SCIENTIA SINICA Informationis





基于 Bi-LSTM 的同时同频全双工数字域自干扰 抑制方法

鲁帆^{1,2*},范占春^{1,2},马超^{1,2},陈远祥³,汪予晗³,程竟爽^{1,2}, 杜海龙^{1,2},胡聪³

1. 北京空间飞行器总体设计部,北京 100094

2. 北京市电磁兼容与天线测试工程技术研究中心,北京 100094

3. 北京邮电大学电子工程学院, 北京 100876

* 通信作者. E-mail: fan8736@pku.edu.cn

收稿日期: 2022-11-30; 修回日期: 2023-02-08; 接受日期: 2023-03-14; 网络出版日期: 2023-10-13

北京市科技新星计划 (批准号: Z211100002121138)、国家自然科学基金 (批准号: 62271079, 61875239) 和国家重点研发计划 (批 准号: 2021YFB2900405) 资助项目

摘要 同时同频全双工 (co-frequency co-time full duplex, CCFD) 系统在相同的频率上同时进行信号的收发,理论上可使通信频谱利用率提高一倍. 但是由于收发天线等前端模块距离较近,系统中会存在很强的自干扰信号.当前常用的自适应滤波、最小二乘法估计等自适应干扰抑制方法存在着不能有效抑制多径信道和功放非线性产生自干扰信号的不足. 针对此问题,本文提出一种基于双向长短时记忆神经网络 (bi-directional long short-term memory, Bi-LSTM) 的 CCFD 数字域自干扰抑制方法.首先根据多径信道的特征,采用记忆多项式对自干扰信道进行建模; 然后采用 Wild Horse 优化算法 (Wild Horse optimizer, WHO),通过迭代寻找到最优时延单位以确定训练数据的特征数; 最后搭建 Bi-LSTM 网络进行训练,重构出自干扰信号,并在接收端减去,以达到自干扰抑制的目的. 在仿真实验中采用OFDM (orthogonal frequency division multiplexing) 信号作为参考信号,实现了 47.17 dB 自干扰信号抑制比,较传统最小二乘 (least square, LS) 算法有 31.58 dB 的提升. 结果表明,本文所提出的方法可高效准确地提高 CCFD 系统的自干扰信号抑制能力.

关键词 同时同频全双工 (CCFD), 双向长短时记忆神经网络 (Bi-LSTM), Wild Horse 优化算法 (WHO), OFDM

1 背景介绍

随着卫星互联网星座的构建、空天地一体化网络通信技术的发展,通信系统对终端设备的数据量 以及数据种类的要求有了前所未有的提升^[1],同时也带来了频谱资源紧张、频谱效率低下,以及与地

引用格式: 鲁帆, 范占春, 马超, 等. 基于 Bi-LSTM 的同时同频全双工数字域自干扰抑制方法. 中国科学: 信息科学, 2023, 53: 1982–1993, doi: 10.1360/SSI-2022-0446
 Lu F, Fan Z C, Ma C, et al. A CCFD digital domain self-interference suppression approach based on Bi-LSTM (in Chinese). Sci Sin Inform, 2023, 53: 1982–1993, doi: 10.1360/SSI-2022-0446

ⓒ 2023《中国科学》杂志社

面 5G 通信网络融合不够等问题. 众所周知, 现实中的频谱资源是十分有限且宝贵的^[2], 因此需要提高频谱资源利用率, 以满足在有限频谱的约束下, 传输大量、多种数据的需求. 同时同频全双工技术 正是在这样的背景下应运产生, 它可以在相同的频率下同时发送和接收信号, 能够使频谱效率提升一 倍^[3~5]. 但是, 这项技术需要解决的一项重要问题是, 在同时同频全双工系统中, 由于发射天线与接收 天线距离较近, 自干扰信号强度远大于期望信号强度, 会对系统产生严重干扰. 因此, 应用同时同频全 双工系统的前提是抑制强自干扰信号^[6~9].

为了解决这一问题,目前常用的自干扰抑制方法有自适应滤波(例如基于最小均方算法(least mean square, LMS)的自适应滤波)、最小二乘法估计(least square, LS)、模式识别和深度学习等.针对同时同频全双工的中继通信,Lopez-Valcarce等^[10]提出了基于谱成型LMS反馈的干扰对消方法,但该方法的缺点在于计算复杂,并且收敛速度与对消比相互制约.Yan等^[11]研究了有源电磁引信系统接收天线与发射天线之间的直接耦合干扰抑制问题,采用变步长LMS算法消除耦合干扰信号,自干扰抑制比达到 40 dB.在使用LS的方法中,有学者在时域中获取信道的最小二乘估计,然而,由于循环前缀(cyclic prefix, CP)的长度有限,使用时域估计进行重建的性能在脉冲响应较长的信道中受到显著影响^[12,13].此外,为了减小文献[12]中每次传输时估计记忆多项式模型(memory polynomial, MP)系数的计算复杂度和训练开销,实现宽带自干扰信号的数字对消,有学者分别采用了正交最小均方(orthogonal least mean square, OLMS)^[14]和递归最小二乘(recursive least-square, RLS)^[15]方法.仿真结果表明二者均可有效降低计算复杂度,但是文献[14]所提方法不能跟踪信道的实时变化从而进行调整,并且需要导引信号.

随着人工智能的兴起, 深度学习在通信技术领域中各个方向的应用进展迅速, 但将深度学习方 法直接应用到 CCFD (co-frequency co-time full duplex) 系统数字域自干扰抑制中的研究还比较少. Kristensen 等^[16] 研究了神经网络的使用, 如递归和复值神经网络, 并对网络架构进行了深入的探索. 此外, Shi 等^[17]还将一种前馈神经网络应用到数字域自干扰抑制上进行自干扰信号重构. 通过设计一 种自适应线性滤波器,从基带发射信号或反馈信号中提取特征,作为神经网络的输入,使用该方法对 OFDM (orthogonal frequency division multiplexing) 信号进行实验, 在干噪比为 30 dB 的情况下, 该方 法的自干扰抑制能力为 29 dB. Muranov 等^[18]提出了两种应用于全双工系统的自干扰抑制方法,均 使用神经网络来估计非线性信号,使用 LS 算法来估计线性信号. Guo 等^[19] 首先对自干扰信道进行 探测, 收集自干扰信道数据, 然后训练深度神经网络并预测自干扰信号. 实验结果表明深度学习方法 在数字对消中可实现非常高的精度,且计算复杂度较低,具有快速稳定的收敛性. Kurzo 等^[20]提出了 一种基于神经网络的非线性自干扰抵消器的硬件架构,并将其与传统基于多项式的硬件实现进行了比 较. 实验结果表明基于神经网络的自干扰抑制方案在 FPGA (field programmable gate array) 上需要的 资源显著减少,当用于专用集成电路 (application specific integrated circuit, ASIC) 时,与记忆多项式 模型抑制方案相比, 硬件效率提高了 81%, 证明了将深度学习方法应用于全双工系统自干扰抑制的可 能性, 然而, 上述方法都存在不同的缺陷, 自适应滤波方法只能处理线性自干扰, 对于通信链路中因被 非线性器件处理过而产生失真的信号, 自适应滤波将无法准确处理. 现有的基于深度学习的方法通常 只抑制非线性自干扰,在实现过程中,需要额外的模块来消除线性自干扰,大大增加了过程的复杂性. 此外,为了提高深度学习网络的训练能力,现有的基于深度学习的方法大多将发射信号进行多段时间 的单位延时作为训练样本的多个特征, 然而, 具体延时的时间单位并没有统一的理论指导. 延时过小 会使训练样本的特征过少,无法真实反映多径信道,导致训练出来的网络效果较差;延时过大会使训 练样本的特征过多,导致网络训练时间过长.

本文提出了一种基于 Wild Horse 优化算法 (Wild Horse optimizer, WHO)^[21] 搜索最优时延联合

双向长短时记忆神经网络的 CCFD 系统自干扰抑制方法. 首先使用 WHO 对原始信号的时延进行估 计, WHO 算法作为新型群智能优化算法, 具有寻优能力强、收敛速度快等特点. 与其他群智能优化算 法对比实验结果表明, WHO 算法在面对多种测试函数均有较好的收敛性, 在面对测试函数维度增加 等方面具有明显的优势^[21]. 利用 WHO 算法的优势, 能够对由发射链路非线性和多径信道产生的信 号延时进行快速求解, 充分考虑了全双工链路的实际情况, 在数字信号处理方面与其他论文相比有较 大改进, 估计结果更加准确. 根据求解得到的最优时延对参考信号进行特征处理, 产生包含多个时延 信息的网络输入信号, 进一步从信号中提取链路的记忆特征. 然后, 将特征处理后的信号送入构建好 的双向长短时记忆神经网络 (bi-directional long short-term memory, Bi-LSTM) 中进行训练, 重构出自 干扰信号. 较普通神经网络而言 Bi-LSTM 能够更加有效地处理与时间序列相关的信息, 对具有记忆 性的线性和非线性失真信号的预测有很好的效果. 最后在接收端从接收信号中减去重构出的自干扰信 号, 达到自干扰抑制的目的.

本文的主要贡献可总结为以下几点:

•提出一种可反映全双工系统真实情况的链路模型,模拟了非线性器件、多径信道对链路的影响;

•提出一种基于群智能优化算法的数据处理方法,可在处理过程中有效得到最佳时延;

提出一种基于深度学习的自干扰信号抑制方法.构建的深度学习网络可根据发射信号精准预测
 出自干扰信号,在接收信号中减去预测的自干扰信号以达到自干扰抑制的目的;

•基于典型同时同频全双工通信场景下,使用 OFDM 发射信号体制的实验验证.

本文各部分的具体内容安排如下: 第2节介绍了同时同频全双工系统的简化收发系统结构, 得到 自干扰信号的表达式. 第3节详细介绍了自干扰信号的整个抑制过程, 其中包含3个主要模块, 分别 是信号预处理、Bi-LSTM 网络的构建, 以及自干扰抑制能力的计算. 在第4节中, 以 OFDM 信号作为 参考信号进行软件仿真, 介绍了 OFDM 信号的产生过程, 并展示了以 OFDM 信号作为参考信号的仿 真结果. 实验结果表明, 使用本文提出的基于 Bi-LSTM 的同时同频全双工数字域自干扰抑制方法进行 自干扰抑制, 自干扰抑制能力可达到 47.17 dB. 最后, 在第5节中得出结论.

2 系统模型

图 1 是一个简化的全双工收发模块框图. 如图 1 所示, x(n) 是 n 时刻的基带发射信号, x(n) 通过 数模转换器 (digital-to-analog converter, DAC) 转换为模拟信号, 然后通过 IQ-Mixer 与载波信号混合, 得到的信号表示为 $x_{IQ}(n)$

$$x_{\rm IQ}(n) = K_1 x(n) + K_2 x^*(n), \tag{1}$$

其中 $K_1 = 1/2(1 + \Psi e^{i\theta}), K_2 = 1/2(1 - \Psi e^{i\theta}), \Psi$ 和 θ 分别表示增益和相位不平衡参数. $x_{PA}(n)$ 为 $x_{IQ}(n)$ 通过功率放大器放大后的信号,由于放大器的非线性效应,信号会产生一定程度的失真,对此 我们采用 parallel Hammerstein (PH) 模型来进行建模,其表达式如下所示:

$$x_{\rm PA}(n) = \sum_{p=1}^{P} \sum_{m=0}^{M} h_{p,m} x \left(n - m \right) \left| x \left(n - m \right) \right|^{p-1},\tag{2}$$

其中, P, M 分别表示多项式的阶数和记忆深度, hp,m 表示 HP 模型的脉冲响应.

多径信道表征发射信号在到达接收端之前所经历的直射路径和反射路径.由于传播距离、"阴影 效应"等因素的影响,多径信道中的信号幅度、相位会发生变化,到达时间也会有所不同,多条路径上

1984



图 1 简化的全双工系统收发模块 Figure 1 Simplified full-duplex transceiver system model

的信号在接收端相互叠加,会产生电平衰落和时延扩展.多径信道可用以下公式进行建模:

$$\widetilde{y}(t) = \left(\sum_{k=1}^{N(t)} r_k(t) \widetilde{x} \left(t - \tau_k\right)\right) e^{j2\pi\Delta f_c t},\tag{3}$$

其中, k 为多径数, rk 为多径衰减参数, Tk 为多径时延参数.

经过功率放大器的自干扰信号还会经过多径信道,并受到空间传播过程中高斯噪声的影响,最终的自干扰信号表示如下:

$$y_{\rm SI} = \sum_{l=0}^{L-1} h_l x_{\rm PA} \left(n - d_1 \right) + w(n), \tag{4}$$

其中, L 是多径信道数, w(n) 是加性高斯白噪声, hl 和 dl 是路径 l 的信道系数和延迟量.

3 基于 Bi-LSTM 的同时同频全双工数字域自干扰抑制

本文所提出方法的整个过程包括信号预处理、Bi-LSTM 网络的构建,以及自干扰抑制能力的计算 3 个模块.对用于发射的 OFDM 信号需先进行预处理,将参考信号重构为多条特征、实部虚部分离的 格式后才可继续送入 Bi-LSTM 网络进行训练. 然后使用构建的 Bi-LSTM 网络对参考信号进行训练、 预测之后,得到重构的自干扰信号.最后根据残留自干扰信号强度,计算出系统的自干扰抑制能力.下 面将依次介绍这 3 个模块.

3.1 信号预处理

随机生成多组发射信号作为 Bi-LSTM 网络的训练样本.产生的发射信号为复数信号,但因 Bi-LSTM 网络无法处理复数运算,所以需要将复数信号重构为只包含实值的形式.另外,为了提高 Bi-LSTM 网络的训练能力,将发射信号进行多段时间单位的延时作为训练样本的多个特征.为了确定具体的延时时间单位,采用 WHO 优化算法寻找最优解,该算法可分为 5 步:初始化、个体位置更新、新个体产生、群体位置更新和最优个体更替.具体过程为:首先将初始种群随机设置为 *X* = {*X*₁,*X*₂,...,*X*_n},

并使用目标函数评价所有种群.将初始种群分组,设置种群数量为 N 分组数目为 G = [N × P_s],其中 P_s 是最优个体占种群数目的百分比,令其为算法的控制参数.设置 G 个最优个体之后,将剩余 (N – G) 个个体平均分配.算法初始,随机选择最优个体,在后续阶段依据成员的适应度确定最优个体的更替.然后将最优个体位置设置为种群的中心,其余成员在最优个体的周围搜索.使两个来自不同分组 *i* 和 *j* 的个体脱离原分组,在临时分组中产生新个体,新个体会离开临时分组,并加入一个新的分组 *k*.最后由最优个体带领整个分组在全局内搜索更合适的位置,若分组在当前位置的适应度高,则选择这个位置,否则由适应度更高的分组替代,为了保证算法的随机性,根据适应度函数的计算结果选择新的最优个体.

使用 WHO 算法对最大时延做估计时,初始种群即参考信号 *x*(*n*)的时延、幅度实部和幅度虚部 3 种参数.适应度函数为优化后的自干扰信号与实际自干扰信号的均方差,经过多次迭代后使适应度 函数达到最小,并取此时 *x*(*n*)的时延参数为最优值.假设估计出的时延量矩阵为 *D* = [*d*₁,*d*₂,...,*d*_L], *L* 为算法估计的最大时延.假设发射信号为 *x*,则第 *n* 个采样点对应的信号复值特征矩阵为

$$X[n] = \left[x^{d_1}[n], x^{d_2}[n], \dots, x^{d_i}[n], \dots, x^{d_L}[n] \right],$$
(5)

其中 x^{d_i}[n] 为发射信号在 n 时刻的采样点经过时延 d_i 个采样点的信号, 复值形式为

$$x^{d_i}[n] = R\left[x^{d_i}[n]\right] + j \times I\left[x^{d_i}[n]\right].$$
(6)

第 n 个采样点对应的信号实值特征矩阵为

$$X[n] = \begin{bmatrix} R[x[n]] & I[x[n]] \\ R[x^{d_1}[n]] & I[x^{d_1}[n]] \\ R[x^{d_2}[n]] & I[x^{d_2}[n]] \\ \vdots & \vdots \\ R[x^{d_2}[n]] & I[x^{d_2}[n]] \\ \vdots & \vdots \\ R[x^{d_i}[n]] & I[x^{d_i}[n]] \\ \vdots & \vdots \\ R[x^{d_L}[n]] & I[x^{d_L}[n]] \end{bmatrix}$$
(7)

此时自干扰信号的复值形式如下:

$$Y_{\rm SI} = \left[R[Y_{\rm SI}[n]] \ I[Y_{\rm SI}[n]] \right], \tag{8}$$

则 (X[n], Y_{SI}[n]) 构成一个训练对, 通过 WHO 算法得到的最大时延数可以确定特征维数.

3.2 Bi-LSTM 网络的构建

循环神经网络 (recurrent neural network, RNN) 是一类能够处理序列数据的神经网络, 它具有循 环核结构, 可以从时间维度提取特征信息, 送入后续网络中进行处理、预测等操作. RNN 的循环核可 以接受更为广泛的数据作为网络的输入, 且数据可在网络中持续存在, 这对于时间序列的处理十分有 利. LSTM 网络是 RNN 的一种变体, 因而也具有这种可描述动态时间行为的特性. LSTM 的网络结构 如图 2 所示, 其中重复的结构被称为长短时记忆网络单元. LSTM 的单个网络单元结构如图 3 所示.

LSTM 单元的输入参数由当前时刻的输入 X_t、上一时刻的单元状态输出 C_{t-1} 和上一时刻的隐藏层状态输出 h_{t-1} 组成, 输出参数由当前时刻单元状态输出 C_t 和当前时刻隐藏层状态输出 h_t 组成.



单元内部由遗忘门 f、输入门 i、候选门 g、输出门 o 组成, 其中 i 和 g 可合为输入门. 引入门结构是 为了保护和控制单元状态, 其中遗忘门可以决定从细胞状态中丢弃什么信息, 输入门可以决定多少新 的信息加入到单元状态中来, 输出门可以基于单元状态决定最终的输出值. 状态参数 C_t, h_t 的更新公 式为

$$C_t = f_t \odot C_{t-1} + i_t \odot g_t,$$

$$h_t = o_t \odot \tanh(C_t),$$
(9)

其中,门结构的输出公式为

$$f_{t} = \sigma \left(W_{f} X_{t} + R_{f} h_{t-1} + b_{f} \right),$$

$$i_{t} = \sigma \left(W_{i} X_{t} + R_{i} h_{t-1} + b_{i} \right),$$

$$g_{t} = \tanh \left(W_{g} X_{t} + R_{g} h_{t-1} + b_{g} \right),$$

$$o_{t} = \sigma \left(W_{o} X_{t} + R_{o} h_{t-1} + b_{o} \right).$$

(10)



图 5 LSTM 训练和预测过程

Figure 5 Diagrams of offline training and online testing

LSTM 网络在反向传播过程中每次迭代需要更新的参数如下:

$$W = \begin{bmatrix} W_f \\ W_i \\ W_g \\ W_o \end{bmatrix}, \quad R = \begin{bmatrix} R_f \\ R_i \\ R_g \\ R_o \end{bmatrix}, \quad b = \begin{bmatrix} b_f \\ b_i \\ b_g \\ b_o \end{bmatrix}, \quad (11)$$

其中 W 为输入权重, R 为循环权重, b 为偏置.

Bi-LSTM 的结构如图 4 所示,可以将它看作是两层信息传递方向相反的神经网络,其中,正向和反向的网络隐藏层会保存两个值 A, A',最终的输出值 y 取决于 A 和 A'.使用具有双向结构的 Bi-LSTM 网络,可以处理与之前状态和未来状态都相关的时间序列.

使用 Bi-LSTM 网络进行数据处理包括离线训练和在线预测两个过程, 如图 5 所示. 离线训练, 即 在不接收期望信号的情况下进行网络训练. 设置迭代次数、隐含层数、小批量大小、学习率等参数, 将 预处理后的训练样本的参考信号作为 Bi-LSTM 网络的输入, 训练样本的自干扰信号作为 Bi-LSTM 网 络的输出进行训练.

在线预测,即在训练过程结束后,在接收期望信号的同时,将预测样本的参考信号送入网络进行 预测,然后从接收信号中减去预测的自干扰信号,从而达到自干扰抑制的效果.

1988



图 6 基于 Bi-LSTM 的 CCFD 数字域自干扰抑制方案流程图 Figure 6 Flow chart of the whole scheme

3.3 自干扰能力的计算

数字域自干扰消除的原理在于通过参考信号准确估计出自干扰信号的近似值,并将其从接收信号 中减去以达到抑制自干扰的目的. 自干扰能力的计算通常是在离线状态下进行的, 计算公式如下:

$$C_{\rm dB} = 10 \lg \left(\frac{P_{y_{\rm SI}}}{P_{y_r_{\rm SI}}}\right),\tag{12}$$

其中, *P*_{ys1} 为实际自干扰信号功率, *P*_{y-rs1} 为残留自干扰信号功率. Bi-LSTM 网络需解决的是一个回归问题, 其参数迭代的最终目的在于最小化实际自干扰信号与预测自干扰信号之间的误差, 得到损失函数 loss 的最小值, 损失函数的计算公式如下:

$$loss = \frac{1}{S} \sum_{i=1}^{R} \sum_{j=1}^{L} |y_{ij} - y'_{ji}|^2,$$
(13)

其中, R 是预测样本的特征维度, L 是预测样本的时间序列长度, $S = R \times L$ 为数据总数, y 为网络预测输出, y' 为预测样本的实际自干扰信号. 本文提出的 CCFD 系统的数字域自干扰信号抑制方法总体 流程如图 6 所示.

4 实验结果

本文以 OFDM 信号作为参考信号进行软件仿真,参考信号产生的具体过程如图 7 所示. 随机生成多组 OFDM 信号作为训练样本送入 Bi-LSTM 网络进行训练,其损失函数值随迭代次数增加的变



Figure 8 Loss function of the Bi-LSTM method

化情况如图 8 所示. 由图 8 可得,随着迭代次数的增加,损失函数的值不断下降,迭代结束之后训练集的损失函数值达到 8.85×10⁻⁸ 左右,测试集的损失函数值达到 9.03×10⁻⁸ 左右,说明算法随迭代次数的增加逐渐收敛,并最终趋于稳定. 在传统的自干扰抑制方法中,使用自适应滤波 LMS 方法进行自干扰抑制,其主要原理是对发射信号 x(n) 进行自适应滤波. 将发射信号序列中的数值依次输入滤波器中,通过 LMS 算法进行计算,每次计算都输出计算后的值并实时更新滤波器的系数,直至整条序列输入完毕. 此算法最终目的是使实际自干扰信号与滤波器重建出的自干扰信号之间的误差最小,其损失函数值随序列长度增加的变化情况如图 9 所示. 随着序列长度的增加, LMS 算法的损失函数值逐渐降低,最终收敛并且达到 1.10×10⁻⁷ 左右,由此可得 Bi-LSTM 方法的收敛性能相较自适应滤波 LMS 方法更佳. 另外, LS 自干扰抑制的原理是通过最小二乘估计得到式 (2) 的参数 h_{p,m},并且带入公式中得到经过非线性失真的自干扰信号,然后进行数字域抑制. 其计算模型参数的方式是将全部序列输入进行一次计算,因此 LS 算法不存在收敛度.

将本文所提出的自干扰抑制方法与传统基于 LS 算法、自适应滤波 LMS 算法抑制自干扰信号的 方法进行比较,结果如图 10 所示.图中 3 条曲线从上至下依次表示未经过抑制的自干扰信号频谱、经 过 LS 方法抑制之后的残留信号频谱、经过自适应滤波 LMS 方法抑制之后的残留信号频谱和经过本 文方法抑制之后的残留信号频谱.由于利用深度学习的方法使用 Bi-LSTM 网络对自干扰信号进行预 测和重建的性能更加优越,结果更为精准,所以最终的残留信号为三者最少.经计算分析,使用 LS 方 法进行自干扰信号抑制,自干扰抑制能力可达到 15.59 dB;使用自适应滤波 LMS 算法进行自干扰抑制 时,抑制比可达到 40.33 dB;使用本文提出的算法进行自干扰抑制时,抑制比可达到 47.17 dB.自干扰 信号经过本文提出的数字域抑制方法抑制之后,残余信号强度远小于经过 LS 和自适应滤波 LMS 算 法抑制的残余自干扰信号强度,最终抑制能力较自适应滤波 LMS 方法可提升 6.84 dB,较传统 LS 算 法可提升 31.58 dB,抑制效果要好很多.



Figure 9 Loss function of the LMS method



图 10 (网络版彩图) 自干扰抑制后信号频谱图 Figure 10 (Color online) Spectrum of the SI signal after applying various cancellation schemes

5 结论

本文研究了同时同频全双工的数字域自干扰抑制问题,针对现有利用深度学习进行自干扰抑制的 方法在产生参考信号时,对于确定时延单位的具体数值没有统一指导的问题,提出使用 WHO 算法对 多径信道的延时和衰减进行自适应估计,并依据估计结果将发射信号进行多段延时作为训练样本的多 个特征,以有效适应多径信道情况的方法.针对普通神经网络无法有效处理与时间相关序列的问题, 提出采用 Bi-LSTM 网络来进行处理,可以更好地适应具有记忆性的时间序列,进一步提升了最终的自 干扰抑制效果.最终实验结果表明,使用本文提出的基于 Bi-LSTM 的同时同频全双工数字域自干扰抑 制方法进行自干扰抑制,抑制能力可达到 47.17 dB,相较于自适应滤波 LMS 方法可提升 6.84 dB,相 较于传统 LS 算法可提升 31.58 dB,具有更加显著的抑制效果,对同时同频全双工系统的自干扰抑制 具有潜在研究价值.

参考文献

- 1 Kong D H, Kil Y S, Kim S H. Neural network aided digital self-interference cancellation for full-duplex communication over time-varying channels. IEEE Trans Veh Technol, 2022, 71: 6201–6213
- 2 Elsayed M, El-Banna A A A, Dobre O A, et al. Low complexity neural network structures for self-interference cancellation in full-duplex radio. IEEE Commun Lett, 2021, 25: 181–185
- 3 Sabharwal A, Schniter P, Guo D, et al. In-band full-duplex wireless: challenges and opportunities. IEEE J Sel Areas Commun, 2014, 32: 1637–1652
- 4 Wu F, Ma W, Liu D. Multicast beamforming with LOS self-interference cancellation in full-duplex wireless communications. Int J Commun Syst, 2018, 31: e3544
- 5 Zhang D D, Wang X, Zhang Z S. Key techniques research on full-duplex wireless communications. Sci Sin Inform, 2014, 44: 951–964 [张丹丹, 王兴, 张中山. 全双工通信关键技术研究. 中国科学: 信息科学, 2014, 44: 951–964]
- 6 Mauskar C. Self-interference cancellation in full duplex radios and LTE-unlicensed. Dissertation for Ph.D. Degree. Riverside: University of California, Riverside, 2016
- 7 Narayanan S, Ahmadi H, Flanagan M F. On the performance of spatial modulation MIMO for full-duplex relay networks. IEEE Trans Wirel Commun, 2017, 16: 3727–3746
- 8 Ahmed E, Eltawil A M. All-digital self-interference cancellation technique for full-duplex systems. IEEE Trans Wirel Commun, 2015, 14: 3519–3532

- 9 Guo W, He Y, Zhao H, et al. Self-interference cancellation for cooperative jamming communications with nonideal alignment and channel equalization. Sci China Inf Sci, 2021, 64: 212302
- 10 Lopez-Valcarce R, Antonio-Rodriguez E, Mosquera C, et al. An adaptive feedback canceller for full-duplex relays based on spectrum shaping. IEEE J Sel Areas Commun, 2012, 30: 1566–1577
- 11 Yan Z T, Zhang Q F, Shi W T. Suppression of coupling interference based on variable step size LMS algorithm. In: Proceedings of IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC), 2017. 1–5
- 12 Bharadia D, McMilin E, Katti S. Full duplex radios. SIGCOMM Comput Commun Rev, 2013, 43: 375–386
- 13 Bharadia D, Katti S, Full duplex mimo radios. In: Proceedings of the 11th USENIX Symposium on Networked Systems Design and Implementation (NSDI14), 2014. 359–372
- 14 Korpi D, Choi Y-S, Huusari T, et al. Adaptive nonlinear digital self-interference cancellation for mobile Inband full-duplex radio: algorithms and RF measurements. In: Proceedings of IEEE Global Communications Conference (GLOBECOM), 2015. 1–7
- 15 Emara M, Roth K, Baltar L G, et al. Nonlinear digital self-interference cancellation with reduced complexity for full duplex systems. In: Proceedings of the 21th International ITG Workshop on Smart Antennas (WSA), 2017. 1–6
- 16 Kristensen A T, Burg A, Balatsoukas-Stimming A. Advanced machine learning techniques for self-interference cancellation in full-duplex radios. In: Proceedings of the 53rd Asilomar Conference on Signals, Systems, and Computers, 2019. 1149–1153
- 17 Shi C Z, Hao Y F, Liu Y, et al. Digital self-interference cancellation for full duplex wireless communication based on neural networks. In: Proceedings of the 4th International Conference on Communication and Information Systems (ICCIS), 2019. 53–57
- 18 Muranov K, Islam M A, Smida B, et al. On deep learning assisted self-interference estimation in a full-duplex relay link. IEEE Wirel Commun Lett, 2021, 10: 2762–2766
- 19 Guo H Q, Wu S E, Wang H G, et al. DSIC: deep learning based self-interference cancellation for in-band full duplex wireless. In: Proceedings of IEEE Global Communications Conference (GLOBECOM), 2019. 1–6
- 20 Kurzo Y, Burg A, Balatsoukas-Stimming A. Design and implementation of a neural network aided self-interference cancellation scheme for full-duplex radios. In: Proceedings of the 52nd Asilomar Conference on Signals, Systems, and Computers, 2018. 589–593
- 21 Naruei I, Keynia F. Wild horse optimizer: a new meta-heuristic algorithm for solving engineering optimization problems. Eng Comput, 2022, 38: 3025–3056

A CCFD digital domain self-interference suppression approach based on Bi-LSTM

Fan LU^{1,2*}, Zhanchun FAN^{1,2}, Chao MA^{1,2}, Yuanxiang CHEN³, Yuhan WANG³, Jingshuang CHENG^{1,2}, Hailong DU^{1,2} & Cong HU³

1. Beijing Institute of Spacecraft System Engineering, Beijing 100094, China;

2. Beijing Engineering Research Center of EMC and Antenna Measurement, Beijing 100094, China;

3. School of Electronic Engineering, Beijing University of Posts and Telecommunications, Beijing 100876, China

* Corresponding author. E-mail: fan8736@pku.edu.cn

Abstract Co-frequency co-time full duplex (CCFD) systems can transmit and receive signals simultaneously at the same frequencies and bring on double spectrum utilization, but CCFD systems suffer from self-interfering signals caused by the short distance between the Tx and Rx antennas. The commonly applied self-interference suppression methods, such as adaptive filtering and least-squares estimation, suffer from not suppressing multipath channels and self-interfering signals caused by non-linearity in the power amplifier at the same time. Based on this, we propose a CCFD digital domain self-interference suppression approach based on bi-directional long short-term memory (Bi-LSTM). First, according to the multipath channel characters, we build a self-interfering channel model using memory polynomials. Then, we search for the optimal unit of delay through iteration to confirm the number of features, by using Wild Horse optimizer. Finally, we build the Bi-LSTM to train and reconfigure self-interfering signals and suppress self-interference by canceling these signals at the Rx ports. We use orthogonal frequency division multiplexing signals at simulations and achieve a 47.17 dB self-interference suppression ratio result, with a 31.58 dB improvement compared with a traditional least-squares algorithm. Simulation results indicate the effectiveness of this approach.

Keywords co-frequency co-time full duplex (CCFD), bi-directional long short-term memory (Bi-LSTM), Wild Horse optimizer (WHO), OFDM