

基于深度学习的非扩跳频通信体制窄带干扰抑制技术



马松^{1,2}, 王家豪³, 张蔺^{1*}, 王军¹

(1. 电子科技大学通信抗干扰全国重点实验室, 成都 611731; 2. 中国西南电子技术研究所, 成都 610036;

3. 电子科技大学(深圳)高等研究院, 深圳 518110)

摘要 复杂环境下的无线业务在近年来呈现数据密集化发展趋势, 对无线通信系统的数据传输能力和干扰对抗能力都提出了更高的要求。现有扩跳频通信体制通过牺牲时频资源利用率换取干扰对抗能力, 难以满足复杂环境下的高速数据传输需求。为此, 提出了一种基于深度学习的非扩跳频通信体制窄带干扰抑制技术, 在非扩跳频通信体制基础上, 在接收端级联频域陷波模块和深度神经网络模块有效抑制窄带干扰, 同时提升数据传输速率和干扰抑制能力。其中, 深度神经网络用于从频域陷波后的失真信号中重构真实信号。实验结果表明, 与传统频域陷波算法相比, 所提出的算法具有更低的误码率, 训练好的深度神经网络能够泛化到不同信号强度、干扰强度、干扰频段、干扰波形等场景。

关键词 深度学习; 泛化能力; 窄带干扰抑制; 非扩跳频通信

中图分类号 TN97 文献标志码 A DOI 10.12178/1001-0548.2024016

Deep Learning Based Narrowband Interference Suppression Technique in Non-Spread-Hopping Spectrum Communication System

MA Song^{1,2}, WANG Jiahao³, ZHANG Lin^{1*}, and WANG Jun¹

(1. National Key Laboratory of Wireless Communications, University of Electronic Science and Technology of China, Chengdu 611731, China;

2. Southwest China Institute of Electronic Technology, Chengdu 610036, China;

3. Shenzhen Institute for Advanced Study, University of Electronic Science and Technology of China, Shenzhen 518110, China)

Abstract The wireless service in complex environment shows the trend of data intensive development in recent years, which puts forward higher requirements for the data transmission capability and interference countermeasure capability of wireless communication systems. The existing spread spectrum and frequency hopping communication systems achieve interference countermeasure capability by sacrificing time-frequency resource utilization, but can not meet the demand of high-speed data transmission in complex environment. Therefore, this paper proposes a deep learning based narrowband interference suppression technology of non-spread-hopping spectrum communication system. On the basis of non-spread-hopping spectrum communication system, the frequency-domain notch filtering module and deep neural network module are cascaded at the receiver end to effectively suppress narrowband interference, improving data transmission rate and interference suppression ability at the same time. In particular, the deep neural network is used to reconstruct the expected signal from the distorted signal by the frequency-domain notch filtering module. The experimental results show that the proposed algorithm has a lower bit error rate than the traditional frequency-domain notch filtering algorithms, and the well-trained deep neural network can generalize to the scenarios with differences of signal power, interference power, interference frequency band, interference waveform, etc.

Key words deep learning; generalization ability; narrowband interference suppression; non-spread-hopping spectrum communication

复杂环境下的无线业务呈现数据密集化发展趋势, 对无线通信系统的抗干扰能力和数据传输能力都提出了更高要求, 如星地高速数传链路在受到非

合作方恶意干扰时容易发生中断甚至难以正常工作^[1-2]。因此, 亟须研究能同时提升干扰抑制能力和数据传输能力的新型通信技术。

收稿日期: 2024-01-06; 修回日期: 2024-03-20

基金项目: 电子科技大学通信抗干扰全国重点实验室基础科研创新基金 (IFN20230102)

作者简介: 马松, 博士研究生, 高级工程师, 主要从事飞行器测控通信、人工智能等方面的研究。

*通信作者 E-mail: linzhang1913@uestc.edu.cn

扩跳频技术被广泛应用于无线通信系统中的干扰躲避和抑制^[3-5]。扩频码越长、跳频图案越大, 扩跳频技术需要的时频资源越多, 抗干扰能力越强。在时频资源受限的通信场景中, 基于扩跳频技术的无线通信系统的抗干扰能力和数据传输能力存在显著的跷跷板效应: 抗干扰能力越强, 数据传输能力越弱。

文献[6]总结了新一代通信抗干扰系统的重要发展方向——智能抗干扰通信技术。该技术体制根据电磁干扰环境自适应地选择最佳抗干扰方式, 实现高效可靠的抗干扰通信。随着深度学习技术在计算机科学领域的快速发展与多场景的成功应用^[7], 全球电子信息科学家与工程师开始研究基于深度学习的智能抗干扰通信关键技术, 如干扰认知^[8-11]、抗干扰决策^[12-15]等。然而, 复杂环境下的干扰往往呈现快速时变特性, 现有智能抗干扰方法面临着抗干扰决策滞后和策略难收敛等问题^[16]。同时, 现有智能抗干扰技术往往需要在收发双方之间建立可靠的信息交互链路进行抗干扰策略协同, 在强干扰环境下, 难以维护用于协同收发双方抗干扰策略的可靠链路。

综上所述, 现有扩跳频技术难以同时有效提升无线通信系统干扰抑制能力与数据传输能力, 而智能抗干扰通信技术也面临着严峻的挑战, 亟须探索更智能的干扰抑制策略。为此, 本文研究基于深度学习的非扩跳频通信体制窄带干扰抑制技术, 通过利用非扩跳频通信体制并在接收端级联频域陷波模块和深度神经网络模块, 同时提升无线通信系统抗干扰能力和数据传输能力。其中, 非扩跳频通信体制保证数据的高速传输, 频域陷波模块用于滤除大部分干扰, 深度神经网络模块用于滤除残余干扰并重构频域陷波后的失真信号。该方案具有较高的时频资源利用率, 且不需要收发端进行抗干扰策略协同。

1 信号模型

将接收机接收到的单载波数字信号表示为:

$$\mathbf{y} = [y_0, y_1, \dots, y_{N-1}]^T = \mathbf{h} * \mathbf{s} + \mathbf{n} + \mathbf{j} \quad (1)$$

式中, $\mathbf{s} = [s_0, s_1, \dots, s_{N-1}]^T$ 为期望信号, 占用基带

频段 $[f_L, f_H]$; $\mathbf{h} = [h_0, h_1, \dots, h_{N-1}]^T$ 为信道响应; \mathbf{n} 为均值为0、方差为 σ^2 的热噪声; \mathbf{j} 为窄带干扰, 占用基带频段 $[f_L, f_H]$ 。

对接收信号做 N 点离散傅里叶变换 (Discrete Fourier Transform, DFT) 得到频域信号:

$$\mathbf{Y} = [Y_0, Y_1, \dots, Y_{N-1}]^T = \mathbf{P}\mathbf{y} \quad (2)$$

式中, \mathbf{P} 为DFT变换矩阵, 表示为:

$$\mathbf{P} = \begin{bmatrix} P_{00} & P_{01} & \dots & P_{0(N-1)} \\ P_{10} & P_{11} & & P_{1(N-1)} \\ \vdots & \vdots & \ddots & \vdots \\ P_{(N-1)0} & P_{(N-1)1} & \dots & P_{(N-1)(N-1)} \end{bmatrix} = \begin{bmatrix} W_N^{0 \times 0} & W_N^{0 \times 1} & \dots & W_N^{0 \times (N-1)} \\ W_N^{1 \times 0} & W_N^{1 \times 1} & & W_N^{1 \times (N-1)} \\ \vdots & \vdots & \ddots & \vdots \\ W_N^{(N-1) \times 0} & W_N^{(N-1) \times 1} & \dots & W_N^{(N-1) \times (N-1)} \end{bmatrix} \quad (3)$$

式中, $W_N = e^{-j2\pi/N}$ 。

同理, 窄带干扰的频域表示为:

$$\mathbf{J} = [J_0, J_1, \dots, J_{N-1}]^T = \mathbf{P}\mathbf{j} \quad (4)$$

式中, 当 $a \leq k \leq b$ 时, J_k 不为0, 否则 $J_k = 0$ 。

2 基于深度学习的窄带干扰抑制算法

2.1 基本思路

本文抑制窄带干扰的思路如图1所示。考虑到不同干扰强度和波形对接收信号的影响差异大, 本文首先采用频域陷波的方法滤除大部分干扰。但是, 频域陷波在滤除干扰的同时也会滤除部分期望信号, 影响期望信号的接收性能。考虑到真实期望信号与频域陷波后的失真期望信号之间存在相关性, 本文将根据频域陷波后的失真期望信号重构真实期望信号。鉴于深度神经网络, 特别是深度卷积神经网络, 具有强大的特征提取与表征能力^[7], 本文将利用深度神经网络来表征频域陷波后的失真期望信号与真实期望信号之间的映射关系, 从而实现窄带干扰的滤除和期望信号的重构。

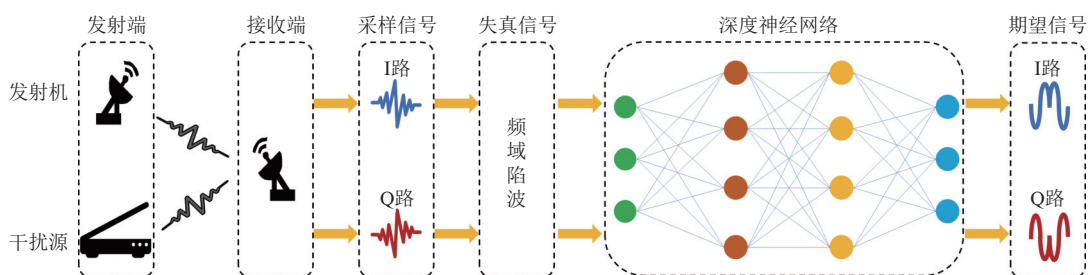


图1 基于深度学习的窄带干扰抑制思路

2.2 基于频域陷波的窄带干扰滤除

经过频域陷波后的失真期望信号在频域上可以表示为:

$$\hat{Y} = [Y_0, \dots, Y_{a-1}, 0, \dots, 0, Y_{b+1}, \dots, Y_{N-1}]^T \quad (5)$$

对 \hat{Y} 做离散傅里叶反变换 (Inverse Discrete Fourier Transform, IDFT) 得到陷波后的接收时域信号为:

$$\hat{y} = [\hat{y}_0, \hat{y}_1, \dots, \hat{y}_{N-1}]^T = \frac{1}{N} \mathbf{P}^\dagger \hat{Y} \quad (6)$$

式中, 上标“ \dagger ”表示共轭运算。

接着, 利用信道估计和均衡技术, 消除掉信道对信号的影响。如果考虑理想信道估计和均衡, 那么可以得到失真期望信号的时域表达为:

$$\hat{s} = [\hat{s}_0, \hat{s}_1, \dots, \hat{s}_{N-1}]^T = \frac{1}{N} \mathbf{P}^\dagger \hat{S} \quad (7)$$

式中, \hat{S} 为失真期望信号的频域表达, 并且与 \hat{Y} 具有相同的结构, 表示为:

$$\hat{S} = [S_0, \dots, S_{a-1}, 0, \dots, 0, S_{b+1}, \dots, S_{N-1}]^T \quad (8)$$

2.3 基于生成式对抗网络的期望信号重构

鉴于生成式对抗网络具有高精度的信号生成能力^[17-19], 本文采用生成式对抗网络架构设计重构真实期望信号的深度神经网络。与现有生成式对抗网络的输入为随机噪声不同^[20-21], 本文设计的深度神经网络输入为频域陷波后的失真期望信号, 如图 2 所示。

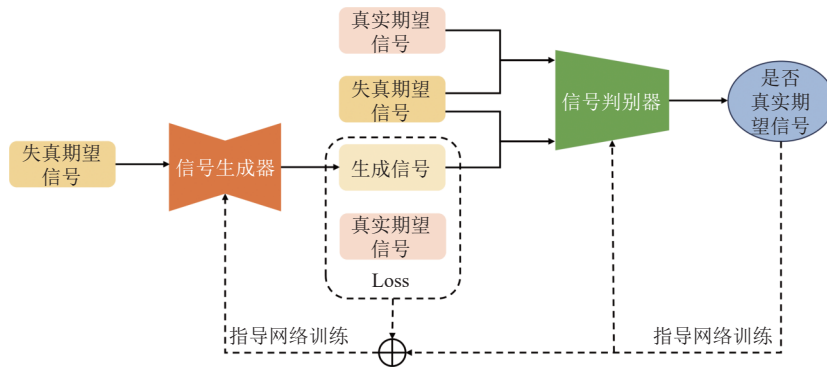


图 2 基于生成式对抗网络架构的神经网络

构建的生成式对抗网络包含基于深度神经网络的信号生成器和信号判别器, 其中, 信号生成器用于根据失真期望信号重构真实期望信号, 信号判别器用于区分输入是真实期望信号还是信号生成器重构的期望信号。本文采用联合训练的方式对信号生成器和信号判别器进行训练。训练好的信号生成器能够重构高精度期望信号且信号判别器难以区分真实期望信号和重构的期望信号。因此, 训练好的信号生成器能够根据频域陷波后的失真期望信号重构真实期望信号。

2.4 算法设计

2.4.1 网络结构设计

该生成式对抗网络的信号判别器部分为一个传统的二分类网络, 网络结构如图 3 所示, 其输入为真实期望信号与失真信号的拼接, 或者重构期望信号与失真期望信号的拼接, 然后分别经过卷积核个数为 16、64、1 的卷积层, 卷积核的尺寸均为 3×1 , 卷积步长为 2, 每个卷积层后接一个 LeakyReLU 激活层。最后一个 LeakyReLU 激活层的输出结果

经 Flatten 层展平为一维向量后输入神经元个数为 1 的全连接层, 最后使用 Sigmoid 激活函数对全连接层的输出进行处理, 输出结果为信号判别器对输入向量是否包含真实期望信号的置信度。

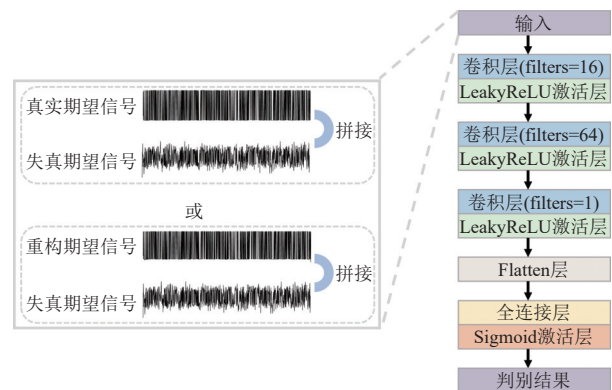


图 3 信号判别器网络结构图

鉴于自编码器在图像去噪^[22]、数据去扰^[23]等方面表现出了卓越的性能, 本文采用对称的自编码器结构设计生成式对抗网络的信号生成器部分。如图 4 所示, 信号生成器中的编码器部分由 4 个卷积

层组成, 每个卷积层后接一个用于非线性处理的 PReLU 激活层。每个卷积层的卷积核个数为前一层的 4 倍, 尺寸为 3×1 。通过设置卷积步长为 2, 编码器能够实现输入信号的降维去噪与特征提取^[22]。解码器由 4 个反卷积层组成, 反卷积层的卷积核个数是前一层的四分之一, 尺寸为 3×1 , 卷积

步长为 2, 每个反卷积层后接一个 PReLU 激活层。另外, 本文在对称的卷积层和反卷积层之间使用跳跃连接, 即每一个反卷积层的输入都是前一层的输出与对应卷积层输出的拼接。该设计既有利于保存信号传播过程中丢失的细节信息, 也有利于恢复出信号的高频成分^[24]。

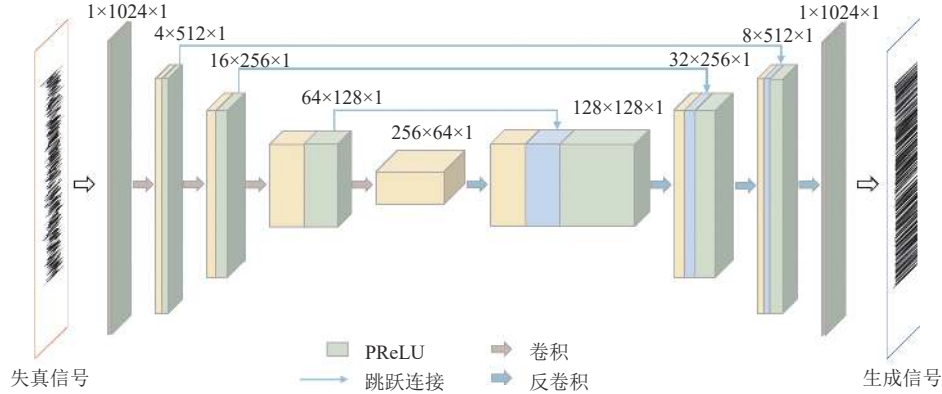


图 4 信号生成器网络结构图

本文使用浮点运算数 (Floating Point Operations, FLOPs) 指标来衡量信号判别器和信号生成器的计算量。卷积层与反卷积层的 FLOPs 的计算方式为 $(2 \times C_i \times K_H \times K_W - 1) \times H_o \times W_o \times C_o$, 其中, C_i 代表输入通道数, $K_H \times K_W$ 代表卷积核宽高尺寸, -1 代表不使用偏置项, H_o 代表输出长度, W_o 代表输出宽度, C_o 代表输出通道数; 激活层的 FLOPs 计算方式为 $C_i \times W_i \times H_i$, 其中, H_i 代表输入长度, W_i 代表输入宽度。经过计算, 信号判别器的 FLOPs 为 1.72 M, 信号生成器的 FLOPs 为 23.36 M。

2.4.2 双目标优化函数设计

本文联合训练信号生成器和信号判别器的目标包括: 1) 最小化重构期望信号与真实期望信号的分布差异; 2) 最小化重构期望信号与真实期望信号的误差。

首先, 本文优化现有生成式对抗网络中数据分布差异的评估方式如下:

$$\min_G \max_D V(D, G) = E_s[\log D(s)] + E_{\hat{s}}[\log(1 - D(G(\hat{s})))] \quad (9)$$

式中, G 表示信号生成器; D 表示信号判别器。在固定信号生成器的条件下, 通过最大化式 (9) 的值来优化信号判别器; 在固定信号判别器的情况下, 通过最小化式 (9) 的值来优化信号生成器。信号生成器和信号判别器的优化是一个博弈的过程。因

此, 本文的第一个目标是通过交替训练信号生成器和信号判别器, 使得当信号判别器具有最强判别能力的时候也无法对信号生成器重构的期望信号与真实期望信号进行准确判别。

同时, 本文采用 Huber 函数来评估重构的期望信号与真实期望信号之间的误差, 计算方式如下:

$$L_{\text{Huber}}(s, G(\hat{s})) = \frac{1}{N} \sum_{i=0}^{N-1} \begin{cases} \frac{1}{2}(s_i - G(\hat{s}_i))^2, & d < \delta \\ \delta \left(|s_i - G(\hat{s}_i)| - \frac{1}{2}\delta \right), & d \geq \delta \end{cases} \quad (10)$$

式中, δ 为超参数; d 的取值为 $|s_i - G(\hat{s}_i)|$, Huber 函数通过判断 $|s_i - G(\hat{s}_i)|$ 和阈值 δ 的大小来选择不同的误差统计方式。当信号差异较小时, 误差计算方式为二次函数形式的均方误差; 当信号差异较大时, 误差计算方式为线性形式的平均绝对误差。此设计能够避免异常点对统计误差的过度影响, 提升网络训练的稳定性。综上, 本文的双目标优化函数为:

$$G^* = \arg \min_G \max_D V(D, G) + \lambda L_{\text{Huber}}(s, G(\hat{s})) \quad (11)$$

式中, λ 为平衡两种目标的超参数。本文使用交叉验证的方法确定超参数 δ 和 λ 的取值, 通过平衡算法收敛速度及算法性能选择 δ 的值为 0.5, λ 的值为 100。

2.4.3 网络训练算法

本文按照算法 1 所示流程对信号生成器和信号

判别器进行训练。该算法的核心在于联合迭代训练过程。本文首先在固定信号生成器的情况下采用批量梯度下降方法对信号判别器进行 k 次训练。接着, 本文固定信号判别器, 并采用批量梯度下降方法对信号生成器进行 1 次训练。重复此过程直至信号判别器和信号生成器均收敛。本文在整个训练过程中采用学习率为 0.000 2 的 Adam 优化器。

算法 1 基于生成式对抗网络的信号生成器与信号判别器联合训练算法

输入: 期望信号、失真的期望信号

输出: 信号生成器网络和信号判别器网络

初始化信号生成器网络参数 θ_g 和信号判别器网络参数 θ_d

将训练使用的数据集按照 $\text{Batchsize}=m$ 的条件随机划分成不同的 Minibatch

for 训练轮数 Epochs do

for 判别器训练次数 k do

for 数据集中的 Minibatches do

从训练数据集中取出一个批次的失真期望信号 $\{\hat{s}^{(0)}, \hat{s}^{(1)}, \dots, \hat{s}^{(m-1)}\}$ 及其对应的期望信号 $\{s^{(0)}, s^{(1)}, \dots, s^{(m-1)}\}$

通过批量梯度下降法更新信号判别器网

络参数

$$\nabla_{\theta_d} - \frac{1}{m} \sum_{i=0}^{m-1} (\log D(s^{(i)}) + \log(1 - D(G(\hat{s}^{(i)}))))$$

end for

end for

for 数据集中的 Minibatches do

从训练数据集中取出一个批次的失真期望信号 $\{\hat{s}^{(0)}, \hat{s}^{(1)}, \dots, \hat{s}^{(m-1)}\}$ 及其对应的期望信号 $\{s^{(0)}, s^{(1)}, \dots, s^{(m-1)}\}$

通过批量梯度下降法更新信号生成器网络

参数

$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=0}^{m-1} (\log(1 - D(G(\hat{s}^{(i)}))) + \lambda L_{\text{Huber}}(s^{(i)}, G(\hat{s}^{(i)})))$$

end for

end for

3 结果及分析

3.1 数据集生成

本文使用 MATLAB 软件仿真实现了一个正交相移键控 (Quadrature Phase Shift Keying, QPSK) 信号收发的数字基带通信系统, 并用该系统产生训练深度神经网络的数据集, 具体过程如图 5 所示。

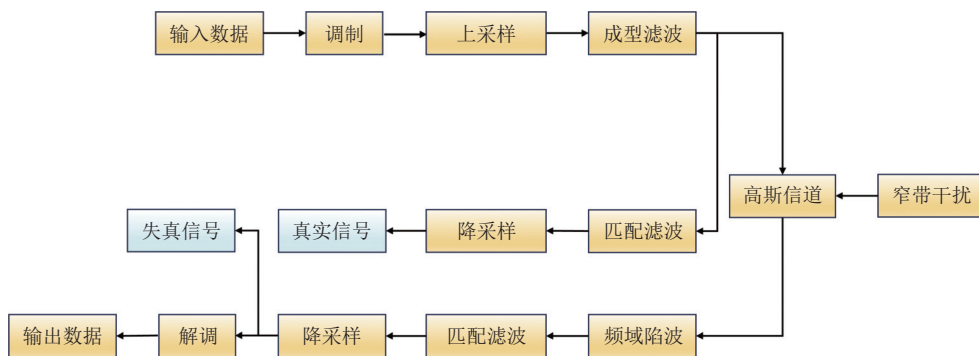


图 5 QPSK 数字基带通信系统仿真模型

成型滤波完成后的信号分为两路用来制作数据集。其中一路经过匹配滤波、降采样后存储为真实信号; 另一路经过高斯信道并且叠加上窄带干扰之后, 经过频域陷波、匹配滤波、降采样后存储为失真信号, 需要注意的是, 失真信号需要和真实信号为一一对应的关系。

本文考虑仿真的窄带干扰类型为窄带高斯干扰、QPSK 调制干扰、线性调频干扰。其中窄带高斯干扰为高斯白噪声通过带通滤波器产生; QPSK 调制干扰为基带 QPSK 信号通过频谱搬移至指定频

段位置处产生; 线性调频干扰产生方式为:

$$j(n) = \sqrt{p} e^{j(2\pi f_0 n / f_s + \pi K n^2 / f_s^2 + \theta)} \quad (12)$$

式中, p 为干扰功率; f_0 为干扰的中心频率; f_s 为采样频率; K 为调频斜率; θ 表示随机相位。

考虑到复数信号的实部和虚部彼此独立, 本文利用信号生成器对信号的实部和虚部分别进行干扰抑制与信号重构, 最后, 再将实部和虚部组合为对应的复数信号形式, 仿真中使用到的具体参数如表 1 所示。

表 1 QPSK 数字基带通信系统仿真参数设置

参数类型	参数取值
调制方式	QPSK
输入比特数量/个	2 048
输入符号数量/个	1 024
信源信息传输速率/Mbps	200
采样率/MHz	400
滚降因子	0.25
信道类型	高斯信道

3.2 实验结果及分析

此部分主要验证算法的干扰抑制能力与泛化能力。为了验证算法的干扰抑制能力, 本文在相同仿真条件下生成两组不同数据集, 分别用于信号生成器的训练和干扰抑制能力的评估。为了验证算法的模型泛化能力, 本文分别评估相同模型在不同 SIR (Signal to Interference Ratio)、干扰频段、Eb/No、干扰类型下的干扰抑制性能。

3.2.1 干扰抑制能力评估

本文按照表 2 所示参数产生两套具有相同分布特性的数据集, 并利用其中一套数据集对信号生成器进行训练, 用另外一套数据集对训练后的信号生成器干扰抑制能力进行评估。

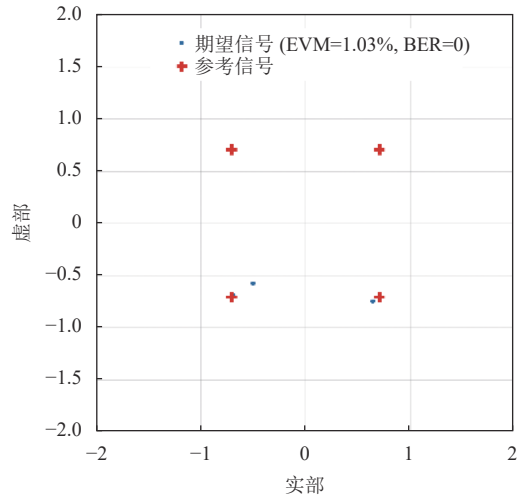
表 2 数据集参数设置

参数类型	参数取值
训练集窄带干扰频段/MHz	40~50
训练集大小	10 000×1×1 024
训练集SIR/dB	-15
训练集Eb/No/dB	10

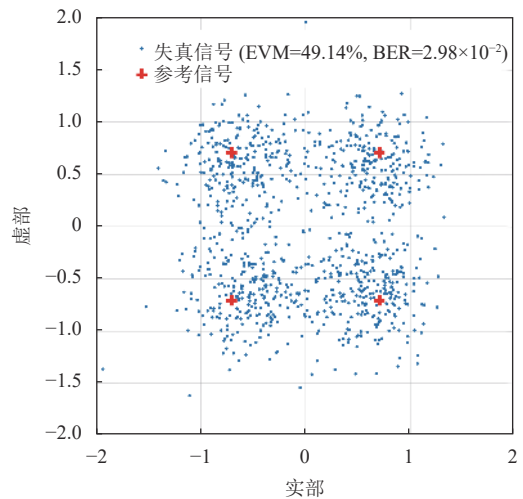
图 6 为期望信号、频域陷波后的失真信号、重构信号与参考信号对应的星座图, 本文使用误差矢量幅度 (Error Vector Magnitude, EVM) 和误码率 (Bit Error Ratio, BER) 来衡量接收调制符号和理想调制符号之间的误差, 其中参考信号为 QPSK 调制后的符号序列。可以看到图 6b 中频域陷波后的失真信号 EVM 和 BER 分别为 49.14% 和 2.98×10^{-2} , 而图 6c 中重构信号 EVM 降低至 7.52%, BER 降低为 1.46×10^{-3} 。此结果说明了本文提出的算法能够根据频域陷波后的失真信号恢复真实期望信号。

图 7 为期望信号、频域陷波后的失真信号、重构信号以及重构误差的时域对比, 信号序列长度为 256。从图 7a 和图 7b 可以看出, 期望信号与频域陷波后的失真信号在时域上有较大误差, 而从

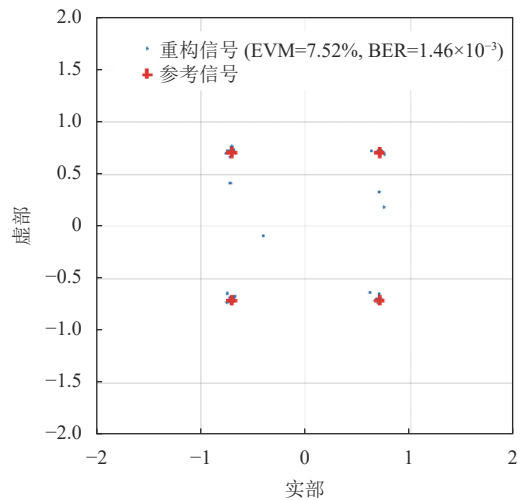
图 7d 可以看出, 经过信号生成器的干扰抑制之后, 重构信号和期望信号之间的时域误差降低至 0 左右。



a. 参考信号与期望信号星座图



b. 频域陷波算法干扰抑制效果



c. 提出的“频域陷波+信号生成器”算法干扰抑制效果

图 6 干扰抑制效果星座图对比

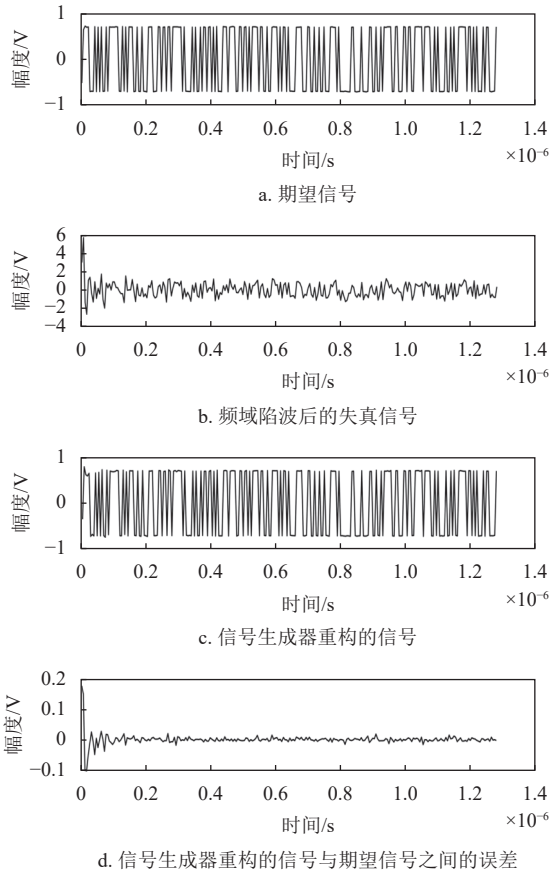


图 7 干扰抑制效果时域对比

图 6 和图 7 表明训练好的信号生成器可以根据频域陷波后的失真信号以较小误差重构真实期望信号，同时说明了本文提出的结合频域陷波与深度神经网络的干扰抑制算法效果显著。

3.2.2 算法泛化能力评估

算法的泛化性能是一个关键的评估指标。按照表 3 所示参数设置了 4 组训练集和测试集，分别

测试所提算法对固定频段的不同 SIR 条件下、任意频段不同 SIR 条件下、固定频段的不同 E_b/N_0 条件下以及固定频段的不同干扰类型条件下的干扰抑制效果。测试结果如图 8 所示，其中，“不处理”代表直接对受干扰的接收信号进行解调，“频域陷波算法”表示对接收信号进行频域陷波以滤除大部分干扰，“提出的算法”表示使用本文所提“频域陷波+信号生成器”算法进行干扰抑制。

从图 8a、图 8b 和图 8c 中可以看到，“不处理”“频域陷波算法”和“提出的算法”的 BER 曲线依次降低，说明信号生成器在不同于训练集的测试集上具有一定的泛化性。以图 8a 为例，接收信号不做处理直接解调的 BER 最高，而经过陷波处理后，接收信号整体的 BER 有明显降低。SIR 从 0 dB 到 -30 dB，陷波处理后的 BER 逐渐升高，主要原因是陷波处理在做 DFT 变换时频谱泄露以及干扰的过渡带随着干扰功率的增强对干扰抑制效果的影响也增大。图 8a 中使用到的信号生成器在 SIR 为 -15 dB 的条件下训练，而 SIR 从 0 dB 到 -30 dB 的范围内，“提出的算法”的 BER 相较于“不处理”和“频域陷波算法”的 BER 均有明显降低，在 SIR 为 0 dB 时，BER 从 0.16 降低至 4.98×10^{-4} ，说明算法在 SIR 条件不同于训练集的测试集上具有泛化能力。

如图 8d 所示，尽管窄带干扰类型不同，但使用本文所提算法进行干扰抑制的 BER 均低于只经过频域陷波算法的 BER。图 8 所示结果表明，信号生成器在干扰功率、频段位置、信号功率、干扰类型不同于训练集的测试集上具有泛化性能。

表 3 信号生成器泛化能力评估数据集参数设置

参数类型	泛化能力评估项目参数设置			
	SIR	干扰频段	E_b/N_0	干扰类型
训练集干扰类型	窄带高斯干扰	窄带高斯干扰	窄带高斯干扰	窄带高斯干扰
训练集干扰频段/MHz	40~50	20~100 (每10 MHz一组)	40~50	40~50
训练集大小	$10\,000 \times 1 \times 1\,024$	$3\,000 \times 8 \times 1\,024$	$10\,000 \times 1 \times 1\,024$	$10\,000 \times 1 \times 1\,024$
测试集干扰类型	窄带高斯干扰	窄带高斯干扰	窄带高斯干扰	窄带高斯干扰、QPSK调制干扰、线性调频干扰
测试集SIR/dB	-30~0 (每5 dB一组)	-30~0 (每5 dB一组)	-15	-30~0 (每5 dB一组)
测试集 E_b/N_0 /dB	10	10	0~14 (每2 dB一组)	10
测试集干扰频段/MHz	40~50	20~100 (随机10 MHz)	40~50	40~50
测试集大小	$5\,000 \times 7 \times 1\,024$	$5\,000 \times 7 \times 1\,024$	$5\,000 \times 8 \times 1\,024$	$5\,000 \times 7 \times 1\,024$




图8 提出的“频域陷波+信号生成器”算法干扰抑制泛化能力评估 BER 曲线

4 结束语

本文设计了一种基于深度学习的非扩跳频通信体制窄带干扰抑制技术, 仿真结果表明, 本文所提算法能够有效降低窄带干扰环境下非扩跳频通信体制的误码率, 同时提升无线通信系统干扰抑制能力和数据传输能力。值得强调的是, 本文所提算法只需要在接收端对基带信号进行处理, 可以结合现有天线域、射频域抗干扰技术进一步提升通信系统干扰对抗性能, 具有较为广泛的应用范围。典型应用场景包括但不限于星间、星地、空空、空地高速可靠通信。当前, 本文所提算法主要针对单一频段的窄带干扰, 未来需要探索针对多个频段干扰的智能抑制方案。

参考文献

- [1] XIA S Y, JIANG Q J, ZOU C, et al. Beam coverage comparison of LEO satellite systems based on user diversification[J]. *IEEE Access*, 2019, 7: 181656-181667.
- [2] CHEN S L, YU S H, WANG S M, et al. Development of a low cost and high data rate X-band transmitter for micro-satellite applications[C]//2017 IEEE Asia Pacific Microwave Conference. Kuala Lumpur: IEEE, 2017: 1115-1118.
- [3] PIRAYESH H, ZENG H C. Jamming attacks and anti-jamming strategies in wireless networks: A comprehensive survey[J]. *IEEE Communications Surveys & Tutorials*, 2022, 24(2): 767-809.
- [4] SHI Y X, AN K, LI Y S. Index modulation based frequency hopping: Anti-jamming design and analysis[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(7): 6930-6942.
- [5] LIU Y, NING P, DAI H Y, et al. Randomized differential DSSS: Jamming-resistant wireless broadcast communication [C]//2010 Proceedings IEEE INFOCOM. San Diego: IEEE, 2010: 1-9.
- [6] 李少谦, 程郁凡, 董彬虹, 等. 智能抗干扰通信技术研究[J]. *无线电通信技术*, 2012(1): 1-4.
LI S Q, CHENG Y F, DONG B H, et al. Research on intelligent anti-jam communication techniques[J]. *Radio Communications Technology*, 2012(1): 1-4.
- [7] BENGIO Y, LECUN Y, HINTON G. Deep learning for AI[J]. *Communications of the ACM*, 2021, 64(7): 58-65.
- [8] 党泽. 基于深度学习的无线通信干扰信号识别与处理技术研究[D]. 成都: 电子科技大学, 2020.
DANG Z. Research on the technology of wireless communication interference signal identification and processing based on deep learning[D]. Chengdu: University of Electronic Science and Technology of China, 2020.
- [9] KLEMP M, CHEN S Y, WAGNER R, et al. End-to-end trainable deep neural network for radar interference detection and mitigation[C]//2023 IEEE International Radar

- Conference. Sydney: IEEE, 2023: 1-6.
- [10] LIU C G, CHEN Y F, YANG S H. Deep learning based detection for communications systems with radar interference[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(6): 6245-6254.
- [11] WANG P Y, CHENG Y F, DONG B H, et al. Convolutional neural network-based interference recognition[C]//2020 IEEE 20th International Conference on Communication Technology. Nanning: IEEE, 2020: 1296-1300.
- [12] DING Y M, YANG F H, FENG J X. Intelligent cognitive anti-jamming algorithm based on long short-term memory network[C]//2020 IEEE 3rd International Conference on Electronics and Communication Engineering. Xi'an: IEEE, 2020: 76-82.
- [13] 冉雨, 程郁凡, 陈大勇, 等. 采用 BP 神经网络的智能抗干扰决策引擎研究[J]. *信号处理*, 2019(8): 1350-1357.
- RAN Y, CHENG Y F, CHEN D Y, et al. Intelligent anti-jamming decision engine based on BP neural network[J]. *Journal of Signal Processing*, 2019(8): 1350-1357.
- [14] CHANG X, LI Y B, ZHAO Y, et al. An improved anti-jamming method based on deep reinforcement learning and feature engineering[J]. *IEEE Access*, 2022, 10: 69992-70000.
- [15] CAO K T, ZHENGKONG H N. Intelligent anti-jamming methods for wireless networks[C]//2023 8th International Conference on Intelligent Computing and Signal Processing. Xi'an: IEEE, 2023: 670-674.
- [16] YAO F Q, ZHU Y G, SUN Y F, et al. Wireless communications "N+1 dimensionality" endogenous anti-jamming: Theory and techniques[J]. *Security and Safety*, 2023, 2: 2023003.
- [17] ZHOU H J, BAI J, WANG Y R, et al. Few-shot electromagnetic signal classification: A data union augmentation method[J]. *Chinese Journal of Aeronautics*, 2022, 35(9): 49-57.
- [18] XIA Y, XU Y Y, CHEN P, et al. Generative adversarial network with transformer generator for boosting ECG classification[J]. *Biomedical Signal Processing and Control*, 2023, 80(1): 104276.
- [19] ZHOU X, SUN Z, WU H M. Wireless signal enhancement based on generative adversarial networks[J]. *Ad Hoc Networks*, 2020, 103: 102151.
- [20] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [21] ISOLA P, ZHU J Y, ZHOU T H, et al. Image-to-image translation with conditional adversarial networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 5967-5976.
- [22] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders[C]//Proceedings of the 25th International Conference on Machine Learning. New York: ACM, 2008: 1096-1103.
- [23] OWFI A, AFGHAH F. Autoencoder-based radio frequency interference mitigation for SMAP passive radiometer[C]//IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium. Pasadena: IEEE, 2023: 6783-6786.
- [24] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.

编辑 刘飞阳