

• 信息与通信工程 •

## 基于生成对抗网络的 OFDM 信号生成



陈 丽<sup>1</sup>, 许思扬<sup>2</sup>, 刘 芳<sup>1</sup>, 冯 奇<sup>1</sup>, 刘承享<sup>2</sup>, 徐福琛<sup>2</sup>, 田 淼<sup>2</sup>, 刘光辉<sup>2\*</sup>

(1. 中国电子科技集团公司第五十四研究所 石家庄 050051; 2. 电子科技大学信息与通信工程学院 成都 611731)

**【摘要】**提出了一种基于图样-星座双判别器生成对抗网络 (Pattern-Constellation dual GAN) 的正交频分复用 (OFDM) 信号生成方案。首先, 使用快速傅里叶变换 (FFT) 对时域 OFDM 信号进行预处理, 得到的频域符号向量被拼接为二维数据矩阵, 用于 GAN 的训练和测试。为保证生成的信号具有协议要求的子载波结构和调制方式, 设计了双判别器 GAN: 生成器生成时频二维图样以欺骗两个判别器, 而两个判别器分别从子载波结构和调制符号的星座密度两个方面区分生成的图样和真实图样。最后, 以 Wi-Fi 802.11a 协议为例验证了该方案的有效性。

**关键词** 通信对抗; 数字信号生成; 生成对抗网络; 正交频分复用; 时频二维图样  
中图分类号 TN975 文献标志码 A doi:10.12178/1001-0548.2022253

## OFDM Signal Generation Based on Generative Adversarial Network

CHEN Li<sup>1</sup>, XU Siyang<sup>2</sup>, LIU Fang<sup>1</sup>, FENG Qi<sup>1</sup>, LIU Chengxiang<sup>2</sup>, XU Fuchen<sup>2</sup>, TIAN Miao<sup>2</sup>, and LIU Guanghui<sup>2\*</sup>

(1. The 54th Research Institute of China Electronics Technology Group Corporation Shijiazhuang 050051;

2. School of Information and Communication Engineering, University of Electronic Science and Technology of China Chengdu 611731)

**Abstract** Generating digital signal in complex electromagnetic environment is one of the core issues in communication countermeasures and jamming. An orthogonal frequency-division multiplexing (OFDM) signal generation scheme based on the pattern-constellation dual discriminator generative adversarial network (Pattern-Constellation dual GAN) is developed. First, symbol vectors in frequency domain are generated by applying the fast Fourier transform to the OFDM signals. Then, the symbol vectors are orderly concatenated into a two-dimensional matrix and stored as a gray-scale image, which contains the corresponding time-frequency features of the OFDM signals. Furthermore, such gray-scale images are used for training and testing the proposed Dual GAN network. In our network, an adversarial game among one generator and two discriminators is established to generate gray-scale images which contain the same time-frequency features as in the training images. The generator aims to generate a counterfeit image to confuse the two discriminators, while the two discriminators aim to distinguish the subcarrier structure and the constellation density between the generated image and the real image, respectively. Finally, the Wi-Fi 802.11a protocol signals are used as examples to verify the effectiveness of proposed signal generation model.

**Key words** communication countermeasure; digital signal generation; generative adversarial network; orthogonal frequency-division multiplexing; time-frequency pattern

引用数字信号自主生成是认知通信对抗领域的研究热点<sup>[1-2]</sup>, 即通过生成与敌方信号高度近似的数字信号, 逃脱敌方设备的物理层认证<sup>[3]</sup>, 实现欺骗干扰。该技术在通信干扰、通信对抗以及电子战领域具有重要研究意义。

在传统的通信对抗中, 面对未知的敌方信号, 需要先进行信道和信号参数估计, 再对信号进行跟踪式干扰, 或在对方信号识别失败的情况下直接

进行阻塞式干扰<sup>[4]</sup>。但随着通信和网络技术的发展进步, 电磁信号呈现出多模式、多制式、智能化、高度自适应和快速捷变等特点。为满足不同通信场景的差异化需求, 人们设计了多种复杂的无线通信协议。面对未知的复杂协议信号, 传统干扰方法存在识别难、生成难的问题<sup>[1]</sup>。另外, 使用传统方法针对不同的协议生成干扰信号时, 需要不同的硬件实现, 不仅存在巨大的硬件开销且缺少足够的灵活

收稿日期: 2022-07-26; 修回日期: 2022-09-09

基金项目: 国家自然科学基金面上项目 (62071097); 四川省自然科学基金面上项目 (2023NSFSC0458)

作者简介: 陈丽 (1982-), 女, 高级工程师, 主要从事通信对抗、复杂电磁环境构建方面的研究。

\*通信作者: 刘光辉, E-mail: guanghui.liu@uestc.edu.cn

性和泛化能力。

在各类复杂协议信号的调制中, 正交频分复用 (OFDM) 应用最为广泛, 如移动通信的 4G 及 5G 通信<sup>[5-6]</sup>、数字视频广播 (DVB)、无线局域网等均使用了 OFDM 调制, 但这些协议采用了不同的信号帧结构。为克服传统干扰方法在不同参数信号间迁移能力的不足, 本文使用基于机器学习的算法实现复杂协议 OFDM 信号的自主生成。

传统的机器学习生成模型, 如高斯混合模型<sup>[7]</sup>、隐马尔可夫模型<sup>[8]</sup>、极大似然法等, 依赖于对真实样本概率密度函数的先验假设, 面对分布复杂的数据难以生成逼近真实样本的数据。作为目前在机器学习领域最热门的生成模型, 生成对抗网络 (generative adversarial networks, GAN) 相较于上述传统生成类算法的最大优势在于不用对数据分布做任何假设<sup>[9]</sup>, 通过生成器和判别器的对抗性学习, 可以自主学习真实样本的数据分布。GAN 已在语音信号增强、图像处理、音乐、视频生成等诸多领域取得成功。在这些应用中, GAN 生成的图片或数据具有较强的空间相关性。但 OFDM 信号在时域具有类似噪声的特点, 不利于特征提取和数据分布的拟合, 直接将时域 OFDM 信号作为 GAN 训练的真实样本可行性低。

在利用 GAN 进行通信信号生成方面, 文献 [10] 提出了基于条件 GAN (conditional GAN, CGAN) 的调幅 (AM) 信号和连续相位频移键控 (CPFSK) 信号的生成。但是该方案仅考虑了生成信号的时域波形与 AM 和 CPFSK 的波形的相似性, 没有从载波频率、信号幅度等参数角度分析生成信号是否合理。文献 [2] 利用边界平衡 GAN (boundary equilibrium GAN, BEGAN) 实现了单载波 BPSK 和 8PSK 信号生成。文献 [3,11] 提出了基于 GAN 的欺骗干扰信号生成模型, 生成的信号可以绕过敌方物理层信号认证, 有效降低了敌方接收机的分类准确率。文献 [12] 利用 CGAN 模拟信道特性, 生成了经过特定瞬时信道的时域信号。以上的信号生成方案都有效地生成了特定调制方式的单

载波信号, 但难以适用于多载波信号生成。目前针对多载波信号生成的研究比较少, 文献 [13] 利用双向 GAN (Bidirectional GAN, BIGAN) 和 CGAN 将在不同信道条件下的 OFDM 信号互相转换, 但该方案仅考虑了信号的幅度分布, 没有保证信号的调制方式, 子载波结构不变。

为解决上述问题, 本文利用 GAN 实现 OFDM 信号生成, 主要贡献如下。

1) 为解决 OFDM 信号时域类噪声、不容易提取特征的问题, 在信号生成架构中用 FFT 对 OFDM 时域信号进行预处理, 得到时频二维图样。

2) 为解决单判别器 GAN 生成的信号难以同时满足复杂协议要求的子载波结构 (传输数据的子载波和导频子载波的分布) 和数据符号调制方式的问题, 本文设计双判别器 GAN 实现时频二维图样生成, 双判别器分别学习信号的子载波结构和星座分布。

3) 提出了适用于 OFDM 信号生成的架构, 该架构可以实现特定复杂协议下不同参数 OFDM 复杂协议信号的生成。为在未来实现用统一架构生成更广泛的复杂协议干扰信号奠定了基础。

## 1 系统模型

OFDM 调制技术是多载波调制的一种, 其将高速数据流转换成并行的低速子数据流并调制到每个子载波上进行传输, 具有较好的抗多径衰落能力, 是目前无线通信应用最为广泛的调制技术。OFDM 信号生成流程如图 1 所示。首先, 输入的比特流被映射到相移键控 (PSK) 或正交振幅调制 (QAM) 的星座点上, 它是由星座平面上的同相分量和正交分量 (IQ) 组成的。然后, 通过串/并转换将调制符号映射到并行的  $N_{\text{FFT}}$  个数据流 (用于传输数据的子载波) 中。再将导频符号以梳状模式插入每个频域 OFDM 符号。经过  $N_{\text{FFT}}$  点快速傅里叶逆变换 (IFFT) 将得到的频域 OFDM 符号转换为时域。为避免符号间干扰, 在每一 OFDM 符号前添加循环前缀 (cyclic prefix, CP)。最终通过并串转换后得到 OFDM 信号。




图 1 系统模型

传统信号生成器发送的 OFDM 信号  $s$  在受到无线信道中加性高斯白噪声 (AWGN) 的影响后被接收机接收。经过本文提出的基于 GAN 的 OFDM 信号生成系统处理后生成与输入信号高度相似的采样信号  $s'$ 。

与接收信号  $r$  相比,  $s'$  携带不同信息但具有相同的子载波结构 (传输数据的子载波和导频子载波的分布) 和调制方式。

## 2 生成对抗网络算法基础

GAN 主要包含生成器和判别器两大模块, 其一般架构如图 2 所示<sup>[14]</sup>。




图 2 GAN 一般架构

生成器的作用是生成尽可能逼近真实样本的数据, 判别器的作用则是尽可能准确区分生成器生成样本与真实样本, 并将判别结果反馈给生成器。生成器和判别器不断循环对抗, 直至判别器无法正确区分生成样本与真实样本。常规 GAN 的目标函数为:

$$\min\{\text{loss}(G)\} = \min\{E_{z \sim p_z(z)}[\log(1 - D(G(z)))]\} \quad (1)$$

$$\min\{\text{loss}(D)\} = \min\{-E_{x \sim p_{\text{data}}(x)}[\log D(x)] - E_{z \sim p_z(z)}[\log(1 - D(G(z)))]\} \quad (2)$$

式中,  $G$  表示生成器;  $D$  表示判别器;  $x$  代表真实数据;  $z$  表示随机噪声。

常规 GAN 存在训练困难的问题, 如模式崩溃等, 因此许多改进方案被提出。WGAN (Wasserstein GAN)<sup>[15]</sup>、带梯度惩罚的 WGAN (WGAN gradient

penalty, WGAN-GP)<sup>[16]</sup>、CGAN<sup>[17]</sup>、信息最大化 GAN (information maximizing GAN, Info-GAN)<sup>[18]</sup> 等通过改变常规 GAN 的目标函数、增加输入条件等使 GAN 有更好的学习能力、更快的收敛速度和更好的训练稳定性。

本文应用最小二乘生成对抗网络<sup>[19]</sup> (least squares GAN, LSGAN), 利用最小二乘损失函数惩罚距决策边界正确一侧很远的虚假样本, 让 LSGAN 生成器生成数据更接近真实样本, 并且该目标函数具有最小皮尔逊  $\chi^2$  散度 (Pearson  $\chi^2$  divergence), 在训练时比常规 GAN 有更好的稳定性。其目标函数为:

$$\min_D V_{\text{LSGAN}}(D) = \frac{1}{2} E_{x \sim p_{\text{data}}(x)} [(D(x) - b)^2] + \frac{1}{2} E_{z \sim p_z(z)} [(D(G(z)) - a)^2] \quad (3)$$

$$\min_G V_{\text{LSGAN}}(G) = E_{z \sim p_z(z)} [(D(G(z)) - c)^2] \quad (4)$$

式中,  $a$ 、 $b$  分别是虚假样本和真实样本的标签;  $c$  表示判别器判别样本真假的决策边界。

## 3 基于生成对抗网络的 OFDM 信号生成方案

### 3.1 整体架构

本文提出的基于生成对抗网络的 OFDM 信号生成系统如图 3 所示。系统的输入为带噪声 OFDM 采样信号。在已知快速傅里叶变换 (FFT) 点数和 CP 长度的条件下, 将其进行串并转换后利用 FFT 将时域信号转换到频域。经过预处理后得到时频二维图样并将其作为真实样本输入本文提出的双判别器 GAN 进行训练。训练完成后, 将生成器生成的时频二维图样进行 IFFT 和并串转换, 即可得到与输入信号具有相同子载波结构和调制方式的 OFDM 时域采样信号。

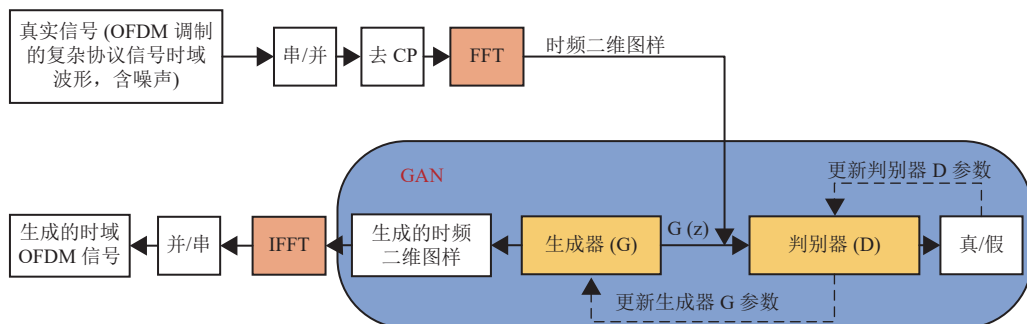


图 3 基于生成对抗网络的 OFDM 信号生成系统

尽管本文的具体架构是针对 OFDM 信号提出的, 但面对其他未知的多载波信号时, 如果可以使用其他的处理方法将时域信号转换为时频二维图样, 仍然可以使用本文中提出的架构进行信号生成。

### 3.2 时频二维图样

基带 OFDM 时域信号由若干正交子载波的时域序列叠加而来。根据中心极限定理, OFDM 时域信号服从均值为零的高斯分布<sup>[20]</sup>, 有类似噪声的特性, 使用神经网络难以从中提取特征。而 OFDM 频域信号包含的特征更为明显, 更利于神经网络的学习。

因此, 为解决 GAN 提取 OFDM 信号时域特征困难的问题, 本文首先对接收到的包含 AWGN 的 OFDM 时域信号  $r$  进行预处理。先将  $r$  进行串并转换并去掉 CP 后, 得到维度为  $N_T \times N_{FFT}$  的矩阵  $R$ , 其中  $N_T$  为 OFDM 符号数量,  $N_{FFT}$  为 FFT 点数。矩阵的每一行代表一个时域 OFDM 符号。将矩阵  $R$  中的每一行进行 FFT, 将信号从时域变换到频域即得到时频二维矩阵  $\hat{R} = [\hat{r}_1 \ \hat{r}_2 \ \dots \ \hat{r}_{N_T}]^T$ , 其中向量  $\hat{r}_i (1 \leq i \leq N_T)$  为维度为  $N_{FFT} \times 1$  的列向量。对所有的向量  $\hat{r}_i$  进行如下的归一化处理:

$$\tilde{r}_i = \hat{r}_i / (2 \times \|\hat{r}_i\|_{\infty}) + 0.5 + 0.5j \quad (5)$$

式中,  $\|\cdot\|_{\infty}$  表示向量无穷范数;  $j$  为虚数单位。归一化后矩阵  $R_{\text{norm}} = [\tilde{r}_1 \ \tilde{r}_2 \ \dots \ \tilde{r}_{N_T}]^T$  中的每个元素的实部和虚部的取值范围为  $[0, 1]$ 。

提取矩阵  $R_{\text{norm}}$  的每一个元素实部和虚部且分别组成新的时频二维矩阵  $\mathfrak{R}(R_{\text{norm}})$  和  $\mathfrak{I}(R_{\text{norm}})$ 。以单通道灰度图像的形式存储上述矩阵并将其作为双判别器 GAN 的训练样本  $x$ 。由于  $r$  受到 AWGN 的影响, 训练样本  $x$  中表示虚拟子载波的像素点幅度满足高斯分布。

本文以 Wi-Fi 802.11a 协议中数据部分的 OFDM

信号为例, 该信号经过上述预处理后得到的实部时频二维图样如图 4 所示。其中,  $N_T = 100, N_{FFT} = 64$ 。在 64 个子载波中有 48 个数据子载波, 每个数据子载波上搭载了随机的 QPSK 符号, 在实部时频二维图样中为黑白交错的像素点; 4 个搭载导频的子载波为白色; 剩余的 12 列为虚拟子载波, 在图样中为灰色。




图 4 时频二维图样 (实部)

### 3.3 图样-星座双判别器 GAN

若采用常规的单判别器 GAN 对生成的时频二维图样进行训练, 生成图样具有正确的子载波结构, 即数据子载波、导频、虚拟子载波位置。但是, 生成图样中表示数据符号的像素点幅度随机分布, 而在真实图样中, 数据符号的幅度分布在特定调制方式 (BPSK/QPSK) 下的星座点附近, 生成信号的调制方式不满足协议中的规定。另外, 生成器输出容易落入激活函数 (Tanh) 的饱和区, 导致梯度难以回传。为了解决上述问题, 本文在原有单判别器 GAN 的基础上增加了判别器  $D_2$ , 用于区分生成图样与训练样本图样的幅度分布, 一旦分布偏离真实样本, 生成的时频图就被判别器  $D_2$  判断为假。为了欺骗判别器  $D_2$ , 生成器生成的时频图的幅度分布会逼近真实样本, 因此生成图样与训练样本图样具有相同的调制方式。同时生成图样的分布被限制在激活函数的非饱和区, 梯度消失得以缓解。提出的双判别器 GAN 结构如图 5 所示。

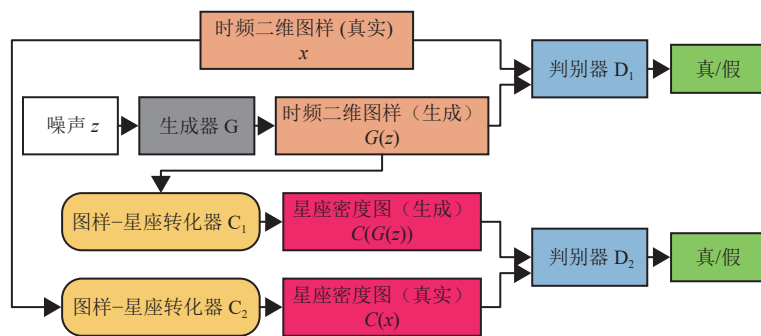


图 5 图样-星座双判别器 GAN 网络结构

#### 3.3.1 网络总体结构

为了判断时频二维图样中数据符号调制星座的

分布的真假, 判别器  $D_2$  的输入分别为真实图样和生成图样的星座密度图<sup>[21]</sup>。生成星座密度图包含量



化和统计的过程, 若在 GAN 训练过程中直接将时频二维图样转换为星座密度图会令梯度无法反向传播, 使得判别器  $D_2$  无法约束生成器。为了解决上述问题, 本文提出了图样-星座转换网络, 该网络是离线训练的, 其功能是实现时频二维图样到星座密度图的转换。

经过验证, 本文提出的图样-星座双判别器 GAN 生成的图样在子载波结构和数据符号的星座分布上均与真实信号相同。

本文使用 LSGAN 作为基网络。分别采用 0、1 表示虚假样本和真实样本的标签, 并且为使生成器生成样本尽可能真实, 令判别器判别样本真假的决策边界为 1。结合式 (3) 和式 (4), 双判别器的 LSGAN 的目标函数定义如下:

$$\min_{D_1} V_{LSGAN}(D_1) = \frac{1}{2} E_{x \sim p_{data}(x)} [(D_1(x) - 1)^2] + \frac{1}{2} E_{z \sim p_z(z)} [(D_1(G(z)))^2] \quad (6)$$

$$\min_{D_2} V_{LSGAN}(D_2) = \frac{1}{2} E_{x \sim p_{data}(x)} [(D_2(C(x)) - 1)^2] + \frac{1}{2} E_{z \sim p_z(z)} [(D_2(C(G(z))))^2] \quad (7)$$

$$\min_G V_{LSGAN}(G) = \lambda_1 E_{z \sim p_z(z)} [(D_1(G(z)) - 1)^2] + \lambda_2 E_{z \sim p_z(z)} [(D_2(C(G(z)))) - 1]^2 \quad (8)$$

式中,  $\lambda_1$  和  $\lambda_2$  分别表示图样判别器  $D_1$  和星座判别器  $D_2$  损失函数的权重。

### 3.3.2 图样-星座转化器

数据符号的调制方式体现在时频二维图样像素点的幅值分布中。但对于神经网络而言, 难以直接学习到像素点的幅度分布。因此, 本文统计像素点分布, 并将分布信息转化为图像输出。

如图 6 所示, 时频二维图样转换为星座密度图包括以下步骤。

1) 量化统计。本文将  $[0, 1]$  等分为  $n$  个量化区间, 把时频二维图样第  $i$  行的  $N_{FFT}$  个像素点的幅度用向量  $\mathbf{x}_i = [x_{i,1}, x_{i,2}, \dots, x_{i,N_{FFT}}]$ ,  $i = 1, 2, \dots, N_T$  表示, 每一行像素点幅度落在第  $k$  个量化区间的个数  $y_{i,k}$  为:

$$y_{i,k} = \sum_{l=1}^{N_{FFT}} \left[ u\left(x_{i,l} - \frac{k-1}{n}\right) - u\left(x_{i,l} - \frac{k}{n}\right) \right] \quad k = 1, 2, \dots, n \quad (9)$$

式中,  $u(t)$  是单位阶跃函数。

2) 归一化。将步骤 1) 得到的  $n$  维向量  $\mathbf{y}_i = [y_{i,1}, y_{i,2}, \dots, y_{i,n}]^T$  进行如下归一化:

$$\tilde{\mathbf{y}}_i = \frac{\mathbf{y}_i}{\|\mathbf{y}_i\|_\infty} \quad (10)$$

3) 拼接。将向量  $\tilde{\mathbf{y}}_i$  拼接为维度为  $N_T \times n$  二维矩阵  $\tilde{\mathbf{y}} = [\tilde{\mathbf{y}}_1, \tilde{\mathbf{y}}_2, \dots, \tilde{\mathbf{y}}_{N_T}]^T$ , 该矩阵即为星座密度图。通过星座密度图可以清晰观察到时频二维图样中的幅度分布。

由于:

$$\frac{\partial u(t)}{\partial t} = \begin{cases} +\infty & t = 0 \\ 0 & t \neq 0 \end{cases} \quad (11)$$

因此向量  $\mathbf{y}_i$  关于  $\mathbf{x}_i$  的梯度矩阵  $\partial \mathbf{y}_i / \partial \mathbf{x}_i$  中绝大部分元素为 0, 导致梯度回传困难, 最终无法训练。

因此, 为避免量化统计过程造成的梯度消失, 本文采用自编码器 (auto encoder, AE) 进行时频二维图样到星座密度图的转换, 并让 AE 生成的星座密度图尽可能逼近信号实际的星座密度图。自编码器包括编码器和译码器两大模块, 通过利用输入层与输出层之间的映射关系, 可以对时频二维图样进行实现星座特征提取和星座特征输出, 其中编码器用于提取数据分布特征, 译码器用于数据分布特征的重构输出。本文使用卷积自编码器 (CAE) [22] 拟合时频二维图样到星座密度图的量化统计流程, 即图 5 中的图样-星座转化器, 其损失函数如下:

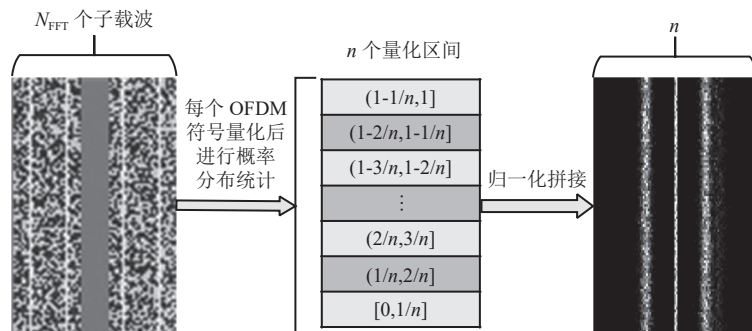


图 6 时频二维图样-星座密度图转换示意图

$$\text{loss}(C) = \frac{1}{n \times N_T} \sum_{i=1}^{N_T} \sum_{k=1}^n |C_{i,k}(\mathbf{x}) - \tilde{y}_{i,k}|^2 \quad (12)$$

式中,  $\tilde{y}_{i,k}$  和  $C_{i,k}(\mathbf{x})$  分别为矩阵  $\tilde{\mathbf{y}}$  和  $C(\mathbf{x})$  (图样星座转化器的输出) 的第  $i$  行第  $k$  列的元素。图样-星座转化器通过 3 层卷积层提取时频二维图样上像素点的星座分布特征, 利用 4 层转置卷积层对特征进行

重构输出, 生成星座密度图, 并使生成星座密度图与实际星座密度图均方误差 (MSE) 尽可能小。图样-星座转化器具体结构如图 7 所示, 对每个卷积层的输出都使用了批量归一化来限制网络各层输出的分布, 令其位于激活函数的非饱和区<sup>[23]</sup>, 从而缓解了梯度消失。

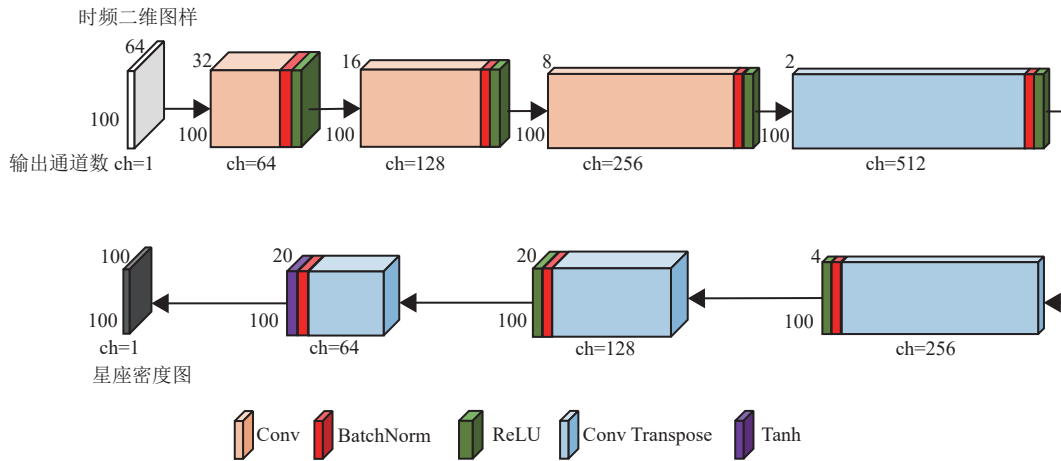


图 7 图样-星座转换网络结构

### 3.3.3 生成器结构

生成器由转置卷积和卷积神经网络构成, 具体结构如图 8 所示。在图样结构和星座数据双

判别器作用下, 将输入的随机噪声转化为逼近真实样本的时频二维图样。




图 8 生成器结构

### 3.3.4 判别器结构

判别器由卷积神经网络构成, 具体结构如图 9 所示。作用是尽可能正确区分输入的真实样本和生成样本, 其中判别器  $D_1$  为图样判别器, 目的是区分生成时频二维图样和真实时频二维图样在子载波结构上的差别, 判别器  $D_2$  是星座判别器, 目的是区分生成时频二维图样中数据符号星座分布和真实图样的数据符号星座分布。通过双判别器的制约, 生成器生成样本将从子载波结构和数据分布两个方向逼近真实样本, 使得生成信号与真实信号具有相同的子载波结构和调制方式。

### 3.3.5 网络复杂度分析

本文中提出的双判别器 GAN 网络结构主要由卷积神经网络和转置卷积神经网络组成。该网络的时间复杂度和空间复杂度是各个卷积层以及转置卷积层时间和空间复杂度的累加。

本文用输入一个样本, 模型进行前项传播发生的浮点运算次数 (floating point operations, FLOPs) 来衡量时间复杂度。卷积层的时间复杂度由卷积核面积、输出特征图面积以及输入输出通道数决定。转置卷积层与卷积层相反, 其时间复杂度与输入矩阵尺寸有关, 与输出特征图面积无关<sup>[24]</sup>。同时, 本

文用模型的参数数量和各层的输出特征图占用的内存空间来衡量网络的空间复杂度。卷积层和转置卷积层的参数数量都与卷积核大小和输入输出通道数有关, 而输出特征图占用的空间与输出特征图面积和输出通道数相关。本文使用 pytorch 中的 Thop

库对图样-星座双判别器 GAN 各个模块的时间复杂度和空间复杂度进行了统计, 统计结果如表 1 所示。根据统计结果, 生成一个 OFDM 信号样本所需的时间复杂度为 $1.78 \times 10^9$ Flops, 占用的内存空间为 $1.65 \times 10^7$  B。

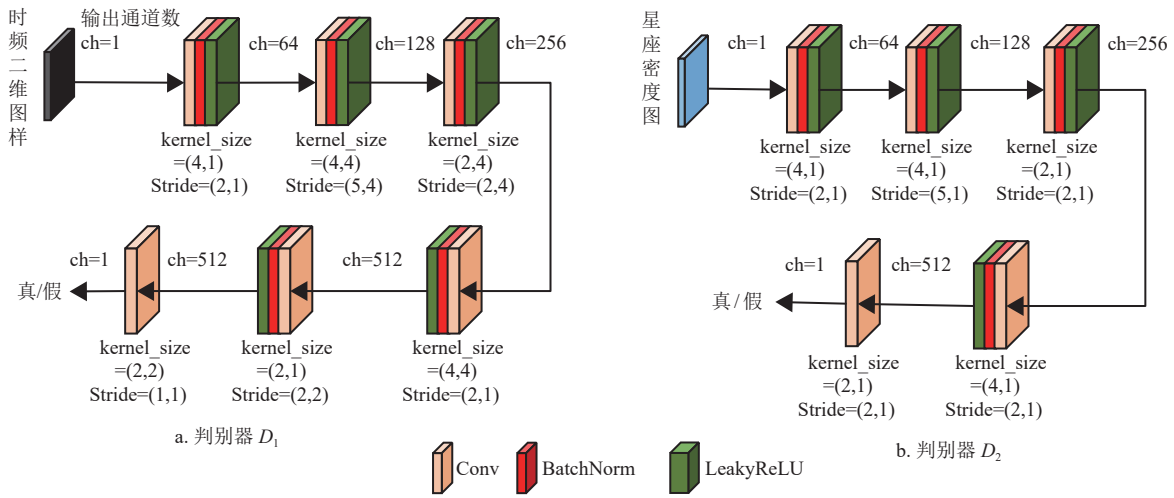


图 9 判别器结构

表 1 图样-星座双判别器 GAN 各个模块的时间和空间复杂度

模块	时间复杂度/FLOPs	空间复杂度/B
图样-星座转换器	$7.78 \times 10^8$	$9.32 \times 10^6$
生成器	$1.78 \times 10^9$	$1.65 \times 10^7$
判别器 $D_1$	$5.00 \times 10^7$	$2.04 \times 10^7$
判别器 $D_2$	$2.34 \times 10^8$	$5.52 \times 10^6$

## 4 实验与结果分析

为了验证本文提出的基于图样-星座双判别器 GAN 的复杂协议 OFDM 信号生成模型的有效性, 选用 Wi-Fi 802.11a PLCP 协议数据单元 (PCLP Protocol Date Unit, PPDU) 中的数据段作为真实信号进行信号生成实验。

数据段由 OFDM 符号构成, 子载波个数 $N_{FFT} = 64$ , 其中搭载数据符号的子载波个数为 48 个, 分别位于第 2~7, 9~21, 23~27, 39~43, 45~57 和 59~64 个子载波; 导频占据 4 个子载波, 分布在第 8、22、44、58 个子载波; 其余的 12 个为虚拟子载波。信号带宽为 20 MHz, 每个 OFDM 符号持续时间为 4 us, CP 长度为 0.8 us, 在采样率为 20 MHz 的情况下, 一个 OFDM 符号包含 80 个采样点, 其中 CP 包含 16 个采样点, 调制方式为

BPSK/QPSK, 优化器为 Adam。表 2~表 4 分别给出了仿真参数和模型训练所选用的超参数。

表 2 仿真参数

参数	值
子载波个数 $N_{FFT}$	64
一个时频图中 OFDM 符号数量 $N_T$	100
量化区间的数量 $n$	100
带宽	20 MHz
信噪比 SNR/dB	10 / 20
每一信噪比及调制方式下样本数据集大小	10 000

表 3 图样-星座转换网络训练超参数

参数	值
一次训练所选取的样本数	40
学习率	$10^{-4}$

表 4 图样-星座双判别器 GAN 训练超参数


参数	值
一次训练所选取的样本数	40
生成器 G 学习率	$4 \times 10^{-4}$
判别器 $D_1$ 学习率	$10^{-4}$
判别器 $D_2$ 学习率	$10^{-4}$
判别器 $D_1$ 损失函数权重 $\lambda_1$	0.1
判别器 $D_2$ 损失函数权重 $\lambda_2$	0.4

本文将从时频二维图样和时域信号两个角度对

生成信号进行评估，从而验证本文提出的 OFDM 信号生成模型的有效性。

### 4.1 时频二维图样分析

图 10 给出了图样-星座双判别器 GAN 和单判别器 GAN 生成的时频二维图样对比。可以看到，单判别器 GAN 和双判别器 GAN 生成时频二维图样在子载波结构上一致，都满足 Wi-Fi 802.11a PLCP 协议中的规定。生成的图样中第 1 和第 28~38 列为灰色，代表虚拟子载波；实部图样中第 8、22、44 和 58 列为白色，虚部图样中第 8、22、44 和 58 列为灰色，对应导频符号所在的子载波；其余的 48 列中黑色和白色的像素点随机排列，对应数据子载波。



注：左 1 图为双判别器生成图样的实部，左 2 图为双判别器生成图样虚部，右 2 图为单判别器生成图样的实部，右 1 图为单判别器生成图样的虚部

图 10 双判别器 GAN 和单判别器 GAN 生成的时频二维图样

图 11 分别给出了单判别器 GAN、双判别器 GAN 生成图样和作为训练样本的真实时频二维图样的像素点幅度概率密度，左边为实部图，右边为

虚部图。可以看到，单判别器 GAN 生成图样数据符号幅度随机分布，不符合 BPSK/QPSK 的调制方式要求。而双判别器 GAN 生成图样的幅度分布与真实训练样本的幅度分布比较接近。这说明判别器  $D_2$  的损失函数成功回传到了生成器，生成的时频图可以欺骗判别器  $D_2$ 。

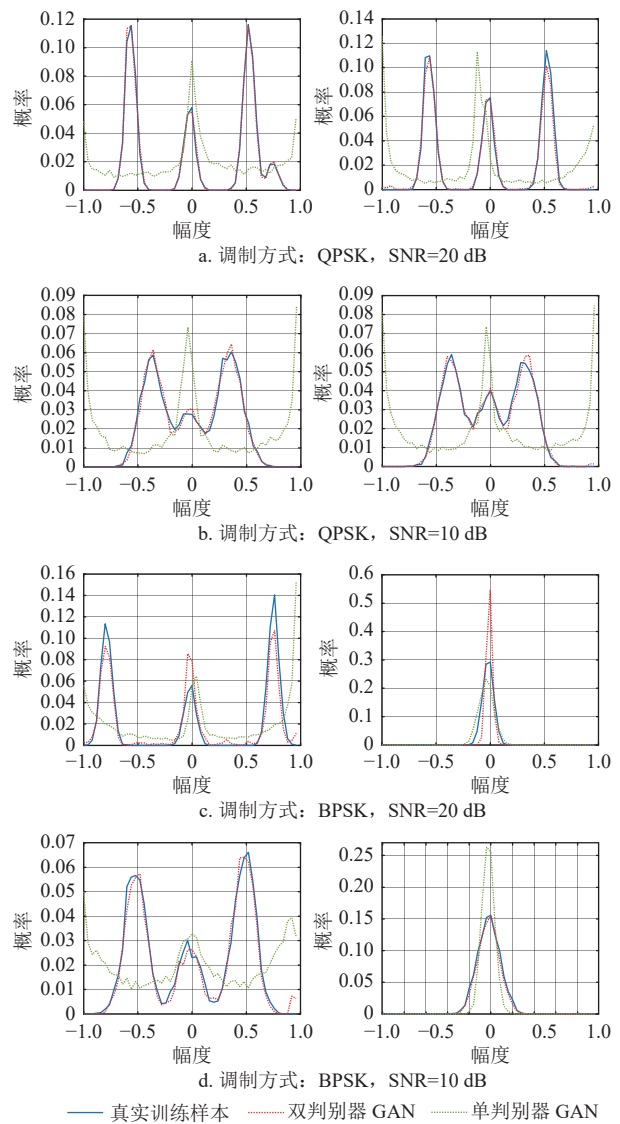


图 11 时频二维图样的幅度概率密度

表 5 给出了时频二维图样与无噪声图样的 MSE，具体计算如下。

表 5 时频二维图样与无噪声图样的 MSE

调制方式	SNR/dB	双判别器GAN	单判别器GAN	含噪声真实样本
BPSK	20	0.042 6	0.157 6	0.01
BPSK	10	0.142 8	0.241 6	0.10
QPSK	20	0.048 4	0.319 1	0.01
QPSK	10	0.152 4	0.368 2	0.10



$$\text{MSE} = \frac{1}{N_{\text{FFT}} \times N_{\text{T}}} \sum_{i=1}^{N_{\text{T}}} \sum_{l=0}^{N_{\text{FFT}}} \left[ \|x_{i,l} \|\hat{r}_i\|_{\infty} - x_{\text{Theory}} \right]^2 \quad (13)$$

式中,  $x_{\text{Theory}}$  是距离  $x_{i,j} \times \|\hat{r}_i\|_{\infty}$  最近的有限字符集中的字符, 虚拟子载波  $x_{\text{Theory}} \in \{0+0j\}$ , 导频  $x_{\text{Theory}} \in \{1+0j\}$ , BPSK 数据符号  $x_{\text{Theory}} \in \{\pm 1+0j\}$ , QPSK 数据符号  $x_{\text{Theory}} \in \{\pm \sqrt{2}/2 \pm \sqrt{2}j/2\}$ 。MSE 越小, 表示两组数据间越接近, 信号噪声越小。可以看出, 相比真实图样, 无论是单判别器还是双判别器 GAN 生成图样都具有更大的噪声, 但双判别器 GAN 的 MSE 与真实图样更接近, 尤其是在 SNR = 10 dB 的情况下。

综上所述, 本文提出双判别器结构在约束生成样本分布上优于单判别器, 可以实现 Wi-Fi 802.11a PLCP 协议 OFDM 信号生成。

#### 4.2 时域信号分析

对生成的时频二维图样进行 IFFT 和并串转换即可得到的时域 OFDM 信号。图 12 给出了双判别器 GAN 生成的和真实的时域信号波形, 图中蓝色曲线为生成波形, 红色曲线为真实波形。根据对比, 双判别器 GAN 生成的 OFDM 符号与 Wi-Fi 802.11a PLCP 协议的数据段 OFDM 符号都呈现近似噪声的特性。


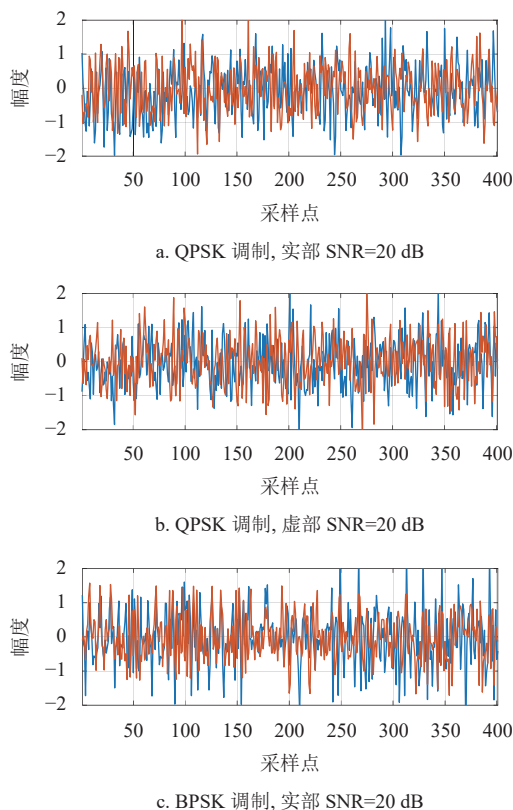


图 12 OFDM 符号序列时域波形

## 5 结束语

本文提出了一种基于生成对抗网络的 OFDM 信号生成方案。首先针对 OFDM 时域信号特征难以提取的问题, 利用 FFT 对时域信号预处理, 得到了容易提取特征的时频二维图样作为 GAN 训练样本。并且针对常规 GAN 难以学习到图样中数据符号的星座分布的问题, 提出了双判别器 GAN。相比常规的单判别器 GAN, 双判别器 GAN 同时约束图样和星座密度, 令生成样本满足真实信号的子载波结构和调制方式。

本文对多载波信号生成进行了初步探索, 但需要已知 OFDM 符号周期等先验信息。在未来需要实现符号周期自主识别, 以提高模型的实际应用能力。同时本文只考虑了 AWGN 信道, 在实际中截取的信号可能会受到多径信道的影响, 因此进一步探索在多径信道下的信号生成方案是有必要的。

## 参考文献

- [1] 张君毅, 李淳, 杨勇. 认知通信对抗关键技术研究[J]. 无线电工程, 2020, 50(8): 619-623.  
ZHANG J Y, LI C, YANG Y. A Study on key techniques in cognitive communication countermeasures[J]. Radio Engineering, 2020, 50(8): 619-623.
- [2] 杨鸿杰, 陈丽, 张君毅. 基于生成对抗网络的数字信号生成技术研究[J]. 电子测量技术, 2020, 43(20): 127-132.  
YANG H J, CHEN L, ZHANG J Y. Research on digital signal generation technology based on Generative adversarial network[J]. Electronic Measurement Technology, 2020, 43(20): 127-132.
- [3] SHI Y, DAVASLIOGLU K, SAGDUYU Y E. Generative adversarial network in the air: Deep adversarial learning for wireless signal spoofing[J]. IEEE Transactions on Cognitive Communications and Networking, 2020, 7(1): 294-303.
- [4] 薛灏勳. 关于无线通信干扰和抗干扰技术分析[J]. 数字通信世界, 2021(9): 137-138.  
XUE H J. Wireless communication interference and anti-jamming technology analysis[J]. Digital Communication World, 2021(9): 137-138.

- [5] 梁昊. 5G 通信系统的发展现状及关键技术研究[J]. 信息通信, 2019(9): 231-233.  
LIANG H. Research on current situation and key technology of 5G communication[J]. Information & Communications, 2019(9): 231-233.
- [6] 张万东, 戴鸿鹏, 刘理, 等. 4G 通信系统中 OFDM 技术的分析[J]. 通讯世界, 2017(20): 9-10.  
ZHANG W D, DAI H P, LIU L, et al. Analysis of OFDM technology in 4G communication system[J]. Communication World, 2017(20): 9-10.
- [7] RASMUSSEN C E. The infinite Gaussian mixture model [C]//Proceedings of the 12th International Conference on Neural Information Processing Systems. [S.l.]: ACM, 1999: 554-560.
- [8] FINE S, SINGER Y, TISHBY N. The hierarchical hidden Markov model: Analysis and applications[J]. *Machine learning*, 1998, 32(1): 41-62.
- [9] HONG Y, HWANG U, YOO J, et al. How generative adversarial networks and their variants work: An overview[J]. *ACM Computing Surveys (CSUR)*, 2019, 52(1): 1-43.
- [10] 秦剑. 基于生成对抗网络的信号重构[D]. 西安: 西安电子科技大学, 2018.  
QIN J. Signal reconstruction based on Generative adversarial networks[D]. Xi'an: Xidian University, 2018.
- [11] SHI Y, DAVASLIOGLU K, SAGDUYU Y E. Generative adversarial network for wireless signal spoofing[C]//Proceedings of the ACM Workshop on Wireless Security and Machine Learning. [S.l.]: ACM, 2019: 55-60.
- [12] 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.
- [13] DAVASLIOGLU K, SAGDUYU Y E. Generative adversarial learning for spectrum sensing[C]//2018 IEEE International Conference on Communications (ICC). [S.l.]: IEEE, 2018: 1-6.
- [14] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. *Advances in Neural Information Processing Systems*, 2014, 27(2): 2672-2680.
- [15] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks[C]//International Conference on Machine Learning. [S.l.]: PMLR, 2017: 214-223.
- [16] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. [S.l.]: ACM, 2017: 5769-5779.
- [17] MIRZA M, OSINDERO S. Conditional generative adversarial nets[EB/OL]. [2022-05-21]. <https://arxiv.org/pdf/1411.1784.pdf>.
- [18] CHEN X, DUAN Y, HOUTHOOFT R, et al. Infogan: Interpretable representation learning by information maximizing generative adversarial nets[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. [S.l.]: ACM, 2016: 2180-2188.
- [19] MAO X, LI Q, XIE H, et al. Least squares generative adversarial networks[C]//Proceedings of the IEEE international conference on computer vision. [S.l.]: IEEE, 2017: 2794-2802.
- [20] 林津辉. 基于机器学习的 OFDM 系统峰均比降低技术研究[D]. 西安: 西安电子科技大学, 2020.  
LIN J H. PAPR reduction in OFDM system based on machine learning[D]. Xi'an: Xidian University, 2020.
- [21] KUMAR Y, SHEORAN M, JAJOO G, et al. Automatic modulation classification based on constellation density using deep learning[J]. *IEEE Communications Letters*, 2020, 24(6): 1275-1278.
- [22] MASCI J, MEIER U, CIREŞAN D, et al. Stacked convolutional auto-encoders for hierarchical feature extraction[C]//International conference on artificial neural networks. Berlin: Springer, 2011: 52-59.
- [23] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on International Conference on Machine Learning. [S.l.]: ACM, 2015, DOI: [10.48550/arXiv.1502.03167](https://doi.org/10.48550/arXiv.1502.03167).
- [24] HE K, SUN J. Convolutional neural networks at constrained time cost[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.]: IEEE, 2015: 5353-5360.

编辑 税红