

DOI: 10.13382/j.jemi.B2003113

基于变分自编码器的 WLAN 定位方法

米伟娟 李娜

(河北传媒学院 信息技术与文化管理学院 石家庄 051430)

摘要:基于无线局域网(WLAN)的定位是当前室内定位领域的主流技术之一。提出一种基于变分自编码器的 WLAN 定位方法,具备定位通路和接收信号强度(RSS)信号指纹重构通路,使得该方法既具备定位能力,也具备重新生成 RSS 信号指纹或指纹地图的能力。利用开源的数据集进行验证,证明了该方法在定位通路上,相比稀疏重构定位方法和传统 k 最邻近(kNN)定位方法,误差分别下降了约 14% 和 24%;能够对指纹地图(RM)进行重新生成,利用重构的 RM 进行定位,相比于利用稀疏重构生成的 RM 定位误差下降了约 11%。

关键词:变分自编码器;WLAN 定位;神经网络

中图分类号: TP391;TN96 **文献标识码:** A **国家标准学科分类代码:** 510.51040

Variational auto encoder based WLAN positioning

Mi Weijuan Li Na

(Information Technology and Cultural Management Institute, Hebei Institute of Communication, Shijiazhuang 051430, China)

Abstract: Wireless local area network (WLAN) based positioning is one of the main stream techniques for indoor positioning. In this paper, a WLAN based method is proposed based on a variational auto encoder (VAE), which contains a positioning path and a reconstruction path. This structure has enabled the ability to position along with reconstruction of RSS radio map (RM). The proposed method is validated by open-sourced dataset, which shows that the proposed method can increase the positioning accuracy by about 14% and 24% respectively compared to the compressive sensing (CS) based method and the traditional kNN method in the positioning path. Moreover, from the reconstructed RM, the method can have accuracy enhancement of about 11% in positioning than that from the CS reconstructed RM.

Keywords: variational auto encoder; WLAN based positioning; neural network

0 引言

在室内环境中,由于卫星导航无线信号无法穿透到室内,或者存在严重的多径效应,导致卫星导航定位方式在室内环境中无法正常工作。因此,在室内环境中进行定位,需要依赖其它技术。当前主要的室内定位技术包含,基于超宽带 (ultra-wide band, UWB) 的室内定位技术^[1-2]、基于低功耗蓝牙 (low energy bluetooth, BLE) 的定位^[3-4]、基于惯性导航 (inertial navigation) 的定位^[5-6]、基于卫星伪基站的定位^[7-8]、基于无线局域网 (wireless local area network, WLAN) 的定位等^[9-10]。其中,WLAN

定位是当前室内定位中的一项主流技术,由于 WLAN 信号在室内环境中的普及,其定位成本和覆盖范围较大,是当前研究的热点。

基于 WLAN 的室内定位方法主要包含两种,1) 通过 WLAN 的接收信号强度 (received signal strength, RSS) 进行定位;2) 通过信道状态信息 (channel state information, CSI) 信息进行定位。其中,第 1 种方法中假设室内环境中存在较多的 WLAN 路由器,即 AP (access point),因此不同的室内的位置具有从不同的 AP 的 RSS 信息,该信息可以当作不同位置的“指纹”,因此该方法又被称为信号指纹定位^[11]。第 2 种方法中,通过一些特殊的接收设备和软件,能够获取 WLAN 信号的 CSI 信息,从这些信

息中,可以根据相位信息等估计出时间差,从而获取距离信息,再根据到达时间差算法(time difference of arrival, TDOA)进行定位^[12]。第 1 种方法由于不需要特殊的设备,并且相比于第 2 种方法更加适用于复杂的信道环境的定位应用,因此基于信号指纹的 WLAN 定位方式更加普及,是当前研究的热点。

基于 RSS 信号指纹的定位方法中,通常分为两个过程,1) 离线测绘过程;2) 在线定位过程^[13]。其中步骤 1) 通过离线测量室内环境中不同位置的 RSS 信号指纹,从而建立几何位置与信号指纹的对应关系,生成信号指纹地图(radio map, RM)。由于该过程中需要对室内的许多位置进行测量,因此所需的时间较长,需要测量后进行数据的离线处理。步骤 2) 通过匹配在线采集的 RSS 信号指纹,与 RM 中的信号指纹进行定位。

当前存在许多 WLAN 定位方法,这些方法分别侧重于定位过程中的不同方面。文献[14]通过 k 最近邻(k nearest neighbors, kNN)方法根据信号指纹匹配结果对位置进行估计。文献[15]划分了不同的定位阶段,即粗定位和精定位,粗定位中解算出人员的可能区域,精定位解算出人员的位置估计。该方法的提出解决了定位过程时间延迟较大的问题。文献[16]指出了信号匹配过程中不同度量对精度的影响,这些度量包括欧氏距离、马氏距离、高斯对数距离、Jaccard 距离等。文献[17]提出将惯性传感器的观测数据,与已有的 WLAN 信号指纹定位融合,再通过多级滤波或图优化,从而提高 WLAN 定位精度。新出现的一些方法中,将深度学习技术应用于 WLAN 定位中。文献[18]提出将卷积神经网络(convolutional neural network, CNN)用于 WLAN 定位,将 RSS 信号指纹作为输入,位置信息作为输出,利用卷积神经网络学习信号指纹与几何位置的对应关系。文献[19]提出了基于循环神经网络(recurrent neural network, RNN)的定位方法,该方法中,利用 WLAN 的信号指纹地图的序列的前后的关系,对人员的位置进行估计,具有更好的定位精度。文献[20]提出了利用自编码器(auto encoder, AE)进行半监督定位。首先利用大量的无位置标签的 RSS 信号指纹对自编码器进行逐层贪心训练,再利用少量的带位置标签的数据进行参数微调,从而完成定位网络的训练。文献[21]提出了基于回归神经网络的方法,通过学习出两个 RSS 信号指纹的最佳度量,从而提高匹配定位的精度。

上述的方法都聚焦于定位,虽然有效,但是无法在相同的框架下同时完成定位和信号指纹地图的重构。然而实际情况中,对信号指纹地图进行重构十分重要,原因如下:1) 当原始的 RM 地图的维度较高、定位的区域较大、原始 RM 地图中的 RSS 指纹数目较大时,由于计算量的增加,导致定位的延迟增加,从而无法提供实时定位服务,实

际应用受到了限制;2) 原始的 RM 地图中,测量得到的 RSS 指纹数目分布不均匀,如在一些区域覆盖的 RSS 指纹数目较多,在另一些区域没有 RSS 指纹覆盖,该情况可能导致定位精度变差,需要对 RM 重新生成,使得新的 RM 分布更加均匀,从而提高定位的精度;3) 通常来说,某区域的 RM 地图随着时间而变化,从而导致定位精度下降,为了避免该现象的发生,需要对 RM 进行重新测量,通过对变分自编码器(variational auto encoder, VAE)的应用,仅需要获取少量的带位置标签的 RSS 指纹数据和大量的无位置标签的 RSS 指纹数据,就能够对 RM 进行重新生成,从而避免了 RM 动态变化对定位精度的影响。

本文提出一种基于变分自编码器(VAE)的 WLAN 定位方法。VAE 是深度学习中一种较新的模型,它既是一个估计模型,也是一个生成模型,能够根据原始样本的分布生成新的样本。本文的应用中,改变了传统的变分自编码器的结构。设置两路独立的译码器通路,其中一路为定位通路,输入为 RSS 经过自编码器后的隐变量,输出为位置信息;另一路为重构指纹地图通路,其输入也为 RSS 经过自编码器后的隐变量,输出为重构的 RSS 信号指纹。通过该结构的设置,使得该方法不仅能够进行传统的 WLAN 定位,也能够对已有的 RM 进行重新生成。本文的最大创新点在于能够将传统的单通道的定位子网络和重构子网络结合起来,从而同时实现位置估计和 RSS 重构。网络结构的改变,使得该方法能够充分利用已有信息(位置信息和重构代价信息),从而定位子网络和重构子网络的输出更加精确。

通过开源数据集对本文提出的方法进行了验证,证明了本文的方法在定位通路上,相比基于稀疏重构的定位方法和传统的 kNN 定位方法,误差分别下降了约 14% 和 24%;能够对 RM 进行重新生成,利用重新生成的 RM 进行定位,相比于利用稀疏重构生成的 RM 定位误差下降了约 11%。

1 方法步骤

本文提出的基于变分自编码器的结构如图 1 所示,相比于传统变分自编码器,其增加了一个通路。由图 1 可知,本文方法中该神经网络存在两个通路,包含定位通路,与 RM 地图重构通路。并且,该变分自编码器存由 3 个子网络组成,其中,第 1 个子网络为降维网络,其结构与传统的自编码器中的降维子网络(又叫编码器网络)相同,目的是将高维度的输入数据(此处为 RSS 信号指纹数据)进行编码后,输出低维度的数据,并且存在较小的信息损失;第 2 个子网络为定位子网络,其输入为 RSS 信号指纹数据经过编码器网络降维后的低维表示,经过神经网络的处理,得到对应的几何位置的估计,由于该子

网络具有从信号指纹信息中估计几何位置的功能,因此叫定位子网络;第 3 个子网络为重构子网络,该网络与传统的变分自编码器的译码网络类似,能够从编码子网络输出的低维数据表示中,恢复原始数据的高维表示,从而得到重构的 RSS 信号指纹。上述的 3 个子网络分别对应了 3 个不同的代价子函数,其中降维子网络的代价函数对数据的低维表示进行了约束;定位子网络的代价函数对定位误差进行了约束;重构子网络的代价函数对 RSS 信号指纹的重构误差进行了约束。根据本文方法中的变分自编码的结构,由于定位子网络和重构子网络具有相同的输入,并且由于代价函数同时对定位误差和重构误差都进行了约束,因此, RSS 信号指纹的低维表示中既包含了几何位置相关的特征,也包含了 RSS 信号指纹本身的重构敏感特征,使得降维后的数据表示更加适合定位的应用。

注意该结构中两通道互不独立,存在较大的联系。两通道三子网在进行训练时,包含 3 种代价或约束,分别是 KL 散度代价、定位误差代价和重构误差代价。这 3 种代价在训练时相互影响,使定位子网络和重构子网络所利用的隐藏表示既充分包含了位置敏感特征,也包含了重构敏感特征,从而使得该网络结构能够同时进行定位和 RSS 重构。具体来说,对于重构子网络,在训练时能够充分利用已有位置信息,使得重构的 RSS 更好地体现内蕴的位置信息。对于定位子网络,能够利用重构 RSS 代价信息,使得定位子网络对 RSS 中的噪声波动降低敏感度。

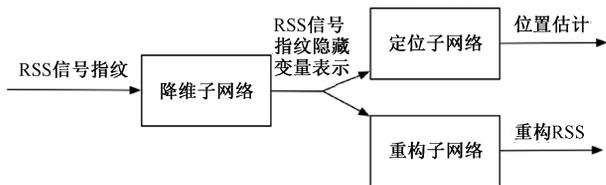


图 1 本文提出的基于变分自编码器网络的结构 (包含降维子网络、定位子网络和重构子网络)

Fig. 1 The proposed framework of the variational auto encoder based method (including the embedding sub-network, the positioning sub-network and the reconstruction sub-network)

1.1 变分自编码器简介

由于变分自编码器具有生成新样本(该样本与原始样本具有相同的分布)的能力,被广泛应用于图像领域。从原理上,变分自编码器将神经网络的万能近似理论与贝叶斯估计理论结合,即用神经网络的方法进行分布的估计。传统的变分自编码器网络的结构如图 2 所示,其与经典的编码器-译码器网络的结构类似。在变分自编码器的框架中,基于了如下的假设,原始数据的后验概率分布是多维高斯的正态分布,并且该正态分布的协方差矩阵具有对角矩阵的结构,即:

$$p(\mathbf{z} | \mathbf{x}_i) = \mathcal{N}(\mathbf{z}; \boldsymbol{\mu}_i, \sigma_i^2 \mathbf{I}) \quad (1)$$

式中: \mathbf{x}_i 表示原始的数据; \mathbf{z} 表示数据的隐变量表示; $p(\mathbf{z} | \mathbf{x}_i)$ 为原始数据的隐变量后验分布; $\boldsymbol{\mu}_i$ 表示正态分布的均值; $\sigma_i^2 \mathbf{I}$ 表示正态分布的方差,下标表示输入数据的序号。基于该假设,并基于神经网络的万能近似定理,原始数据经过神经网络后,可以求得 $\mathcal{N}(\mathbf{z}; \boldsymbol{\mu}_i, \sigma_i^2 \mathbf{I})$ 表示的后验概率的均值 $\boldsymbol{\mu}_i$ 和方差 $\sigma_i^2 \mathbf{I}$, 输出为均值和方差的神经网络的部分即为图 2 的编码器部分。其均值 $\boldsymbol{\mu}_i$ 即可看作是原始数据的降维表示,也为隐藏变量。

求得均值和方差后,本文对隐藏变量施加标准正态分布的约束假设,该假设与每个输入数据都为标准正态分布假设是一致的:

$$p(\mathbf{z}) = \sum_i p(\mathbf{z} | \mathbf{x}_i) p(\mathbf{x}_i) = \sum_i \mathcal{N}(\mathbf{0}, \mathbf{I}) p(\mathbf{x}_i) = \mathcal{N}(\mathbf{0}, \mathbf{I})$$

根据分布 $\mathcal{N}(\mathbf{z}; \boldsymbol{\mu}_i, \sigma_i^2 \mathbf{I})$, 对隐藏变量进行重生成,并且再输入到译码器,可以对原始数据进行重构。可以得到,变分自编码器的代价函数由两部分组成:

$$KL(\mathcal{N}(\boldsymbol{\mu}_i, \sigma_i^2 \mathbf{I}) || \mathcal{N}(\mathbf{0}, \mathbf{I})) + || \mathbf{x}_i - \boldsymbol{\mu}_{iz} ||^2 \quad (2)$$

式中: $KL(\mathcal{N}(\boldsymbol{\mu}_i, \sigma_i^2 \mathbf{I}) || \mathcal{N}(\mathbf{0}, \mathbf{I}))$ 表示对后验概率的标准正态分布约束, $|| \mathbf{x}_i - \boldsymbol{\mu}_{iz} ||^2$ 表示对重构数据误差的约束。变分自编码器的更详细的原理与推导参考文献[22]。

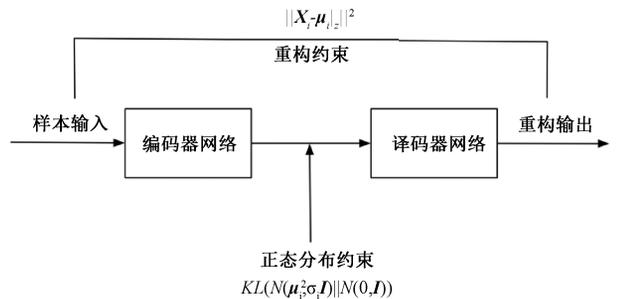


图 2 原始的变分自编码器的结构

Fig. 2 The structure of the original variational auto encoder

1.2 变分自编码器在本文中的应用

本文所用的变分自编码器的结构如图 1 所示,包含降维子网络、定位子网络和重构子网络。该整体框架中,降维子网络的输入为预处理后的 RSS 信号指纹,定位子网络的输出为预处理后的几何位置,重构子网络的输出为重构后的 RSS 信号指纹。为了对该框架进行训练,需要预处理后的 RSS 信号指纹和对应的几何位置。另外前文提到,为了使隐藏变量既具有位置相关的特征,同时也能尽量无损地重构 RSS 信号指纹,在训练过程中,需要建立对应的代价函数项。本文中几个子网络与代价函数项的对应关系如图 3 所示,其中降维子网络对应 KL 散度的代价函数项,该代价函数项是变分自编码器框架的约束,

表征了隐藏变量的分布与标准多维正态分布的差别;定位子网络对应的代价函数项是位置的均方误差项,表征了估计位置与实际位置的误差;重构子网络对应的代价函数项对应了 RSS 信号指纹的重构误差。上述的数据预处理和不同的代价函数项构成将在后文进行介绍。

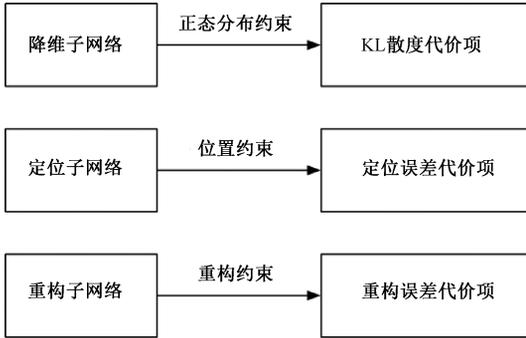


图 3 三种子网络与对应的代价函数项

Fig. 3 The three sub-networks and their corresponding cost function terms

1) 数据预处理

由于神经网络的输入和输出要求是固定维度和归一化后的,因此需要对原始的样本数据进行处理。本文中原始采集到的 WLAN 的 RSS 信号指纹,存在如下的特点:1)信号维度不同,由于不同的 RSS 信号指纹在不同的位置采集,其接收到的不同 AP 的信号,导致了其维度不同;2)信号的噪声较大,特别是在室内环境中,信号的衰落现象较为严重,并且动态变化的室内环境也会引入额外的噪声。针对特点 2),对接收到的 RSS 信号进行了如文献[21]的滑动平均滤波,从而减小信号噪声的影响。针对特点 1),本文对采集到的所有 RSS 信号指纹进行了维度的补齐:

$$AP(RSS) = AP(RSS_1) \cup AP(RSS_2) \cup AP(RSS_3) \cup \dots$$

其中, $AP(\cdot)$ 表示求去对应的信号指纹的所有 AP 的 MAC 地址集合,而新的信号指纹对应的 MAC 地址集合为所有集合的并集。根据该并集,可以将原始的不同维度的 RSS 信号指纹映射到相同维度的 RSS 信号指纹上,从而解决了维度不同问题。进行维度映射后,还需要对 RSS 信号指纹进行归一化处理:

$$r_{\text{new}} = \frac{r_{\text{raw}} - r_{\text{min}}}{r_{\text{max}} - r_{\text{min}}} \quad (3)$$

其中, r 表示对应某 AP 对应的信号强度。本文样本 RSS 信号在经过预处理后可以用向量进行表示:

$$\vec{r}_{\text{new}} = (r_1, r_2, r_3, \dots, r_N) \quad (4)$$

式中: N 表示向量的维度,表示总共收到过 N 个 AP 的信号,每一维对应于某个 AP 预处理后的信号强度,由于经过了归一化预处理,其值在 0~1。

针对几何位置的归一化处理与信号强度的归一化处理类似:

$$s_{\text{new}} = \frac{s_{\text{raw}} - s_{\text{min}}}{s_{\text{max}} - s_{\text{min}}} \quad (5)$$

式中: s 表示对应几何位置某维度坐标。

2) 代价函数的构成

本文所用的变分自编码器的详细结构和对应的不同的代价函数项如图 1 和 3 所示。其中降维子网络的结构如图 4 所示,其包含了两个结构,分别为典型的多层卷积神经网络结构和重参数生成层。其中多层神经网络的输出分别为 μ_z 和 ϵ_z , 分别表示后验多维高斯分布的均值向量和方差。其对应的代价函数项可以写为:

$$KL(\mathcal{N}(\mu_z, \epsilon_z) \parallel \mathcal{N}(\mathbf{0}, \mathbf{I})) = \frac{1}{2} (-\log \epsilon_z + \mu_z^2 + \epsilon_z - \mathbf{I}) \quad (6)$$

其中, $KL(\cdot)$ 表示两种不同分布之间的 KL 散度,该散度通常用于表示两个不同分布之间的距离。此处用 KL 散度量后验分布 $\mathcal{N}(\mu_z, \epsilon_z)$ 和标准多维正态分布 $\mathcal{N}(\mathbf{0}, \mathbf{I})$ 的距离。

得到 μ_z 和 ϵ_z 后,根据分布 $\mathcal{N}(\mu_z, \epsilon_z)$ 进行随机抽样,但是由于该抽样过程不可导,无法对该网络进行训练。因此在变分自编码器中引入了重参数生成层,该层中将 $\mathcal{N}(\mu_z, \epsilon_z)$ 在中进行抽样改为了在标准的多维正态分布 $\mathcal{N}(\mathbf{0}, \mathbf{I})$ 中进行抽样,假设抽样的样本为 η 然后进行如下的处理:

$$z_{\text{new}} = \eta \cdot \epsilon_z + \mu_z \quad (7)$$

处理后的点 z_{new} 相当于从原始的 $\mathcal{N}(\mu_z, \epsilon_z)$ 分布中进行抽样。该层的优点是通过抽样,避免了梯度下降中对变量 μ_z 和 ϵ_z 的计算,因此使得网络能够被训练。其中 z_{new} 可以看作是经过计算得到的表示 RSS 信号指纹的隐藏变量,该隐藏变量既能反映几何位置相关的特征和 RSS 信号指纹本身的表示特征。

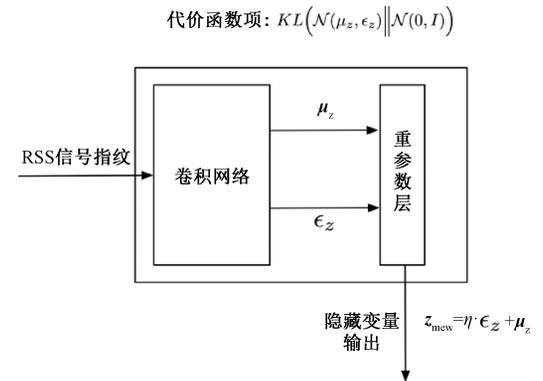


图 4 降维子网络的细化结构和对应的代价函数项

Fig. 4 The detailed structure of the embedding sub-network and its corresponding cost function term

定位子网络和重构子网络的具体结构如图 5 所示,这两个网络的输入为 z_{new} , 表示 RSS 信号指纹的隐藏变量表示。从结构上说,定位子网络和重构子网络都是一个多层的卷积神经网络,他们具体结构不同。定位子网络的输出为三维,对应了三维几何位置,重构子网络的输出维度与预处理后的 RSS 信号指纹维度一致。定位子网络对应的代价函数项为:

$$MSE(\mathbf{s}_{\text{sample}} - \mathbf{s}_{\text{est}}) \quad (8)$$

式中: $MSE(\cdot)$ 表示均方误差; \mathbf{s}_{est} 表示神经网络输出的坐标; $\mathbf{s}_{\text{sample}}$ 表示训练样本中的坐标。而重构子网络的代价函数项为:

$$MSE(\mathbf{r}_{\text{sample}} - \mathbf{r}_{\text{reconstruct}}) \quad (9)$$

式中: $MSE(\cdot)$ 表示均方误差; $\mathbf{r}_{\text{sample}}$ 表示预处理后的 RSS 样本信号指纹, $\mathbf{r}_{\text{reconstruct}}$ 表示重构的 RSS 信号指纹。

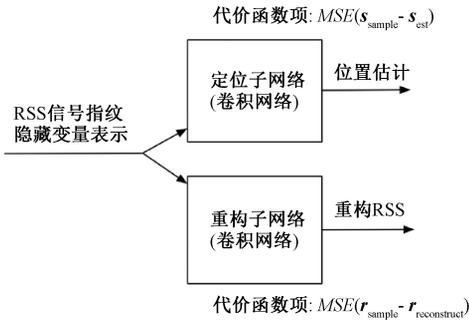


图 5 定位子网络和重构子网络结构和对应的代价函数项
Fig. 5 The detailed structure of the positioning sub-network and the reconstruction sub-network

按照本文所述的 3 种不同的代价函数项,可以对本文提出的变分自编码器网络进行训练。训练后得到的隐藏变量表示既具有定位的相关特征,也能够进行重构。值得注意的是,在训练过程中,隐藏变量是通过重参数层中的抽样得到。但是,在测试过程中,仅存在前向过程,直接利用降维子网络的中间过程输出 μ_z 作为定位子网络和重构子网络的输入。

2 实验

为了对本文的方法进行验证,利用了开源的室内 WLAN 定位数据集^[15]。该数据集包含了从校园内的两个不同的建筑物采集的 RSS 信号指纹,并且利用地图点按标注的方法为这些 RSS 信号指纹打上了几何位置的标签。如图 6 所示,标出了该数据集中在两个建筑物内采集的 RSS 信号指纹的几何位置。可以看出,几何位置是三维的坐标表示。本文实验首先研究了本文框架中的降维子网络、定位子网络和重构子网络的不同的卷积层的层数对定位精度的影响。然后,对比了本文所用的基于

变分自编码器的方法的定位通路的定位精度与传统的 kNN 方法^[14]、基于压缩感知 (compressive sensing, CS)^[23] 的定位精度。并且,进一步对比了利用重构生成的 RM 地图和原始的 RM 地图以及利用压缩感知生成的 RM 地图的定位精度和平均定位延迟。

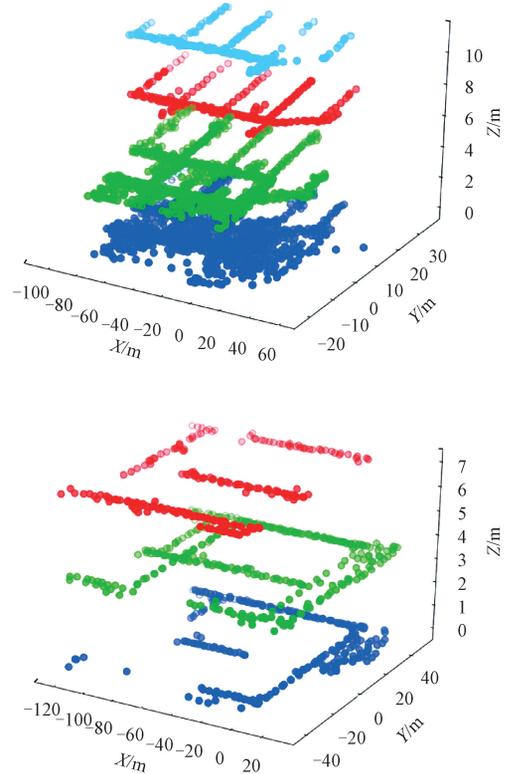


图 6 本文所用的开源数据集中的 RSS 信号指纹的几何位置分布(分别在两个不同的建筑物内)
Fig. 6 The positions of the RSS fingerprints from the open-sourced dataset (in two buildings respectively)

2.1 子网络的层数对定位和重构效果的影响

本文提出的基于变分自编码器的方法中,用到了 3 种不同的子网络,分别是降维子网络、定位子网络和重构子网络,3 种子网络的主体部分就是卷积神经网络。由文献[24]可知,降维子网络的最佳层数为 3,本文固定降维子网络的层数,研究定位子网络和重构子网络的层数的影响。图 7 所示为不同层数的卷积神经网络对定位误差和重构误差的影响,其中纵坐标为定位误差和重构误差的均方误差之和。注意,此处的用到的均方误差是测试集的均方误差。从图 7 可以看出,当定位子网络的层数大于 2 时,均方误差和的降低较不明显。本文为了使得网络的结构更简单,更利于训练,将定位子网络的层数设置为 2,将重构子网络的层数设置为 3。

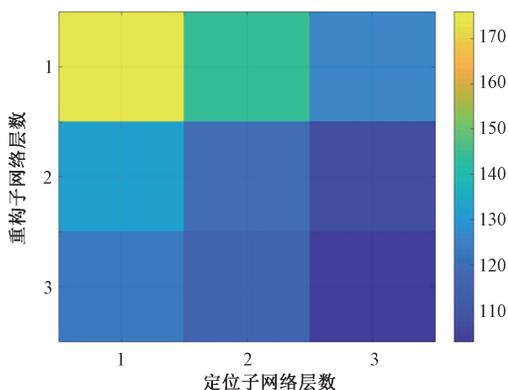


图 7 定位子网络和重构子网络层数对均方误差误差和的影响

Fig. 7 The effects of different number of layers over the mean square error sum for the positioning sub-network and the reconstruction sub-network

2.2 定位性能比较

为了对比本文提出的方法与其他方法,本文从两个角度对本文方法的性能进行说明。首先是定位通路的定位精度,其次是 RSS 信号指纹地图的重构性能。

在定位通路的定位精度对比中,本文方法与两种具有代表性的方法:kNN 方法和基于压缩感知的方法,进行了对比。其中 kNN 方法是最传统的方法,一般作为 WLAN 定位的基准方法;基于压缩感知的方法比较特殊,它与本文的方法一样既具备定位也具备 RSS 重构的能力。图 8 所示为本文的 3 种方法的误差积累分布曲线。可以看出本文提出的方法对应的曲线在最上方,表示了本文方法的定位精度整体分布在更低的位置,体现了更好的定位精度。表 1 给出了 3 种方法的平均定位精度对比,可以看出,本文提出的方法平均误差相比基于稀疏重构的定位方法和传统的 kNN 定位方法,分别下降了 0.8 和 1.6 m (约 14% 和 24%)。

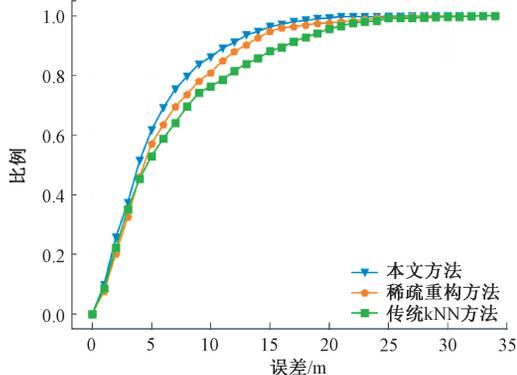


图 8 不同方法的定位误差积累分布曲线对比

Fig. 8 The positioning accuracies comparisons adopting accumulative error density curves among the different methods

表 1 平均定位误差对比

Table 1 Mean positioning accuracy comparisons

方法	平均误差/m
本文方法	5.1
稀疏重构方法	5.9
传统 kNN 方法	6.7

为了对比重构的 RSS 定位精度,本文用到了基准的 kNN 定位方法。注意,此处的定位是直接利用的 RSS 信号指纹的隐藏变量域的表示进行的 kNN。图 9 所示为本文重构的 RSS 信号指纹地图和利用稀疏重构的 RSS 定位方法^[23]的误差积累分布曲线。可以看出利用本文的重构 RSS 信号指纹地图的定位曲线在稀疏重构的定位曲线上方,证明了此处本文方法定位性能更好,也间接证明了本文方法的重构 RSS 地图的精度更高。经统计,相比于利用稀疏重构生成的 RM 定位,本文重构的 RM 定位误差下降了约 1.0 m (约 11%)。本文的重构精度高于稀疏重构方法的一个原因是本文方法用到的是基于样本的训练,而基于稀疏重构的方法是基于 RSS 表示在频率空间中的系数可稀疏表示的假设,该假设在室内复杂环境中可能不成立。

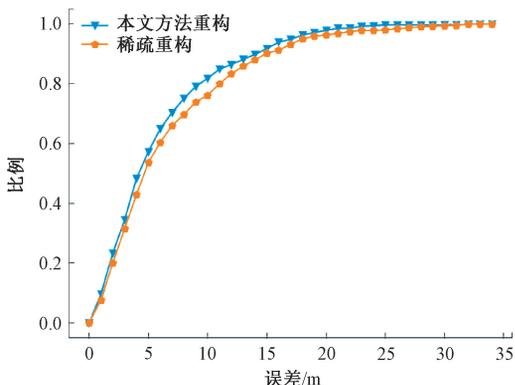


图 9 本文的重构 RSS 地图与基于稀疏重构的方法^[23]

在 kNN 基准方法的定位精度误差积累曲线对比

Fig. 9 The accumulative error density curve comparisons adopting the baseline kNN method adopting the reconstructed RM using the proposed method and the compressive sensing based method^[23]

该实验是在静态环境中对数据进行重构。由于隐藏变量的维度较低,因此相比于利用原始的 RSS 信号进行定位的方法,kNN 算法遍历并计算距离的速度更快,因此所需要的定位延迟降低。经统计,利用原始的 RSS 信号进行定位的平均耗时为 0.53 s,而利用隐藏变量 RSS 地图进行定位的平均耗时为 0.08 s,速度快了约 85%。

3 结论

本文提出一种基于变分自编码器的 WLAN 室内定

位方法。该方法改变了传统的变分自编码器结构,由降维子网络、定位子网络和生成子网络组成,形成了定位通路和 RSS 信号指纹重构通路,使得本文提出的方法既具备定位的能力,也具备重新生成 RSS 信号指纹或指纹地图的能力。利用开源的数据集对本文提出的方法进行了验证,证明了在定位通路上,本文方法定位误差,相比于稀疏重构的定位方法和传统的 kNN 定位方法,分别下降了约 14% 和 24%;能够对 RM 进行重新生成,利用重新生成的 RM 进行定位,相比于利用稀疏重构生成的 RM 定位误差下降了约 11%。本文的下一步研究方向是,采集动态变化的 WLAN 定位数据集,并且研究本文方法对动态变化数据集的适应程度。

参考文献

- [1] 魏培,姜平,贺晶晶,等. 基于内三角形质心算法的 UWB 室内定位[J]. 计算机应用, 2017, 37(1): 289-293.
WEI P, JIANG P, HE J J, et al. UWB indoor localization based on the inner triangle centroid algorithm[J]. Journal of Computer Applications, 2017, 37(1): 289-293.
- [2] 李荣冰,王念曾,刘建业,等. 面向相对导航的 UWB 测距误差估计与补偿方法[J]. 仪器仪表学报, 2019, 40(5): 28-35.
LI R B, WANG N Z, LIU J Y, et al. UWB ranging error estimation and compensation method for relative navigation[J]. Chinese Journal of Scientific Instrument, 2019, 40(5): 28-35.
- [3] 刘振远,侯明祥,方维维,等. 基于低功耗蓝牙信标的室内定位方法研究[J]. 中国电子科学研究院学报, 2018, 13(5): 126-132.
LIU ZH Y, HOU M X, FANG W W, et al. Research on indoor positioning method based on bluetooth low energy[J]. Journal of China Academy of Electronics and Information Technology, 2018, 13(5): 126-132.
- [4] 张俞,冷璐. 基于图优化的蓝牙信标室内定位方法[J]. 电子测量与仪器学报, 2019, 10(6): 23-37.
ZHANG Y, LENG L. Graph optimization based indoor positioning method using bluetooth low energy [J]. Journal of Electronic Measurement and Instrument, 2019, 10(6): 23-37.
- [5] 谷阳,宋千,李杨寰,等. 基于惯性鞋载传感器的人员自主定位粒子滤波方法. 电子与信息学报, 2015, 37(2): 484-488.
GU Y, SONG Q, LI Y H, et al. A particle filter method for pedestrian navigation using foot-mounted inertial sensors [J]. Journal of Electronics & Information Technology, 2015, 37(2): 484-488.
- [6] 谷阳,宋千,马明,等. 基于鞋载惯性传感器的地图辅助人员定位方法[J]. 系统工程与电子技术, 2015, 37(7): 1633-1637.
GU Y, SONG Q, MA M, et al. Map-aided pedestrian navigation based on foot-mounted inertial sensors [J]. Systems Engineering and Electronics, 2015, 37(7): 1633-1637.
- [7] ALEXANDRE V P, NEL S. Interference mitigation in a repeater and pseudolite indoor positioning system [J]. IEEE Journal of Selected Topics in Signal Processing, 2012, 10(2): 810-820.
- [8] MA C, YANG J, CHEN J Y, et al. Indoor and outdoor positioning system based on navigation signal simulator and pseudolites [J]. Advances in Space Research, 2018, 62(9): 2509-2517.
- [9] WANG K, YU X, XIONG Q, et al. Learning to improve WLAN indoor positioning accuracy based on DBSCAN-KRF algorithm from RSS fingerprint data [J]. IEEE Access, 2019, 4(7): 72308-72315.
- [10] FRANCESCANTONIO D R, MAURO P, JARI N. Indoor positioning in WLAN: From conventional to cooperative techniques [C]. Mobile Positioning and Tracking, 2017: 143-149.
- [11] ALI, K, NIKOLAOS G, DAVID A. Modern WLAN fingerprinting indoor positioning methods and deployment challenges [J]. IEEE Communications Surveys & Tutorials, 2017, 19(3): 1974-2002.
- [12] ZHANG Y, LI D P, WANG Y J. An indoor passive positioning method using CSI fingerprint based on Adaboost [J]. IEEE Sensors Journal 2019, 19(14): 5792-5800.
- [13] ABUSARA A, MOHAMED S H, MAHMOUD H I. Reduced-complexity fingerprinting in WLAN-based indoor positioning [J]. Telecommunication Systems, 2017, 65(3): 407-417.
- [14] FANG Y Q. Application of an improved K nearest neighbor algorithm in WiFi indoor positioning [C]. China Satellite Navigation Conference (CSNC), Springer, 2015(3): 34-45.
- [15] CRAMARIUC A, HEIKKI H, ELENA S L. Clustering benefits in mobile-centric WiFi positioning in multi-floor buildings [C]. International Conference on Localization and GNSS (ICL-GNSS), IEEE, 2016: 323-338.
- [16] MINAEV G, ARI V, ROBERT P. Comprehensive survey of similarity measures for ranked based location fingerprinting algorithm [C]. International Conference on Indoor Positioning and Indoor Navigation (IPIN), IEEE,

- 2017; 123-134.
- [17] GU Y, MA M, SONG Q. Trajectory initialization foot-mounted IMU and calibration using a and UWB anchors[C]. Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS), IEEE, 2018; 232-245.
- [18] JIAO J C, LI F, DENG Z L, et al. A smartphone camera-based indoor positioning algorithm of crowded scenarios with the assistance of deep CNN[J]. Sensors, 2017, 17(4): 704-723.
- [19] LUKITO Y, ANTONIUS R C. Recurrent neural networks model for WiFi-based indoor positioning system [C]. International Conference on Smart Cities, Automation & Intelligent Computing Systems (ICON-SONICS), IEEE, 2017; 1310-1321.
- [20] ZHANG W, LIU K, ZHANG W D, et al. Deep neural networks for wireless localization in indoor and outdoor environments [J]. Neurocomputing, 2016, 194(1): 279-287.
- [21] DONG B X, BURGESS T, NEUNER H B, et al. Neural network based radio fingerprint similarity measure [C]. International Conference on Indoor Positioning and Indoor Navigation (IPIN), IEEE, 2018; 212-223.
- [22] KINGMA D P, MAX W. Stochastic gradient VB and the variational auto-encoder [C]. Second International Conference on Learning Representations, ICLR, 2014(19): 76-87.
- [23] CHEN F, AU W S A, VALAEE S, et al. Received-signal-strength-based indoor positioning using compressive sensing [J]. IEEE Transactions on Mobile Computing, 2012, 11(12): 1983-1993.

- [24] ZHOU C F, GU Y. Joint positioning and radio map generation based on stochastic variational Bayesian inference for FWIPS [C]. International Conference on Indoor Positioning and Indoor Navigation (IPIN), IEEE, 2017; 231-243.

作者简介



米伟娟, 1999 年于河北工业大学获得学士学位, 2019 年于河北科技大学获得硕士学位, 现为河北传媒学院教师, 主要研究方向, 计算机及其应用技术、大数据科学与技术、计算机程序设计。

E-mail: mmwei76@sina.com

Mi Weijuan received her B. Sc. degree from Hebei University of Technology in 1999 and M. Sc. degree from Hebei University of Science and Technology in 2019. Now she is a teacher at Hebei Institute of Communications. Her main research interests include computer and its application technology, big data science and technology, and computer programming.



李娜, 2005 年于河北师范大学获得学士学位, 2014 年于河北经贸大学获得硕士学位, 现为河北传媒学院教师, 主要研究方向为计算机应用基础、计算机网络技术、计算机程序设计。

E-mail: 610587057@qq.com

Li Na received her B. Sc. degree from Hebei Normal University in 2005 and M. Sc. degree from Hebei University of Economics and Business in 2014. She is now a teacher at Hebei Institute of Communications. Her main research interests include computer application foundation, computer network technology and computer programming.