

联合深度学习与FDSS的抑制PAPR研究

张金灿, 杨鸿文

北京邮电大学信息与通信工程学院, 北京

收稿日期: 2024年7月11日; 录用日期: 2024年8月7日; 发布日期: 2024年8月15日

摘要

OFDM是5G物理层关键技术之一, 其缺点是PAPR过高, 容易导致功放效率下降并造成信号失真。如何抑制OFDM信号的PAPR对低功耗的物联网终端来说是一个重要问题。本文提出了一种联合深度学习与FDSS的抑制PAPR算法。仿真结果表明, 所提算法对于多种调制方式及子载波个数配置均有很好的PAPR抑制效果。在峰值功率受限的条件下, 采用所提算法能使信道的传输增益提升6 dB左右。

关键词

峰均功率比, 深度学习, 频域赋形

Inhibition of PAPR by Combining Deep Learning and FDSS

Jincan Zhang, Hongwen Yang

School of Information and Telecommunication Engineering, Beijing University of Posts and Telecommunications, Beijing

Received: Jul. 11th, 2024; accepted: Aug. 7th, 2024; published: Aug. 15th, 2024

Abstract

OFDM, one of the key techniques of the 5G physical layer, has the disadvantage of excessively high PAPR. The excessively high PAPR will lead to a decrease in power amplifier efficiency and cause signal distortion. How to suppress the PAPR of OFDM signals is an important problem for low-power Internet of Things terminals. This paper proposes a joint method combining deep learning and FDSS for PAPR suppression based on the PAPR suppression scheme of FDSS, and conducts simulation verification. The results show that the proposed joint method achieves excellent PAPR suppression performance in different modulation scenarios and different subcarrier numbers. Under the condition of peak power constraint, the proposed joint method can improve

the transmission gain of the channel by about 6 dB.

Keywords

PAPR, Deep Learning, FDSS

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)是第五代移动通信技术(5th generation, 5G)中物理层的关键技术之一。与单载波系统相比, OFDM 有峰均功率比(Peak Average Power Ratio, PAPR)过高的缺点, 过高的 PAPR 将导致功放效率下降并造成信号失真, 影响无线覆盖, 特别是上行覆盖。因此, 如何抑制 OFDM 信号的 PAPR 是一个长期以来备受关注的课题[1] [2]。

降低 OFDM 系统 PAPR 的传统方法主要有信号预畸变法、概率类和编码类等算法[3]。信号预畸变有低实现复杂度的优势, 但信号畸变会使系统性能下降。概率类算法和编码类算法一般会降低频谱效率, 且计算复杂度较高[4]。此外, 这两类算法不能直接兼容 5G 标准。频域赋形(Frequency Domain Spectral Shaping, FDSS)技术是近年来受到关注的技术[2], 这种技术能够以较低的计算复杂度, 在不改变链路设计的前提下降低 OFDM 的 PAPR, 达到上行增强、提升覆盖、降低终端功耗等目的[5]。FDSS 算法的性能与其使用的窗函数设计密切相关。较常用的根升余弦(Root Raised Cosine, RRC)窗函数可调整参数只有滚降系数 α (决定过渡带的形状)和截断系数 β (过渡带向中心的偏移), 所实现的窗函数形状受限, 使其难以达到更好的效果[2] [6]。为此, 本文考虑结合深度学习技术直接优化 FDSS 的窗函数, 以获得更好的性能。

深度学习已经越来越多地应用于通信物理层, 在 PAPR 抑制方面也已经有很多基于深度学习的方法[7]-[10]。例如文献[9]提出了一种通过 TT-RDNN 的技术来降低 PAPR, 能保证频谱效率并能最大限度地减少带内失真。文献[10]研究了使用神经网络(Neural Network, NN)的方法, 其研究表明 NN 能使 GFDM (Generalized Frequency Division Multiplexing)系统的 PAPR 和误块率(Block Error Rate, BLER)大大降低。目前, 结合 FDSS 与深度学习的研究还比较少见。本文提出了一种联合深度学习中神经网络与 FDSS 的方式来优化窗函数, 以实现 PAPR 抑制的目的。仿真证明, 所提联合算法能有效抑制 OFDM 系统的 PAPR。

2. 联合算法设计

2.1. FDSS

频域赋形技术是将频域信号乘以频谱赋形窗函数, 通过修正频谱来影响时域波形, 从而达到降低 PAPR 的目的。令 OFDM 系统中的频域数据为 $\mathbf{X} = (X_0, X_1, \dots, X_{K-1})^T$, 其中 K 为 OFDM 系统的子载波数。令 $\mathbf{W} = (W_0, W_1, \dots, W_{K-1})^T$ 表示各个子载波处的频域赋形权值, 则采用 FDSS 后不考虑循环前缀的 OFDM 时域信号为

$$\mathbf{y} = \mathbb{F}^\dagger [\mathbf{W} \odot \mathbf{X}] \quad (1)$$

其中 $\mathbf{y} = (y_0, y_1, \dots, y_{K-1})^T$, \mathbb{F}^\dagger 表示逆离散傅立叶变换(Inverse Discrete Fourier Transform, IDFT)矩阵, \odot 表示两个向量逐元素点乘(哈达玛乘积)。此时, OFDM 时域发送信号的 PAPR 为

$$\text{PAPR} = \frac{\|\mathbf{y}\|_{\infty}^2}{\|\mathbf{y}\|_2^2} \quad (2)$$

其中 $\|\cdot\|_2$ 表示平方范数, $\|\cdot\|_{\infty}$ 表示无穷范数, 也即 $\max_k \{|y_k|^2\}$ 。受功率放大器非线性的影响, 给定发送峰值功率时, 功放必须进行回退以避免落入非线性区。此时平均功率明显低于峰值功率。PAPR 越大, 回退越大, 导致链路预算下降, 链路损失加大。

式(2)右边是 \mathbf{W} 的函数, \mathbf{W} 不同则 PAPR 也不同。因此, 针对 PAPR 抑制的最优问题可以表示为

$$\mathbf{W}^* = \arg \min_{\mathbf{w}} \left\{ \frac{\|\mathbf{y}\|_{\infty}^2}{\|\mathbf{y}\|_2^2} \right\} \quad (3)$$

上式的最优解一般难以给出闭式表达。传统 FDSS 给出的是一种次优解, 例如采用根升余弦频谱, 通过调节少量参数来优化 PAPR。

2.2. 联合算法

本文提出了如图 1 所示的方法, 借助人工智能神经网络来优化赋形向量。

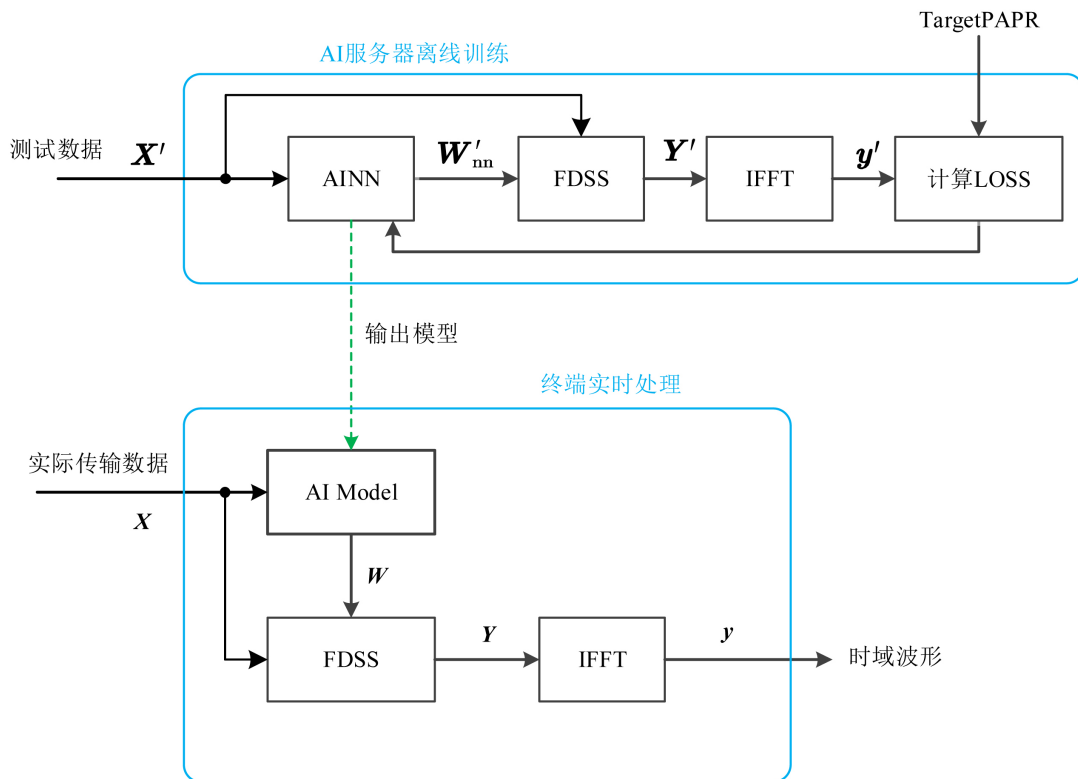


Figure 1. Real-time processing flow diagram

图 1. 实时处理流程框图

图 1 包括两部分。一部分是用 AI 服务器训练模型, 其输入是频域测试数据 \mathbf{X}' 。 \mathbf{X}' 送入位于 AI 服务器的人工智能神经网络(Artificial Intelligence Neural Network, AINN), 经过网络正向运算得到输出 \mathbf{W}'_{nn} 。用 \mathbf{W}'_{nn} 进行 FDSS, 得到

$$\mathbf{Y}' = \mathbf{W}'_{nn} \odot \mathbf{X}' \quad (4)$$

将频域向量 \mathbf{Y}' 转换到时域成为 $\mathbf{y}' = \mathbf{F}^T \mathbf{Y}'$ 。用 \mathbf{y}' 的 PAPR 来计算 LOSS 值。计算 LOSS 时的输入还有来 PAPR 目标值 TargetPAPR, 以防止窗函数收敛到全零。PAPR 目标值可根据功放的具体情况设定。LOSS 定义为

$$\text{LOSS} = \text{AVG}[\text{PAPR}(\mathbf{y}')] - \text{TargetPAPR} \quad (5)$$

其中 AVG 表示求平均。上式中的 $\text{PAPR}(\mathbf{y}')$ 是 \mathbf{y}' 的 PAPR。注意上式中的 LOSS 值是分贝值, $\text{AVG}[\text{PAPR}(\mathbf{y}')]$ 是平均 PAPR 的分贝值, TargetPAPR 是目标 PAPR 的分贝值。

生成的 LOSS 值通过反向传播送入 AINN 进行迭代运算, 对网络进行训练。训练完成的网络模型 AINN 根据一定的触发机制(周期触发或者事件触发)送入位于终端侧的数字处理单元作为 AI Model 参与运算。

数字处理单元以实时方式运行, 其输入是实际要传输的 OFDM 频域符号向量 \mathbf{X} 。 \mathbf{X} 经过网络(AI Model)运算, 生成 \mathbf{W} , 然后进行 FDSS、IFFT 等计算得到输出时域信号 \mathbf{y} 。

图 2 是 AINN 网络分析图。模型内部共分为三层, 每层均由一个全连接层和一个 RELU 激活函数构成。层数可以根据需求增加, 只要保证输入输出所需要的维度不变即可。

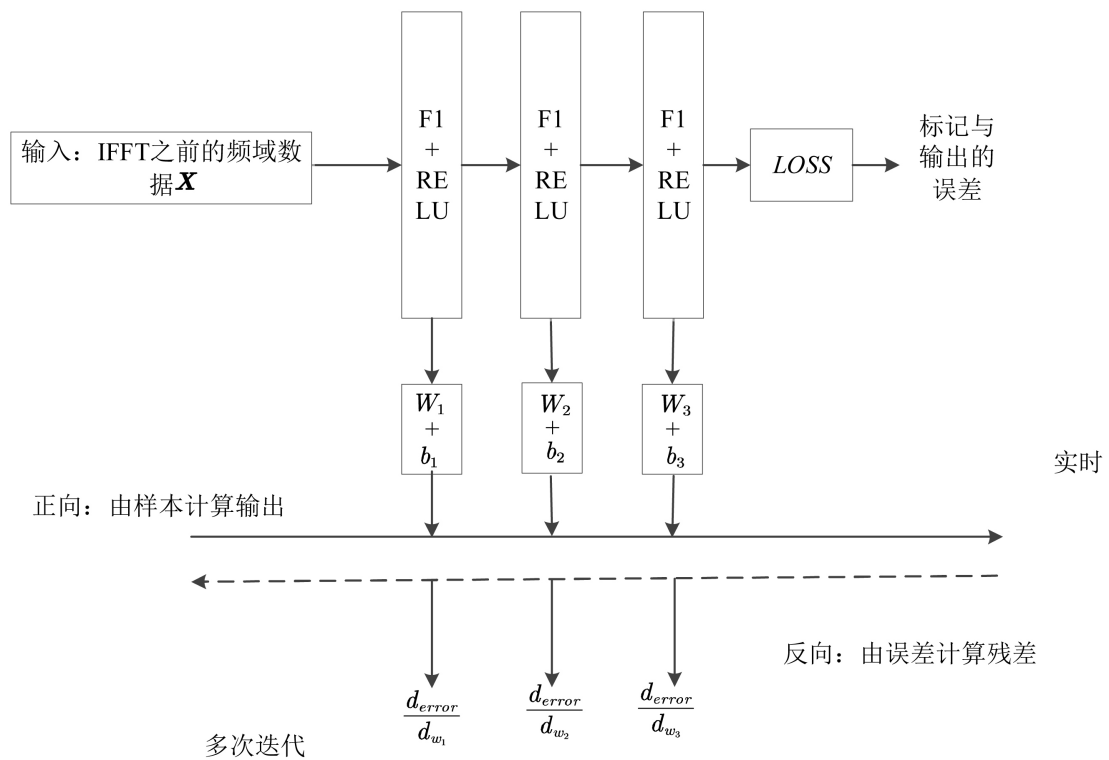


Figure 2. AINN network analysis diagram

图 2. AINN 网络分析图

AINN 本质是卷积神经网络(Convolutional Neural Network, CNN)。AINN 网络是一种“端到端”的学习范式, 整个学习流程完全交给神经网络模型进行学习, 从原始数据到期望输出的映射, 整个训练和预测过程都是在 AINN 中完成。

AINN 网络分为四个步骤, 与 CNN 网络训练相同。具体包括如下步骤:

1) 数据预处理

IFFT 之前的频域数据 \mathbf{X} 是复数形式, 需要转化为实数进行处理。因此, 将 \mathbf{X} 的实部与虚部提取,

并以一定的格式重新排列。

2) 网络层处理

学习率设置为 0.01, epoch 设置为 1000。网络分为五个部分, 每一部分由一个全连接层和一个激活函数组成, \mathbf{W}'_m 用来表示网络的输出。

3) 反向传播

损失函数的设计是整个网络的关键部分, 其定义见公式(5)。为了防止窗函数收敛为零, 这里的 PAPR 目标值设定为 6 dB。

4) 使用测试集来验证

3. 仿真结果

本节通过仿真来验证所提方法, 并与传统 FDSS 方法进行对比。传统 FDSS 采用 T-RRC 窗函数。图 3 是示出了不同方法窗函数图形。图例中 T-RRC 的两个参数 α/β 分别是滚降系数和截断系数。




Figure 3. Window function waveform comparison

图 3. 窗函数波形对比

图 4 所示为 PAPR 性能对比。图中的仿真条件为: 子载波数为 512, 调制方式为 16QAM。从图中可以看出, 所提 AINN 网络联合 FDSS 的算法在抑制 PAPR 方面显著优于传统 FDSS 方法。在 CCDF 等于 10^{-3} 时, 所提方法较无抑制情况有约 6 dB 的性能改善, 与传统 FDSS 方法相比有约 1 dB 改善。当终端功率放的饱和功率受限时, 为了避免信号失真, 必须采用功率回退。PAPR 越大, 功率回退也越大。因此, 图 4 中的 PAPR 改善量基本相对于链路预算的改善量。

图 5 和图 6 分别给出了 512 子载波下, QPSK 和 256QAM 调制的 PAPR 性能对比。可以看出, 调制阶数越高, 所提方法的增益越大。在 CCDF 等于 10^{-3} 时, 所提方法对于 QPSK 调制的 PAPR 改善量约为 5.6 dB, 对于 256QAM 调制的 PAPR 改善量基本与 16QAM 相当。另外可以注意到, 如果功放削峰的概率可以放宽一些, 例如在 CCDF 为 0.01 处, 所提方法的性能增益比传统 FDSS 更大。




Figure 4. PAPR performance under 16-QAM modulation
图 4. 16-QAM 调制下的 PAPR 性能




Figure 5. PAPR performance under QPSK modulation
图 5. QPSK 调制下的 PAPR 性能




Figure 6. PAPR performance under 256-QAM modulation

图 6. 256-QAM 调制下的 PAPR 性能

图 7 和图 8 分别示出了 256QAM 调制下, 子载波个数为 1272 和 3276 时的 PAPR 抑制性能。结果标明子载波数对所提方法的性能影响不大。




Figure 7. PAPR performance under 1272 subcarriers

图 7. 1272 个子载波的 PAPR 性能




Figure 8. PAPR performance under 3276 subcarriers
图 8. 3276 个子载波的 PAPR 性能

4. 结论

为了降低 OFDM 系统的 PAPR, 改善上行覆盖, 本文提出了一种结合深度学习与 FDSS 的 PAPR 抑制方法。仿真表明, 所提联合算法具有良好的 PAPR 抑制表现, 当 CCDF 等于 10^{-3} 的时候, 联合算法较无抑制情况可以有 6 dB 的链路级增益, 且性能增益对调制阶数及子载波数基本不敏感。

参考文献

- [1] Nasarre, I.P., Levanen, T., Pajukoski, K., Lehti, A., Tirola, E. and Valkama, M. (2021) Enhanced Uplink Coverage for 5G NR: Frequency-Domain Spectral Shaping with Spectral Extension. *IEEE Open Journal of the Communications Society*, **2**, 1188-1204. <https://doi.org/10.1109/ojcoms.2021.3082688>
- [2] 段向阳, 辛雨, 暴桐, 等. 一种高频场景候选波形方案[J]. 电子与信息学报, 2021, 43(1): 60-67.
- [3] 黄梦佳. OFDM 系统中基于预畸变技术的峰均比抑制方案的研究[D]: [硕士学位论文]. 北京: 北京邮电大学, 2019.
- [4] 韩东升, 杨维, 刘薇. 一种改进的限幅滤波降低 PAPR 算法[J]. 北京邮电大学学报, 2014, 37(4): 44-48.
- [5] Chen, L., Pan, J., Zhang, J., Cheng, J., Xu, L. and Ye, N. (2023) FDSS-Based DFT-S-OFDM for 6G Wireless Sensing. *Sensors*, **23**, Article No. 1495. <https://doi.org/10.3390/s23031495>
- [6] Sahin, A., Hosseini, N., Jamal, H., Hoque, S.S.M. and Matolak, D.W. (2021) DFT-Spread-OFDM-Based Chirp Transmission. *IEEE Communications Letters*, **25**, 902-906. <https://doi.org/10.1109/lcomm.2020.3039222>
- [7] da Silva, B.S.d.C., Souto, V.D.P., Souza, R.D. and Mendes, L.L. (2024) A Survey of PAPR Techniques Based on Machine Learning. *Sensors*, **24**, Article No. 1918. <https://doi.org/10.3390/s24061918>
- [8] Wang, X., Jin, N. and Wei, J. (2021) A Model-Driven DL Algorithm for PAPR Reduction in OFDM System. *IEEE Communications Letters*, **25**, 2270-2274. <https://doi.org/10.1109/lcomm.2021.3076605>
- [9] Omar, M.S., Qi, J. and Ma, X. (2023) Mitigating Clipping Distortion in Multicarrier Transmissions Using Tensor-Train Deep Neural Networks. *IEEE Transactions on Wireless Communications*, **22**, 2127-2138. <https://doi.org/10.1109/twc.2022.3209188>

- [10] Chakravarty, S. and Kumar, A. (2023) PAPR Reduction of GFDM Signals Using Encoder-Decoder Neural Network (Autoencoder). *National Academy Science Letters*, **46**, 213-217. <https://doi.org/10.1007/s40009-023-01230-1>