

DOI: 10.19650/j.cnki.cjsi.J2210213

一种基于神经网络的 THD 参数快速估计算法*

侯琳杰¹, 解维坤^{2,3}, 陈世博¹, 刘雨涛³, 赵贻玖^{1,2}

(1. 电子科技大学(深圳)高等研究院 深圳 518110; 2. 电子科技大学自动化工程学院 成都 611731;
3. 中国电子科技集团第58研究所 无锡 214035)

摘要:模数转换器(ADC)测试主要包括静态参数和动态参数两个测试过程。随着性能的提升,ADC的测试复杂度和成本也急剧增加。替代测试,即通过分析两类参数间的关系来实现一个测试过程得到两类参数,已被证明是降低ADC测试复杂度和成本的主要方案之一。本文通过构建基于人工神经网络的参数预测模型来实现替代测试,模型以总谐波失真为预测目标,以静态性能参数为输入特征。针对高维的ADC非线性曲线,文章结合统计分析和主成分分析设计了专用的特征提取方法,在降低特征维度的同时尽可能地减少了信息损失。模型在测试集上的预测结果与参考值的均方误差和拟合优度分别达到了1.15 dB和0.6,显著优于相关对比模型。此外,在SHAP解释器的框架下分析了上述模型的预测目标和特征变量之间的依赖关系,并得到了有意义的结果。

关键词:模数转换器;总谐波失真;静态参数;人工神经网络;统计分析;主成分分析;SHAP;替代测试

中图分类号: TN407 TH862 **文献标识码:** A **国家标准学科分类代码:** 510.3010

Fast estimation algorithm of THD based on artificial neural network

Hou Linjie¹, Xie Weikun^{2,3}, Chen Shibo¹, Liu Yutao³, Zhao Yijiu^{1,2}

(1. Shenzhen Institute for Advanced Study, University of Electronic and Technology of China (UESTC), Shenzhen 518110, China; 2. School of Automation Engineering, UESTC, Chengdu 611731, China;
3. China Electronics Technology Corporation No. 58 Research Institute, Wuxi 214035, China)

Abstract: The test of analog-to-digital converter (ADC) mainly includes two test processes of static parameters and dynamic parameters. With the improvement in the performance, the testing complexity and cost of ADC increases dramatically. Alternative test, which means obtaining two types of parameters from only one test process by analyzing the relationship between static and dynamic parameters, has been proven to be a major solution to reducing the complexity and cost of ADC test. In this article, the alternative testing is achieved by constructing a regression model based on artificial neural network. The model takes total Harmonic distortion (THD) as the prediction target, and takes the static performance parameters as the input features. For high-dimensional ADC nonlinear curves, statistical analysis and principal component analysis are combined to design a special feature extraction method, which greatly reduces the feature dimension and the loss of information. The prediction results on the test set show that the mean absolute error and R-squared between the predicted THD and the reference value reach 1.15 dB and 0.6, respectively, which are significantly better than those of other comparison models. In addition, SHAP (shapley additive explanations) model interpreter is used to analyze the dependencies between the prediction target and feature variables of the model, and meaningful results are obtained.

Keywords: ADC; THD; static parameters; statistical analysis; principal component analysis; artificial neural network; SHAP; alternative testing

0 引言

模数转换器(analog-to-digital converter, ADC)是现代电子信息系统中不可缺少的组成部分,其性能的优劣极大程度上影响着系统整体的性能指标^[1-3]。近年来,随着制作工艺和设计水平的提升,ADC的性能也快速提升。这使得传统测试方法所需的测试成本也快速增长,极大限制了其在高性能ADC上的应用。

静态参数和动态参数是ADC所有参数中最为重要和关键的两类参数,其中静态参数包括微分非线性(differential nonlinearity, DNL)、积分非线性(integral nonlinearity, INL)、偏移误差(offset error, OE)和增益误差(gain error, GE),动态参数包括信噪比(signal-to-noise ratio, SNR)、无杂散动态范围(spurious-free dynamic range, SFDR)和总谐波失真(total harmonic distortion, THD)等。这两类参数能够很大程度上决定ADC的适用场景。例如,静态参数在控制回路中非常重要,静态参数能够影响整个控制系统的工作性能;而动态性能在高速仪器仪表和无线通信系统中更为关键。

根据传统测试方法,静态参数和动态参数的测试需要两个独立的测试过程,即通过给待测ADC两个不同的激励信号,然后分别用码密度直方图法和频域转换法来对ADC的输出数字码进行处理并计算,进而得到动态参数和静态参数。在实际的测试中,ADC的总测试成本也主要来自于这两个测试过程^[4-5]。而对于高性能ADC来说,传统测试方法所面临的成本方面的挑战主要来自动态参数测试所需要的复杂且昂贵的辅助测试设备,包括:1)低抖动时钟信号发生器。实际的时钟信号都会有一定程度的抖动,即转换沿的出现时间相对于整个信号周期的随机偏移。时钟抖动就相当于一个噪声源,尤其在采集高速信号时,会极大影响ADC输出信号的质量。因此,随着ADC采样速率的提高,测试对采样时钟信号质量的要求也会相应提高。2)低噪声正弦信号发生器。实际测试中,往往要求输入信号的信噪比要大于待测ADC至少20 dB。这就对输入信号发生器提出了很高的要求,即波形发生器应该能够产生具有高信噪比的特定频率的正弦波^[5]。

为解决上述问题,改进现有ADC测试方法,在保证可接受的测量精度下实现高性能ADC的低成本测试已经成为国内外混合信号测试领域的热点研究课题之一。相关研究表明静态和动态参数在ADC的转换性能评估中起着类似的作用^[1,4],这带来了一种新思路,替代测试(alternative test),即通过分析静态参数和动态参数之间的关系来实现仅通过一个测试过程中获得两类参数,从而解决传统测试方法的高测试成本问题。

替代测试主要有两个研究方向:1)利用动态性能预测静态非线性参数^[6-8]。由于动态测试采样的点少,此类方法的精度较低,只能粗略的描绘非线性特性;2)利用静态性能预测动态参数。此类方法基于静态测试的结果,所以消除了传统的FFT方法测量ADC动态参数所需要的外围测试设备和测试时间开销。而且,大量的采样点数保证了预测精度。

关于ADC的替代测试主要关注如何利用静态性能参数来预测动态参数。Duan等^[9]通过基本理论推导、仿真及实验详细分析及验证了积分非线性与谐波失真的关系。相关学者在这个基础上,通过用理想的正弦波对INL曲线进行采样得到了能够进行傅里叶变换的信号,然后对该信号进行频域转换并得到THD和SFDR^[4,10]。目前已有的方法主要是以确定性的理论推导为基础,结合仿真或少量的测试数据加以验证,因此,其在大批量测试中的稳定性和准确性均未知。

机器学习能够识别更为复杂的信号特征,学习样本数据的内在规律,已经在模式识别、信息处理、决策制定等多个领域得到了广泛的应用^[11]。人工神经网络(artificial neural network, ANN)是最流行的机器学习模型之一^[12],能够用于逼近某种函数关系或是表达某种逻辑策略。在ADC测试方面,ANN能够建立动态参数和静态参数之间的预测模型,实现对动态参数的快速预测^[13]。本文建立了一个具有两个隐藏层的ANN模型,并结合统计分析和主成分分析(principal component analysis, PCA)设计了专用特征提取方法。模型在大批量上ADC的实测数据集上展示了较好的预测性能。

1 数据集

为验证所提出的模型,本文用传统方法测试了一款16 bit、125 MSPS的工业级ADC,得了共计3 060组数据,包括动态参数、静态参数、频谱曲线、非线性曲线在内的全部动态和静态性能参数。数据集的统计性描述如表1所示。

表1 ADC数据集的统计分布
Table 1 Statistics of ADC dataset

参数	均值	方差	最大值	最小值	单位
INL	3.46	0.64	6.90	1.94	LSB
DNL	0.55	0.05	0.74	0.44	LSB
OE	0.04	0.04	0.18	-0.12	%FSR
GE	-0.49	1.00	2.81	-3.42	%FSR
SNR	78.60	1.60	81.33	63.45	dB
SFDR	84.73	2.79	94.56	74.71	dB
THD	78.20	2.66	89.36	72.07	dB

为了获得更好的预测性能,数据被随机分成两组,300 个用于模型验证,其余用于模型训练,分配比例大约 1:9。

测试平台由上位机、测试机台 (Advantest 公司的 V93000) 和射频及微波信号发生器 (R&S® SMA100B RF and microwave signal generator) 构成。图 1 和 2 分别展示了测试平台的实景和结构框图。




图 1 测试平台实景
Fig. 1 Test platform environment

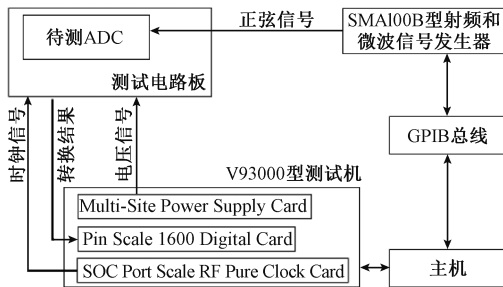


图 2 测试平台结构框图
Fig. 2 Structure block diagram of the test platform

其中静态参数和动态参数测试所需的测试时间和外围辅助测试的设备情况如表 2 所示。

表 2 ADC 不同类型参数的测试时间开销
Table 2 Test time overhead of different types of parameters of ADC

测试时长/秒	参数数量	所需外设
静态参数	28.2	4 V93000 型测试机
动态参数	1.2	3 1) 带有 SOC Port Scale RF Pure Clock 板卡的 V93000 型测试机; 2) 高性能信号发生器; 3) GPIB 总线。

2 特征及其分析

2.1 特征工程

预测目标通常有多个相关变量,若将其直接作为特征变量输入模型中会导致问题分析变得复杂。而盲目的减少特征则会损失有用信息,从而产生错误的结论。特征工程意味着以适当的方式呈现原始数据,以实现在降低特征维度的同时,尽量减少信息损失,从而降低建模难度,增强模型鲁棒性^[14]。但由于数据和模型的多样化,还没有一个通用的特征提取方法,便捷有效的特征提取方法只能根据具体的模型和数据来确定。

非线性曲线、GE 及 OE 可以完备地描述 ADC 的静态特性。其中 GE 和 OE 都是一维的,可直接当作特征输入模型,但非线性曲线的维度过高(16 位 ADC 的 DNL 和 INL 曲线就分别有 $2^{16} = 65\ 536$ 维)。为使用非线性曲线中尽可能多的信息来表征静态参数(而不是像大多数器件手册中那样,仅使用最大值),这里用特征工程来对其进行降维。图 3 是数据集中随机选取的一组实测 DNL 和 INL 曲线及其统计直方图。

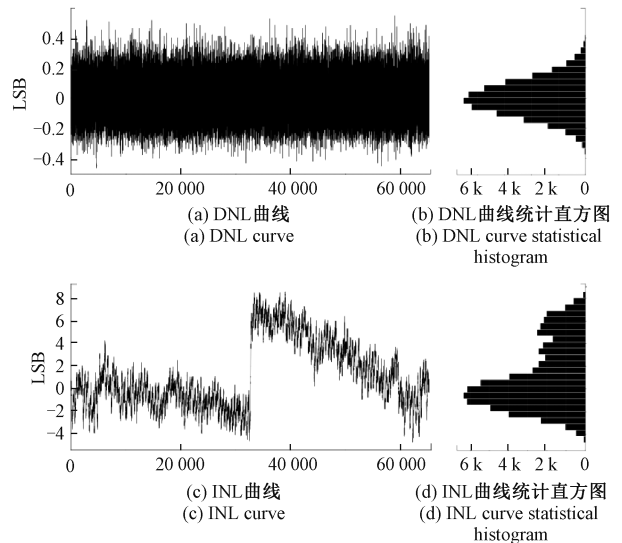


图 3 实测 DNL 和 INL 曲线及其统计直方图
Fig. 3 DNL and INL curves and their statistical histograms were measured

可以看出,非线性曲线有以下特点:1) DNL 曲线中的各数值在某个固定的水平上随机波动,基本不存在某种趋势性和周期性。这与 Duan 等在文献[5]中的分析,即 DNL 曲线可看作是平稳序列,基本一致;2) INL 曲线中的数据有某种趋势性;3) INL 曲线不同点的取值具有一定的随机性,因此通过历史观测值很难完全准确的预测;4) 间隔较近数值点具有较强的关联性,即如果两个数据点的码值很接近,那么它们之间通常非常接近。

根据上述特点,ADC 的非线性曲线与时间序列很相似。因此,这里借助于时间序列分析这一数学工具来对 ADC 非线性时序数据进行分析 and 特征提取,以实现 ADC 静态性能的综合评价。统计分析是对平稳时间序列最常用的特征提取方法^[15],因此,首先考虑使用相关的统计指标来描述 INL 和 DNL 曲线。常用的统计特征包括均值(Mean)、标准差(standard deviation, Std)、平方和(也叫能量, Power)、最小值(minimum value, Min)、最大值(maximum value, Max)、第一分位数(the first quartile, Q_1)、第二分位数(the second quartile, Q_2)和第三分位数(the third quartile, Q_3)。此外,可以看到,INL 曲线的直方图并非都近似服从正态分布,因此,为了增加整个直方图描述的完整性,本文对进行了如下处理。

1) 增加偏度(skewness, G_1)和峰度(kurtosis, G_2)作为特征变量。

偏度能够描述概率密度曲线偏移的程度和方向, $|G_1|$ 越大意味着分布越偏斜,如果 $G_1 > 0$,则称分布是正偏(或右偏),否则,它是负偏斜的。峰度能够描述概率密度曲线的陡峭程度, G_2 越大,分布的尾部越粗,详见文献[16]。

表3是单个 ADC 的 INL 曲线和 DNL 曲线的统计特征在整个数据集上的分布情况。可以看到 DNL-Mean 的方差 0,这意味着该变量的变化很小,可以看作常数,因此将该变量从特征中剔除。

2) 使用主成分分析(principal component analysis, PCA)对 INL 曲线进行特征提取。

从几何学上讲,主成分是初始成分的线性组合,是能够表示解释最大方差量的数据的方向。方差大意味着该方向所承载的样本间的差异信息越大,数据点沿该方向越分散。PCA 的主要思想是保留大方差方向的维度,即高阶主成分(如图4中的 \vec{u}_2),而忽略低阶主成分(如图4中的 \vec{u}_1),从而实现降维(详见文献[17])。




图4 PCA 算法示意图

Fig.4 Schematic diagram of the PCA algorithm

因为 INL 曲线中每个数据点都在不同程度上反映了静态非线性特性的某些信息,并且数据点之间彼此有一

表3 静态参数统计分析特征分布特征表

Table 3 Statistical parameter statistical analysis feature distribution feature table

参数	均值	方差	最大值	最小值
Mean	0.22	1.491	7.65	-6.57
Std	9.96	3.359	29.14	1.46
G_1	0.12	0.277	1.04	-0.93
G_2	-1.03	0.327	0.48	-1.73
Max	7.61	2.253	17.26	1.14
Min	-6.66	1.687	-1.19	-16.12
Q_1	-2.43	1.444	4.13	-9.2
Q_2	-0.03	1.124	7.82	-7.3
Q_3	2.89	1.875	10.86	-3.99
Power	12.23	5.797	73.4	1.59
Mean	0	0	0	0
Std	0.02	0.002	0.03	0.01
G_1	0.06	0.125	0.46	-0.59
G_2	0.01	0.066	0.4	-0.25
Max	0.55	0.047	0.74	0.42
Min	-0.48	0.040	-0.38	-0.65
Q_1	-0.08	0.006	-0.07	-0.11
Q_2	0	0.004	0.02	-0.02
Q_3	0.08	0.007	0.11	0.07
Power	0.02	0.002	0.01	0.03

定的相关性,因而可以用 PCA 来降维,过程中产生的信息损失可以根据式(1)量化。

$$\frac{\sum_{x^i \in Q(x)} \|x^i - x_{approx}^i\|^2}{\sum_{x^i \in Q(x)} \|x^i\|^2} \leq 1 - \alpha \quad (1)$$

其中, $Q(x)$ 表示所有样本数据的集合; x^i 表示特征样本集合中第 i 个样本; $\sum_{x^i \in Q(x)} x^i$ 表示原始样本与投影点之间的距离之和; $0 < \alpha < 1$ 表示信息的保留量, α 越大,说明信息损失越小。

图5所示为原始数据集中的 INL 曲线特征重要性最高的前 40 个主成分,柱形的纵坐标表示该主成分方向上的数据方差所占总方差的比重,曲线表示前 n 个主成分方差所占总方差的比重。可以看到,大部分的信息都可以由第一主成分(55%的可解释方差)和第二主成分(13%的可解释方差)来共同解释。前两个主成分共包含 68%的信息。从第 3 个主成分起,每个的可解释方差占总方差的比均小于 5%。




图 5 主成分方向上的方差与总方差之比示意图

Fig. 5 The ratio of the variance in the principal components to the total variance

2.2 特征评价

机器学习方法常常被视为黑盒,模型的输出结果缺乏理论支撑。而一般来说,任何与易于解释的标准方法不那么直接和概念上不同的方法都很难令人信服^[18]。本文选用 shapley value 启发的可加性 (shapley additive explanation, SHAP) 解释器来提高预测模型的可解释性。

SHAP 是一种基于博弈论的新型模型解释方法,具有较好的局部准确性和全局一致性^[19-20]。在 SHAP 中,所有特征都被视为模型输出结果的“贡献者”。这里用 ϕ_i 来表示第 i 个特征对最终预测值 \hat{y} 的边际贡献 (也叫 Shapley 值或 SHAP 值),用 F 来定义所有特征的集合。则 ϕ_i 的计算公式如式(2)所示。

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! (|F| - |S| - 1)!}{|F|!} [M(S \cup \{i\}) - M(S)] \quad (2)$$

其中,算符 $|\cdot|$ 表示集合的大小,即集合中的特征个数; $N \setminus \{i\}$ 表示不包含第 i 个特征的所有特征子集的集合。 $M(S \cup \{i\})$ 是训练数据包含第 i 个特征情况下的模型输出,而另一个模型 $M(S)$ 则是不包含第 i 个特征情况下的模型输出。然后对 S 所有的可能情况进行遍历即可得到 ϕ_i 。如果 $\phi_i > 0$,则第 i 个特征与 y 正相关,反之则负相关。

3 基于神经网络的参数估计模型

3.1 神经元模型

人工神经元,又称感知器 (perceptron),是 ANN 的基本单元。其数学模型为:

$$y_{output} = F(s) = F\left(\sum_{i=1}^n w_i x_i + b\right)$$

其中, x_i 用于表示前层神经元的输出; w_i 和 b 分别被称为权重和偏置,相当于神经元的记忆; $s = \sum_{i=1}^n w_i x_i + b$ 是中间变量; $F(s)$ 是激活函数,它能将非线性因素引入神经元,使其能够理解和学习复杂的非线性关系,在人工神经网络模型中发挥着重要作用。常用的激活函数包括 tanh 及其各种变体和 ReLU 及其各种变体^[21]。

3.2 模型性能评价及损失函数

损失函数,也叫模型评价函数,能够量化预测值和参考值之间的差距,同时也是机器学习调整参数的重要依据。在回归问题中,常用的损失函数包括^[22]:均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE) 和决定系数 R^2 。其中, $RMSE$ 是预测值与参考值偏差的平方同观测次数比值的平方根; MAE 测量预测值与参考值的平均绝对偏差; R^2 衡量模型对数据的解释程度,最大值为 1,越接近 1,说明回归模型对观测值的拟合程度越好。

由于 RMSE 容易受异常点 (即误差很大的点) 影响,即容易朝减小异常点误差的方向行进而牺牲总体性能。此外,Chicco 等^[22]的工作表明 R^2 能够在回归任务中更好的评价模型性能。因此,这里选择 MAE 和 R^2 作为损失函数。较小的 MAE 和较大的 R^2 意味着更好的模型预测性能。它们的数学表达式如式(3)和(4)所示。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

其中, \hat{y}_i , \bar{y} 和 y_i 分别是第 i 个 ADC 的参数预测值、参考值和参考值的平均值; n 是数据集中样本个数。

3.3 具有两个隐藏层的神经网络模型

普通参数和超参数是建模过程中需要考虑的两种参数。普通参数,如权重和偏置,能够通过反向传播 (back propagation, BP) 算法来优化调整,以使得误差函数最小化,进而使网络表现出期望的行为 (详见文献[23]); 超参数主要包括网络结构、激活函数等。不合适的超参数可能会导致过拟合或欠拟合,但目前还没有统一的方法来确定“最优超参数”,实际应用中主要是根据经验和模型性能的对比如来确定。

通过对比发现,图 6 所示的网络结构预测性能最好。图 6 是一个具双隐层的 ANN,其中,输入层负责接收输入信号 ($x_i, i=1, 2, \dots, 51$), 51 个输入变量对应两个静态线性参数 (OE 和 GE) 加非线性曲线的统计量 (详见表 3) 再加上 30 个 INL 曲线的主成分 (对比发现,选前 30 个主成分时,模型的预测性能最好)。中间两层是隐含层,每层有 63 个神经元,提供复杂的网络结构和模型参数来拟合输入与输出之间的非线性关系。最后一层是输出层,用于产生预测结果 (y_p)。

此外,对比发现,采用 tanh (其表达式和函数如图 7 所示) 为激活函数时,网络预测性能最好。为了避免 tanh 存在的梯度弥散问题 (即在 $|s|$ 很大时,梯度几乎为 0。这会导致使用 BP 算法更新网络很慢),作者在两个隐层




图6 神经网络数学模型示意图

Fig. 6 Mathematical model of ANN




图7 tanh 及其导数示意图

Fig. 7 Diagram of tanh and its derivatives

之间增加了 Batch Normalization 层,即批规范化,它能够通过将输出信号规范化来解决梯度弥散问题,加速网络收敛速度,提升训练稳定性^[24]。此外,为了避免过度拟合,这里采用了 early stopping,一种最常用的正则化技术,即在出现过拟合迹象时停止训练过程。

最后,本研究中相关分析均是基于 Python 3.7 中的一些开源库,包括 NumPy 1.18.2、TensorFlow 2.3.0 及 SHAP 0.39.0 等。

4 实验结果分析

图8所示为从测试集中随机选取的部分(100个)ADC数据样本的结果对比。其中实线和虚线分表表示THD的估计值和参考值,横坐标表示样本的编号。可以看到,参考值与预测值的变化趋势基本相同。




图8 测试集中部分数据的预测值对比参考值示意图

Fig. 8 The predicted value versus the reference value of some data in the test set

图9所示为模型在整个测试集(300个样本点)上的结果对比。其中实线和虚线分别表示THD的参考值等于模型估计值和±3 dB误差的界限。可以看到,仅22个数据的预测误差大于3 dB,即92.67%的数据的误差都在3 dB范围内。这意味着通过静态参数预测THD,甚至仅通过静态参数对ADC进行综合评估是可行的。




图9 测试集上预测值对比参考值示意图

Fig. 9 Schematic diagram of predicted value versus reference value on the test set

值得注意的是,模型在测试集上的最大预测误差甚至接近6 dB。本文分析误差可能有3方面的原因:

- 1) 模型本身的缺陷。因为ANN大多是被当成黑箱在用,其在做出预测的过程中所进行的一系列操作是未知的,所以可能会存在一些未知的缺陷。
- 2) 特征提取方法的不足。本文采用的统计分析和PCA相结合的特征提取方法具有一定的可行性,但是否还有更合适的特征提取方法仍有待验证。
- 3) 原始数据分布不均。本文所用的原始数据大多都以某种分布集聚在某个范围,这可能会导致模型在某些区间拟合的不够好。

表4给出了数据集上包括平均值回归(mean regression, MR)、多元线性回归(multiple linear regression, MLR)及ANN在内的3个的THD估算模型上的性能对比。其中MR是指用训练集上THD的平均值作为测试集上THD的预测值,该模型能够为其他预测模型提供一个评价基准,即如果一个预测模型的在测试集上的指标不如MR,则该模型没有价值。

表4 不同模型预测性能对比

Table 4 Comparison of prediction performance

模型	训练集		测试集	
	MAE	R ²	MAE	R ²
ANN	1.21	0.53	1.15	0.60
MLR	1.38	0.47	1.36	0.49
Mean	1.93	0	1.95	0

可以看到,3 个模型在训练集和测试集上的评价指标基本一致,这表明模型基本没有出现拟合或欠拟合现象。MR 的两个评价指标均显著差于 MLR 和 ANN,这表明其他两个模型均有意义。MLR 在测试集上的 MAE 为 1.36,相比于 MR 降低了约 31%。而 ANN 的两个评价指标均显著优于两个比对模型,MAE 仅为 1.15 dB,相比于 MLR 降低了约 15%,特征对结果的解释分数 R^2 达到了 0.6,相比于 MLR 提高了 22%。

此外,相比于传统动态参数测试方法所需要的测试时间开销和辅助测试设备(如表 2),本文提出的基于 ANN 的动态参数回归估计模型在牺牲一些准确性的前提下,将测试时间减少了 4% (1.19 s),避免了动态性能测试环节和消除了大部分测试设备以及接近一半的测试参数,大大降低了测试的复杂性。

图 10 所示为对 THD 估计值影响最大的前 20 个特征。图中,每一行都分别代表一个特征,横坐标为 SHAP 的平均绝对值(|SHAP 值|,可以用来表示不同特征对最终预测值的影响程度)。特征根据 |SHAP 值|的大小按降序从上到下排列。

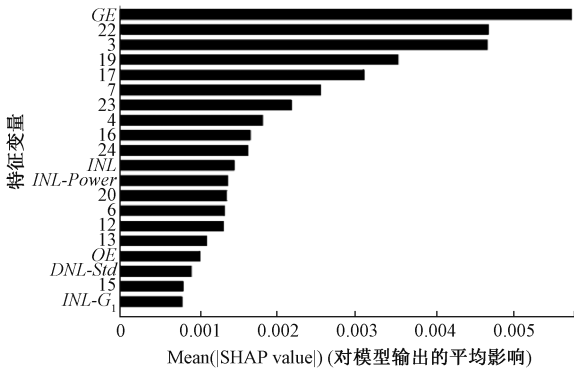


图 10 特征重要性

Fig. 10 Feature importance

可以看到,GE 是对 THD 估计值贡献最大的特征,它的 |SHAP 值|约等于 0.006,高于第 22 主成分和第 3 主成分。后两者以相近的 |SHAP 值|(约为 0.004 5) 分别排第 2 和第 3。贡献排在第 4 位的是第 19 主成分,它的 |SHAP 值|约等于 0.003 5。从第 19 主成分起,特征对 THD 估算值的贡献开始快速稳定下降,直至排在第 8 位的第 4 主成分(|SHAP 值|约为 0.001 5),并随后缓慢下降,最后不到 0.001。整体来看,在影响最大的前 20 个特征中,与 INL 曲线直接相关的特征变量达到了 17 个。这表明积分非线性是估计 THD 的关键特征,影响因子很大,这一结论与传统测试理论一致。而与 DNL 曲线相关的特征变量则只有方差一个,这表示微分非线性在 THD 预测的影响并不高。

图 11 所示为最重要的前 20 个特征在每个样本上的影响情况,排列顺序同图 10。图 11 中的每一行代表一个特征,每一个点都代表一个样本,点所在的横坐标为该特征对该样本 THD 估算值的贡献,即 SHAP 值,点的颜色表示特征本身的大小,颜色越浅则数值越大,颜色深则相反。




图 11 特征密度散点图

Fig. 11 Feature density scatter plot

横向来看,样本的分布越分散则该特征影响越大。另外,在 GE 和第 22 主成分这两个特征都呈现出清晰的左侧蓝色和右侧红色,这表示它们对预测结果的影响很大而且和 THD 的预测值是正相关关系。文献[25]中的研究表明,这主要是由 INL 引入的谐波失真引起的。而且一般来说,增益误差能够放大积分非线性对输出波形的影响,增益误差越大,非线性带给输出波形的失真就越高。第 17 主成分和第 23 主成分则相反,与 THD 呈现负相关。在排名靠后的 INL - G_1 行中,大多数的点都弥漫在 0 附近,这表示该特征对 THD 估算结果的影响不大。

5 结 论

针对传统测试算法在高性能 ADC 测试上存在的高成本问题,本文提出了基于 ANN 的动态参数估计模型。该模型能够在保证一定测试精度的情况下,用更少的测试时间,更低的测试成本给出较准确的预测结果。同时,可解释性模型地使用增加了模型地透明度,提高了预测结果的可靠性,使得该方法能够在高性能 ADC 的生产测试中,具有较大的工程应用潜力和实用价值。

参考文献

[1] DA SILVA J M, ALVES J C. An alternative SNR computation method for ADC testing[C]. 2019 XXXIV

- Conference on Design of Circuits and Integrated Systems (DCIS), 2019:1-6.
- [2] 陈豹, 王逢州. 一种基于参数提取算法的快速 ADC 测试方法 [J]. 电子器件, 2017, 5: 1145-1150.
- CHEN B, WANG F ZH. A fast ADC measurement approach based on parameter extraction [J]. Chinese Journal of Electron Devices, 2017, 5: 1145-1150.
- [3] XU S, ZOU X, MA B, et al. Analog-to-digital conversion revolutionized by deep learning [J]. Arxiv Preprint, 2018, ArXiv:1810.08906.
- [4] DUAN J, JIN L, CHEN D. Testing ADC spectral performance without dedicated data acquisition [J]. IEEE Transactions on Instrumentation and Measurement, 2012, 61(11): 2941-2952.
- [5] DUAN J, CHEN D. SNR measurement based on linearity test for ADC BIST [C]. 2011 IEEE International Symposium of Circuits and Systems (ISCAS), 2011: 269-272.
- [6] SERRA A C, DA SILVA M F, RAMOS P M, et al. Combined spectral and histogram analysis for fast ADC testing [J]. IEEE Transactions on Instrumentation and Measurement, 2005, 54(4): 1617-1623.
- [7] ADAMO F, ATTIVISSIMO F, GIAQUINTO N, et al. Frequency domain analysis for dynamic nonlinearity measurement in A/D converters [J]. IEEE Transactions on Instrumentation and Measurement, 2007, 56(3): 760-769.
- [8] KERZÉRHO V, BERNARD S, CAUVET P, et al. A first step for an INL spectral-based BIST: The memory optimization [J]. Journal of Electronic Testing, 2006, 22(4): 351-357.
- [9] DUAN J, JIN L, CHEN D. A new method for estimating spectral performance of ADC from INL [C]. 2010 IEEE International Test Conference, 2010:1-10.
- [10] DUAN J, JIN L, CHEN D. INL based dynamic performance estimation for ADC BIST [C]. Proceedings of 2010 IEEE International Symposium on Circuits and Systems. Paris, France, 2010:3028-3031.
- [11] SARKER I H. Machine learning: Algorithms, real-world applications and research directions [J]. SN Computer Science, 2021, 2(3): 1-21.
- [12] ABIODUN O I, JANTAN A, OMOLARA A E, et al. State-of-the-art in artificial neural network applications: A survey [J]. Heliyon, 2018, 4(11): e00938.
- [13] HOU L, LIU Y, XIE W, et al. Statistical neural network (SNN) for predicting signal-to-noise ratio (SNR) from static parameters and its validation in 16 bit, 125 MSPS analog-to-digital converters (ADCs) [J]. Review of Scientific Instruments, 2022, 93(8): 084701.
- [14] ZHENG A, CASARI A. Feature engineering for machine learning: Principles and techniques for data scientists [M]. O'Reilly Media, Inc., 2018.
- [15] SHI Z, BAI Y, JIN X, et al. Deep prediction model based on dual decomposition with entropy and frequency statistics for nonstationary time series [J]. Entropy, 2022, 24(3): 360.
- [16] CAIN M K, ZHANG Z Y, YUAN K H. Univariate and multivariate skewness and kurtosis for measuring nonnormality: Prevalence, influence and estimation [J]. Behavior Research Methods, 2017, 49(5): 1716-1735.
- [17] ANOWAR F, SADAOUI S, SELIM B. Conceptual and empirical comparison of dimensionality reduction algorithms (pca, kpca, lda, mds, svd, lle, isomap, le, ica, t-sne) [J]. Computer Science Review, 2021, 40: 100378.
- [18] STRATIGOPOULOS H G, STREITWIESER C. Adaptive test with test escape estimation for mixed-signal ICs [J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2018, 37(10): 2125-2138.
- [19] ŠTRUMBELJ E, KONONENKO I. Explaining prediction models and individual predictions with feature contributions [J]. Knowledge and Information Systems, 2014, 41(3): 647-665.
- [20] RIBEIRO M T, SINGH S, GUESTRIN C. "Why should I trust you?" Explaining the predictions of any classifier [C]. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016:1135-1144.
- [21] SHARMA S, SHARMA S, ATHAIYA A. Activation functions in neural networks [J]. Towards Data Science, 2017, 6(12): 310-316.
- [22] CHICCO D, WARRENS M J, JURMAN G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation [J]. PeerJ Computer Science, 2021, 7: 1-24.
- [23] LILLICRAP T P, SANTORO A, MARRIS L, et al. Backpropagation and the brain [J]. Nature Reviews Neuroscience, 2020, 21(6): 335-346.
- [24] SANTURKAR S, TSIPRAS D, ILYAS A, et al. How does batch normalization help optimization? [J].

Advances in Neural Information Processing Systems, 2018, 31: 1-11.

- [25] JENQ Y, LI Q. Differential non-linearity, integral non-linearity, and signal to noise ratio of an analog to digital converter [J]. IMEKO International Measurement Confederation, 2002: 1-4.

作者简介



侯琳杰, 2020 年于西安电子科技大学获得学士学位, 现为电子科技大学硕士研究生, 主要研究方向为 ADC 的测试优化。

E-mail: 13399132667@163.com

Hou Linjie received his B. Sc. degree from Xidian University in 2020. He is currently a


master student at University of Electronic Science and Technology of China (UESTC). His research interest is ADC test optimization.



解维坤, 2003 年于青岛大学获得学士学位, 2008 年于厦门大学获的硕士学位, 2019 年开始在电子科技大学攻读工程博士, 现在为中国电子科技集团公司第五十八研究所高级工程师, 主要研究方向为大规模集成电路测试。

E-mail: chinagrass@163.com

Xie Weikun received his B. Sc. degree from Qingdao University in 2003, and received his M. Sc. degree from Xiamen University in 2008. He is currently a Ph. D. candidate at University of Electronic Science and Technology of China (UESTC) and a senior engineer at China Electronics Technology Corporation No. 58 Research Institute. His research interest is large scale IC test.



陈世博, 2020 年于四川大学获得学士学位, 现为电子科技大学硕士研究生, 主要研究方向为集成电路测试。

E-mail: chenshibo_1012@163.com

Chen Shibo received his B. Sc. degree from Sichuan University in 2020. He is currently a master student at University of Electronic Science and Technology of China (UESTC). His research interest is IC test.



刘雨涛, 2018 年于电子科技大学获得学士学位, 2019 年于新加坡国立大学获得硕士学位, 现在为中国电子科技集团公司第五十八研究所工程师, 主要研究方向为混合电路测试。

E-mail: gt123ccxp@hotmail.com

Liu Yutao received his B. Sc. degree from University of Electronic Science and Technology of China (UESTC) in 2018, and M. Sc. degree from National University of Singapore in 2019. He is currently an IC test engineer at China Electronics Technology Corporation No. 58 Research Institute. His research interest is mixed-signal IC test.



赵贻玖 (通信作者), 分别于 2004 年、2007 年和 2012 年在电子科技大学获得学士、硕士和博士学位, 现为电子科技大学教授, 主要研究方向为宽带时域测试技术、集成电路特征测试技术等。

E-mail: yijiu Zhao@uestc.edu.cn

Zhao Yijiu (Corresponding author) received his B. Sc., M. Sc. and Ph. D. degrees all from University of Electronic Science and Technology of China (UESTC) in 2004, 2007, and 2012, respectively. He is currently a professor at UESTC. His main research interests include wideband time-domain testing technology and integrated circuit signature testing technology.