

DOI:10.19651/j.cnki.emt.2415974

基于 cGAN-SAE 的室内定位指纹生成方法*

刘伟^{1,3} 王智豪^{2,3} 李卓^{1,3} 韦嘉恒^{2,3}

(1. 桂林理工大学物理与电子信息工程学院 桂林 541006; 2. 桂林理工大学计算机科学与工程学院 桂林 541006;
3. 桂林理工大学广西嵌入式技术与智能系统重点实验室 桂林 541006)

摘要: 针对室内定位中指纹采集成本高、构建数据集难等问题,提出了一种基于条件稀疏自编码生成对抗网络的室内定位指纹生成方法。该方法通过增加自编码器隐藏层和输出层,增强了特征提取能力,引导生成器学习并生成指纹数据的关键特征。利用指纹选择算法筛选出最相关的指纹数据,扩充至指纹数据库中,并用于训练卷积长短时记忆网络模型以进行在线效果评估。实验结果表明,条件稀疏自编码生成对抗网络在不增加采集样本的情况下,提高了多栋多层建筑室内定位的精度。与原始条件生成对抗网络模型相比,在 UJIIndoorLoc 数据集上的预测中,定位误差降低了 6%;在实际应用中,定位误差降低了 14%。

关键词: 室内定位;稀疏自编码器;指纹数据库;条件生成对抗网络;卷积长短时记忆网络

中图分类号: TN92 **文献标识码:** A **国家标准学科分类代码:** 510.1050

Indoor positioning fingerprint generation method based on cGAN-SAE

Liu Wei^{1,3} Wang Zhihao^{2,3} Li Zhuo^{1,3} Wei Jiaheng^{2,3}

(1. School of Physics and Electronic Information Engineering, Guilin University of Technology, Guilin 541006, China;

2. School of Computer Science and Engineering, Guilin University of Technology, Guilin 541006, China;

3. Guangxi Key Laboratory of Embedded Technology and Intelligent Systems, Guilin University of Technology, Guilin 541006, China)

Abstract: To address the issues of high fingerprint collection costs and the difficulty of constructing datasets in indoor positioning, a method for indoor positioning fingerprint generation based on a conditional sparse autoencoder generative adversarial network is proposed. This method enhances the feature extraction capability by adding hidden and output layers to the autoencoder, guiding the generator to learn and generate key features of fingerprint data. A fingerprint selection algorithm is used to filter out the most relevant fingerprint data, which is then added to the fingerprint database and used to train a convolutional long short-term memory network model for online performance evaluation. Experimental results show that the conditional sparse autoencoder generative adversarial network improves the accuracy of indoor positioning in multi-building, multi-floor environments without increasing the number of collected samples. Compared to the original conditional generative adversarial network model, the positioning error in predictions on the UJIIndoorLoc dataset is reduced by 6%, and in practical applications, the positioning error is reduced by 14%.

Keywords: indoor positioning; sparse autoencoder; fingerprint database; conditional generative adversarial network; convolutional long short-term memory network

0 引言

在当今数字化社会,室内定位技术的日益重要性促使人们对于在室内环境中获取精准位置信息的需求不断增长^[1]。无论是商业场馆、医疗机构,还是智能家居等居民用途,室内定位技术成为满足这一需求的关键技术之一^[2]。为了解决室内定位的问题,国内外学者提出了许多室内定

位技术,例如:蓝牙定位^[3]、RFID定位^[4]、可见光定位^[5]、Wi-Fi定位^[6]等。Wi-Fi室内定位技术因其依托室内大量设备的部署,并且还支持智能手机、可穿戴设备的优势而备受研究关注^[7]。

接收信号强度(received signal strength, RSS)以其对硬件要求低、覆盖范围广、低功耗等优点^[8],在Wi-Fi室内定位技术系统中得到了广泛应用。Yang等^[9]从网络分层、

收稿日期:2024-05-05

* 基金项目:国家自然科学基金(62362017)项目资助

稳定性和可访问性等方面对比了信道状态信息(channel state information, CSI)和 RSS 的性能,实验结果表明 RSS 在可访问性方面优于 CSI。Guo 等^[10]通过将采集到的 RSS 数据生成两种新型指纹特征,并利用这些特征进行指纹定位,以确定用户位置,成功应对了环境变化对 RSS 指纹定位的影响。基于 RSS 的指纹定位算法^[11]在定位精度上也取得了显著成果。通常,室内定位系统一般分为离线和在线两个主要阶段,离线阶段,专业人员在需要的参考点进行数据采集,并将采集到带有位置信息的 Wi-Fi 数据用于构建指纹数据集;在线阶段,系统根据当前环境中的 Wi-Fi 信号强度匹配已构建的指纹数据集,利用指纹定位算法预测用户的当前位置。因此,指纹数据集的构建以及及时更新对于指纹定位算法定位精度至关重要。

然而,在一些大型场景中,指纹数据集的构建是一项耗时而且体力劳动密集的工作,尤其在环境发生变化时,对于如何降低指纹数据集的构建成本,是基于指纹定位算法需要解决的重要问题。为了降低指纹数据集的构建成本,Zhou 等^[12]提出了 GrassMA 方法,利用 RSS 测量值、位置信息和未标记数据的时间戳信息丰富数据地图,但这种方法无法减少采集的样本数量。Belmonte 等^[13]提出了一种结合循环神经网络(recurrent neural network, RNN)和生成对抗网络(generative adversarial network, GAN)优点的新框架,该框架旨在从未知环境中部署的设备接收测量值,并恢复相关信息以计算用户路径和更新指纹数据库。与其他技术相比,该方法实现了 3% 的定位误差减少。Njima 等^[14]使用深度学习模型和 GAN 生成新的 RSS 数据,以扩展指纹数据库,与早期研究不同,Njima 建立了一个新标准来选择最真实的假指纹,也称为人造或合成指纹。与基准相比,作者的定位准确度提高了 15%。然而,Belmonte 和 Njima 等提出的模型在生成多栋多层指纹数据时效果不佳。条件生成对抗网络(conditional generative adversarial network, cGAN)作为 GAN 的扩展,在生成器和判别器之间引入了条件信息,使生成器可以根据给定的条件生成特定类型的样本数据。在此基础上,本文提出了一种基于条件稀疏自编码生成对抗网络(conditional sparse autoencoder generative adversarial network, cGAN-SAE)的室内定位指纹生成方法,相比于原始的 cGAN 模型,本文在 cGAN 生成器模型上增加自编码器隐藏层和输出层,增强特征提取能力,引导生成器学习并生成指纹数据的关键特征。然后利用指纹选择算法筛选出最相关的指纹数据,扩充至指纹数据库中,并用于训练卷积长短期记忆网络(convolutional neural network-long short-term memory, CNN-LSTM)模型以进行在线效果评估。实验结果表明,在不增加采集样本的情况下,提高了多栋多层建筑室内定位的精度。与原始 cGAN 模型相比,在 UJIIndoorLoc 数据集上的预测中,定位误差降低了 6%;在实际应用中,定位误差降低了 14%。

1 相关理论

1.1 稀疏自编码器

自编码器(autoencoder, AE)是一种特殊的多层前馈神经网络^[15],网络结构图如图 1 所示,可以看作由一个编码器 $h = f(x)$ 和一个生成重构信号的解码器 $r = g(h)$ 两部分组成。

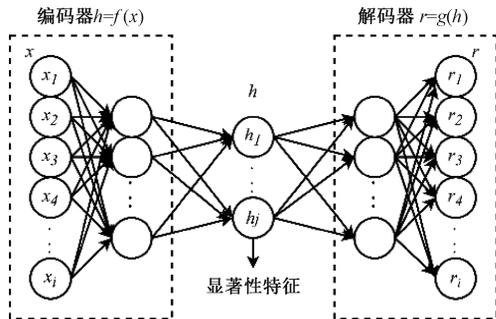


图 1 AE 原理图

Fig. 1 Schematic diagram of the AE

在学习时让解码器输出的目标值 r 接近于编码器的输入值 x , 经过训练后的网络能够尝试将输入复制到输出。训练自编码器目的是使 h 成为有用的特征,所以在网络中需要限制 h 的维度,使 h 的维度 j 小于输入向量 x 的维度 i 。稀疏自编码器(sparse autoencoder, SAE)是在 AE 的基础上引入隐藏层神经元的稀疏性约束来实现。该约束迫使部分神经元处于活跃状态,而另一部分神经元则处于抑制状态,从而使网络达到一种稀疏效果。为了实现这一目标,稀疏自编码器利用 KL 散度,将隐藏层神经元的平均激活值与给定的稀疏值相近,将其作为惩罚项添加到损失函数中,以实现隐藏层神经元的抑制效果。通过对隐藏层施加稀疏性限制,稀疏自编码器迫使模型将每个输入表示为少量激活的神经元组合。如果通过这些稀疏表达能够完美地重建原始输入信号,那么说明这些表达已经包含了原始信号的关键特征。这样的表达形式可以作为输入数据的一种简单表示,在保持模型重建精度的同时降低数据的维度^[16]。

1.2 条件生成对抗网络

在传统的 GAN 中,生成器的输入是随机噪声向量,而在 cGAN 中,生成器的输入不仅包括随机噪声向量,还包括额外的条件信息,如文本描述、标签或图像等。这样就允许生成器可以有针对性地生成给定楼层或建筑物的指纹数据。其网络结构图如图 2 所示。

该结构的关键组件为鉴别器和生成器。生成器的主要任务是生成更加真实的指纹数据,而鉴别器则致力于区分指纹的真假,即对生成的人工指纹与真实指纹进行分类,形成一个输出为 0 或 1 的二元分类器。在这个模型中,鉴别器和生成器通过对抗性训练相互影响,即随着鉴别器能力的提高,生成器的能力将下降,反之亦然,这种过程被称为

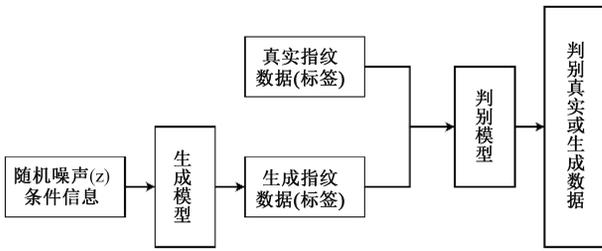


图 2 cGAN 网络结构图

Fig. 2 cGAN network architecture diagram

最大-最小博弈。在提出的模型中,通过引入条件标签 y , 本文能够有选择性地生成与特定条件相对应的逼真数据。具体来说,本文定义了生成对抗网络的优化目标函数 $V(D,G)$, 如式(1)所示。

$$\min_G \max_D V(D,G) = E_{\Psi \sim P_{data}(\Psi)} [\log D(\Psi | y)] + E_{z \sim P_z(z)} [\log 1 - D(G(\Psi | y))] \quad (1)$$

其中, D 是鉴别器, G 是生成器, 符号 Ψ 表示指纹数据, y 表示条件类别, z 表示噪声。通过对抗性学习,旨在训练生成器 G 以生成符合指定条件的更逼真的指纹数据,同时确保鉴别器 D 能够准确地判别生成的指纹数据和真实指纹数据。通过最大化 $V(D,G)$, 在每次迭代中通过梯度下降等算法调整生成器和鉴别器的参数,逐渐提高生成器的逼真程度和鉴别器的准确性。

2 cGAN-SAE 指纹生成方法

2.1 指纹生成流程设计

本文提出的 cGAN-SAE 指纹生成流程设计主要包括 4 个阶段:指纹数据集预处理、数据集扩充、定位模型训练和在线效果评估。在指纹数据预处理阶段,采用 MinMaxScaler 方法对经度、纬度和高度标签分别进行缩放,对楼层和建筑物标签采用 OneHotEncoder 进行编码,以降低数据复杂性,便于后续模型的训练。在数据集扩充阶段,训练 cGAN-SAE 指纹生成模型,分别使用楼层和建筑物不同的条件标签,分析这些条件标签对指纹生成效果的影响。利用指纹选择算法筛选出最符合要求的生成指纹数据,以扩充数据集。在定位模型训练阶段,使用扩充后的指纹数据集训练 CNN-LSTM 定位模型,以达到最优定位效果。在在线效果评估阶段,将实时数据经过预处理后,输入已经训练好的定位模型中进行效果评估。本文将在 2.2 和 2.3 节详细介绍 cGAN-SAE 模型的设计和指纹选择算法的具体操作。生成流程设计图如图 3 所示。

2.2 cGAN-SAE 生成模型结构设计

在原始的条件生成对抗网络,虽然添加条件标签可以有针对性地生成给定楼层或建筑物的指纹数据,但其是直接对噪声和向量进行全连接层和卷积反转层处理,当输入高维度数据包含大量噪声时,会直接影响生成器的生成效果,同时由于生成器的层数和复杂度不够,不能有效捕捉和

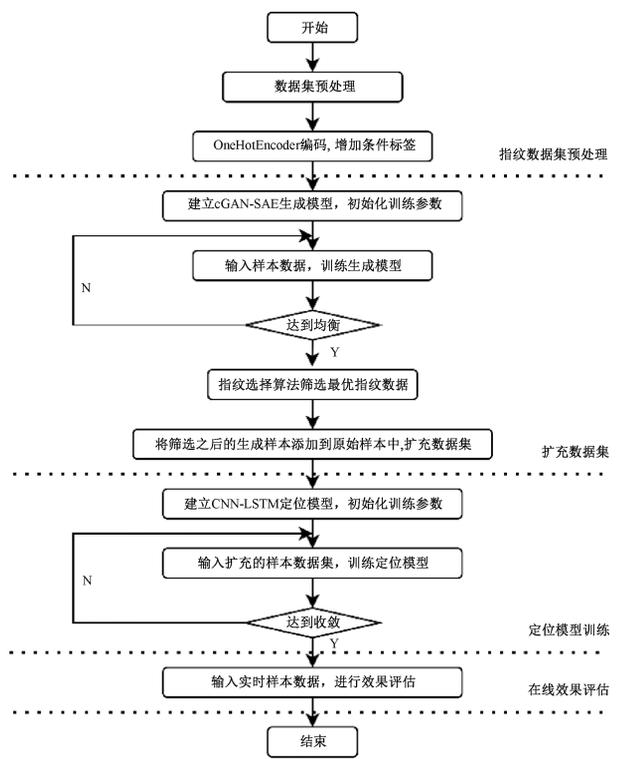


图 3 指纹生成流程设计图

Fig. 3 Fingerprint generation process flow diagram

生成复杂的多栋多层室内环境数据,进而无法有效提取输入数据中的有效关键特征,导致生成的数据质量不高。图 4 展示了 cGAN 与 cGAN-SAE 模型生成器结构对比,原始的 cGAN 生成器结构如图 4(a)所示,cGAN-SAE 生成器结构如图 4(b)所示。

cGAN-SAE 模型生成器相比于原来的 cGAN 模型生成器,增加了自编码器隐藏层、自编码器输出层和卷积反转层。自编码器隐藏层包含有 512 个隐藏单元,将高维度的输入数据投影到一个新的特征空间中,通过权重矩阵进行线性变换,再通过 ReLU 激活函数引入非线性变化,提取到更抽象、更具代表的指纹特征。然后自编码器输出层将隐藏单元的特征压缩到输出维度,通过 Sigmoid 激活函数将输出值限制在 $[0,1]$ 范围内,用于进一步提取特征,对数据进行平滑处理,减少了噪声的影响。额外增加的卷积反转层将特征图通道数从原来的 128 增加到 256,用以生成器捕捉数据中更多细节和复杂模式,生成更逼真和多样化的数据样本。

2.3 指纹选择算法

生成的新指纹无法判断其有效性,针对这一问题,本文设计了一种指纹选择算法,用以选择最相关的生成指纹数据。首先,在生成指纹的过程中,根据建筑物和楼层进行分组,针对每个建筑物和楼层的组合,计算生成指纹与训练集中真实指纹之间的欧式距离,然后取平均值,代表两个指纹之间的距离。欧氏距离计算如式(2)所示,在特征空间中,

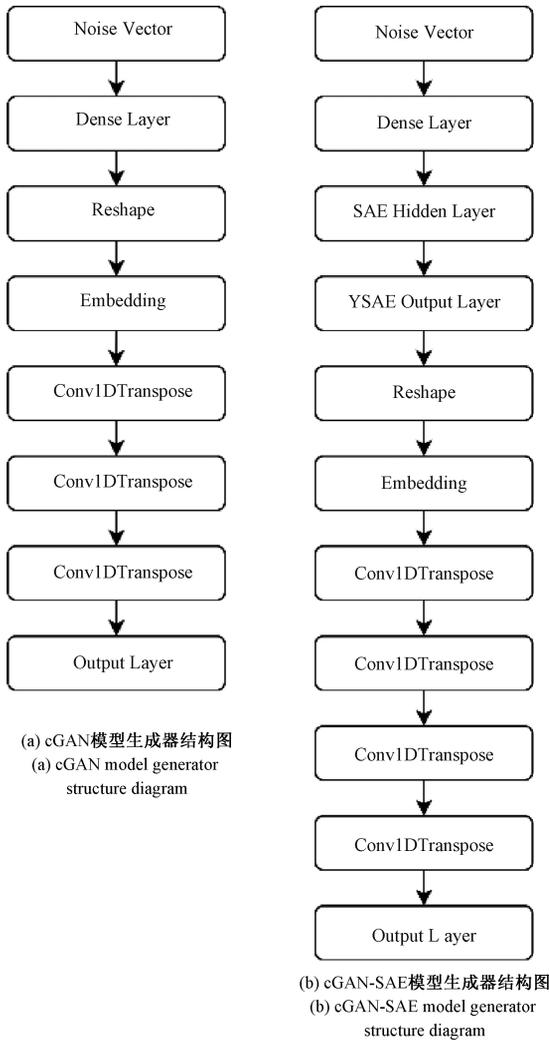


图 4 cGAN 与 cGAN-SAE 模型生成器结构对比图

Fig. 4 Comparison of generator structures between cGAN and cGAN-SAE models

$$x_i, x_j \in x, x_i = (x_i^1, x_i^2, \dots, x_i^n), x_j = (x_j^1, x_j^2, \dots, x_j^n).$$

$$\text{dis}(x_i, x_j) = \left(\sum_{l=1}^n |x_i^l - x_j^l|^2 \right)^{\frac{1}{2}} \quad (2)$$

设定两个参数:距离阈值和迭代次数,距离阈值表示生成指纹与真实指纹之间的距离,只选择在距离阈值范围内的生成指纹;迭代次数用以控制生成器每迭代生成一组指纹数据时,通过距离阈值选择最相关的指纹数据。最后将所有选择出的最相关指纹数据扩充到指纹数据集中,用以训练定位模型。通过迭代,可以生成多种组合的指纹数据,再经过筛选,不仅增加了生成指纹数据的多样性,还能够使生成的数据更全面地覆盖真实数据的特征。

3 实验设计与结果分析

3.1 实验设计

实验环境基于:Python 3.9、TensorFlow 2.6、Intel® Core™ i5-12500H 处理器。

为了验证本文所提出的 cGAN-SAE 室内定位生成方法在实际环境中的有效性,选择室内定位具有代表性的 UJIIndoorLoc 数据集,对 cGAN-SAE 模型进行训练并在 CNN-LSTM 定位模型上进行验证。验证过程中,使用测试样本从均方根误差和定位精度对 cGAN-SAE 模型生成指纹效果评估。

UJIIndoorLoc 数据集,下文中简称 UJI,其包含 3 栋建筑,每栋建筑包含 5 层,共有 19 937 条训练数据和 1 111 个验证记录组成。每条记录包含来自 520 个 AP 的接受信号强度、经纬度、建筑标号、楼层标号等。由于没有公开的测试集,本文参考 Song 等^[17]提出的拆分方法,按照 70% 训练集、10% 验证集、20% 测试集,重新对 UJI 数据集进行划分。为了降低数据的复杂性,本文按照文献^[18]所提到的建议重新设计了 UJI 数据集的数据表示,采用了 MinMaxScaler 对经度、纬度和高度标签分别进行缩放,具体缩放方法如式(3)所示,其中, X_{\min} 表示经度、纬度和高度标签的最小值, X_{\max} 代表经度、纬度和高度标签的最大值。同时,对楼层和建筑采用了 OneHotEncoder 进行编码。

$$X_{scaler} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (3)$$

3.2 结果分析

1) 不同条件标签对生成指纹效果的影响

为了研究不同条件标签对指纹生成效果的影响以及本文提出的改进策略的有效性,分别设置以楼层、建筑物为条件标签,训练 cGAN 模型和 cGAN-SAE 模型,生成同等数量的指纹数据扩充指纹数据集后,训练 CNN-LSTM 模型,对比在同一测试集下的定位效果。图 5 为 cGAN 模型和 cGAN-SAE 模型不同条件标签下定位效果对比,表 1 为 cGAN 模型和 cGAN-SAE 模型不同条件标签下定位误差。

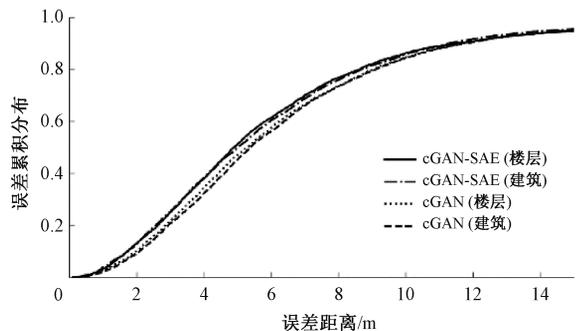


图 5 不同模型不同条件标签下定位效果对比

Fig. 5 Comparison of localization performance under different models and condition labels

可以看出,不同条件标签对指纹生成效果有显著影响。以楼层为条件标签时,cGAN-SAE 模型的均方根误差为 7.686 m,而以建筑物为条件标签时,该误差为 7.990 m。相应地,cGAN 模型在这两种条件下的均方根误差分别为 8.026 m 和 8.035 m。相比于 cGAN 模型,cGAN-SAE 模型在以楼层为条件标签时将定位误差降低了 4%。具体来

表 1 不同模型不同条件标签下定位误差

Table 1 Localization error under different models and condition labels

模型(标签)	均方根误差/m
cGAN(楼层)	8.026
cGAN-SAE(楼层)	7.686
cGAN(建筑物)	8.035
cGAN-SAE(建筑物)	7.990

说,cGAN-SAE 模型在以楼层为条件标签时,误差在 8 m 以内的比例为 76.81%,而 cGAN 模型为 73.59%;以建筑物为条件标签时,cGAN-SAE 模型在 8 m 以内的误差比例为 75.90%,而 cGAN 模型为 73.52%。cGAN-SAE 模型相比于原始的 cGAN 模型,自编码器隐藏层和输出层的引入增强了特征提取的深度和广度,而卷积反转层增加了特征图的细节捕捉能力。实验结果表明,这些改进提升了模型在不同条件标签下的定位精度,使得 cGAN-SAE 模型在定位准确性上有显著提升。

2) 指纹选择算法对扩充指纹库的影响

为了验证本文提出的指纹选择算法对指纹数据集扩充的影响,选择以楼层为条件标签,采用 cGAN-SAE 生成模型,生成同等数量的指纹数据,然后以直接扩充和经过指纹选择后再扩充两种方法,分别作为 CNN-LSTM 定位模型的训练集,对比在同一测试集下的定位效果。图 6 为两种扩充方法定位效果对比,表 2 为两种扩充方法定位误差。

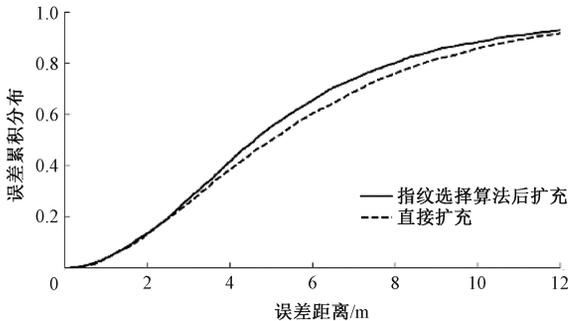


图 6 直接扩充与指纹选择算法扩充定位效果对比

Fig. 6 Comparison of localization performance between direct expansion and fingerprint selection algorithm expansion

表 2 直接扩充与指纹选择算法扩充定位误差

Table 2 Localization error between direct expansion and fingerprint selection algorithm expansion

扩充方式	均方根误差/m
直接扩充	7.686
指纹选择算法后扩充	7.557

可以看出,直接扩充的均方根误差为 7.686 m,误差在 8 m 以内的比例为 75.90%;经过指纹选择算法扩充后,均方根误差降低至 7.557 m,误差在 8 m 以内的比例提高到

80.00%,定位误差下降了约 2%。通过选择与真实指纹数据距离较近的生成指纹,减少了噪声和无效数据的影响,增强了指纹数据集的代表性和多样性。实验结果表明,本文提出的指纹选择算法有效地利用了生成指纹数据的特征,使模型在不增加实际数据采集成本的情况下,显著提升了定位性能。

3) 不同生成方法对比

将本文提出的基于 cGAN-SAE 室内定位生成方法与常用的基于 RNN-GAN 模型和 SSGAN 模型室内定位生成方法进行对比,分析其性能之间的差异。实验选用 UJI 数据集训练 3 种模型,生成同等数量的指纹数据。图 7 给出了 3 种生成方法在 CNN-LSTM 定位模型上的定位效果对比,表 3 是 3 种生成方法在 CNN-LSTM 定位模型上的定位误差。

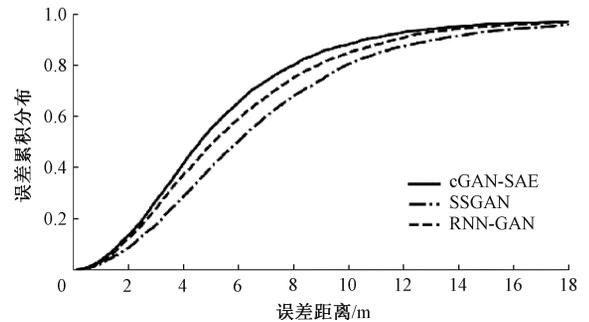


图 7 不同生成方法定位效果对比

Fig. 7 Comparison of localization performance among different generation methods

表 3 不同生成方法定位误差

Table 3 Localization error among different generation methods

模型	均方根误差/m
cGAN-SAE	7.557
RNN-GAN	7.909
SSGAN	9.299

从图 7 的曲线对比和表 3 的数据可以看出,本文提出的 cGAN-SAE 室内定位生成方法在定位误差方面表现优异。具体来说,该方法的定位误差在 8 米以内的比例为 80.00%,而基于 RNN-GAN 和 SSGAN 的室内定位生成方法,这一比例分别为 75.09% 和 67.99%。此外,cGAN-SAE 方法的均方根误差为 7.557 m,显著低于 RNN-GAN 的 7.909 m 和 SSGAN 的 9.299 m。在误差累积分布和定位误差方面,cGAN-SAE 方法均优于另外两种方法。实验结果表明,本文提出的 cGAN-SAE 室内定位生成方法在多栋建筑定位时具有显著优势。

4 应用与结果分析

4.1 实际应用案例设计

为了验证基于 cGAN-SAE 室内定位指纹生成方法在

实际环境中处理多栋多层建筑的定位效果,设计了一个包括 4 个阶段的应用案例:指纹数据集的构建及数据预处理,数据生成,训练定位模型和在线效果评估。在指纹数据集的构建及数据预处理阶段,在桂林理工大学教学楼 6 栋和 7 栋内进行实验。实验场地每栋楼包含两层,6 栋为第 3 层和第 4 层,7 栋为第 4 层和第 5 层。6 栋每层共有 10 个教室,7 栋每层共有 12 个教室。大教室布置 2 个 AP,小教室布置 1 个 AP,走廊共布置 7 个 AP,并记录每个 AP 的位置。实验场地平面图展示如图 8 所示,图 8(a)为教学楼 7 栋平面图,图 8(b)为教学楼 6 栋平面图,图中黑点为设定的 AP 位置。通过手机进行数据采集,在预定的测量点上扫描 Wi-Fi 信号,记录每个 AP 的 RSS 值及其 BSSID,同时记录测量点的实际坐标。数据采集完成后,构建指纹数据集并进行预处理,采用 MinMaxScaler 对经度、纬度和高度标签进行缩放,对楼层和建筑采用了 OneHotEncoder 进行编码,处理后的数据保存为 CSV 文件,用于后续分析和研究。在数据生成阶段,使用构建的指纹数据集训练 cGAN-SAE 模型,并与其他生成方法进行对比。在训练定位模型阶段,使用生成的数据训练 CNN-LSTM 定位模型,达到最佳效果。在在线效果评估阶段,将实时数据经过预处理后,输入训练好的定位模型中进行效果评估。通过这一系列步骤,验证本文提出的指纹生成方法在多栋多层建筑中的实际定位效果。4.2 节将详细分析实验结果。

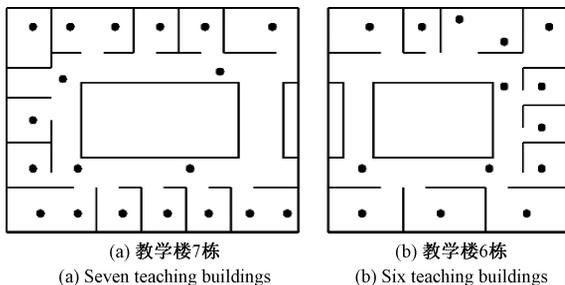


图 8 实验场地平面图

Fig. 8 Floor plan of the experimental site

4.2 结果分析

本文将提出的基于 cGAN-SAE 的室内定位生成方法与原始 cGAN 模型、常用的 RNN-GAN 模型以及 SSGAN 模型进行对比,以分析其性能差异。图 9 展示了 4 种生成方法在 CNN-LSTM 定位模型上的定位效果对比,表 4 则列出了 4 种生成方法在 CNN-LSTM 定位模型上的定位误差。

从图 9 的曲线对比和表 4 的数据可以看出,cGAN-SAE 生成方法的定位误差为 3.136 m,而基于 cGAN、SSGAN 和 RNN-GAN 生成方法的定位误差分别为 3.631 m、3.782 m 和 3.197 m。cGAN-SAE 生成方法的误差在 4 m 以内的比例为 80.64%,而 cGAN、SSGAN 和 RNN-GAN 生成方法分别为 65.87%、60.99% 和 78.78%。与原始 cGAN 方法相比,cGAN-SAE 将定位误差降低了 14%,并在与其他方

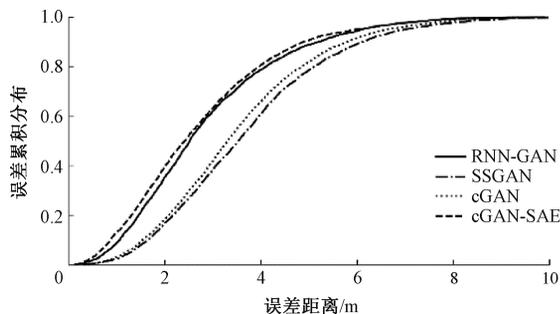


图 9 实际应用不同生成方法定位效果对比

Fig. 9 Comparison of localization performance of different generation methods in practical applications

表 4 实际应用不同生成方法定位误差

Table 4 Localization error of different generation methods in practical applications

模型	均方根误差/m
cGAN	3.631
cGAN-SAE	3.136
SSGAN	3.782
RNN-GAN	3.197

法的对比中显示出显著优势。实验结果表明,本文提出的 cGAN-SAE 生成方法在多栋多层建筑中的实际定位效果具有显著优势。

5 结 论

本文针对室内定位中指纹采集成本高、数据库构建难的问题,提出了一种基于 cGAN-SAE 的室内定位生成方法。相比于传统 cGAN 模型,cGAN-SAE 通过增加自编码器隐藏层和输出层,增强了特征提取能力,引导生成器学习并生成指纹数据的关键特征。随后,利用指纹选择算法筛选出最相关的指纹数据,并将其扩充至指纹数据库中。生成的指纹数据用于训练 CNN-LSTM 模型,以在在线阶段进行效果评估。

实验结果表明,在 UJI 数据集上的预测中,与未改进的 cGAN 模型相比,cGAN-SAE 将定位误差降低了 6%,在实际应用中,cGAN-SAE 将定位误差降低了 14%。此外,相较于其他常用的指纹生成方法,如 RNN-GAN 和 SSGAN,cGAN-SAE 在定位精度上也具有显著优势。这表明,在不增加采集样本的情况下,cGAN-SAE 在处理多栋多层建筑的室内定位任务时表现出显著优势。

参考文献

- [1] 周宇辉,朱晓强,曾丹.室内无线定位技术研究[J].工业控制计算机,2022,35(3):102-103,127.
ZHOU Z H, ZHU X Q, ZENG D. Research on indoor wireless positioning technology[J]. Industrial Control Computer, 2022, 35(3): 102-103,127.

- [2] 胡佳焯, 梁中华, 张培琰, 等. 基于深度学习的 WiFi 指纹室内定位方法[J]. 计算机与数字工程, 2022, 50(11): 2485-2489.
HU J Y, LIANG ZH H, ZHANG P W, et al. Deep learning-based WiFi fingerprint indoor positioning method[J]. Computer and Digital Engineering, 2022, 50(11): 2485-2489.
- [3] SPACHOS P, PLATANIOTIS K N. BLE beacons for indoor positioning at an interactive IoT-based smart museum[J]. IEEE Systems Journal, 2020, 14(3): 3483-3493.
- [4] VENA A, ILLANES I, ALIDIERES L, et al. RFID based Indoor Localization System to Analyze Visitor Behavior in a Museum[C]. 2021 IEEE International Conference on RFID Technology and Applications (RFID-TA). IEEE, 2021: 183-186.
- [5] GUO X, HU F, ELIKPLIM N R, et al. Indoor localization using visible light via two-layer fusion network[J]. IEEE Access, 2019, 7: 16421-16430.
- [6] 吴雅琴, 陈林, 侯云峰. 基于 CNN-GAN 的信道状态信息室内定位算法[J]. 电子测量技术, 2023, 46(24): 119-126.
WU Y Q, CHEN L, HOU Y F. Indoor positioning algorithm based on CNN-GAN using channel state information[J]. Electronic Measurement Technology, 2023, 46(24): 119-126.
- [7] 杨敏, 刘思怡. 一种基于先验信息的 WiFi 室内定位方法[J]. 电子测量与仪器学报, 2023, 34(6): 163-168.
YANG M, LIU S Y. A WiFi indoor positioning method based on prior information[J]. Journal of Electronic Measurement and Instrumentation, 2023, 34(6): 163-168.
- [8] DONG Y, ARSLAN T, YANG Y. Real-time nlos/los identification for smartphone-based indoor positioning systems using wifi rtt and rss [J]. IEEE Sensors Journal, 2021, 22(6): 5199-5209.
- [9] YANG Z, ZHOU Z, LIU Y. From RSSI to CSI: Indoor localization via channel response [J]. ACM Computing Surveys(CSUR), 2013, 46(2): 1-32.
- [10] GUO X, ELIKPLIM N R, ANSARI N, et al. Robust WiFi localization by fusing derivative fingerprints of RSS and multiple classifiers[J]. IEEE Transactions on Industrial Informatics, 2019, 16(5): 3177-3186.
- [11] XUE J, LIU J, SHENG M, et al. A WiFi fingerprint based high-adaptability indoor localization via machine learning[J]. China Communications, 2020, 17(7): 247-259.
- [12] ZHOU M, TANG Y, NIE W, et al. GrassMA: Graph-based semi-supervised manifold alignment for indoor WLAN localization[J]. IEEE Sensors Journal, 2017, 17(21): 7086-7095.
- [13] BELMONTE HERNANDEZ A, HERNANDEZ PENALOZA G, GUTIÉRREZ D M, et al. Recurrent model for wireless indoor tracking and positioning recovering using generative networks [J]. IEEE Sensors Journal, 2019, 20(6): 3356-3365.
- [14] NJIMA W, CHAFII M, CHORTI A, et al. Indoor localization using data augmentation via selective generative adversarial networks [J]. IEEE Access, 2021, 9: 98337-98347.
- [15] 诸燕平, 谭强志. 基于 SAE-SVM 算法的振动信号定位方法研究[J]. 电子测量技术, 2022, 45(16): 15-20.
ZHU Y P, TAN Q ZH. Research on vibration signal positioning method based on SAE-SVM algorithm[J]. Electronic Measurement Technology, 2022, 45(16): 15-20.
- [16] YUAN F N, ZHANG L, SHI J T, et al. Theories and applications of auto-encoder neural networks: a literature survey[J]. Chinese Journal of Computers, 2019, 42(1): 203-230.
- [17] SONG X, FAN X, XIANG C, et al. A novel convolutional neural network based indoor localization framework with WiFi fingerprinting[J]. IEEE Access, 2019, 7: 110698-110709.
- [18] TORRES SOSPEDRA J, RICHTER P, MOREIRA A, et al. A comprehensive and reproducible comparison of clustering and optimization rules in wi-fi fingerprinting[J]. IEEE Transactions on Mobile Computing, 2020, 21(3): 769-782.

作者简介

刘伟, 副教授, 主要从事室内定位, 无线传感器网络方面的研究。

E-mail: lwsdjnyz@163.com

王智豪, 硕士研究生, 主要从事室内定位, 深度学习方面的研究。

E-mail: 240910782@qq.com

李卓(通信作者), 实验师, 主要从事无线传感网络, 室内定位方面的研究。

E-mail: 234162414@qq.com

韦嘉恒, 硕士研究生, 主要从事室内定位, 深度学习方面的研究。

E-mail: 2841049626@qq.com