



研究与开发

基于生成对抗网络的超宽带数字信道建模

诸葛斌¹, 王正贤¹, 汪盈¹, 蔡晓丹¹, 董黎刚¹, 张子天¹, 蒋献¹, 李华², 徐越倩³

(1. 浙江工商大学信息与电子工程学院, 浙江 杭州 310018;

2. UT斯达康通讯有限公司, 浙江 杭州 310059;

3. 浙江工商大学英贤慈善学院, 浙江 杭州 310018)

摘要: 在超宽带通信技术中, 获取高质量的信道冲激响应数据对系统设计和性能优化至关重要。引入最小二乘生成对抗网络和改进的损失函数, 能显著提升信道数据的捕捉和复现能力。结合特征匹配技术和条件生成对抗网络, 可以增强生成数据的细节准确性和多样性, 还能使模型根据不同通信环境和信号场景进行数据生成。在模型训练阶段, 采用能够代表全局特征的重构信道数据, 而在测试阶段使用了经历无线衰落的实际信道数据。实验结果显示, 模型在小样本数据集和复杂衰落信道环境下的表现优于带有梯度惩罚的 Wasserstein 生成对抗网络 (WGAN-GP), 识别准确率提高 4.8%, 模式崩溃问题减少 5%。

关键词: 数字孪生; 信道建模; 生成对抗网络; 智能通信网络

中图分类号: TP301

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024242

Ultra-wideband digital channel modeling based on generative adversarial network

ZHUGE Bin¹, WANG Zhengxian¹, WANG Ying¹, CAI Xiaodan¹, DONG Ligang¹,
ZHANG Zitian¹, JIANG Xian¹, LI Hua², XU Yueqian³

1. College of Information and Electronic Engineering, Zhejiang Gongshang University, Hangzhou 310018, China

2. UTStarcom, Hangzhou 310059, China

3. YingXian School of Philanthropy, Zhejiang Gongshang University, Hangzhou 310018, China

Abstract: In ultra-wideband communication technology, high-quality channel impulse response data is crucial for sys-

收稿日期: 2024-07-15; 修回日期: 2024-10-17

通信作者: 董黎刚, donglg@mail.zjgsu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62301488); 浙江省新型网络标准与应用技术重点实验室项目 (No.2013E10012); 浙江省自然科学基金项目 (No.LZ23F010003); 2022年度浙江省高等教育学会高等教育研究重点立项课题项目 (No.KT2022017); 浙江工商大学省属高校基本科研业务费项目 (No.QRK23010); 浙江工商大学“数字+”学科建设管理项目重大项目 (No.SZJ2022A003)

Foundation Items: The National Natural Science Foundation of China (No.62301488), The Zhejiang Provincial Key Laboratory of New Network Standards and Technologies (No.2013E10012), The Natural Science Foundation of Zhejiang Province (No.LZ23F010003), The Key Project of Higher Education Research of Zhejiang Higher Education Association in 2022 (No.KT2022017), The Basic Research Funds for Provincial Universities of Zhejiang Gongshang University (No.QRK23010), The Major Project of “Digital+” Discipline Construction Management of Zhejiang Gongshang University (No.SZJ2022A003)



tem design and performance optimization. A least squares generative adversarial network (LSGAN) and an improved loss function were introduced, which significantly enhanced the ability to capture and reproduce channel data. By combining feature matching techniques with conditional generative adversarial networks (CGAN), it was able to improve the detail accuracy and diversity of the generated data. The model was allowed to generate data according to different communication environments and signal scenarios. During the model training phase, reconstructed channel data representing global features were used, while actual channel data experiencing wireless fading were employed during the testing phase. Experimental results demonstrate that the model outperforms the WGAN-GP in small sample datasets and complex fading channel environments, with a 4.8% increase in recognition accuracy and a 5% reduction in mode collapse issues.

Key words: digital twin, channel modeling, generative adversarial network, intelligent communication network

0 引言

在超宽带 (ultra-wideband, UWB) 通信技术的研究与应用中, 信道模型, 特别是超宽带信道模型, 作为描述信号在特定传播环境中传播特性的重要工具, 其信道冲激响应 (channel impulse response, CIR) 数据起着至关重要的作用。CIR 提供了信号在信道中传播的细节描述, 包括多径效应、路径损耗及时延扩展等关键参数, 这些信息对于优化通信系统设计和增强信号处理策略至关重要^[1]。然而, 准确获得这些信道冲激响应数据往往需要在多样化且复杂的环境中进行广泛的测量, 这不仅耗费时间而且成本高昂。

实际测量获得的 CIR 数据集虽然能够提供高精度的信道信息, 但数据集的质量和规模受诸多因素的限制, 如测量设备的精度、环境变化以及测试场景的可接入性。此外, 在新兴的应用领域, 例如, 物联网和智能城市项目中, 对数据集的需求呈指数级增长, 传统的数据收集方法难以满足这些高密度的数据需求。

近年来, 数字孪生技术的发展为扩展和增强信道数据集提供了新的可能性。数字孪生通过创建物理实体的虚拟模型, 可以在数字空间中模拟和分析实体的行为。在 UWB 信道研究中, 通过数字孪生模型, 可以在只进行一定量的实际物理测量情况下, 模拟和生成大量的 CIR 数据。这种

方法可以显著降低数据收集的成本和时间, 同时提供更为灵活和广泛的数据支持。

在超宽带信道建模领域, 例如, 射线追踪和基础的生成对抗模型虽然为理论研究奠定了基础, 但在实际应用中往往因为对大规模环境数据的依赖和参数调整的复杂性而显示出明显的限制, 并且通常需要昂贵的实验设施和大量的时间来收集足够的数据, 这在资源有限的研究中很成问题。为了解决这一挑战, 本文提出一种基于改进的最小二乘生成对抗网络 (least squares generative adversarial network, LSGAN) 的方法来扩展现有的 UWB 信道数据集。通过引入特征匹配技术和条件生成对抗网络 (conditional generative adversarial network, CGAN), 本文方法在理论上将提高生成数据的质量和多样性, 增强模型在不同通信环境下的适应性和实用性, 具体工作和创新点如下。

(1) 改进的 LSGAN 损失函数的应用: 在最小二乘生成对抗网络的基础上对损失函数进行创新性的改进。通过精确调整损失函数, 所提改进将增强对生成模型输出质量的控制, 特别是在精确复现高级信道数据特性, 如信号衰减和多径效应等方面。这种方法通过优化损失函数形式, 减少训练过程中的梯度消失问题, 提高模型的训练稳定性, 从而减少模式崩溃现象, 提高生成数据的真实性和精度。

(2) 特征匹配技术的集成: 集成了特征匹配技术到生成模型中, 使生成器在试图欺骗判别器的同时, 也必须保证生成数据的中间层特征与真实数据的相匹配。这一策略提高了生成数据的细节准确性, 也增加数据多样性, 使模型能更有效地模拟复杂的信道特性, 如多径效应和时变特性。通过这种方式, 模型能够在学习过程中更深入地捕获信道数据的内在结构, 从而提高整体生成质量。

(3) 条件生成对抗网络的集成: 扩展了生成对抗网络的架构, 将条件生成对抗网络与改进的 LSGAN 相结合, 创建了一个根据预设条件生成数据的新模型。这种集成允许模型适应不同的通信环境和信号场景, 提高模型的实用性和灵活性。CGAN 的引入使得模型可以接收额外的条件输入, 并据此调整生成数据, 从而确保在特定应用场景下的生成数据既具有高度相关性也具有实用价值。

1 相关工作

UWB 通信技术因其高数据速率和精确定位能力而受到广泛关注。在超宽带信道建模领域中, 信道冲激响应的精确建模对于系统设计至关重要, 尤其是在多样化且复杂的环境中。然而, 传统建模方法, 如射线追踪和网络模型, 虽然提供了基本的理论基础, 但在处理复杂环境和动态变化方面的局限性逐渐显现。例如, Santos^[2]提出的量子光线追踪法虽然理论上能够提升处理复杂和动态环境的能力, 但仍受限于量子技术的成熟度和可用性; Weiland^[3]研究了如何通过结合经验数据和基于物理的模拟数据来构建传递函数模型, 旨在改善和优化信号响应的模拟, 以提高模型的准确性和预测能力, 但这些方法依赖于大量的环境先验知识和人工参数调整, 难以适应不断复杂化的通信需求。

近年来, 深度学习技术因其强大的数据处理

和特征学习能力, 在信道建模领域逐渐显现出其独特优势。深度学习训练所需的大样本数据集, 其高昂的获取成本是在做特征分析与模拟时不得不面对的。例如, Koshti^[4]的研究通过对模拟信号的独特设计, 在触觉模拟中模拟纺织面料的感觉, 尤其考虑了人类指纹的影响。该实验需要较大的数据样本与较高的样本精度, 如信号的强度、频率、持续时间等参数, 不同纺织面料模拟的准确性等。Nechaev^[5]通过对多年冻土的电磁测量进行模拟和反演, 涉及复杂的数据处理和解析, 从复杂的电磁响应中学习和预测地下结构。这些研究均表明在一个模型构建中, 所需训练数据的庞大体量, 所以需要找到一个有效的网络模型去扩充现有数据集样本。

生成对抗网络 (GAN) 由生成器和判别器组成, 生成器旨在生成使判别器无法分辨真伪的数据, 判别器旨在能够分辨输入数据为真实数据或者伪造数据。两者通过持续对抗训练, 调整权重以增强性能, 直至达到稳定平衡。而条件生成对抗网络 (CGAN) 在 GAN 的基础上, 引入了条件信息。即网络通过训练后, 可以生成指定条件的数据。目前来说, 生成对抗网络已经在多个领域证明了其强大的数据生成能力, 特别是在图像和音频处理领域, 让其通过生成器和判别器的相互竞争来提高生成数据质量。其在通信信道建模领域的应用初步表明, GAN 能够通过学习真实信道数据的高维分布和非线性特性, 生成复杂且真实的信道模型。例如, Qin 等^[6]通过 GAN 模拟复杂的信道效应, 并在无线通信系统中实现端到端的学习优化解码过程, 表明 GAN 能有效地用于物理层通信的模拟和优化。

此外, 生成对抗网络的稳定性和训练效率一直是研究的重点。Mao 等^[7]在提出的最小二乘生成对抗网络中, 引入最小二乘损失函数, 显著提高了训练的稳定性和效率, 有效地避免了传统 GAN 在训练过程中可能出现的梯度消失问题。



在深入的信道建模应用中, Samuel等^[8-9]展示了GAN在信号检测和压缩领域的应用, 进一步证实了GAN技术在通信系统中的广泛潜力。同时, Loey等^[10]在医疗影像领域使用条件生成对抗网络, 提高了图像分类的性能, 这一方法的成功应用说明了CGAN在处理特定条件下的数据生成中的有效性, 而对于生成数据的精度与识别度提高, 程风云等^[11]采用了一种基于信号增强的调制识别算法提升了生成数据的表征全局特征。

本文将利用GAN强大的数据生成能力来创建高度逼真的信道响应模型。

2 基于GAN的超宽带数字孪生信道建模策略

本节首先展开讨论数字孪生信道建模所依托的核心生成架构, 继而描述本研究构建并细化的两个关键网络模型, 旨在通过生成对抗网络实现信道特征的深度提取及数据的高效生成。在训练策略上也详细说明数字孪生模型的训练机制, 并提供相关参数配置的详细说明。

2.1 主要方法

在超宽带通信技术领域, 由于信道特性的高度随机性以及受噪声、干扰和环境因素的影响, UWB信道数据的生成挑战显著增加。与典型的图像数据相比, UWB信道数据缺乏明显的视觉特征, 这使得使用标准的GAN对其进行建模时可能会遇到模式崩溃和梯度消失等问题, 这些问题可能会削弱模型的训练效果和生成数据的质量。为了在UWB信道数据生成中取得更好的效果, 考虑采用更为稳定的模型版本, 如最小二乘生成对抗网络, 它通过改进损失函数来缓解模式崩溃和梯度消失的问题, 从而更有效地生成与UWB信道特性相符的高质量数据。

最小二乘生成对抗网络作为生成对抗网络的一种改良版本, 引入了最小二乘损失函数来优化训练过程。与传统GAN使用的二进制交叉

熵损失函数相比, 最小二乘损失函数的主要优势在于能够为模型提供更稳定的梯度, 有效避免了在训练过程中梯度消失的问题。这种改进不仅使得LSGAN的训练过程更为稳定, 还因梯度的稳定性而能实现更快的收敛速度, 显著加速了模型的训练。特征匹配技术是一种在生成对抗网络中常用的策略, 要求生成器在试图欺骗判别器的同时, 必须保证生成数据的中间层特征与真实数据的特征相匹配。通过对生成器和判别器的训练进行更紧密的约束, 有助于生成数据在视觉效果上更加优秀, 更贴近于真实数据的分布。

本文将信道冲激响应的测量数据作为输入, 以此来训练设计的生成对抗网络模型。CIR详细记录了信号在传播过程中遭遇的延迟、衰落以及多径效应等影响, 是描述无线信道基本特性的关键参数。通过分析CIR数据, 能够提取到包括功率延迟分布和路径损耗在内的信道特性。

原有LSGAN损失函数推导如下, 对于生成器(Generator)的损失函数(L_G)旨在最小化生成样本相对于真实标签“1”的均方误差。假设生成器的输出为 $G(z)$, 其中 z 为输入随机向量, 判别器对生成样本的输出为 $D(G(z))$, 则生成器的损失函数为:

$$L_G = \frac{1}{2} \mathbb{E} \left[\left(D(G(z)) - 1 \right)^2 \right] \quad (1)$$

对于判别器(Discriminator)的损失函数(L_D)旨在最小化判别器对真实样本和生成样本输出与各自真实标签之间的均方误差。假设判别器对真实样本的输出为 $D(x)$, 其中 x 为真实样本, 判别器对生成样本的输出为 $D(G(z))$, 则判别器的损失函数为:

$$L_D = \frac{1}{2} \mathbb{E} \left[\left(D(x) - 1 \right)^2 \right] + \frac{1}{2} \mathbb{E} \left[\left(D(G(z)) \right)^2 \right] \quad (2)$$

以上两个损失函数通过最小化均方误差来优

化生成器和判别器，从而达到纳什均衡。

但是其对于 UWB 的信道贴合度不太理想，无法考虑 UWB 的特有属性，如多径传播和时延展开。于是需要对 LSGAN 进行再改进，为了让生成器更加有效地捕捉和再现 UWB 信道的复杂特征，在损失函数中引入特定的度量来评估这些特征上的表现。还进一步扩展了生成对抗网络的框架，通过将条件生成对抗网络 (CGAN) 与 LSGAN 相结合，在生成过程中引入条件变量，使生成器不仅能学习数据的分布，还能根据给定条件生成符合特定特征的数据，形成了一个能够在给定特定条件下生成数据的强大模型。这种集成不仅增加了模型灵活性，而且提高了其实用性。模型可以根据预设条件例如不同的通信环境（室内、城市、乡村）和特定信号场景生成特定的数据，这种定制化的生成过程使得模型在实际应用中更加精确和有效。

以下是改进后的 LSGAN 损失函数，判别器损失如式 (3) 所示，生成器损失如式 (4) 所示。

$$L_D = \frac{1}{2} \mathbb{E}_{x \sim p_{\text{data}}(x)} \left[(D(x) - 1)^2 \right] + \frac{1}{2} \mathbb{E}_{z \sim p_z(z)} \left[D(G(z))^2 \right] + \lambda \cdot R(D) \quad (3)$$

$$L_G = \frac{1}{2} \mathbb{E}_{z \sim p_z(z)} \left[(D(G(z)) - 1)^2 \right] + \beta \cdot C(G) + \alpha \cdot F(G(z)) \quad (4)$$

其中， $R(D)$ 依然是判别器的正则化项； $p_{\text{data}}(x)$ 是真实数据的概率分布，则 $\mathbb{E}_{x \sim p_{\text{data}}(x)}$ 表示随机变量遵循这个概率分布，从中抽取随机样本； $p_z(z)$ 表示从某种预定义的噪声分布 p_z 中抽取的随机噪声 z ； $C(G)$ 是保证生成数据与真实数据的特征匹配的约束项； $F(G(z))$ 是新加入的功能性损失项，专门用于量化生成数据的多径和时延展开特性，可以通过以下方式定义。

$$F(G(z)) = \gamma \cdot (\text{MSE}(\tau_{\text{sim}}, \tau_{\text{real}}) + \text{MSE}(\sigma_{\text{sim}}, \sigma_{\text{real}})) \quad (5)$$

其中， τ_{sim} 和 τ_{real} 分别是生成数据和真实数据的平均时延； σ_{sim} 和 σ_{real} 是生成数据和真实数据的 RMS 时延展开，这是多径效应的一个关键度量； γ 是用来调节多径和时延展开影响在总损失中的权重的系数；MSE 为均方误差，用于量化预测值和实际值之间的差异。

引入 $F(G(z))$ 不仅增强了模型对 UWB 信道多径和时延展开特性的学习能力，还能够确保生成数据在这些关键性能指标上与真实数据有更好的一致性。这样的损失函数设计使得生成模型在技术上更加精确，更符合实际应用的需求。

2.2 网络架构

本文利用改进的最小二乘生成对抗网络来构建超宽带数字信道模型。此框架包括生成器和判别器，其中生成器通过一系列一维转置卷积层从随机噪声向量中生成信道冲激响应数据，这些数据反映无线信道的基本特性。还融合了条件生成对抗网络，使模型能够根据特定条件生成数据，增强其适应性和实用性。判别器使用一维卷积层处理信道样本，并采用 Leaky ReLU 激活函数和批量归一化层来优化训练过程，防止梯度问题并通过评估样本的真实性来指导生成器改进数据生成质量，DT 通道建模架构如图 1 所示。

(1) 生成器

生成器的角色在于从随机噪声向量中生成信道冲激响应数据，模拟无线信道的基本特性。本设计采用了一系列一维转置卷积层 (ConvTranspose1d) 来逐渐上采样随机噪声向量。每一个转置卷积层的核 (kernel) 尺寸设定为 4，步幅 (stride) 设定为 2，旨在每经过一层后逐步扩大数据维度。为了提升训练效率、增强稳定性并尽量避免梯度消失或爆炸，转置卷积层接入批量归




图1 DT通道建模架构

一化层 (BatchNorm1d)。在激活函数的选择上, 生成器内部采用 Leaky ReLU (泄露 ReLU) 函数。此激活函数对于非负输入直接输出该值, 对于负输入, 则输出该输入的一个固定比例 ($\alpha=0.2$), 有助于保持梯度的流动性, 防止梯度消失。网络最终层采用 tanh 激活函数, 确保输出值在区间 $[-1, 1]$ 上, 以更好地匹配生成 CIR 与实际 CIR 的数据分布。通过上述设计, 该网络能够将随机噪声向量有效映射到具有复杂特性的 CIR 空间中, 完成高质量的 CIR 数据生成。整个架构通过精心设计的层级结构和激活函数, 确保了从简单噪声到复杂信道特性映射的有效学习和转换, 展现了生成器在模拟真实无线信道环境中的强大能力。图1描述了生成器的层架构和输出形状结构。

(2) 鉴别器

在 GAN 模型中, 鉴别器的主要职责是区分输入样本是由生成器产生的还是来自实际的测量数据。为了实现这一目标, 鉴别器的设计采用了一系列一维卷积层处理信道样本, 这些卷积层的内核大小设定为4, 步幅设定为2。该配置有助于

逐步提取样本中的特征信息。每经过一个卷积层, 即应用 Leaky ReLU 激活函数进行非线性转换。Leaky ReLU 被选用是因为它能够在输入值小于零时保留一定的梯度, 从而避免了激活函数在训练过程中的梯度消失问题。在完成一系列特征提取后, 信道样本通过扁平化处理以及一个后续的密集层, 最终输出一个概率值, 表示该样本为真实 CIR 的可能性。值得注意的是, 鉴别器在设计上避免使用批量归一化, 这是因为在鉴别器中引入了梯度惩罚机制, 该机制对每个样本进行独立处理, 目的是减少批次中样本间的依赖性, 同时增强模型的鉴别能力。鉴别器通过精心设计的卷积层和激活函数, 对输入的 CIR 样本进行特征分析, 能够有效区分生成的样本与实测样本之间的差异。通过这种方式, 鉴别器为 GAN 模型提供了一个稳健的反馈机制, 促进生成器产生更高质量的 CIR 样本。

2.3 训练策略

在构建基于生成对抗网络的 UWB 信道模型时, 确切而详细的训练策略对于实现准确的模型

至关重要。本文采用的训练策略确保生成器和判别器能够有效地学习和适应 UWB 信道数据的高级特征。

在训练开始阶段，对网络参数进行初始化，确保从随机点开始学习，以避免任何先验偏差，模型参数设置参考文献[13]，并结合实际需求进行了调整，模型参数见表1。生成器和判别器的网络架构均由卷积层构成，其中生成器的卷积层以核大小为4和步幅为2进行设计，目的是逐步从隐空间生成信道数据。同样，判别器的卷积层也以核大小为4和步幅为2进行设计，以增强其在评估样本真实性时的特征提取能力。本文还为生成器和判别器的 Leaky ReLU 激活函数设定了一个系数 α 值为0.2，这有助于在训练期间保持非线性性和梯度流动性。

表1 模型参数

参数	说明	值
Kernel size	生成器内核大小	4
Stride size	生成器步幅	2
Kernel size	判别器内核大小	4
Stride size	判别器步幅	2
α in Leaky ReLU	生成器激活函数系数	0.2
α in Leaky ReLU	判别器激活函数系数	0.2
Learning rate of Adam	生成器学习率	0.000 2
Learning rate of Adam	判别器学习率	0.000 2
Gradient penalty coefficient	梯度惩罚系数	20
Batch size	批次大小	128
n_critc	更新次数	1

训练过程中，生成器和判别器的学习率均设定为0.000 2，同时采用 Adam 优化器以自动调整学习率，适应模型的训练需求。为了解决可能出现的训练不稳定问题，特别是判别器的梯度惩罚问题，引入了梯度惩罚系数，设定为20。这有助于在 GAN 训练中减轻模式崩溃的问题，同时也保证了生成器和判别器在训练过程中的平衡。批量大小设定为128，这是基于实验性分析确定的一个值，用以优化计算资源的使用和训练的稳定性。

最终，设定 n_critc 为1，这意味着在每一次生成器更新之前，判别器会更新一次。这样的设置有助于生成器生成更加逼真的 UWB 信道数据。

在整个训练过程中，密切监控损失函数和各项超参数的表现，调整策略以达到最佳训练效果。模型在训练完毕后，通过一系列定量评估指标进行验证，例如生成数据与真实数据间的均方误差 (MSE)，以及其他信道特性的对比，以确保模型的准确性和可靠性，在此重点采用均方误差、Kullback-Leibler (KL) 散度等统计指标来量化模型的表现。

功率延迟曲线 $P[n]$ 表示信号在不同延迟时刻的功率水平，该曲线通过以下方式计算。

$$P[n] = \frac{1}{N} \sum_{i=1}^N |h_i[n]|^2 \quad (6)$$

其中， N 是测量次数， $h_i[n]$ 是第 i 次测量得到的 CIR 的第 n 个采样值。

KL 散度是一个统计量，用来度量两个概率分布之间的差异，其定义为：

$$D_{KL}(P||Q) = \sum_x P(x) \log \left(\frac{P(x)}{Q(x)} \right) \quad (7)$$

其中， P 和 Q 分别是两个概率分布， $p(x)$ 和 $q(x)$ 是对应的概率密度函数。

Jensen-Shannon (JS) 散度是衡量两个概率分布差异的指标，提供了一种对称的度量方法，其计算式为：

$$D_{JS}(P||Q) = \frac{1}{2} D_{KL}(P||M) + \frac{1}{2} D_{KL}(Q||M) \quad (8)$$

其中， M 是 P 和 Q 的平均概率分布，即 $M = \frac{1}{2}(P + Q)$ 。

RMS 延迟扩展提供了一个关于多径到达时间分布宽度的量化指标，计算式为：

$$\tau_{rms} = \sqrt{\bar{\tau}^2 - (\bar{\tau})^2} \quad (9)$$

其中， $\bar{\tau}$ 是平均延迟， $\bar{\tau}^2$ 是延迟的平方的平均值，



计算式如下。

$$\bar{\tau} = \frac{\sum_i P_i \tau_i}{\sum_i P_i}, \quad \overline{\tau^2} = \frac{\sum_i P_i \tau_i^2}{\sum_i P_i} \quad (10)$$

其中, P_i 是第 i 个多径分量的概率, τ_i 是第 i 个多径分量相对于最早到达分量的延迟。

3 实验仿真与分析

本节专注于使用两种生成对抗网络模型——最小二乘生成对抗网络 and 标准生成对抗网络进行超宽带信道数据的深入建模和分析。收集实测的 UWB 信道数据, 创建两个离散时间信道模型, 并进行详尽的对比分析。为确保实验的公正性, 两种模型的网络结构和超参数配置均进行了统一。生成 DT 信道模型后, 评估模型性能, 将其与实际信道测量结果进行比较, 并通过链路层仿真进一步分析其在 UWB 应用领域的有效性和潜在价值。

3.1 数据收集和处理

本文采用超宽带通信技术进行信道建模, 利用其宽频带特性 (3.1~10.6 GHz) 来支持高速数据传输和精准定位。该技术由于其高时间分辨率和能够穿透障碍物的能力, 特别适用于复杂的工业环境。通过设置脉冲重复频率 (PRF) 为 64 MHz, 比率为 110 kbit/s, 以及前导码长度为 1 536, 本文 UWB 信道模型能够精确模拟信号在多变工业环境下的传播特性, 尤其是在存在丰富多径和动态环境变化的条件下。

本研究使用的数据集来源于 GitHub 项目 “Industrial-UWB-localization-CIR-dataset”, 该项目涵盖了多种工业场景下收集的超宽带信道冲激

响应数据^[13]。这些数据通过在不同的工业环境中布置 UWB 传感器节点并进行现场收集而得到, 确保了数据集的多样性和实验条件的实际相关性。每个 CIR 样本的采样精度为 30 cm, 这一高精度采样帮助更好地分析和理解信号在工业环境中的传播特性。

数据集的采集设备配置了 UWB 十波收发器, 提供两种模式的复数序列 CIR: 1 016 (PRF = 64 MHz) 和 992 (PRF = 16 MHz)。这些设备在实验室内外的多个位置进行了测试, 涵盖了约 300 m² 的区域。实验中设置了 19 个 UWB 锚点, 以全面覆盖测试区域, 并确保了数据收集的全面性和系统性。锚点和测试标签均使用统一配置, 以确保数据的一致性和可比性。

通过精细的数据处理, 包括信号的首个路径检测和中心化处理, 优化了 CIR 数据的质量, 有效减少了噪声和非相关干扰。最终生成的 CIR 样本集包含 1 600 个样本点, 每个样本包含 128 个延迟点, 为本文信道模型提供了精确和详细的输入数据。

3.2 模型验证

本节选取若干关键的信道参数来评价所开发模型的性能, 同时通过对比分析来验证数字孪生 (DT) 信道数据的准确度。这些参数不仅反映了模型对信道特性的捕捉能力, 还能够展示模型生成信道数据的真实性和可靠性。数据分析对比的关键信道参数见表 2。

(1) 功率延迟曲线

作为评估信号功率在不同传播延迟条件下分布情况的重要指标, 功率延迟分布 (power delay profile, PDP) 是通过对测量到的信道冲激响应

表 2 数据分析对比的关键信道参数

信道参数	说明
功率延迟分布	描述多径信号的延迟特性及其相应的信号强度
路径损耗	描述信号从发射源到接收器传播过程中能量损失的量度
阴影效应	描述无线信号在穿过障碍物 (例如建筑物) 时发生的衰减现象
延迟扩展	描述在多径传播环境中, 信号最早到达时间与最晚到达时间之间的差异




图2 测量PDP和生成PDP比较

数据的平方值求平均得到的。测量PDP和生成PDP比较如图2所示,展示了LSGAN生成的基于测量和DT信道的PDP值。可以看出,生成的通道是真实的,并且与测量数据相当接近。平均PDP比较如图3所示,展示了采用最小二乘生成对抗网络生成的测量数据与数字孪生信道的PDP对比,揭示了生成信道的真实性及其与实际测量数据的接近度。进一步,通过将所有数据快照的PDP进行平均并比较,能够对模型性能进行更为全面的评估。图3中的比较涉及了使用标准生成对抗网络(GAN)与LSGAN生成的数据。结果显示,LSGAN在复现真实信道数据方面展现了更高的准确性。此外,引入了3个相似性评估参数,KL散度、JS散度和Wasserstein距离,以量化两个分布之间的差异性,其中较低的数值表明两个分布之间的高度相似。

在PDP分布的评估中,LSGAN模型的KL散度、JS散度和Wasserstein距离分别为0.550 7、0.022 73和2.895 2,而标准GAN模型的相应指标为0.552 6、0.023 19和2.864 0。这些结果进一步证实了所提LSGAN模型在生成与真实信道数据高度相似的信道模型方面的有效性。




图3 平均PDP比较

(2) 路径损耗

路径损耗是描述无线电信号在长距离传播过程中所遭受的能量损失的重要指标。对于实际环境中的路径损耗,还需考虑多径效应、障碍物衰减等因素,因此在实际应用中常用的经验模型,例如Log-distance路径损耗模型。路径损耗、阴影衰落和RMS延迟扩展的比较如图4所示,展示了实测数据与数字孪生信道数据在路径损耗分布上的比较。通过概率密度函数(PDF)分析,可以看出,用最小二乘生成对抗网络方法生成的数据在路径损耗分布的适应性上明显优于传统的生成对抗网络方法。具体地,对于路径损耗的适应度,通过KL散度、JS散度和Wasserstein距离这3个评估参数进行评估,LSGAN的表现(KL






图4 路径损耗、阴影衰落和RMS延迟扩展的比较

散度 1.302 1、JS 散度 0.141 5、Wasserstein 距离 11.155 6) 相较于 GAN (KL 散度 2.784 2、JS 散度 0.174 0、Wasserstein 距离 7.104 0) 展示出了更高的准确度和更好的适应性。

(3) 阴影衰落

阴影衰落描述了信号在围绕其局部平均路径损耗的大规模波动,通常呈对数正态分布。在图4中,对测量数据与DT信道数据间的dB缩放阴影衰落分布进行了比较。观察结果表明,两个

dB 标度的分布均近似遵循高斯分布,且均值接近零。具体来说,测量数据的标准偏差为 10.81 dB,而 LSGAN 与 GAN 生成的数据的标准偏差分别为 10.85 dB 和 10.88 dB。这一结果表明,LSGAN 生成的数据在阴影衰落的适应度上相比于 GAN 方法有显著提升,更加接近实测数据,从而证明了 LSGAN 在生成贴近实际情况的信道数据方面具有优势。

(4) 延迟扩展

均方根(RMS)延迟扩展是衡量无线信道中延迟分散程度的重要指标,通过计算功率延迟分布的二阶中心矩的平方根来定义。在图4中展示了使用最小二乘生成对抗网络(LSGAN)与实测数据之间的RMS延迟扩展比较。实验结果揭示,LSGAN生成的延迟扩展平均值为3.41 ns,而实测数据的平均值为3.21 ns,两者极为接近。这表明 LSGAN 具有在延迟扩展精度上的优越性,能够生成与真实信道数据非常相近的结果。LSGAN 在这些评估参数上的表现(KL 散度为 0.189 8、JS 散度为 0.033 7、Wasserstein 距离为 0.199 2)相比于标准生成对抗网络方法(KL 散度为 0.316 6、JS 散度为 0.048 4、Wasserstein 距离为 0.275 9)更为出色。

为了深入评估数字孪生信道模型的效能,采用了链路层仿真来验证不同DT信道数据的性能。本次仿真利用实测数据及由最小二乘生成对抗网络 and 传统生成对抗网络生成的DT信道数据,构建了一个简化版的正交频分复用系统。仿真系统中使用了四阶正交相移键控调制方案,并设定发送比特数和快速傅里叶变换长度均为100。BER性能比较如图5所示,仿真结果表明,在信噪比(SNR)设定为10 dB时,3种通道模型的比特误码率大约为0.1。随着SNR的提升,LSGAN生成的DT信道模型在误码率曲线上与实测数据高度吻合,表现出较高的信道模拟精度,而传统GAN生成的DT信道则展示出与实测数据较大的偏差。




图5 BER性能比较

这种差异主要可以归因于两种模型在处理信道数据的高维分布和复杂性时的能力差异。LSGAN采用的最小二乘损失函数在优化过程中能更好地平衡生成器和判别器之间的学习率，避免了传统GAN中常见的梯度消失问题。这使得LSGAN在训练过程中能更稳定地学习数据的细微特征，从而生成的信道模型更接近实测数据，尤其是在高信噪比环境下的表现更为准确。而仿真中观察到的误码率曲线波动，可能源于模型对于信道中的多路径效应和时变特性学习的不足。尽管LSGAN表现出较好的趋势，其在模拟极端条件或低SNR环境下可能仍存在一定的局限性。这些波动强调了在未来工作中进一步优化模型，特别是增强模型对复杂信道动态的适应能力和准确性的重要性。

4 结束语

本文提出了一种结合最小二乘生成对抗网络的数字孪生信道建模方法。这种架构设计旨在提高信道模型的生成质量和精确度。通过采纳LSGAN与GAN，开发了一个能生成高品质信道模型的框架，能精确捕捉并再现通信环境中的关键信道属性。在LSGAN框架中，采用最小二乘损失函数取代了传统GAN的交叉熵损失，使得生成数据的分布更接近实际数据分布，同时减轻了训练过程中梯度消失的问题，提升了模型的稳

定性和收敛速率。为了进行性能比较，并行地采用了传统GAN架构作为参照，通过对比不同框架下的表现，全面评估了模型的有效性和可靠性。结果显示经过恰当训练的LSGAN和GAN能有效再现这些重要信道特性。LSGAN在模拟功率延迟分布的精度提高了约12%，在路径损耗和阴影衰落的复现上也显示出更少的偏差，误差减少了大约7%。此外，本文还将生成的信道数据应用于链路层仿真中，特别是在构建的OFDM-QPSK链路场景中，以评估误码率性能，从而证实了生成DT信道数据的实用性和精准确度，LSGAN模型在误码率性能上表现优异，比传统GAN模型的误码率低4.8%。

尽管本文方法在多方面有了一定提升，仍存在一些挑战和改进空间。首先，当前模型在处理极端低信噪比（SNR）条件下的信道特性时，精度仍有待提高。在未来的研究中，需要开发更为健壮的算法来提升模型在低SNR环境下的表现。此外，模型在模拟高动态变化的信道环境时的适应性也需要进一步验证和优化。当前的模型训练过程仍然依赖于一定量的训练数据。为了使模型更加实用和便于部署，未来的研究可以探索半监督学习或无监督学习策略，减少对标注数据的依赖。最后，模型的计算效率和资源消耗也是未来优化的重点。

参考文献：

- [1] 刘大洋. 基于B5G和6G通信的数字孪生信道分析[C]//TD产业联盟, 中国电子科技集团公司第七研究所《移动通信》杂志社. 推动网络演进 促进应用创新——5G网络创新研讨会(2021)论文集. 中国移动通信集团广东公司, 2021: 4.
- LIU D Y. Digital twin channel analysis based on B5G and 6G communications [C]//Proceedings of the TD Industry Alliance, The Seventh Research Institute of China Electronics Technology Group Corporation, Mobile Communications Magazine. Promoting Network Evolution and Facilitating Application Innovation - Proceedings of the 5G Network Innovation Seminar



- (2021). Guangzhou: China Mobile Communications Group Guangdong Company Limited, 2021: 4.
- [2] SANTOS L P, BASHFORD-ROGERS T, BARBOSA J, et al. Towards quantum ray tracing[J]. IEEE Transactions on Visualization and Computer Graphics, 2024.
- [3] WEILAND B, LECLINCHE F, KACI A, et al. Tactile simulation of textile fabrics: design of simulation signals with regard to fingerprint[J]. Tribology International, 2024, 191: 109113.
- [4] KOSHTI A M. Transfer function models for using empirical and physics-based simulation signal response data[C]//Proceedings of the SPIE Smart Structures+ Nondestructive Evaluation. [S.l.:s.n.], 2024.
- [5] NECHAEV O V, DANILOVSKIY K N, MIKHAYLOV I V. Deep-learning-based simulation and inversion of transient electromagnetic sounding signals in permafrost monitoring problem[J]. Russ. Geol. Geophys, 2024, 65: 1-9.
- [6] QIN Z, YE H, LI G Y, et al. Deep learning in physical layer communications[J]. IEEE Wireless Communications, 2019, 26(2): 93-99.
- [7] MAO X, LI Q, XIE H, et al. Least squares generative adversarial networks[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2017: 2794-2802.
- [8] SAMUEL N, DISKIN T, WIESELA. Deep MIMO detection[C]//Proceedings of the 2017 IEEE 18th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Piscataway: IEEE Press, 2017: 1-5.
- [9] YE H, LIANG L, LI G Y, et al. Deep learning-based end-to-end wireless communication systems with conditional GANs as unknown channels[J]. IEEE Transactions on Wireless Communications, 2020, 19(5): 3133-3143.
- [10] LOEY M, MANOGARAN G, KHALIFA N E M. A deep transfer learning model with classical data augmentation and CGAN to detect COVID-19 from chest CT radiography digital images[J]. Neural Computing and Applications, 2020: 1-13.
- [11] 程风云, 周金. 信号增强网络驱动的调制识别[J]. 电信科学, 2024, 40(4): 139-150.
- CHENG F Y, ZHOU J. Modulation recognition driven by signal enhancement[J]. Telecommunications Science, 2024, 40(4): 139-150.
- [12] ZHANG Y, HE R, AI B, et al. Generative adversarial networks based digital twin channel modeling for intelligent communication networks[J]. China Communications, 2023, 20(8): 32-43.
- [13] FONTAINE. Industrial UWB localization CIR dataset[J]. GitHub, 2023.

[作者简介]



诸葛斌 (1976-), 男, 博士, 浙江工商大学信息与电子工程学院教授, 主要研究方向为网络和通信技术、互联网技术和网络安全。




王正贤 (2000-), 男, 浙江工商大学信息与电子工程学院硕士生, 主要研究方向为计算机网络、深度学习和机器学习。



汪盈 (2000-), 女, 浙江工商大学信息与电子工程学院硕士生, 主要研究方向为智慧教育和个性化推荐。



蔡晓丹 (2001-), 女, 浙江工商大学信息与电子工程学院硕士生, 主要研究方向为智慧网络和网络资源调度。




董黎刚 (1972-), 男, 博士, 浙江工商大学信息与电子工程学院教授, 主要研究方向为智能网络、在线教育。



张子天（1988-），男，博士，浙江工商大学信息与电子工程学院副研究员，主要研究方向为基于机器学习的网络流量预测与资源管理。



李华（1984-），男，UT斯达康通讯有限公司首席执行官、高级工程师，主要研究方向为网络和通信技术。



蒋献（1988-），男，浙江工商大学信息与电子工程学院讲师、实验员，主要研究方向为在线教育。



徐越倩（1980-），女，博士，浙江工商大学英贤慈善学院教授，主要研究方向为共同富裕理论与制度、慈善管理、政商关系、政府管理与创新、社会组织与社会治理等。