

DOI: 10.19650/j.cnki.cjsi.J2514757

基于频率特征的 TIADC 非线性校正神经网络研究*

王煜森¹, 张 益², 梅思涛², 王言立², 赵贻玖^{1,2}

(1. 电子科技大学(深圳)高等研究院 成都 611731; 2. 电子科技大学自动化工程学院 成都 611731)

摘要:模数转换器(ADC)的性能决定了采集系统的性能优劣,随着采集系统采样率和采样带宽的提升,ADC的非线性误差相较于线性误差具有更大的危害。针对频率相关的ADC非线性误差,提出了一种基于人工神经网络(ANN)校正的方法,对ADC采样数据进行数字后校正处理。该方法首先对ADC所采集的单音正弦信号进行频谱分析去除其中包含的非线性谐波失真,并以该结果作为参考真值,从频域角度对神经网络进行训练。所提方法以采集信号频谱的幅度信息作为神经网络的训练对象,将相位信息保留并在校正后对输出的幅度结果进行补偿,随后将幅度校正结果与保留的相位信息重构为复数频谱,并进行逆傅里叶变换以恢复时域信号。在实验验证中,以时间交织(TI)ADC系统为应用场景,将时间交织采样架构子ADC间的多种失配误差与子ADC的非线性误差一同校正。采用多组不同频率的单音正弦信号,按照频率分层抽样与时间分段采样相结合的策略进行数据划分与神经网络训练,并针对多音信号的校正进行了神经网络泛化性能验证,验证所提校正方法在ADC校正应用中的普适性。在一个4通道的20 GSPS采样率的TIADC硬件平台对神经网络的ADC校正性能进行了验证,所提方法保证了多音信号可以维持正确相位关系,且系统无杂散动态范围提升了36 dB。

关键词:模数转换器;人工神经网络;非线性误差;失配误差;频率特征;数字后校正

中图分类号: TN407 TH701 **文献标识码:** A **国家标准学科分类代码:** 510.40

Frequency characteristics based neural network for TIADC nonlinearity calibration

Wang Yusen¹, Zhang Yi², Mei Sitao², Wang Yanli², Zhao Yijiu^{1,2}

(1. Shenzhen Institute for Advanced Study, University of Electronic Science and Technology of China, Chengdu 611731, China;

2. School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: The performance of an analog-to-digital converter (ADC) determines the quality of the entire acquisition system. As system sampling rates and bandwidths increase, nonlinear errors become significantly more detrimental than linear errors. To address frequency-dependent nonlinear errors in ADCs, this paper proposes a novel digital post-calibration method based on an artificial neural network (ANN). This method first conducts spectral analysis on the single-tone signal sampled by the ADC to remove nonlinear harmonics, and takes this result as the reference true value to train the artificial neural network from the perspective of the frequency domain. The proposed method takes the amplitude information of the signal spectrum as the training object of the artificial neural network, retains the phase information, and compensates the output amplitude result after calibration. The amplitude result is reconstructed with the retained phase information to form a complex frequency spectrum, and an inverse Fourier transform is performed to restore the time-domain signal. For experimental validation, a time-interleaved (TI) ADC system is utilized as the application scenario, where various inter-channel mismatch errors and the non-linear error of the ADC are jointly calibrated. Using multiple sets of single-tone signals with different frequencies, the data is divided and the neural network training is conducted by combining the strategy of frequency-layered sampling and time-segmented sampling. Furthermore, the generalization performance of the multi-tone signals is also verified. The universality of the proposed method in ADC nonlinear calibration applications is demonstrated. The network is also verified on a 4-channel TIADC hardware platform with a sampling rate of 20 GSPS, resulting in an overall improvement in the spurious-free dynamic

收稿日期: 2025-12-08 Received Date: 2025-12-08

* 基金项目: 四川省自然科学基金面上项目(2024NSFSC0469)资助

range of the system by about 36 dB while ensuring that the multi-tone signals could maintain the correct phase relationship.

Keywords: ADC; artificial neural network; nonlinearity; mismatches; frequency characteristics; digital post-calibration

0 引言

作为沟通模拟世界和数字世界的桥梁,模数转换器(analog-to-digital converter, ADC)被广泛应用于无线通信、雷达探测、环境监测等各种电子设备^[1-5]。在高精度测试测量场合,ADC芯片自身的非理想特性对测量结果会造成一定的影响,例如,ADC前端采样保持电路以及转换特性的非理想特性,会使转换之后的数字信号产生额外的谐波和其他杂散,降低系统的无杂散动态范围(spurious free dynamic range, SFDR)、有效位数(effective number of bits, ENOB)等指标^[6-10]。

针对ADC的非线性特性的校正,已有大量的学者进行了研究^[11-15],主流的校正技术可以分为模拟校正技术和数字校正技术。其中,模拟校正技术是通过在模拟电路中增加或修改特定电路结构来达到校正目的,这种方法通常会较大地提高电路结构的复杂性和电路工作时序的复杂性,ADC工作速率也会受到一定限制;数字校正技术则主要将校正模块放在数字后端中,对模拟电路结构的修改比较少,通常只需要在模拟电路中添加简单的辅助结构,校正算法的适应性和可移植性强,集成度更高。文献[11]提出了一种高效自适应滤波的改进失真算法,提出数字化接收机中失真补偿的新型校正结构。文献[12]应用锯齿波作为模拟输入信号对系统进行非线性建模和校正。文献[13]设计了一种具有两级高速环路展开结构的ADC,并基于模拟电路实现了非线性补偿。文献[14]讨论了多种模拟误差源所导致SAR-ADC的非线性,并给出对应的误差诊断方法。文献[15]提出一种基于Volterra级数的动态非线性误差补偿方法,使用一组参数对多通道进行校准。上述方法对ADC的非线性校正取得了一定的效果,但仍存在需要添加新的模拟结构以及校正算法复杂等困难。

近年来,人工智能技术蓬勃发展,研究者开始关注将神经网络应用于ADC的校正^[16-20]。借鉴传统的数字后校准思路,基于神经网络的ADC校正方法通常通过训练模型并拟合误差,从采样输出中减去误差得到校准结果。文献[16]提出了一种基于卷积神经网络的光学ADC校准方法,将光子前端、电子量化与深度学习数据恢复相结合,通过线性化网络和匹配网络,分别对光学ADC单通道内的非线性误差和多通道间的时序偏移误差进行补偿。文献[17]提出了一种黑盒模型,基于多种非理想因素在频域均表现为谐波这一共性,训练一个3层全连接神经网络来直接抑制输出频谱中的谐波分量。在文

献[18]中,作者提出一种基于加性神经网络的高速ADC的校准框架,明确将非线性失真分解为静态项和动态项,分别设计静态网络和动态网络,对ADC的非线性特性进行校正。文献[19-20]均从网络映射角度入手,分别以添加映射维度和逆映射的角度,对ADC的误差进行校正。

尽管上述方法展现了神经网络对ADC校正问题的潜力,但这些方法在实际应用中存在挑战。文献[17]的模型难以对误差进行确定性解释,文献[18]中限制输入信号类型为单音信号,文献[19]增加了额外的特征维度,网络结构复杂且对模型的泛化能力有限。

此外,在工程应用中常采用时间交织(time-interleaved, TI)的多ADC并行采样架构提高系统采样率^[18-19],校正时需要将TI系统的失配误差考虑在内。

人工神经网络(artificial neural network, ANN)由于其结构规整、特征可解释性强,且有较强的非线性映射能力,被应用于各种非线性场景中。考虑到ADC非线性误差和TI系统失配误差都与输入信号的频率有强烈相关性,本文基于人工神经网络模型,提出一种使用信号频谱信息对神经网络训练的方法,对TI系统中的ADC非线性和通道失配误差进行整体校准。

1 ADC非线性映射分析

模数转换器作为沟通模拟与数字的桥梁,将采集到的数据从连续时间信号转换为离散数据点。本研究的目标是建立实测输出与理想输出之间的非线性映射关系,相较于支持向量机(support vector machine, SVM)等机器学习方法,人工神经网络的灵活性和拟合复杂非线性函数的能力更优,非常适合此类非线性建模问题。现有的基于神经网络的ADC校正方法通常以ADC采样的离散数据点为基础,实现ADC非线性映射函数的反映射,还原出ADC输入端的理想采样值。假设ADC存在非线性映射函数 $f_N(\cdot)$,其表达式如式(1)所示。

$$y_i = f_N(x_i) \quad (1)$$

式中: x_i 为ADC的理想输入离散值; y_i 为ADC的实际采样输出值。现有方法通过神经网络实现的 $f_N(\cdot)$ 反函数 $f_N^{-1}(\cdot)$,从而由 y_i 得到 x_i 的估计值 \hat{x}_i ,从而做到点对点的映射,即通过单个采样值可以得到理想的单个采样值,如式(2)所示。

$$x_i = f_N^{-1}(y_i) \quad (2)$$

这一类方法基于ADC的单元映射是双射的(bijective)这一前提,即每一个ADC的输出 y_i 有唯一对

应输入值 x_i , 这是非线性映射函数的反函数存在的充要条件。但实际情况下, ADC 中非理想因素容易使得该假设不成立, 一个输出值 y_i 可能对应多个输入值 x_i , 此时反函数不存在, 如图 1 所示。




图 1 ADC 的非理想映射示意图

Fig. 1 Diagram of non-ideal mapping for ADC

以记忆效应为例, 该种非线性引入的误差值会受到 ADC 先前输出值的影响, 因此当 ADC 包含记忆效应所造成的非线性误差时, 无法对 ADC 的输出进行唯一的映射, 此时基于反函数的 ADC 非线性校正方法无法实现。

基于上述分析, 本文采用整体映射 (global mapping, GM) 的方法, 将采样数据以 L 长度进行分段, 作为整体映射的长度, 映射关系如式 (3) 所示。

$$[x_1, x_2, \dots, x_L] \xrightarrow{GM} [y_1, y_2, \dots, y_L] \quad (3)$$

数据的长度 L 越大, 神经网络所实现的映射中对输入空间的划分更细致, 有利于减少映射中的模糊和碰撞问题; 但同样也会增加网络的开销, 并存在过拟合 (overfitting) 风险, 因此需要折中考虑。

2 误差的频率相关性分析

2.1 ADC 非线性误差

非线性是表征 ADC 性能的重要参数之一。在 IEEE 标准^[21]中, 基于 ADC 码字转换的阈值电平对微分非线性 (differential nonlinearity, DNL) 和积分非线性 (integral nonlinearity, INL) 进行了定义。

DNL 误差是相邻的输出代码之间的差异与理想值之间的差异, 反映在输出量化阶梯曲线上为某个数字码对应的实际阶梯宽度与理想值的差^[22], 通常以最低有效位 (least significant bit, LSB) 为单位表示。DNL 通常可如式 (4) 所示。

$$DNL = (V_{i+1} - V_i) / LSB - 1 \quad (4)$$

其中, V_i 表示当数字码为 i 时对应的模拟值。较大的 DNL 增加了量化结果中的噪声和寄生成分, 限制了

ADC 的性能。对于一个理想的 ADC 来说, 其微分非线性应该为 0 LSB, 也就是说每个模拟量化台阶的跳变值为精确的 1 LSB。INL 是模数转换器输出值与理想直线输出之前的差异, 使用 LSB 或满量程的百分比 (full scale range, FSR) 来度量, 通常在整个 ADC 量化范围内累加其 DNL 得到。

为了更直观展示 DNL 和 INL 对 ADC 的影响, 选择单音正弦信号作为输入进行分析。非周期信号可以看作是周期无穷长的周期信号, 而周期信号可以表示成以正弦信号为基的傅立叶级数, 因而选择正弦信号进行分析具有普适性。假设输入信号为 $x(t)$, 输出信号为 $y(t)$, 其非线性关系表示如式 (5) 所示。

$$y(t) = f(x(t)) \quad (5)$$

如果函数 $f(x)$ 在静态工作点 (例如 $x = 0$) 附近是光滑的, 那么可以展开为泰勒级数泰勒级数形式, 如式 (6) 所示。

$$y(t) = f(0) + f'(0)x(t) + \frac{f''(0)}{2!}[x(t)]^2 + \dots + \frac{f^{(n)}(0)}{n!}[x(t)]^n \quad (6)$$

对式 (6) 忽略偏移项并将各阶导数替换为常系数, 则由式 (7) 所示。

$$y(t) = a_1x(t) + a_2[x(t)]^2 + a_3[x(t)]^3 + \dots + a_n[x(t)]^n \quad (7)$$

其中, a_1 是线性项系数, $a_2 \sim a_n$ 等是非线性项系数。将正弦波 $x(t) = A\sin(\omega t)$ 代入式 (7) 可以得到:

$$y(t) = a_1A\sin(\omega t) + a_2A^2\sin^2(\omega t) + a_3A^3\sin^3(\omega t) + \dots + a_nA^n\sin^n(\omega t) \quad (8)$$

利用三角恒等式, 可以将高次项分别展开为不同频率的正弦波分量, 如式 (9)、(10) 所示。

$$\sin^2(\omega t) = \frac{1}{2} - \frac{1}{2}\cos(2\omega t) \quad (9)$$

$$\sin^3(\omega t) = \frac{3}{4}\sin(\omega t) - \frac{1}{4}\sin(3\omega t) \quad (10)$$

根据式 (9)、(10) 可知, 输出信号 $y(t)$ 可以表示为多个频率分量的叠加, 包括基波和其高次谐波, 即 ADC 的 DNL 和 INL 所导致的非线性失真在频域的主要表现形式是谐波失真, 频率间存在整数倍的关系。

2.2 TIADC 失配误差

TIADC 中的失配误差最早在 1980 年被 Black 等^[5]提出, 通常包括偏置、增益和时间 3 种失配误差。偏置失配误差与输入信号无关, 出现在固定位置, 因此本研究重点分析增益失配和时间失配误差与输入信号的频率相关性。

增益失配误差是指由于 TIADC 的不同通道之间具有不同的增益系数而导致的误差。如果某个通道有增益

误差,那么不同通道的输入信号会被放大或者缩小不同的倍数,因此就产生了增益失配。

假设存在一个只包含增益失配的 TIADC 系统,其输入为单音信号 $x(t) = A\sin(\omega_0 t)$, 此时 TIADC 系统的输出 $y(t)$ 可以表示为式(11),即:

$$y(t) = \sum_{n=0}^{M-1} \sum_{k=-\infty}^{+\infty} g_n x(t) \delta(t - kMT_s - nT_s) \quad (11)$$

式中: g_n 是通道增益; T_s 是采样间隔。将式(11)变换至频域得到式(12),即:

$$Y(j\omega) = \frac{1}{2\pi} \sum_{n=0}^{M-1} g_n X(j\omega) * \frac{2\pi}{MT_s} \sum_{k=-\infty}^{+\infty} \delta\left(\omega - k\frac{\omega_s}{M}\right) e^{-jk n \frac{2\pi}{M}} = \sum_{n=0}^{M-1} \sum_{k=-\infty}^{+\infty} \frac{A\pi g_n}{jMT_s} \left[\delta\left(\omega - \omega_0 - k\frac{\omega_s}{M}\right) - \delta\left(\omega + \omega_0 - k\frac{\omega_s}{M}\right) \right] e^{-jk n \frac{2\pi}{M}} \quad (12)$$

其中,“*”代表卷积符号, ω_s 是采样频率。

由式(12)可以得到,增益失配误差的误差谱线频率与输入信号的频率和 TIADC 系统的采样频率有关,且会固定出现在 $(k\omega_s/M) \pm \omega_0$ 处,增益失配误差的幅度大小则与增益以及单通道采样率有关。

时间失配误差通常由输入信号经过模拟前端部分的群延时和采样时钟的相位偏差引入^[23]。假设存在一个只包含时间失配的 TIADC 系统,其存在 Δt 的采样时间偏移,输入同样为 $x(t) = A\sin(\omega_0 t)$, 此时系统的输出 $y(t)$ 可以表示为式(13),即:

$$y(t) = \sum_{n=0}^{M-1} \sum_{k=-\infty}^{+\infty} x(t - \Delta t_n) \delta(t - kMT_s - nT_s) \quad (13)$$

将式(13)变换至频域可得式(14),即:

$$Y(j\omega) = \frac{1}{2\pi} \sum_{n=0}^{M-1} X(j\omega) * \frac{2\pi}{MT_s} \sum_{k=-\infty}^{+\infty} \delta\left(\omega - k\frac{\omega_s}{M}\right) e^{-jk n \frac{2\pi}{M}} = \sum_{n=0}^{M-1} \sum_{k=-\infty}^{+\infty} \frac{A\pi}{jMT_s} X\left(\omega - k\frac{\omega_s}{M}\right) e^{-jk n \frac{2\pi}{M}} e^{-j\omega_0' n} \quad (14)$$

其中, $r_n = T_s \Delta t_n$ 是以采样时间间隔为单位基的相对采样时刻误差。

由式(12)、(14)可知,时间失配误差与增益失配误差类似,都与输入信号的频率及幅值有关,而且它们产生的误差谱线处在相同的频率位置。

3 基于频率特征的网络训练方法

由第2章的分析可知,ADC 的非线性误差和 TIADC 系统的失配误差都具有明确的频率相关特性,采用频域数据进行神经网络训练更有益于捕获其误差特征。整体的训练流程如图2所示。

3.1 基于频域分析的真实值近似方法

在采样系统中,ADC 实际输出信号 $y(n)$ 进行误差




图2 基于频率特征的网络训练流程

Fig. 2 Flowchart of network training based on frequency features

估计时,误差估计结果本身与真实误差会存在较大偏差, $y(n)$ 中本身所含有的非线性误差等会产生更多的谐波杂散信号。为了解决这个问题,在构造误差信号时,应使参与误差估计的序列尽可能接近真实值。

常见的处理方式是采用三参数正弦拟合的方法,由已知频率的采集数据拟合出输入信号的幅度、相位和偏置^[24],但其无法分离谐波,拟合的是包含谐波的总信号,且只适用于单音信号。文献[19]中采用一种基于最小二乘法直接拟合的真值获取方法,但需要输入信号的表达式已知,且输出信号不包含表达式以外的其他误差。本文采用一种基于频域分析的参考真值获取方法,通过频域处理将谐波和杂散的能量移除,并将移除的能量加在信号主瓣上从而获得真值。该方法能够精确识别和分离各次谐波,为神经网络提供纯净的基波信号作为参考真值,且可以处理如线性调频信号和双音信号等多种类型的信号。需要注意的是,该方法对于具有频谱混叠的信号并不适用,这类信号被排除在训练集外或采用其他处理方式。

相比较而言,频域分析生成的参考信号更接近物理上无失真的信号,而三参数拟合生成的是数学上最优的正弦近似。对于神经网络来说,神经网络学习的是失真模式本身,因此频域分析的方法在本研究的场景中更加适用。需要注意的是,网络训练过程中仅使用了频谱的幅度作为训练目标,相位信息保留并在幅度校正后重新添加。

对 ADC 采样序列 $y(n)$ 做快速傅里叶变换 (fast Fourier transform, FFT) 得到 $Y(j\omega)$, 随后从其频谱数据中减去误差得到 X_g , 再做傅里叶反变换就得到“线性化”的

ADC 输出如式 (15) 所示。

$$x_g(n) = \text{IFFT}(X_g) = \text{IFFT}(G(Y(j\omega))) \quad (15)$$

其中,函数 $G(\cdot)$ 表示对频谱做去误差处理,得到 X_g 用于网络训练; $x_g(n)$ 是近似时域真值,用作结果验证。

3.2 神经网络结构设计

在高速率实时后校正的应用场景下,硬件平台如现场可编程逻辑门阵列 (field programmable gate array, FPGA) 的乘法器和寄存器等资源有限。在设计时需要保证足够非线性容量的同时,避免因网络过深或过复杂而导致的过拟合和计算开销增大。基于第 2 章和 3.1 节的推导,本文所使用的以频域数据训练的神经网络结构图如图 3 所示。




图 3 神经网络结构

Fig. 3 Diagram of neural network structure

图 3 中, L 为本研究设定的整体映射的数据长度,此时对序列做 FFT 的频率分辨率表达式如式 (16) 所示。

$$\Delta f = f_s / L \quad (16)$$

由式 (16) 可知,更长的序列包含了更丰富的时频域信息,为网络提供了更高分辨率的输入视图,使其能够捕捉到更细微的误差模式,从而实现对输入空间更细致的划分。但 L 过大会导致网络参数增加,且导致过拟合的风险上升。因此,对于数据长度 L 的选取需要综合考虑。

Y 是 ADC 采样输出序列 $y(n)$ 做 FFT 后的频谱数据,通过神经网络得到校正后的频谱 \hat{X} , 对其做 IFFT 得到输入信号的校正值 $\hat{x}(n)$ 。隐藏层包含 64 个神经元,采用双曲正切函数 (tansig) 作为激活函数,数学表达式如式 (17) 所示。

$$\text{tansig}(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (17)$$

隐藏层的计算表达式如式 (18) 所示。

$$\mathbf{a}_1 = \text{tansig}(\mathbf{w}_1 \cdot Y + \mathbf{b}_1) \quad (18)$$

其中, \mathbf{w}_1 是包含 64 个权重值的连接权重矩阵, \mathbf{b}_1 是包含 64 个偏置值的偏置项矩阵。输出层的计算表达式如式 (19) 所示。

$$a_2 = \mathbf{w}_2 \cdot \mathbf{a}_1 + b_2 \quad (19)$$

式中: \mathbf{w}_2 是包含 64 个权重值的连接权重矩阵; b_2 是 1 个偏置值。

训练过程中,优化目标以均方误差损失函数实现,表达式如式 (20) 所示。

$$\text{Loss}(x, y) = \frac{1}{n} \sum_{i=1}^n (x - y)^2 \quad (20)$$

该损失函数通过最小化预测输出与真实输出之间的误差,使得模型输出更加精确。

3.3 训练数据

该网络的训练数据来源于一个实际的四通道 TIADC 系统,从硬件平台中采集多组不同频率的正弦波数据,并存储作为数据集。实验平台的硬件原型如图 4 所示。该平台的系统总采样率为 20 GSPS,子通道采样率为 5 GSPS。




图 4 硬件平台

Fig. 4 Hardware prototype

在硬件平台中,信号发生器产生正弦波信号送入采集系统硬件平台,经过信号调理后送入采集板,由 4 个子 ADC 按照时间交织方式进行采集。随后,采集数据传输至 FPGA 处理,并送入双倍速率随机存储器 (double data rate synchronous dynamic random access memory, DDR SDRAM) 进行存储。通过主控板与工控机 (industrial personal computer, IPC) 进行数据和控制指令的传输,将采集到的数据通过网线传输给工控机,进行神经网络训练。此外,主控板连接了显示器,用于波形数据显示功能。

在硬件 TIADC 平台的采集带宽范围内,间隔 50 MHz 频率,共采集了 160 组单音正弦波信号,每组频率值经过多次采集获取 100 000 个数据点。

4 结果验证

4.1 数据划分

针对 160 组不同频率采集的长时间序列数据,本研究采用频率分层抽样与时间分段采样相结合的策略进行数据划分与训练。首先将 160 个频率点排序后按比例分层划分至训练集(128 组)、验证集(16 组)和测试集(16 组),确保各集合在全频段均匀分布。对于每组 10 万点的长序列,进一步采用分段采样将其划分为若干等长子序,作为模型输入的基本单元。

训练时设置批次大小为 64,通过 Adagrad 优化器和 MSE 损失函数进行优化。该方案在保证频率覆盖完整性的同时,通过分段处理解决了长序列的计算负担,使神经网络能够有效学习跨频率的时序特征并具备良好的泛化能力。

4.2 数据长度对比实验

对硬件平台采集到的信号做 FFT($L=10\ 000$),其结果如图 5 所示。从图 5 的频谱结果可以看出,对于 1.801 GHz 的单音正弦波输入信号,所采集的信号中较大的误差频谱有非线性误差所产生的位于 3.602 GHz 的二次谐波、位于 5.403 GHz 的三次谐波和失配误差所产生的位于 8.199 GHz 处的杂散,同时还包括了其他的较小误差频谱,严重损害了系统的 SFDR。




图 5 带有误差的 TIADC 输出频谱

Fig. 5 Spectrum of TIADC output with errors

以不同数据长度 L 训练后的神经网络进行误差校正,其校正后的频谱如图 6~8 所示。其中,图 6 所示的网络的数据长度 L 设置为 5 000,图 7 所示的网络的数据长度 L 设置为 10 000,图 8 所示的网络的数据长度 L 设置为 20 000。

从图 6~8 可以看出,本研究训练的网络对前文所分析的非线性误差和失配误差进行校正,各项误差均被抑制到噪声水平。由于网络训练的输入是频域特征,其对

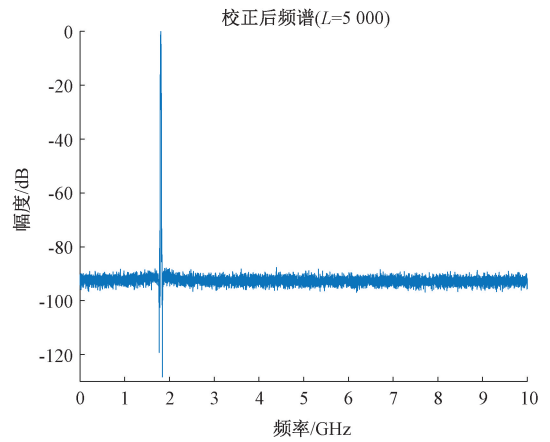


图 6 单音信号校正后频谱($L=5\ 000$)

Fig. 6 Spectrum of calibrated single-tone signal with $L=5\ 000$

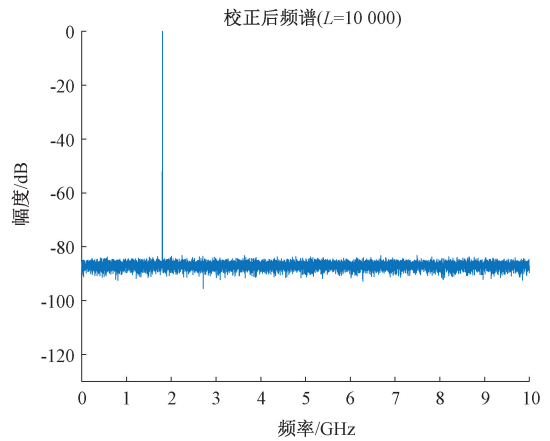


图 7 单音信号校正后频谱($L=10\ 000$)

Fig. 7 Spectrum of calibrated single-tone signal with $L=10\ 000$




图 8 单音信号校正后频谱($L=20\ 000$)

Fig. 8 Spectrum of calibrated single-tone signal with $L=20\ 000$

除了基波外的其他成分均进行了一定程度的抑制,极大提升了系统的性能,校正后系统 SFDR 提升约 40 dB。

图6中网络的数据长度 L 设置过小,此时输入数据频谱的频率分辨率较低,信号出现了频谱泄露的现象,使得校正结果不理想。图7、8的数据长度 L 足以准确分辨输入信号的频率,没有出现频谱泄露现象。此外,校正后频谱的噪声水平也随着 L 值的增大有所减小,趋于平滑。

总体而言,增大数据长度 L 可以通过提供充足的时频域信息来有效抑制频谱泄露,并通过对噪声的平滑效应降低噪声底。然而,增大数据长度会使网络参数增加,且会因过拟合而学习训练数据中的随机噪声,导致泛化性能下降,甚至引起性能恶化。因此,数据长度对比实验的核心是为性能和复杂度的综合考量提供支撑。

4.3 多音信号校正

为了验证该网络的泛化能力,采用不同幅度的多音输入进行验证。多音信号包含更复杂的频率成分和互调干扰等,其特性与训练所用的单音信号有显著差异。以包含频率1.401、3.351和4.801 GHz的三音信号为例,其中,对频率为4.801 GHz的信号成分进行了幅度衰减,其校正前后的频谱分别如图9、10所示。




图9 带有误差的三音信号频谱

Fig. 9 Spectrum of three-tone signal with errors




图10 三音信号校正后频谱

Fig. 10 Spectrum of calibrated three-tone signal

从图9中可以看出,输入三音信号包含了较大的非线性误差和失配误差,其中最大的误差谱线是4.801 GHz输入信号引入的失配误差,此时系统的SFDR仅有约30 dB。在图10校正后的频谱中,尽管仍有误差谱线存在,但其幅度已被抑制到较低的水平,3个正弦信号的基波幅度与输入时保持一致的大小比例,此时系统的SFDR约为66 dB,校正网络将系统SFDR提升约36 dB。

为了保证多音信号在校正后可以保持正确的相位关系,本研究在3.1节中提到,将频谱的相位信息保留并在校正后重新添加。对该处理方法进行验证,三音信号校正前后的时域波形对比如图11所示。




图11 校正前后时域波形对比

Fig. 11 Waveform comparison before and after calibration

由图11可以看出,校正前后的信号时域波形基本一致,由于对误差频率成分进行了抑制,波形细节上有所不同。图11说明了保留相位的方法可以正确恢复多音信号的相位关系。

与单音信号的校正实验进行对比,单音信号校正后系统SFDR提升约40 dB,除基波外其余误差均被抑制到噪声水平;多音信号校正后仍有较小的误差谱线存在,系统SFDR提升约为36 dB。三音信号的频率组合与训练集不重叠,证明了模型具有对未见信号类型的泛化能力。

综上所述,本节的验证结果表明了本文提出的基于频率特征训练的神经网络在TIADC的校正应用中可以覆盖一定的误差变化并实现对非线性误差和失配误差的有效校准,且在多音信号场景中可以保证频率成分具有正确的相位关系,实现波形恢复。

4.4 方法对比

表1为本文所提出方法与其他相关方法的对比,对比内容包括校准对象、ADC架构依赖性、参考真值获取方法、验证平台及信号类型以及SFDR改善。

表1 本文方法与其他方法的对比
Table 1 Comparison with other methods

文献	校准对象	ADC 架构依赖	真值获取方法	核心原理	测试平台	信号类型	SFDR 改善/dB
[18]	静态、动态非线性	SAR ADC	正弦拟合	静态+动态网络	5 GSPS TIADC	单音	20
[20]	非线性谐波	通用	EBSM 生成	逆向映射	12 位高精度 ADC	单音、多音	30
[25]	非线性误差	Pipelined ADC	正弦拟合	黑盒式映射	14 位高精度 ADC	单音、双音、AM、FM	27
本文	非线性误差、失配误差	通用	频谱分析	频域训练	20 GSPS TIADC	单音、多音	36

文献[18,20,25]都针对 ADC 的非线性误差校准进行了研究,其中文献[18]将非线性分为了静态和动态两种类型;本文在非线性误差之外,将 TIADC 的失配误差也综合考虑。文献[18,25]用到了级间增益等 ADC 的器件内数据,真值采用正弦拟合的方法获取;而文献[20]和本文的方法则是使用 ADC 的输出采样结果,对 ADC 的类型没有限制,文献[20]采用实验频谱模型(experiment-based spectrum model,EBSM)生成真值,本文则采用频谱分析的方法获取。

对于网络性能验证,文献[20,25]采用高精度采集系统,对单音信号、多音信号以及调制波形输入进行验证;文献[18]在 5 GSPS 的 TIADC 系统中,仅使用了单音信号进行验证,系统 SFDR 均得到提升。本文使用单音信号和多音信号进行校正,在 20 GSPS 采样率的 TIADC 系统进行验证,系统的 SFDR 提升达到 36 dB。

综上所述,本文方法采用适合频域特征训练的真值获取方法,所训练网络在校正误差种类、架构通用性、以及 SFDR 提升方面具有优势,为 ADC 非线性和 TIADC 系统失配误差的数字校正提供了一种更有效的解决方案。

5 结 论

针对 TIADC 系统中的非线性杂散和失配误差的校正,本文基于人工神经网络和整体映射机制,提出一种利用频域数据进行网络训练的方法,对误差进行数字后校正。对实际硬件平台采集的数据通过频率分层抽样与时间分段采样相结合的策略进行数据集划分,并采用频域分析的方法对采集数据处理获取参考真值。以一个 4 通道的 20 GSPS 的 TIADC 系统进行验证,单音信号校正后系统 SFDR 提升约 40 dB,多音信号校正后系统 SFDR 提升约为 36 dB。在多音信号校正中,校正网络维持了各信号成分间的幅度关系和相位关系,在对非线性误差和失配误差校正后,正确完成对多音信号的波形恢复。本研究不依赖 ADC 的具体电路实现架构,以频率特征角度对

TIADC 校正网络进行训练,为相关的神经网络校正方法提供了新的思路。

参考文献

- [1] ALJOHANI M, ABDELBAĞI H, LO MONTE L, et al. ISAR imaging with pseudo-coherent marine radars [C]. International Conference on Radar Systems (Radar 2017), 2017:1-5.
- [2] GÓMEZ-GARCÍA R, MUÑOZ-FERRERAS J M, SÁNCHEZ-RENEDO M. Multi-band pre-selectors for software-defined radio receivers [C]. 2013 IEEE Radio and Wireless Symposium, 2013: 13-15.
- [3] LEE W Y, KIM K, HONG S. ADC resolutions of MIMO systems in structured code schemes on a discrete memoryless symmetric channel environment [C]. 2017 International Conference on Computational Science and Computational Intelligence, 2017:1820-1821.
- [4] 郑彦泽,周乃馨,赵贻玖,等. 混合并行交替最优采样技术研究[J]. 电子测量与仪器学报, 2023, 37(4): 18-26.
ZHENG Y Z, ZHOU N X, ZHAO Y J, et al. Optimal configuration analysis of hybrid parallel interleaved acquisition techniques[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(4): 18-26.
- [5] BLACK W C, HODGES D A. Time interleaved converter arrays[J]. IEEE Journal of Solid-State Circuits, 1980, 15(6): 1022-1029.
- [6] 曹超,马瑞,朱樟明,等. 高精度 SAR ADC 非理想因素分析及校准方法[J]. 西安电子科技大学学报, 2015, 42(6): 61-65,87.
CAO CH, MA R, ZHU ZH M, et al. Analysis of non-ideal factors and digital calibration for high-resolution SAR ADCs[J]. Journal of Xidian University, 2015, 42(6): 61-65,87.
- [7] UM J Y, KIM Y J, SONG E W, et al. A digital-domain

- calibration of split-capacitor DAC for a differential SAR ADC without additional analog circuits [J]. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2013, 60(11):2845-2856.
- [8] 赵禹, 叶芄, 孟婕, 等. 基于带宽交织采样架构的 80 GSps 超宽带实时采集系统[J]. *仪器仪表学报*, 2024, 45(5):147-156.
- ZHAO Y, YE P, MENG J, et al. Ultra-wideband data acquisition system with 80 GSps based on bandwidth interleaved architecture[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(5):147-156.
- [9] 丁博文, 苗澎, 黎飞, 等. 500 MS/s 12 位流水线 ADC 的设计研究[J]. *电子测量与仪器学报*, 2022, 36(3):130-138.
- DING B W, MIAO P, LI F, et al. Design research of 500 MS/s 12 bit pipeline ADC[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(3):130-138.
- [10] SEROV A N, SEROV N A, DOLGATCHEVA E A. Influence of nonlinearity of ADC conversion function on RMS measurement error [C]. 2018 International Conference on Industrial Engineering, Applications and Manufacturing, 2018: 1-6.
- [11] VANSEBROUCK R, JAMIN O, DESGREYS P, et al. Digital distortion compensation for wideband direct digitization RF receiver [C]. 2015 IEEE 13th International New Circuits and Systems Conference, 2015: 1-4.
- [12] MOHAMMEDALI M A, AI-GAYEM Q. An accurate and fast method for improving ADC nonlinearity[J]. *Applied Computational Intelligence and Soft Computing*, 2023: 8899666.
- [13] LI N N, ZHANG H R, LIU B, et al. A 10-bit 500-MS/s pipelined SAR ADC with nonlinearity-compensated open-loop amplifier and parallel conversion through comparator reusing[J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2025, 72(2):354-358.
- [14] HUANG CH P, TING H W, CHANG S J. Analysis of nonideal behaviors based on INL/DNL plots for SAR ADCs [J]. *IEEE Transactions on Instrumentation and Measurement*, 2016, 65(8):1804-1817.
- [15] ZHAO Y F, WANG Y S, MEI S T, et al. Dynamic nonlinear error estimation and calibration for TIADC systems based on Volterra series [J]. *Journal of Instrumentation*, 2025, 20(4):T04007.
- [16] XU SH F, ZOU X T, MA B W, et al. Deep-learning-powered photonic analog-to-digital conversion[J]. *Light: Science & Applications*, 2019, 8(1):66.
- [17] PENG X ZH, MI Y H, ZHANG Y F, et al. A neural network-based harmonic suppression algorithm for medium-to-high resolution ADCs [C]. 2021 5th IEEE Electron Devices Technology & Manufacturing Conference, 2021: 1-3.
- [18] ZHAI D F, JIANG W N, JIA X R, et al. High-speed and time-interleaved ADCs using additive-neural-network-based calibration for nonlinear amplitude and phase distortion [J]. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2022, 69(12):4944-4957.
- [19] LU ZH F, ZHANG B W, PENG X ZH, et al. A new artificial neural network-based calibration mechanism for ADCs: A time-interleaved ADC case study [J]. *IEEE Transactions on Very Large Scale Integration Systems*, 2024, 32(7):1184-1194.
- [20] PENG Y T, XIAO Y, CHEN L, et al. A novel calibration algorithm for ADCs based on inverse mapping by neural network [J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2024, 71(7):3283-3287.
- [21] IEEE. IEEE Standard for terminology and test methods for analog-to-digital converters: IEEE Std 1241-2010 [S]. IEEE, 2011.
- [22] 侯琳杰, 解维坤, 陈世博, 等. 一种基于神经网络的 THD 参数快速估计算法[J]. *仪器仪表学报*, 2023, 44(2):101-109.
- HOU L J, XIE W K, CHEN SH B, et al. Fast estimation algorithm of THD based on artificial neural network [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(2):101-109.
- [23] NIU G SH, LIU C, ZHANG J W, et al. Research progress of time-interleaved analog-to-digital converters [J]. *Integration*, 2021, 81:313-321.
- [24] LI J Y, PAN J M, ZHANG Y. Automatic calibration method of channel mismatches for wideband TI-ADC system [J]. *Electronics*, 2019, 8(1):56.
- [25] LIU H, LU ZH F, XIAO Y, et al. A convolutional

neural network based calibration scheme for pipelined ADC [C]. 2023 IEEE International Symposium on Circuits and Systems, 2023;1-5.

作者简介



王煜森, 2023 年于电子科技大学获得学士学位, 现为电子科技大学博士研究生, 主要研究方向为宽带测试技术。

E-mail: wangyusen@std.uestc.edu.cn

Wang Yusen received his B.Sc. degree from University of Electronic Science and Technology of China in 2023. He is currently a Ph.D. candidate at University of Electronic Science and Technology of China. His main research interest includes wideband testing.



赵贻玖(通信作者), 2012 年获得电子科技大学自动化工程学院测试技术与仪器工学博士学位, 现为电子科技大学教授、博士生导师, 主要研究方向为宽带时域测试技术。

E-mail: yijiuzhao@uestc.edu.cn

Zhao Yijiu (Corresponding author) received his Ph.D. degree in measuring and testing technology and instruments from the University of Electronic Science and Technology of China in 2012. He is currently a professor and doctoral supervisor of the University of Electronic Science and Technology of China. His main research interest includes wideband time domain testing.