 使用线性映射,得到最后的输出数据 H_{in} ;使用线性映射以增加矩阵的特征丰富度,便于后续的建模过程。

[0079] 实施方式三.本实施方式是对实施方式二所述的一种基于可解释的深度学习的5GNR室内定位方法中的三维的CSI数据和重塑操作Re作举例说明,所述三维的CSI数据表示为:

$$[0080] \quad H \in \mathbb{R}^{C \times W \times L};$$

[0081] 所述重塑操作Re表示为:

$$[0082] \quad H_{in} \in \mathbb{R}^{\left(\frac{W}{P_w} \times \frac{L}{P_l}\right) \times (C \times P_w \times P_l)} = \text{Re}\left(H \in \mathbb{R}^{C \times W \times L}\right);$$

[0083] 其中,C为输入通道的数量,W为输入宽度,L为输入长度, P_w 为图像块的宽度, P_l 为图像块的长度。

[0084] 本实施方式在实际应用时,给定一个CSI输入数据 $H \in \mathbb{R}^{C \times W \times L}$,其中C表示输入通道的数量,W和L分别表示输入宽度和长度。为了获得S个非重叠子载波片的期望输入序列类型数据 H_{in} ,定义一个重塑操作Re。

[0085] 实施方式四.参见图3说明本实施方式,本实施方式是对实施方式一所述的一种基于可解释的深度学习的5G NR室内定位方法中步骤S2的单信道内的子载波的建模模块的处理流程作举例说明,所述单信道内的子载波的建模模块的处理流程为:

[0086] S21、定义可学习的参数矩阵W;

[0087] S22、采用LayerNorm将所述二维的序列类型数据 H_{in} 进行层归一化处理,获得处理

后的二维的序列类型数据;

[0088] S23、将所述处理后的二维的序列类型数据输入到所述参数矩阵W的参数为 W_1 的全连接层中,获得 W_1 的全连接层输出数据;

[0089] S24、将所述 W_1 的全连接层输出数据输入到Drop层中进行正则化处理,获得正则化处理数据;

[0090] S25、将所述正则化处理数据输入到所述参数矩阵W的参数为 W_1 的全连接层中,获得 W_2 的全连接层输出数据;

[0091] S26、将所述 W_2 的全连接层输出数据与所述二维的序列类型数据 H_{in} 相加,获得最后的输出数据 X' 。

[0092] 本实施方式在实际应用时,为了充分模拟单个基站的子载波,考虑到 H_{in} 的特点,需要对其列进行建模。具体建模过程如下:

[0093] 首先定义一个可学习的参数矩阵W,其形式为:

[0094] $W = [w_1, w_2, w_3, w_4]^T$;

[0095] 来自 $H_{0,:}$ 的子载波形式如下式:

[0096] $x_{sum1} = x_{11} + x_{13} + x_{21} + x_{23}$

[0097] $x_{sum2} = x_{12} + x_{14} + x_{22} + x_{24}$;

[0098] 来自 $H_{1,:}$ 的子载波形式如下式:

[0099] $y_{sum1} = y_{11} + y_{13} + y_{21} + y_{23}$

[0100] $y_{sum2} = y_{12} + y_{14} + y_{22} + y_{24}$;

[0101] 矩阵乘法 WH_{in} 的输出 H_{out} 如下式:

[0102]
$$\begin{bmatrix} w_1(x_{sum1}) & w_1(y_{sum1}) & w_1(x_{sum2}) & w_1(y_{sum2}) \\ w_2(x_{sum1}) & w_2(y_{sum1}) & w_2(x_{sum2}) & w_2(y_{sum2}) \\ w_3(x_{sum1}) & w_3(y_{sum1}) & w_3(x_{sum2}) & w_3(y_{sum2}) \\ w_4(x_{sum1}) & w_4(y_{sum1}) & w_4(x_{sum2}) & w_4(y_{sum2}) \end{bmatrix};$$

[0103] 在实际的实现过程中,通过深度学习中具有一维卷积的全连接层来实现,具体过程如下式所示:

[0104] $X' = X_{:,i} + W_2(\text{Drop}(\sigma(W_1(\text{LayerNorm}(X_{:,i}))))))$

[0105] for $i = 1, 2, \dots, C$;

[0106] 其中 σ 表示元素方式为非线性,使用高斯误差线性单元(GELU)激活函数进行激活,LayerNorm表示层归一化, W_1 和 W_2 分别表示所使用的全连接层的参数,Drop表示为了防止过拟合的一种正则化操作。

[0107] 实施方式五.本实施方式是对实施方式四所述的一种基于可解释的深度学习的5G NR室内定位方法中的可学习的参数矩阵W作举例说明,所述可学习的参数矩阵W表示为:

[0108] $W = [w_1, w_2, w_3, w_4]^T$ 。

[0109] 实施方式六.参见图4说明本实施方式,本实施方式是对实施方式四所述的一种基于可解释的深度学习的5G NR室内定位方法中步骤S3的多信道内的子载波建模模块的处理流程作举例说明,所述多信道内的子载波建模模块的处理流程为:

[0110] S31、采用LayerNorm对所述输出数据 X' 进行层归一化处理,获得处理后的数据 X' ;

[0111] S32、将所述处理后的数据 X' 输入到所述参数矩阵 W 的参数为 W_3 的全连接层中,获得 W_3 的全连接层输出数据;

[0112] S33、将所述 W_3 的全连接层输出数据输入到Drop层中进行正则化处理,获得正则化处理数据;

[0113] S34、将所述正则化处理数据输入到所述参数矩阵 W 的参数为 W_4 的全连接层中,获得 W_4 的全连接层输出数据;

[0114] S35、将所述 W_2 的全连接层输出数据与所述二维的序列类型数据 H_{in} 相加,获得最后的输出数据 X'' 。

[0115] 本实施方式在实际应用时,该模块的目的是对不同的信道之间的子载波进行建模。具体方法如下:

[0116] 首先定义可学习矩阵 K 和 $s(xy)$,具体公式如下所示:

[0117] $K = [k_1, k_2, k_3, k_4]$

[0118] $s(xy) = x_{sum1} + y_{sum1} + x_{sum2} + y_{sum2}$;

[0119] 从 H_{out} K 获得的输出 H'_{out} 的公式如下所示:

[0120]
$$\begin{bmatrix} k_1 w_1 s(xy) & k_2 w_1 s(xy) & k_3 w_1 s(xy) & k_4 w_1 s(xy) \\ k_1 w_2 s(xy) & k_2 w_2 s(xy) & k_3 w_2 s(xy) & k_4 w_2 s(xy) \\ k_1 w_3 s(xy) & k_2 w_3 s(xy) & k_3 w_3 s(xy) & k_4 w_3 s(xy) \\ k_1 w_4 s(xy) & k_2 w_4 s(xy) & k_3 w_4 s(xy) & k_4 w_4 s(xy) \end{bmatrix},$$

[0121] 在实际实现过程中,通过线性层来进行实现,将该过程中使用的可训练参数集定义为 W_3 和 W_4 ,具体过程如公式所示:

[0122] $X'' = X'_{j,:} + W_4 (\text{Drop}(\sigma(W_3 (\text{LayerNorm}(X')_{j,:}))))$

[0123] for $j=1, 2, \dots, S$;

[0124] 其中 W_3 和 W_4 分别表示两个所使用的线性层的参数, X' 是单信道(单基站)内的子载波的建模模块得到的输出,所获得的矩阵 X'' 的每一个单独的元素 $k_i w_i s(xy)$ 包含整个CSI数据中的各种元素,这意味着来自不同基站的CSI的子载波经过建模后具有交互功能,可以获得具有丰富特征的特征矩阵作为位置映射模块的输入。

[0125] 实施方式七.本实施方式是对实施方式一所述的一种基于可解释的深度学习的5G NR室内定位方法中步骤S4的位置映射模块作举例说明,所述步骤S4的位置映射模块采用基于深度学习的映射方法实现。

[0126] 本实施方式在实际应用时,通过位置映射模块可以将获得的特征映射到三维坐标中,从而进行位置映射。具体描述公式如下式所示:

[0127] $(X, Y, Z) = \text{Mapping}(\text{Mean}(\text{LayerNorm}(X)))$ 。

[0128] 实施方式八.本实施方式提供一种基于可解释的深度学习的5G NR室内定位系统,所述系统为:

[0129] 用于采用CSI与序列类型数据转换模块对三维的CSI数据转换为二维的序列类型数据的存储装置;

[0130] 用于采用单信道内的子载波的建模模块对所述二维的序列类型数据进行处理,获得输出数据的存储装置;

[0131] 用于采用多信道内的子载波建模模块对所述输出数据进行处理,获得最后的输出数据的存储装置;

[0132] 用于采用位置映射模块对所述最后的输出数据进行位置定位,获得映射位置的存储装置。

[0133] 实施方式九.本实施方式提供一种计算机可读存储介质,该计算机可读存储介质上存储有计算机程序,该计算机程序被处理器运行时执行实施方式一至实施方式七任意一项所述的一种基于可解释的深度学习的5G NR室内定位方法。

[0134] 实施方式十.本实施方式提供一种计算机设备,该设备包括存储器和处理器,所述存储器中存储有计算机程序,当所述处理器运行所述存储器存储的计算机程序时,所述处理器执行实施方式一至实施方式七任意一项所述的一种基于可解释的深度学习的5G NR室内定位方法。

[0135] 实施方式十一.参见图5说明本实施方式,本实施方式是对实施方式一至实施方式七任意一项所述的一种基于可解释的深度学习的5G NR室内定位方法作验证说明,

[0136] 采用北京中国科学院新实验楼的室内空间收集的三个真实的5G场景数据集作为实验数据,整个室内空间的大小为宽20米、长60米、高4米,是一个适合工厂和博物馆等应用的大房间。为了获得CSI,在3.5G赫兹下使用集成的感测和通信部署五个5G基站,带宽为100M赫兹,功率为40瓦特。这些基站安装在塑料支架上,在地面以上2.4米的高度,并在模拟过程中引入了0.1米的随机浮动高度,以防止共面性。用户设备充当接收器,并且被放置在离地面1.2米的高度处的标记的小型汽车上,模拟在1.8米的高度处拿着移动的电话的人。所获得的数据集包括4816个定位样本,其中三个数据集对应于SNR信噪比10、SNR20和SNR50处的CSI的不同表示。为了将数据集分为训练集、验证集和测试集,根据不同的信噪比使用近似的6:2:2的比例,分别得到2888、964和964个样本。单个CSI矩阵的大小为 $5 \times 16 \times 193$,表示存在5个基站,每个基站具有16个天线,每个天线具有193个子载波。

[0137] 初始学习率为 1×10^{-4} ,在100个训练周期之后,学习率每25个周期减半,训练轮次epoch为300,批大小batch_size为16。

[0138] 实验过程中采用的两种评价标准分别为均方根误差(Root Mean Square Error, RMSE),平均绝对误差(MeanAbsolute Error,MAE):

$$[0139] \quad RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}}, MAE = \frac{\sum_{i=1}^N |y_i - \hat{y}_i|}{N}$$

[0140] 其中 y_i 表示预测值, \hat{y}_i 表示真实值。

[0141] 本实施方式的对比方法有:Clnet方法:Complex input lightweight neural network designed for massive MIMO CSI feedback(设计用于大规模MIMO CSI反馈的复杂输入轻量级神经网络)、KNN方法:Deep learning for massive MIMO CSI feedback(大规模MIMO CSI反馈的深度学习)、MIMOnet方法:MaMIMO CSI-Based Positioning using CNNs:Peeking inside the Black Box(基于CNN的MaMIMO csi定位:窥视黑匣子内部)、Hiloc方法:Hybrid Indoor Localization via Enhanced 5G NR CSI(基于增强5G NR CSI的混合室内定位)、SVM方法:Toward 5G NR High-Precision Indoor Positioning via Channel Frequency Response:A New Paradigm and Dataset Generation Method(基于信

道频率响应的5GNR高精度室内定位:一种新的范式和数据集生成方法)和MPRI方法:Toward 5G NR High-Precision Indoor Positioning via Channel Frequency Response:ANew Paradigm andDataset Generation Method(基于信道频率响应的5G NR高精度室内定位:一种新的范式和数据集生成方法)。

[0142] 将上述方法与本实施方式所述的基于可解释的深度学习的5G NR室内定位方法的误差大小进行对比,如图6所示,从图6中可以看出,本实施方式所述的基于可解释的深度学习5G NR室内定位方法相比于CLnet、KNN、CSInet、MIMOnet、Hilloc、SVM、MPRI方法,大幅降低了误差大小,有效提高了预测精度。

[0143] 同时将上述方法与本实施方式所述的基于可解释的深度学习5G NR室内定位方法的累积分布函数分布进行对比,如图5(a)和图5(b)所示,可以看出,本实施方式所述的基于可解释的深度学习5G NR室内定位方法相比于CLnet、KNN、CSInet、MIMOnet、Hilloc、SVM、MPRI方法定位精度大幅度提高。

[0144] 此外,术语“第一”、“第二”仅用于描述目的,而不能理解为指示或暗示相对重要性或者隐含指明所指示的技术特征的数量。由此,限定有“第一”、“第二”的特征可以明示或者隐含地包括至少一个该特征。在本发明的描述中,“多个”的含义是至少两个,例如两个,三个等,除非另有明确具体的限定。

[0145] 在本说明书的描述中,参考术语“一个实施例”、“一些实施例”、“示例”、“具体示例”、或“一些示例”等的描述意指结合该实施例或示例描述的具体特征、结构、材料或者特点包含于本发明的至少一个实施例或示例中。在本说明书中,对上述术语的示意性表述不必针对的是相同的实施例或示例。而且,描述的具体特征、结构、材料或者特点可以在任一个或多个实施例或示例中以合适的方式结合。此外,在不相互矛盾的情况下,本领域的技术人员可以将本说明书中描述的不同实施例或示例以及不同实施例或示例的特征进行结合和组合。

[0146] 以上所述仅为本发明的实施例而已,并不限制于本发明,对于本领域的技术人员来说,本发明可以有各种更改和变化。凡在本发明的精神和原则之内,所做的任何修改、等同替换、改进等,均应包含在本发明的权利要求范围之内。

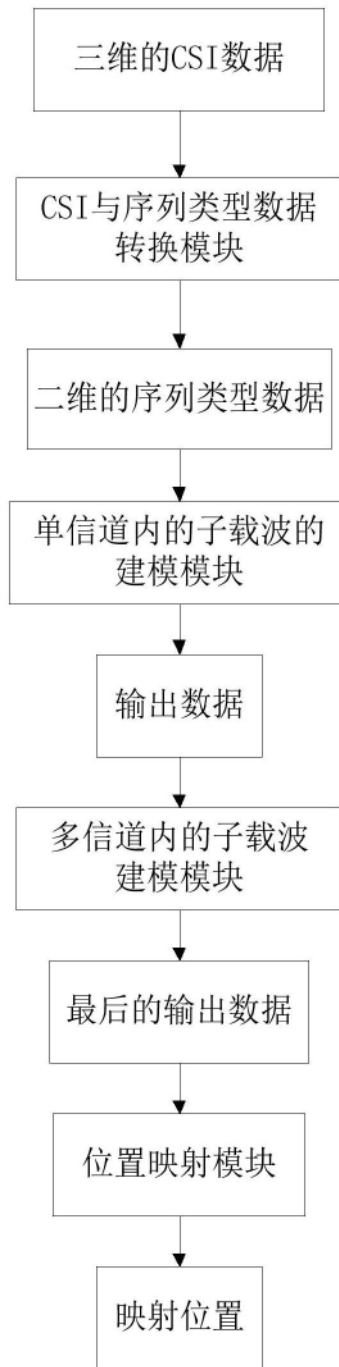


图1

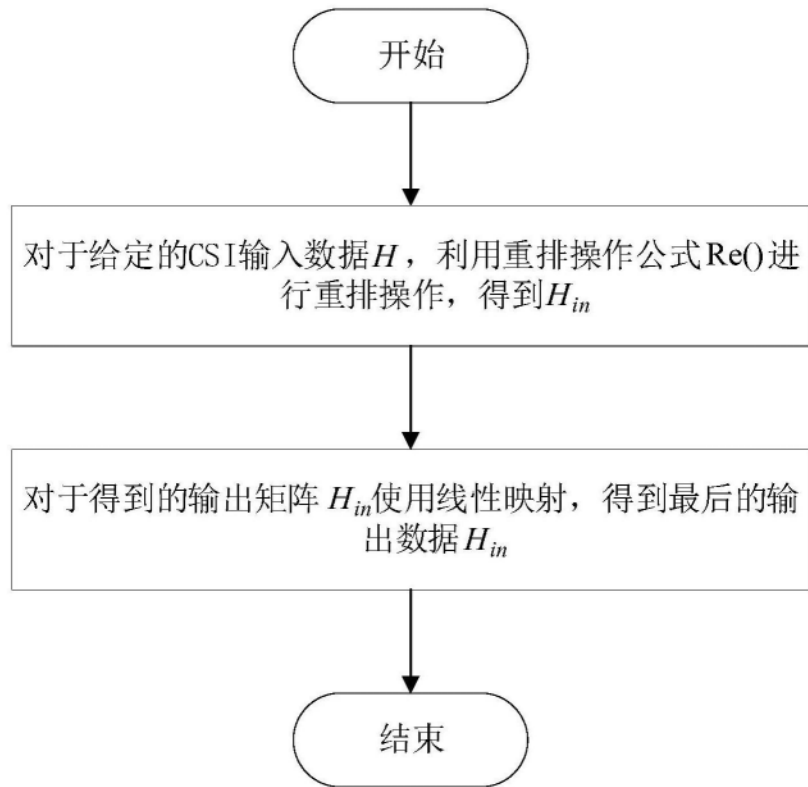


图2

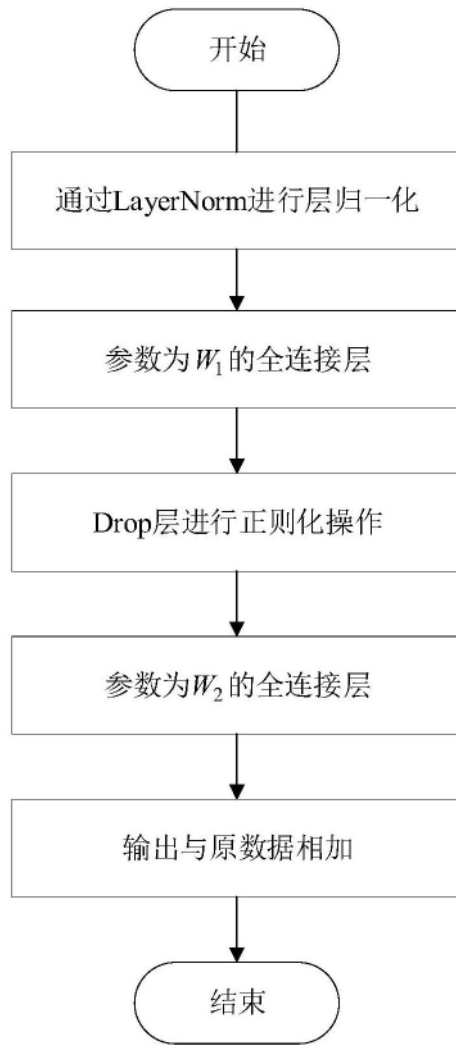


图3

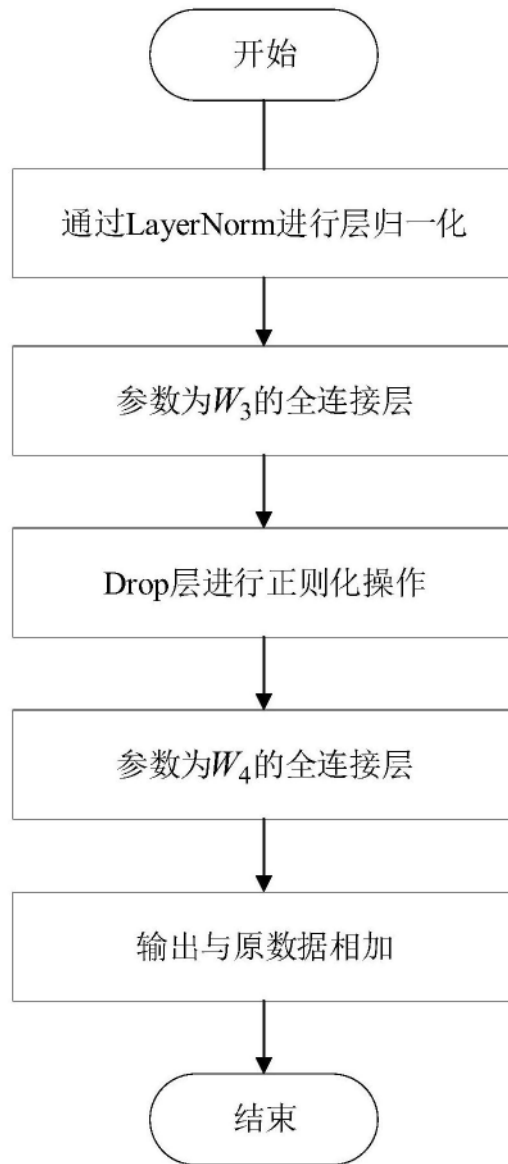


图4




图5(a)




图5(b)

方法	参数	SNR20		SNR50		Mean	
		MAE	RMSE	MAE	RMSE	MAE	RMSE
CLnet 方法 32/16/8/4	2.41M/4.80M/ 9.56M/19.10M	6.76/5.10/ 6.12/5.92	8.25/6.45/ 7.49/7.31	5.90/5.45/ 4.14/5.26	7.36/6.83/ 5.15/6.71	6.28/5.29/ 5.25/5.76	7.77/6.62/ 6.50/7.26
KNN 方法 5/25/50/100	-	5.04/6.89/ 7.90/9.02	6.95/8.49/ 9.45/10.61	5.06/6.91/ 7.95/9.07	6.89/8.49/ 9.53/10.67	5.06/6.90/ 7.93/9.05	6.92/8.49/ 9.50/10.64
CSInet 方法	12.79M	3.46	4.58	3.45	4.96	3.56	4.89
MIMOnet 方法	4.73M	6.07	7.27	5.52	6.46	5.66	6.73
Hiloc 方法	23.10M	3.28	4.11	3.94	4.67	3.98	4.78
SVM 方法	-	13.70	15.93	13.55	15.40	13.70	15.74
MPRI 方法	2.50M	2.65	3.18	2.52	3.09	2.73	3.31
本发明的方法	1.25M	2.07	2.71	2.03	2.67	2.05	2.69

图6