

隐空间采样与隐蔽特征提取的CR-GAN复杂无线信道建模

姜斌^{1,2}, 程子巍¹, 包建荣^{1*}, 吕鑫¹, 赵宜楠¹

(1. 杭州电子科技大学通信工程学院, 浙江杭州 310018; 2. 杭州电子科技大学电子信息学院, 浙江杭州 310018)

摘要: 为了更准确地建模随机无线信道, 提出一种自适应增强条件生成对抗网络信道建模方法. 其采用扩展的生成对抗网络(Generative Adversarial Network, GAN)开展训练, 以近似估计无线信道响应, 模拟真实无线环境信道. 为了改善GAN训练稳定性和学习能力, 引入条件信息和梯度惩罚项, 并提出一种增强条件生成对抗网络框架, 用于提取信道隐蔽特征. 此外, 还提出隐空间采样策略, 以增加随机变量与生成数据的互信息量, 提高所提框架的信道建模性能. 仿真表明: 所提框架能很好地模拟复杂无线信道分布. 在信噪比为10 dB时, 与现有GAN训练方法相比, 其归一化均方误差性能改善约24%.

关键词: 无线通信; 深度学习; 信道建模; 生成对抗网络

基金项目: 浙江省自然科学基金(No.LZ24F010005)

中图分类号: TN929.5

文献标识码: A

文章编号: 0372-2112(2024)06-1817-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20230406

CR-GAN Complex Wireless Channel Modeling with Hidden Space Sampling and Hidden Feature Extraction

JIANG Bin^{1,2}, CHENG Zi-wei¹, BAO Jian-rong^{1*}, LÜ Xin¹, ZHAO Yi-nan¹

(1. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China;

2. School of Electronic Information, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China)

Abstract: To accurately model random wireless channels, an adaptive channel modeling framework based on a strengthened conditional generative adversarial network (GAN) is proposed. It utilizes the extended GAN for training to approximately estimate the response of wireless channels and thus stimulate the actual wireless channels. To improve both the GAN training stability and learning capability, conditional information and gradient penalty terms are introduced. Besides, a strengthened conditional GAN frame, named condition reinforcement GAN (CR-GAN), is proposed to extract the essential hidden characteristics of wireless channels. In addition, a hidden space sampling strategy is utilized to increase the mutual information between the potential variables and generative data for the improved channel modeling performance of the proposed framework. Simulation results demonstrate that, at a signal-to-noise ratio of 10 dB, the proposed CR-GAN framework outperforms current GAN-based models by reducing 24% of the normalized mean squared error.

Key words: wireless communication; deep learning; channel modeling; generative adversarial networks

Foundation Item(s): Natural Science Foundation of Zhejiang Province (No.LZ24F010005)

1 引言

为提高信道建模精度并为网络算法设计和协议优化提供更准确的基础模型^[1], 需深入探讨各种时变信道模型间的差异以及用户移动性对信道特性的影响. 文献[2]通过仿真特定城市环境, 研究了路径损耗、莱斯K

因子等典型信道参数对车辆通信的影响, 但仍存在通用性受限的问题. 针对长序列建模中维度诅咒问题, 文献[3]将卷积神经网络(Convolutional Neural Network, CNN)与生成对抗网络(Generative Adversarial Network, GAN)相结合, 利用CNN和全连接层的局部连接特性模

拟传输长序列信号,但也面临训练困难和时间复杂度较高等挑战。

为了解决上述问题,可用GAN^[4]信道建模. 相较传统建模, GAN有以下优势^[5]: (1)可准确建模复杂的信道分布,提高信道建模精度; (2)可自适应学习建模不同信道模型,适应复杂多变无线信道; (3)不需手工提取特征,具有可扩展性和通用性。

在测量数据有限情况下,针对信道建模算法中存在参数分析困难和通用性不足等问题,研究了GAN在近似鲁棒概率分布方面应用,精确近似信道分布 $p(y|x)$. 将信道网络 $y=h(x)$ 视为随机函数近似,优化 $p(y|x)$ 的精度,显著改进无模型信道近似结果. 具体包括使用GAN增强传统信道建模并验证最优训练参数,生成近似信道响应模拟序列测试和优化,及提出CR-GAN框架来提高训练稳定性和学习能力,并探讨潜在变量分布对模拟性能的提升. 本文提出了数据驱动的信道建模,以获得更好通用性和精度,适用于端到端无线传输。

2 CR-GAN系统模型

2.1 CR-GAN设计原理

利用三个神经网络,包括一个编码器 $f(s, \theta_f)$ 、一个信道近似网络 $h(s, \theta_h)$ 和一个解码器 $g(y, \theta_g)$. 编码器网络 $f(s, \theta_f)$ 将符号 s 编码成发送符号值 x ,信道近似网络 $y=h(x)$ 模拟随机信道传输过程,而解码器网络 $g(y, \theta_g)$ 从接收样本 y 中恢复发送符号 s 的估计值^[6]. 这三种网络均采用带有权重参数 θ_f 和偏差参数 θ_g 的密集神经网络函数,以优化学习各种非线性映射和函数近似. 每个网络主要由全连接层与整流线性单元(Rectified Linear Unit, ReLU)层组成^[7]. 其中,单个全连接-ReLU层的传递函数如式(1)所示:

$$l_{i+1,j} = \max(0, \sum_k l_{i,k} w_{i,k} + b_{i,j}) \quad (1)$$

图层输出值 $l+1$,由输入值 l ,权重向量 w ,偏置向量 b 计算所得. 其中, i 表示层索引, k 表示输入索引, j 表示输出索引. 在编码器的输出阶段,使用无ReLU激活的等效全连接层,信道近似层定义为

$$l_{i+1,j} = \sum_k l_{i,k} w_{i,k} + b_{i,j} \quad (2)$$

利用均方误差损失(Mean Squared Error, MSE)执行发送和接收样本值回归,同时随机梯度更新网络参数,有

$$\nabla_{\theta_h} L_{\text{MSE}} = \nabla(y - h(x, \theta_h))^2 \quad (3)$$

在传统GAN结构中,生成器和判别器通常采用全连接网络,分别具有参数集 θ_D 和 θ_G . 生成器网络 $G(z, \theta_G)$ 将服从分布 p_z 的潜在变量 z 转换为符合分布 p_g 的模拟样本. 因此, $G(z, \theta_G)$ 可视为从隐空间到数据空

间的映射,即 $x=G(z, \theta_G)$. 判别器网络 $D(x, \theta_D)$ 判断实例 x 是否符合 p_{data} 分布或 p_g 分布. 若样本 x 接近真实数据分布 p_{data} ,判别器网络 $D(x, \theta_D)$ 输出概率值趋近1;反之, $D(x, \theta_D)$ 输出概率值趋近0. $D(x, \theta_D)$ 的训练目标是最大化正确判别概率,而 $G(z, \theta_G)$ 的目标是最大化判别器 $D(x, \theta_D)$ 的误判概率. 因此,GAN训练涉及求解式(4):

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - G(z))] \quad (4)$$

其中, $V(D, G)$ 表示GAN的成本函数. 通过误差反向传播和梯度学习,固定该网络参数,更新另一个网络参数。

通过迭代优化GAN网络参数,使生成器和判别器网络最终达到一个平衡点,两者都无法优化. 这表明生成器产生模拟样本分布 p_g 收敛于实际数据分布 p_{data} ,使判别器无法区分符合 p_g 分布和 p_{data} 分布的模拟与实际样本。

2.2 利用梯度惩罚项的目标函数改进

传统GAN的损失函数所提供的梯度对生成器的更新并无实质性帮助^[8,9],导致传统GAN训练不稳定. 为解决GAN模型的收敛困难和不稳定问题,提高生成样本质量,本文结合CGANs^[10]与WGAN^[11]的优势,提出一种改进的CR-GAN框架. 与普通GAN采用Jensen-Shannon散度不同,本文在Lipschitz约束下采用Wasserstein距离来推导替代损失函数. 文献[12]中,在判别器目标函数加入了1-Lipschitz约束,但并未直接解决网络训练问题,而是将判别器参数更新后的值限制在 $(-c, c)$ 范围内,实现判别器目标函数的平滑. 当判别器服从1-Lipschitz约束时,等价于判别器 D 在任意处的梯度均小于1,具体表达如下:

$$D \in 1\text{-Lipschitz} \Leftrightarrow \|\nabla_x D(x)\| \leq 1 \quad (5)$$

鉴于二者等价性,在直接使判别器 D 满足1-Lipschitz约束较困难时,通过该修改判别器的目标函数,有

$$V(G, D) \approx \max_D \{E_{x \sim p_{\text{data}}} [D(x)] - E_{x \sim p_g} [D(x)] - \lambda \int_x \max(0, \|\nabla_x D(x)\| - 1) dx\} \quad (6)$$

其中, $\lambda \int_x \max(0, \|\nabla_x D(x)\| - 1) dx$ 的作用类似正则项,对梯度更新大于1的行为进行惩罚. 然而,要获得所有 x 是不可行的,因为无法遍历整个数据空间。

如图1所示,为解决CR-GAN的近似信道响应生成框架问题,定义惩罚样本抽取数据的空间分布 P_{sample} ,确保从 P_{sample} 中抽取样本数据 x 对应的 $\nabla_x D(x)$ 小于1. 在执行式(6)时,样本 $\hat{x}_{P_{\text{sample}}}$ 通过两部分相加得到:一部分为随机数 $t \in U(0, 1)$ 与实际样本 $x \in p_{\text{data}}(x)$ 的乘积,另一部分为 $(1-t)$ 与模拟样本 $x \in p_g(x)$ 的乘积:

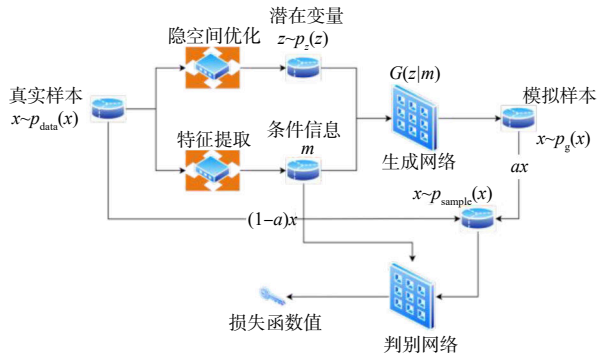


图1 CR-GAN 近似信道响应生成框架

$$\hat{x}_{p_{\text{sample}}} = tx_{p_g} + (1-t)x_{p_{\text{data}}} \quad (7)$$

CR-GAN 的生成器度量同样采用 Wasserstein 距离, 其训练目标如下:

$$V(G, D) \approx \min_G E_{x \sim p_{\text{data}}} [D(x)] - E_{x \sim p_g} [D(x)] \quad (8)$$

使生成器分布 p_g 与真实分布 p_{data} 间的 Wasserstein 距离最小化. 由于 $E_{x \sim p_{\text{data}}} [D(x)]$ 与生成器无关, 故生成器训练目标为

$$V(G, D) \approx \min_G - E_{x \sim p_g} [D(x)] = \min_G - E_{z \sim p_z} [D(G(z))] \quad (9)$$

为使 GAN 的体系结构受益于 $p(y|x)$, 将条件信息 m 作为判别器和生成器的附加输入, 提高 CR-GAN 在此条件下的学习能力. 判别器网络 D 等效于以下优化问题:

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [D(x|m)] + E_{z \sim p_z(z)} [-D(G(z|m))] - \lambda GP(D) \quad (10)$$

其中, λ 为惩罚系数, 梯度惩罚项^[13]为

$$GP(D) = E_{\hat{x} \sim p_{\text{sample}}(\hat{x})} [(\|\nabla_{\hat{x}} D(\hat{x}|m)\|_2 - 1)^2] \quad (11)$$

在训练阶段, 寻求测量和变分信道近似网络分别产生的条件概率分布 $p(y|x)$ 和 $p(\hat{y}|x)$ 之间距离的最小化. 利用式(12)、式(13)给出的随机梯度, 最小化网络参数:

$$\nabla_{\theta_D} \frac{1}{N} \sum_{i=0}^N [(D(x_i, y_i, \theta_D)) - D(x_i, h(x_i, \theta_h), \theta_D)] - \lambda GP(D) \quad (12)$$

$$\nabla_{\theta_h} \frac{1}{N} \sum_{i=0}^N D(x_i, h(x_i, \theta_h), \theta_D) \quad (13)$$

其中, 引入新的判别网络 $D(x_i, y_i, \theta_D)$, 负责在给定的输入 x 的信道中对真实样本 y 和合成样本 \hat{y} 进行分类. 在此情况下, $h(x, \theta_h)$ 替代生成器网络. 其中, x 表示条件传输符号/样本, 函数中的附加随机性由变分层引入^[14].

3 CR-GAN 自适应信道建模算法

为使生成器网络产生的模拟样本分布 p_g 更近似 $p(y|x)$ 分布, 利用所提 CR-GAN 架构进行训练. 给定信道样本序列 \mathbf{X} , 训练完成后, 生成器网络将产生可视为

模拟接收序列样本的序列.

3.1 隐空间采样优化策略

在 GAN 的训练中, 通常采用最小化生成样本与真实样本间距离的方法来优化隐空间策略. 为拟合信道样本的统计特性, 设计以下采样优化策略步骤:

Step1 采用样本序列 \mathbf{X} 对 CR-GAN 进行训练, 序列 \mathbf{X} 以 $l \times N$ 维矩阵存在, 即 $\mathbf{X} \in \mathbb{C}^{l \times N}$ 为

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n, \dots, \mathbf{x}_N] \quad (14)$$

其中, N 为正整数, 表示序列长度; l 为正整数, 表示为每个符号 \mathbf{x} 的维度; 每个符号 \mathbf{x} 以 $l \times 1$ 维的矩阵形式存在, 即 $\mathbf{x} \in \mathbb{C}^{l \times 1}$ 为

$$\mathbf{x} = [x_1, x_2, \dots, x_{l-1}, x_l]^T \quad (15)$$

对于服从 p_z 分布的潜在变量 \mathbf{Z} , 设其为随机序列, 该分布的随机值可通过均匀随机数和特征函数^[15]生成. 分布 p_z 可从接收序列统计信息中受益, 这些信息称为先验信息. 因此, 通过计算序列 \mathbf{X} 的统计信息以构建先验信息, 优化潜在变量分布.

计算每个符号 \mathbf{x} 的样本均值, 令第 n 个 (n 为正整数且 $1 \leq n \leq N$) 符号 \mathbf{x}_n 的均值 μ_{x_n} 为

$$\mu_{x_n} = \frac{1}{l} \sum_{i=1}^l x_i \quad (16)$$

计算样本方差, 令第 n 个符号 \mathbf{x}_n 的方差 $\sigma_{x_n}^2$ 为

$$\sigma_{x_n}^2 = \frac{1}{l} \sum_{i=0}^l |x_i - \mu_{x_n}|^2 \quad (17)$$

将 \mathbf{X} 的样本方差集合作为输入参数, 组成先验信息序列 \mathbf{I} , 以 $1 \times N$ 维的矩阵形式存在, 即 $\mathbf{I} \in \mathbb{C}^{1 \times N}$ 为

$$\mathbf{I} = [i_1, i_2, \dots, i_N] = [\sigma_{x_1}^2, \sigma_{x_2}^2, \dots, \sigma_{x_N}^2] \quad (18)$$

Step2 对于每一批次输入的原潜在变量序列 \mathbf{Z}_p , 服从 $\mathbf{Z}_p \sim N(0, 1)$. 为使其更接近信道数据分布 p_{data} , 将序列 $\mathbf{Z} \in \mathbb{C}^{2l \times N}$ 的期望 μ_z 修改为 μ_{x_n} , 同时将序列 $\mathbf{Z} \in \mathbb{C}^{2l \times N}$ 的方差 σ_z^2 调整为序列 \mathbf{I} 的均值 μ_i :

$$\sigma_z^2 = \frac{1}{N} \sum_{j=0}^N i_j = \frac{1}{N} \sum_{j=0}^N \sigma_{x_j}^2 \quad (19)$$

输出优化后的 $2l \times N$ 维潜在变量序列 \mathbf{Z} , 服从位置参数 $\mu_z = \mu_{x_n}$ 、尺度参数 $\sigma_z^2 = \sigma_{x_n}^2$ 的正态分布.

3.2 所提 CR-GAN 框架训练流程

利用信道样本序列 \mathbf{X} , 当其由复数构成时, 由于神经网络无法直接处理复数, 不满足输入要求^[16].

故定义重构函数 $f_R(\mathbf{x})$, 给定第 n 个复数序列 $\mathbf{x}_n = [a_1 + b_1j, \dots, a_l + b_lj]^T$, 其中 a, b 皆为实数, 重构函数 $f_R(\mathbf{x})$ 为

$$f_R(\mathbf{x}) = [a_1, b_1, a_2, b_2, \dots, a_{l-1}, b_{l-1}, a_l, b_l]^T \quad (20)$$

将 \mathbf{X} 作为输入参数, 采用式(20)所定义的重构函数 $f_R(\mathbf{x})$ 执行计算, 得到 $2l \times N$ 维重构样本序列 \mathbf{X}_R . 定义

$f_R(\mathbf{x})$ 的反函数 $f_R^{-1}(\mathbf{x})$,其中 $f_R^{-1}(f_R(\mathbf{x}))=\mathbf{x}$.通过对生成器网络的输出执行 $f_R^{-1}(\mathbf{x})$ 函数,得到模拟接收序列 $\hat{\mathbf{X}}$.将所得潜在变量序列 \mathbf{Z} 、重构样本序列 \mathbf{X}_R 、惩罚样本序列 \mathbf{X}_p ,通过式(18)及(19)计算对应方差 $\sigma_{X_R}^2$ 、 σ_Z^2 、 $\sigma_{X_p}^2$,所得方差分别作为三个条件信息 m_{X_R} 、 m_Z 、 m_{X_p} ,构建条件输入序列为

$$\mathbf{m}=[m_{X_R}, m_Z, m_{X_p}]=[\sigma_{X_R}^2, \sigma_Z^2, \sigma_{X_p}^2] \quad (21)$$

将潜在变量序列 \mathbf{Z} 、重构样本序列 \mathbf{X}_R 、惩罚样本序列 \mathbf{X}_p 与其对应条件信息结合,构成 (\mathbf{Z}, \mathbf{m}) 、 $(\mathbf{X}_R, \mathbf{m})$ 、 $(\mathbf{X}_p, \mathbf{m})$.式(10)所示的生成器训练目标函数优化为

$$\min_G V(D, G) = E_{\mathbf{X}_R \sim p_{\text{data}}(\mathbf{x})} [D(\mathbf{x}_R | \mathbf{m})] + E_{\mathbf{Z} \sim p_z(\mathbf{z})} [-D(G(\mathbf{z} | \mathbf{m}))] \quad (22)$$

式(10)所示的判别器训练目标函数优化为

$$\max_D V(D, G) = E_{\mathbf{X}_R \sim p_{\text{data}}(\mathbf{x})} [D(\mathbf{x}_R | \mathbf{m})] + E_{\mathbf{Z} \sim p_z(\mathbf{z})} [-D(G(\mathbf{z} | \mathbf{m})) - \lambda GP(D)] \quad (23)$$

如图2,生成器和判别器依次采用Adam梯度下降迭代更新来执行训练,达到预设迭代次数,可得近似信道响应效果良好的生成器模型 G .CR-GAN框架训练见算法1.




图2 CR-GAN的网络训练过程

4 仿真实验及数值分析

4.1 典型一维信道情形分析

在本文中,考虑在加性高斯白噪声(Additive White Gaussian Noise, AWGN)环境下的二进制相移键控(Bi-

算法1 CR-GAN框架训练

输入:信道样本序列 \mathbf{X} ;


输出:近似信道响应效果良好的生成器模型 G 与参数集 θ_G .

- 1:网络模型初始化,基于生成对抗网络构建方法得到生成器、判别器网络与训练参数集合,包括迭代次数 K ;
- 2:FOR 训练的迭代次数 K DO
- 3: FOR 重复 K 次 DO
- 4: 从信道样本序列 \mathbf{X} 即真实数据分布 p_{data} 中取出 m 个小批次样本 $[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m]$;
- 5: 基于 $[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m]$,利用式(18)与(19),得到潜在变量序列 \mathbf{Z} ;
- 6: 基于 $[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m]$,利用式(20),得到重构样本序列 \mathbf{X}_R ;
- 7: 利用式(23),使用随机梯度下降更新判别器参数;
- 8: END FOR
- 9: 从生成器前置随机分布取出 m 个小批次样本;
- 10: 利用式(22),采用随机梯度下降来更新生成器参数;
- 11:END FOR


nary Phase Shift Keying, BPSK)编码情况.在AWGN信道中,信道输出 \mathbf{y} 由输入信号 \mathbf{x} 和噪声 \mathbf{w} 的和组成(即 $\mathbf{y}=\mathbf{x}+\mathbf{w}$).其中 \mathbf{x} 表示传输数据, $\mathbf{w} \sim N(2, \sigma^2)$ 表示AWGN噪声.

完整的训练参数设置如下:优化器:Adam;学习率:0.003;Batch_size:24;Epoch:500;损失函数:MSE损失函数;SNR:15 dB;训练集大小:20 000;测试集大小:4 000;验证集大小:1 000.在给定条件下,对所提CR-GAN框架进行仿真训练.

图3(a)、(b)分别展示了在GAN与CR-GAN框架下训练的损失函数的变化趋势.由图3可知,GAN和CR-GAN模型在BPSK调制下都能有效处理AWGN信道的损失函数.其中,GAN模型经过247次迭代获得纳什均衡,即训练达到平衡状态,而CR-GAN模型仅需96次迭代便能实现相同目标.引入式(12),CR-GAN的收敛速度明显优于GAN,且具有更强的实时性.



(a) 基于GAN的损失函数



(b) 基于CR-GAN的损失函数

图3 AWGN信道下GAN与CR-GAN的损失函数对比

在CR-GAN训练过程中,生成器产生了与实际数据非常接近的分布.为验证其性能,图4展示了目标信道、GAN生成信道与CR-GAN生成信道的概率密度函数(Probability Density Function, PDF)间的对比.

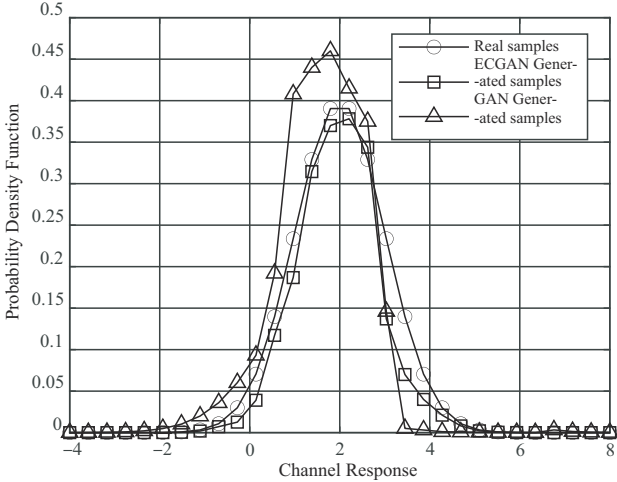


图4 AWGN信道下真实样本和生成信道数据的概率密度函数对比

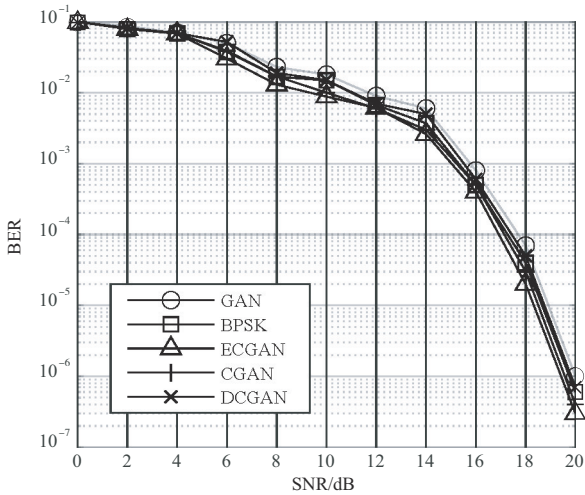
在图4中,PDF用于描述连续随机变量的概率分布,表示某个取值范围内随机变量出现的相对可能性.由图可知,相较于真实分布,传统GAN生成的分布方差较大,且均值存在较大误差.而CR-GAN成功逼近真实信道PDF,收敛至更紧凑的分布,并集中于真实分布的平均值附近.这一现象的原因在于,式(9)优化下的生成器产生的内容具有随机性,而判别器根据式(10)来

判断生成数据的真实性.此外,生成器容易陷于特定参数设置,导致点分布分散,从而引发GAN失效.将条件信息序列加入式(22)后,生成器在式(21)约束下生成样本,以最小化 $G^* = \arg \min_G V(G, D_G^*)$,使CR-GAN训练更稳定,提高系统的可控性.


4.2 增加维度和影响的案例分析

为验证CR-GAN框架在处理更高维信道响应性能方面的扩展性,采用四相移键控(Quadrature Phase Shift Keying, QPSK),并通过星座图对比观察生成样本的质量.环境参数设置如下:水深100 m;传输距离300 m;载波频率5 kHz;带宽10 kHz;频率分辨率0.04 kHz;发射机放置深度20 m;接收机放置深度20 m;信道阶数148.

在瑞利和水声信道中,采用BPSK调制的传统GAN和CR-GAN误比特率(Bit Error Rate, BER)如图5所示.在各个SNR下,CR-GAN的BER性能均具有一定优势,而传统GAN在BER性能上难以优于BPSK调制.这一现象的原因在于,传统GAN和DCGAN的优化目标主要由式(4)决定.然而,当真实数据概率分布 p_{data} 与生成数据概率分布 p_g 没有重叠时,使用式(4)可能导致分布距离存在 $2\log 2$ 的误差^[17].因此,CR-GAN采用 $\|X_g - X_{data}\|$ 作为分布距离,并使用式(9)进行优化训练.在瑞利信道和水声信道环境下,发送节点到接收节点链路的SNR越大,真实数据概率分布 p_{data} 与生成数据概率分布 p_g 的重叠越少,CR-GAN系统所获得的增益越高.



(a) 瑞利信道下的误码性能



(b) 水声信道下的误码性能

图5 CR-GAN与其他方法在不同信道下的误码性能对比

4.3 NMSE对比

归一化均方误差(Normalized Mean Squared Error, NMSE)方案可用于衡量生成与真实数据之间的偏差,

评估数据变化程度.其表达式如下:

$$NMSE(y, \hat{y}) = \frac{E[\sum_{i=1}^N |y_i - \hat{y}_i|^2]}{E[\sum_{i=1}^N |\hat{y}_i|^2]} \quad (24)$$

根据表1, NMSE直观地反映了真实数据与生成数据之间的差距, 并比较了不同方法在随机信道响应建模效果上的表现。

表1 CR-GAN与其它方法在不同信道下的NMSE性能对比
单位: dB

算法	BPSK+高斯	QPSK+高斯	16QAM+瑞利
GAN	13.57	5.16	-0.83
CGAN	16.08	7.45	-1.52
DCGAN+CNN	16.19	9.98	3.65
CR-GAN	23.46	15.27	4.53

由表1可得, 在BPSK-AWGN下, GAN与CR-GAN的NMSE值分别为-13.57 dB与-23.46 dB. 这表明GAN与CR-GAN都能较好地学习适当的统计信息, 并与测量分布实现匹配. 与传统GAN相比, 式(19)所提框架使潜在在变量优化方法的期望更接近真实数据分布, 提高了数据拟合程度. 在16正交幅度调制(16 Quadrature Amplitude Modulation, 16QAM)瑞利衰落的场景中, 与DCGAN+CNN相比,


CR-GAN的NMSE性能提高约24%. 因此, 上述NMSE性能对比表明, 基于CR-GAN的建模优于基于GAN的方法。

4.4 系统参数的影响

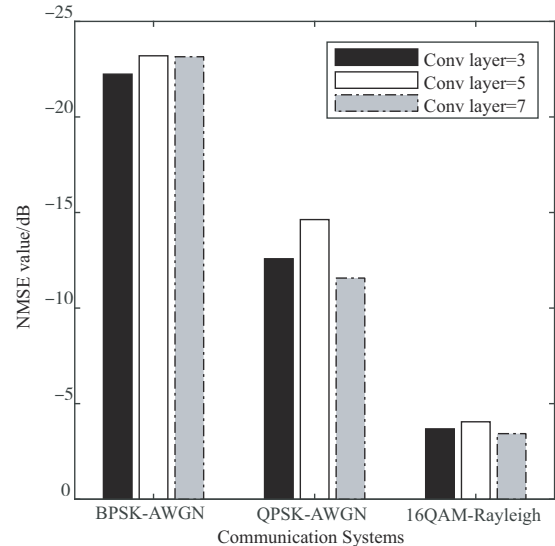
为最大化所提框架的近似信道响应能力, 研究改变学习率、卷积层数、批量大小等系统参数对其性能影响, 如图6所示。

(1)调整学习率: 为评估所提框架在不同学习率下的性能, 固定批量大小和迭代次数, 在各种通信场景中进行测试. 过大的学习率可能导致模型收敛过程波动, 而过小学习率使训练速度减缓. 因此, 针对特定场景下选择合适的学习率至关重要. 如图6(a)所示, 当学习率为0.003时, 框架产生最优NMSE值。

(2)调整卷积层总数: 此参数表示生成器设计涉及的卷积层总数. 过多卷积层可能导致过拟合和计算负担增加. 如图6(b)所示, 卷积层数量超过5层会提高模型复杂度, 但效果未明显改善. 实验表明, 5层卷积结构在性能和计算复杂度间实现平衡。



(a) 调整学习率NMSE对比



(b) 调整卷积层的总数NMSE对比

图6 CR-GAN框架在不同系统参数下的NMSE性能对比

5 结束语

本文研究了采用增强条件生成对抗网络的自适应信道建模方法. 利用训练和接收序列作为条件信息, Wasserstein距离作为分布间度量, 有效提高了GANs训练稳定性和学习能力. 另外, 利用先验信息, 探讨训练过程中潜在变量的分布, 显著增强所提出的增强条件生成对抗网络框架的模拟性能. 仿真表明: 相对卷积GAN模型, 所提CR-GAN模型在模拟复杂无线信道分布方面表现更为优异. 在AWGN信道和瑞利信道10 dB

下的NMSE性能, 分别提高45%和53%. 该方案通过减少假设并更准确地建模信道响应, 适用于高性能、低时延端到端无线信道场景。

参考文献

- [1] 赵雄文, 张钰, 秦鹏, 等. 空天地一体化无线光通信网络关键技术及其发展趋势[J]. 电子学报, 2022, 50(1): 1-17.
ZHAO X, ZHANG Y, QIN P, et al. Key technologies and development trends for a space-air-ground integrated wire-


- less optical communication network[J]. *Acta Electronica Sinica*, 2022, 50(1): 1-17. (in Chinese)
- [2] 张文茹, 汪莞乔, 官科, 等. 城市交通环境下 23GHz 信道仿真建模[J]. *电子学报*, 2021, 49(10): 2069-2080.
ZHANG W, WANG W, GUAN K, et al. Channel simulation modeling at 23GHz in urban scenarios[J]. *Acta Electronica Sinica*, 2021, 49(10): 2069-2080. (in Chinese)
- [3] 程芳芳, 王旭东, 吴楠. 基于最小二乘支持向量机的时变信道建模 DCGAN 信道下的端到端通信系统设计[J]. *电讯技术*, 2022, 62(6): 742-748.
CHENG F, WANG X, WU N. Design of an end-to-end communication system in DCGAN channel[J]. *Telecommunication Engineering*, 2022, 62(6): 742-748. (in Chinese)
- [4] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [5] O'SHEA T J, ROY T, WEST N. Approximating the void: Learning stochastic channel models from observation with variational generative adversarial networks[C]//2019 International Conference on Computing, Networking and Communications (ICNC). Piscataway: IEEE, 2019: 681-686.
- [6] O'SHEA T, HOYDIS J. An introduction to deep learning for the physical layer[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2017, 3(4): 563-575.
- [7] NAIR V, HINTON G E. Rectified linear units improve restricted boltzmann machines[C]//Proceedings of the 27th International Conference on Machine Learning. New York: ACM, 2010: 807-814.
- [8] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: An overview[J]. *IEEE Signal Processing Magazine*, 2018, 35(1): 53-65.
- [9] ARJOVSKY M, BOTTOU L. Towards principled methods for training generative adversarial networks[EB/OL]. [2023]. <http://arxiv.org/abs/1701.04862.pdf>.
- [10] MIRZAM, OSINDEROS. Conditional generative adversarial networks[EB/OL]. [2023]. <http://arxiv.org/abs/1411.1784.pdf>.
- [11] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks[C]//International Conference on Machine Learning. New York: ACM, 2017: 214-223.
- [12] FOURNIER N, GUILLIN A. On the rate of convergence in Wasserstein distance of the empirical measure[J]. *Probability Theory and Related Fields*, 2015, 162(3): 707-738.
- [13] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[J]. *Advances in Neural Information Processing Systems*, 2017, 30(1): 703-715.

- [14] KINGMA D P, WELING M. Auto-encoding variational Bayes[EB/OL]. [2023]. <http://arxiv.org/abs/1312.6114.pdf>.
- [15] BEVROYE L. An automatic method for generating random variates with a given characteristic function[J]. *SIAM Journal on Applied Mathematics*, 1986, 46(4): 698-719.
- [16] HU T Y, HUANG Y, ZHU Q M, et al. Channel estimation enhancement with generative adversarial networks[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2021, 7(1): 145-156.
- [17] WU N, WANG X, LIN B, et al. A CNN-based end-to-end learning framework toward intelligent communication systems[J]. *IEEE Access*, 2019, 7: 110197-110204.

作者简介



姜 斌 男, 1980 年生, 浙江衢州人. 现为杭州电子科技大学通信工程学院高级实验师, 在职博士生. 主要研究方向为无线通讯、信号处理、无线传感网络等.
E-mail: jiangbin@hdu.edu.cn



程子巍 男, 1998 年生, 山东潍坊人. 现为杭州电子科技大学通信工程学院研究生.
E-mail: 1611861153@qq.com



包建荣 男, 1978 年生, 浙江杭州人. 杭州电子科技大学教授、博导, 研究方向为空间无线通信、协同信息论与编码、分布式多天线联合迭代检测等. 中国电子学会会员编号: E190006599S.
E-mail: baojr@hdu.edu.cn