陈乃馨, 朱春丽, 陈磊, 等. 面向 GNSS 拒止环境的极少参考点无线电指纹定位方法[J]. 安全与环境学报, 2026, 26(7): 2527 - 2538.

Chen Naixin, Zhu Chunli, Chen Lei, et al. Research on radio fingerprint positioning method with extremely sparse reference points in GNSS-denied environments[J]. Journal of Safety and Environment, 2026, 26(7): 2527 - 2538.

面向 GNSS 拒止环境的极少参考点无线电指纹定位方法*

陈乃馨[1],朱春丽[2],陈 磊[3],高 镇[4]

(1 北京理工大学信息与电子学院,北京 100081;2 北京理工大学机电学院,北京 100081;
3 北京理工大学人工智能学院,北京 100081;4 北京理工大学前沿交叉科学院,北京 100081)

摘 要:全球导航卫星系统(Global Navigation Satellite System,GNSS)拒止环境下的精准定位是保障无人机在复杂空间内安全作业的关键。然而,受环境封闭、多径效应严重及电磁干扰等多重因素影响,高精度无人机位置获取难度较大。基于信道状态信息(Channel State Information,CSI)的无线电指纹定位技术因具有抗多径干扰能力而成为重要解决方案。然而,该技术高度依赖高密度的无线电地图,在实际部署中面临现场采集工作量大、参考点稀疏导致定位精度急剧下降的难题。针对这一难题,提出了基于条件生成对抗网络(Location-to-CSI Generative Adversarial Network,L2C - GAN)的指纹增强模型,通过学习粗粒度无线电地图的空间位置与无线电指纹间的非线性映射关系生成虚拟无线电指纹,从而重构细粒度无线电地图。其中,条件是指无人机坐标;网络输入是由高维信道状态信息分段获取的单通道指纹图及对应坐标;生成器与判别器分别对坐标进行高维编码,并引入自注意力机制提升全局上下文学习能力。结果表明,在仅有 2% 参考点的极端稀疏情况下,平均定位误差可由 2.01 m 降低至 1.67 m,精度提升了 16.92%。

关键词:安全工程;无人机安全监测;无线电地图;无线电指纹定位;条件生成对抗网络

中图分类号:X931;TP391 **文献标志码**:A **文章编号**:1009-6094(2026)07-2527-12

DOI: 10.13637/j.issn.1009-6094.2025.0755

0 引 言

无人机(Unmanned Aerial Vehicle,UAV)是低空经济的核心载具之一,具有机动特性强、物流成本低等优势,在应急救灾、快递配送、基础设施巡检等[1-2]领域的应用初具规模。当前,国家大力推动低空经济发展,《国家综合立体交通网规划纲要》[3]、政府工作报告、中央经济工作会议等曾多次涉及低空经济相关议题。无人机常需在密集建筑群与大型仓储等全球导航卫星系统(Global Navigation Satellite System,GNSS)拒止环境中作业,在此类环境中,卫星导航信号易受遮挡,且存在严重的多径效应,给无人机的安全监管与定位[4]带来了严峻挑战。既有研究中声学、光学、雷达、无线电等多种监测手段应用于前述问题[5]。其中,无线电监测技术通过被动接收无人机发射的无线信号并进行特征解算,相较其他手段,具有全天候、被动探测及隐蔽性强等显著特点。

基于无线电的无人机定位主要包括基于几何定位机制和基于指纹匹配的定位方法。其中,无线电指纹指受环境多径效应和遮挡等因素影响,无线电信号在特定空间位置上呈现的独一无二的特征。通过在区域内采集大量已知物理坐标及对应的无线电指纹,可以构建出记录二者映射关系的参考数据库,即无线电地图。几何定位机制包括三边测量法和三角测量法[6],其实现首先依赖于对无线电信号关键参数的测量,如接收信号强度指示[7]、到达时间[8]、到达角度[9]等。指纹定位方法以接收信号强度[10]或信道状态信息[11]为指纹,通过学习空间位置与指纹之间的映射关系,实现定位匹配。对比而言,指纹定位方法更适用于非视距环境普遍存在且多径效应严重的 GNSS 拒止复杂场景中[12-13],但存在大规模现场指纹采集导致部署成本高昂[14]、动态环境变化导致适应能力弱[15]等问题。

针对以接收信号强度为指纹的定位方法,Wu 等[16]提出的自动连续无线电地图更新(Automatic

* **收稿日期**: 2025 - 05 - 14

作者简介: 陈乃馨,博士研究生,从事无线电监测研究,naixin_chen@bit.edu.cn;朱春丽(通信作者),助理教授/副研究员,博士,从事安全监测与智能交通研究,chunlizhu@bit.edu.cn。

基金项目:国家自然科学基金项目(52302426)

and continuous radio Map updating, AcMu) 方法、Yin 等[17]提出的模型树位置估计方法(Location Estimation using Model Trees, LEMT)等关注环境变化中的信号波动,实现了细粒度指纹的获取。LEMT 方法使用基于学习的方法,通过模型树方法学习位置与其相邻区域之间的函数关系,实现时变无线电地图的自适应构建。而 AcMu 方法利用移动设备,通过移动路径与建模不同位置间接收信号强度的时空关联关系,实现无线电地图的自适应调整。其中,无线电地图指由各参考点空间坐标及对应无线电指纹特征共同构成的数据库。Xiang 等[18]应用众包技术,利用异构移动终端自动采集数据,通过用户报告进行无线电地图的更新,并结合历史指纹实现高定位精度。Chen 等[19]使用迁移学习方法,通过最小化环境变化前后信号空间的分布差异,学习跨无线电地图变化的共享知识表征。2008 年,唐文胜等[20]利用接收信号强度的空间相关性,首次提出对传神经网络插值算法,减少采集人力并缩短采集时间。Ng 等[21]使用高斯过程回归,通过构建核函数矩阵,实现从稀疏采样点的接收信号强度到连续空间场的概率建模。总体而言,接收信号强度指纹定位方法成本极低,且计算简单,但易受环境干扰影响且难以刻画多径传播。

针对以信道状态信息(Channel State Information, CSI)为指纹的定位方法,Muta 等[22]提出使用频域采样方法减少无线电地图采样需求,利用压缩空间级联 CSI 实现无设备室内定位。Wei 等[23]提出基于结构相似性的增强方法对经由相位校准后的 CSI 相位数据进行简单高效的无线电地图扩充方法。2019 年,Li 等[24]首次使用生成对抗网络进行 CSI 指纹生成,首先将 CSI 指纹转换为幅值特征图,并提出幅值特征深度卷积生成对抗网络(Amplitude-Feature Deep Convolutional Generative Adversarial Network, AF-DCGAN)扩展粗粒度无线电地图,使定位精度得到提升。Zhang 等[25]使用生成对抗网络生成 CSI 指纹,并使用基于局部邻近特性的关系网络得到生成指纹的对应坐标,从而降低采样成本、应对环境干扰。总体而言,CSI 指纹定位方法可以提供更细粒度的无线信号信息且缓解多径问题的能力更强,但 CSI 计算复杂度高且存在相位偏差问题。因此,本文关注使用信道状态信息作为指纹的飞行状态无人机定位问题,重点解决生成对抗网络模型下指纹增强的问题。

综上所述,尽管现有文献为指纹增强提供了有力参考,但目前针对指纹定位方法中无线电地图构建工作量巨大、维护成本高等挑战的研究仍是热门课题。鉴于此,本文提出一种基于条件生成对抗网络(Location-to-CSI Generative Adversarial Network, L2C-GAN)的指纹增强模型。本文的主要贡献如下:

(1)提出 L2C-GAN 架构,以空间位置为条件,引入位置编码与自注意力机制,解决传统 GAN 在生成高维 CSI 矩阵时空间特征丢失的问题,实现从粗粒度坐标到细粒度 CSI 指纹的高保真映射;

(2)针对无线电指纹采样中存在的环境噪声与硬件干扰,提出基于密度聚类的指纹抗噪预处理方法,有效剔除离群值,保证稀疏样本下的模型训练质量。

1 CSI 数学模型与指纹选择

假设目标区域已被 WiFi 或蜂窝网络覆盖,当无人机在目标区域内活动时,不同的运动位置会给接收端接收到的 CSI 幅值与相位带来不同的影响。因此,通过学习 CSI 特征与空间位置的映射关系可实现无人机在复杂 GNSS 拒止环境下的被动定位。

本文中,无人机作为发射端,配置 $N_t = 1$ 根天线,地面监测站为接收端,配置 N_r 根接收天线。这种架构将多天线接收与信号处理的负载集中在地面端,对无人机硬件载荷并无额外需求。CSI 描述信道中信号散射、多径衰落、阴影衰落及距离导致的功率衰减,用于衡量信道状态[22]。CSI 指纹是长期演进技术(Long Term Evolution, LTE)带宽上的信道频率响应(Channel Frequency Response, CFR),包括 N_t、N_r与子载波的数量 N_S和 CSI 矩阵 $\boldsymbol{H}$,整体是一个形状为 $N_t \times N_r \times N_S$的复数矩阵,即

$$\boldsymbol{H} = (\boldsymbol{H}_{uv})_{N_t \times N_r} \tag{1}$$

式中 $\boldsymbol{H}_{uv}$代表发射端 u 与接收端 v 形成的通信链路的 CSI 数据,包含 N_S个子载波的信息。

$$\boldsymbol{H}_{uv} = (h_1^{uv}, h_2^{uv}, \cdots, h_{N_S}^{uv})^T \tag{2}$$

式中 h_i表示第 i 个子载波对应的信道频率响应复数值,包含对应子载波的幅值与相位信息。

$$h_i^{uv} = |h_i^{uv}| e^{j\angle h_i^{uv}} \quad 1 \leqslant i \leqslant N_S \tag{3}$$

式中 $|h_i^{uv}|$ 和 $\angle h_i^{uv}$ 分别表示第 i 个子载波对应的幅值和相位;j 为虚数单位。

每个参考点的 CSI 指纹是独一无二的,与周边参考点的 CSI 指纹差异明显,参考点间相隔距离越大差异越大。但研究表明,商用无线网卡采集的原始相位测量数据存在系统性误差[23]。即使在完全

静态的环境中,某些频段的相位测量值仍会呈现显著波动。这种不稳定性导致相位信息难以直接用于定位,因此,当前主流 CSI 指纹定位算法通常仅采用幅值特征。相比之下,特定子载波的幅值在固定位置表现出优异的时空稳定性,这使幅值成为 CSI 指纹定位的理想特征选择。

2　基于 L2C－GAN 的指纹增强模型

指纹定位技术在实际部署过程中面临两个主要挑战:其一,无线电地图构建过程中依赖大量人工测量,效率低下且成本高昂[26];其二,无线电地图对无线信道环境变化敏感,易出现时效性差和适应性不足[27]。对此本文提出一种面向 GNSS 拒止环境的指纹数据增强方法,整体流程如图 1 所示。该方法设计了一套高效的指纹采集与建图规则,主要包含三个核心步骤:首先,利用基于密度的聚类算法(Density-Based Spatial Clustering of Applications with Noise,DBSCAN)对采集的原始指纹进行抗噪预处理,剔除离群干扰;接着,利用坐标条件驱动的指纹生成模型 L2C－GAN 学习稀疏参考点与其 CSI 指纹的非线性映射关系,实现对任意空间位置虚拟指纹的生成;最后,结合生成数据与原始数据构建指纹定位模型,验证该方法在 GNSS 拒止环境中极端稀疏参考点条件下的定位精度与鲁棒性。

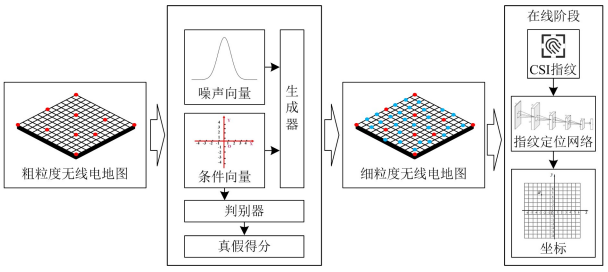

图 1　基于坐标感知 CSI 生成器的指纹定位方法整体流程示意图

Fig. 1　Schematic diagram of overall workflow for fingerprint positioning method based on coordinate-aware CSI generator

2.1　基于密度聚类的指纹抗噪预处理

由于环境多径效应的随机性及硬件底噪的波动,原始 CSI 幅值特征中不可避免地掺杂着显著偏离真实信道响应的离群噪声。这些非高斯分布的噪声若直接输入生成模型,极易误导生成器对潜在数据分布的学习,诱发模式崩塌。为此,本文不采用传统的固定阈值滤波,而是构建了一种基于密度的自适应指纹清洗策略。

该策略以基于密度的聚类算法(DBSCAN)为核心架构,利用 CSI 指纹在信号空间中的密度差异,自适应地分离高密度信号集中区与低密度离群噪声区。相较于基于距离的统计方法,该策略无需预设数据的分布先验,能更鲁棒地处理具有非线性簇状特征的 CSI 指纹。

假设给定参考点下的 CSI 幅值集合 $D=\{\boldsymbol{x}_1,\boldsymbol{x}_2,\cdots,\boldsymbol{x}_n\}$,对于任意样本 $\boldsymbol{x}_j\in D$,其 ε –邻域定义为集合 $N_\varepsilon(\boldsymbol{x}_j)=\{\boldsymbol{x}_i\in D\mid\|\boldsymbol{x}_i-\boldsymbol{x}_j\|\leqslant\varepsilon\}$,其中 ε 为邻域半径阈值[28]。首先,需要基于邻域半径 ε 和最小样本数 m_s 构建密度连接,递归合并密度可达的样本点以形成若干聚类簇。考虑到在准静态采集场景下,真实的信道响应应表现为出现频率最高、聚集度最高的模态,引入最大簇保留机制,在聚类完成后,强制锁定并保留样本量最大的簇作为有效指纹真值,而将其余小簇及离散点判定为瞬时干扰予以剔除。这一机制有效增强了输入数据的空间一致性,从源头上保证了 L2C－GAN 模型特征学习的纯度。

2.2　L2C－GAN 网络结构

生成对抗网络(Generative Adversarial Network,GAN)由生成器与判别器构成[29],生成器致力于生成尽可能真实的数据以欺骗判别器,判别器则试图准确地区分真实数据与生成数据,二者互相博弈学习。条件生成对抗网络(conditional Generative Adversarial Network,cGAN)是 GAN 的一种变体,其核心目标是引入先验条件信息以控制生成样本的分布,使生成样本不仅具有高质量与多样性,还满足约束条件。这里的条件可以是类别标签、实际图片、语音信号等。本文以位置坐标为条件构建生成模型 L2C－GAN,其核心思想是以二维空间坐标为输入条件,结合随机噪声以建模样本多样性,训练生成器以学习从空间位置到 CSI 指纹之间的映射函数,输出与真实 CSI 分布一致的指纹矩阵,从而扩充原始无线电地图,提高空间覆盖率,同时增强系统对环境变化的鲁棒性。L2C－GAN 整体网络结构如图 2 所示。

在 L2C－GAN 的训练过程中,需要对原始 CSI 指纹数据进行预处理。CSI 指纹本质上由多个子载波与通信信道的幅值信息构成,其结构具有显著的空间特征。因此,将原始 CSI 数据在子载波段上进行分段,视为单通道二维图像进行建模,并以此作为生成器与判别器对抗训练的输入。

在 L2C－GAN 中,生成器的输入由来自高斯分布 P_z 的随机噪声向量 $\boldsymbol{z}$ 与条件向量 $\boldsymbol{c}$ 构成。其中,

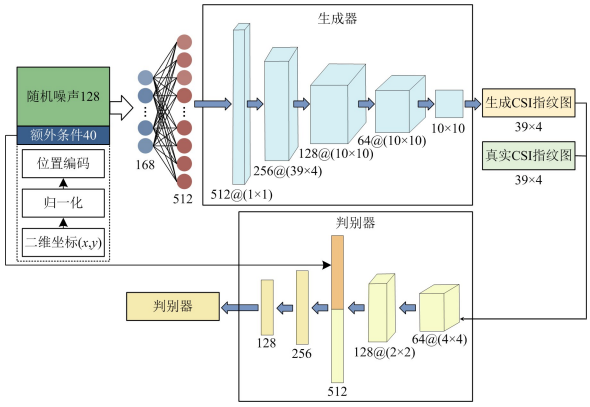

图 2 L2C－GAN 指纹增强模型网络结构示意图

Fig. 2 Schematic diagram of network structure for the L2C－GAN fingerprint augmentation model

$\boldsymbol{c}=(c_1, c_2)$,分别表示 CSI 指纹数据对应的二维坐标 x 与 y,且该坐标信息在输入模型前需经过归一化处理。为提升模型对空间位置的感知能力,L2C－GAN 在条件分支中引入了基于傅里叶基的位置编码机制,即

$$\boldsymbol{\gamma}(\boldsymbol{p}) = [\sin(2^0\pi\boldsymbol{p}),\cos(2^0\pi\boldsymbol{p}),\cdots, \sin(2^{L-1}\pi\boldsymbol{p}),\cos(2^{L-1}\pi\boldsymbol{p})] \tag{4}$$

式中 $\boldsymbol{p}=(x, y)$ 表示归一化的空间坐标;L 为编码层数。该编码方法将低维坐标映射为一个 $2\times2\times L$ 维的高维嵌入向量,从而增强空间位置信息在模型中的表达能力。接着,将该高维条件向量与噪声向量 $\boldsymbol{z}$ 进行拼接,并通过全连接层映射为高维表示,进一步重塑为初始特征图。此特征图随后通过多层转置卷积网络进行逐步上采样,实现空间分辨率的逐层恢复。在中间阶段引入自注意力模块,以增强模型对全局上下文的学习能力,从而兼顾局部结构的精细还原与跨区域依赖的表达。最终输出为生成的分段 CSI 指纹图。

在判别器结构中,L2C－GAN 的设计目标不仅是判断输入 CSI 指纹的真实性,还需验证输入 CSI 指纹是否符合给定的条件 $\boldsymbol{c}$。该条件一致性判别策略显著提升了模型生成样本的约束性与精确性。判别器的输入包括生成或真实的 CSI 指纹图及对应的归一化坐标 $\boldsymbol{p}=(x, y)$。首先,CSI 数据通过一个包含多层卷积与自注意力模块的浅层卷积神经网络作为主干网络提取频域特征,输出一个维度为 256 的全局特征向量。同时,条件坐标 $\boldsymbol{p}$ 同样经过位置编码 $\boldsymbol{\gamma}(\boldsymbol{p})$ 处理,并通过两层多层感知器(Multilayer Perceptron,MLP)网络映射为 256 维的坐标特征向量。随后,判别器将频域特征与坐标嵌入向量拼接为联合特征,并送入后续两层 MLP 网络进行融合判别,输出最终的真假分数。

2.3 训练过程

L2C－GAN 在训练过程中,生成器将服从高斯分布 P_z 的噪声向量 $\boldsymbol{z}$ 映射为假 CSI 指纹图 $\hat{\boldsymbol{F}}=G(\boldsymbol{z}|\boldsymbol{c})$,其分布为 P_f,且 $\boldsymbol{c}$ 表示作为额外条件输入的二维坐标。生成器通过学习在条件 $\boldsymbol{c}$ 下的真实 CSI 指纹数据分布 P_r,使得生成数据的分布 P_f 逼近 P_r。判别器 $D(\boldsymbol{H}|\boldsymbol{c})$ 则输出当前条件下输入 $\boldsymbol{F}$ 来自真实分布 P_r 的概率,其中 $\boldsymbol{H}$ 为 CSI 矩阵。生成器与判别器网络通过极大极小目标函数进行协同训练。

$$L = \min_G \max_D E_{\boldsymbol{F}\sim P_r}[\lg D(\boldsymbol{F}|\boldsymbol{c})] + E_{z\sim P_z}[\lg(1 - D(G(\boldsymbol{z}|\boldsymbol{c})))] \tag{5}$$

式中 E 表示数学期望。

针对 GAN 存在的训练困难、模式崩塌及生成样本多样性不足等问题,特别是在利用 cGAN 学习复杂非线性关系并生成大规模 CSI 指纹数据时表现出的局限性,L2C－GAN 在训练过程中采用 Wasserstein 生成对抗网络(Wasserstein Generative Adversarial Network,WGAN)[30] 中引入的 Wasserstein 距离,代替常规的 Jensen-Shannon(JS)散度,作为分布度量标准,显著提升模型的训练稳定性和生成可靠性。

$$L = \min \inf_{\pi\in\Pi(P_r,P_z)} E_{\boldsymbol{F},\hat{\boldsymbol{F}}\sim\gamma}[\|\boldsymbol{F} - \hat{\boldsymbol{F}}\|] \tag{6}$$

式中 $\Pi(P_r, P_z)$ 表示所有以 P_r 和 P_z 为边缘分布的联合分布 $\pi(\boldsymbol{F},\hat{\boldsymbol{F}})$ 的集合。即使真实分布 P_r 与生成分布 P_f 近似不相交或完全不相交时,Wasserstein 距离依旧能够有效量化分布之间的差异,并提供稳定且有意义的梯度信息。利用 Kantorovich-Rubinstein 对偶定理,式(6)可被化简为

$$L = \max \sup_{f\in Z} E_{\boldsymbol{F}\sim P_r}[f(\boldsymbol{F})] - E_{\hat{\boldsymbol{F}}\sim P_z}[f(\hat{\boldsymbol{F}})] \tag{7}$$

式中 sup 表示期望的上确界;Z 表示 1－Lipschitz 函数 $f(\cdot)$ 的集合。1－Lipschitz 条件通过 Kantorovich-Rubinstein 对偶性要求强制约束函数梯度有界,这一约束不仅能够防止梯度爆炸从而稳定对抗训练过程,同时可以保证 Wassertein 距离估计的有效性。为了在训练过程中持续满足 1－Lipschitz 连续性约束,需要采用梯度惩罚的方式,从而产生如下优化目标。

$$L = \min_G \max_D E_{\boldsymbol{F}\sim P_r}[D(\boldsymbol{F}|\boldsymbol{c})] - E_{z\sim P_z}[D(G(\boldsymbol{z}|\boldsymbol{c}))] + \lambda E_{\bar{\boldsymbol{F}}\sim P_n}[(\|\nabla_{\bar{\boldsymbol{F}}} D(\bar{\boldsymbol{F}})\|_2 - 1)^2] \tag{8}$$

式中　λ 为梯度惩罚系数; $\overline{\boldsymbol{F}} = \epsilon \boldsymbol{F} + (1-\epsilon) G(\boldsymbol{z} \mid \boldsymbol{c})$,且 ϵ 来自均匀分布 $U[0, 1]$, $\overline{\boldsymbol{F}}$ 服从分布 P_n。在训练过程中,生成器与判别器采用交替优化的方式,当该过程收敛时,生成器则可被用来生成虚拟参考点或已有参考点的 CSI 片段指纹图。

在训练过程中,首先需要对原始 CSI 指纹数据进行分段,并将分段后的 CSI 数据视作 CSI 片段指纹图 $\boldsymbol{M} = \{\boldsymbol{F}_1, \boldsymbol{F}_2, \cdots, \boldsymbol{F}_i, \cdots, \boldsymbol{F}_k\}$,对各 CSI 片段指纹图依次训练 L2C - GAN。当生成器与判别器的损失基本稳定在 0. 5 左右时,保存此时的模型参数。接着,在进行生成任务时,需要选择已有参考点或虚拟参考点作为条件,与随机噪声共同输入模型,得到生成 CSI 片段指纹图 $\boldsymbol{G}_i$。然后需要对生成 CSI 片段指纹图进行拼接操作,得到最终生成 CSI 指纹。最后,将选择的已有参考点或虚拟参考点处新获得的生成 CSI 指纹集合与原始 CSI 指纹库合并,用于后续指纹定位网络模型的训练。

3　生成模型实施与定位性能验证

3. 1　数据集介绍与预处理

使用公开数据集 OpenCSI 进行算法验证[31]。该数据集的采集系统将软件定义无线电(Software Defined Radio,SDR)设备 USRP B200mini 固定在轮式机器人 Thymio Ⅱ上。移动主体沿着地面上已被设定好的线路移动,定期停下来记录一定数量的连续指纹,从而获得密集无线电地图。OpenCSI 数据集中初始 CSI 指纹包含 1 200 个子载波,经过降采样、异常剔除、相位校正、噪声平滑等处理流程,最终得到包含 39 个子载波的 CSI 指纹数据。该数据集共 3 983 个采集点,每个采集点处采集的 CSI 指纹个数由于预处理操作并不相同,最少的仅包含 19 个数据包。

由于 OpenCSI 在采集过程中,每移动到一个参考点会暂停固定时间以采集指定数据包的 CSI 指纹,而环境噪声、硬件不稳定性和瞬时干扰等均有可能导致部分采集序列的幅值显著偏离真实信道响应。图 3 展示了来自坐标(119. 3, 300. 1)参考点处每个信道的平均幅值分布,可以明显看出来自信道 2 和信道 3 的 CSI 指纹出现了小尺度衰落情况。这样的情况不仅出现在单独的参考点处,通过观察分析 OpenCSI 每个参考点处不同信道,可以发现有较多参考点出现小尺度衰落情况,这会给增强算法的非线性学习带来不良影响。因此,在进行 CSI 指纹增强操作之前需要对数据进行预处理。

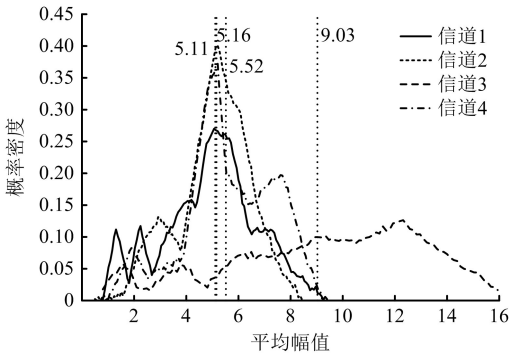

(a) CSI平均幅值分布

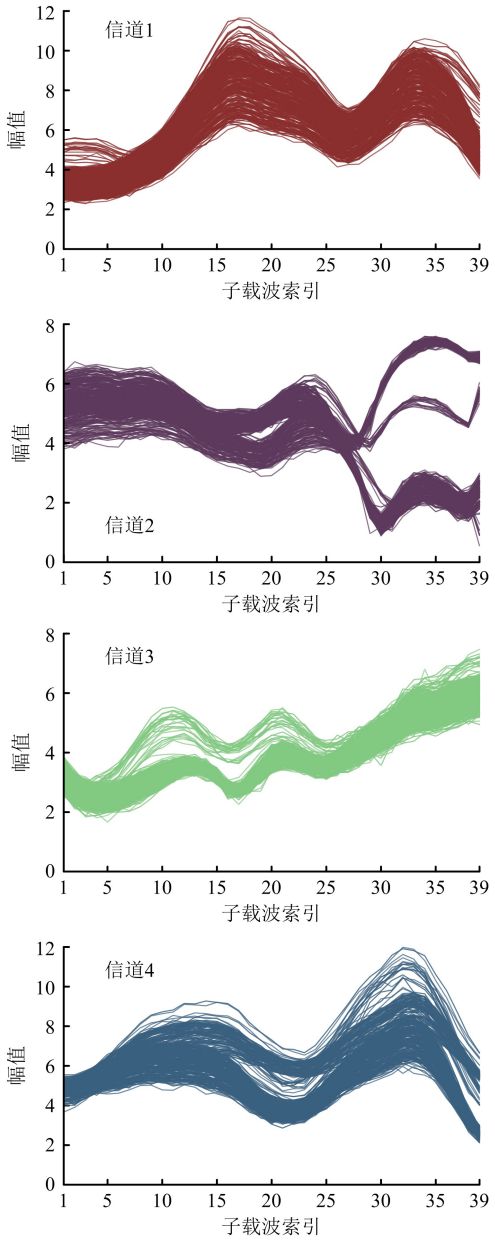

(b) CSI指纹展示图

图 3　来自坐标(119. 3, 300. 1)每条信道的 CSI 平均幅值分布与 CSI 指纹展示图

Fig. 3　CSI average amplitude distribution and CSI fingerprint display for each channel from coordinates (119. 3, 300. 1)

根据 2.1 节所述的预处理策略对每个参考点下各信道的 CSI 幅值指纹进行密度筛选。针对 OpenCSI 数据的分布特性,经过多次试验验证,设置邻域半径 $\epsilon = 1.5$;同时,考虑到 OpenCSI 数据集中每个参考点的数据包数量最少为 19,为保证统计显著性,设置 $m_s = 3$。图 4 展示了坐标(119.3, 300.1)处各信道 CSI 指纹经由基于密度聚类的指纹抗噪预处理前后的对比,通过可视化分析可以清晰观察到算法有效剔除了离群数据并保留了稳定的簇。

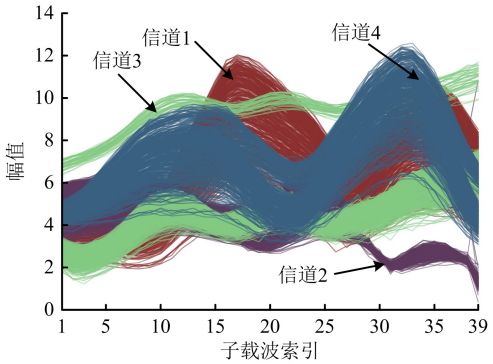

(a) 原始各信道CSI指纹

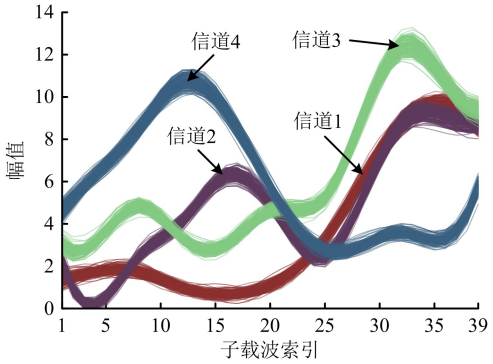

(b) 基于密度聚类的预处理各信道CSI指纹

图 4 来自坐标(119.3, 300.1)各信道的 CSI 指纹预处理结果

Fig. 4 Preprocessing results of CSI fingerprints from each channel at coordinates (119.3, 300.1)

3.2 CSI 指纹增强验证

经过预处理后的 CSI 指纹数据需进一步进行分段处理,并作为 L2C - GAN 模型的训练输入。该数据集中 CSI 指纹包含 39 个子载波和 4 个通信信道,L2C - GAN 将 CSI 指纹数据按照子载波索引进行分割,共分为 10 段,其中 9 段包含 4 个子载波,第 10 段包含 3 个子载波。

为了保证模型训练的稳定性与收敛性,依据数据特征与网络属性精细调整了超参数。判别器需提供准确的 Wasserstein 距离,采用 5∶1 的交替优化策略,即判别器每更新 5 次,生成器更新 1 次,以确保判别器在生成器更新前达到近似最优状态。考虑到稀疏参考点场景下样本量有限,将批大小(batch size)设定为 32。这一量级在保证梯度下降方向稳定的同时,引入了适量的随机噪声,有助于模型跳出局部极值点并提升泛化能力。如图 5 所示,在训练进行到 800 轮左右时,生成器与判别器的对抗博弈逐渐达到纳什均衡,损失值趋近于 0.5 并保持稳定,表明模型已充分收敛。因此,本文将总训练轮次设定为 1 000。

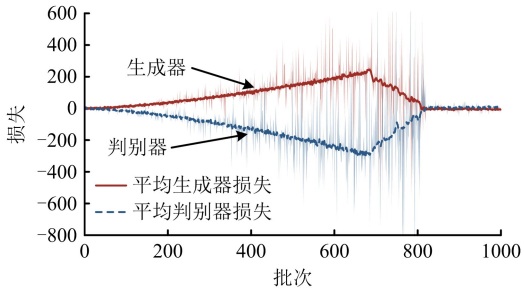

图 5 生成器与判别器训练损失

Fig. 5 Training loss of generator and discriminator

由于使用的 OpenCSI 经过预处理后,每个参考点的数据量并不均衡,最多的可达 679 个,最少的仅有 10 个。为了减少数据集对定位性能的影响,不仅选择部分虚拟生成点进行 CSI 指纹生成,也选择部分已有参考点进行 CSI 指纹扩充。图 6 展示了已有参考点(0.0, 0.0)与虚拟参考点(105.3, 150.1)处的指纹增强结果,其中的虚线为此处真实指纹。可以看出,生成指纹在保持多样性的同时,紧密包络了真实指纹的分布特征。考虑到指纹增强任务与常规生成任务的差异性,传统生成模型评估指标[Inception 分数(Inception Score, IS)、弗雷歇 Inception 距离(Frechet Inception Distance, FID)等]在此场景下适用性有限。为此,采用定位性能作为核心评估标准,通过构建增强指纹数据库并测试增强指纹数据库在实际定位任务中的表现,对增强效果进行量化验证。

3.3 定位效果验证

无线电指纹定位方法旨在从无线电地图中学习指纹特征,并判断新获取到的且未在指纹库中出现的新指纹对应的位置坐标。选取 OpenCSI 数据集中部分点作为参考点,其余点作为测试点。如图 7 所示,设置参考点(五角星表示)间距为 50 cm,共计 88 个(2%);其余点作为测试点,共计 3 895 个(98%)。

使用基于 OpenCSI 数据集研发者们提供的神经网络作为定位验证模型,由于经过试验验证,CSI

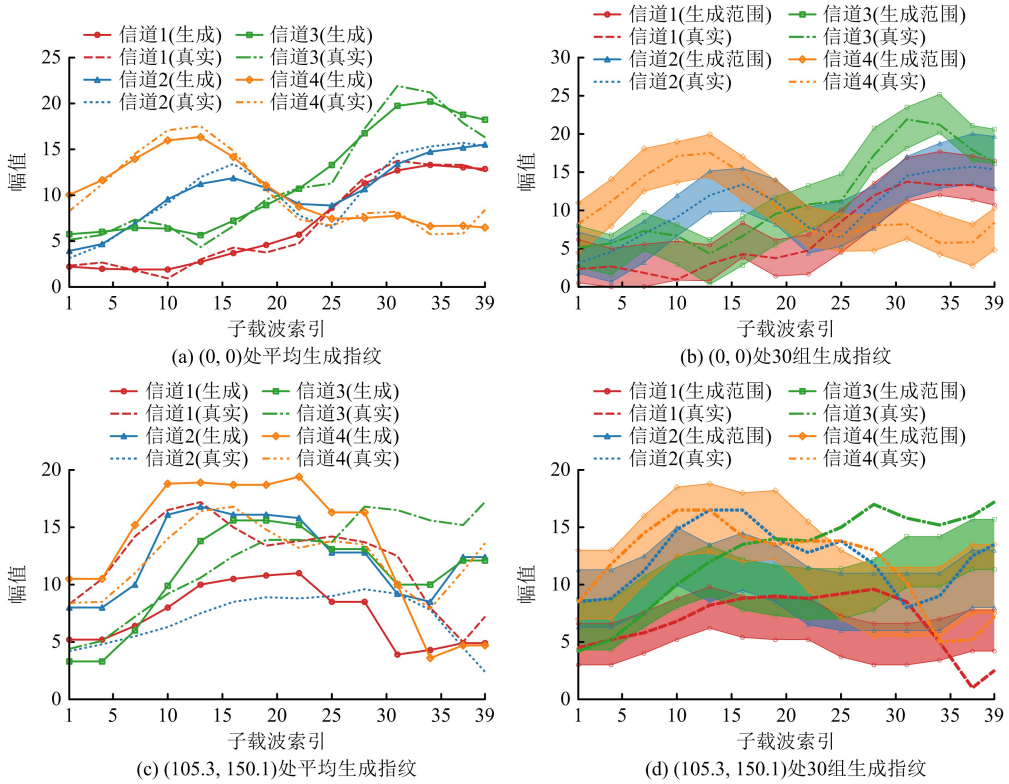

(a) (0, 0)处平均生成指纹　(b) (0, 0)处30组生成指纹

(c) (105.3, 150.1)处平均生成指纹　(d) (105.3, 150.1)处30组生成指纹

图 6　两个坐标处指纹增强结果

Fig. 6　Fingerprint augmentation results at two coordinates

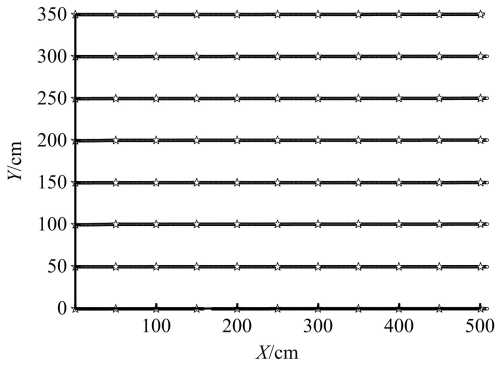

图 7　参考点与测试点平面设置

Fig. 7　Planar layout of reference points and test points

相位数据中包含过多噪声,严重影响定位效果,对该定位模型进行修改,使模型只接收 CSI 幅值信息并推理出目标位置二维坐标。该模型将无线电指纹定位视为一个回归任务,是一种基于 AlexNet 和 ConFi 架构改进的卷积神经网络(Convolutional Neural Network, CNN),具体结构如图 8 所示。与 ConFi 方法不同,该模型不需要依赖连续多次测量来构建图像输入,而是直接将单个 CSI 测量样本处理为 39 ×4 的二维特征图像,其中每个样本包含 4 个天线端口的 CSI 数据(每个端口对应 39 个子载波)。该 CSI 图像采用单通道表示(即幅值信息),四个列向量分别对应四个通信信道(即四个天线端口)的测量结果。模型通过端到端的回归学习,将输入的 CSI 图像映射到对应的二维坐标(x, y)。这种处理方式不仅简化了数据预处理流程,同时保留了多天线系统提供的空间特征信息,为基于深度学习的指纹定位提供了更高效的解决方案。

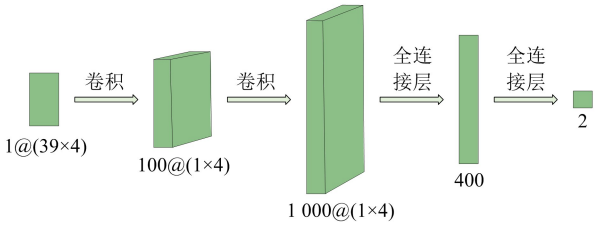

图 8　CSI 幅值指纹定位网络结构

Fig. 8　Network architecture for CSI amplitude fingerprint positioning

首先设计了 4 种不同参考点与测试点的分割比例方案(90% – 10% 、60% – 40% 、20% – 80% 、2% – 98%),通过控制变量法系统考查参考点数量减少对

定位精度的影响。如图 9 所示,定位误差累积分布函数(Cumulative Distribution Function,CDF)曲线呈现明显的分层恶化趋势,当参考点比例维持在 90% 时,系统具有极高的定位可靠性,平均误差仅为 0.48 m。然而,当比例降至 2% 的极端稀疏水平时,平均定位误差急剧攀升至 2.01 m,性能降幅超过 300%。因此,针对这一情况,将 2% 参考点配置作为主要研究对象,在此类极端稀疏条件下引入生成式指纹增强具有紧迫性。

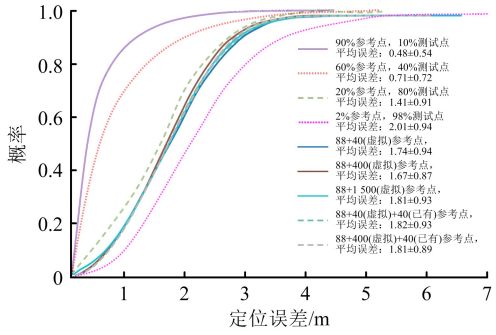

图 9 不同试验设置与对应定位误差 CDF 图

Fig. 9 CDF plots of positioning errors corresponding to different experimental settings

针对仅保留 2% 参考点的极端稀疏场景,进一步设计了 5 组对比试验,系统评估不同指纹增强策略的优化效果:40 个虚拟参考点(从原始测试点中选取坐标)、400 个虚拟参考点、1 500 个虚拟参考点、40 个已有参考点与 40 个虚拟参考点、40 个已有参考点与 400 个虚拟参考点。其中,在每个虚拟点处,或被选择到的已有参考点处,均生成 50 条增强指纹。上述两个试验结果如表 1 所示。试验结果表明,在仅有 2% 参考点的极端场景中,选择 400 个虚拟参考点设置使得定位性能达到最优,平均定位误差由 2.01 m 降低至 1.67 m。值得注意的是,当虚拟点增加至 1 500 个时,平均定位误差反而回升至 1.81 m。这是因为过量的虚拟样本放大了生成器在潜在空间边缘的采样误差,引入了生成噪声,导致了生成分布的累积偏差大幅度增加。此外,由于真实监督信号的过度稀疏,即虚拟数据占比过高,导致定位网络过拟合于生成伪影,而非学习真实的信道传播规律。

为了验证 L2C - GAN 在不同增强强度下的行为特性并确定最优增强策略,对不同虚拟点数量 0 ~ 1 500 进行了细粒度搜索与 10 次重复试验,结果如图 10 所示,随着虚拟参考点数量的增加,定位误差并非单调递减,而是呈现三个显著阶段。首先,在初始阶段,随着虚拟参考点数量从 0 增加至 300,平均定位误差从基准的 2.01 m 迅速下降至 1.70 m,这是因为指纹空间覆盖率的提升。在极度稀疏条件下,原始无线电地图存在大量空间空洞,L2C - GAN 生成的虚拟指纹有效填充了这些盲区,为定位模型提供了关键的插值特征,显著缓解了因数据匮乏导致的欠拟合问题。当虚拟参考点数量处于 300 ~ 600 时,平均误差稳定在 1.67 左右。在此区间内,生成样本的多样性与真实样本的分布密度达到了最佳平衡。上述试验结果得到的最优选择,即 400 个虚拟点正好位于此稳健区间的中心。然而,当虚拟点数量进一步增加到超过 800 个时,定位误差反而呈现缓慢上升趋势。可见,L2C - GAN 的增强效果并非越多越好,而是存在一个由真实参考点密度决定的最佳增强阈值。在本文的试验环境下,将虚拟点数

表 1 不同试验设置与对应定位性能详细数据

Table 1 Detailed data of different experimental setups and their corresponding positioning performance

参考点数	测试点数	是否增强	选择方式	平均定位误差/m
3 585(90%)	398(10%)	否	随机选择	0.48 ±0.54
2 390(60%)	1 593(40%)	否	随机选择	0.71 ±0.72
796(20%)	3 187(80%)	否	随机选择	1.41 ±0.91
88(2%)	3 895(98%)	否	均匀选择	2.01 ±0.94
88 +40(虚拟点)	3 895	是	均匀选择	1.74 ±0.94
88 +400(虚拟点)	3 895	是	均匀选择	1.67 ±0.87
88 +1 500(虚拟点)	3 895	是	均匀选择	1.81 ±0.93
88 +40(虚拟点) +40(已有点)	3 895	是	均匀选择	1.82 ±0.90
88 +400(虚拟点) +40(已有点)	3 895	是	均匀选择	1.81 ±0.89

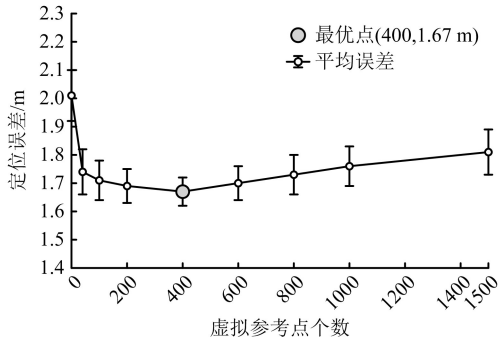

图 10　虚拟参考点数量对定位误差的影响

Fig. 10　Impact of virtual reference point quantity on positioning error

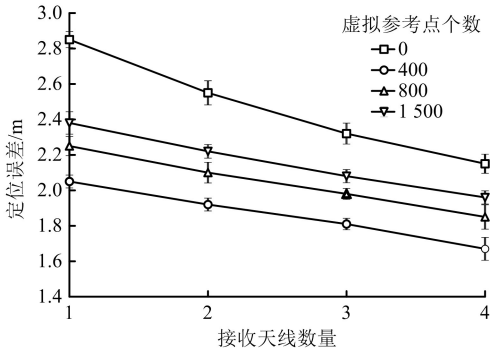

图 11　接收天线数与虚拟参考点数对定位误差的影响

Fig. 11　Impact of the number of receiving antennas and virtual reference points on positioning error

量控制在真实点数量的 4 ~ 6 倍是兼顾精度与计算效率的最优解。

此外,还测试了在接收天线数量受限情况下的算法鲁棒性。图 11 展示了在保留 2% 真实参考点的条件下,不同虚拟参考点数量设置下定位误差随接收天线数量的变化曲线。随着接收天线数量从 4 根减少至 1 根,由于空间分集增益的降低,CSI 指纹的空间辨识度减弱,导致所有试验设置下的定位误差均呈现上升趋势。然而,对比无增强基准(即 0 虚拟参考点)与上述最优增强策略(即 400 虚拟参考点),L2C - GAN 在低硬件配置下表现出了显著的性能优势。具体而言,在单天线的极端受限场景下,未增强的定位误差恶化至约 2. 85 m。而经过 L2C - GAN(400 虚拟参考点)增强后,定位误差被有效控制在 2. 05 m 左右,精度提升幅度约为 28% 。这表明 L2C - GAN 能够充分挖掘子载波层面的频率分集特征,有效补偿了空间维度缺失带来的信息损失。上述结果验证了所提方法在降低硬件依赖方面的有效性,表明该方法能够以更低的天线配置实现高精度的定位。

为了验证方法的先进性,在相同的 2% 稀疏条件下,将 L2C - GAN 与基于结构相似性的增强(Structural Similarity-based Augmentation,SSIM - Aug)方法[23]、幅度特征深度卷积生成对抗网络(Amplitude Feature Deep Convolutional GAN,AF - DCGAN)[24]及基于自适应指纹的减少现场勘测定位方法(Adaptive Fingerprint-based Localization with Less Site Survey,LESS)[25]进行了对比。试验在相同的 2% 训练集上进行训练,并分别测试了生成 400 个和 1 500 个虚拟样本时的定位精度,试验结果如表 2 所示。试验结果表明,尽管所有方法均优于无增强基准,但 L2C - GAN 取得了显著的最优性能。值得注意的是,由于 SSIM - Aug 方法并不是生成虚拟位置的指纹,而是增加已有位置的指纹样本,无法填补无线电地图的物理空白区域,因此,这种方法对于定位精度的提升效果有限。LESS 属于流形插值,且基于局部线性假设,即认为相邻位置的信号变化是线性的。但在 GNSS 拒止复杂环境,多径效应会导致信号呈现高度非线性变化。因此,其定位效果并不如本文所提方法。L2C - GAN 与 AF - DCGAN 都是利用生成对抗网络进行虚拟指纹生成,然而,L2C - GAN(1. 67 m)的结果远好于 AF - DCGAN(1. 89 m)。这是因为 AF - DCGAN 缺乏对空间坐标的显式高维编码,且在极少样本下,纯卷积结构难以捕捉全局的信道特征,导致生成样本出现模式崩塌,引入了大量噪声。而 L2C - GAN 引入的高维位置编码和自注意力机制

表 2　不同指纹增强方法下的定位误差对比

Table 2　Comparison of positioning errors under different fingerprint augmentation methods

指纹增强方法	虚拟点个数	平均定位误差/m
无	0	2. 01
SSIM - Aug	400(已有位置)	1. 94
	1 500(已有位置)	1. 91
AF - DCGAN	400	1. 89
	1 500	1. 98
LESS	400	1. 74
	1 500	1. 85
L2C - GAN	400	1. 67
	1500	1. 81

有效解决了这一问题,确保了生成指纹的保真度。此外,所有方法在 1 500 点时的性能均弱于 400 点,这表明在仅有 2% 真实数据的强约束下,过度的虚拟生成会不可避免地稀释真实特征的分布。然而,L2C - GAN 在 1 500 点时依然是最优精度,展现了模型在小样本学习任务中极强的鲁棒性。

4 结 论

本文针对指纹定位在构建无线电地图过程中效率低与环境适应性差的问题,提出了一种指纹增强模型 L2C - GAN,得到如下主要结论。

(1)使用基于密度聚类的指纹抗噪预处理方法对 CSI 数据中受到环境噪声、硬件不稳定性和瞬时干扰等影响的偏离值进行去除,预防偏离值给 L2C - GAN 的映射学习带来负面影响。

(2)提出 L2C - GAN 指纹增强模型,从原始粗粒度无线电地图出发,充分学习已有参考点空间位置与对应 CSI 指纹的关系,实现对虚拟参考点的虚拟指纹生成,从而获得细粒度无线电地图。并通过卷积定位模型验证增强指纹库对定位性能的影响,结果表明,对于拥有极少数参考点的无线电地图,选取已有参考点数量的约 5 倍数量的点作为随机参考点时,定位精度可以实现 16.92% 的提升。

(3)受限于当前验证数据集的采集维度,本文聚焦于 GNSS 拒止场景下二维平面的指纹增强与定位验证。未来,将探索三维空间中高度变化对多径效应及无线电指纹分布的影响,将 L2C - GAN 模型由二维平面扩展至三维空间。

参考文献(References):

[1] Amarasingam N, Salgadoe A S A, Powell K, et al. A review of UAV platforms, sensors, and applications for monitoring of sugarcane crops [J]. Remote Sensing Applications: Society and Environment, 2022, 26: 100712.

[2] Cheng Nan, Wu Shen, Wang Xiucheng, et al. AI for UAV-assisted IoT applications: a comprehensive review [J]. IEEE Internet of Things Journal, 2023, 10(16): 14438 - 14461.

[3] 中共中央国务院印发《国家综合立体交通网规划纲要》[J]. 中华人民共和国国务院公报, 2021(8): 25 - 37.
The CPC Central Committee and the State Council issued the "*Outline of the National Comprehensive Three-dimensional Transportation Network Planning*" [J]. State Council of the People's Republic of China, 2021(8): 25 - 37.

[4] 魏志强, 王晶. 大型固定翼无人机跟随民航机的尾流安全评估方法[J]. 安全与环境学报, 2024, 24(12): 4533 - 4541.
Wei Zhiqiang, Wang Jing. Calculation method for required wake turbulence separation integrating UAVs into civil aviation airspace [J]. Journal of Safety and Environment, 2024, 24(12): 4533 - 4541.

[5] 张静, 张科, 王靖宇, 等. 低空反无人机技术现状与发展趋势[J]. 航空工程进展, 2018, 9(1): 1 - 8, 34.
Zhang Jing, Zhang Ke, Wang Jingyu, et al. A survey on anti-UAV technology and its future trend[J]. Advances in Aeronautical Science and Engineering, 2018, 9(1): 1 - 8, 34.

[6] Zekavat S, Buehrer R M, Durgin G D, et al. An overview on position location: Past, present, future[J]. International Journal of Wireless Information Networks, 2021, 28: 45 - 76.

[7] Liu Zheng, Fu Zhe, Li Tongyun, et al. A phase and RSSI-based method for indoor localization using passive RFID system with mobile platform[J]. IEEE Journal of Radio Frequency Identification, 2022, 6: 544 - 551.

[8] 杨海龙, 祁小凤, 王瑞元, 等. 高噪声环境下声发射损伤源定位技术研究[J]. 工程与试验, 2024, 64(2): 23 - 27.
Yang Hailong, Qi Xiaofeng, Wang Ruiyuan, et al. Research on damage source localization by acoustic emission in high noise environments[J]. Engineering and Test, 2024, 64(2): 23 - 27.

[9] 秦杰, 邓平, 罗锐, 等. 一种基于鲸鱼优化的 TOA/AOA 最优化定位算法[J]. 导航定位学报, 2023, 11(6): 93 - 101.
Qin Jie, Deng Ping, Luo Rui, et al. A TOA/AOA optimization localization algorithm based on whale optimization[J]. Journal of Navigation and Positioning, 2023, 11(6): 93 - 101.

[10] Lee H, Kang T, Jeong S, et al. Evaluation of RF fingerprinting-aided RSS-based target localization for emergency response[C]//Proceedings of the 2022 IEEE 95th Vehicular Technology Conference (VTC2022-Spring). Piscataway, NJ, USA: Institute of Electrical and Electronics Engineers, 2022: 1 - 7.

[11] Kong Ruiqi, Chen He. CSI - RFF: leveraging micro-signals on CSI for RF fingerprinting of commodity WiFi [J]. IEEE Transactions on Information Forensics and Security, 2024, 19: 5301 - 5315.

[12] Bianchi V, Paolo C, Ilaria D M. RSSI-based indoor localization and identification for ZigBee wireless sensor networks in smart homes [J]. IEEE Transactions on

Instrumentation and Measurement, 2018, 68: 566 - 575.

[13] Bottigliero S, Milanesio D, Saccani M, et al. A low-cost indoor real-time locating system based on TDOA estimation of UWB pulse sequences [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 5502211.

[14] Tong Xinyu, Wan Yang, Li Qianru, et al. CSI fingerprinting localization with low human efforts [J]. IEEE/ACM Transactions on Networking, 2020, 29(1): 372 - 385.

[15] Amiri R, Yerramalli S, Yoo T, et al. Indoor environment learning via RF-mapping[J]. IEEE Journal on Selected Areas in Communications, 2023, 41(6): 1859 - 1872.

[16] Wu Chenshu, Yang Zheng, Xiao Chaowei. Automatic radio map adaptation for indoor localization using smartphones [J]. IEEE Transactions on Mobile Computing, 2017, 17(3): 517 - 528.

[17] Yin Jie, Yang Qiang, Ni L M. Learning adaptive temporal radio maps for signal-strength-based location estimation [J]. IEEE Transactions on Mobile Computing, 2008, 7(7): 869 - 883.

[18] Xiang Chenlu, Zhang Shunqing, Xu Shugong, et al. Crowdsourcing-based indoor localization with knowledge-aided fingerprint transfer[J]. IEEE Sensors Journal, 2022, 22(5): 4281 - 4293.

[19] Chen Lüdong, Zhao Caidan, Zheng Yicheng, et al. Radio frequency fingerprint identification based on transfer learning[C]//Proceedings of the 2021 IEEE/CIC International Conference on Communications in China (ICCC). Piscataway, NJ, USA: Institute of Electrical and Electronics Engineers, 2021: 81 - 85.

[20] 唐文胜, 李姗, 匡旺秋. RF 室内定位指纹库空间相关生成算法[J]. 计算机工程与应用, 2008, 44(23): 226 - 229, 232.
Tang Wensheng, Li Shan, Kuang Wangqiu. New algorithm based-on spatial correlation for yielding fingerprints database of RF indoor localization [J]. Computer Engineering and Applications, 2008, 44(23): 226 - 229, 232.

[21] Ng P C, Spachos P, She J, et al. A kernel method to nonlinear location estimation with RSS-based fingerprint [J]. IEEE Transactions on Mobile Computing, 2022, 22(8): 4388 - 4404.

[22] Muta O, Takata K, Noguchi K, et al. Device-free WLAN based indoor localization scheme with spatially concatenated CSI and distributed antennas [J]. IEEE Transactions on Vehicular Technology, 2022, 72(1): 852 - 865.

[23] Wei Wu, Yan Jun, Wu Xiaofu, et al. CSI fingerprinting for device-free localization: Phase calibration and SSIM-based augmentation[J]. IEEE Wireless Communications Letters, 2022, 11(6): 1137 - 1141.

[24] Li Qiyue, Qu Heng, Liu Zhi, et al. AF - DCGAN: amplitude feature deep convolutional GAN for fingerprint construction in indoor localization systems [J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2019, 5(3): 468 - 480.

[25] Zhang Lingyan, Wu Shaohua, Zhang Tingting, et al. Learning to locate: Adaptive fingerprint-based localization with few-shot relation learning in dynamic indoor environments[J]. IEEE Transactions on Wireless Communications, 2023, 22(8): 5253 - 5264.

[26] Lü Zhongyuan, Chan T T L, Leung G C M, et al. High-dimensional radio frequency fingerprint synthesis for indoor positioning [J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 2517416.

[27] Yuan Yazhou, Liu Xun, Liu Zhixin, et al. Indoor localization with wireless heterogeneous devices by composite fingerprint sets and hybrid classification[J]. IEEE Transactions on Vehicular Technology, 2022, 71(11): 12117 - 12127.

[28] 李楠, 强懿耕, 樊瑞, 等. 基于异常因子的航空器飞行轨迹异常检测研究[J]. 安全与环境学报, 2021, 21(2): 643 - 648.
Li Nan, Qiang Yigeng, Fan Rui, et al. On the abnormal detection of the aircraft flight trajectory based on the abnormal factor statistics [J]. Journal of Safety and Environment, 2021, 21(2): 643 - 648.

[29] 艾矫燕, 郑剑武, 刘高煊. 基于 GF - LSTM 和 GAN 网络的小样本集人工水体溶解氧浓度预测[J]. 安全与环境学报, 2021, 21(1): 426 - 434.
Ai Jiaoyan, Zheng Jianwu, Liu Gaoxuan. Forecast for dissolved oxygen concentration in artificial water body based on GF - LSTM and GAN network[J]. Journal of Safety and Environment, 2021, 21(1): 426 - 434.

[30] Martin A, Soumith C, Leon B. Wasserstein generative adversarial networks [C]//Proceedings of the 34th International Conference on Machine Learning (ICML 2017). Sydney, NSW, Australia: Journal of Machine Learning Research, 2017: 214 - 223.

[31] Gassner A, Musat C, Rusu A, et al. OpenCSI: an open-source dataset for indoor localization using CSI-based fingerprinting[PP/OL]. (2021 - 04 - 16)[2025 - 05 - 06]. https://arxiv.org/abs/2104.07963.

Research on radio fingerprint positioning method with extremely sparse reference points in GNSS-denied environments

Chen Naixin[1], Zhu Chunli[2], Chen Lei[3], Gao Zhen[4]

(1 School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China;
2 School of Mechatronics Engineering, Beijing Institute of Technology, Beijing 100081, China;
3 School of Artificial Intelligence, Beijing Institute of Technology, Beijing 100081, China;
4 School of Interdisciplinary Science, Beijing Institute of Technology, Beijing 100081, China)

Abstract: To tackle the significant decline in positioning accuracy caused by sparse reference points in Channel State Information (CSI) fingerprinting, this paper presents a fingerprint augmentation model called L2C - GAN (Location-to-CSI Generative Adversarial Network). The proposed method reconstructs fine-grained radio maps by generating virtual fingerprints based on the learned non-linear mapping between spatial locations and Radio Frequency (RF) features. The methodology consists of three key stages. First, a Density-Based Spatial Clustering of Applications with Noise (DBSCAN) is employed to preprocess the raw CSI amplitude data. This approach adaptively identifies and retains dominant signal clusters while eliminating outliers arising from environmental noise and hardware instability, thereby ensuring the purity and spatial consistency of the training data. Second, to accommodate convolutional operations, high-dimensional CSI matrices are segmented along subcarrier indices and reshaped into single-channel 2D feature maps. Third, the L2C - GAN architecture is constructed using a conditional generation mechanism. To address the low dimensionality of spatial coordinates, a Fourier-feature-based Positional Encoding mechanism is designed to map 2D coordinates into high-dimensional embedding vectors. Both the generator and discriminator integrate Self-Attention modules to capture long-range dependencies among subcarriers, enabling the model to learn global context. Experimental validation is conducted using the OpenCSI dataset in an extremely sparse setting with only 2% (88) real reference points. The results demonstrate that L2C - GAN effectively enhances radio map reconstruction. The average positioning error decreases from 2.01 m to 1.67 m, representing a 16.92% improvement over the baseline without augmentation. Furthermore, experiments with varying parameter settings show that augmenting with 400 virtual reference points yields the optimal positioning accuracy of 1.67 m. Comparative results also indicate that the proposed method significantly outperforms state-of-the-art augmentation techniques, such as SSIM - Aug (Structural Similarity-based Augmentation), AF - DCGAN (Amplitude Feature Deep Convolutional GAN), and LESS (Adaptive Fingerprint-based Localization with Less Site Survey). Notably, the model exhibits robust performance even under limited hardware configurations, achieving a positioning error of 1.92 m with only two receiving antennas, which surpasses the unaugmented four-antenna baseline.

Key words: safety engineering; UAV safety monitoring; radio map; radio fingerprint positioning; conditional generative adversarial network