

文章编号:1007-5321(2021)01-0026-06

DOI:10.13190/j.jbupt.2019-210

基于生成对抗网络模型的 RSS 缺失值预测

任晓琪, 翁仲铭

(天津大学 智能与计算学部, 天津 300350)

摘要: 无线上网(Wi-Fi)定位是目前室内定位中的主流方法,指纹数据库的构建是 Wi-Fi 定位系统的关键。然而指纹数据库中的接收信号强度(RSS)指纹值会随室内环境的变化而变化,通常需要不断地重新测量指纹值去更新指纹数据库,这就导致了成本高、耗时长,尤其是在定位区域较大的动态环境中是不切实际的。针对此问题,提出了自适应上下文生成对抗网络模型。该模型只需测量指纹数据库中的部分 RSS 指纹,即“参考点”,然后通过学习参考点的分布情况,预测特定位置的缺失指纹。仿真实验结果表明,室内定位精确性显著提高,人力成本大大减少。

关键词: 接收信号强度指纹数据库;生成对抗网络;室内定位系统

中图分类号:TN932

文献标志码:A

RSS Missing Value Estimation with Generative Adversarial Networks Model

REN Xiao-qi, OWN Chung-ming

(College of Intelligence and Computing, Tianjin University, Tianjin 300350, China)

Abstract: Wireless-fidelity(Wi-Fi)positioning is currently the mainstream method in indoor positioning, and the construction of fingerprint database is the key to Wi-Fi positioning system. However, the received signal strength(RSS)value in the fingerprint database will be changed with the variability of the indoor environment, and it is usually need to constantly re-measure the value in the fingerprint database, which leads to high cost and long time, especially in the dynamic environment with large positioning area. To address this problem, the adaptive context generative adversarial networks model is proposed. The model only needs to measure part of RSS fingerprints, and then learn the RSS fingerprints distribution to finally predict the missing fingerprint at a specific location. Simulation shows that the accuracy of indoor positioning is significantly improved, and the labor cost is greatly reduced.

Key words: received signal strength fingerprint database; generative adversarial network; indoor positioning system

对于下一代社交应用来说,准确、可靠和实时的室内定位协议和服务尤为重要。移动设备与定位系统联合使用可以确定用户的实时位置,例如跟踪、监控和导航。尽管全球定位系统(GPS, global positioning system)在室外定位的应用已经非常成熟,却不

适用于室内定位,原因是 GPS 发出的信号穿过建筑、墙壁后会变得非常微弱,无法进行准确的定位^[1]。因此,学者们提出了许多室内定位技术,例如红外线、超宽带、超声波、蓝牙、无线射频识别、无线个域网以及无局域网等技术^[2]。

收稿日期:2019-11-09

作者简介:任晓琪(1994—),女,硕士生,renxiaoqi@tju.edu.cn;翁仲铭(1970—),男,副教授。

近年来,边缘计算技术和无线上网(Wi-Fi, wireless-fidelity)技术日益发展,这也使得室内环境中的定位结果更加准确^[3]. 因此,结合 Wi-Fi 网络与移动设备提供的室内定位服务引起了广泛关注,例如在大型商场、机场、医院、地铁以及图书馆等. 在室内定位服务中,定位测量方法有许多不同选择,例如基于到达时间、到达时差、到达角度和接收信号强度. 大多数 Wi-Fi 室内定位商业模型采用的定位测量方法是接收信号强度(RSS, received signal strength)^[4]. 原因在于,室内定位中指纹数据库所需要的 RSS 指纹值可直接从移动设备上安装的网卡进行获取,也就是说,这种测量方法无额外的网络硬件成本. 伴随着 Wi-Fi 网络的兴起,这种定位模式为定位服务提供了一种有效的节约成本方案. 所以 Wi-Fi 室内定位越来越流行和普遍^[5].

一般来说,RSS 指纹是指每个位置上独一无二的信号值集合. 即一个 RSS 指纹可推断一个位置. RSS 指纹最大的问题是任何物理位置上的 RSS 指纹值随着时间的推移会受到不同的干扰而不断变化,干扰因素可能是多径衰落效应,或者是温湿度等^[6]. 因此,不同时间测量的 RSS 指纹与先前存储在数据库中的指纹存在差异,这会导致位置估计的错误. 也就是说,通过将当前收集到的 RSS 指纹与之前的指纹数据库进行比对从而估计位置,而此时的指纹数据库未进行更新,得到的结果很可能是预估位置与当前 RSS 指纹真正所对应的物理位置相距甚远. 所以,需要不间断地更新每个位置的 RSS 指纹来提高定位的准确性^[7].

但是,当室内定位区域面积非常大的时候,重新测量每个位置上的 RSS 指纹去更新指纹数据库不仅成本高而且任务繁重. 特别是干扰持续变化的定位区域,需要不断地更新指纹数据库. 显然,这是不切实际的. Yiu 等^[8]使用高斯过程回归(GPR, Gaussian process regression)进行 RSS 预测以解决室内定位问题. 他们首先在定位区域进行部分测量,然后再使用萤火虫算法(FA, firefly algorithm)对使用 GPR 得出的先验结果进行训练和分类,训练的结果用于构建整个定位区域的精确指纹数据库,为了论述清晰,将该方法命名为 GPR-FA^[8]方法. 然而,该方法计算比较复杂,消耗的时间较长,定位精度并没有较大提高. Liu 等^[9]针对 GPR-FA 方法进行改进,提出了高斯过程回归加强系统,首先通过高斯的先验分布来回归和预测先前未测量位置处的 RSS

指纹值,然后再采用朴素贝叶斯从高斯模型中选择所需预测的位置. 虽然相对于 GPR-FA 方法简化了计算、缩短了时间,也提高了定位精度. 但是在预测位置时,需要对位置信息的 x 值和 y 值分别进行计算,定位过程比较繁琐. 为了直接获得定位位置的 x 值和 y 值,进一步提高定位精度,Teng 等^[10]采用一种基于深度高斯过程回归(DGPR, deep Gaussian process regression)模型进行定位. 该模型只需要测量部分指纹即可,将 RSS 值转换为 4 种特征值作为输入数据,然后再由 DGPR 模型预测位置坐标,最后经过增强学习优化位置坐标. 然而,DGPR 方法的精确性还需要强化学习进一步优化,即定位结果需要再加工.

尽管基于 Wi-Fi 指纹定位的研究已经有了很多,但是指纹数据库的适应问题还没有得到充分的研究,仍然处于开放状态. 其原因是指纹数据库维护的重复性和初始化数据库的高实现开销. 生成对抗网络(GAN, generative adversarial networks)在学习高维、复杂的真实数据方面具有巨大的潜力. 例如,GAN 应用于无监督学习时,可以生成高维数据或复杂的概率分布. 受基于无监督像素预测视觉特征学习算法的启发,提出了自适应上下文生成对抗网络模型(ACO-GAN, adaptive context generative adversarial networks). 针对动态变化后的环境,重新测量之前的指纹数据库中部分 RSS 指纹(称为“参考点”),然后通过 ACO-GAN 模型学习参考点的分布情况,从而预测特定位置的 RSS 指纹(称为“缺失指纹”). 在室内定位领域中,这是一种新的方法,利用 GAN 网络去解决离线阶段测量数据高成本的问题,并且定位效果非常好.

1 相关工作

1.1 RSS 指纹

ACO-GAN 模型需要大量的实验数据,为了获取充足的实验数据、减少人力成本,采用仿真方法获取实验数据,也就是通过仿真方法生成 RSS 指纹. 对数距离衰减模型计算的 RSS 指纹值无法反映室内环境的复杂性,因此采用射线跟踪模型作为替代方法去生成 RSS 指纹数据. 射线追踪模型考虑了发射器和接收器之间发生的直接路径损耗,经过多个反射、衍射以及通过多个路径遇到的墙壁和地面的信号传输,最后叠加生成接收点上的 RSS 指纹值^[11].

1.2 GAN

GAN 不需要做进一步的分布假设,可以简单地从潜在空间中推断出真实样例. 这一强大的特性使得 GAN 被广泛应用于图像合成、图像属性编辑和图像语义分解等领域. 对于缺失数据较多的场景,可以用来生成更多的样例数据,是当前用来解决信息缺失的最好方式^[12]. 在动态变化的环境中,针对离线阶段测量数据高成本的问题,希望通过重新测量原指纹数据库中参考点,估计特定位置的缺失指纹. 图1所示为 GAN 网络与自编码器结合示意图,其上半部分为 GAN 网络结构,它包含生成器和判别器两部分. 生成器模拟真实数据的分布,生成一个与真实训练数据相似的样本,一般来说,噪声样本服从一定的分布,如均匀分布、高斯分布等. 判别器是从训练数据中估计样本概率的两分类器. 如果样本来自真实的训练数据,判别器输出高概率,反之输出低概率.

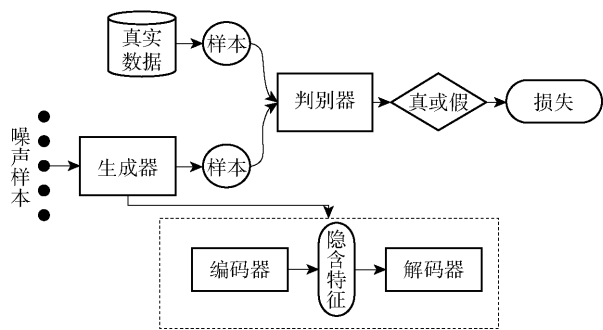


图1 GAN网络与自编码器结合

1.3 自编码器

自编码器是一种人工神经网络,在不需要任何监督的情况下,能够学习输入数据的有效表示形式,并提取为隐含特征,这一过程称为编码. 之后,通过对隐含特征进行重构,得到近似于原始输入数据的结果,并作为输出,这一过程称为解码. 所以把自编码器结构放入1.2节中的生成器中,将GAN网络重新优化,如图1所示. 自编码器的实现过程,如图2所示. 自编码器将输入的 x_1, x_2, x_3 编码生成对应的隐含特征,然后将隐含特征解码输出与 x_1, x_2, x_3 相似的 x'_1, x'_2, x'_3 .

2 系统设计

2.1 离线阶段

2.1.1 数据预处理

通过 ACO-GAN 模型学习参考点的分布情况




图2 自编码器的编码与解码过程

预测缺失指纹,但是有时参考点距离缺失指纹的物理位置较远,参考点未能很好地预测缺失指纹. Koweerawong 等^[7]提出物理位置越相近, RSS 指纹越相似;参考点与缺失指纹的距离越小,预测的缺失指纹可信度越高. 设置参考点的限制是围绕着缺失指纹的. 因此,将整个大的区域分割成更小的且大小一致的方块. 例如,图3所示为将一个房间定义为一个大小为 $m \times n$ 的整体区域. 将房间区域切割成若干个大小为 $k \times k$ 的2D方块. 若房间大小不能切割成整数个方块,可将方块元素重叠,以确保分割后的方块大小一致. 对于每个方块,随机选择 $i \times i$ ($i < k$) 的区域,对应3D-RSS指纹矩阵中的问号部分,称作“缺失指纹”,那么剩余区域就是“参考点”. 此外,假设该区域有 r 个无线路由器 (AP, access point), 则3D-RSS指纹矩阵的大小为 $k \times k \times r$, 将2D方块转换为3D-RSS指纹矩阵,如图3所示,将其作为ACO-GAN模型的输入矩阵.




图3 数据预处理

2.1.2 ACO-GAN模型

ACO-GAN模型由两部分组成:分别为自适应上下文生成器和自适应上下文判别器. ACO-GAN模型的问题场景是随时间变化而变化的动态环境,并且缺失指纹是由周围的参考点特征重构而来,这种行为被定义为“自适应上下文”. 因此,将自适应上下文生成器中的自编码器定义为上下文

编码器,上下文编码器的总体结构包括编码器、通道全连接层和解码器。编码器从输入数据中提取参考点的隐含特征,解码器根据这些隐含特征预测缺失指纹,即更新每个 3D-RSS 指纹矩阵。自适应上下文判别器是用来估计解码精度的两分类器,即将自适应上下文生成器预测的缺失指纹和缺失指纹对应的真实指纹数据输入自适应上下文判别器中,判别真假。

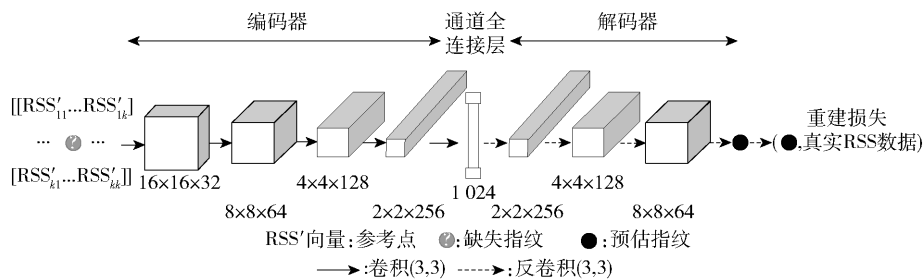


图 4 自适应上下文生成器详细结构

2) 通道全连接层

在自适应上下文生成器中,编码器和解码器的隐含特征大小为 $2 \times 2 \times 512$ 。如果将“编码器特征”和“解码器特征”以全连接的方式进行连接,会导致参数数量激增,以至于难以对当前的图形处理器进行有效的训练。为了缓解该问题,使用通道全连接层将“编码器特征”和“解码器特征”进行连接。该层本质上是组—全连接层,用于在每个特征映射的激活内传播信息。如果输入层具有大小为 $n \times n$ 的 m 个特征图,则该层将输出尺寸为 $n \times n$ 的 m 个特征图。与全连接的图层不同,它没有连接不同指纹块的参数,只在指纹块中传播信息。因此,与全连接层中的 $m^2 n^4$ 个参数相比,该通道全连接层中的参数数量是 mn^2 。

3) 解码器

解码器使用编码器产生的隐含特征预测缺失指纹。图 4 后半部分所示为解码器结构,其中,在通道全连接层之后是 3 个向上卷积层,其具有学习滤波器,每个滤波器具有整流的线性单元激活功能,其中卷积核大小依旧为 3×3 ,步长为 2。即,将 $2 \times 2 \times 256$ 维的隐含特征进行一系列非线性加权上采样,最终输出大小为 $8 \times 8 \times 64$ 的预估指纹。

2.1.2.2 自适应上下文判别器

图 5 所示为自适应上下文判别器的结构:使用 3 个卷积层和全连接层来对生成器预测的缺失指纹

2.1.2.1 自适应上下文生成器

1) 编码器

图 4 的前半部分所示为编码器详细结构:给定大小为 $32 \times 32 \times 6$ 的 3D-RSS 指纹矩阵(矩阵大小设置将于 3.1 节具体说明),使用 4 个卷积层和池化层来计算抽象的 $2 \times 2 \times 512$ 维指纹的隐含特征,其中卷积核大小为 3×3 ,步长为 2。当随机初始化权重后,训练整个模型来预测缺失指纹。

与真实的 RSS 指纹数据进行判别,其中预测缺失指纹大小为 $8 \times 8 \times 6$,卷积核大小为 3×3 ,步长为 2。




图 5 自适应上下文判别器详细结构

2.1.2.3 损失函数

通常存在多种同样合理的方式来生成与参考点分布情况一致的缺失指纹。受文献[13]的启发,通过解耦联合损失函数来模拟这种行为,以处理缺失指纹预测中的连续性和输出的多个模式。重建损失 (L_r) 函数负责捕获缺失指纹的整体结构和关于与参考点分布情况的一致性,但通常倾向于将预测缺失指纹过程中的多个模式平均在一起。此外,对抗损失 (L_a) 函数试图使预测的缺失指纹看起来真实,并具有从参考点分布情况中选择特定模式的作用。损失函数包含重建损失和对抗损失。

1) 重建损失

使用标准化的掩码欧式距离作为重建损失函数,如下:

$$L_r = \|\hat{M} \odot \{\mathbf{x} - G[(1 - \hat{M}) \odot \mathbf{x}]\}\|_2^2 \quad (1)$$

其中: \hat{M} 为二进制掩码,其值为 1 时,表示其为每个 3D-RSS 指纹矩阵中的缺失指纹,反之,其值为 0 时表示其为参考点; \mathbf{x} 为真实的 3D-RSS 指纹矩阵;

G 为生成器. L_r 促使自适应上下文生成器预测缺失指纹的粗略值,它通常无法捕获参考点的精确分布情况. 因为 L_r 预测分布均值更“安全”,这样可以最大限度地减少 RSS 指纹平均误差,但会导致 RSS 指纹值不准确. 以下使用对抗损失来缓解这个问题.

2) 对抗损失

$$L_a = \max_D E_{\mathbf{x} \in X} \{ \ln[D(\mathbf{x})] + \ln(1 - D[G((1 - \hat{M}) \odot \mathbf{x})]) \} \quad (2)$$

其中: D 为判别器,对抗损失在训练过程中, G 和 D 交替使用随机梯度下降进行优化. 对抗损失最终目标是使自适应上下文生成器预测的缺失指纹值更准确,而不是如式(1)所示仅预测出模糊的缺失指纹值.

3) 联合损失

联合损失函数定义为

$$L = \lambda_r L_r + \lambda_a L_a \quad (3)$$

在自适应上下文生成器中,联合损失被用来平衡重建损失和对抗损失之间的重要程度. 根据经验, λ_r 为 0.999, λ_a 为 0.001.

2.2 在线阶段

位置指纹法可以看作是分类或回归问题(特征是 RSS 向量,标签是位置),监督式机器学习方法可以从数据中训练出一个从特征到标签的映射关系模型. 而 k -近邻是一种很简单的监督式机器学习算法,可以用于分类或回归^[14]. 所以采取 k -近邻算法对 2.1 节更新后的 RSS 指纹数据库进行在线定位,通过选取与在线测得的 RSS 指纹最邻近的 k 个指纹的位置,从而估计其位置. 一般选择较小的 k 值,通常使用交叉验证来选择 k 的最显著值. 实验中 k 的选取范围一般为 5~7.

3 实验

3.1 实验环境

实验环境使用 Matlab R2017b 进行搭建.

第一,设置好房间尺寸为 32 m × 32 m,设置好各个 AP 的位置分别为 [1,1]、[10,1]、[19,1]、[1,14]、[10,14]、[19,14],使用射线跟踪计算每个位置的 RSS 指纹,位置点的间隔设为 0.01 m,计算一次射线跟踪后将数据保存起来,由于 ACO-GAN 模型需要大量训练数据,所以选择每隔 0.1 m 在刚刚保存的 RSS 仿真环境数据集进行均匀采样,从而获取 320 × 320 × 6 的大型离线指纹数据库.

第二,为了模拟第一部分房间中的环境的动态变化,调整房间中各个 AP 的位置分别为 [1,1]、[7,6]、[13,11]、[19,16]、[26,21]、[27,30]. 再次使用射线跟踪计算每个位置的 RSS 指纹,位置点的间隔设为 0.01 m,计算一次射线跟踪后将数据保存起来,选择每隔 0.1 m 在刚刚保存的 RSS 仿真环境数据集进行均匀采样,从而获取 320 × 320 × 6 的大型离线指纹数据库. 该数据库即为测试数据指纹库,其中部分指纹为参考点,剩余为缺失指纹对应的真实 RSS 指纹数据.

第三,在线定位测试数据:模拟一个目标在房间中运动,获得一条运动轨迹,每个轨迹点上的 RSS 指纹值,用作定位算法的测试数据.

3.2 实验结果

图 6 所示为 4 种方法定位误差的累积分布函数(CDF, cumulative distribution function)图. 由图 6 可见,指纹定位(FP, fingerprint)方法^[7]、GPR-FA 方法^[6]、DGPR 方法^[3]、ACO-GAN 方法在误差为 2 m 处的 CDF 分别为 0.28, 0.69, 0.7, 0.74, 其 CDF 达到最大值时相应的误差分别为 4.4 m, 12.13 m, 8.0 m, 6.2 m. 结果表明, ACO-GAN 方法具有良好的性能且保持了收敛距离的优势. 4 种方法的定位结果对比如表 1 所示,其中系统训练时间和在线预测时间以秒对的形式呈现. 结果表明,传统的 FP 方法^[7]易于设计和实现;然而,在指纹数据库的准备和在线预测方面,时间消耗很大. GPR-FA^[6]和 DGPR^[3]方法可以节省数据准备时间,平均误差也能保持良好的性能. 虽然,提出的 ACO-GAN 方法数据准备时间更长,但其预测误差较小,仅为 1.62 m. 在室内定位系统中,这个值是比较突出的. 因此,目前的结果表明,提出的 ACO-GAN 方法可以保留定位的准确率,减少人力成本.




图6 比较不同算法仿真定位误差的 CDF

表 1 4 种方法的定位结果比较

方法	仿真实验	
	耗时/s(训练,预测)	平均误差/m
FP	(4 201,1)	1.46
GPR-FA	(1 385,0.73)	4.88
DGPR	(1 316,0.58)	1.78
ACO-GAN	(3 841,0.33)	1.62

4 结束语

提出了一种新方法来动态更新具有高效率和减少人力的 Wi-Fi 指纹数据库. 首先需要测量参考点,然后使用提出的 ACO-GAN 模型学习参考点分布情况,ACO-GAN 是一种改进的生成式对抗网络模型,收敛速度快,预测的缺失指纹数据更加准确. 通过使用 ACO-GAN 模型,不间断地更新室内环境的 RSS 指纹数据库,可以有效地提高定位精确度. 实验结果表明,ACO-GAN 优于现有的构建指纹数据库的方法和定位方法.

参考文献:

[1] Opiela M, Frantiek Galík. Grid-based bayesian filtering methods for pedestrian dead reckoning indoor positioning using smartphones[J]. Sensors, 2020, 20(18): 5343-5374.

[2] Yu Feng, Jiang Minghua, Liang Jing, et al. 5G WiFi signal-based indoor localization system using cluster k-nearest neighbor algorithm[J]. International Journal of Distributed Sensor Networks, 2014, 10(12): 1-12.

[3] Li Wenjun, Chen Zhenyu, Gao Xingyu, et al. Multimodel framework for indoor localization under mobile edge computing environment[J]. IEEE Internet of Things Journal, 2019, 6(3): 4844-4853.

[4] Liu Hunghung, Liu Chun. Implementation of WiFi signal sampling on an android smartphone for indoor positioning systems[J]. Sensors, 2018, 18(1): 1-16.

[5] Pu Yuchi, You Peichun. Indoor positioning system based

on BLE location fingerprinting with classification approach[J]. Applied Mathematical Modelling, 2018, 62(10): 654-663.

[6] Tolza X, Acco P, Fourniols J Y, et al. Optimal uncalibrated RSS indoor positioning and optimal reference node placement using cramér-rao lower bound[J]. Journal of Sensors, 2019, 2019(11): 1-12.

[7] Koweerawong C, Wipusitwarakun K, Kaemarungsi K. Indoor localization improvement via adaptive RSS fingerprinting database[C]//International Conference on Information Networking. Bangkok: IEEE Computer Society, 2013: 412-416.

[8] Yiu S, Yang Kai. Gaussian process assisted fingerprinting localization[J]. IEEE Internet of Things Journal, 2017, 3(5): 683-690.

[9] Liu Kehan, Meng Zhaopeng, Own Chungming. Gaussian process regression plus method for localization reliability improvement[J]. Sensors, 2016, 16(8): 1-17.

[10] Teng Fei, Tao Wenyuan, Own Chungming. Localization reliability improvement using deep Gaussian process regression model[J]. Sensors, 2018, 18(12): 1-19.

[11] Renaudin O, Zemen T, Burgess T. Ray-tracing based fingerprinting for indoor localization[C]//International Workshop on Signal Processing Advances in Wireless Communications. Kalamata: IEEE, 2018: 1-5.

[12] Wang Jie, Zhang Liang, Wang Changcheng, et al. Device-free human gesture recognition with generative adversarial networks[J]. Internet of Things Journal IEEE, 2020, 7(8): 7678-7688.

[13] Pathak D, Krahenbuhl P, Donahue J, et al. Context encoders: feature learning by inpainting[C]//IEEE Conference on Computer Vision and Pattern Recognition. LasVegas: IEEE, 2016: 2536-2544.

[14] Hu Jiusong, Liu Hongli, Liu Dawei, et al. Reducing WiFi fingerprint collection based on affinity propagation clustering and WKNN interpolation algorithm[C]//2018 2nd IEEE Advanced Information Management. Xi'an: IEEE, 2018: 1-6.