

CNN-Mamba 融合的 $\Sigma-\Delta$ ADC 残差校准方法

郭昊 鲍云

东华大学物理学院

DOI:10.32629/etd.v7i6.21000

[摘要] 针对电容失配、积分器非理想特性及反馈误差造成的 $\Sigma-\Delta$ ADC 精度劣化问题,本文提出一种 CNN-Mamba 融合的数字后端残差校准方法。该方法依托理想与非理想模型构建监督数据集,将非理想滤波输出作为输入,以输出残差为标签完成误差补偿预测;利用 CNN 提取局部误差特征,结合 Mamba 建模长序列依赖关系。实验结果表明,该方法无需修改模拟调制器结构,可有效抑制非理想误差,显著提升 $\Sigma-\Delta$ ADC 的输出精度。

[关键词] $\Sigma-\Delta$ ADC; 数字校准; CNN-Mamba; 残差学习; 数字滤波器

中图分类号: P631.4+24 **文献标识码:** A

A CNN-Mamba Fusion-Based Residual Calibration Method for $\Sigma-\Delta$ ADCs

Hao Guo Yun Bao

COLLEGE OF PHYSICS DONGHUA UNIVERSITY

[Abstract] This paper proposes a CNN-Mamba fusion-based digital back-end residual calibration method for $\Sigma-\Delta$ ADCs to address accuracy degradation caused by capacitor mismatch, integrator nonidealities, and feedback errors. Supervised datasets are constructed using ideal and nonideal behavioral models. The filtered output of the nonideal model is used as the network input, while the output residual is used as the training label. The CNN branch extracts local error features, and the Mamba-based branch models long-range sequence dependencies. Experimental results show that the proposed method can effectively suppress nonideal errors and significantly improve the output accuracy of $\Sigma-\Delta$ ADCs without modifying the analog modulator structure.

[Key words] $\Sigma-\Delta$ ADC; Digital calibration; CNN-Mamba; Residual learning; digital filter

引言

$\Sigma-\Delta$ ADC 依靠过采样和噪声整形技术实现高分辨率^[1]模数转换,广泛应用于低带宽、高精度检测场景。与奈奎斯特型 ADC 相比, $\Sigma-\Delta$ ADC 对模拟前端线性度、反馈 DAC 匹配精度和数字滤波链路稳定性均具有较高要求。实际电路中,开关非理想、电容失配、积分器有限增益、比较器失调、时钟抖动以及反馈路径误差会共同作用于调制器输出,使量化噪声和谐波杂散分布发生变化,最终导致 SNDR、SFDR 和 ENOB 等指标下降。

传统校准方法^[2]通常针对某一类误差源建立数学模型,例如电容失配校准、DAC 动态元素匹配、积分器增益补偿或数字滤波器系数量化优化。这类方法物理意义明确,但当多种非理想因素^{[3][4]}同时存在时,误差耦合关系较复杂,单一补偿机制难以覆盖全部失真来源。近年来,神经网络方法被引入 ADC 数字后端校准中,其核心思想是利用网络学习实际数字输出与理想数字输出之间的非线性映射关系,从而在数字域完成误差补偿。

本文面向 $\Sigma-\Delta$ ADC 数字后端,采用理想行为级模型和非理想行为级模型生成监督学习样本。考虑到直接由网络重建完整

滤波输出存在主信号幅值大、残差幅值小、训练不稳定等问题,本文采用 CNN-Mamba^[5]残差补偿结构:网络仅预测非理想输出相对于理想输出的误差项,再与原始非理想输出相加形成校准^[6]输出。该方法既保留了原数字滤波链路的主体信息,又降低了网络学习难度,更适合后续进行 RTL 友好化实现。

1 数据集构造与残差校准原理

1.1 数据集构造

本文采用两套三阶四比特 $\Sigma-\Delta$ ADC 行为级模型生成数据:一套为理想模型,另一套加入 DAC 失配等非理想因素。两者输入相同单音激励,采样频率为 5.12 MHz,OSR 为 256,对应信号带宽为 10 kHz。输入频率取 $k \times 156.25$ Hz, $k=1, 2, \dots, 48$ 。幅值范围为 0.15 至 0.85,频率范围用于覆盖主要工作带宽,幅值范围用于覆盖不同输入幅度条件,并避免过低频率导致仿真时间过长。

1.2 残差校准原理

非理想模型输出为调制器量化后的温度计码序列。由于实际数字后端接口包含温度计码转换、CIC 积分、抽取、梳状滤波、ISOP 补偿以及半带滤波等模块,本文不直接在原始调制器码流

上计算频谱指标,而是将理想模型和非理想模型的输出均送入同一数字滤波链路,得到滤波后的理想输出序列和非理想输出序列。记非理想滤波输出为 y_{non} ,理想滤波输出为 y_{ideal} ,则残差标签定义为:

$$r = y_{ideal} - y_{non} \quad (1.1)$$

神经网络输入为非理想滤波输出 y_{non} ,输出为预测残差 $\hat{r}$ 。最终校准结果为:

$$y_{cal} = y_{non} + \hat{r} \quad (1.2)$$

这种结构与直接预测 y_{ideal} 的方法不同。直接重建理想输出要求网络同时学习主信号和误差项,而在 $\Sigma-\Delta$ ADC数字滤波后,主信号幅度通常远大于非理想残差幅度,网络容易优先拟合主信号,导致残差修正能力不足。残差学习则将训练目标集中在误差分量上,使模型更加关注非理想因素引入的偏差、谐波和互调成分。

数据集采用滑动窗口方式构造。对每个case的连续输出序列,以2048点作为一个训练窗口,并设置一定步长进行滑动切分。每个样本包含一段非理想输出序列及其对应残差序列。为了避免同一case中的相邻窗口同时出现在训练集和测试集中造成数据泄漏,数据划分以case为单位进行,而不是简单按窗口随机划分。训练集用于优化网络参数,验证集用于选择模型和收缩系数,测试集则用于最终评价校准效果。

表1.2-1数据集构成

数据集	信号种类	信号数量	k 值范围	幅值范围
训练集	单音	1280	[1, 48]	[0.15, 0.85]
验证集	单音	64	[1, 48]	[0.15, 0.85]
测试集	单音	20	十个频点	[0.15, 0.85]

在数据预处理阶段,仅使用训练集统计均值和标准差,并将同一归一化参数应用于验证集和测试集。这样可以避免测试信息泄漏到训练过程。对于网络输出的归一化残差,在推理阶段再恢复到原始量纲,并与非理想输出相加得到校准序列。该流程保证了训练、验证和测试阶段的数据处理一致性。同时,为保证残差标签的可解释性,理想模型与非理想模型在输入激励、采样时钟和数字滤波配置上保持一致,仅保留非理想因素造成的输出差异。这样得到的残差能够更直接地对应DAC失配和环路非理想引入的动态误差,减少由数据处理流程差异带来的干扰。

2 CNN-Mamba融合校准模型

2.1 CNN局部误差特征提取

$\Sigma-\Delta$ ADC非理想误差在时域上并非完全随机。电容失配、反馈DAC误差和量化路径非线性往往会在相邻采样点之间形成局部相关特征,数字滤波器的卷积特性也会使局部误差在一定范围内扩展。因此,本文引入一维CNN分支提取短时段局部误差模式。

CNN分支以归一化后的非理想输出窗口为输入,首先通过因果卷积完成特征嵌入,再经过若干深度可分离卷积模块提取局部特征。因果卷积只利用当前及历史采样点信息,不引入未来信息,便于后续映射到实时数字后端。深度可分离卷积将通道内时序滤波和通道间线性组合分开处理,能够在降低参数量的同时保留局部特征提取能力。在每个卷积模块中,输入特征经过深度卷积、ReLU激活和逐点卷积后,与原输入形成残差连接。残差连接可以缓解多层网络训练中的梯度衰减问题,使模型在保留原始数字输出主要趋势的基础上学习误差修正项。CNN分支更适合捕捉由局部非线性、码间变化和滤波器短时响应造成的误差特征。

2.2 Mamba式长程序列建模

仅依靠CNN难以充分描述 $\Sigma-\Delta$ ADC中的长程相关效应。 $\Sigma-\Delta$ 调制器本身具有反馈环路,量化噪声经过噪声整形后呈现明显的频率相关性;后端CIC和半带滤波器又会进一步引入较长的时域响应。因此,本文在CNN分支之外加入Mamba式序列建模分支,以增强模型对长序列依赖的表达能力。

Mamba分支采用门控状态更新思想,将输入序列映射为隐状态,并通过递推形式描述历史信息对当前输出的影响。与传统注意力机制相比,该结构不需要计算完整的序列相关矩阵,计算复杂度更适合长序列处理。为了适应数字后端实现,本文使用RTL友好的简化结构,避免使用复杂的softmax、动态指数函数和难以硬件化的归一化操作,而采用卷积、乘法、加法、门控和寄存器状态更新等基本运算。

CNN分支和Mamba分支分别输出局部特征和长程特征,两者在通道维度上拼接后进入融合层。融合层通过逐点卷积和因果卷积完成特征压缩与交互,最终输出与输入窗口长度一致的残差序列。该结构兼顾局部误差提取和长序列误差建模,适合 $\Sigma-\Delta$ ADC数字后端中“调制器噪声整形+多级数字滤波”共同作用下的残差补偿任务。

3 训练流程与结果分析

3.1 训练设置与评价指标

训练过程采用监督学习方式。输入为非理想滤波输出窗口,标签为理想输出与非理想输出之间的残差窗口。网络预测残差后,与标签计算均方误差损失:

$$Loss = \frac{1}{N} \sum_{i=1}^N (\hat{r}_i - r_i)^2 \quad (3.1)$$

优化器采用Adam,初始学习率设置为 1×10^{-3} ,并结合验证集损失进行早停判断,以降低过拟合风险。训练过程中对梯度进行裁剪,保证长序列训练稳定性。

此外,为避免网络在局部样本上过度修正,本文在验证集上引入残差收缩系数 α ,最终校准输出写为:

$$y_{cal} = y_{non} + \alpha \hat{r} \quad (3.2)$$

当 $\alpha=1$ 时表示完全采用网络预测残差; 当 $\alpha<1$ 时表示对预测残差进行适度收缩。该策略可以提高测试集泛化稳定性, 尤其适用于训练case数量有限或不同输入频率分布存在差异的情况。训练过程中验证损失未出现持续上升趋势, 表明模型未发生明显过拟合, 并已学习到非理想模型的主要残差规律。残差式结构将训练目标集中在误差分量上, 较直接重建理想输出更易稳定收敛。评价时除观察损失曲线外, 还重点比较校准前后的 SNDR、带内杂散和噪声底变化。由于残差幅度远小于主信号, 单纯降低均方误差并不一定代表频域性能同步改善, 因此需要结合 PSD 结果判断模型是否真正抑制了失真成分。

3. 2 校准效果分析

从频域结果看, 校准前非理想输出中可能出现较明显的谐波和互调分量。加入 DAC 失配等非理想因素后, 调制器原始输出的 SNDR 为 89.8 dB。未校准前, 直接经过数字滤波器滤波后输出的 SNDR 为 46.3 dB。经残差校准后, SNDR 提升至 80.14 dB。带内杂散和部分谐波成分得到抑制, 噪声底分布更接近理想模型。由于 $k=1$ 频点对应的数据长度不满足相干采样条件, 无法计算 PSD。剔除 $k=1$ 对应样本后, 图 3.2-1 展示了其余 19 组测试样本的 SNDR 提升结果; 这些样本覆盖 9 个测试频点。表明模型不仅改善了点时域的误差, 也对频域动态性能具有修正作用。此外, 本文将测试集独立于训练频点和幅值组合设置, 目的是检验模型对未参与训练样本的外推能力, 而不仅是对已见波形的记忆。若后续引入双音或多音激励, 还可以进一步验证模型对互调失真的补偿效果。




图3.2-1测试集SNDR提升结果, 剔除 $k=1$ 频点

4 结论

本文提出了一种 CNN-Mamba 融合的 $\Sigma-\Delta$ ADC 数字后端残差校准方法。该方法利用理想行为级模型和非理想行为级模型构造监督学习数据集, 以滤波后的非理想数字输出作为网络输入, 以理想输出和非理想输出之间的残差作为标签, 通过残差叠加

方式获得校准结果。相比直接重建理想输出, 残差学习降低了网络训练难度, 使模型更加聚焦于非理想误差分量。

在模型结构上, CNN 分支用于提取局部误差特征, Mamba 式分支用于描述长序列相关性, 两者融合后能够同时处理短时非线性误差和数字滤波链路带来的长记忆效应。该结构主要由因果卷积、逐点卷积、门控状态更新和残差连接组成, 具有较好的 RTL 实现潜力。

后续工作可从三方面展开: 第一, 进一步扩大训练集覆盖范围, 引入更多频率、幅值和多音组合, 提高模型泛化能力; 第二, 结合定点量化和硬件资源评估, 完成网络参数到 RTL 结构的映射; 第三, 将行为级数据训练得到的模型迁移到电路级仿真或实测数据中, 验证其在真实非理想条件下的校准有效性。总体而言, 本文方法为 $\Sigma-\Delta$ ADC 数字辅助校准提供了一种兼顾精度提升和工程实现可行性的方案。从工程应用角度看, 本文方法可以作为模拟电路优化之外的数字辅助补偿手段, 在不增加前端电容阵列面积和运放设计压力的情况下提高系统容错能力, 便于后续扩展, 并降低系统调试与验证成本。

【参考文献】

- [1]周智.高精度 $\Sigma-\Delta$ 调制器的研究与设计[D].南京:东南大学,2019.
- [2]张章,徐姚华,解光军.一种基于LMS算法的流水线ADC数字校准算法[J].微电子学与计算机,2018,35(9):103-107.
- [3]张博文.基于Transformer/CNN混合结构的流水线ADC数字校准算法设计与实现[D].电子科技大学,[2026-05-19].
- [4]马浩.基于神经网络校准的高精度低功耗Sigma-Delta调制器设计[D].西安电子科技大学,2024.
- [5]GUA,DAOT.Mamba:Linear-TimeSequenceModelingwithSelectiveStateSpaces[EB/OL].arXiv:2312.00752,2023.
- [6]ZHAI D,JIANG W, JIA X,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.

作者简介:

郭昊(2000—),男,汉族,河南偃师人,硕士研究生,研究方向:集成电路设计,锂离子电池SOH、阻抗估计。

鲍云(1976—),男,汉族,浙江绍兴人,博士研究生,副教授,研究方向:数字集成电路设计,电子与电力系统。