

引用格式: 王小波, 张云龙, 张译丹, 等. 基于复数神经网络的共平台非线性自干扰抵消 [J]. 电子科技大学学报, 2025, 54(6): 952-960.  
WANG X, ZHANG Y, ZHANG Y D, et al. Nonlinear self-interference cancellation based on complex-valued neural networks for co-platform[J]. Journal of University of Electronic Science and Technology of China, 2025, 54(6): 952-960.

# 基于复数神经网络的共平台非线性 自干扰抵消



王小波<sup>1,2\*</sup>, 张云龙<sup>2</sup>, 张译丹<sup>1</sup>, 赵宏志<sup>1</sup>

(1. 电子科技大学 通信抗干扰全国重点实验室, 成都 611731; 2. 中电信人工智能科技(北京)有限公司, 北京 100010)

**摘要:** 在争夺制电磁权过程中, 多功能一体化平台面临信号同时发送和接收而产生的共平台自干扰问题, 这对多功能系统的性能构成了重大挑战。传统自干扰信号的消除采用多项式模型, 该方法因参数量大、复杂度高而难以广泛应用于实际场景。为解决这一问题, 该文提出了一种基于 Mish 激活函数的复数卷积网络 (M-CVCNN) 自干扰抵消方法。通过引入复数神经网络, 能够同时挖掘信号在幅度和相位上的信息, 确保模型效果的同时显著降低了模型参数量。实验结果显示, M-CVCNN 干扰抵消器在参数量仅为 178 时, 成功将非线性自干扰信号的功率降低了 7.16 dB。

**关键词:** 同时收发; 非线性; 复数神经网络; 自干扰消除

中图分类号: TN929.S

文献标志码: A

DOI: 10.12178/1001-0548.2024157

## Nonlinear self-interference cancellation based on complex-valued neural networks for co-platform

WANG Xiaobo<sup>1,2\*</sup>, ZHANG Yunlong<sup>2</sup>, ZHANG Yidan<sup>1</sup>, and ZHAO Hongzhi<sup>1</sup>

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

2. China Telecom Artificial Intelligence Technology Co., Ltd., Beijing 100010, China)

**Abstract:** In the contest for electromagnetic spectrum dominance, multifunctional integrated platforms face the challenge of co-platform self-interference (SI) caused by simultaneous signal transmission and reception, which significantly degrades the performance of multifunctional systems. Traditional SI cancellation (SIC) methods employ polynomial models. However, due to their large number of parameters and high complexity, these methods are difficult to deploy widely in practical scenarios. To address this issue, a novel method based on a complex-valued convolutional neural network with Mish activation function (M-CVCNN) is proposed. M-CVCNN can simultaneously exploit information in both the amplitude and phase of signals, ensuring effective cancellation performance while significantly reducing the number of model parameters. Experimental results demonstrate that the M-CVCNN canceller successfully reduces the power of nonlinear SI signals by 7.16 dB with only 178 parameters.

**Key words:** simultaneous signal transmission and reception; nonlinearity; complex-valued neural network; self-interference cancellation

以机载、舰载、车载为代表的多功能一体化平台, 同时部署了电子战、雷达、通信、侦察等电磁波收发设备, 多任务在同一频段内被同时发送和接收<sup>[1-3]</sup>。平台面临的主要挑战是共平台自干扰 (self-interference, SI) 问题, 即平台自身的发射信号会对接收信号造成强烈干扰<sup>[4-6]</sup>。因此, 设计一

种高效的自干扰抵消器是实现共平台同时同频收发的关键。

由于共平台同时收发系统中的自干扰信号会通过非理想组件, 如功率放大器 (power amplifier, PA)、模拟-数字转换器 (analog-to-digital converter, ADC)、数字-模拟转换器 (digital-to-analog converter, DAC)

收稿日期: 2024-06-30

基金项目: 国家自然科学基金 (62071094, 62471111)

作者简介: 王小波, 博士生, 主要从事人工智能与无线通信融合方面的研究。

\*通信作者 E-mail: nvguxinyz@126.com

和低噪声放大器 (low noise amplifier, LNA) 等, 产生非线性失真, 通常使用多项式模型来表征非线性自干扰信号。这种方法计算复杂高、模型参数量大, 并且随着非线性阶数的增加而显著增加。因此学者提出了许多基于神经网络 (neural network, NN) 的方法对非线性自干扰信号进行建模<sup>[7-14]</sup>。

实数神经网络 (real-valued neural network, RVNN) 干扰对消器首先被提出用于对自干扰信号的非线性部分进行建模<sup>[7]</sup>; 随后, 文献 [10] 提出了复数前向神经网络干扰对消器。文献 [12] 中提出了两种低复杂度的复数神经网络 LWGS 和 MWGS, 用于拟合非线性自干扰。2024 年, 文献 [14] 提出了实数神经网络的 KD-MCNN 模型, 在模型效果和复杂度上性能都得到提升。

近年来, 随着深度学习技术的飞速发展, 复数神经网络 (complex-valued neural networks, CVNN) 因其能够直接处理复数域数据而在信号处理领域广泛使用<sup>[15]</sup>。本文设计了一种基于复数神经网络的共平台同时收发系统自干扰对消器, 通过深度学习的方法实现对自干扰信号的高精度预测和有效消除。

## 1 系统模型

### 1.1 共平台同时收发系统

共平台同时收发基带信号模型如图 1 所示, 在时刻  $n$  发送数字基带复数信号  $x(n)$ , 首先经过数字模拟转换器和低通滤波器 (low pass filter, LPF), 将数字信号转化为模拟信号, 然后通过 IQ 混频器, 将信号进行上变频, 得到信号  $x_{IQ}(n)$ 。假设

DAC 和 LPF 是理想器件,  $x_{IQ}(n)$  的数值基带等效表达式可以表示为:

$$x_{IQ}(n) = \frac{1}{2}(1 + \varphi e^{j\theta})x(n) + \frac{1}{2}(1 - \varphi e^{j\theta})x^*(n) \quad (1)$$

式中,  $\varphi$  和  $\theta$  分别表示 IQ 混频器的增益和相位失真因子。混合后的信号经过可变增益放大器 (variable gain amplifier, VGA) 和功率放大器, 由于放大器的非线性特性, 得到的信号  $x_{PA}$  可以由 parallel Hammerstein 模型表示为<sup>[6]</sup>:

$$x_{PA}(n) = \sum_{\substack{p=1 \\ p \text{ odd}}}^P \sum_{m=0}^M h_{m,p} x_{IQ}(n-m)^{\frac{p+1}{2}} x_{IQ}^*(n-m)^{\frac{p-1}{2}} \quad (2)$$

式中,  $h_{m,p}$  表示 parallel Hammerstein 模型的冲击响应;  $M$  和  $P$  分别表示功率放大器的记忆深度和非线性阶数。假设低通滤波器、带通滤波器 (band pass filter, BPF) 和模拟数字转换器是理想器件, 下变频采样得到的自干扰信息  $y_{SI}(n)$  可以表示为:

$$y_{SI}(n) = \sum_{l=0}^{L_C-1} h_{SI}(l) x_{PA}(n-l) \quad (3)$$

式中,  $L_C$  表示信道的记忆长度;  $h_{SI}(l)$  表示信道的冲击响应。将  $x_{PA}$  展开可以得到接收端干扰信号的表达式为:

$$y_{SI}(n) = \sum_{\substack{p=1 \\ p \text{ odd}}}^P \sum_{q=0}^p \sum_{m=0}^{T-1} h_{p,q}(m) x_{IQ}(n-m)^q x_{IQ}^*(n-m)^{p-q} \quad (4)$$

式中,  $T = M + L_C$ , 表示整个系统的记忆长度,  $h_{p,q}(m)$  表示系统的冲击响应。

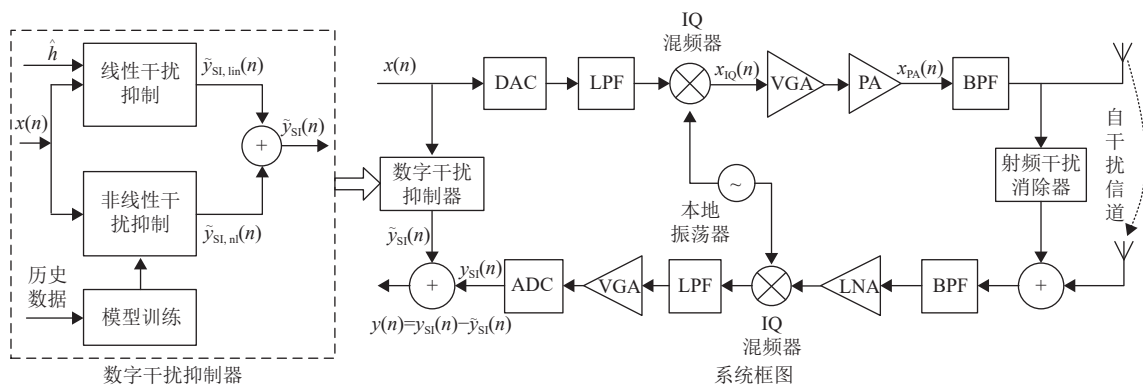


图 1 共平台同时收发系统自干扰数字对消模型

### 1.2 线性干扰对消器与非线性干扰对消器

通常, 数字干扰信号可以由线性干扰和非线性干扰两部分组成, 干扰信号的估计值可以分为线性部分和非线性部分分别估计:

$$\tilde{y}_{SI}(n) = \tilde{y}_{SI,lin}(n) + \tilde{y}_{SI,nl}(n) \quad (5)$$

式中,  $\tilde{y}_{SI,lin}(n)$  和  $\tilde{y}_{SI,nl}(n)$  分别表示干扰的线性部分和非线性部分; 其中线性干扰部分可以表示为:

$$\tilde{y}_{SI,lin}(n) = \sum_{m=0}^{T-1} \hat{h}_{1,1}(m) x_{IQ}(n-m) \quad (6)$$

线性干扰计算所需的 FLOPs 和实数参数量可以

分别表示为  $10T-2$  和  $2T$ <sup>[11]</sup>；非线性干扰可以表示为：

$$\tilde{y}_{\text{SI},nl}(n) = g\{x_{\text{IQ}}(n), x_{\text{IQ}}(n-1), \dots, x_{\text{IQ}}(n-T+1)\} \quad (7)$$

式中， $g\{\cdot\}$  表示非线性函数。

接收信号减去干扰信号估计值即得到信号残差  $y(n)$ ，可以表示为：

$$y(n) = y_{\text{SI}}(n) - \tilde{y}_{\text{SI}}(n) \quad (8)$$

数字自干扰消除降噪比（单位 dB）可以定义为：

$$C = 10 \lg \left( \frac{\sum_n |y_{\text{SI}}(n)|^2}{\sum_n |y(n)|^2} \right) \quad (9)$$

### 1.3 多项式干扰对消器

多项式数字干扰对消器是通过预估式（4）中的参数  $h_{p,q}$  进行干扰重建，当  $P \geq 3$  时，多项式干扰对消器总的实数参数量可以表示为<sup>[7]</sup>：

$$P_{\text{poly}} = 2T \left( \frac{P+1}{2} \right) \left( \frac{P+1}{2} + 1 \right) \quad (10)$$

可以看出，参数量随着多项式的阶数增加呈指数增长。多项式对消器的实数计算复杂度可以表示为<sup>[9]</sup>：

$$F_{\text{poly,mul}} = 3T \left( \frac{P+1}{2} \right) \left( \frac{P+1}{2} + 1 \right) \quad (11)$$

$$F_{\text{poly,add}} = 7T \left( \frac{P+1}{2} \right) \left( \frac{P+1}{2} + 1 \right) - 2 \quad (12)$$

$$F_{\text{poly}} = F_{\text{poly,mul}} + F_{\text{poly,add}} \quad (13)$$

式中， $F_{\text{poly,mul}}$ 、 $F_{\text{poly,add}}$  分别表示乘法操作和加法操作数； $F_{\text{poly}}$  表示计算所需总的浮点运算次数（floating point operations, FLOPs）。

## 2 基于复数卷积网络的干扰对消器设计

### 2.1 卷积神经网络

卷积神经网络（convolutional neural network, CNN）通过稀疏连接和权重共享降低了模型的参数量。CNN 中的多级分组操作，如最大池化，增强了模型对数据噪声的容忍度，提升了模型的鲁棒性<sup>[16]</sup>。

一维 CNN 在信号处理领域得到了广泛应用<sup>[17-19]</sup>，在处理时序信号时具有独特的优势。一维 CNN 的前向传播可以表达为<sup>[20]</sup>：

$$y_k^l = f_l \left( \sum_{i=1}^{C_{\text{in}}^l} \text{Conv1D}(x_i^l, w_{i,k}^l) + b_k^l \right) \quad (14)$$

式中， $y_k^l$ 、 $b_k^l$  和  $w_{i,k}^l$  分别表示一维 CNN 网络的第  $l$  层的第  $k$  个输出通道的输出值、偏置参数、和权重参数； $f_l$  和  $C_{\text{in}}^l$  分别表示一维 CNN 网络的第  $l$  层的激活函数和输入通道数； $\text{Conv1D}(\cdot)$  表示一维卷积操作。

一维 CNN 每一层的计算复杂度可以由加法操作次数  $N_l(\text{add})$  和乘法操作次数  $N_l(\text{mul})$  来表示：

$$N_l(\text{mul}) = C_{\text{in}}^l C_{\text{out}}^l L_x^l L_f^l \quad (15)$$

$$N_l(\text{add}) = C_{\text{in}}^l C_{\text{out}}^l L_x^l L_f^l \quad (16)$$

每一层的参数量  $P_l$  可以表示为：

$$P_l = C_{\text{in}}^l C_{\text{out}}^l L_f^l + C_{\text{out}}^l \quad (17)$$

式中， $C_{\text{out}}^l$ 、 $L_x^l$  和  $L_f^l$  分别表示一维 CNN 网络第  $l$  层的输出通道数、输出数据长度和卷积核长度。

### 2.2 复数神经网络

CVNN 是实数神经网络在复数域的扩展，与实数神经网络相比，复数神经网络能够更有效地处理复数信号，如无线通信中的复数调制信号。复数神经网络的设计和训练涉及复数权重和复数激活函数，这使得它们在处理相位信息和幅度信息方面更为灵活<sup>[15]</sup>。

#### 1) CVNN 的参数效率

考虑一个典型的复数一维卷积层，其中连接  $C_{\text{in}}$  个复数输入通道到  $C_{\text{out}}$  个复数输出通道的三维复数张量  $W$ ，其核的长度为  $m$ 。因此  $W$  是一个大小为  $C_{\text{in}} C_{\text{out}} m$  的复数张量，相当于  $2C_{\text{in}} C_{\text{out}} m$  个实数参数。当使用实数一维卷积层来处理这些输入输出复数时，需要  $2C_{\text{in}}$  个实数输入通道。前  $C_{\text{in}}$  个实数通道用来表示实部，后  $C_{\text{in}}$  个通道表示虚部。由于输出值也是复数，需要  $2C_{\text{out}}$  个实数输出通道，实数一维卷积网络需要  $4C_{\text{in}} C_{\text{out}} m$  个实数参数，是复数卷积参数量的两倍，因此 CVNN 比对应的实数网络参数量更少。

#### 2) CVNN 的计算复杂度

考虑两个复数  $x_1 = a + bj$  和  $x_2 = c + dj$  之间的乘法，先计算  $s_1 = ac$ 、 $s_2 = bd$  和  $s_3 = (a+b)(c+d)$ ，使得  $x_1 x_2 = (s_1 - s_2) + (s_3 - s_2 - s_1)j$ ，这种方法需要 8FLOPs，包括 5 个实数加法和 3 个实数乘法<sup>[13]</sup>。

#### 3) 复数损失函数

假设  $x_1 = a + bj$  和  $x_2 = c + dj$ ， $x_1$  和  $x_2$  的复数均方误差（mean squared error, MSE）可以表示为：

$$\text{MSE}(x_1, x_2) = \text{mean}((a-c)^2 + (b-d)^2) \quad (18)$$

### 2.3 知识蒸馏

知识蒸馏 (knowledge distillation, KD) 是一种有效的模型压缩、性能提升技术, 在人工智能的不同领域中被广泛使用, 包括视觉识别、语音识别、自然语言处理和推荐系统, 也可用于自干扰消除<sup>[14]</sup>。在回归任务中, 目标是预测一个连续值, KD 可以使用均方误差作为损失函数来实现知识的传递。根据教师模型是否与学生模型同时更新, KD 的学习方案可以分为 3 个主要类别: 离线蒸馏、在线蒸馏和自蒸馏。

离线蒸馏整个训练过程有两个阶段: 在蒸馏前, 教师模型首先在一组训练样本上进行训练; 蒸馏时教师模型的预测输出结果用于在蒸馏过程中指导学生模型的训练。离线蒸馏的损失函数可以表示为:

$$L_{\text{offline}} = \rho L(y_s, y_t) + (1 - \rho)L(y_s, y_g) \quad (19)$$

式中,  $y_t$  和  $y_s$  分别表示教师和学生模型的预测输出;  $y_g$  表示真实值;  $\rho$  为知识蒸馏系数;  $L$  是 MSE 损失函数。当  $\rho$  设置为 0 时, 知识蒸馏任务简化为普通的回归任务。

在线蒸馏旨在提高学生模型的性能, 尤其是在参数量大、模型性能好的教师模型不可用时。如图 2 所述, 教师和学生模型同时更新, 使得知识蒸馏框架可以端到端训练<sup>[21]</sup>。在线蒸馏的损失函数可以表示为:

$$L_{\text{online}} = \rho L(y_s, y_t) + (1 - \rho)L(y_s, y_g) + L(y_t, y_g) \quad (20)$$

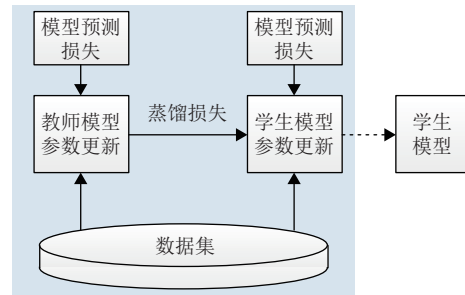


图 2 在线知识蒸馏结构图

当  $\rho$  设置为 0 时, 可以忽略教师模型的影响, 教师模型和学生模型将独立训练。

自蒸馏通过网络收缩来提高 CNN 的性能。首先将网络分割成多个层或部分, 然后将深层的知识蒸馏回较浅的层<sup>[22]</sup>, 以提升模型本身的有效性。

### 2.4 复数卷积神经网络干扰抵消器

基于 Mish 激活函数的复数卷积神经网络 (Mish-based complex valued CNN, M-CVCNN) 采用一维复数神经网络作为基础结构, 并使用 Mish 函数作为模型的激活函数。它继承了一维 CNN 的优点, 并扩展到复数输入, M-CVCNN 模型结构及训练方法如图 3 所示。

采用在线蒸馏的方法, 避免单独训练教师模型, 同时还能进一步提升模型性能, 干扰抵消器的损失函数可以表示为:

$$\text{Loss} = \rho L(y_s, y_t) + (1 - \rho)L(y_s, y_g) + L(y_t, y_g) \quad (21)$$

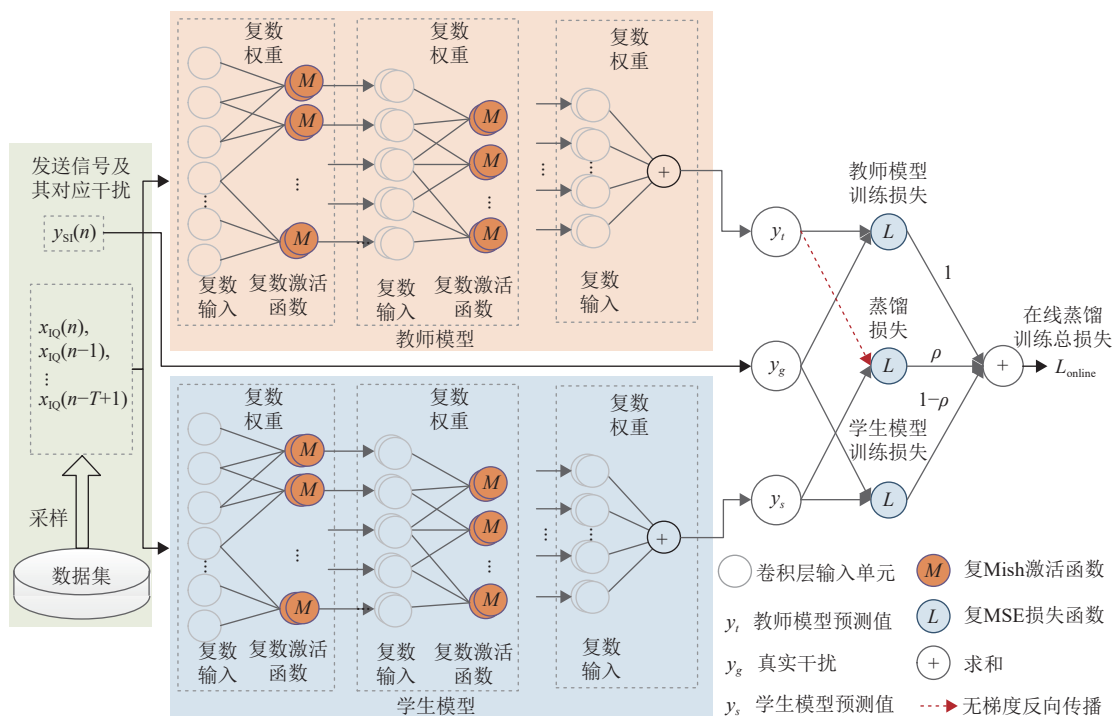


图 3 M-CVCNN 模型结构及训练方法示意图

为提高复数网络模型的表达能力,采用 Mish 函数作为网络的激活函数<sup>[23]</sup>,其计算复杂度为 10 FLOPs<sup>[14]</sup>,Mish 激活函数可以表示为:

$$\text{Mish}(x) = x \tanh(\ln(1 + e^x)) \quad (22)$$

## 2.5 M-CVCNN 干扰对消器复杂度分析

对于复数一维卷积网络,每一层的计算复杂度可以表示为:

$$F_l = 8N_l(\text{mul}) + 2N_l(\text{add}) + 2C_{\text{out}}^l F_l^{\text{Act}} L_{\text{out}}^l \quad (23)$$

式中,  $F_l^{\text{Act}}$  和  $L_{\text{out}}^l$  分别表示第  $l$  层的激活函数需要的 FLOP 和输出数据长度。

复数一维卷积网络,总的参数量可以由每一层参数量求和得到,每一层的实数参数量可以表示为:

$$P_l = 2C_{\text{out}}^l (C_{\text{in}}^l L_f^l + 1) \quad (24)$$

## 3 实验分析

### 3.1 数据集

本文使用文献 [7] 和文献 [24] 中公开的数据集。数据集 1 和数据集 2 由同时收发硬件测试平台采集得到,使用了带宽为 10 MHz 和 20 MHz 的正交频分复用 (orthogonal frequency division multiplexing, OFDM) 信号,并采用正交相移键控 (quadrature phase shift keying, QPSK) 进行调制。数据集由 20 480 个观测值组成,其中 90% 用于训练,其余用于测试。生成数据集使用参数如表 1 所示<sup>[25]</sup>。

表 1 数据集信息参数表

参数项	数据集1参数值	数据集2参数值
调制方式	QPSK调制OFDM	QPSK调制OFDM
信号带宽/MHz	10	20
载波数	1 024	2048
采样率/MHz	20	80
平均传输功率/dBm	10	32
被动模拟抑制/dB	53	15
主动模拟抑制/dB	N/A	50
总模拟抑制/dB	53	65
收发天线数量	1发1收	1发1收
数据集大小	20 480	20 480

数据集1地址: <https://github.com/abalatsoukas/fdnn>

数据集2地址: <https://github.com/abalatsoukas/CSI-full-duplex>

### 3.2 仿真设置

M-CVCNN 干扰对消器采用 Python 3.10 开发,使用 TensorFlow 和 Keras 工具作为网络开发和训练工具。训练过程采用 0.001 的学习率,批量大小为 512,数据集训练次数为 1 000,使用 Adam 优

化器进行模型优化。核参数采用 Glorot\_uniform 初始化方法进行初始化,偏置参数初始化为零。与其他基于神经网络的干扰对消器类似,M-CVCNN 在线性自干扰消除后处理非线性自干扰数据。

### 3.3 模型蒸馏实验

为了验证模型蒸馏参数  $\rho$  的取值对模型效果的影响,在数据集 1 上采用系统记忆深度  $T=13$ <sup>[14]</sup>,并分别取  $\rho$  为 [0,0.1,0.3,0.5,0.7,0.9] 进行了对比实验,其中  $\rho$  取 0 表示学生模型的训练不依赖蒸馏损失,即独立训练学生模型。实验过程采用式 (21) 作为训练的损失函数,其中  $L(y_t, y_g)$  项为教师模型损失函数部分,用以更新教师模型参数;  $L(y_s, y_t)$  是学生模型的蒸馏损失函数部分,  $L(y_s, y_g)$  是学生模型的有监督损失部分,二者共同更新学生模型参数。

表 2 的实验结果表明,对于 M-CVCNN 的教师模型,教师模型 2 的规模更大,其蒸馏效果更好;两个教师模型在  $\rho$  为 0.5 时,都获得了最好的蒸馏效果,因此在后面的训练过程中,蒸馏系数  $\rho$  设置为 0.5。

表 2 M-CVCNN 在不用蒸馏系数下学生模型非干扰抑制效果

模型	蒸馏系数 $\rho$					
	0	0.1	0.3	0.5	0.7	0.9
教师模型1	7.10	7.10	7.12	7.14	7.12	7.03
教师模型2	7.10	7.11	7.13	7.16	7.14	7.06

### 3.4 数据集 1 仿真结果

对于数据集 1,设置系统记忆深度  $T=13$ <sup>[14]</sup>,选择教师模型 2 作为实验的教师模型;M-CVCNN 模型采用不同的随机初始化参数进行了 10 次训练,基础模型和教师模型配置如表 3 所示。

表 3 M-CVCNN 模型参数配置表

模型	$C_{\text{out}}, L_k$	参数量	计算复杂度
M-CVCNN	[2,8,3,3,3,1,2]	152	2 280+62×10
M-CVCNN教师模型1	[6,8,8,3,8,3,1,2]	846	12 640+170×10
M-CVCNN教师模型2	[6,4,8,4,8,4,1,4]	1 054	26 400+298×10

表 4 中所列神经网络模型参数量和计算复杂度包括了线性降噪所需的参数量和计算量。从表 4 可以看出,经过知识蒸馏后,M-CVCNN (KD) 相对于 M-CVCNN,在不增加参数量和推理复杂度的前提下提升了 0.06 dB 非线性自干扰抑制效果;和 KD-MCNN base 模型相比,在参数量仅为 KD-MCNN base 模型参数 73.86% 的情况下,获得了相同的非线性自干扰抑制性能。

表 4 M-CVCNN 与现有模型效果及复杂度对比<sup>[4]</sup>

模型	非线性抑制比/dB	参数量	计算复杂度	参数增减比/%	复杂度增减比/%
多项式模型 ( $p=5$ )	6.59	312	1 558	—	—
KD-MCNN tiny1	6.15	139	416	-55.44	-73.30
KD-MCNN tiny2	6.33	145	436	-53.53	-72.02
MWGS (12,5)	6.54	212	1 026	-32.05	-34.15
HCRDNN (5,12)	6.55	223	725	-28.53	-53.47
DN-2HLNN (2-6)	6.58	130	608	-58.33	-60.98
HCRDNN (7,11)	6.58	248	700	-20.51	-55.07
LWGS (9)	6.62	162	782	-48.08	-49.81
CV-TDNN (7)	6.64	238	1 166	-23.72	-25.16
HCRNN (9)	6.64	229	745	-26.60	-52.18
DN-2HLNN (2-7)	6.64	138	638	-55.77	-58.54
DN-2HLNN (2-4-5)	6.65	166	782	-46.79	-49.81
KD-MCNN mini1	6.71	157	634	-49.68	-59.31
CV-TDNN (4-4-4)	6.77	228	1 106	-26.92	-29.01
RV-TDNN (10-10-10)	6.87	538	1 120	+72.44	-28.11
KD-MCNN mini2	6.87	175	686	43.91	-55.97
RV-TDNN (18)	6.90	550	1 156	+76.28	-25.80
Polynomial (P = 7)	6.94	520	2 598	+66.67	+66.75
KD-MCNN small	7.04	201	790	-32.37	-49.29
RNN (20)	7.08	528	1 210	+69.23	-22.34
M-CVCNN	7.10	178	2 720	42.95	+66.24
KD-MCNN base	7.16	241	1 000	-22.76	-35.82
<b>M-CVCNN (KD)</b>	<b>7.16</b>	<b>178</b>	<b>3 030</b>	<b>-42.95</b>	<b>+94.48</b>
Deep RNN (16-16-16)	7.41	1 420	3 106	+355.13	+99.36
KD-MCNN large	7.42	354	1 390	+13.46	-10.78
KD-MCNN huge	7.59	535	2 110	+71.47	+35.43
KD-MCNN teacher	7.70	996	3 318	+218.23	+112.97

从图 4 可以看出, 在与 KD-MCNN mini2 参数量相当的情况下, M-CVCNN (KD) 获得了 0.30 dB 的非线性干扰抑制增益, 这也证明了 M-CVCNN 在模型参数方面的优越性。数据集 1 非线性自干扰信号在 M-CVCNN (KD) 及其他参数量相近

模型处理后, 其功率谱密度如图 5 所示, 在频率为 200 KHz 时, M-CVCNN (KD) 相对于 5 阶多项式模型, 功率谱密度降低了约 1 dBm/Hz; 相对于 KD-MCNN mini2 模型, 功率谱降低了约 0.2 dBm/Hz。

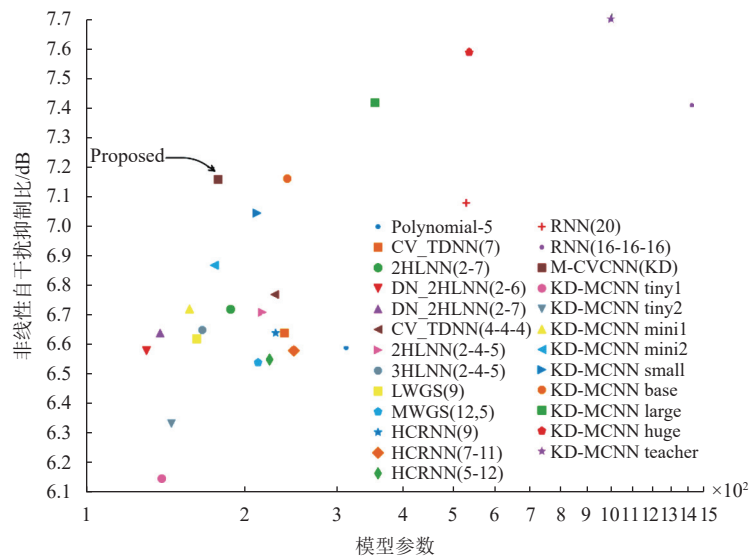


图 4 模型参数机器非线性降噪性能关系图




图 5 数据集 1 非线性自干扰抵消后功率谱密度图

### 3.5 数据集 2 仿真结果

对于数据集 2，设置系统记忆深度  $T=6$ ，M-CVCNN 模型采用不同的随机初始化参数进行了 10 次训练，基础模型和教师模型配置如表 5 所示。

表 5 M-CVCNN 模型参数配置表

模型	$C_{out}, L_k$	参数量	计算复杂度
M-CVCNN small	[2,3,4,3,1,2]	90	800+34×10
M-CVCNN base	[3,3][6,3,1,2]	170	1 560+50×10
M-CVCNN large	[4,3,8,3,1,2]	274	2 560+66×10
M-CVCNN教师模型	[5,3,10,3,1,2]	402	3 800+82×10

表 6 中所列神经网络模型参数量和计算复杂度包括了线性降噪所需的参数量和计算量。从表 6 可以看出，在数据集 2 上，M-CVCNN 相对于其他机器学习模型，在同干扰抑制比条件下，模型参数具有明显的优势。M-CVCNN small 相对于 7 阶多项式模型，性能提升了 0.99 dB，同时参数减少了 57.5%；M-CVCNN base 模型，在与 RV-TDNN (8-6) 有相近参数量的情况下，非线性降噪比提升了 3.18 dB；M-CVCNN large 模型，在与 HCRDNN (4,9,12) 有相近参数的情况下，非线性降噪比提升了 1.75 dB。数据集 2 自干扰信号经过不同非线性抑制方法处理后，其功率谱密度如图 6 所示，M-CVCNN (KD) large 在自干扰抑制后，在频率为 5 MHz 处，相对于 7 阶多项式模型，功率谱密度降低了 8 dBm/Hz；相对于 KD-MCNN base 模型，降低了约 2 dBm/Hz。

表 6 M-CVCNN 与现有模型效果及复杂度对比<sup>[14]</sup>

模型*	总干扰抑制比/dB	非线性抑制比/dB	参数量	计算复杂度	参数增减/%	复杂度增减比/%
多项式模型 (p=5)	30.36	11.25	144	718	-40.00	-40.07
多项式模型 (p=7)	30.75	11.65	240	1 198	—	—
M-CVCNN (KD) small	31.74	12.64	102	1 200	-57.50	+0.17
HCRDNN (4,9)	33.74	14.63	158	405	-34.17	-66.19
RV-TDNN (8-6)	34.07	14.96	184	386	-23.33	-67.78
HCRDNN (3,7,11)	34.61	15.50	208	506	-13.33	-57.76
RV-TDNN (7)	35.24	16.13	242	510	+0.83	-57.43
HCRNN (4,12)	35.67	16.56	236	558	-1.67	-53.42
CV-TDNN (4-4-4)	35.78	16.67	158	684	-34.17	-41.90
RNN (20)	36.53	17.42	514	1 040	+114.16	-13.19
KD-MCNN base	36.69	17.58	215	780	-10.42	-34.89
HCRDNN (4,9,12)	36.77	17.66	284	645	+18.33	-46.16
M-CVCNN (KD) base	37.25	18.14	182	2 120	-24.17	+76.96
RV-TDNN (12-10-6)	37.53	18.42	372	760	+55.00	-58.26
M-CVCNN (KD) large	38.52	19.41	286	3 280	+19.17	+173.79
RV-TDNN (12-10-6)	39.11	20.00	964	1920	+301.67	+60.27

\*表示HCRNN、HCRDNN、RNN和RC-TDNN模型，都采用ReLU作为激活函数

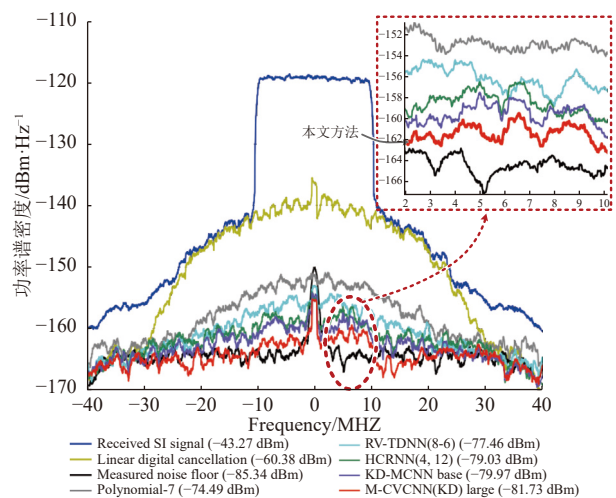


图 6 数据集 2 非线性自干扰抵消后功率谱密度图

### 3.6 M-CVCNN 实现复杂度优化

由于 M-CVCNN 采用一维复数卷积网络，未引入池化等操作，实现过程中可以通过缓存中间计

算结果来避免重复计算, 从而降低计算复杂度。如图7所示, 当数据 $X_n$ 到来时需要预测干扰信号 $Y_n$ , 可通过缓存计算 $Y_{n-1}$ 时得到的中间结果, 如图中橘黄色单元, 避免重复计算, 降低计算量; 预测干扰 $Y_n$ 时只需计算蓝色节点, 即每一层的 $L'_k$ 为1。




图7 一维复数卷积网络中间结果缓存示意图

对于数据集1所构建 M-CVCNN 模型, 通过引入 26 个存储单元, 存储 13 个复数结果, 可将原来非线性干扰抑制部分的计算复杂度由 3 030 FLOPs 降至 830 FLOPs, 总的计算复杂度缩减为 960 FLOPs; 相对 KD-MCNN base 模型, 在获得相同模型效果的情况下, 计算复杂度降低 4%。对于数据集 2 所构建的 M-CVCNN small、M-CVCNN base 和 M-CVCNN large 这 3 个模型, 分别通过引入 16、24 和 32 个存储单元, 即可将 M-CVCNN 模型的计算量降至 500, 930 和 1 480, 达到与现有模型相当的计算复杂度。

### 3.7 结果分析

对于 M-CVCNN 自干扰抑制器, 由于采用了复数神经网络, 在降低模型参数的同时, 也增加了计算的复杂度。

1) M-CVCNN 相对于对应结构的实数网络, 计算复杂度有所提升, 由于采用复数网络, 利用 CNN 网络的权重共享机制, 有效地减少了所需的模型参数数量; M-CVCNN 在实现过程中, 通过缓存中间计算结果, 降低了计算复杂度。

2) 引入 Mish 激活函数增强了模型容量, 从而提高了模型整体性能。

3) 整体模型基于一维卷积网络设计, 结构简单; 利用在线蒸馏方法, 在不增加模型参数数量和推理复杂度的同时, 提升了自干扰抑制性能。

## 4 结束语

本文介绍了一种基于 Mish 激活函数的复数卷

积神经网络自干扰抵消器。仿真结果表明, 与具有相同参数量的现有抵消器相比, 所提出的抵消器性能更优。对于 10 MHz 带宽数据, 在参数量仅为 178 时, M-CVCNN 干扰抵消器实现了约 7.16 dB 的非线性干扰抑制, 将残余非线性自干扰信号的功率从 -80.60 dBm 降低到 -87.77 dBm。对于 20 MHz 带宽数据, 在参数量仅为 182 时, M-CVCNN 干扰抵消器实现了约 18.14 dB 的非线性干扰抑制。在未来的工作中, 将探索在硬件上验证 M-CVCNN 干扰抵消器的性能, 并探索复数神经网络在共平台同时收发系统内的其他应用。

### 参考文献

- [1] 梁兴东, 李强, 王杰, 等. 雷达通信一体化技术研究综述[J]. 信号处理, 2020, 36(10): 1615-1627.  
LIANG X D, LI Q, WANG J, et al. Joint wireless communication and radar sensing: Review and future prospects[J]. Journal of Signal Processing, 2020, 36(10): 1615-1627.
- [2] 胡元奎, 靳学明, 范忠亮. 多功能综合射频系统技术研究[J]. 雷达科学与技术, 2015, 13(3): 233-239.  
HU Y K, JIN X M, FAN Z L. Research on multi-function integrated RF system technology[J]. Radar Science and Technology, 2015, 13(3): 233-239.
- [3] 李圣衍, 吴久涛, 江涛, 等. 多功能一体化平台实现及其关键技术研究[J]. 舰船电子对抗, 2023, 46(6): 9-14.  
LI S Y, WU J T, JIANG T, et al. Research into the realization of multifunctional integrated platform and key technologies[J]. Shipboard Electronic Countermeasure, 2023, 46(6): 9-14.
- [4] 唐友喜. 同时同频全双工原理与应用[M]. 北京: 科学出版社, 2016.  
TANG Y X. No division duplex: Full duplex principles and applications[M]. Beijing: Science Press, 2016.
- [5] ZHANG Z S, LONG K P, VASILAKOS A V, et al. Full-duplex wireless communications: Challenges, solutions, and future research directions[J]. Proceedings of the IEEE, 2016, 104(7): 1369-1409.
- [6] KORPI D, ANTTILA L, VALKAMA M. Nonlinear self-interference cancellation in MIMO full-duplex transceivers under crosstalk[J]. EURASIP Journal on Wireless Communications and Networking, 2017, 2017(1): 24.
- [7] BALATSOUKAS-STIMMING A. Non-linear digital self-interference cancellation for in-band full-duplex radios using neural networks[C]//Proceedings of the IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications. New York: IEEE, 2018: 1-5.
- [8] HIROSE A. Applications of complex-valued neural networks to coherent optical computing using phase-sensitive detection scheme[J]. Information Sciences - Applications, 1994, 2(2): 103-117.
- [9] KURZO Y, KRISTENSEN A T, BURG A, et al. Hardware implementation of neural self-interference cancellation[J]. IEEE Journal on Emerging and Selected Topics in Circuits and Systems, 10(2): 204-216.
- [10] KRISTENSEN A T, BURG A, BALATSOUKAS-STIMMING A. Advanced machine learning techniques

- for self-interference cancellation in full-duplex radios[C]//Proceedings of the 53rd Asilomar Conference on Signals, Systems, and Computers. New York: IEEE, 2019: 1149-1153.
- [11] ELSAYED M, EL-BANNA A A A, DOBRE O A, et al. Hybrid-layers neural network architectures for modeling the self-interference in full-duplex systems[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(6): 6291-6307.
- [12] 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[J]. *IEEE Communications Letters*, 2021, 25(1): 181-185.
- [13] ELSAYED M, AZIZ EL-BANNA A A, DOBRE O A, et al. Full-duplex self-interference cancellation using dual-neurons neural networks[J]. *IEEE Communications Letters*, 2022, 26(3): 557-561.
- [14] WANG X B, ZHAO H Z, HE Y M, et al. A simple neural network for nonlinear self-interference cancellation in full-duplex radios[J]. *IEEE Transactions on Vehicular Technology*, 2024, 73(7): 10817-10822.
- [15] LOPEZ-PACHECO M, YU W. Complex valued deep neural networks for nonlinear system modeling[J]. *Neural Processing Letters*, 2022, 54(1): 559-580.
- [16] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[EB/OL]. [2024-05-25]. <https://dl.acm.org/doi/10.1145/3065386>.
- [17] KIRANYAZ S, INCE T, HAMILA R, et al. Convolutional neural networks for patient-specific ECG classification[C]//Proceedings of the 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. New York: IEEE, 2015: 2608-2611.
- [18] KIRANYAZ S, GASTLI A, BEN-BRAHIM L, et al. Real-time fault detection and identification for MMC using 1-D convolutional neural networks[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(11): 8760-8771.
- [19] DE SILVA U, KOIKE-AKINO T, MA R, et al. A modular 1D-CNN architecture for real-time digital pre-distortion[C]//Proceedings of the IEEE Topical Conference on RF/Microwave Power Amplifiers for Radio and Wireless Applications. New York: IEEE, 2022: 79-81.
- [20] KIRANYAZ S, AVCI O, ABDELJABER O, et al. 1D convolutional neural networks and applications: A survey[J]. *Mechanical Systems and Signal Processing*, 2021, 151: 107398.
- [21] MIRZADEH S I, FARAJTABAR M, LI A, et al. Improved knowledge distillation *via* teacher assistant[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(4): 5191-5198.
- [22] ZHANG L F, SONG J B, GAO A N, et al. Be your own teacher: Improve the performance of convolutional neural networks via self distillation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. New York: IEEE, 2019: 3712-3721.
- [23] MISRA D. Mish: A self regularized non-monotonic neural activation function[EB/OL]. [2024-05-27]. <https://arxiv.org/pdf/1908.08681>.
- [24] JOCHEMS F, BALATSOUKAS-STIMMING A. Non-linear self-interference cancellation *via* tensor completion[C]//Proceedings of the 54th Asilomar Conference on Signals, Systems, and Computers. New York: IEEE, 2020: 905-909.
- [25] ELSAYED M, EL-BANNA A A A, DOBRE O A, et al. Machine learning-based self-interference cancellation for full-duplex radio: Approaches, open challenges, and future research directions[J]. *IEEE Open Journal of Vehicular Technology*, 2023, 5: 21-47.

编辑 叶芳