

# 一种基于生成对抗网络的稀疏 CSI 数据增强方法

闫大伟<sup>1)</sup> 闫宇博<sup>2)</sup> 杨盘隆<sup>3)</sup>

<sup>1)</sup>(河北大学网络空间安全与计算机学院 河北 保定 071002)

<sup>2)</sup>(中国科学技术大学计算机科学与技术学院 合肥 230026)

<sup>3)</sup>(南京信息工程大学计算机学院 南京 210044)

**摘 要** 近年来,基于 WiFi 的感知技术得到了广泛的研究,旨在为人类提供更便捷的服务。尽管许多技术能够利用 WiFi 信号实现多种细粒度感知任务,但大多数方法依赖于能够获取连续、均匀的感知数据,如信道状态信息(Channel State Information, CSI)。然而,在现实应用中,由于 WiFi 信道竞争访问的特性及通信数据的随机性,基于 WiFi 的感知应用常常面临低采样率和不均匀采样的问题,导致系统性能下降。传统插值方法虽能在一定程度上缓解采样不足的问题,但往往存在信号细节丢失和误差累积的缺陷。因此,本文提出了一种名为 CSI-GAN 的 WiFi 信号稀疏恢复方案,旨在从稀疏和非均匀采样的 CSI 中恢复出充分且连续的感知数据。借鉴图像恢复技术的成功经验,我们对生成对抗网络(Generative Adversarial Network, GAN)进行了创新改进,以更好地适应 WiFi 感知数据的恢复需求。考虑到 CSI 与图像在数据形式上的差异,我们在时域中直接处理原始 CSI 波形,以避免频域转换中可能造成的频谱损伤,从而有效地恢复出连续的信道变化。为了进一步提高恢复质量,我们引入了新颖的去噪方法,并在时域和频域中施加约束,以优化信号的低级特征和高频信息。实验结果表明,即使在每秒仅接收 10 个数据包的低采样率条件下,CSI-GAN 依然能够准确恢复 CSI 信号。通过在步态识别、手势识别和活动识别中的实际应用,CSI-GAN 相比传统插值方法和最新基于 GAN 的方法,实现了至少 16.4% 的准确率提升。

**关键词** WiFi 感知;信道状态信息;稀疏数据;生成对抗网络;非均匀采样

**中图法分类号** TP391 **DOI 号** 10.11897/SP.J.1016.2026.02094

## Sparse CSI Augmentation Based on Generative Adversarial Network

YAN Da-Wei<sup>1)</sup> YAN Yu-Bo<sup>2)</sup> YANG Pan-Long<sup>3)</sup>

<sup>1)</sup>(School of Cyber Security and Computer, Hebei University, Baoding, Hebei 071002)

<sup>2)</sup>(School of Computer Science and Technology, University of Science and Technology of China, Hefei 230026)

<sup>3)</sup>(School of Computer Science, Nanjing University of Information Science & Technology, Nanjing 210044)

**Abstract** In recent years, WiFi-based sensing technology has been extensively studied with the goal of providing more convenient and intelligent services for human-centric applications. By leveraging the fine-grained channel variations embedded in WiFi signals, numerous approaches have demonstrated the feasibility of performing tasks such as gait recognition, gesture recognition, and activity recognition without requiring users to carry additional devices. Most of these techniques rely on the availability of continuous and uniformly sampled sensing data, particularly Channel State Information (CSI), which captures detailed amplitude and phase variations of wireless channels. Stable and dense CSI sampling is generally regarded as a fundamental prerequisite for accurate feature extraction and reliable sensing performance. However, in real-world deployments, this assumption is often difficult to satisfy. Due to the competitive access nature of WiFi

收稿日期:2025-08-27;在线发布日期:2026-03-27。本课题得到河北大学高层次人才科研启动项目(No. 521100225229)、安徽省科技创新攻坚计划项目(No. 202523009050019)、国家自然科学基金重大研究计划(No. 92567301)资助。闫大伟,博士,中国计算机学会(CCF)会员,主要研究领域为无线感知、移动计算与多模态融合。E-mail: daweiyan@hbu.edu.cn。闫宇博,博士,副研究员,中国计算机学会(CCF)会员,主要研究领域为物联网、无线网络与智能感知。杨盘隆(通信作者),博士,教授,中国计算机学会(CCF)会员,主要研究领域为物联网、无线网络与智能感知。E-mail: plyang@nuist.edu.cn。

channels and the randomness of communication traffic, CSI measurements are inherently irregular and dependent on packet transmission behaviors. Since sensing systems passively collect CSI from communication packets, low traffic loads or bursty transmissions frequently result in low sampling rates and uneven sampling intervals. Such sparse and non-uniform CSI sequences disrupt temporal continuity, distort motion-related channel dynamics, and ultimately degrade system performance. These issues pose significant challenges to the practical deployment of WiFi-based sensing systems in realistic environments. Traditional interpolation methods, including linear and spline-based approaches, can partially alleviate the problem of insufficient sampling. Nevertheless, these deterministic techniques typically assume smooth transitions between adjacent samples and lack the ability to model complex nonlinear channel variations induced by human motion. As a result, they often suffer from signal detail loss, oversmoothing effects, and cumulative reconstruction errors, particularly under extremely low sampling rates. Consequently, subtle micro-movements and high-frequency components critical for fine-grained sensing cannot be effectively preserved. To address these limitations, this paper proposes CSI-GAN, a WiFi signal sparse recovery scheme designed to reconstruct sufficient and continuous sensing data from sparse and non-uniformly sampled CSI. Inspired by the success of image restoration techniques, we innovatively improve the Generative Adversarial Network (GAN) framework to better adapt to the recovery requirements of WiFi sensing signals. Considering the fundamental differences between CSI and image data representations, CSI-GAN directly processes raw CSI waveforms in the time domain instead of converting them into image-like formats. This design avoids potential spectral damage caused by frequency-domain transformations and enables more faithful recovery of continuous channel variations. To further enhance reconstruction quality, we introduce a novel denoising strategy to suppress hardware noise and environmental interference before recovery. In addition, constraints are imposed in both time and frequency domains to jointly optimize low-level structural features and high-frequency information of the signal. The time-domain constraint ensures waveform continuity and temporal consistency, while the frequency-domain constraint preserves detailed spectral characteristics associated with fine-grained human motion. Extensive experimental results demonstrate that even under extremely low sampling conditions, such as receiving only 10 packets per second, CSI-GAN can accurately recover CSI signals with high fidelity. When applied to practical tasks including gait recognition, gesture recognition, and activity recognition, CSI-GAN achieves at least 16.4% improvement in accuracy compared with traditional interpolation methods and state-of-the-art GAN-based approaches. These results validate the robustness and effectiveness of CSI-GAN, highlighting its strong potential for real-world WiFi sensing applications under sparse and irregular sampling scenarios.

**Keywords** WiFi-based sensing; channel state information; sparse data; generative adversarial network; non-uniform sampling

## 1 引言

在全球智能化转型的背景下,物联网(Internet of Things, IoT)和人工智能(Artificial Intelligence, AI)技术迅速发展,推动着智慧城市和数字经济建设。国家对隐私保护和高效资源利用的需求日益

增加,这也促使了创新型感知技术的不断涌现。近二十年来,随着移动互联网设备的激增,WiFi接入点(Access Point, AP)已经成为智能环境中无处不在的基础设施,从智慧办公到智能家居场景,都在为人类提供新的服务。得益于这种普适性,基于WiFi的环境和人员感知技术也备受关注,越来越多的研究可以实现丰富且复杂的感知任务,成为学术界和

工业界的研究热点。这类技术利用现有的 WiFi 基础设施,能够感知和理解周围环境和人员的状态,进而实现各种复杂的智能化应用。尤其在一些隐私保护要求较高或传感器部署成本昂贵的环境中,WiFi 感知系统的优势更加显著。

特别是,WiFi 信道状态信息(Channel State Information,CSI)因其细粒度的特性,成为支持各种高级感知任务的关键信号数据形式。例如,CSI 可以应用于目标追踪<sup>[1-2]</sup>、活动识别<sup>[3-4]</sup>、步态识别<sup>[5-6]</sup>、手势识别<sup>[7-8]</sup>、呼吸速率监测<sup>[9-10]</sup>和材料识别<sup>[11-12]</sup>等诸多领域。与粗粒度的接收信号强度指示(Received Signal Strength Indication,RSSI)不同,CSI 反映并记录了 WiFi 通信链路的信道属性,它描述了信号在各传输路径上的衰减因子,即信道矩阵  $\mathbf{H}$  中各元素的值,如信号散射、多径传播、阴影衰落、距离功率衰减等<sup>[13]</sup>,这使得 CSI 可以对环境中物体的移动、姿态变化以及动作进行敏感地检测。因此,当目标处于不同的位置或人类执行不同的动作时,他们会以不同的方式吸收或反射 WiFi 信号,这使得 CSI

的值不同。WiFi 感知系统通过标记不同状态下的 CSI 值,并分析 CSI 的信号模式,从而能够实现特定的感知任务。

目前,一些工具已经能够使用某些 WiFi 网卡从接收到的数据包中提取 CSI 并解析出信道矩阵  $\mathbf{H}$ ,例如 Intel 5300 CSI Tool<sup>[14]</sup>、Atheros CSI Tool<sup>[15]</sup>、Nexmon CSI Extractor<sup>[16]</sup>和 PicoScenes<sup>[17]</sup>等,从而展示了 WiFi 感知应用具有与 WiFi 通信基础设施集成的巨大潜力。然而,大多数 WiFi 感知系统严重依赖于充分 CSI 的获取,极大地阻碍了它们在现实环境中的普及,如图 1 所示,这主要体现在两个方面:(1)稀疏数据:通常,CSI 只能在 WiFi 设备通信期间进行估计。因此,当 WiFi 设备运行在低通信流量状态时,CSI 的采样率显著降低,从而无法满足细粒度感知任务的要求。(2)非均匀采样:WiFi 技术中基于竞争的多路访问特性使得相邻数据帧的时间间隔出现显著变化,导致数据帧的到达率不规则,CSI 的采样呈现非均匀状态,从而影响感知性能。




图1 实际 WiFi 通感系统中的 CSI 存在稀疏数据和非均匀采样的问题

为了在复杂环境下实现高效的 WiFi 感知应用,充分且均匀的 CSI 获取至关重要。稀疏数据和非均匀采样不仅削弱了 CSI 的时序相关性,还降低了感知的分辨率,从而影响系统的感知准确性。尽管这一问题在 WiFi 感知领域广泛存在,但目前大多数系统都假设能够持续获取充分的 CSI 数据,而并未有效解决实际数据采样不足和不均匀的问题。为了应对稀疏数据,现有的一些方法如线性插值和样条插值被广泛采用<sup>[18-19]</sup>。这些方法基于已知采样点之间的插值来恢复数据,例如线性插值假设两个相邻采样点之间的变化是线性的,利用已知点来插值出中间值。相比于线性插值,样条插值能够生成更加平滑的曲线,它通过每一段数据点来拟合多项式,适合处理非线性变化。然而,这些方法有一定的局限性,线性插值容易导致在复杂环境下数据恢

复不准确,无法捕捉 CSI 的复杂变化,而样条插值虽然能提供平滑的曲线,但对快速变化的场景表现不足,且计算复杂度较高。这些方法在处理真实世界的稀疏数据时,通常无法有效恢复出足够准确和具有细节的 CSI 信息。因此,当前急需一种更加有效的稀疏数据恢复方案,以应对 WiFi 感知系统中普遍存在的稀疏数据和非均匀采样问题。

近年来,生成对抗网络(Generative Adversarial Network,GAN)在图像修复、超分辨率等领域广受欢迎<sup>[20-21]</sup>。它通过学习数据分布,能够有效填充缺失像素或生成高质量的图像。然而,在之前的研究中,GAN 的应用主要集中在其他领域,利用其数据生成能力合成虚拟样本,促进领域适应,并非用于数据恢复或生成具体的信号<sup>[6,22-26]</sup>。受到 GAN 应用的启发,我们专注于利用 GAN 的全局信息感知能

力来恢复稀疏的 CSI 数据。相比传统的生成任务,我们的目标是通过 GAN 高效地恢复并优化 CSI 数据,为 WiFi 感知任务提供更加精确的基础数据支撑。

为了实现上述目标,我们还面临几个重要挑战。首先,如何构建适用于 WiFi 信号恢复的 GAN 学习模型是一个难点。与图像数据不同,CSI 具有独特的时频特性,虽然一些研究将 WiFi 信号从时域转换到频域或图像<sup>[27-28]</sup>,但这种转换可能会导致重要感知信息的丢失。因此,我们设计了一个直接在原始 CSI 波形上运行的新生成模型,旨在从稀疏的采样中恢复出连续的信道变化。其次,CSI 数据中较大的采样间隔对恢复算法构成了极大挑战,而传统方案难以处理这些较长的间隔。为此,我们提出了一个基于短时傅里叶变换(Short-Time Fourier Transform, STFT)的新频域损失函数,能够有效生成缺失的频率成分。该方法同时参考时域和频域的信息,增强了恢复精度,并更好地保留了 CSI 频谱的细节。最后,原始 CSI 包含多种未知噪声,直接对其恢复容易导致信号失真。为解决这一问题,我们的思想是采用有效的噪声抑制手段,并恢复中间态的时域 CSI 数据,以增强具体的感知系统性能。

综上所述,本文的主要贡献包括 4 个方面:

(1)我们提出了一种基于生成对抗网络的稀疏 WiFi CSI 数据的恢复方案 CSI-GAN,旨在从稀疏和不均匀的 CSI 采样中恢复出充分且连续的 WiFi 感知数据,以推进实际应用中的 WiFi 感知系统。

(2)为避免在将信号从时域转换到频域时损失 WiFi 信号,我们提出了一种新的恢复模型,该模型直接在原始 CSI 波形上运行,以从间歇性稀疏样本中恢复出连续的信道变化。

(3)为提高信号恢复的质量,我们引入新的去噪方法,并在时域和频域上应用了损失函数,从而在恢复高质量的时间序列信号方面取得了显著成效。

(4)我们使用 WiFi 手势识别公共数据集 Wistar3.0 以及我们在实际场景中收集的步态和活动数据集 OurGait 和 OurActivity 评估了系统的性能,与两种插值方法和最新基于 GAN 的方法的比较结果表明,在不同数据包速率下,我们的方案在恢复 WiFi 信号方面更出色。

## 2 背景知识与相关工作

在本节中,我们将重点介绍与本文相关的背景

和相关工作,主要包括四个方面:WiFi 感知的基本数据形式、采样对 WiFi 感知系统的影响、基于 GAN 的 WiFi 感知系统和现有的 CSI 数据恢复方案。

### 2.1 WiFi 感知的基本数据形式

最近的 WiFi 技术普遍使用正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)和多输入多输出(Multiple-Input Multiple-Output, MIMO),因此发射器-接收器(Transmitter-Receiver, TX-RX)之间的信道由多个天线对和多个子载波组成。众所周知,信道矩阵  $\mathbf{H}$  是复数矩阵,对于 TX-RX 天线对  $n$  和子载波  $k$ :

$$\mathbf{H}(n, k) = \|\mathbf{H}(n, k)\| \cdot e^{j\angle \mathbf{H}(n, k)} \quad (1)$$

其中,  $\|\cdot\|$  和  $\angle \cdot$  分别表示 CSI 的幅值与相位。当人类进行不同的活动时,他们会以不同的方式吸收或反射 WiFi 信号,从而产生不同的 CSI 值。基于 WiFi 的感知系统标记这些不同的 CSI 值,并使用物理模型或深度学习网络来识别不同的人类活动。为了准确感知人类活动,目前的大部分工作都是基于散射模型来分解信号<sup>[7]</sup>:

$$\mathbf{H}(n, k, t) = \sum_{i=1}^{N_i} \gamma_i(n, f, t) e^{-j\phi_i(n, f, t)} \quad (2)$$

其中,  $N_i$  表示反射路径总数,  $\gamma_i$  和  $\phi_i$  是第  $i$  条反射路径的幅值衰减和相位。现有技术通过从散射模型中求解动态反射路径的时频特性,可以获得与人类活动相关的特征,从而实现 WiFi 感知任务。

### 2.2 采样对 WiFi 感知系统的影响

在 WiFi 感知系统中,采样率和采样均匀性是影响感知性能的关键因素。根据奈奎斯特采样定理,若采样频率低于信号带宽的两倍,会造成高频成分混叠,使得时域波形出现形变,频域上也会出现伪频率成分,从而削弱对细粒度运动特征的刻画能力。此外,非均匀采样会使时间间隔不稳定,导致信号的瞬时变化无法被正确捕获,从而在频域造成谱线展宽与能量泄漏,影响特征提取质量。为了直观展示采样率对步态感知的影响,我们在真实场景中以 1000 Hz 的高采样率记录了人类行走的 CSI 数据,并分别将其降采样到 100 Hz、50 Hz 和 20 Hz,得到不同采样条件下的时域波形和对应的时频谱图,如图 2 所示。从图中可以观察到以下现象:

(1)时域层面:当采样率从 100 Hz 降低到 20 Hz 时,原本连续、平滑的步态振荡波形开始出现明显的阶梯化与形变,步幅对应的周期结构逐渐模糊;部分快速变化的细节(如脚步落地引起的局部幅值突变)在低采样率下无法被记录。此外,低采样率使得不




图2 不同采样率下人类行走的时域信号波形((a)~(c))和时频谱图((d)~(f))

同子载波之间的相对变化模式难以保持一致,进一步削弱了跨子载波的运动相关性。

(2)频域层面:在高采样率下,行走活动的多普勒能量集中在 15-30 Hz 范围内,结构清晰;当采样率降低到 50 Hz 时出现明显谱线展宽与能量混叠,部分高频成分被折叠至低频区域;降至 20 Hz 时,时频谱图几乎失去可辨识的周期性结构,行走的主频峰值与谐波特征均被破坏。

因此,低采样率不仅影响频谱,还会直接破坏时域波形,这意味着后续基于时序模型或基于频率特征的感知任务均会受到干扰。因此,采样率不足和采样不均匀会共同导致系统对步态等动态行为的描述能力下降。综上所述,高采样率能够保留完整的时间结构与频率结构,而低采样率会造成明显的时域形变和频谱混叠,难以准确刻画人体行为模式。

更具体地,我们以步态识别和手势识别系统为例分析采样如何干扰 WiFi 感知任务。步态识别中,人体的运动节奏较为缓慢,但步伐的周期性和每一步的细微变化都依赖于较为精确的 CSI 信号捕捉。低采样率会导致步态细节的丢失,例如步伐的加速度和相位变化等无法被准确捕捉,进而影响步态模式的提取,导致相似步态(如慢走和快走)之间难以区分。而在非均匀采样情况下,步态的时间序列特征会受到干扰,CSI 中的多径信息变得不稳定,从而影响步态识别的准确性。手势识别则需要更高的采样率,因为手部动作通常较为快速且复杂。如果采样率过低,快速手势中的细微动作会被忽略,信号可能出现模糊或失真,导致系统无法准确检测到手部的动态变化,识别效率和准确性下降。而非均匀采样的影响在手势识别中表现得更加明显,因为

手势动作的细微时间差异对于 CSI 信号至关重要。非均匀采样会使手势动作特征出现错位,导致系统的实时响应性下降,甚至产生误判。因此,采样率低和采样不均匀都会显著影响 WiFi 感知系统的能力。特别地,我们根据在真实世界手机的 CSI 数据验证了这一影响,结果如图 3 所示。我们可以看到,随着采样率的降低,手势识别和步态识别的准确率均在下降,且在 20 Hz 时低于 70%。




图3 不同采样率下 WiFi 感知的准确率

## 2.3 现有的 CSI 数据恢复方案

为了应对 WiFi 感知系统中 CSI 采样率低和采样不均匀的问题,传统方案通常采用插值方法,如线性插值和样条插值。这些方法简单易用,但容易导致信号细节丢失和插值误差较大,无法充分解决低采样率和不均匀采样的问题。为此,近年来提出了一些更先进的 CSI 数据恢复方案。FallDeFi<sup>[18]</sup>引入线性插值来获得均匀 CSI 以提升跌倒检测的识别精度。SenCom<sup>[19]</sup>通过拟合重采样和主动注入检测数据包来改善采样精度,尽管能缓解不均匀采样的问题,但这种方法增加了网络负载,可能影响 WiFi 性能,且需要额外设备支持。Muse-Fi<sup>[27]</sup>采用稀疏恢复算法与基于时间卷积网络(Temporal Convolutional Network, TCN)的自动编码器相结合,恢复

信号频谱中的稀疏部分,提升了信号重建的精度。WiImg<sup>[28]</sup>通过将 CSI 样本转换为图像,利用 GAN 进行图像修复,降低了对高采样率的要求。然而,把 WiFi 信号转化到频域或图像处理可能导致部分信号细节丢失,且对高质量训练数据有较强依赖性,导致训练过程不稳定,数据恢复效果不佳。

## 2.4 基于生成模型的 WiFi 感知系统

由于 GAN 的强大能力及其在图像领域的广泛应用,最近有一些研究探索了基于 GAN 的 WiFi 感知应用。这些工作主要使用 GAN 模型的数据生成能力来合成目标领域中的虚拟样本并促进域适应。例如,CsiGAN<sup>[22]</sup>引入了一种半监督的 GAN 网络,通过生成补充的虚假数据样本来提高新用户在执行活动时的识别准确性,这种方法有效地增强了模型在处理新用户数据时的泛化能力。WIARGAN<sup>[24]</sup>和 WiGAN<sup>[23]</sup>也致力于扩展 WiFi 数据的容量和多样性,旨在生成更多样化的样本,从而提升系统对不同场景和环境下活动的识别效果。DMNet<sup>[25]</sup>和 GNG<sup>[26]</sup>也利用 GAN 技术生成额外样本,以增强 WiFi 感知系统在活动识别任务中的表现,通过增加训练数据集的多样性来提升模型的鲁棒性。Meta-GANFi<sup>[6]</sup>采用条件循环 GAN,其设计目标是过滤掉由不同干扰域引起的不相关扰动,从而在步态识别中抑制其他外部因素的干扰。此外,受视觉领域成功经验的启发,扩散模型也开始被引入射频感知研究。例如,RF-Diffusion<sup>[29]</sup>提出了射频扩散方法,利用时频扩散理论来增强原有的扩散模型,从而能够生成多样化和高质量的时序射频数据。Xu 等

人<sup>[30]</sup>设计了一种基于扩散模型的人体活动识别数据增强方案,以生成与多种活动对应的 WiFi 数据,从而避免为每种活动单独训练模型。然而,尽管这些 GAN 和扩散模型的方法在活动识别和数据增强方面取得了显著进展,它们并未直接应用于 WiFi CSI 数据恢复的任务中。它们的目标更偏向于提升识别任务的泛化能力,而不是专门解决采样率低或采样不均匀带来的 CSI 信号缺失问题。

## 3 问题定义与系统概述

在本节中,我们主要介绍问题定义和 WiFi 稀疏数据恢复的系统概述。

### 3.1 问题定义

在本研究中,我们的主要问题是如何有效地从稀疏和不均匀采样的 CSI 中恢复高质量的感知数据。我们的目标是实现一种高效的信号恢复系统,以提升 WiFi 信号在感知任务下的准确性和可靠性,特别是在步态识别和手势识别等细粒度感知任务中。具体来说,我们把实际采集的包含低采样率和不均匀的原始 CSI 时间序列的数据作为输入,在经由 GAN 模型后,输出充分均匀的 CSI 时间序列数据,并通过具体的感知任务评估恢复 CSI 性能。

### 3.2 系统概述

为实现上述目标,我们设计了如图 4 所示的稀疏 CSI 数据恢复系统,它主要包括三个模块:噪声抑制与重采样、稀疏 CSI 数据恢复、感知应用实现。




图 4 系统概述

(1)噪声抑制与重采样:我们从收集的原始 CSI 数据中提取幅值。然后,我们在子载波维度执行主成分分析(Principal Component Analysis, PCA)滤除环境噪声,并消除自动增益控制(Automatic Gain Control, AGC)的影响,以获得干净的 CSI。接下来,我们对 CSI 数据进行切片和重采样,以获得相同维度的输入。

(2)稀疏 CSI 数据恢复:我们把重采样后的 CSI 输入 GAN 中用于稀疏数据恢复。在训练阶段,我们从高采样率且均匀的原始 CSI 数据  $Y(t)$  中根据特定策略进行随机采样后的数据  $X(t)$  作为稀疏数据,并最小化  $X(t)$  和  $Y(t)$  之间的损失来训练一个生成函数;在预测阶段,直接把处理后的 CSI 数据输入生成函数中并输出恢复后的 CSI。

(3)感知应用实现:在获取高采样率且均匀的 CSI 数据后,我们将其生成频谱图并馈入特征提取和任务分类网络,用于实现具体的感知任务,其中特征提取和任务分类网络的结构与参数细节根据任务确定。

## 4 噪声抑制与重采样方法

在本节中,我们主要介绍对包含噪声的原始 CSI 数据进行噪声抑制和重采样的方法。

### 4.1 子载波维度的主成分分析

在本文中,我们使用商用 WiFi 无线网卡(Intel 5300)来收集 CSI,而原始 CSI 数据包含大量噪声,例如影响幅值的环境噪声与 AGC 引入的波动,影响相位测量值的载波频率偏移与采样频率偏移等<sup>[10,31]</sup>。这些干扰需要在数据处理中被有效消除,以获取用于感知任务的干净 CSI 数据。此外,在恢复稀疏 CSI 数据时,同样需要进行噪声抑制,以提取与感知目标相关的关键特征数据并加速算法的收敛过程。

噪声抑制面临两个主要挑战:首先,与传统感知系统的去噪模式不同,我们必须尽量保持原始 CSI 的分布特性,以避免失去对目标的有效感知;其次,当目标远离 WiFi 收发器或其运动方向与传播路径平行时,信号特征可能会被噪声所掩盖。基于这两个挑战,传统的去噪方法如小波去噪和高斯滤波在弱信号提取方面效果有限<sup>[32]</sup>。而最近应用于 WiFi 感知系统的比值法<sup>[9]</sup>虽然可以消除部分噪声,但往

往会改变原始 CSI 的分布特性,影响感知结果的准确性。此外,传统的 PCA 去噪方法<sup>[3]</sup>,其在时间维度上的有效性高度依赖于主成分数量的选择。如果选择过多或过少的主成分,可能导致环境噪声的残留或重要目标信号的丢失,尤其是在目标信号被环境噪声掩盖的情况下,PCA 去噪的效果显著下降,因为主成分不再能准确表征目标信号。值得注意的是,由于相位测量噪声在满足上述要求时难以恢复,因此我们主要关注与幅值相关的稀疏恢复。

为了从稀疏数据中恢复出充分均匀的 CSI 幅值并保留原始分布,我们将重点转移到子载波维度。一个重要的观察是在环境不变的条件下,每个子载波的传播路径是相似的,且环境噪声通常在整个空间中遵循高斯分布<sup>[10,33]</sup>。通过转置 CSI 矩阵,我们可以表示环境中所有子载波随时间的反射路径。如图 5(a)所示,在子载波维度,CSI 幅值的变化对应于目标运动引起的反射路径的变化。假设静态环境不变,子载波维度的 CSI 数据表现出更高的相关性。我们采用协方差方法来计算在不同距离收集的 CSI 数据的 PCA,并测量它们的相关性。如图 5(b)所示,虽然第一主成分在时间维度上的贡献随着距离的增加而减小,但第一主成分在子载波维度上的贡献在不同距离上始终保持较高水平。因此,通过在子载波维度应用 PCA,我们可以仅使用第一主成分有效地消除环境噪声,并保留原始 CSI 的分布特性,结果如图 6(a)、(b)所示。




图5 子载波维度的 CSI 数据与 PCA 第一主成分分析效果




图6 原始 CSI 数据的噪声抑制效果

具体来说,我们遵循传统 PCA 算法的基本原理,将 CSI 矩阵  $\mathbf{A}$  (子载波为列,时间为行)按子载波维度(即每个时间点的多个子载波为一组数据)作为输入。首先,采用较为通用的协方差方法计算 CSI 矩阵的 PCA,即对每个子载波减去其时间均值,得到中心化矩阵,计算中心化矩阵的协方差矩阵,并进一步对协方差矩阵进行特征分解,获得特征值  $\mathbf{D}$  和特征向量  $\mathbf{P}$ 。然后,我们选取最大特征值对应的特征向量,并对中心化矩阵进行投影,根据投影结果重构 CSI 幅值,并加回均值得到去噪后的 CSI 矩阵  $\hat{\mathbf{A}}$ 。

#### 4.2 AGC 影响的抑制

去除环境噪声后,AGC 引入的波动仍然会干扰目标信号的连续性,如图 6(b)所示,我们需要抑制 AGC 的影响以有效恢复稀疏 CSI 数据。先前的方案使用比值法去除 AGC 的影响<sup>[9]</sup>,但会改变原始 CSI 的分布;另外,由于 AGC 引起的波动分量与目标运动分量高度相关,因此在子载波维度中去除 AGC 引起的波动也是非常困难的。我们的关键观察是 AGC 引起的波动是时间维度上目标运动分量周围的不确定且稀疏的点<sup>[34]</sup>,因此我们可以根据稀疏密度分布滤除 AGC 引起的波动。具体来说,我们利用基于密度的噪声应用空间聚类(Density-Based Spatial Clustering of Applications with Noise, DBSCAN)方法根据 AGC 相关点的稀疏分布密度对其进行聚类,并仅保留散点数量最多的簇,并通过 K 均值进行自动半径搜索,结果如图 6(b)、(c)所示。

具体来说,AGC 引入的主要是幅度增益的动态波动,其特点并非持续偏移,而是围绕实际行为动作轨迹出现的局部、稀疏且不规则的离散偏移点。这类点在时间-幅度平面中的密度通常显著低于由目标运动形成的主分布带。因此,基于密度的聚类方法 DBSCAN 能够将高密度、连续分布的真实运动轨迹与由 AGC 波动造成的低密度离散点区分开来。由于 DBSCAN 不依赖簇的形状假设,能够处理线性或弧形等任意结构的主分布,其在识别“密集主簇+稀疏异常点”的结构上具有天然优势。此外,通过利用 K 均值估计子载波散点的局部尺度,可以自适应地确定搜索半径,使 DBSCAN 在不同环境与不同设备条件下依然能够稳健地区分 AGC 引入的稀疏波动点。通过上述密度差异建模与自适应参数选择机制,我们能够在不破坏幅值分布结构的前提下,实现对 AGC 影响的有效抑制。

#### 4.3 数据切片与重采样

在完成环境噪声和 AGC 影响的抑制后,CSI 数据需要输入到稀疏恢复模型中进行学习与推断。由于原始 CSI 序列往往较长且不同数据段采样长度不一致,我们在输入恢复模型之前对时间序列进行切片和重采样。具体而言,我们将较长的 CSI 序列划分为 2 秒的固定长度切片,以在输入长度、感受野范围、计算资源和模型性能之间取得平衡。时间切片的作用主要体现在两个方面。首先,从模型结构的角度来看,生成器与判别器等模型均基于卷积与循环单元构建,其有效感受野是有限的。2 秒片段能够覆盖典型的人体运动模式(如手势的一个完整动作周期或步态的若干关键阶段),为模型提供足够的上下文,使其能够捕获跨时间的相关性。如果输入序列过长,超出模型的有效感受野,长距离依赖将被稀释,从而削弱恢复效果。其次,从训练稳定性与资源消耗的角度,为模型直接输入长序列会导致 GPU 内存占用和计算时间显著增加,而合理的切片长度能够在保持恢复精度的同时提升训练效率。当然,时间序列的切割也可能导致 CSI 信号的连续性不足,进而影响恢复效果,特别是当信号存在较长的时序依赖时,切片处理可能削弱模型捕捉全局特征的能力,导致跨片段的恢复精度下降。

为了确保所有片段具有一致的输入长度,我们对数据集中的每段信号执行插值或下采样,使其达到统一的目标采样频率  $f_t$ 。这一处理对恢复模型至关重要,因为不同设备或环境可能产生不同的采样频率,不一致的采样过程会导致输入维度不统一,从而影响模型的训练稳定性和泛化性能。通过重采样,所有片段被调整到一致的时间尺度,使模型能够学习统一表示,减少频率差异带来的偏差。在具体实现中, $f_t$  的选择基于下游任务的动态特性。例如,在手势识别和步态识别任务中,人类动作具有较高的时间变化率,对时间分辨率要求较高,因此我们将  $f_t$  设定为 1000 Hz。该采样率已在多个相关研究中得到验证,并被证明能够有效捕捉人体运动中的细微变化<sup>[5]</sup>。最终,时间切片加重采样的组合既保证了模型输入格式的统一性,又为后续 GAN 恢复模型的稳定训练提供了必要前提。

### 5 基于 GAN 的稀疏数据恢复模型

在本节中,我们主要介绍用于稀疏数据恢复的 GAN 模型的设计与实现,以及对 CSI 数据的优化方案。

## 5.1 模型总览

在本文中,我们提出了一种基于 GAN 的稀疏数据恢复模型,用于在时间序列 CSI 波形上执行恢复任务。该模型的核心思想是通过学习稀疏采样信号的特征,将受实际流量影响而产生的间歇性稀疏样本  $\mathbf{X}(t)$  恢复为连续的信道变化  $\mathbf{Y}(t)$ ,从而准确重建信号的动态变化。模型不仅在时间维度上执行恢复,还利用多个子载波数据作为输入通道,以充分利用空间信息,提高恢复的精度和鲁棒性。模型基于 GAN 框架<sup>[35]</sup>,由生成器 G 和判别器 D 两部分组成,通过对抗训练不断提升恢复质量,如图 7 所示。




图 7 基于 GAN 的稀疏数据恢复模型的生成网络和判别网络结构

## 5.2 生成网络

生成器是整个稀疏数据恢复模型的核心部分,其任务是接收稀疏采样的 CSI 数据作为输入,学习稀疏数据与完整数据之间的映射关系,补全缺失的部分,生成具有连续性和一致性的恢复信号序列。

如图 7(a)所示,我们采用了深度卷积神经网络作为生成器的基础架构,其中核心组件是残差块(Residual Blocks)。残差块的引入不仅能够缓解深度网络中的梯度消失问题,还可以增强模型对稀疏 CSI 数据的时空特征提取能力。我们参考 SRGAN 的设计<sup>[36]</sup>,用两个具有  $9 \times 9$  内核和 64 个特征图的卷积层,这样能够捕捉 CSI 数据中的局部特征,同时减少参数量,提高计算效率。然后是批量归一化层(Batch Normalization, BN)和 Parametric ReLU (PReLU)激活函数,以确保训练过程的稳定性和信号处理的灵活性。

生成器网络的输入为多个子载波的稀疏 CSI 时间序列信号,输出为恢复后的完整信号序列。通过卷积神经网络层,生成器能够充分利用子载波间的空间依赖性,联合处理稀疏信号,从而在时间和空

其中,生成器 G 负责生成与真实数据分布相似的稀疏数据补全结果,对于稀疏数据恢复,生成器接受稀疏数据输入,学习从不完整数据生成完整数据的映射;而判别器 D 用于区分生成的数据和真实数据,其目标是将生成器生成的假数据与真实数据进行对比,以此指导生成器提高生成数据的质量。在模型的输入与输出设计上,输入数据为多个子载波的稀疏采样信号  $\mathbf{X}(t)$ ,输出为完整的连续信号  $\mathbf{Y}(t)$ ,其中每个时间点都包含子载波的联合信息。通过这种设计,模型可以有效处理时间和空间上的稀疏性问题。

间维度上捕捉重要特征。该架构不仅恢复了稀疏数据中的丢失部分,还确保生成的信号保持与原始数据的连续性和一致性,生成高质量的信号补全结果。

## 5.3 判别网络

判别器在 GAN 框架中负责鉴别生成器输出的信号是否接近真实数据,从而引导生成器不断优化其生成结果。它通过区分生成信号与真实信号,确保生成信号在时间和空间上都准确捕捉到信道的变化特征。如图 7(b)所示,判别器的设计参考了 Radford 等人的架构<sup>[37]</sup>,使用 LeakyReLU 激活函数,避免最大池化操作,保留更多的输入细节信息。其结构由四个下采样块和四个上采样块组成,分别用于提取信号的时空特征和恢复空间分辨率。

在判别过程中,信号首先经过下采样块,逐层缩小空间分辨率并提取重要特征。每个下采样块包含卷积层和 LeakyReLU 激活函数,确保在局部提取信号的关键特征,缓解稀疏数据中的信息丢失问题。接着,信号通过上采样块恢复空间分辨率,结合提取的时空特征,以更精确地区分生成和真实信号。最终,通过平均池化层和 sigmoid 激活函数输出分类

结果,表示输入信号属于真实数据的概率。判别器通过这种设计有效学习全局时空特征,提升生成信号的真实性和指导生成器优化。

#### 5.4 模型优化与损失函数

在构建稀疏 WiFi 信号恢复模型的过程中,我们采用了一个综合损失函数,以优化生成器在时域和频域的表现。此损失函数通过在时域和频域增加约束,使模型能够更全面地捕捉信号的特性,从而提高恢复效果。

时域损失( $L_t$ )是模型优化的基础,专注于信号的低频特征。我们采用均方误差(Mean Square Error, MSE)作为损失度量,以评估生成器恢复信号与真实信号之间的差异:

$$L_t = E_t [|\hat{\mathbf{Y}}_t - \mathbf{Y}_t|^2] \quad (3)$$

MSE 是图像和音频修复领域广泛使用的标准损失函数,其简单而有效的特性使得生成器能够在时域中保持信号的连续性和一致性。通过这一约束,模型能够有效捕捉到信号的基本轮廓,确保生成的信号在时域上与原始信号保持相似。需要强调的是,与传统 GAN 仅依赖判别器提供的分布级信号不同,我们额外引入的时域约束能够直接引导模型关注稀疏片段的连续性和低频结构,这对于 CSI 这种以慢变趋势与周期性波动为主的射频信号具有关键作用。借助显式的点对点回归约束,模型可以在恢复过程中减少时域漂移与突变,有效提高稀疏填充的平滑性与物理一致性。

为了进一步增强模型的恢复能力,我们引入了频域损失( $L_f$ ),其核心在于针对信号的高频成分进行优化。频域损失的计算基于 STFT,它将信号从时域转换到频域,使得频谱特征更加明确。具体而言,我们通过计算生成信号和真实信号在频谱幅度上的 L1 损失,来量化它们之间的差异:

$$L_f = \frac{1}{AB} \sum_{a=1}^A \sum_{b=1}^B ||\hat{\mathbf{S}}|_{a,b} - |\mathbf{S}|_{a,b}|| \quad (4)$$

其中,  $\hat{\mathbf{S}}$  和  $\mathbf{S}$  分别表示恢复信号和真实信号的频谱幅度,  $A$  和  $B$  分别表示时间和频率分量的数量。这一约束特别关注高频信息的恢复,允许模型在恢复稀疏部分时,更有效地重建缺失的频率成分。频域损失不仅强调了高频信息的重要性,还通过傅里叶变换的全局特性,为训练提供了更全面的指导,使得模型能够在恢复过程中从全局视角考虑信号特征。由于稀疏采样会破坏高频信息,导致 CSI 波形出现尖锐跳变或不自然地过度平滑,传统 GAN 的判别

器难以仅凭时域判别这些差异。通过显式加入频域约束,我们能够迫使生成器对频谱细节进行恢复,尤其是对用户动作、移动反射路径等对应的高频扰动,使其在恢复过程中同时满足时域连续性与频域结构一致性。

综上所述,通过在时域和频域增加约束,我们的整体损失函数实现了对信号的全面优化,兼顾了低频与高频信息的恢复。在训练过程中,时域损失确保生成信号保持时间上的连贯性,而频域损失则增强了对信号高频成分的精确重建。这样一来,生成器能够在更大范围内提高恢复信号的质量,使生成的稀疏数据与真实信号更加接近。这种双域联合优化的机制也构成了本模型与传统 GAN(仅使用判别器损失+单域回归)的关键区别,其优势在于能够同时约束局部连续性与整体频谱结构,使恢复出的 CSI 信号在物理特性上更加逼真。

此外,当真实信号输入判别器时,标签  $y_i$  为 0;当生成的数据输入判别器时,则标签  $y_i$  为 1,我们使用二元交叉熵(Binary Cross Entropy, BCE)作为判别器的损失函数( $L_d$ ):

$$L_d = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (5)$$

其中,  $N$  是样本数量,  $p_i$  是判别器对真实信号的输出概率。

因此,我们模型的整体损失函数为

$$L_{\text{GAN}} = \alpha L_t + \beta L_f + L_d \quad (6)$$

其中,  $\alpha$  和  $\beta$  是超参数。通过调整  $\alpha$  与  $\beta$ , 模型能够在时域平滑性与频域细节之间进行权衡,使其适配不同应用场景下对恢复速度、质量与细节敏感度的需求。

## 6 感知应用实现

本文的重点在于如何通过 GAN 模型有效恢复稀疏数据,但我们同样关注如何利用这些恢复后的 CSI 数据进行具体的感知任务实现。为此,我们采用了一些已有的成熟感知模型,如卷积神经网络(Convolutional Neural Network, CNN)和长短时记忆网络(Long Short-Term Memory, LSTM),以便在手势识别和步态识别等领域进行应用<sup>[5,7,38]</sup>。具体来说,在感知应用实现过程中,我们利用恢复后的 CSI 数据生成对应的时-频谱图,并将其作为输入送入上述感知模型以进行特征提取和任务分类。

在感知任务中,我们采用常见的 2D CNN 与 LSTM 组合结构:2D CNN 用于从生成的时-频谱图中提取局部空间特征,并通过最大池化层获得更加稳定的特征表示;随后,将 CNN 输出的时间序列特征按时间展开后输入至 LSTM,以捕获跨时间的长期依赖关系。该结构在相关研究中被广泛采用,并能够适配多种 CSI 感知任务。在训练阶段,我们采用监督学习方式,以交叉熵损失为优化目标,对 CNN-LSTM 模型进行端到端训练。所有模型参数(包括卷积层与 LSTM 单元)均通过标准反向传播算法进行更新。为确保实验的可比性与公平性,感知模型始终在相同的训练集上进行训练,并在原始 CSI 与恢复后的 CSI 上分别评估性能,以量化 CSI-GAN 对下游识别任务的提升程度。在推理阶段,我们首先将稀疏 CSI 输入 CSI-GAN 得到其恢复版本,随后将恢复后的时-频谱图输入固定的 2D CNN-LSTM 模型,即可完成对应的识别任务。尽管感知应用的实现并非本文的核心,但通过利用成熟的深度学习模型与统一的训练-推理流程,我们能够在不同感知场景中有效评估 CSI-GAN 的恢复效果,从而验证其在下游应用中的潜在价值。

## 7 实验设置与结果分析

在本节中,我们主要介绍用于数据和系统评估的设置,并展示详细的实验结果。

### 7.1 数据集说明

为了全面评估该方法的性能,我们特别选择了三类对高采样率要求较高的应用场景:手势识别、步态识别和活动识别。在步态识别实验中,我们在两台配有 Intel 5300 网卡的工控机(Industrial Control Computer,IPC)上安装了 CSI 采集工具 Linux CSI Tool<sup>[14]</sup>,并在注入/监控模式下进行 CSI 数据收集,设置采样率为 1000 Hz。实验中,发射端 Tx 配备了一根天线,而接收端 Rx 则配备了三根天线,所有设备均安装在距地面 0.5 米的三脚架上,以更有效地捕捉到人体运动产生的信号变化。如图 8 所示,我们在 Tx 和 Rx 之间设置了 6 米的距离进行实验。在实验过程中,每位志愿者被要求沿着预定的三个轨迹行走,并且每条轨迹需重复三次以确保数据的可靠性。我们招募了三名不同身高和体重的志愿者,以记录不同个体在行走过程中产生的 CSI 数据(记录为 OurGait 数据集)。在活动识别实验中,基本设置与步态识别实验相同。在实验过程中,三位

志愿者被要求执行 4 种不同活动(正常行走、弯腰、挥手、站立静止),每种活动重复 10 次(记录为 OurActivity 数据集)。




图 8 OurGait 数据集和 OurActivity 数据集的实验场景设置

此外,我们还利用了 Widar3.0 公开数据集来进行手势识别实验<sup>[7]</sup>。Widar3.0 是目前最大的手势识别 WiFi 感知数据集,包含 22 个类别和 43000 个样本,数据是通过 Intel 5300 网卡在多个不同环境中使用  $3 \times 3$  的天线配置收集的。通过结合这些数据集,我们能够有效评估提出的方法在实际应用中的表现,确保其在高采样率条件下的有效性和可靠性。

### 7.2 部署与参数设置

为了实现系统的高效部署,我们设计了参数设置以模拟间歇性数据传输的特性,并优化了各个模块的性能。我们采用随机屏蔽不同比例的原始 CSI 数据来模拟间歇性采样。例如,采样率为 1000 Hz 的原始数据,屏蔽 75% 的数据意味着将采样率降低至约 200 Hz。此后,我们对这些稀疏数据进行去噪和重采样处理。这个过程在配备 AMD-6800HS 3.2 GHz CPU 的计算机上并使用 Matlab R2023b 完成。深度学习模型的训练和预测则在配备 NVIDIA 3090 显卡的服务器上,运行 Python 3.10、CUDA 11.8 以及 Pytorch 2.0 进行。在模型训练中,我们使用了 Adam 优化器,并将学习率设定为 0.001,批处理大小固定为 64。为了保证训练的稳定性 and 性能,所有数据集均采用分层采样策略,训练集与测试集的划分比例为 8:2。损失函数的超参数设置为:  $\alpha = 1$ ,  $\beta = 10$ ,以确保对时域和频域的平衡优化。

### 7.3 基线方法与度量指标

在本文中,我们将设计的稀疏数据恢复系统 CSI-GAN 与 WiFi 传感领域中常用的两种插值方法和当前最新基于 GAN 的方法进行对比。作为基线,我们选择了线性插值法、样条插值法和基于 GAN 网络的 WiImg。两种插值方法是 WiFi 感知

中常见的稀疏数据处理手段<sup>[18-19]</sup>,线性插值方法基于相邻数据点的线性关系来填补缺失值,样条插值法则通过多项式曲线拟合来插值。而 WiImg<sup>[28]</sup>是当前最新基于 GAN 的 CSI 数据恢复方案,其通过将 CSI 样本转换为图像,进而利用 GAN 进行图像修复。

为了全面评估各方法的性能,我们采用了三种主要的度量指标:平均绝对误差(Mean Absolute Error, MAE)、均方误差(Mean Square Error, MSE)和峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)。

(1)MAE 评估模型预测值  $\hat{y}_i$  与真实值  $y_i$  之间的平均差异,它在度量误差时对异常值不敏感,因此能够反映出模型的整体恢复精度。

(2)MSE 评估模型预测值  $\hat{y}_i$  与真实值  $y_i$  之间的波动情况,它在计算误差时对较大误差有更大的权重,因此能够反映出模型对大误差的敏感性。

(3)PSNR 是用来衡量恢复信号质量的指标,特别适用于信号重建,它通过比较信号的最大值与噪声带来的误差,来量化恢复信号的精度。PSNR 越高,表示恢复信号的质量越好:

$$PSNR = 10 \cdot \log_{10} \left( \frac{Y_{\max}^2}{MSE} \right) \quad (7)$$

其中,  $Y_{\max}$  是信号的最大可能值(这里取 1),MSE 是均方误差。

#### 7.4 整体性能

在实验中,我们对比了不同稀疏恢复方案在时

序 CSI 信号和时频谱图上的表现,并给出了一个示例,如图 9 所示,包含真实信号与不同恢复方案(线性插值、样条插值、WiImg 以及我们的 CSI-GAN 模型)的时序 CSI 信号和对应的时频谱图,其中真实信号的采样率为 1000 Hz,而我们将随机降采样到 100 Hz 作为稀疏数据。我们可以看到,传统的插值方法无法准确恢复稀疏数据,尤其是在恢复频谱中的高频分量时表现不佳,WiImg 则能够恢复一部分稀疏数据。相比之下,我们的 CSI-GAN 模型不仅在时域中有效恢复了主要的信号特征,在频域中也成功恢复了大部分频率分量,与真实信号的峰值和模式更为接近。

需要指出的是,图 9 中的结果是在保持通信环境一致的条件下获得的,因此模型能够在较为稳定的信道条件下呈现出与真实信号高度一致的恢复效果。在更复杂或动态变化的环境中,由于稀疏采样带来的信息缺失更为严重,恢复结果与真实信号之间的差异可能会增大。此外,GAN 模型本身具有一定的数据驱动特性,其生成能力也会受到训练集覆盖范围的影响,这意味着当环境变化超出训练分布时,模型的恢复性能可能会下降。因此,图 9 的恢复质量展示了模型在理想条件下的能力边界,也体现了当前方法在跨环境泛化上的潜在局限,这将是未来进一步研究的重要方向。




图 9 不同稀疏恢复方案的时序 CSI 和时频谱图示例

接下来,我们详细分析了不同稀疏数据恢复方案在 OurGait、OurActivity 和 Widar3.0 数据集上的性能,如表 1 所示。随着采样率的降低,所有恢复

方案的 MSE 和 MAE 值都有显著上升,PSNR 值则呈下降趋势。在线性插值、样条插值方案和 WiImg 方案中,恢复效果相对较差,尤其在较低的采样率下,

MSE 和 MAE 值较高,信号失真严重。而我们的 CSI-GAN 模型在两个数据集上都表现出了显著的优势,其 MSE 和 MAE 值明显低于插值方法,PSNR

值则显著提高。这一结果表明,CSI-GAN 模型可以更好地保留时序信号的特征,并显著提升信号恢复的质量。

表 1 不同方案在 OurGait 和 Widar3.0 数据集上的稀疏数据恢复性能对比

| 数据集    |         | OurGait 数据集                      |                                  |                                    | Widar3.0 数据集                      |                                   |                                    |
|--------|---------|----------------------------------|----------------------------------|------------------------------------|-----------------------------------|-----------------------------------|------------------------------------|
| 采样率    | 方案      | MAE( $10^{-2}$ )                 | MSE( $10^{-2}$ )                 | PSNR                               | MAE( $10^{-2}$ )                  | MSE( $10^{-2}$ )                  | PSNR                               |
| 500 Hz | 线性插值    | 1.450 $\pm$ 0.97                 | 0.247 $\pm$ 0.12                 | 22.436 $\pm$ 72.94                 | 2.287 $\pm$ 4.39                  | 6.885 $\pm$ 505.15                | 5.733 $\pm$ 30.21                  |
|        | 样条插值    | 2.834 $\pm$ 0.44                 | 0.304 $\pm$ 0.03                 | 13.213 $\pm$ 52.55                 | 7.853 $\pm$ 1.35                  | 2.805 $\pm$ 0.78                  | 9.804 $\pm$ 19.61                  |
|        | WiImg   | 1.520 $\pm$ 0.71                 | 0.181 $\pm$ 0.05                 | 23.100 $\pm$ 25.31                 | 0.590 $\pm$ 0.08                  | 0.712 $\pm$ 0.41                  | 10.420 $\pm$ 10.77                 |
|        | CSI-GAN | <b>1.373<math>\pm</math>0.63</b> | <b>0.150<math>\pm</math>0.03</b> | <b>24.930<math>\pm</math>22.82</b> | <b>0.475<math>\pm</math>0.07</b>  | <b>0.591<math>\pm</math>0.34</b>  | <b>11.246<math>\pm</math>12.34</b> |
| 250 Hz | 线性插值    | 3.847 $\pm$ 4.72                 | 0.951 $\pm$ 1.20                 | 6.942 $\pm$ 88.07                  | 4.998 $\pm$ 23.34                 | 9.892 $\pm$ 4.60                  | 4.779 $\pm$ 28.06                  |
|        | 样条插值    | 5.404 $\pm$ 1.77                 | 0.818 $\pm$ 0.14                 | 3.003 $\pm$ 61.33                  | 12.123 $\pm$ 5.00                 | 8.099 $\pm$ 4.40                  | -6.209 $\pm$ 27.25                 |
|        | WiImg   | 3.620 $\pm$ 2.71                 | 0.553 $\pm$ 0.17                 | 9.920 $\pm$ 19.88                  | 2.480 $\pm$ 5.03                  | 0.954 $\pm$ 0.58                  | 5.600 $\pm$ 10.80                  |
|        | CSI-GAN | <b>3.409<math>\pm</math>2.60</b> | <b>0.485<math>\pm</math>0.15</b> | <b>10.896<math>\pm</math>20.02</b> | <b>2.151<math>\pm</math>4.71</b>  | <b>0.880<math>\pm</math>0.56</b>  | <b>6.139<math>\pm</math>12.97</b>  |
| 100 Hz | 线性插值    | 7.067 $\pm$ 11.61                | 2.220 $\pm$ 5.64                 | -3.159 $\pm$ 65.24                 | 14.047 $\pm$ 18.71                | 18.591 $\pm$ 38.13                | -12.148 $\pm$ 78.55                |
|        | 样条插值    | 8.447 $\pm$ 2.30                 | 1.560 $\pm$ 0.23                 | -3.975 $\pm$ 111.25                | 23.415 $\pm$ 19.77                | 9.544 $\pm$ 10.25                 | -11.884 $\pm$ 80.95                |
|        | WiImg   | 6.410 $\pm$ 5.95                 | 1.188 $\pm$ 0.59                 | 1.050 $\pm$ 8.13                   | 6.270 $\pm$ 7.52                  | 1.482 $\pm$ 1.33                  | 1.100 $\pm$ 8.82                   |
|        | CSI-GAN | <b>5.784<math>\pm</math>5.27</b> | <b>1.043<math>\pm</math>0.50</b> | <b>2.191<math>\pm</math>9.35</b>   | <b>5.845<math>\pm</math>7.35</b>  | <b>1.314<math>\pm</math>1.30</b>  | <b>1.930<math>\pm</math>9.49</b>   |
| 50 Hz  | 线性插值    | 26.910 $\pm$ 94.60               | 13.085 $\pm$ 5.15                | -32.200 $\pm$ 37.15                | 17.492 $\pm$ 119.62               | 33.993 $\pm$ 10.92                | -23.080 $\pm$ 76.76                |
|        | 样条插值    | 18.224 $\pm$ 11.30               | 6.174 $\pm$ 3.60                 | -17.556 $\pm$ 315.10               | 40.266 $\pm$ 42.70                | 24.196 $\pm$ 18.37                | -31.146 $\pm$ 59.12                |
|        | WiImg   | 12.513 $\pm$ 9.35                | 2.412 $\pm$ 1.50                 | -7.400 $\pm$ 12.11                 | 9.010 $\pm$ 12.61                 | 3.880 $\pm$ 12.60                 | -6.310 $\pm$ 8.21                  |
|        | CSI-GAN | <b>9.342<math>\pm</math>8.58</b> | <b>2.135<math>\pm</math>1.36</b> | <b>-5.918<math>\pm</math>13.78</b> | <b>8.039<math>\pm</math>14.97</b> | <b>3.334<math>\pm</math>12.30</b> | <b>-5.011<math>\pm</math>7.80</b>  |

然后,我们进一步比较了不同稀疏数据恢复方案在 WiFi 感知任务中的识别精度,分别在步态识别、活动识别和手势识别三项任务中进行了评估。如图 10 所示。CNN-LSTM 分类器的实验结果显示,传统插值方法和 WiImg 的精度提升有限,尤其是在较低的采样率下,分类精度较差。而我们的 CSI-GAN 模型,即使在低至 10 Hz 的数据包速率下,仍能保持较高的分类精度,步态识别的准确率达到 81.3%,仅比高采样率下的精度降低了 13.1%,

明显小于插值方案 26.7% 的降低;活动识别的准确率达到 85.2%,仅比高采样率下的精度降低了 10.8%,明显小于插值方案的 16.4% 的降低;手势识别的准确率达到 83.1%,仅比高采样率下的精度降低了 12.2%,明显小于插值方案的 21.8% 的降低。这一表现表明,CSI-GAN 模型不仅能有效恢复稀疏 CSI 数据,还能提高后续感知任务的准确率,展现了优于插值方法和传统基于 GAN 方案的显著优势。




图 10 不同稀疏数据恢复方案在步态识别、活动识别和手势识别中的精度对比

## 7.5 数据长度的影响

在实验中,我们针对步态数据集 OurGait 评估了不同数据长度对系统性能的影响,图 11(a)展示了不同数据长度下的步态识别精度。结果表明,随着数据长度的增加,准确度逐渐提升。这是因为更长的时间序列能够为模型提供更多上下文信息,从

而帮助其更好地捕捉长期的时间依赖性。然而,较长的数据长度也带来了更高的计算成本,包括内存使用和计算时间的增加。这种额外的计算开销可能对训练和推理的效率产生负面影响,尤其是在资源有限的情况下。值得注意的是,尽管仅使用了 0.2 秒的数据来恢复,步态识别精度仍超过 80%。因

此,尽管较长的数据长度在精度方面具有优势,但在实际应用中需要权衡精度提升和计算资源消耗。

### 7.6 噪声抑制方案的影响

我们还评估了我们噪声抑制方案的有效性。具体来说,我们在步态数据集上比较了不同去噪方法的恢复性能,包括无去噪方案、中值滤波、小波去噪和我们的去噪方法。如图 11(b),我们展示了这些去噪方案的对比结果,清楚地表明我们的去噪方法




图 11 数据长度和噪声抑制方案的影响

### 7.7 损失函数的影响

最后,我们还对生成网络在不同损失函数配置下的表现进行了评估,具体包括没有频域损失函数的  $L_d + L_t$ 、没有时域损失函数的  $L_d + L_f$ ,以及同时包含时域和频域损失函数的完整模型  $L_d + L_t + L_f$ ,结果如图 12(a)和图 12(b)所示。具体来说,我们分别在步态数据集上应用三种损失函数组合来训练模型和预测。整体来看,完整模型( $L_d + L_t + L_f$ )提供了最低的 MAE 和 MSE 值,说明其在信




图 12 损失函数的影响

## 8 系统可部署性讨论

为了评估 CSI-GAN 在实际应用中的可部署性,我们对模型的计算开销、部署需求以及在不同设备和环境下的扩展性进行了讨论。

计算开销与部署需求。需要注意的是,在运行流程中,噪声抑制与重采样方法属于输入规范化步

显著降低了信号恢复的误差。去噪对于准确恢复信号至关重要,而我们的去噪方案在所有度量指标上(包括 MSE、MAE、PSNR)均优于其他方法。通过在子载波维度应用 PCA 去噪以及聚类算法,我们的方案能够有效去除环境噪声和 AGC 的影响,同时最大程度地保留了原始信号的特征。这种平衡极大地提升了恢复性能,确保了在复杂环境下的信号保真度。

号恢复方面表现最佳。然而,当去除频域损失函数时( $L_d + L_t$ ),恢复信号在感知任务中的效果显著下降,表明频域损失对捕捉信号中的全局信息以及高频特征尤为关键。相比之下,去除时域损失函数后( $L_d + L_f$ )的恢复效果也有所下降,其感知任务的表现仍然较为理想。这表明,频域损失函数在特定传感任务中更为敏感,对信号的全局恢复起到了重要作用,尤其是在感知应用的精度上贡献较大。

骤,因此在训练与推理阶段均需执行,以保证后续模型输入的结构一致,这部分不涉及复杂的算法,因此计算开销基本可以忽略。同时,CSI-GAN 模型的训练仅需在离线阶段执行一次,推理阶段不再包含对抗训练,而是仅进行一次生成器的前向传播。CSI-GAN 的生成器包含约 3.2M 个参数,判别器包含约 1.1M 个参数,总体规模适中。在 NVIDIA RTX 3090 上对单个 2 s 的 CSI 片段进行一次前向恢复的

平均推理延时约为 7~10 ms;在消费级 GPU(如 RTX 2060)上推理延时约为 18~25 ms;在高性能 CPU(Intel i7)上推理延时约为 40~55 ms,能够满足大部分近实时感知任务的需求。训练阶段约需要 12~18 小时(视数据规模而定)。此外,由于模型仅基于时序卷积与反卷积结构,无需大规模 3D 卷积或 Transformer 块,因此在嵌入式或边缘设备上 also 具备一定部署潜力。

从整体来看,与插值的方法相比,GAN 的引入确实带来了额外的模型规模,但其计算量主要集中在离线训练阶段,对在线推理时延的影响十分有限。更重要的是,生成器前向传播的复杂度与普通卷积网络处于同一量级,因此不会对实时应用造成显著负担。在感知精度大幅提升的前提下,这一计算开销保持在可接受范围内,使得 CSI-GAN 能够在性能与准确性之间取得良好平衡。

跨设备和跨环境的应用。在跨设备与跨环境扩展性方面,CSI-GAN 的设计基于原始 CSI 的时间序列结构,因此对不同采样率、不同天线链路数量具有较好的兼容性。在处理采样率差异时,我们通过统一的重采样策略将输入规范化至目标频率  $f_t$ ,为跨设备场景提供数据一致性。此外,由于恢复模型主要学习时间序列的局部与全局变化模式,其在不同室内布局、反射路径变化较强的环境中亦保持较好的恢复效果。然而,我们也观察到当设备硬件差异较大(如 CSI 分辨率显著变化)时,模型性能会受到一定影响,未来可引入领域自适应或跨设备校准机制进一步提升泛化能力。

## 9 总结与展望

本文提出了 CSI-GAN,一种基于生成对抗网络的 WiFi 信号稀疏恢复模型,旨在解决当前 WiFi 感知系统中稀疏数据和非均匀采样的问题。CSI-GAN 通过直接在原始 CSI 波形上运行,并结合时域和频域损失函数,能够有效恢复高保真时间序列信号。通过创新的 PCA 去噪方法,该模型显著提升了信号恢复质量,尤其是在复杂环境下更能保持 WiFi 信号的细节和时序相关性。实验结果表明,CSI-GAN 在低采样率下依然能够实现高精度的信号恢复和感知任务准确性,超越了传统的插值方法和最新基于 GAN 的方案。这一模型在手势识别、活动识别和步态识别等应用中表现出色,并为进一步拓展到其他 WiFi 感知任务奠定了坚实基础。

展望未来,CSI-GAN 的潜力不仅限于 WiFi 手势识别、活动识别和步态识别等任务,还可以广泛应用于其他无线感知任务,如室内定位、环境监测和行为分析等。未来研究可集中于优化该模型的实时性与自适应性,以适应动态变化的环境,提升系统在实际部署中的应用效率。此外,进一步结合深度学习与无线信号处理技术,有望推动 WiFi 感知系统在稀疏数据处理中的发展,为物联网、智能家居等领域提供更加智能和精准的感知能力。同时,未来的工作还可以探索不同的信号恢复算法,以提升高频信号的重建能力,进一步提高系统的整体性能和应用广度。

## 参 考 文 献

- [1] Xie Y, Xiong J, Li M, et al. mD-Track: Leveraging multi-dimensionality for passive indoor Wi-Fi tracking//Proceedings of the 25th Annual International Conference on Mobile Computing and Networking. Los Cabos, Mexico, 2019:1-16
- [2] Qian K, Wu C, Zhang Y, et al. Widar2. 0: Passive human tracking with a single Wi-Fi link//Proceedings of the 16th Annual International Conference on Mobile Systems, Applications, and Services. Munich, Germany, 2018:350-361
- [3] Wang W, Liu A X, Shahzad M, et al. Understanding and modeling of wifi signal based human activity recognition//Proceedings of the 21st Annual International Conference on Mobile Computing and Networking. Paris, France, 2015:65-76
- [4] Jiang W, Miao C, Ma F, et al. Towards environment independent device free human activity recognition//Proceedings of the 24th Annual International Conference on Mobile Computing and Networking. New Delhi, India, 2018:289-304
- [5] Zhang L, Wang C, Zhang D. Wi-PIGR: Path independent gait recognition with commodity Wi-Fi. IEEE Transactions on Mobile Computing, 2021,21(9):3414-3427
- [6] Zhang J, Chen Z, Luo C, et al. MetaGanFi: Cross-domain unseen individual identification using WiFi signals. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2022,6(3):1-21
- [7] Zheng Y, Zhang Y, Qian K, et al. Zero-effort cross-domain gesture recognition with Wi-Fi//Proceedings of the 17th Annual International Conference on Mobile Systems, Applications, and Services. Seoul, Republic of Korea, 2019:313-325
- [8] Gao R, Li W, Xie Y, et al. Towards robust gesture recognition by characterizing the sensing quality of WiFi signals. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2022,6(1):1-26
- [9] Zeng Y, Wu D, Xiong J, et al. FarSense: Pushing the range limit of Wi-Fi-based respiration sensing with CSI ratio of two antennas. Proceedings of the ACM on Interactive, Mobile,

- Wearable and Ubiquitous Technologies, 2019,3(3):1-26
- [10] Zhang Y, Han F, Yang P, et al. Wi-cyclops: Room-scale wifi sensing system for respiration detection based on single-antenna. *ACM Transactions on Sensor Networks*, 2024,20(4):1-24
- [11] Yan D, Yang P, Shang F, et al. Wi-painter: Fine-grained material identification and image delineation using cots WiFi devices. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2024,7(4):1-25
- [12] Shang F, Yang P, Yan D, et al. LiquImager: fine-grained liquid identification and container imaging system with COTS WiFi devices. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2024,8(1):1-29
- [13] Yan D, Yan Y, Yang P, et al. Real-time identification of rogue WiFi connections in the wild. *IEEE Internet of Things Journal*, 2022,10(7):6042-6058
- [14] Halperin D, Hu W, Sheth A, et al. Tool release: Gathering 802.11 n traces with channel state information. *ACM SIGCOMM Computer Communication Review*, 2011,41(1):53-53
- [15] Xie Y, Li Z, Li M. Precise power delay profiling with commodity WiFi//*Proceedings of the 21st Annual international conference on Mobile Computing and Networking*. Paris, France, 2015:53-64
- [16] Gringoli F, Schulz M, Link J, et al. Free your CSI: A channel state information extraction platform for modern Wi-Fi chipsets//*Proceedings of the 13th International Workshop on Wireless Network Testbeds, Experimental Evaluation & Characterization*. Los Cabos, Mexico, 2019:21-28
- [17] Jiang Z, Luan T H, Ren X, et al. Eliminating the barriers: Demystifying Wi-Fi baseband design and introducing the Pi-coScenes Wi-Fi sensing platform. *IEEE Internet of Things Journal*, 2021,9(6):4476-4496
- [18] Palipana S, Rojas D, Agrawal P, et al. FallDeFi: Ubiquitous fall detection using commodity Wi-Fi devices. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2018,1(4):1-25
- [19] He Y, Liu J, Li M, et al. Sencom: Integrated sensing and communication with practical wifi//*Proceedings of the 29th Annual International Conference on Mobile Computing and Networking*. Madrid, Spain, 2023:1-16
- [20] Zeng Y, Lin Z, Lu H, et al. Cr-fill: Generative image inpainting with auxiliary contextual reconstruction//*Proceedings of the IEEE/CVF International Conference on Computer Vision*. Montreal, Canada, 2021:14164-14173
- [21] Jain J, Zhou Y, Yu N, et al. Keys to better image inpainting: Structure and texture go hand in hand//*Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. Waikoloa, USA, 2023:208-217
- [22] Xiao C, Han D, Ma Y, et al. CsiGAN: Robust channel state information-based activity recognition with GANs. *IEEE Internet of Things Journal*, 2019,6(6):10191-10204
- [23] Jiang D, Li M, Xu C. Wigan: A wifi based gesture recognition system with gans. *Sensors*, 2020,20(17):4757
- [24] Huang T, Wang S, Li S, et al. WiARGAN: A WiFi-based action recognition method with GANs//*2021 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/IOP/SCI)*. Virtual, 2021:59-66
- [25] Wei L, Feng J, Liu Y, et al. A dense margin network for human activity recognition based on augmented channel state information//*2021 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/IOP/SCI)*. Virtual, 2021:67-74
- [26] Vishwakarma S, Tang C, Li W, et al. Gan based noise generation to aid activity recognition when augmenting measured wifi radar data with simulations//*Proceedings of the 2021 IEEE International Conference on Communications Workshops (ICC Workshops)*. Virtual, 2021:1-6
- [27] Hu J, Zheng T, Chen Z, et al. MUSE-Fi: Contactless multi-person sensing exploiting near-field Wi-Fi channel variation//*Proceedings of the 29th Annual International Conference on Mobile Computing and Networking*. Madrid, Spain, 2023:1-15
- [28] Yang K, Zheng X, Xiong J, et al. Wiimg: Pushing the limit of wifi sensing with low transmission rates//*Proceedings of the 2022 19th Annual IEEE International Conference on Sensing, Communication, and Networking (SECON)*. Virtual, 2022:1-9
- [29] Chi G, Yang Z, Wu C, et al. RF-diffusion: Radio signal generation via time-frequency diffusion//*Proceedings of the 30th Annual International Conference on Mobile Computing and Networking*. Washington, USA, 2024:77-92
- [30] Xu M, Li Y, Han K, et al. A conditional diffusion model based wifi sensing enhancement method//*Proceedings of the 2024 IEEE 35th International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*. Valencia, Spain, 2024:1-6
- [31] Han F, Wan C, Yang P, et al. ACE: Accurate and automatic CSI error calibration for wireless localization system//*Proceedings of the 2020 6th International Conference on Big Data Computing and Communications (BIGCOM)*. Deqing, China, 2020:15-23
- [32] Ma Y, Zhou G, Wang S. WiFi sensing with channel state information: A survey. *ACM Computing Surveys (CSUR)*, 2019,52(3):1-36
- [33] Zhang F, Wu C, Wang B, et al. WiDetect: Robust motion detection with a statistical electromagnetic model. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2019,3(3):1-24

- [34] Li S, Liu Z, Zhang Y, et al. WiBorder: Precise Wi-Fi based boundary sensing via through-wall discrimination. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2020,4(3):1-30
- [35] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets. *Advances in Neural Information Processing Systems*, 2014,27:2672-2680
- [36] Liu B, Chen J. A super resolution algorithm based on attention mechanism and srgan network. *IEEE Access*, 2021,9: 139138-139145
- [37] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*, 2015
- [38] Yang J, Chen X, Zou H, et al. SenseFi: A library and benchmark on deep-learning-empowered WiFi human sensing. *Patterns*, 2023,4(3):1-22



**YAN Da-Wei**, Ph. D. His current research interests include wireless sensing, mobile computing, and multi-modal fusion.

**YAN Yu-Bo**, Ph. D., associate researcher. His research interests include Internet of Things, wireless networks,

and intelligent sensing.

**YANG Pan-Long**, Ph. D., professor. His research interests include Internet of Things, wireless networks, and intelligent sensing.

## Background

This paper focuses on the field of WiFi-based sensing, especially on the reconstruction of sparse and non-uniform channel state information (CSI) sequences in actual communication scenarios, to make WiFi sensing data sufficient and uniform.

With the rapid development of human activity recognition, gait identification, respiration monitoring, and other sensing applications based on commodity WiFi devices, CSI has emerged as a cost-effective and privacy-preserving alternative to camera-or wearable-based sensing systems. However, in real-world deployments, CSI can only be acquired during active data transmission, and the contention-based nature of WiFi results in irregular frame arrivals. Consequently, CSI measurements are often sparse and non-uniformly sampled, significantly degrading the temporal resolution and accuracy of downstream sensing tasks.

Several solutions have already been proposed to address missing CSI data, such as linear interpolation, spline interpolation, and model-based estimation methods. While these techniques can partially reconstruct missing samples, they often fail to capture complex temporal variations in dynamic environments, and may introduce artifacts when dealing with rapid signal changes. Internationally, research in WiFi sensing has primarily focused on improving feature extraction and recognition algorithms under the assumption of continuous CSI availability, while high-fidelity reconstruction of missing CSI data remains relatively underexplored.

This paper proposes CSI-GAN, a Generative Adversarial Network-based framework for reconstructing continuous CSI waveforms from sparse and non-uniform samples. Unlike traditional interpolation methods, CSI-GAN directly operates on raw CSI sequences and integrates a frequency-domain loss based on the Short-Time Fourier Transform (STFT) to preserve fine spectral details. In addition, a denoising mechanism is introduced to suppress noise-induced distortions during reconstruction. By jointly learning temporal and spectral characteristics, the proposed method significantly improves the quality of recovered CSI, enabling more accurate Doppler spectrum analysis and downstream sensing performance.

Experimental evaluations on both public datasets (Widar3.0) and our self-collected datasets (OurGait and OurActivity) demonstrate that CSI-GAN consistently outperforms conventional interpolation approaches and the latest GAN-based method across various packet rates and motion conditions. This advancement narrows the gap between ideal and practical CSI acquisition, and extends the applicability of WiFi sensing to low-traffic and highly dynamic scenarios.

This work was partially supported by the Hebei University High-level Talents Scientific Research Start-up Project (Grant No. 521100225229), the Anhui Provincial Science and Technology Innovation Tackling Program (Grant No. 202523009050019) and the Major Research Plan of the National Natural Science Foundation of China (Grant No. 92567301).