

# 基于 CWGAN-SLM 的多小波 OFDM 系统峰均比抑制算法研究

杨光, 吴朝阳, 聂敏, 闫晓红, 江帆

(西安邮电大学通信与信息工程学院(人工智能学院), 陕西 西安 710121)

**摘要:** 为满足未来 6G 星地一体化系统对正交频分复用 (OFDM) 技术低峰均比 (PAPR) 的需求, 首先提出一种将选择映射 (SLM) 算法与多小波 OFDM 技术相结合的算法, 但此算法降低 PAPR 的幅度有限, 并且计算复杂度较高。因此, 进一步提出基于条件 Wasserstein 生成对抗网络 (CWGAN) 和 SLM 的峰均比抑制算法, 即 CWGAN-SLM 算法, 并将其应用于多小波 OFDM 系统, 该算法通过引入 CWGAN, 生成多个时域备选信号, 以达到降低峰均比的目的。仿真结果表明, CWGAN-SLM 算法能够有效降低系统的 PAPR 和计算复杂度, 而且具有较低的误码率, 与 GAN 和 WGAN 相比, CWGAN 具有训练容易、稳定性强且 PAPR 性能好的特点。

**关键词:** 星地一体化; 正交频分复用; 峰均比; 多小波 OFDM; 计算复杂度

中图分类号: TN919.3

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2023069

## Research on PAPR reduction algorithm based on CWGAN-SLM for multi-wavelet OFDM system

YANG Guang, WU Zhaoyang, NIE Min, YAN Xiaohong, JIANG Fan

School of Communication and Information Engineering & School of Artificial Intelligence,  
Xi'an University of Posts and Telecommunications, Xi'an 710121, China

**Abstract:** In order to meet the demand for low peak to average ratio (PAPR) of orthogonal frequency division multiplexing (OFDM) technology in the future 6G satellite-ground integrated system, an algorithm combining selective mapping (SLM) algorithm and multi-wavelet OFDM technology was proposed firstly. However, the PAPR reduction was limited and the computational complexity was high. To solve this problem, a multi-wavelet OFDM PAPR reduction algorithm based on conditional Wasserstein generative adversarial network (CWGAN) and SLM was proposed, which was called CWGAN-SLM algorithm. CWGAN was introduced to generate more time-domain alternative signals to reduce the PAPR in the CWGAN-SLM algorithm. Simulation results indicate that the CWGAN-SLM algorithm greatly reduces the PAPR of the system and the computational complexity, and has a lower bit error rate. Compared with the GAN and WGAN, the CWGAN has the advantages of easy training, strong stability and good PAPR performance.

**Keywords:** satellite-ground integration, OFDM, PAPR, multi-wavelet OFDM, computational complexity

## 0 引言

为扩展通信覆盖广度和深度, 实现高可靠低时延的全球无线通信, 未来 6G 将地面通信与卫星通信进行融合, 构建空天地海一体化网络, 实现全球

无缝覆盖<sup>[1]</sup>。正交频分复用 (OFDM, orthogonal frequency division multiplexing) 技术具有频谱利用率高和抗多径等优点, 非常适用于星地一体化的空口设计<sup>[2]</sup>。然而高峰均比 (PAPR, peak to average power ratio) 是 OFDM 的一大缺点。过高的 PAPR

收稿日期: 2022-11-28; 修回日期: 2023-02-21

基金项目: 国家自然科学基金资助项目 (No.61971348, No.62071377); 陕西省自然科学基金资助项目 (No.2021JM-464)

**Foundation Items:** The National Natural Science Foundation of China (No.61971348, No.62071377), The Natural Science Basic Research Program of Shaanxi Province (No.2021JM-464)

将会导致高功率放大器产生非线性失真,同时使 OFDM 信号在经过非线性功率放大器后面临较大的误码率<sup>[3]</sup>,因而 OFDM 系统的 PAPR 抑制算法一直都是研究热点。在 6G 通信场景下,抑制 PAPR 变得更加重要。一方面,随着太赫兹技术<sup>[4]</sup>的引入,6G 将会使用更多的子载波进行数据传输,导致系统 PAPR 被进一步加大。另一方面,在星地通信中,高峰值功率对星载功率放大器的要求更高,这会导致在频段内和相邻频段之间产生干扰,直接使用 OFDM 技术则会降低星载功率放大器的效率,并带来散热等问题<sup>[5]</sup>。因此,降低信号 PAPR 是未来星地一体化网络研究中的重要问题。

目前,国内外学者针对如何降低 OFDM 系统中的 PAPR 已经做了大量的工作,这些研究可以归结为两类,即通过传统算法解决 PAPR 问题和通过引入深度学习解决 PAPR 问题。其中,传统算法根据算法特点可以分为三大类:预畸变类算法<sup>[6]</sup>、编码类算法<sup>[7]</sup>和概率类算法<sup>[8-9]</sup>。文献[10]提出 2 种改进的选择映射(SLM, selective mapping)算法,首先提出基于转移矩阵和混沌序列的 SLM 算法,有效减少了边带信息的传输,但 PAPR 的降低幅度有限。因此,进一步提出基于转移矩阵和旋转向量的选择映射(TR-SLM, transfer matrix and rotation vector SLM)算法,通过引入旋转向量,产生更多的时域备选信号,从而达到降低系统 PAPR 的目的。近年来,深度学习已经在很多领域表现出卓越的性能,引入深度学习的 PAPR 抑制算法已被视为 6G<sup>[11]</sup>中的一项潜在技术。文献[11]通过引入深度学习,提出一种模型驱动的预留子载波(MDTR, model-driven tone reservation)算法,与传统的预留子载波算法相比,在相同的 PAPR 性能下,该算法降低了计算复杂度与训练成本。文献[12]提出一种基于自编码器架构的 PAPR 抑制网络(PRNet, PAPR reducing network),通过深度学习技术自适应地确定每个子载波上符号的星座映射和解映射,从而同时降低 OFDM 系统的误码率和 PAPR。文献[13]提出一种基于实值神经网络(RV-NN, real valued neural network)的 PAPR 抑制算法,与 PRNet 相比,在相同的 PAPR 性能下,RV-NN 具有更低的计算复杂度和误码率。文献[14]提出一种削峰深度展开网络(PR-DUN, peak-reduction deep unfolding network)来降低 PAPR,所提出的多层模型通过展开迭代算法构建,得到具有可训练参数的层,并以最小化与

PAPR 值相关的损失函数为优化目标,达到降低 PAPR 的目的。

然而以上方法都是基于快速傅里叶变换(FFT, fast Fourier transformation)的 OFDM 系统来降低 PAPR。研究表明,使用离散小波变换代替传统 OFDM 中的快速傅里叶变换同样可以降低系统 PAPR。文献[15]提出一种新的基于小波方法的 OFDM PAPR 抑制技术,并结合压扩变换技术来进一步降低 PAPR。结果表明,基于小波的 OFDM 可以与其他 PAPR 减少技术集成,以进一步提高性能。文献[16]提出一种具有高带宽效率的滤波正交小波分复用(F-OWDM, filtered-orthogonal wavelet division multiplexing)系统,并研究 F-OWDM 系统在加性白高斯噪声和平坦衰落通道下采用不同小波的 PAPR 和误码率。结果表明,F-OWDM 具有比传统 F-OFDM 更低的 PAPR 和误码率。文献[17]为了解决 OFDM 系统的 PAPR 问题,采用基于小波变换的 OFDM 系统和部分传输序列技术来降低 PAPR,并比较采用不同调制方式的系统误码率性能。但由于单小波不能同时具备紧支撑、正交性、对称性和高逼近阶等特性,因此文献[18]提出一种基于正交多小波包的 OFDM 技术,通过使用多小波包变换代替传统 OFDM 技术中的傅里叶变换,使系统在传输相同数据速率时减少子载波数。研究表明,采用正交多小波包的 OFDM 技术具有比传统 OFDM 和单小波包 OFDM 更低的 PAPR 和更高的频谱利用率,但依旧无法满足未来 6G 通信系统的低 PAPR 需求。

为了满足未来星地一体化网络的低 PAPR 需求,本文提出将概率类算法中的 SLM 算法<sup>[8]</sup>与多小波 OFDM(MWOFDM, multi-wavelet-OFDM)技术相结合的算法,以达到改善 PAPR 性能的目的。但是此算法 PAPR 降低的幅度有限,并且计算复杂度较高,针对以上问题,本文将传统 SLM 算法与条件 Wasserstein 生成对抗网络(CWGAN, conditional Wasserstein generative adversarial network)<sup>[19]</sup>相结合,提出基于 CWGAN-SLM 的 PAPR 抑制算法。其主要思想是利用 CWGAN 生成  $K$  个具有相同信息的 MWOFDM 信号用于 PAPR 的计算和比较,省去频域信号与相位旋转因子的点乘以及大规模快速傅里叶逆变换(IFFT, invert fast Fourier transformation)运算,大幅度减少了计算复杂度;利用卷积神经网络(CNN, convolutional neural network)作为 CWGAN 生成器的基本网络结构,并利用

Wasserstein 距离作为损失函数, 使模型在训练时更加稳定; 利用条件信息作为给定标签, 使 CWGAN 生成结果可预测, 并生成特定信号。仿真结果和计算复杂度分析表明, 相较于传统 SLM 算法, 该算法的计算量要小很多, 同时该算法能在不增加系统误码率的情况下有效降低系统 PAPR。

## 1 多小波 OFDM 系统

### 1.1 多小波包理论

传统的单小波包由一个尺度函数和一个小波函数产生, 而多小波包由  $r$  个尺度函数  $\Phi(t) = [\phi_1(t), \dots, \phi_r(t)]^T$  和  $r$  个小波函数  $\Psi(t) = [\psi_1(t), \dots, \psi_r(t)]^T$  ( $r > 1$ ) 产生。多小波包理论<sup>[20]</sup>为若  $\Phi(t) = [\phi_1(t), \dots, \phi_r(t)]^T$  和  $\Psi(t) = [\psi_1(t), \dots, \psi_r(t)]^T$  的正交多尺度函数和多小波函数满足

$$\Phi(t) = \sqrt{2} \sum_k H(k) \phi(2t - k) \quad (1)$$

$$\Psi(t) = \sqrt{2} \sum_k G(k) \psi(2t - k) \quad (2)$$

则定义

$$W_{2l}(t) = \sqrt{2} H(k) W_l(2t - k) \quad (3)$$

$$W_{2l+1}(t) = \sqrt{2} G(k) W_l(2t - k) \quad (4)$$

其中,  $W_0(t) = \Phi(t) = [\phi_1(t), \dots, \phi_r(t)]^T$ ,  $W_1(t) = \Psi(t) = [\psi_1(t), \dots, \psi_r(t)]^T$ , 这样, 函数  $W_n(t)$  就是关于多尺度函数  $W_0(t) = \Phi(t)$  的多小波包函数,  $n = 2l$  或  $2l + 1$ ,  $l = 0, 1, \dots$ 。

多小波包的整数时移正交特性可以表述为对于每个  $n \geq 0$ , 有

$$\langle W_n(t - m), W_n(t - k) \rangle = \delta(k - m) I_{r \times r}, \quad m, k \in Z \quad (5)$$

### 1.2 基于多小波包变换的 OFDM

OFDM 技术的本质是将信息调制到不同频率的正交傅里叶基(子载波)上, 在频域上进行了精确的划分, 但在时域上没有进行控制, 因此子载波数过多导致 OFDM 信号在时域上出现 PAPR 过高的现象。MWOFFDM 除了在频域实现传统的频分复用之外, 在时域利用多小波基的整数时移特性实现正交复用, 以达到用较少的子载波数传输相同数据, 缓解因子载波数较多产生的高 PAPR 问题。

传统基于傅里叶基的 OFDM 信号可以表示为

$$s(t) = \frac{1}{\sqrt{N}} \sum_{k=0}^{N-1} d_k e^{j \frac{2\pi k t}{T}}, \quad 0 \leq t \leq T \quad (6)$$

其中,  $d_k$  是信息符号,  $T$  是符号时间,  $N$  是子载波数,  $f_k = \frac{k}{T}$ ,  $k = 0, 1, \dots, N$  是子载波频率。

当用多小波基函数取代傅里叶基后, 基于频域正交复用的 OFDM 发送信号可以表示为

$$s_0(t) = \frac{1}{\sqrt{N}} \sum_{k=0}^{N-1} d_k p_k(t), \quad 0 \leq t \leq T \quad (7)$$

其中,  $N$  为子载波数,  $p_k(t)$  为多小波子函数。常见的多小波基有 GHM 多小波、CL 多小波等。本文所使用的多小波基函数为文献[21]中提出的支撑于  $[0, 3]$  的优化多小波 SA4, 其滤波器长度为 3。

在频域正交复用的基础上, 基于式(5), 进一步采用时域整数正交时移复用方案后的 MWOFFDM 符号可以表示为

$$s(t) = \sum_{m=0}^{M-1} s_m \left( t - \frac{mT}{M} \right) = \frac{1}{\sqrt{N}} \sum_{k=0}^{N-1} \sum_{m=0}^{M-1} d_{k,m} p_k \left( t - \frac{mT}{M} \right), \quad 0 \leq t \leq T \quad (8)$$

其中,  $N$  为子载波数,  $M$  为多小波时域支撑长度。系统的 PAPR 为

$$\text{PAPR}_{\text{dB}} = 10 \lg \frac{\max |s(t)|^2}{E(|s(t)|^2)} \quad (9)$$

其中,  $E(|s(t)|^2)$  表示求期望。

对于  $N$  个子载波的 OFDM 系统, 其理论 PAPR 为  $10 \lg N$  dB。对于 MWOFFDM, 若基函数支撑长度为整数  $M$ , 则子载波数可减少为  $\frac{N}{M}$  个, 理论上

当帧长度为无限长时, PAPR 为  $10 \lg \left( \frac{N}{M} \right) = 10 \lg N - 10 \lg M$ , 较传统 OFDM 低  $10 \lg M$  dB。

图 1 为传统 OFDM 与 MWOFFDM 的互补累积分布函数 (CCDF, complementary cumulative distribution function)。从图 1 可以看出, 当 CCDF =  $1.0 \times 10^{-4}$  时, MWOFFDM 系统的 PAPR 为 8 dB, 低于传统 OFDM 系统。MWOFFDM 系统采用多小波包变换 (MWPT, multi-wavelet packets transformation) 和多小波包反变换 (IMWPT, invert multi-wavelet packets transformation) 代替传统 OFDM 中的 FFT 和 IFFT, 保留了传统 OFDM 系统的大部分优点,

同时提高了系统的频谱利用率和 PAPR。将传统 PAPR 抑制算法与 MWOFFDM 系统相结合,可进一步降低 PAPR,满足未来星地一体化网络对 PAPR 的需求。

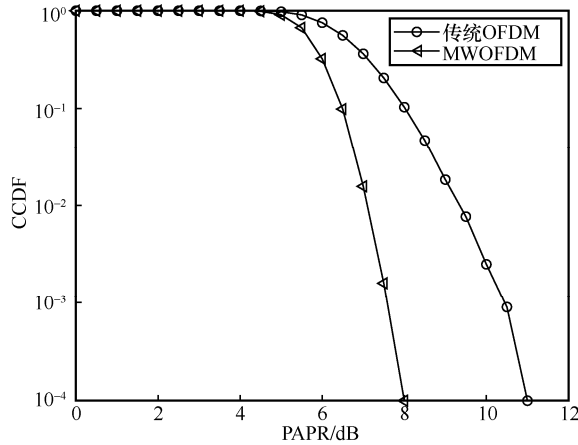


图 1 传统 OFDM 与 MWOFFDM 的 CCDF

## 2 CWGAN-SLM 峰均比抑制算法

### 2.1 SLM 算法原理

SLM 算法的基本思想是通过增加发送信号的数量来降低高数值信号出现的概率,从而降低系统的 PAPR。SLM 算法原理架构如图 2 所示。

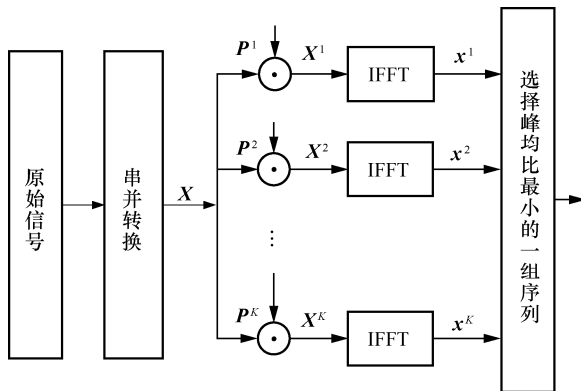


图 2 SLM 算法原理架构

在发送端,首先将未处理的 OFDM 频域数据  $X$  复制成相同的  $K$  路,生成  $K$  个长度均为  $N$  的随机相位序列矢量  $P^k = [P^k(0), \dots, P^k(N-1)]$ ,  $k=1, 2, \dots, K$ , 其中  $P^k(i) = e^{j\varphi_{i,k}}$ , 且  $\varphi$  在  $[0, 2\pi)$  内服从均匀分布。随后将  $X$  与  $P$  进行点乘得到  $X^k (1 \leq k \leq K)$ , 如式(10)所示。

$$X^k = [X(0)P^k(0), \dots, X(N-1)P^k(N-1)] \quad (10)$$

然后对每组信号进行 IFFT 运算得到经过旋转的  $K$  路不同的输出序列信号  $x^k$ , 如式(11)所示。

$$x^k = \text{IFFT}(X^k) = \text{IFFT}(XP^k), 1 \leq k \leq K \quad (11)$$

最后从  $K$  组时域信号  $x^k$  中选取具有最小 PAPR 值的那一组信号  $x^k$  作为传输信号。图 3 为采用 SLM 算法处理后的 MWOFFDM 系统的 CCDF 曲线。




图 3 采用 SLM 算法处理后的 MWOFFDM 系统的 CCDF 曲线

由图 3 可以看出,经过 SLM 算法处理后,信号的 PAPR 值明显降低,但随着组数的增多, PAPR 抑制性能的提升不再明显,且系统的计算复杂度大幅度增加。本文基于 SLM 算法的原理,联合生成对抗网络技术,提出了一种 CWGAN-SLM 峰均比抑制算法,在降低 MWOFFDM 系统 PAPR 的同时,减少了计算复杂度。

### 2.2 CWGAN-SLM 联合 PAPR 抑制算法

本文提出的 CWGAN-SLM 算法总体框架如图 4 所示。该框架由多小波 OFDM 信号生成、CWGAN 和 PAPR 计算 3 个模块组成。通过对比图 2 与图 4 可以看出,传统 SLM 算法将原始信号复制成  $K$  个信号并进行  $K$  次 IFFT 运算,复杂度较高。而本文所提算法通过多小波 OFDM 信号发生器生成一个多小波 OFDM 信号,只进行一次 IMWPT 运算,随后通过 CWGAN 模块生成  $K$  个独立统计、传输相同信息的 MWOFFDM 信号,并从中选择 PAPR 最小的一组信号进行传输,从而达到降低系统峰均比的目的。CWGAN-SLM 算法通过优化传输信号的波形来产生备选信号,不改变原始信号所携带的信息,并且整个过程仅需一个 IMWPT 模块,具有较低的计算复杂度。

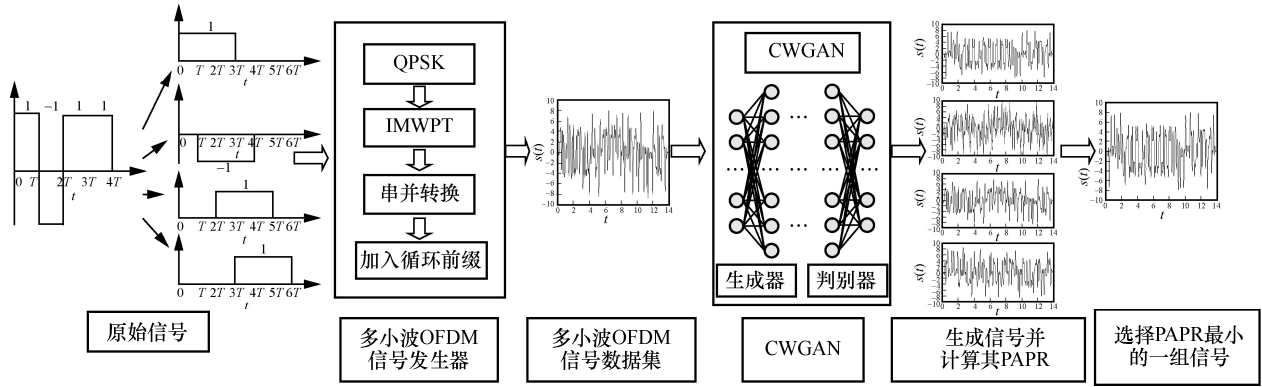


图 4 CWGAN-SLM 算法总体框架

### 2.2.1 CWGAN 模型构建

生成对抗网络 (GAN, generative adversarial network) 借鉴博弈论的思想, 通过对抗训练的方式来使生成器产生的样本服从真实样本分布。GAN 的目标函数为

$$\min_G \max_D L_{GAN}(D, G) = E_{x \sim P_d} [\log D(x)] + E_{z \sim P_g} [\log(1 - D(G(z)))] \quad (12)$$

其中,  $D(x)$  表示真实样本的概率,  $G(z)$  表示生成样本的概率,  $P_d$  表示真实数据的概率分布,  $P_g$  表示生成数据的概率分布。

原始 GAN 存在训练不稳定、收敛速度慢、梯度消失等问题。因此, 本文提出使用 Wasserstein 距离作为损失函数, 解决了原始 GAN 在对抗训练中较难收敛的问题。Wasserstein 距离的具体定义式为

$$W(P_d, P_g) = \inf_{\gamma \in \Pi(P_d, P_g)} E_{(x,y) \sim \gamma} \|x - y\| \quad (13)$$

其中,  $\Pi(P_d, P_g)$  表示  $P_d$  和  $P_g$  组合起来所有联合分布的集合,  $\inf$  表示取下限函数。

将 Wasserstein 距离加入 GAN 中, 并且通过形式变换, 得到

$$W(P_d, P_g) = \frac{1}{C} \sup_{\|f\|_L \leq K} [E_{x \sim P_d} D(x) - E_{z \sim P_g} D(G(z))] \quad (14)$$

其中, 常数  $C \geq 0$ 。式(14)表示在函数  $D(x)$  的 Lipschitz 常数  $\|f\|_L$  不超过  $K$  的条件下, 对所有可能满足条件的  $D(x)$  取到  $E_{x \sim P_d} D(x) - E_{z \sim P_g} D(G(z))$  的上界。

综上, 可以得到 Wasserstein 生成对抗网络 (WGAN, Wasserstein GAN) 的损失函数为

$$\min_G \max_D L_{WGAN}(D, G) = E_{x \sim P_d} D(x) - E_{z \sim P_g} D(G(z)) \quad (15)$$

将 MWOFFDM 系统应用到星地一体化网络, 要求 MWOFFDM 信号具有较低的峰均比。为满足上述需求, 本文在 WGAN 算法的基础上, 将 MWOFFDM 信号的导频信息作为条件信息  $c$ , 并将其作为 CWGAN 生成器输入的一部分, 使生成器按照给定的导频插入格式来生成信号。同时将 CNN 作为生成器与判别器的基本网络结构, 构成有条件的 WGAN 模型, 即 CWGAN, 其模型的框架结构如图 5 所示。

CWGAN 由生成器 (G) 和判别器 (D) 两部分组成。G 可以捕捉真实信号数据的潜在分布并生成新的信号, D 根据真实信号的期望输出  $D(x|c)$  是否接近 1 和生成信号的期望输出  $D(G(z|c))$  是否接近 0 来判断输入样本的真假。在训练过程中, 训练 D 使  $\log D(x|c)$  最大化, 训练 G 使  $\log(1 - D(G(z|c)))$  最小化。因此, CWGAN 的最终优化目标如式(16)所示。

$$\min_G \max_D L_{CWGAN}(D, G) = E_{x \sim P_d} \log D(x|c) + E_{z \sim P_g} \log(1 - D(G(z|c))) \quad (16)$$

其中,  $c$  表示 MWOFFDM 信号的导频信息。本文采用频分复用的方式插入导频序列, 其优点是对移动性的支持较好, 适用于星地通信场景。本文每间隔 8 个子载波插入一个导频, 并且为了方便信道估计, 将最后一个子载波也作为导频, 图 6 为 MWOFFDM 信号导频插入方式。通过加入限制条件  $c$ , 可以使 CWGAN 输出特定的信号, 生成的目标明确、可控性强。

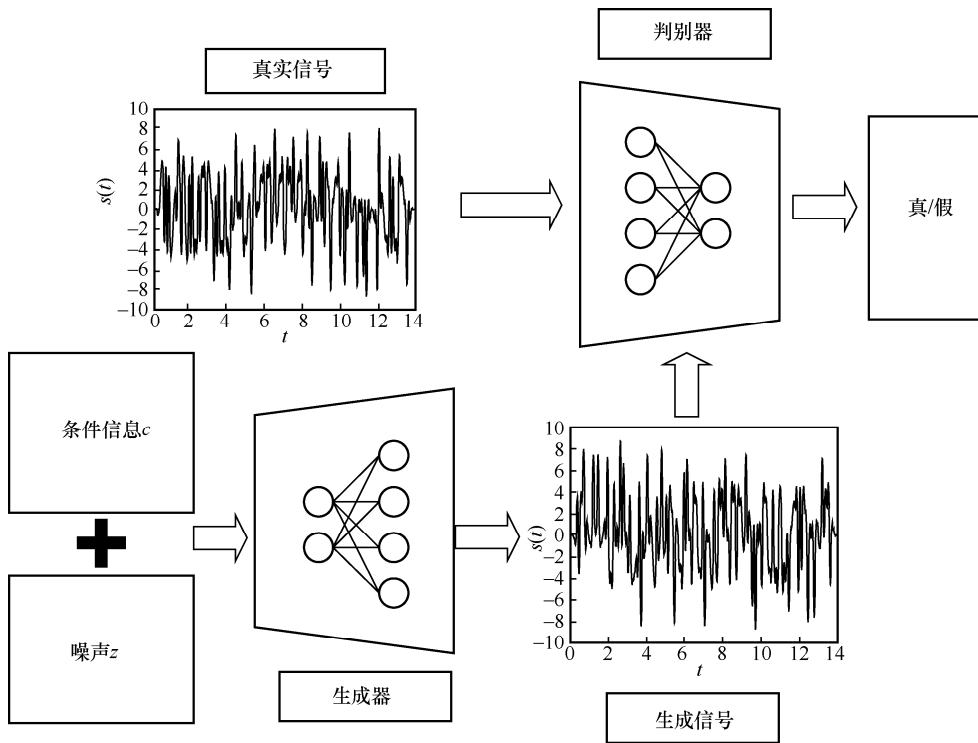


图 5 CWGAN 模型的框架结构




图 6 MWFDM 信号导频插入方式

### 2.2.2 CWGAN 结构

通过使用 CNN 作为生成器与判别器的基本网络结构，可以从复杂的数据中提取鲁棒特征，增强 CWGAN 模型提取样本特征的能力，使生成样本的概率分布更加接近于真实样本的概率分布，从而保证生成样本的质量。研究表明，深层 CNN 通常比浅层 CNN 具有更好的学习能力和图像特征表达能力。然而，随着 CNN 层数的增加，网络参数的数量也呈爆炸式增长，会造成梯度爆炸或梯度消失，导致训练过程不稳定、网络收敛困难，最终导致过拟合问题。

生成器的作用是生成和原始信号相似的假信号，目的是使判别器无法判断输入是原始信号还是假信号。经过分析数据样本分布可知，本文使用的真实数据是二维的数据点，表示特定时间的信号幅值，因此生成器不需要过于复杂，其结构如图 7 所示，其中， $k$  为卷积核大小， $n$  为滤波器个数， $s$  为卷积步长。生成器的最后一层卷积核大小为  $3 \times 3$ ，其余各层卷积核大小均为  $5 \times 5$ ，固定步长为 1，并在各卷积层后添加批归一化 (BN, batch normalization) 层与 ReLU 激活函数，从而加快训练收敛速度；最后使用 tanh 函数模型进行处理，以减轻梯度消失的问题。

判别器部分主要实现二分类问题，其输入为真实信号和生成器生成的虚假信号，由于判别器需要接触真实信号的特征点分布情况，因此判别器要比生成器




图 7 生成器结构

更复杂一些，共包含 4 个一维卷积层，其中卷积核大小为  $4 \times 4$ ，步长固定为 2，滤波器个数依次为 64、128 及 256，并在各卷积层后添加 BN 层与非线性激活函数 LeakyReLU，以避免 ReLU 函数进入负区间后导致神经元不学习的问题；输出采用 Sigmoid 激活函数将输入的概率值压缩到  $(0,1)$ ，当概率值大于 0.5 时判别为 Real，反之判别为 Fake。图 8 为判别器结构。

### 2.2.3 CWGAN 模型训练流程

由于本文提出的 CWGAN 是在 WGAN 的基础上添加了条件信息，因此训练方式与 WGAN 相似，损失函数采用 Wasserstein 距离来度量，并且优化算法采用 RMSProp 算法，如果使用 Adam 优化算法，则会导致训练不稳定。训练时，采取循环嵌套的方法，判别器每训练  $n_{critic}$  次后训练一次生成器。权重得到更新以后需要进行数值裁剪，将数值固定在  $[-c,c]$ 。CWGAN 算法具体实现过程如算法 1 所示。

#### 算法 1 CWGAN 算法

初始化 判别器参数  $w_0$ ，生成器参数  $\theta_0$ ，学习率  $\alpha$

- 1) while 生成器参数  $\theta$  未收敛 do
- 2) for  $t=1, \dots, n_{critic}$
- 3) for  $i=1, \dots, m$
- 4) 从真实数据中采样  $x \sim P(x)$ ，从噪声数据中采样  $z \sim P(z)$ ，生成一个随机数  $\varepsilon \sim \text{uniform}[0,1]$
- 5)  $\hat{x} = \varepsilon z + (1 - \varepsilon)G_\theta(x)$ ，生成混合样本
- 6)  $g_w \leftarrow \nabla_w \frac{1}{m} \sum_{i=1}^m [f_w(x^i) - f_w(g_\theta(z^i))]$
- 7)  $w \leftarrow w + \alpha \text{RMSProp}(w, g_w)$
- 8)  $w \leftarrow \text{clip}(w, -c, c)$
- 9) end for




图 8 判别器结构

- 10) 从真实数据中采样  $x \sim P(x)$ ，从噪声数据中采样  $z \sim P(z)$

$$11) g_\theta \leftarrow -\nabla_\theta \frac{1}{m} \sum_{i=1}^m f_w(g_\theta(z^i))$$

$$12) \theta \leftarrow \theta - \alpha \text{RMSProp}(\theta, g_\theta)$$

13) end for

14) end while

RMSProp 算法在对梯度进行指数加权平均的基础上引入平方和平方根，适合处理非平稳目标。RMSProp 有助于减少抵达最小值路径上的摆动，并允许使用较大的学习率，从而加快算法学习速度。RMSProp 算法具体实现过程如算法 2 所示。

#### 算法 2 RMSProp 算法

初始化 累计变量  $r=0$ ，全局学习率  $\varepsilon$ ，衰减速率  $\rho$ ，初始参数  $\theta$ ，小常数  $\delta$

1) while 没有达到停止准则 do

2) 从训练集中采样包含  $m$  个样本  $\{x^1, \dots, x^m\}$  小批量，对应目标为  $y^i$

$$3) \text{ 计算梯度 } g \leftarrow \nabla_\theta \frac{1}{m} \sum_{i=1}^m L(f(x^i; \theta), y^i)$$

$$4) \text{ 累计平方梯度 } r \leftarrow \rho r + (1 - \rho)g \odot g$$

$$5) \text{ 计算参数更新 } \Delta\theta = -\frac{\varepsilon}{\sqrt{\delta + r}} \odot g$$

$$6) \text{ 应用更新 } \theta \leftarrow \theta + \Delta\theta$$

7) end while

## 3 性能分析与仿真

### 3.1 计算复杂度分析

假设  $N$  为系统的子载波数， $K$  为 IFFT 个数，则传统 SLM 算法、TR-SLM 算法<sup>[10]</sup>、CWGAN-SLM 算法的计算复杂度对比如表 1 所示。

表 1 3 种 SLM 算法的计算复杂度对比

SLM 算法	复数乘法	复数加法
传统 SLM	$\frac{NK}{2} \text{lb}N$	$NK \text{lb}N$
TR-SLM	$\frac{NK}{2} \text{lb}N + 2K(N-1)$	$NK \text{lb}N + 9NK + K(N-1)$
CWGAN-SLM	$14N$	$16N$

对于传统 SLM 算法，产生  $K$  个时域备选信号共需进行次  $K$  次 IFFT 运算，共计需要  $NK \text{lb}N$  次复数加法运算和  $\frac{NK}{2} \text{lb}N$  次复数乘法运算。对于 CWGAN-SLM 算法，其复杂度包括 IMWPT 运算和 CWGAN 模型训练 2 个方面。首先，根据 Mallet 算法，生成  $K$  个时域备选信号需要进行一次 IMWPT 运算，共计需要  $16N$  次复数加法和  $14N$  次复数乘法。其次，影响训练过程复杂度的主要因素为模型的复杂程度和训练的迭代次数，但由于这些因素难以量化，本文在 3.3 节给出了各峰均比抑制算法的运行时间比较。由 3.2 节和 3.3 节可以看出，CWGAN-SLM 算法在降低了系统运行时间的同时，改善了 PAPR 性能。

### 3.2 仿真结果

为了验证 CWGAN-SLM 算法应用于星载多小波 OFDM 系统的可行性，本节对 CWGAN-SLM 算法进行了峰均比、误码率以及模型稳定性的仿真分析。本文依据 TR 38.811 卫星场景设置仿真参数，令卫星位于 1 500 km 的轨道高度，载波频率分别为 20 GHz。参考 5G NR 通信协议中非地面网络部分关于子载波间隔的规定：当同步信号带宽不大于 5 MHz 时，子载波间隔定义为 15 kHz；当同步信号带宽不大于 10 MHz 时，子载波间隔定义为 30 kHz；当同步信号带宽不大于 40 MHz 时，子载波间隔定义为 120 kHz；当同步信号带宽不大于 80 MHz 时，子载波间隔定义为 240 kHz。考虑卫星通信场景下的带宽普遍偏大，本文仿真时使用子载波间隔为 240 kHz。峰均比抑制算法的 MATLAB 仿真参数如表 2 所示。

图 9 给出了  $K=16$  时传统 SLM 算法<sup>[8]</sup>、MDTR 算法<sup>[11]</sup>、PRNet 算法<sup>[12]</sup>、RV-NN 算法<sup>[13]</sup>、PR-DUN 算法<sup>[14]</sup>及 CWGAN-SLM 算法的 CCDF 性能曲线。由图 9 可以看出，CWGAN-SLM 算法降低 MWOFFDM 系统 PAPR 的能力明显优于其他深度学习算法。预测当  $\text{CCDF}=1.0 \times 10^{-4}$  时，CWGAN-SLM 的 PAPR

大约为 6.3 dB，相比于 PR-DUN 和 PRNet 算法，PAPR 抑制性能略有提升。通过对仿真结果分析发现，本文算法具有较好的峰均比抑制性能。

表 2 峰均比抑制算法的 MATLAB 仿真参数

仿真参数	数值
卫星轨道高度/km	1 500
载波频率/GHz	20
信道类型	CDL-A
系统模型	MWOFFDM
多小波基函数	SA4
子载波个数/个	4 096
备选信号个数/个	16
调制/解调方式	QPSK

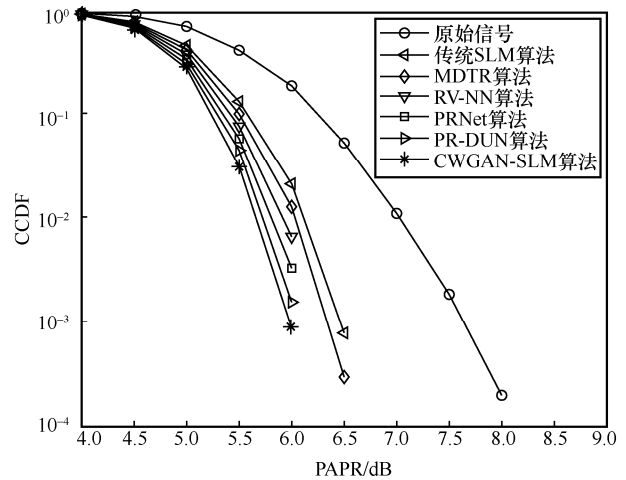


图 9 几种算法的 CCDF 性能曲线 ( $K=16$ )

图 10 为传统 SLM 算法<sup>[8]</sup>、TR-SLM 算法<sup>[10]</sup>与 CWGAN-SLM 算法在  $K$  分别为 8、16 时的 CCDF 性能曲线。由图 10 可知，CWGAN-SLM 算法相比于 TR-SLM 算法 PAPR 抑制性能略有提升。这是因为 CWGAN-SLM 算法所生成的时域备选信号具有比 TR-SLM 算法更好的多样性，并且 CWGAN-SLM 算法是在 MWOFFDM 系统的基础上抑制 PAPR，TR-SLM 算法则是在传统 OFDM 系统的基础上抑制 PAPR，MWOFFDM 具有比传统 OFDM 更低的 PAPR，因此 CWGAN-SLM 算法具有更好的 PAPR 抑制性能。此外，CWGAN-SLM 算法的 PAPR 随着  $K$  的增加而减小，当  $K$  比较小时，其 PAPR 降低幅度较大，然而随着  $K$  的增加，其峰均比降低幅度逐渐减小，与传统 SLM 算法一致。




图 10 传统 SLM 算法、TR-SLM 算法与 CWGAN-SLM 算法的 CCDF 曲线 (K 取不同值)

为了验证 CWGAN 性能优于传统 GAN 与 WGAN, 本文将 CWGAN-SLM 算法中的 CWGAN 分别替换为 GAN 与 WGAN, 通过对比实验证明所提 CWGAN 性能优于 GAN 和 WGAN。GAN 和 WGAN 的生成器和判别器模型与 CWGAN 基本一致, 具体的网络参数如表 3 所示。

表 3 GAN、WGAN 以及 CWGAN 具体的网络参数

仿真参数	GAN	WGAN	CWGAN
生成器卷积层个数	3	3	3
判别器卷积层个数	4	4	4
生成器激活函数	ReLU	ReLU	ReLU
判别器激活函数	LeakyReLU	LeakyReLU	LeakyReLU
判别器的最后一层	Sigmoid	—	Sigmoid
epoch	2 000	2 000	2 000
Batch_size	64	64	64
生成器学习率	0.000 1	0.000 1	0.000 1
判别器学习率	0.000 4	0.000 4	0.000 4
条件信息	无	无	有
优化算法	Adam	RMSProp	RMSProp

图 11 给出了  $K=16$  时 MWOFFDM 系统经过传统 SLM 算法、GAN-SLM 算法、WGAN-SLM 算法及 CWGAN-SLM 算法的 CCDF 性能曲线。由图 11 可以看出, CWGAN-SLM 算法降低 MWOFFDM 系统 PAPR 的能力明显优于 GAN-SLM 算法和 WGAN-SLM 算法。

图 12 为  $K=16$  时几种算法的系统误码率的性能对比。由图 12 可以看出, 传统 SLM 算法、GAN-SLM 算法、WGAN-SLM 算法及 CWGAN-SLM 算法的误码率曲线十分接近, 几乎没

有增加系统误码率, 其原因在于虽然 GAN 生成的信号与原始信号可能并不完全一致, 但是本文算法只是通过 CWGAN 生成具有低峰均比特性的信号波形, 而非生成新的信号, 因而没有带来信息传输错误的问题。




图 11 不同生成对抗网络算法的 CCDF 性能曲线 (K=16)




图 12 几种算法的系统误码率的性能对比 (K=16)

图 13 给出了 GAN-SLM 算法、WGAN-SLM 算法和 CWGAN-SLM 算法在 MWOFFDM 信号训练集上迭代不同次数时的损失函数变化情况。由图 13 可以看出, CWGAN-SLM 在迭代 300 次后损失函数值逐渐趋于稳定; WGAN-SLM 和 GAN-SLM 的收敛速度相对较慢, 分别在迭代 800 次和 1 500 次后损失函数值才逐渐趋于稳定。迭代次数是指整个训练集输入神经网络进行训练的次, 最优迭代次数越小, 则算法的时间复杂度越小, 因此, 与 GAN-SLM 算法和 WGAN-SLM 算法相比, CWGAN-SLM 算法具有收敛快、训练容易和时间复杂度低的优势。

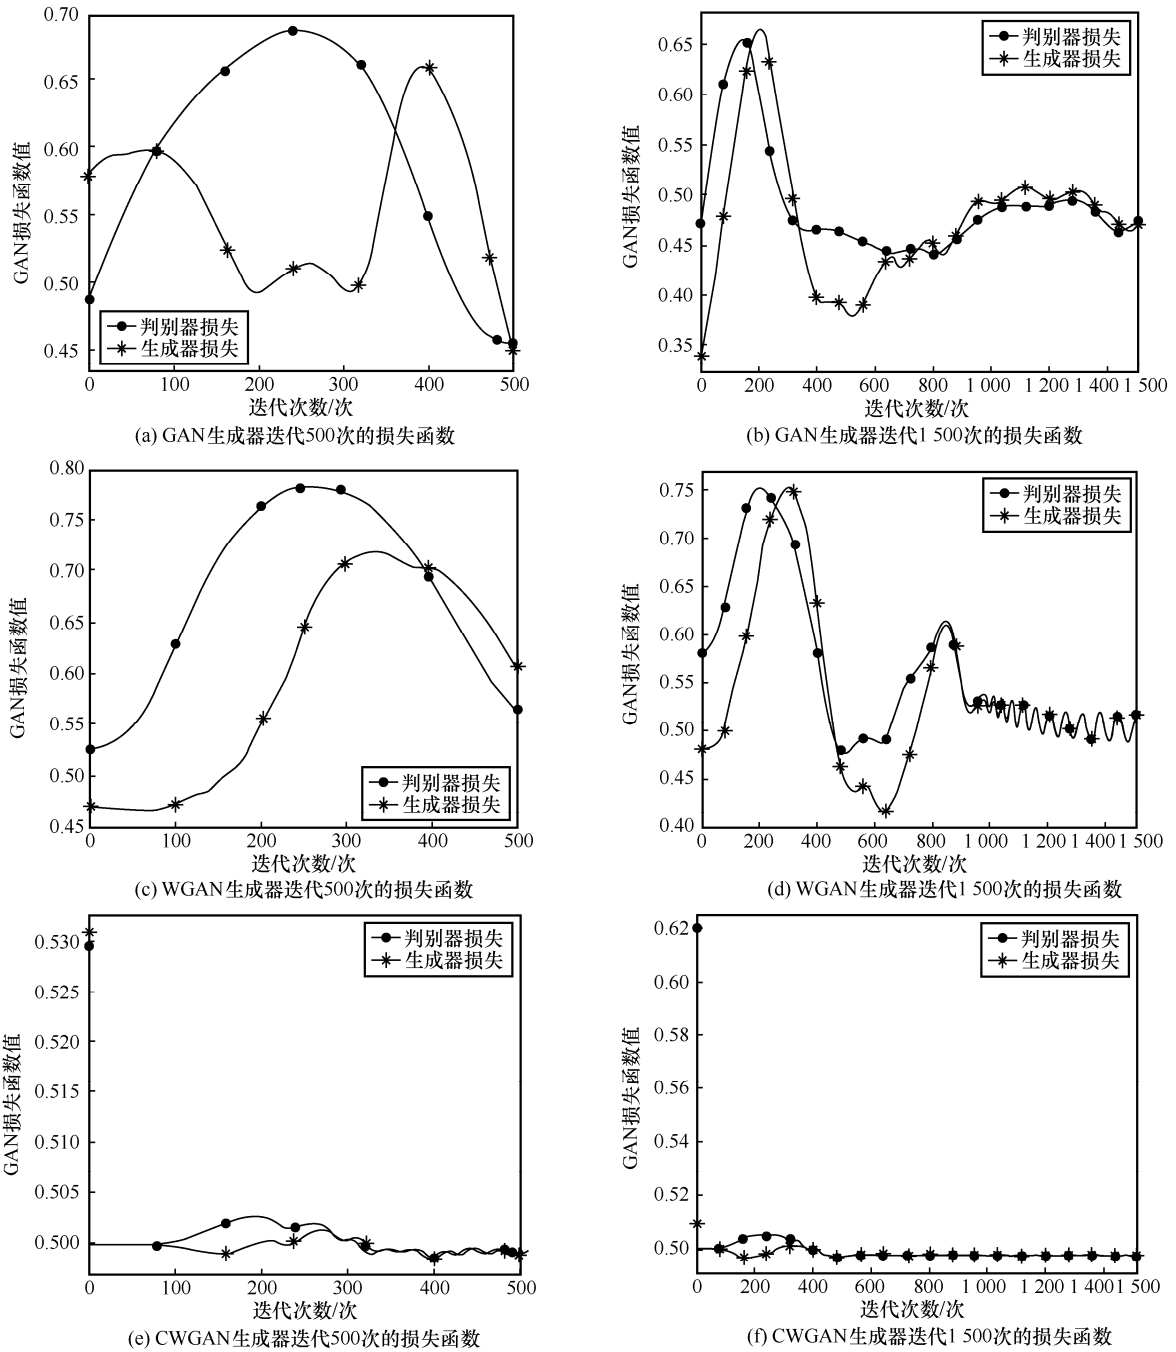


图 13 3 种算法在 MWOFFDM 信号训练集上迭代不同次数时的损失函数变化情况

### 3.3 运行时间分析

本节将不同算法的运行时间与平均运行时间进行对比, 如表 4 所示。由表 4 可知, 首先, CWGAN-SLM 算法速度明显快于传统 SLM 算法及 TR-SLM 算法, 其原因在于 CWGAN-SLM 算法虽然需要模型训练及迭代操作, 但是 CWGAN 的构建较简单, 容易训练, 且迭代 300 次便可收敛, 此外, CWGAN-SLM 算法整个过程仅需一个 IMWPT 模块, 而传统 SLM 算法及 TR-SLM 算法则需要进行

多次 IFFT 运算, 因而运行时间较高; 其次, 基于深度学习的 PAPR 抑制算法中, CWGAN-SLM 算法运行速度略慢于 MDTR、PRNet、PR-DUN、RV-NN, 这主要是因为 CWGAN-SLM 算法需要额外进行 PAPR 比较操作, 并且每组 IMWPT 都需要重新训练系数, 导致系统吞吐率有所提升, 在一定程度上增加了系统的运行时间, 而 CWGAN-SLM 算法的 PAPR 抑制性能优于其余深度学习算法, 因此, CWGAN-SLM 算法增加少量计算复杂度是可以接

表4 不同算法的运行时间与平均运行时间

算法	第1次/s	第2次/s	第3次/s	平均运行时间/s
传统 SLM	1.105	0.998	1.058	1.053
TR-SLM	4.194	4.007	4.138	4.113
MDTR	0.421	0.406	0.415	0.414
PRNet	0.298	0.314	0.308	0.306
RV-NN	0.407	0.397	0.385	0.396
PR-DUN	0.357	0.367	0.368	0.364
GAN-SLM	1.525	1.687	1.592	1.601
WGAN-SLM	0.781	0.826	0.759	0.789
CWGAN-SLM	0.476	0.435	0.461	0.457

受的。最后, CWGAN-SLM 算法运行速度明显快于 WGAN-SLM 算法和 GAN-SLM 算法, 这是因为 CWGAN 的收敛速度明显快于 WGAN 和 GAN。

#### 4 结束语

本文提出了一种基于选择映射算法和生成对抗网络相结合的多小波 OFDM 峰均比抑制算法。该算法通过构建 CWGAN 生成  $K$  个独立统计且传输相同信息的 MWOFFDM 信号, 并从中选择 PAPR 最小的一个进行传输, 以达到降低 PAPR 的目的。仿真结果表明, 本文提出的算法可以在有效降低 MWOFFDM 信号 PAPR 的同时, 确保较低的误码率和计算复杂度。例如, CWGAN-SLM 算法在  $K=16$ 、CCDF= $1.0 \times 10^{-4}$  时, 对应的 PAPR 大约为 6.3 dB。与传统 SLM 算法相比, PAPR 降低了大约 0.5 dB, 运行时间低于传统 SLM 算法, 误码率基本保持不变。

#### 参考文献:

[1] 赵亚军, 郁光辉, 徐汉青. 6G 移动通信网络: 愿景、挑战与关键技术[J]. 中国科学: 信息科学, 2019, 49(8): 963-987.  
ZHAO Y J, YU G H, XU H Q. 6G mobile communication networks: vision, challenges, and key technologies[J]. Scientia Sinica (Informationis), 2019, 49(8): 963-987.

[2] 王悦, 王权, 张德鹏, 等. 低轨卫星通信系统与 5G 通信融合的应用设想[J]. 卫星应用, 2019(1): 54-59.  
WANG Y, WANG Q, ZHANG D P, et al. Application assumption of fusion of LEO satellite communication system and 5G communication[J]. Satellite Application, 2019(1): 54-59.

[3] CUI X, LIU K, LIU Y. Novel linear companding transform design based on linear curve fitting for PAPR reduction in OFDM systems[J].

IEEE Communications Letters, 2021, 25(11): 3604-3608.

[4] SONG H J, LEE N. Terahertz communications: Challenges in the next decade[J]. IEEE Transactions on Terahertz Science and Technology, 2021, 12(2): 105-117.

[5] ZHANG Y, WANG Z, HUANG Y, et al. A digital signal recovery technique using DNNs for LEO satellite communication systems[J]. IEEE Transactions on Industrial Electronics, 2020, 68(7): 6141-6151.

[6] XING Z T, LIU K M, TANG B H, et al. Novel PAPR reduction scheme based on piecewise nonlinear companding transform in OFDM systems[J]. IEEE Communications Letters, 2020, 24(8): 1757-1761.

[7] SGHAIER M, ABDELKEFI F, SIALA M. Efficient embedded signaling through Alamouti STBC precoders in MIMO-OFDM systems[C]//Proceedings of 2013 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2013: 4053-4058.

[8] FATHY S A, EL-MAHALLAWY M S, HAGRAS E A A. C8. SLM technique based on particle swarm optimization algorithm for PAPR reduction in wavelet-OFDM systems[C]//Proceedings of 2015 32nd National Radio Science Conference (NRSC). Piscataway: IEEE Press, 2015: 163-170.

[9] LEE K S, CHO Y J, WOO J Y, et al. Low-complexity PTS schemes using OFDM signal rotation and pre-exclusion of phase rotating vectors[J]. IET Communications, 2016, 10(5): 540-547.

[10] 季策, 祝雯靖, 魏颖, 等. 降低 OFDM 系统 PAPR 的改进 SLM 算法[J]. 通信学报, 2018, 39(4): 152-158.  
JI C, ZHU W J, WEI Y, et al. Improved SLM algorithm for PAPR reduction in OFDM system[J]. Journal on Communications, 2018, 39(4): 152-158.

[11] WANG X, JIN N D, WEI J D. A model-driven DL algorithm for PAPR reduction in OFDM system[J]. IEEE Communications Letters, 2021, 25(7): 2270-2274.

[12] KIM M, LEE W, CHO D H. A novel PAPR reduction scheme for OFDM system based on deep learning[J]. IEEE Communications Let-

- ters, 2018, 22(3): 510-513.
- [13] LIU Z J, HU X, HAN K, et al. Low-complexity PAPR reduction method for OFDM systems based on real-valued neural networks[J]. IEEE Wireless Communications Letters, 2020, 9(11): 1840-1844.
- [14] NGUYEN M T, KADDOUM G, SELIM B, et al. Deep unfolding network for PAPR reduction in multicarrier OFDM systems[J]. IEEE Communications Letters, 2022, 26(11): 2616-2620.
- [15] SAROWA S, KUMAR N, AGRAWAL S, et al. Evolution of PAPR reduction techniques: a wavelet based OFDM approach[J]. Wireless Personal Communications, 2020, 115(2): 1565-1588.
- [16] ALMUTAIRI A F, KRISHNA A. Filtered-orthogonal wavelet division multiplexing (F-OWDM) technique for 5G and beyond communication systems[J]. Scientific Reports, 2022, 12: 4607.
- [17] SUHARTOMO A, VINCENT V. Comparison of BER performance for M-ary QAM and PSK on DWT-based OFDM system with PTS technique through AWGN channel[C]//Proceedings of 2020 IEEE International Conference on Sustainable Engineering and Creative Computing (ICSECC). Piscataway: IEEE Press, 2020: 5-10.
- [18] YAN X H, LI J, WU Z Y. 5G new radio with orthogonal multi-wavelet packet division multiplexing[C]//Proceedings of 2022 IEEE 2nd International Conference on Electronic Technology, Communication and Information (ICETCI). Piscataway: IEEE Press, 2022: 996-1002.
- [19] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems. New York: ACM Press, 2014: 2672-2680.
- [20] LI Y, CUI W G, GUO Y Z, et al. Time-varying system identification

using an ultra-orthogonal forward regression and multiwavelet basis functions with applications to EEG[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(7): 2960-2972.

- [21] KOLEV V, COOKLEV T, KEINERT F. Design of a simple orthogonal multiwavelet filter by matrix spectral factorization[J]. Circuits, Systems, and Signal Processing, 2020, 39(4): 2006-2041.

#### [作者简介]



杨光（1977-），女，陕西西安人，博士，西安邮电大学副教授、硕士生导师，主要研究方向为无线网络传输技术、卫星通信、网络协议设计等。

吴朝阳（1998-），男，陕西扶风人，西安邮电大学硕士生，主要研究方向为 OFDM 关键技术和生成对抗网络。

聂敏（1964-），男，陕西乾县人，博士，西安邮电大学教授、硕士生导师，主要研究方向为无线通信、量子信息处理等。

闫晓红（1974-），男，陕西乾县人，博士，西安邮电大学副教授，主要研究方向为多小波理论应用、扩频通信等。

江帆（1982-），女，江苏盐城人，博士，西安邮电大学教授、硕士生导师，主要研究方向为无线资源管理、D2D 通信技术边缘计算及缓存技术等。