

DOI: 10.13382/j.jemi.B2003060

基于 seq2seq 模型的室内 WLAN 定位方法

邢方方¹ 惠向晖²

(1. 许昌电气职业学院 许昌 461000; 2. 河南农业大学 郑州 450002)

摘要:基于 WLAN(wireless local area network)的定位在智能家居、室内导航、个性化服务等应用中扮演着重要的角色。研究了基于序列到序列 seq2seq 模型的室内 WLAN 定位方法。该方法基于在自然语言处理中广泛应用的 seq2seq 神经网络模型,通过样本数据学习信号指纹空间中的时间序列和坐标空间中的时间序列的关系。经过滤波等预处理后,再进行样本增强,并设计合理的输入输出及代价函数,本方法能够实现更高精度定位。实测的数据表明,提出的方法相比于其他几种基于神经网络的定位方法,度量学习 RFSM 方法、去噪自编码器 DAE 方法、f-RNN 方法,平均定位精度分别提高了 23%、11%和 20%。

关键词:序列到序列模型;WLAN 定位;神经网络

中图分类号: TP24;TN96 **文献标识码:** A **国家标准学科分类代码:** 510.51040

Seq2seq model based WLAN indoor positioning

Xing Fangfang¹ Hui Xianghui²

(1. Xuchang Electrical Vocational College, Xuchang 461000,China; 2. Henan Agricultural University, Zhengzhou 450002,China)

Abstract:Wireless local area network (WLAN) based positioning plays an important role in smart homes, indoor navigation and user-defined services. Proposed a seq2seq model based WLAN indoor positioning method. The method is based on the seq2seq neural network model, which is widely adopted in the natural language processing (NLP). The seq2seq model can learn the relationships of the time sequences in the signal domain and the coordinate domain. After carefully designed signal pre-processing, sample augmentation and reasonable loss function, the learned model can be adopted for positioning. According to the experimental results from our collected data, our method can improve positioning accuracy compared with some other neural network based methods, including the RFSM method, the denoising autoencoder (DAE) based method and the f-RNN method, by 23%, 11% and 20% respectively.

Keywords:seq2seq based model; WLAN based indoor positioning; neural network

0 引言

随着普适计算研究的深入和 WLAN(wireless local area network)无线网络的普及,基于环境的位置感知、特别是室内环境中的位置感知是当前研究的热点^[1-2]。通过一定设备感知环境中 WLAN 信号,并估计当前的设备的位置,是物联网(internet of things, IOT)、基于位置的服务(location based service, LBS)等的信息基础,在智能家居、室内导航、个性化服务等具体应用中扮演着重要的角色。并且由于 WLAN 信号在室内环境中的普及,以及 WLAN 感知设备的普及,使得基于 WLAN 的定位应用具

有较大的优势,具体来说,相比于其他的需要在室内另外建设定位基础设施的方法,如基于 UWB 的定位方式、基于蓝牙的定位方式^[3-4]、基于超声的定位方式^[5-6]、基于可见光通信的定位方式^[7-8]等,具有更低成本和较强的普适性。

由于室内环境中存在较丰富的 WLAN 信号,并且由于这些信号具有一定的短时平稳特性,通常来说,根据设备感知到的不同 WLAN 信号可以用于区分几何空间的位置,即信号空间的信号与几何位置空间中的位置存在一定的映射关系。基于 WLAN 的定位方法,通过一定的训练数据学习信号与位置的映射关系,从而在设备感知到 WLAN 信号时,通过学习到的映射关系求得位置。在

实际应用中,设备感知的 WLAN 信息通常包含信道状态信息(channel state information, CSI)和信号强度(received signal strength, RSS),由于 CSI 信息的获取受到较大的硬件限制^[9],信号强度信息应用更为广泛。又由于信号强度信息在不同的几何位置中具有较高的独特性,因此感知到的 WLAN 信息又被称为信号强度指纹(received signal strength fingerprint, RSSF)。传统的 WLAN 定位方式,通过采集不同几何位置的信号强度指纹信息作为训练数据,再通过指纹匹配的方法进行位置估计。

随着深度学习研究的深入,其也拓展到了 WLAN 定位领域。基于深度学习的 WLAN 定位方法由于能够通过训练数据提取到信号特征间中对定位有用的特征,能够在一定程度上克服信号强度空间中复杂的噪声,提供更好的定位精度,因此是当前研究的热点。

传统的基于深度学习的 WLAN 定位主要有如下几类。

1) 通过卷积神经网络学习信号空间度量方式(radio fingerprint similarity measure, RFSM)^[10]。该方法通过得到最佳的信号空间度量,从而寻找对应的几何空间的近邻关系,再通过最近邻的方法得到几何位置估计。该方法的缺点是,本质仍然时最近邻定位过程,计算量随着信号指纹的数目无限增大,不满足大规模应用的要求;

2) 基于自编码器(auto encoder, AE)的定位方法^[11],通过自编码器对神经网络进行无监督的预训练(pre-training),再通过少许带标签(即已知几何位置的 RSSF)进行精调整(fine-tuning)。该方法的优点是定位方法对信号空间的噪声不敏感,仅需要少许带标签的数据,可以进行半监督的学习。缺点是由于进行与训练时用到的是逐层贪心算法,当带标签的数据较多时,退化成普通的神经网络定位方法,无法充分利用大量的带标签数据。

3) 基于 RNN 的方法^[12-13],基于 RNN 的方法由于可以充分利用序列的信息(在定位背景下,是时间序列),因此通常可以获得更好的定位精度。3 种不同的 RNN 结构如图 1 所示^[13]。图 1(a)为简单的多输入单输出的结构,即根据多个时间的 RSS 信号指纹,联合估计单个时间的几何位置;图 1(b)为多输入多输出的结构,根据多个时间的 RSS 信号指纹,联合估计多个时间的几何位置;图 1(c)在多输入多输出结构的基础上,把前一时刻的位置输出也作为后一时刻的输入。文献[13]指出图 1(c)(f-RNN)中的结构有着最好的定位精度,但是其缺点也很明显,即该方法需要人员的初始位置,才能进行后续的定位,在实际应用中可能受到较大的限制。

受到上面方法的启发,本文提出一种基于 seq2seq 模型^[14-15]的方法。seq2seq 模型具有编码器-解码器的结构,在自然语言处理(natural language process, NLP)的翻译任务中有着重要的应用。




图 1 基于 RNN 的 WLAN 定位方法的经典网络结构

Fig. 1 The three-classical structure for RNN based WLAN positioning method

自然语言中的翻译任务与 WLAN 定位问题有着如下的相似性,因此 seq2seq 模型也非常适用于室内 WLAN 的定位问题。1) 传统的 seq2seq 模型的输入是前后相互关联的序列(一种语言的一句话或一个短语),WLAN 信号指纹定位中的输入的信号强度指纹也是前后相互关联的序列;2) 传统的 seq2seq 模型的输出是前后相互关联的序列(另一种语言的对应的句子或短语),在本文的定位过程中需要的输出也是前后相关的连续位置估计。定位中,相关性体现在连续位置估计中,由于行人的行走速度有限导致的距离限制,由于室内空间限制导致的行人轨迹约束等;3) 在自然语言翻译任务中和 WLAN 行人定位过程中,seq2seq 模型都能应对变化的输入长度。特别是在行人定位过程中,可根据定位场景对实时性和定位精度的限制,灵活调整模型的输入长度,即行走过程中采集到的信号强度指纹的数目。通常来说,该数目越短,实时性越好,精度越差;该数目越长,处理时间越长,但由于更充分利用了序列前后的相关性,精度越高。

由于上面提到的原因,本文将 seq2seq 模型应用到了 WLAN 行人定位中,该方法有如下的特点:1) 能够充分利用连续采集的信号强度指纹的相关性,从而提高定位精度;2) 能够充分利用训练数据中位置空间的前后相关性,提高精度;3) 在定位时,不需要人员的初始位置,并且该模型能够应对不同长度的输入,定位的适应场景更多。最后本文通过实测的实验数据对该方法进行了验证,并且与前文提到的 3 种典型的基于神经网络的方法(RFSM 方法、去噪自编码器 DAE 方法、f-RNN 方法)进行了比

较,证明了本文提出的方法具有更好的定位精度,平均定位精度分别提高了 1.2、0.5 和 1.0 m,对应的百分比为 23%、11%和 20%。但是,由于本文的方法中输入输出均为可变长度的序列,因此在训练中通常需要大量的训练样本数据,即需要人员在定位前在室内环境中采集更多已知位置的信号强度指纹,该问题可以通过连续指纹采集的方式在一定程度上缓解。

1 方法步骤

seq2seq 模型在自然语言处理中的翻译任务有着较为成熟的应用,由于翻译任务中与 WLAN 定位有着一定的相似性,因此也可以将该模型用于 WLAN 定位中。在该节中,首先介绍 seq2seq 模型的特点以及在翻译任务中的经典应用,然后再详细介绍 seq2seq 模型在 WLAN 定位中的具体应用方法。在 WLAN 定位中,应用 seq2seq 模型的不同之处主要体现在如下几个方法:1)输入和输出不同,WLAN 定位中输入为信号强度指纹数据,输出为位置;2)预处理方法不同,特别是模型的输入为信号强度指纹数据,需要进行较多的预处理方法,从而解决输入维度不同、信号衰落导致的信号强度跳变等问题;3)训练样本的匮乏性问题,本文提出一种方法增加训练样本的数目。本文主要从这几个方面详细论述 seq2seq 模型在 WLAN 定位中的应用。

1.1 seq2seq 模型简介

seq2seq 模型最早在文献[14]提出,可以应对输入输出序列长度变化的情况,因此适合在自然语言处理的翻译任务中有进行应用。结构如图 2 所示,有着编码器-译码器结构。该结构中,由一种语言的输入通过 RNN 网络将该输入进行编码成一个向量,再将该向量作为译码 RNN 网络的输入,得到的输出即为翻译后的另一种语言。该模型最大的优点是可以应对长度变化的输入,并且可以学习到两个不同域的映射关系,因此也适合在本文中的 WLAN 定位中应用(由信号域映射到坐标域)。

传统的 seq2seq 模型的应用中主要包含如下 4 种关键技术。

1)词嵌入技术。由于一个域中的单词数目巨大,如果直接进行 one-hot 编码可能导致数据维度巨大,所需要的参数量巨大,从而难以进行实际的运用。因此引入词嵌入技术对单词的表示向量进行降维。传统的词嵌入方法包含 word2vec 方法,通过语料中单词,按照一定的模型,如连续词袋(continuous bag of words,CBOW),图 3 所示为通过 CBOW 方法产生样本进行训练后,得到的单词表示维度较低,并且在该空间的表示能够较好地反映出单词的相似性^[16-17]。

2)encoder-decoder 模型,即编码器译码器模型。如




图 2 seq2seq 编码器译码器模型

Fig. 2 The encoder-decoder structure for the seq2seq model




图 3 CBOW 方式产生的词嵌入训练样本

Fig. 3 The training samples originated from the CBOW method

图 2 所示,能够通过长短期记忆门控单元(long short term memory, LSTM)构成 RNN 网络,得到编码器-译码器结构。

3)注意力机制。注意力机制在 seq2seq 中的应用首先在文献[15]提出。注意力机制解决了传统的 seq2seq 模型中信息输入序列信息丢失的问题:即当输入序列较长,上下文向量,即编码器的输出(context vector)维度有限时,编码器输出的上下文向量丢失了较多信息,导致输出不准确。注意力机制如图 4 所示,相比于图 2 的模型,注意力机制的变化主要存在于编码器译码器之间,加入了注意力机制,影响了编码器和译码器之间的信息传递。

注意力机制中的关键步骤可以表示为计算新的上下文变量 c_i :

$$c_i = \sum_{j=1}^T \alpha_{ij} h_j \quad (1)$$

其中, h_j 对应于编码器的隐藏变量, α_{ij} 对应于式(2),由 e_{ij} 决定。

$$\alpha_{ij} = \frac{\exp e_{ij}}{\sum_{k=1}^T \exp e_{ik}} \quad (2)$$

其中, e_{ij} 由编码器和译码器的不同时刻的隐藏变量共同决定,为:

$$e_{ij} = \text{get_score}(s_j, h_j) \quad (3)$$

其中,函数 $\text{get_score}(\cdot)$ 为得分函数,不同的策略可以有不同的得分函数,详情参考文献[15]。

4)预测机制。在 seq2seq 模型训练完成后,需要通过输入对翻译的输出进行预测。由于模型中,前面一个




图 4 带注意力机制的 seq2seq 模型

Fig. 4 Seq2seq model with the attention mechanism

状态的输出会影响到后面的输出,因此,总是利用贪心算法,计算当前输出概率最大的单词作为输出的策略,可能存在错误的情况,影响到整体的输出质量。通常来说,利用 BeamSearch 算法,计算几个连续输出概率最大的序列从而避免译码器的输出发生的错误影响到后面的输出。

由于翻译任务与 WLAN 定位任务有着如下的相似性,因此 seq2seq 模型同样适用于 WLAN 定位任务。首先,两者的输出输出都是前后关联的序列。特别是在 WLAN 定位任务中,信号强度指纹和位置都是前后关联的序列。其次,两种不同的应用中,其输入输出都是可变长度的。在 WLAN 定位应用中,存在如下情况:有时要求采集到一个信号强度指纹后立即输出当前的位置估计,有时允许一定的延迟,在连续获得几个信号强度指纹后,再估计当前的位置。

1.2 基于 seq2seq 模型的 WLAN 定位方法

在 WLAN 定位中,与自然语言的翻译任务虽然存在较多的相似性,也存在一些有关任务的独特之处,因此在 seq2seq 模型的应用过程中需要一些特殊处理。这些需要特殊处理的地方主要体现在输入输出的预处理,特别是输入的信号强度指纹信号,由于信号的衰落等原因,测量得到的信号强度有较大的噪声,并且信号的维度不同,不能直接作为神经网络的输入,因此需要对输入信号进行预处理;另外,由于 seq2seq 模型在训练时需要较多数量的样本,而在实际应用中,采集大量的已知几何坐标位置的较难实现。需要根据已有的样本,生成新的序列作为输入。本文提出的基于 seq2seq 的方法考虑到了以上提到的两点,下面对该方法进行详细论述。

1) 样本数据预处理

在 WLAN 的定位中,所用到的用于定位的信息是信号强度指纹信息。该信息在实际的应用中有着如下的特

点^[10]:(1)噪声较大,引起噪声的原因有很多。首先由于信号的衰落现象严重,较小的位置偏移可能导致信号强度的较大变化。其次,环境的动态变化,如人员的移动,人员的朝向的变化等,导致接收信号强度产生变化,最后是信号本身的热噪声。(2)信号维度的缺失。通常来说,即使保持人员的位置不变,对于某些 WLAN 路由器的信号时而可见时而不可见,导致信号维度的缺失。该问题从本质上来说,也是噪声导致的问题。(3)信号维度的不同。在一些位置能够观察到的信号强度的维度与其他位置不一样,这种现象在较大的定位场景中尤其明显。(4)由于信号采集平台的不同导致的信号强度的分布不同问题。该问题在 WLAN 定位中较为明显。通常来说在训练过程中,采集信号的软硬件平台是可控的,然而在实际的定位过程中,不同的用户的软硬件平台不同,就算在相同的环境中,采集到的信号强度指纹观测的分布也不同,需要进行归一化处理。

为了解决上述的问题,需要对信号强度指纹进行预处理。本文中的预处理主要有如下 3 个步骤。

(1)对指纹信号进行维度变化,使得所有的信号指纹有相同的维度。如式(4)所示,首先求数据集的所有信号强度指纹中不同路由器的集合,该集合是数据集中不同信号强度指纹的路由器集合的并集,算子 $Set\{\cdot\}$ 表示对某信号强度指纹求路由器集合。

$$S_{all} = \cup \{Set\{RSS_1\}, Set\{RSS_2\}, Set\{RSS_3\}, \dots\} \quad (4)$$

根据 S_{all} 求得所有路由器集合与单独的信号强度中的路由器集合 $Set\{RSS_i\}$ 进行比较,将 RSS_i 中不存在的路由器的信号强度设置为一个默认值。在补齐的过程中,将 RSS_i 中不存在的路由器的信号强度设置为一个默认值。该默认值表示该路由器发出的信号淹没在了环境噪声中。该假设利于实际工程上的应用,是目前 WLAN 信号指纹定位方法中存在的一个普遍假设^[9-10]。不同的方法在默认的底噪数据中存在较小不同。该默认值表示该路由器发出的信号淹没在了环境噪声中。

(2)对信号指纹进行滤波平滑处理。该过程主要是为了减少信号强度观测中的噪声的影响。本文中,采用文献[13]的经典的低通滤波的方法,该方法中的滤波器幅度响应如图 5 所示。该滤波器系数经过文献[13]的验证,为最佳的滤波器,本文中直接采用。

(3)信号的归一化。为了解决信号强度在不同软硬件采集的条件下分布不同的问题,需要对信号强度进行归一化处理。归一化处理后,所有的信号强度都分布在区间 $[0, 1]$ 中,处理方法如下:

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

式中: s_{raw} 为原始的信号强度; s_{norm} 为归一化后的信号强




图 5 滤波器的幅度响应

Fig. 5 The amplitude response of the proposed filter

度; s_{max} 和 s_{min} 分别为信号强度中的最大值和最小值。

2) 训练样本采集方法

seq2seq 模型通常需要较多的训练样本,从而能够学习到不同种类序列之间的关系。在 WLAN 定位中,仅仅依靠人员在室内环境中进行标记行走,样本数据十分有限,因此本文提出对原始采集到的信号样本进行一定的处理,从而从已有的样本中生成新的样本,达到增加样本数据的目的。本文主要通过三种方式增加样本的数目。

首先,通过不同的滑窗长度划分行走轨迹,产生不同长度的子轨迹样本。对于单点定位样本的训练,由于其与多点定位的网络共享网络参数,因此虽然单点训练部分的均方误差(mean square error, MSE)没有变化,但是网络的整体输入输出发生了变化,也会影响单点定位的训练。训练后的网络能够更好地捕捉序列的前后关系,因此具备提高定位精度的潜能。其次,通过改变轨迹的顺序,如轨迹逆向,增加样本数目。最后,如图 6 所示,通过相近的轨迹点生成新的轨迹。图 6 的两个相交的轨迹中,如果存在两个相交的点,则可以按照交点在两个不同的轨迹中切换,从而生成新的轨迹,该图中按照该方式可以生成 4 条新的轨迹,从而产生新的样本。通过交叉点生成新样本序列的方法加入注意力机制对定位精度不会产生负面影响。原因为注意力机制增强了神经网络中当前信号指纹输入和当前位置估计的对应关系,而通过交叉点生成新样本不会对这种对应关系产生影响。

3) 网络结构及损失函数

本文中所用到的 seq2seq 网络的结构如图 7 所示,将两个 LSTM 单元进行级联,生成一个深度的 RNN 网络。该网络中,输入为预处理后的不同长度的信号强度序列,输出为二维的归一化的坐标位置。此处,坐标位置的归一化(式(6))与信号强度的预处理归一化(式(5))类似。

$$p_{norm} = \frac{p_{raw} - p_{min}}{p_{max} - p_{min}} \quad (6)$$

其中, p 表示位置空间中的横坐标或纵坐标。该网络的输出序列是位置坐标的序列,该序列不需要原始 seq2seq 模型中的词嵌入,因为坐标域已经能够较好地衡量近邻关系。




图 6 增加轨迹样本

Fig. 6 A method for increasing the number of trajectory samples




图 7 基于 seq2seq 定位的整体模型

Fig. 7 The overall model for seq2seq based positioning method

由于网络的输出为归一化的坐标域位置,因此该网络与传统网络不同的是该网络是一个回归网络,而不是分类网络。因此,本文直接利用最小 MSE 作为训练的损失函数:

$$MSE = \sum_{i=1}^N [(x_i^{pred} - x_i^{sample})^2 + (y_i^{pred} - y_i^{sample})^2] \quad (7)$$

式中: x_i^{pred} 、 x_i^{sample} 、 y_i^{pred} 、 y_i^{sample} 分别为预测的横坐标、样本横坐标、预测纵坐标、样本纵坐标。本文用到的训练框架为 Tensorflow,采用的优化算法为 Adam 算法,步长设置为 0.05,并且学习步长根据训练循环进行指数衰减。

2 实验分析

为了能够更加充分地说明本文提出的基于 seq2seq 模型的定位方法的有效性,采集了数据集对方法进行了验证。该数据集在办公室环境内采集,具有较好的代表性,其包含了不同楼层、不同硬件型号的信号、不同的人

员采集的数据。采集数据集时,通过人员在环境内行走,利用智能手机在行走过程中连续采集过程中的信号强度指纹,并且通过已知的室内起始点和结束点获得不同时刻的人员位置。通过实验,本文分别验证了信号预处理的滤波、LSTM 层数、注意力机制、样本增加机制对方法性能的影响。最后将本文提出的方法与传统的几种基于神经网络的 RFSM 方法、去噪自编码器 DAE 方法、f-RNN 方法进行了对比,充分说明了本文提出的方法的有效性。

2.1 信号强度预处理对精度的影响

信号强度维度补齐和滤波是信号强度预处理的重要步骤。在维度补齐的过程中,需要设置默认的底噪参数。为了验证底噪参数对定位精度的影响,加入了不同底噪参数影响的实验。如表 1 所示,当底噪参数分别为-100、-110 和-120 dBm(3 个典型值)时,平均定位精度分别为 4.4、4.0 与 4.3 m。因此本文取-110 dBm 作为环境中的噪声水平。

表 1 不同底噪参数对平均定位精度的影响

Table 1 The effect of different noise level parameter over the average positioning accuracy	
底噪参数/dBm	平均定位精度/m
-100	4.4
-110	4.0
-120	4.3

而预处理中的滤波步骤可以在一定程度上克服采集到的信号强度噪声。图 8 所示为加入信号强度滤波过程对定位的误差积分分布曲线(cumulative density function, CDF)的影响。可以看出,在其他参数或条件相同的情况下,加入信号强度滤波预处理过程能够有效提高定位精度,其平均定位误差降低了 0.7 m。




图 8 信号强度预处理的影响

Fig. 8 The effect of pre-processing signal strength

2.2 LSTM 层数对精度的影响

通常来说,增加网络的深度对提高精度有着有利的影响。本文中比较了 LSTM 层数分别为 1 和 2 时对定位

精度的影响。由于 seq2seq 较难训练的特性,此处仅比较了层数分别为 1 和 2 的影响,对更多层数的影响将在后面进行研究。图 9 所示为 LSTM 层数分别为 1 和 2 的不同 CDF 曲线,此处加深 LSTM 一层,对平均定位精度的提高较为有限,仅为 0.9 m。




图 9 LSTM 层数的影响

Fig. 9 The effect of number of layers of LSTM

2.3 注意力机制的影响

从原理上来说,注意力机制在定位过程中有着较为重要的作用。在定位过程中,不同的信号强度指纹与坐标位置存在一定的对应关系,利用 seq2seq 模型可以更好地利用前后相关的信息,但不能通过不采用注意力模型放弃信号指纹与位置的一一对应关系。如图 10 所示,注意力机制的确对定位精度有着较大的影响,取消注意力机制后,平均定位精度由 4.0 下降至 5.4 m。




图 10 注意力模型对精度的影响

Fig. 10 The effects of attention mechanism over performance

2.4 样本增加机制的影响

本文提出的样本增加机制,通过变化的滑窗长度、变化的轨迹方向,以及新生成的轨迹丰富已有的样本数目。该样本增加过程可以看做是对原数据集的增加。由于 seq2seq 的特性,对数据集进行增强,能够帮助神经网络更好地学习到序列前后的关系,并利用该关系提高定位

精度。图 11 所示为样本增强机制对定位曲线的影响,可以看出,增强样本后,定位精度的提高较为明显,提高了约 1.7 m。




图 11 数据增强的影响
Fig. 11 The effects of data augmentation

表 2 对不同因素在定位精度的影响进行了总结。可以看出,对定位精度提高的最大两个影响因素分别为加入注意力机制和对数据集进行增强。

表 2 不同因素对平均定位精度的影响

Table 2 The effect of different aspects over the average positioning accuracy	
因素	精度提高/m
滤波预处理	0.7
加深 LSTM 层数	0.9
加入注意力机制	1.4
样本增强	1.7

2.5 与其他的方法的横向比较

本文方法的一些因素对方法本身定位精度有影响,将这些因素设置好后,(即加入信号预处理滤波,将 LSTM 设置为 2 层,加入注意力机制,进行样本增强),本文的方法与经典的基于神经网络的 RFSM 方法、去噪自编码器 DAE 方法、f-RNN 方法 3 种方法进行了精度对比。其不同的 CDF 曲线如图 12 所示,结果显示了本文的方法由于是基于序列的,能够更好地利用信号或坐标位置序列的前后关系,定位精度更好。如表 3 所示,相比于 RFSM 方法、去噪自编码器 DAE 方法、f-RNN 3 种方法,平均定位精度分别提高了 1.2、0.5 和 1.0 m,提高的百分比分别为 23%、11%和 20%。

表 3 不同方法平均定位精度对比

Table 3 Comparisons of accuracies over different methods	
方法	平均精度/m
本文方法	4.0
RFSM	5.2
DAE	4.5
f-RNN	5.0




图 12 方法对比
Fig. 12 Method comparisons

3 结 论

由于 seq2seq 模型能够学习到可变量长度的不同序列之间的相关性,在自然语言处理的翻译任务中有着重要的应用。该模型同样适用于室内的基于 WLAN 的定位,该定位问题中,需要寻找信号空间的时间序列和坐标空间的时间序列的对应关系。本文提出将 seq2seq 模型应用于 WLAN 人员定位任务中。通过一系列的处理过程,包含信号强度预处理、数据样本增强等,能够使 seq2seq 模型适用于定位任务。实验结果表明,本文提出的方法相比于如下几种基于神经网络的定位方法,基于度量学习的 RFSM 方法,基于降噪自编码器的 DAE 方法,和典型的 f-RNN 方法,在相同的数据条件下,平均定位误差分别下降了 1.2、0.5 和 1.0 m,对应的百分比为 23%、11%和 20%。

参考文献

[1] 梁韵基,周兴社,於志文,等. 普适环境室内定位系统研究[J]. 计算机科学, 2011, 37(3):112-116.
LIANG Y J, ZHOU X W, YU ZH W, et al. Analysis of the indoor positioning systems in pervasive environment [J]. Computer Science, 2011, 37(3):112-116.

[2] ZAFARI F, GKELIAS A, LEUNG K K, et al. A survey of indoor localization systems and technologies[J]. IEEE Communications Surveys & Tutorials, 2017, 3 (2): 23-37.

[3] 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, 2019,33(6): 23-37.
ZHANG Y, LENG L. Graph optimization based indoor positioning method using bluetooth low energy [J]. Journal of Electronic Measurement and Instrument, 2019,33(6): 23-37.

[4] 马旭攀,惠飞,景首才,等. 一种基于蓝牙信标的室内定位系统[J]. 测控技术, 2016, 35(4):55-58,66.

- MA X P, HUI F, JING SH C, et al. An indoor positioning system based on bluetooth beacons [J]. Measurement Control Technology, 2016, 35 (4): 55-58,66.
- [5] MEDINA C, SEGURA J, DE A. Ultrasound indoor positioning system based on a low-power wireless sensor network providing sub-centimeter accuracy[J]. Sensors, 2013, 13(3): 3501-3526.
- [6] FILONENKO V, CULLEN C, CARSWELL J. Indoor positioning for smartphones using asynchronous ultrasound trilateration [J]. ISPRS International Journal of Geo-Information, 2013, 2(3): 598-620.
- [7] YANG S H, JEONG E M, KIM D R, et al. Indoor three-dimensional location estimation based on LED visible light communication [J]. Electronics Letters, 2013, 49(1): 54-56.
- [8] XU W, WANG J, SHEN H, et al. Indoor positioning for multiphotodiode device using visible-light communications[J]. IEEE Photonics Journal, 2015, 8(1): 1-11.
- [9] SCHÜSSEL M. Angle of arrival estimation using WIFI and smartphones [C]. Proceedings of the International Conference on Indoor Positioning and Indoor Navigation (IPIN), 2016(7): 343-354.
- [10] DONG B, BURGESS T, NEUNER H B, et al. Neural network based radio fingerprint similarity measure [C]. International Conference on Indoor Positioning and Indoor Navigation (IPIN), 2018: 1-8.
- [11] ZHANG W, LIU K, ZHANG W, et al. Deep neural networks for wireless localization in indoor and outdoor environments [J]. Neurocomputing, 2016 (194): 279-287.
- [12] HSIEH H Y, PRAKOSA S W, LEU J S. Towards the implementation of recurrent neural network schemes for WIFI fingerprint-based indoor positioning [C]. IEEE 88th Vehicular Technology Conference (VTC-Fall), 2018: 1-5.
- [13] LUKITO Y, CHRISMANTO A R. Recurrent neural networks model for WIFI-based indoor positioning system [C]. IEEE International Conference on Smart Cities, Automation & Intelligent Computing Systems (ICON-SONICS), 2017: 121-125.
- [14] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks [J]. Advances in NIPS, 2014: 123-143.
- [15] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate [J]. Computer Science, 2014, 3(3): 23-34.
- [16] BIAN J, GAO B, LIU T Y. Knowledge-powered deep learning for word embedding [C]. Joint European Conference on Machine Learning and Knowledge Discovery in Databases, Springer, 2014: 132-148.
- [17] 燕必希, 朱立夫, 董明利, 等. 卡尔曼滤波波单目相机运动目标定位研究 [J]. 仪器仪表学报, 2018, 39(8): 220-229.
- YAN B X, ZHU L F, DONG M L, et al. Research on Kalman filtering for moving target location on monocular camera [J]. Chinese Journal of Scientific Instrument, 2018, 39(8): 220-229.

作者简介



邢方方, 2005年毕业于中央广播电视大学, 现为许昌电气职业学院讲师, 主要研究方向为计算机通信、网络应用研究。

E-mail: ffwwork@sina.com

Xing Fangfang graduated from Open University of China in 2005. Now she is a lecturer of Xuchang Electric Vocational College. Her main research direction is computer communication and network application research.



惠向晖, 2003年于郑州大学获得学士学位, 2011年于解放军信息工程大学获得硕士学位, 现为河南农业大学教师, 主要研究方向为云计算、智能机器人技术。

E-mail: truhui@sina.com

Hui Xianghui received his B. Sc. degree from Zhengzhou University in 2003, and M. Sc. degree from Information Engineering University in 2011. Now he is a teacher at Henan Agricultural University. His main research interests include cloud computing and Intelligent robot technology.