

DOI: 10.13382/j.jemi.B2206164

基于 XGBoost 的模拟集成电路测试参数优化方法*

肖寅东¹ 曾宇通¹ 刘科¹ 胡聪²

(1. 电子科技大学自动化工程学院 成都 611731;

2. 桂林电子科技大学广西自动检测技术与仪器重点实验室 桂林 541004)

摘要:随着集成电路的规模不断扩大,其测试成本随测试时间的增长而不断提高,如何优化测试参数是一个重要课题。模拟集成电路测试中,测试参数间存在非线性隐式依赖,使得直接揭示其相互关系并进行测试方法优化非常困难。本文基于 XGBoost 决策树模型提出了一种优化模拟集成电路测试参数数目的方法,该方法探索不同测试参数间的相互表征能力,在测试序列中依次删减可被良好表达的测试参数,在保证一定逃逸率的条件下达到缩短测试时间的目的。本文讨论了故障数目、特征重要性和 SHAP 值 3 种评估测试参数间表征能力的指标,并对两类模拟集成电路测试数据集进行了实验,结果表明故障数目是一种优秀的评估指标,可在测试逃逸率不超过 20 PPM 的条件下实现 25% 的测试参数优化。

关键词: 机器学习; XGBoost; 集成电路测试; 测试成本; 测试逃逸

中图分类号: TN98 **文献标识码:** A **国家标准学科分类代码:** 510.30

Test parameter optimization method for analog IC testing by XGBoost

Xiao Yindong¹ Zeng Yutong¹ Liu Ke¹ Hu Cong²

(1. School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China;

2. Guangxi Key Laboratory of Automatic Testing Technology and Instruments, Guilin University of Electronic Technology, Guilin 541004, China)

Abstract: As the scale of integrated circuits continues to increase and their test cost increases with test time, the optimization of the test terms is an important topic. The existence of nonlinear implicit dependencies among test parameters in analog integrated circuit testing makes it very difficult to directly reveal their interrelationships and perform test method optimization. In this paper, we propose a method to optimize the number of test parameters of analog integrated circuits based on the XGBoost decision tree model, which explores the mutual characterization ability among different test parameters and sequentially deletes the test parameters that can be well expressed in the test sequence to achieve the purpose of shortening the test time under the condition of ensuring a certain escape rate. The paper discusses three metrics to evaluate the inter-representation capability of test parameters, such as the number of faults, feature importance and SHAP value, and conducts experiments on two types of analog IC test datasets. The results show that the number of faults is an excellent evaluation metric that can achieve 25% test parameter optimization under the condition that the test escape rate does not exceed 20 PPM.

Keywords: machine learning; XGBoost; integrated circuit testing; test cost; test escape

0 引言

如今各种芯片的集成度和复杂性都大大提高,其可

靠性也愈加受到重视。由于芯片的集成度限制,人们采用自动测试设备(automatic test equipment, ATE)来对芯片进行自动检测。然而随着芯片集成度的提升,测试所需时间也在不断增长,而 ATE 的使用是按照使用时间进

行计费,因此缩减测试时间成本也就降低了整体的测试成本,通过优化测试参数,或是采用新模式均可有效减少芯片测试时间^[1-2],Brockman 等^[3]在 1989 年就提出过一种通过挖掘特征间的相关性来减少验证所有性能所需的测试数量的方法。文献[4]中实现了一种基于二元决策树的方法,同样有效压缩了测试集^[5-7]。自适应测试优化方法基于对数据相关性的统计分析,在减少测试时间方面也获得了广泛关注,Benner 等^[8]提出了一种基于统计方法来原因测试参数去留的自适应测试方法,文献[9]中通过自适应测试来确定测试项目的最佳子集,文献[10]提出了一种使用间接测试策略的自适应测试方法。

不仅测试参数的多少,测试参数的排序同样对测试时间起着重要的作用,在早期就尽可能多的检出故障即能极好的优化测试时间。在文献[11]中提出的一种用于参数测试的,基于参数间相关性的两阶段自适应测试方法,在第 2 阶段中对在第 1 阶段中成功删减后的测试参数进行排序,使得早期的故障检测的总体概率最大化。文献[12]提出了一种基于测试性能估算的测试集重排序方法,通过估算测试向量的测试性能,根据性能的优劣对测试集重新排序,最多减少了 53% 的测试时间。Li 等^[13]提出了一种基于下一项测试与目前已进行测试间的相互关系,用互信息来评估故障检测电路队列中下一个测试的效用,以此来削减测试时间,他们还在文献[14]中进一步提出了新的测试列表排序算法,使得测试的早期就能获得较大的信息量,以此进一步减少测试时间和错误率。但自适应测试优化方法主要基于贝叶斯理论针对单个样本的不同测试参数的值进行优化,其优化后的测试时间不确定,在实际应用时会造成排表困难的问题。

随着机器学习技术在计算机视觉、医疗诊断、机器人等领域得到成熟的应用^[15-17],越来越多的科研人员将机器学习与集成电路测试结合在一起,并在测试压缩、故障诊断、异常值探测等方面^[18]取得了较好成绩。如文献[19-21]中提到的使用机器学习手段辅助芯片设计、压缩测试集以及测试方案设计,现在已经有了比较成熟的应用。文献[22]提出了一种改进的 RLDA 算法,正确识别出了有效的测试模式,并删除了无效测试模式来减少测试时间,文献[23]中使用最小冗余最大相关算法选取重要测试参数并将数据放入 BP 反馈神经网络使用部分测试参数来预测故障芯片,有效降低了测试成本和测试逃逸率。

本文中提出一种基于 XGBoost^[24]决策树的机器学习方法,对每一个测试参数分别建立独立的模型,评估测试参数能够被其他测试参数联合预测的能力,并根据该预测能力确定优化测试参数的优先级。该方法中使用模拟集成电路中关键参数测试逃逸率,即百万单位缺陷产品

数(defective parts per million, DPPM)作为模型的主要评判标准,同时定义了对应的损失率百万单位损失产品数(loss parts per million, LPPM)来平衡训练过程中的激进策略,降低过拟合的概率。该方法对测试参数进行优化,其结果具有测试时间确定的特点,适合应用于实际模拟集成电路生产过程。

1 基础理论

模拟集成电路测试的目的是判断被测芯片的各测试参数是否符合产品规格要求,确定其为良品或不良品。若所有被测芯片中某个测试参数的测试值或测试结论能够被准确预测,则可将该测试参数从测试流程中删除,从而降低测试时间。

1.1 XGBoost 算法

XGBoost 算法的基础是决策树模型。决策树模型的常见结构如图 1 所示,其中,每一个非叶子节点代表一个特征,叶子节点表示一种标签,或决策结果。应用该决策树时,将待预测样本按节点对应的特征值检查判定条件,从而确定下一节点位置和判定条件,如此往复直到获得确定的决策结果。

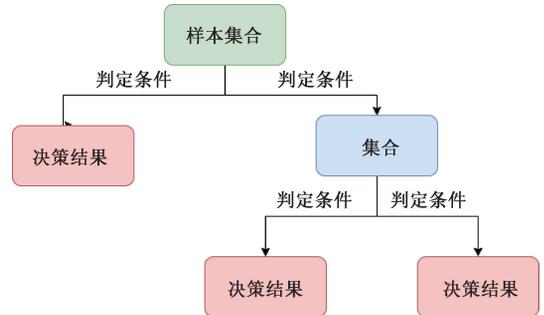


图 1 决策树模型

Fig. 1 Decision tree model

决策树使用数据集训练得到,其过程是根据当前的学习目标,选取具有显著作用的特征作为根节点,将训练集按照一定的判定条件划分为多个样本集;分别在这些样本集中搜索具有最大信息增益的剩余特征作为下一子节点,获取其判定条件和新的样本集;依次重复直到构建出满足要求的分类树。

单纯的决策树结构虽然结构简单逻辑清晰,但容易出现过拟合状态。因此衍生出了以剪枝及随机森林为主的降低过拟合的方法。随机森林,使用自助采样法(bootstrap sampling)构造多个随机训练集并且基于它们分别训练出一个弱学习器决策树,再将这些决策树集成性能显著优越的强学习器决策树,以此来避免过拟合,然而集成的决策树之间相互独立没有反馈作用,由此衍

生出了梯度下降决策树方法 (gradient boosting decision tree, GBDT)。

GBDT 中每一棵树使用前一棵树的残差 (即误差的观测值) 来进行拟合, 最终结果由所有树的结果之和来决定, 但这也导致其无法进行并行运算。XGBoost 基于 GBDT 方法进一步扩展, 在模型训练前就预先将训练数据进行排序并保存起来, 在迭代中直接使用排序好的数据。其在新节点选择的时候计算特征增益, 选择值较大的一个进行分裂, 形成下一层子节点。由于使用了预先排列好的数据, XGBoost 可以同时多个特征进行分裂, 从而实现并行运算, 节省了模型训练时间。同时, 其目标函数中不仅包括常见损失函数还加入了一个正则化项, 且采用随机森林^[25] 中的列采样方法 (column subsampling), 在减少过拟合的同时也加速了并行计算的速度。

1.2 超参数优化

模型训练过程中得到的参数称为模型参数, 而在模型建立之前就设置范围或值的称为超参数, 用于指导模型训练, 例如决策树中的学习率、树的深度等。超参数的设置会影响模型的性能, 通过调整超参数能获取更准确的预测结果。

目前主流的自动调参算法包括随机搜索、贝叶斯优化等。HyperOptSeach 是基于 HyperOpt 库^[26] 支持的搜索算法, 其实现的树形 Parzen 估计器 (tree-structured parzen estimators, TPE) 算法^[27] 具有输出模型准确度高的特点。它是一种基于序列模型优化 (sequential model-based global optimization, SMBO) 的算法, 该算法基于高斯过程对损失函数 y 与超参数 x 的条件概率模型 $p(x, y)$ 进行建模, 其中分别使用两种密度函数来定义 $p(x, y)$:

$$p(x, y) = \begin{cases} l(x), & y < y^* \\ g(x), & y \geq y^* \end{cases} \quad (1)$$

这两种密度函数分别使用观测样本和剩余样本来构造概率密度函数, y^* 为损失的阈值。在成功拟合两个概率密度函数后即可求得 $\frac{g(x)}{l(x)}$, 以 $\frac{g(x)}{l(x)}$ 作为最优化目标使其最小即可得到使预期最大的 x^* 。

本文的模型训练中, 所有的超参数均需要通过自动调参算法进行搜索, 其搜索依据由损失函数确定。

2 方法描述

本文中优化模拟集成电路测试过程的主要手段是在保证测试结论基本不变的情况下, 尽可能的减少需要测试的参数个数, 该目标在机器学习算法中等效于搜索可正确预测测试结论的最小特征集合。该搜索过程是一个具有 $O(N!)$ 复杂度的问题, 为了加速该问题的求解, 本

文中提出的方法按照图 2 所示的流程进行。

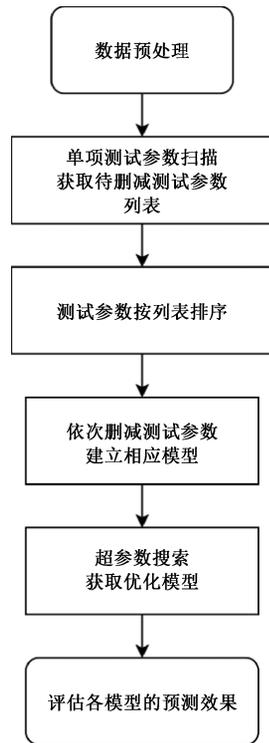


图 2 优化算法整体流程

Fig. 2 Flow chart of the optimization algorithm

如图 2 所示, 其中的数据预处理是将测试参数按照产品规格归一化的过程; 单项测试参数扫描过程有两个作用, 一是对测试参数的测量值进行分析, 统计出每项测试参数不符合产品规格的样本数目, 获取测试参数的故障数目, 二是对每项测试参数建立学习模型, 使用剩余测试参数对相应的目标测试参数进行预测, 获取测试参数的特征重要性和 Shapley 值; 将所有测试参数分别按照故障数目、特征重要性和 Shapley 值排序可得到 3 组待删减测试参数列表; 按照待删减列表顺序依次删除测试参数, 使用每次删除后剩余的测试参数对已删除参数进行建模和预测, 可以得到新的模型集合; 通过超参数搜索获取性能最佳的模型; 评估该集合中模型对测试结论的影响和不同排序依据之间的性能差异。

因此, 该方法需重点考虑两个方面: 1) 定义模拟集成电路测试数据集特有的模型评价函数; 2) 选择可反映待删减测试参数被表征能力的参数作为排序依据。

2.1 评价函数定义

评价函数用于评估当前训练模型的性能。根据模拟集成电路的应用特点选择评价函数的构成, 其定义为:

$$eval = DPPM \quad (2)$$

其中, DPPM 为每百万个单位中的缺陷单位个数, 即测试逃逸率, 反映了测试流程对不良品的甄别能力, 其计

算公式为:

$$DPPM = \frac{n'}{n} \times 1\,000\,000 \quad (3)$$

式中: n' 表示不良品数, n 代表测试结论为良品的产品总数。

2.2 模型训练过程

将图 2 中所述的优化流程进一步细化可得如图 3 所示示意图,该图中模型整体训练流程主要分为 4 个部分。

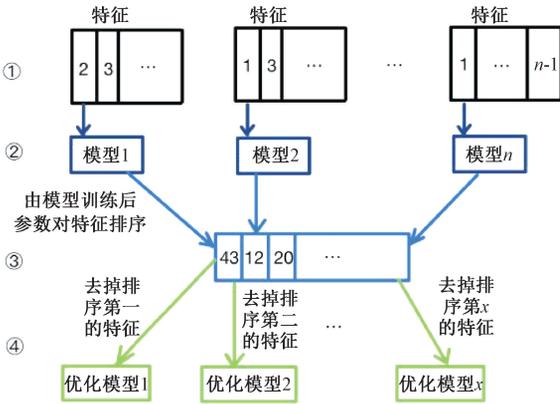


图 3 模型建立示意图

Fig. 3 Schematic diagram of model establishment

①: 将所有测试参数设定为一个总体特征集 $A = \{a_i\}$, $i = 1, 2, \dots, n$ 为测试参数的总数, a_i 是所有被测芯片第 i 项测试参数的测量值集合, 代表了一项测试参数。从 A 中分离出测试参数集 a_i , 余下的测试参数集形成新的集合 $A_i' = \{a_j\}$, $j = 1, 2, \dots, n, j \neq i$ 。

②: 对所有 $i = 1, 2, \dots, n$ 进行数据扫描和局部模型训练, 得到评估指标 $V = \{v_i\}$, $i = 1, 2, \dots, n$ 。

③: 按照评估指标 v_i 的升序顺序对测试参数进行排序, 获得待删减测试参数列表 $S = \{s_i\}$, $i = 1, 2, \dots, n$, 其中 s_i 为排序后的测试参数。

④: 将 S 按顺序分割为参数集 $T_k = \{s_i\}$, $i = 1, \dots, k$ 和剩余参数集 $R_k = \{s_j\}$, $j = k + 1, \dots, n$, 以 T_k 为目标, 训练输入为 R_k 的模型。则对所有 $k = 1, 2, \dots, n$ 可得到 n 个模型, 其对应的 DPPM 可反映出优化后的模型对测试结论的影响。

2.3 评估表征能力的指标

本文评估指标有 3 种: 测试参数的特征重要性、Shapley 值和故障样本数目。

特征重要性: 树模型中反应特征在模型里重要程度的指标, 可以由基尼指数衡量。假设有特征集合 $X = \{x_i\}$, $i = 1, 2, 3, \dots, n$, 模型中共有 M 个节点, 那么特征的基尼指数计算公式为:

$$GI_m = \sum_{k=1}^K \sum_{k' \neq k}^K p_{mk} p_{mk'} \quad (4)$$

其中, K 表示类别的数目, p_{mk} 表示在节点 m 中类别为 k 所占的比例。所以式(1)的含义是从节点 m 任选的两个样本不同的概率。

特征 x_j 在节点 m 上的特征重要性取决于节点 m 分枝前后的基尼指数变化, 其计算公式如下:

$$VI_{jm} = GI_m - GI_l - GI_r \quad (5)$$

式中: VI_{jm} 为特征 x_j 在节点 m 上的重要性评分, $GI_l - GI_r$ 分别是节点 m 分枝后左右节点的基尼指数。

将特征 x_j 在所有节点上的重要性评分进行求和就能够得到 x_j 在模型中的特征重要性。

$$VI_j = \sum_{m \in M} VI_{jm} \quad (6)$$

Shapley 值: SHAP 是由 Lundberg 等^[28]提出的一种可解释型框架, 它可以解释任何机器学习模型的输出, 其核心是将每一个特征都视为模型的贡献者, 计算特征的 Shapley 值, 以此来反映特征在模型的贡献程度。SHAP 将模型的预测值解释为每一个输入特征的归因值的和 (Shapley 值), 其定义为:

$$y = f_0 + \sum_{i=1}^n f_i \quad (7)$$

其中, y 是模型的预测值, f_0 是所有训练样本的预测均值, f_i 是每一个输入特征的归因值。

故障样本数目: 统计出测试参数中不符合产品规格芯片的个数。

由于特征重要性和 Shapley 值都是通过局部训练得到的, 无法反映测试参数在全局的重要程度, 因此本文将所有的局部特征重要性和 Shapley 值分别进行加权平均, 以此来反映测试参数的全局重要程度。

3 实验、结果及分析

本章描述了实验的环境、数据集的准备过程、模型训练结果, 以及对实验结果的分析。

3.1 实验数据集

集成电路的测试数据通常涉及较高的商业机密, 目前没有公开的数据集可用于对比。本文中实验使用的数据来自某模拟集成电路制造厂商, 包含两种型号的芯片, 一种是具有无线功能的模拟电路; 一种是具有混合信号功能的模拟电路, 后续文中分别称该两种电路的测试数据集为数据集 1 和数据集 2。

数据集中单个被测芯片的所有测试参数中, 若存在一个测试参数的值超出产品规格容许范围的, 则可将该芯片归类为不良品。测试参数种类包括电源电压、电流, 输出信号电压幅度、偏移等。

数据集 1 包含 85 926 个芯片, 每个芯片具有 70 项测试参数。其中, 良品 (负样本), 即测试通过的芯片, 共

74 219 个;剩余为测试不通过的不良品(正样本),良品率约为 86.4%。数据集 2 包含 118 456 个芯片,每个芯片具有 42 项测试参数。其中,良品共 113 100 个,良品率约为 95.5%。

3.2 实验环境和过程

由于数据量较大,训练过程需要的计算量随之增大,对硬件环境要求也较高,因此,实验平台使用了 2 颗英特尔 Xeon E5-2673 v3 系列中主频为 2.40 GHz 的 CPU 和 128 GB DDR4 SDRAM 高带宽存储器。

本文基于两种模拟集成电路测试数据进行 3 组实验,后续文中分别称该 3 组实验为实验 1、实验 2 和实验 3。实验 1 根据 3 种评估指标得到了 3 组待优化测试参数列表,按照列表顺序,完成删减实验;实验 2 将实验 1 表现最好的待删减测试参数列表中可删除的最后一项测试参数与不可删除的第 1 项测试参数进行交换,重新进行删减实验;实验 3 在实验 1 的基础上引入数据增强技术,增加被删除测试参数中的正样本个数,减小数据不平衡性对实验的影响,仍然使用之前的 3 组待删减测试参数列表对测试参数进行删减。删减实验的具体步骤如下所示。

数据的预处理在学习机器的训练之前至关重要。晶圆的测试数据以矩阵形式存储,每一行为一个芯片,每一列为一项测试参数。由于这些数据涉及商业机密,因此需进行归一化处理后再用于模型的训练和学习。将其中在产品规格容许误差范围内的数据通过线性变换规整到 $[0,1]$ 的闭区间中,超出临界值的数据则将落在该区间外,即可判定该芯片为不良品。由于被测芯片的部分测试参数测量值均符合产品规格要求,包含信息量小,且不会导致被测芯片被判定为不良品,因此无需对这类测试参数进行进一步分析,可提前进行优化。排除这类测试参数后,数据集 1 中需分析的备选测试参数只有 40 项。数据集 2 中备选测试参数为 29 项。

为了防止过拟合现象的出现,不能直接采用所有数据对模型进行训练,因此采用交叉验证的理念(cross validation),将数据集进行交叉验证。该概念最早由 Seymour Geisser 提出,其基本思想是将数据集按照某种规则分为训练集和验证集,训练集用于训练模型,验证集用于模型各项指标的测试。实验中,为保证数据样本中正、负样本的分布均衡,在训练集、验证集和测试集的分割过程中。

在模型训练中将所有的被测芯片按照 4:1 的比例分割为训练集和验证集,训练集用于模型训练,验证集用于验证模型的泛化及适应能力。同时训练过程中需获取调节超参数后对模型结果的影响,此时,算法将从训练集中随机分割部分被测芯片数据作为测试集,专门用于验证超参数变化对目标函数的影响。这一分割和训练将被

重复多次,为保证算法稳定性,最终的目标函数将由其中损失最大的一个模型决定。

使用预处理后的数据集来进行模型的超参数优化,如前文所述本次实验中使用分布式增强学习模块 Ray.tune 中的 HyperOptSearch 来进行自主调参,该模块可以将多组超参数配置进行并行运行,由于超参数配置的选择范围可能较大且需要在训练中进行一次次的配置效果检测,该方法无疑会节省非常多的配置时间。

在超参数训练配置完毕后,再使用分割好的训练集进行模型训练,在模型的整体训练完成后,将测试集数据输入模型中验证其删减测试参数后的测试效果。测试参数的删减是冗余特征的消除过程,也是特征选择的过程,冗余特征所包含的信息能够被其他特征所拟合出来,因此它们在学习任务中是无关的特征。特征选择能够在一定程度上缓解维度灾难^[29]的问题,同时去除少许特征通常会降低机器学习问题的难度,提高效率。

3.3 超参数的设置

XGBoost 算法中超参数分为通用参数(general parameters)、Booster 参数(booster parameters)、学习任务参数(learning task parameters)3 类。

本文中需优化的超参数按类型可分为:通用参数:1. booster,表示应用的弱学习器类型,可选择线性模型 gblinear、树模型 dart^[30]、gbtree 这 3 种模型;2. num_threads,表示训练过程中的并行线程数。

Booster 参数:1. learning_rate,也可用 eta 表示,代表学习速率;2. min_split_loss,也可用 gamma 表示,表示树要进行下一次分支操作时所需要的最小损失值;3. max_depth,表示树模型的最大深度;4. min_child_weight,表示最小的叶子节点所需要的实例权重总和,若在树的进一步划分过程中生成的叶节点实例权重和小于 min_child_weight,则树不再产生新的分支;5. subsample,表示训练实例的子样本比例;6. colsample_bytree,与 colsample_bylevel 和 colsample_bynode 一同为一组控制对列进行二次采样的参数组,该参数控制每个树被构造出时列的子样本比例;7. grow_policy,该值控制新节点加入树的方法,可选择从最靠近根节点的节点开始分支(depthwise)和在损失变化最大的节点开始分支(lossguide)。

学习任务参数:objective,表示目标函数,可选目标函数包括均方误差回归(reg:squarederror)和逻辑回归(reg:logistic)等。

本次学习任务中对超参数的配置范围如表 1 所示。

3.4 实验结果与分析

1) 实验 1 的实验结果如图 4、5 所示。

数据集 1 实验结果中,使用特征重要性排序的被测芯片,其 DPPM 在删减前 3 项测试参数时一直呈现线性

表 1 参数设置

Table 1 Parameter settings

参数名称	配置范围
booster	dart/gbtree
num_thread	最大可用线程数
learning_rate	$[10^{-4}, 1]$
min_split_loss	$[10^{-8}, 10]$
max_depth	$[1, 11]$, 取整
min_child_weight	$[1, 8]$, 取整
subsample	$[0.5, 1.0]$
colsample_bytree	$[0.3, 0.7]$
grow_policy	depthwise/lossguide
objective	均方误差回归 (reg: squareerror)

的趋势,当测试参数数目为 4 时,出现了一个较小波动,当测试参数 >7 ,DPPM 急剧上升;使用 Shapley 值排序时,DPPM 变化也几乎与特征重要性排序一致;使用故障数目排序的被测芯片,其 DPPM 在删减的测试参数个数 <8 时保持着较低水平,但之后呈波动式增长。

从图中可见,选择测试参数故障芯片数目作为评估指标,其性能表现远远优于本文中其他两种方法。若设置可接受的测试逃逸率在 20 PPM 以下,则两组数据中能够删减的测试参数可以分别达到 10 项和 7 项,占有可分析数据的 25%和 24.13%。文献[31]所使用的实验数据与本文相同,其原理是根据损失函数值依次删减测试参数,两组数据能够删减的测试参数分别到了 6 项和 5 项,因此本文所提出方法具备更好的性能。

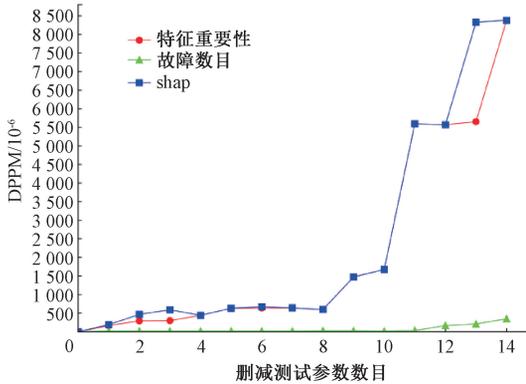


图 4 数据集 1 实验结果
Fig. 4 Results of group 1

2) 实验 2 的结果如图 6、7 所示。

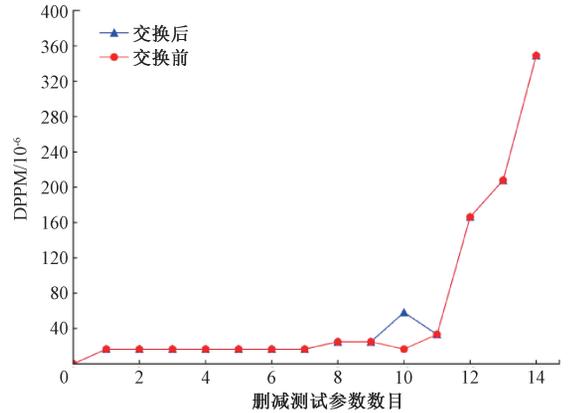


图 6 交换顺序后的数据集 1 实验结果

Fig. 6 Results of group 1 after exchange order

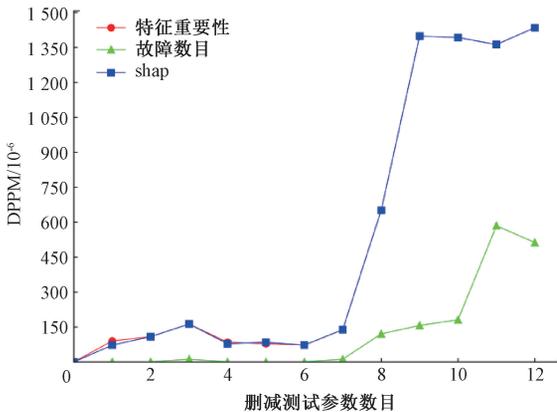


图 5 数据集 2 实验结果
Fig. 5 Results of group 2

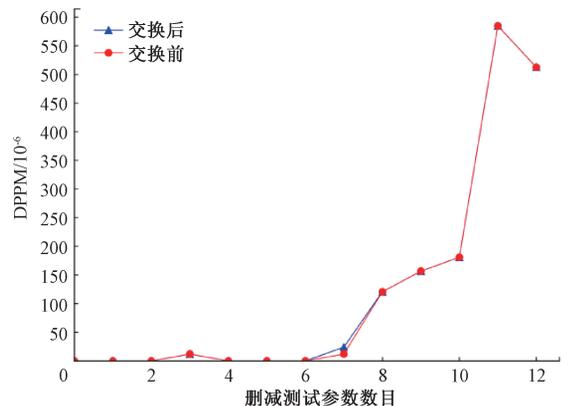


图 7 交换顺序后的数据集 2 实验结果

Fig. 7 Results of group 2 after exchange order

上升趋势,当测试参数数目 >8 时,DPPM 阶跃式上升;使用 Shapley 值排序时,DPPM 变化几乎与特征重要性排序相同;使用故障数目排序的被测芯片,其 DPPM 在删减测试参数数目到达 10 时都一直保持着稳定的低值,当删减参数个数 >10 之后几乎呈现线性增长。

数据集 2 实验结果中,使用特征重要性排序的被测芯片的 PPM 在删减的测试参数个数 <4 时呈现线性增长

从实验结果可知,交换顺序之后,数据集 1 和数据集 2 的可删减测试参数都减少了,数据集 1 的可删减测试参数数目由 10 减少到 9,数据集 2 的可删减测试参数数目由 7 减少到 6。这证明了删减测试参数顺序应严格按照故障数目顺序。

3) 实验3的结果如图8、9所示。

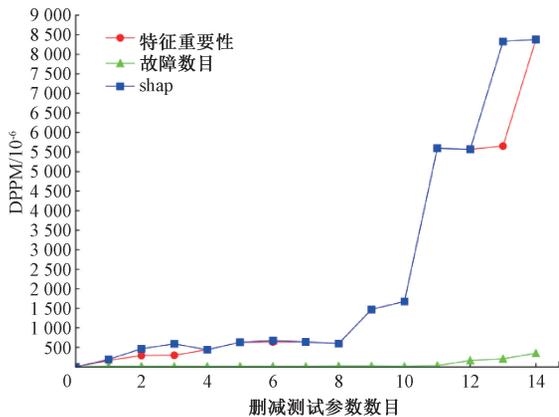


图8 数据增强后的数据集1实验结果

Fig. 8 Results of group 1 after data augmentation

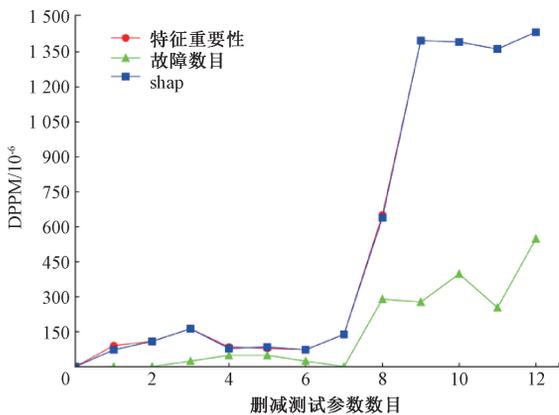


图9 数据增强后的数据集2实验结果

Fig. 9 Results of group 2 after data augmentation

从实验结果可以看出,对数据集进行数据加强后,根据故障数目来删减测试参数的性能表现依旧优于其他方式。但与数据增强前的实验相比,数据集1可删减的测试参数数目由10减少到7;数据集2可删除的测试参数数目不变,但是在删减过程中出现了更大的抖动。

4 结论

本文使用了故障样本数目、特征重要性和Shapley值来评估测试参数间的表征能力。在这3个指标中,故障样本数目是最有效的。实验表明其性能突出,最高能够获得25%的测试参数优化。同时,由于该方法能够静态优化模拟集成电路的测试参数,相较于自适应测试具有更好的适用范围。

在本文中,特征重要性和Shapley值的评估效果较差,因此未来的研究重点是如何将可解释性机器学习更好地应用到集成电路测试参数优化中。

参考文献

- [1] 陈巍. 关于芯片测试良品率和测试时间的优化研究[D]. 成都:电子科技大学, 2014.
CHEN W. The optimization study about improves the IC testing yield and reduce the testing time [D]. Chengdu: University of Electronic Science and Technology of China, 2014.
- [2] 张松鹤. 乒乓模式在IC量产测试中的应用[J]. 中国集成电路, 2011, 20(12): 63-67.
ZHANG S H. The application of ping-pong mode in IC production test [J]. China Integrated Circuit, 2011, 20(12): 63-67.
- [3] BROCKMAN J B, DIRECTOR S W. Predictive subset testing: Optimizing IC parametric performance testing for quality, cost, and yield [J]. IEEE Transactions on Semiconductor Manufacturing, 1989, 2(3): 104-113.
- [4] BISWAS S, BLANTON R D. Statistical test compaction using binary decision trees [J]. IEEE Design Test of Computers, 2006, 23(6): 452-462.
- [5] AMATI L, BOLCHINI C, SALICE F. Optimal test set selection for fault diagnosis improvement[C]. 2011 IEEE International Symposium on Defect and Fault Tolerance in VLSI and Nanotechnology Systems, 2011: 93-99.
- [6] SHUKOOR M A, AGRAWAL V D. A two phase approach for minimal diagnostic test set generation[C]. 2009 14th IEEE European Test Symposium, 2009: 115-120.
- [7] HIGAMI Y, SALUJA K K, TAKAHASHI H, et al. Compaction of pass/fail-based diagnostic test vectors for combinational and sequential circuits[C]. Proceedings of the 2006 Asia and South Pacific Design Automation Conference, 2006: 659-664.
- [8] BENNER S, BOROFFICE O. Optimal production test times through adaptive test programming[C]. Proceedings International Test Conference 2001 (CAT. No. 01CH37260). IEEE, 2001: 908-915.
- [9] LIANG H, WAN J, SONG T, et al. Identifying the optimal subsets of test items through adaptive test for cost reduction of ICs[J]. Electronics, 2021, 10(6): 680.
- [10] BADAWI H E, AZAÏS F, BERNARD S, et al. Evaluation of a two-tier adaptive indirect test flow for a front-end RF circuit [J]. Journal of Electronic Testing, 2021, 37: 225-242.
- [11] CHEN M, ORAILOGLU A. Test cost minimization through adaptive test development [C]. 2008 IEEE International Conference on Computer Design, 2008: 234-239.
- [12] 詹文法, 彭登辉, 邵志伟. 测试性能估算的测试集重排序方法[J]. 电子测量与仪器学报, 2021, 35(11): 54-60.

- ZHAN W F, PENG D H, SHAO ZH W. Test set reordering method for test performance estimation [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(11):54-60.
- [13] LI Y, YILMAZ E, SARSON P, et al. Online information utility assessment for per-device adaptive test flow [C]. 2018 IEEE 36th VLSI Test Symposium (VTS), 2018: 1-6.
- [14] LI Y, YILMAZ E, SARSON P, et al. Adaptive test for RF/Analog circuit using higher order correlations among measurements [J]. *ACM Transactions on Design Automation of Electronic Systems*, 2019, 24(4): 1-16.
- [15] SHI M, GAO J. Research on high altitude remote sensing building segmentation based on improved U-Net algorithm [J]. *Instrumentation*, 2021, 8(4): 8.
- [16] 于宁波, 刘嘉男, 高丽, 等. 基于深度学习的膝关节 MR 图像自动分割方法 [J]. *仪器仪表学报*, 2020, 41(6): 140-149.
- YU N B, LIU J N, GAO L, et al. Auto-segmentation method based on deep learning for the knee joint in MR images [J]. *Chinese Journal of Scientific Instrument*, 2020, 41(6): 140-149.
- [17] LIU X, CHEN Y, LI J, et al. Real-time robotic mirrored behavior of facial expressions and head motions based on lightweight networks [J]. *IEEE Internet of Things Journal*, 2022, 10(2): 1401-1413.
- [18] STRATIGOPOULOS H. Machine learning applications in IC testing [C]. 2018 IEEE 23rd European Test Symposium (ETS), 2018: 1-10.
- [19] WANG L, LUO M. Machine learning applications and opportunities in IC design flow [C]. 2019 International Symposium on VLSI Design, Automation and Test (VLSI-DAT), 2019: 1-3.
- [20] 易茂祥, 宋晨钰, 于金星, 等. 基于随机森林的集成电路适应性测试方法研究 [J]. *郑州大学学报(工版)*, 2021, 42(4): 13-18.
- YI M X, SONG CH Y, YU J X, et al. An adaptive test method of IC based on random forest [J]. *Journal of Zhengzhou University (Engineering Science)*, 2021, 42(4): 13-18.
- [21] WANG H, HE K. Improving test and diagnosis efficiency through ensemble reduction and learning [J]. *ACM Transactions on Design Automation of Electronic Systems (TODAES)*, 2019, 24(5): 1-26.
- [22] SONG T, HUANG Z, GUO X. RLDA: Valid test pattern identification by machine learning classification method for VLSI test [J]. *Microelectronics Journal*, 2022, 128: 105549.
- [23] 侯旺超, 梁华国, 宋钛, 等. 联合 mRMR 算法和 BP 神经网络的集成电路测试方法 [J]. *微电子学*, 2021, 51(5): 766-772.
- HOU W CH, LIANG H G, SONG T, et al. An integrated circuit test method based mRMR algorithm and BP neural network [J]. *Microelectronics*, 2021, 51(5): 766-772.
- [24] CHEN T, GUESTRIN C. XGBoost: A scalable tree boosting system [C]. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: Association for Computing Machinery, 2016: 785-794.
- [25] BREIMAN L. Random forests [J]. *Machine Learning*, 2001, 45(1): 5-32.
- [26] BERGSTRA J, YAMINS D, COX D. Making a science of model search: Hyperparameter optimization in hundreds of dimensions for vision architectures [C]. *International Conference on Machine Learning*. PMLR, 2013: 115-123.
- [27] BERGSTRA J, BARDENET R, BENGIO Y, et al. Algorithms for hyper-parameter optimization [J]. *Advances in Neural Information Processing Systems*, 2011, 24.
- [28] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions [J]. *Advances in Neural Information Processing Systems*, 2017, 30.
- [29] HASTIE T, TIBSHIRANI R, FRIEDMAN J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Second Edition [M]. Springer New York, 2009.
- [30] VINAYAK R K, GILAD-BACHRACH R. DART: Dropouts meet multiple additive regression trees [C]. *Artificial Intelligence and Statistics*. PMLR, 2015: 489-497.
- [31] XIAO Y, ZENG Y, WU Q, et al. Research on analog integrated circuit test parameter set reduction based on XGBoost [J]. *Journal of Electronic Testing*, 2022, 38(3): 279-288.

作者简介



肖寅东, 2004 年于电子科技大学获得学士学位, 2007 年于电子科技大学获得硕士学位, 2013 年于电子科技大学获得博士学位, 现为电子科技大学副教授, 主要研究方向为任意波形合成技术和自动测试系统。
E-mail: xydarcher@uestc.edu.cn

Xiao Yindong received his B. Sc. degree from University of Electronic Science and Technology in 2004, M. Sc. degree from University of Electronic Science and Technology in 2007, and Ph. D. degree from University of Electronic Science and Technology in 2013. He is now an associate professor at University of Electronic Science and Technology. His main research interests include arbitrary waveform generation techniques and automatic test system.