

DOI:10.19651/j.cnki.emt.2212526

基于邻域信息的细粒度在线适应性测试^{*}

汤宇新 梁华国 潘宇琦 易茂祥 鲁迎春
(合肥工业大学微电子学院 合肥 230009)

摘要:为了解决晶圆测试成本过高的问题,在适应性测试领域已经提出了一些基于空间相关性的质量预测方案。但这些方案大多为了降低成本而牺牲了过多的预测准确度。针对这一问题,提出了一种细粒度质量预测方法。该方法利用故障晶粒邻域率对空间相关性模型预测后的晶粒进行分类,针对不同类型的晶粒选择不同的测试集。此外,在进行晶粒测试集选择前还引入了空间验证步骤,这能够保证整个方案的测试质量。实验结果表明,本方法相较于间接测试方法,平均测试逃逸率降低了83%,平均测试项节省率提升了14%;相较于动态部分平均测试方法,平均测试逃逸率降低了81%,平均测试项节省率提升了17%。

关键词:晶圆测试;适应性测试;空间相关性;质量预测;故障晶粒邻域率

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

Fine-grained online adaptive test based on neighborhood information

Tang Yuxin Liang Huaguo Pan Yuqi Yi Maoxiang Lu Yingchun
(School of Microelectronics, Hefei University of Technology, Hefei 230009, China)

Abstract: In order to solve the problem of high cost of wafer test, some quality prediction solutions based on spatial correlation have been proposed in the field of adaptive test. But most of these solutions sacrifice too much forecast accuracy in order to reduce costs. To solve this problem, this paper proposes a fine-grained quality prediction method. This method uses the Bad Neighbor Ratio to classify the grains predicted by the spatial correlation model, and selects different test sets for different types of grains. In addition, a spatial verification step is introduced before the selection of the die test set, which can ensure the test quality of the entire solution. The experimental results show that compared with the indirect test method, the average test escape rate of the proposed method is reduced by 83%, and the average test item saving rate is increased by 14%. Compared with the dynamic part average test method, the average test escape rate is reduced by 81%, and the average test item saving rate is increased by 17%.

Keywords: wafer test; adaptive test; spatial correlation; quality predict; bad neighbor ratio

0 引言

芯片参数测试是集成电路生产制造的一个重要环节,通过测量芯片的各个参数并与测试限值进行比较,将故障芯片和好芯片进行区分^[1]。然而,随着先进集成电路工艺进入5 nm时代,单个芯片的复杂度急剧增加,这导致芯片测试需要更复杂的测试项目和更先进的测试设备。国际半导体技术路线图指出,测试成本在整个制造成本中占据的比例越来越大,有时甚至占主导地位^[2]。因此,如何有效降低测试成本成为集成电路测试领域的重大挑战。

为了应对这一挑战,已经有研究学者提出了一系列旨在降低测试成本的适应性测试方法,其中一个重要的方法

是利用空间相关性降低测试成本。基于空间相关性的方法是对晶圆上部分晶粒进行标准测试,并利用邻近晶粒质量存在聚集性的特点对剩下的晶粒做出质量预测。例如,杜克大学Li等提出的虚拟探针方法^[3-5],这种方法通过离散余弦变换对空间变化进行建模,利用小部分晶粒的测试结果能够捕获整个晶圆的空间相关性。在虚拟探针的基础上,有研究人员提出了一种隐马尔科夫树的空间建模方法,该方法进一步提升了虚拟探针的预测准确度^[6]。三星电子的研究人员提出一种基于深度学习的良率预测模型,该模型利用晶圆上芯片位置和芯片尺寸等空间特征建模^[7]。此外,空间相关性在晶圆图上表现为聚集性的故障模式,对于这种故障模式的学习为良率提升和根本原因分析提供了指

收稿日期:2022-12-31

*基金项目:国家重大科研仪器研制项目(62027815)、国家自然科学基金重点项目(61834006)资助

导致^[8-10]。尽管这些基于空间相关性的方法能够降低测试成本,但它们牺牲了过多的预测准确度。

另一种被广泛研究的适应性测试方法是利用测试项相关性降低成本,这种方法不用考虑故障晶粒在晶圆上的分布方式,只需要分析晶粒测试项之间的内在联系,它能够弥补空间相关性预测准确度不足的问题。近年来,已经研究了很多统计方法和机器学习算法来探索测试项相关性,例如索邦大学 Stratigopoulos 等^[11-12]利用统计模型筛选出测试子集来近似代替原始测试集的方法,杜克大学 Chakrabarty 提出了一种基于随机森林的细粒度适应性测试方法^[13]。类似的,还有一些基于机器学习探索测试项间相关性并对芯片质量预测的方法^[14-15]。测试项相关性方法虽然具有较高的预测准确度,但是过于复杂的建模使得它在成本节省方面远不如空间相关性方法。

综上所述,现有基于空间相关性的预测方案大多是粗粒度的,没有单独考虑每个晶粒的空间特性,这会导致对于晶粒质量变化比较大的区域预测准确度降低。针对这一问题,本文提出一种基于邻域信息的细粒度在线适应性测试方法。该方法在基于空间相关性建模预测的前提下,利用邻域信息来提升模型的预测准确度。首先依据邻域晶粒信息验证晶圆的空间相关性是否显著,对于显著的晶圆,进一步地利用故障晶粒邻域率(bad neighbor ratio, BNR)值的大小将晶粒分为故障随机类、边界类和故障聚集类,并对各类型的晶粒采取不同的测试方法;对于空间相关性不显著的晶圆则采用更加严格的测试方法。

1 研究背景

1.1 测试中的相关性

空间相关性是指晶圆上晶粒的测试值以某种方式和其邻近的晶粒相关^[16]。产生这种相关性的主要原因是相邻的晶粒具有相似的制造环境,因此具有相似的性能和参数^[17]。故障晶粒在晶圆图上的分布表现为两种形式:全局分布的随机故障和局部分布的聚集性故障^[18],聚集性故障就是空间相关性的具体表现。如图 1 所示的晶圆图,故障晶粒在边缘呈环状聚集,而在中间呈随机分布。利用这种相关性可以通过对晶圆上部分晶粒进行测试并预测出其他晶粒的测试结果。

各测试项之间可能存在线性相关性,这表明可以使用一些测试项的值线性组合去预测另一些测试项的值,而不需要实际测试^[19]。一旦确定了测试项之间的相关性,就可以对测试程序中的测试项进行重新排序,以便更有效地进行故障筛选,同时还可以删除一些冗余的测试项以减少测试时间^[18]。如果不存在这种相关性,则必须对所有测试项目进行完整测试。产生测试项相关性的原因有多种,例如在不同测试配置下被多次应用的测试项;以及测试同一个芯片相同功能的不同测试项。由于测试项相关性的存在,不同测试项的测试结果可能高度一致,因此只需要将相关

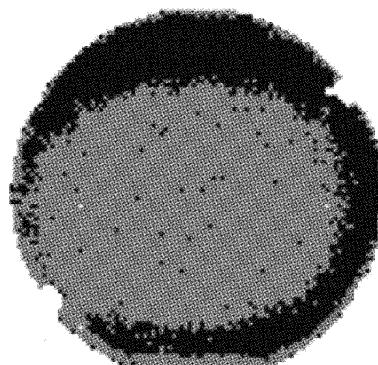


图 1 随机故障和聚集故障

测试项中最具代表的项添加到测试集中,绝大多数的芯片都可以被正确测试。

1.2 在线质量预测模型

基于机器学习的在线质量预测是适应性测试中一种重要的思路,现有的一些方案已经证实了这一思路能够有效降低测试成本^[20-22]。如图所示为基于机器学习的在线质量预测建模流程。跨晶圆的空间相关性可能受到工艺波动的影响而变得不显著,因此本文中训练空间模型的数据来自待测晶圆。首先在待测晶圆上抽样部分晶粒进行标准测试,并利用这部分晶粒的测试结果训练预测模型。未被抽样的晶粒则作为待测晶粒,由质量预测模型给出测试结果。接下来如图 2 所示,在建立空间相关性模型(以下简称空间模型)时,将晶粒的坐标(X, Y)作为特征,测试结果(Result)作为标签输入机器学习算法。将测试集晶粒的坐标输入训练好的学习机器,由最终迭代的决策树给出晶粒的预测结果。对于测试项相关性模型(以下简称测试项模型),首先需要进行特征测试项筛选,筛选出的测试项将作为特征训练测试项模型。对于待测晶粒,在通过测试项模型预测时仅需测试特征测试项,最终由训练好的模型对晶粒质量做出预测(通过/故障)。

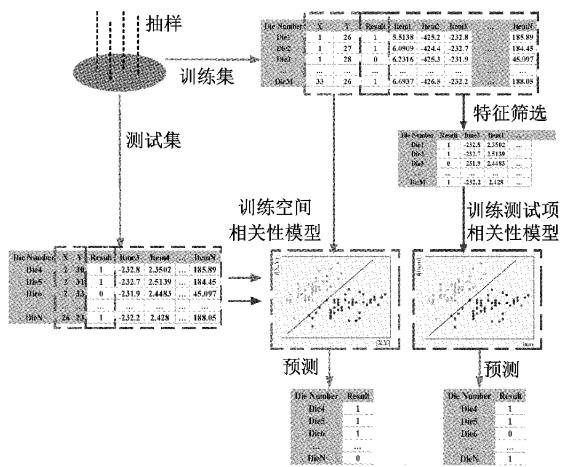


图 2 质量预测建模流程

1.3 故障晶粒邻域率

BNR 是指某个晶粒周围邻域中故障晶粒所占的比例。如果一个晶粒周围晶粒中大多数都是故障的,那么这颗晶粒也极有可能是不通过测试的。在此前提下,它可以作为一项衡量晶粒能否通过测试的概率指标。BNR 的计算表达式如下:

$$BNR_{mn} = 1 - \frac{1}{N} \sum y_{ab}$$

$$(m-1 \leq a \leq m+1, n-1 \leq b \leq n+1) \quad (1)$$

其中, BNR_{mn} 表示第 m 行和第 n 列的 BNR 值, y_{ab} 表示周围晶粒的测试结果(0 表示故障,1 表示通过), N 则表示周围可用晶粒数量。在对近 300 万粒晶粒进行 BNR 计算后给出表 1, 表中第 1 行列出了依据 BNR 分的 5 个区间, 第 2 行表示这 5 个区间中出现故障晶粒的概率^[23]。从表中可以看出当 BNR 介于 0~0.2 时, 故障晶粒占比非常低, 在此区间的晶粒称为故障随机类; 介于 0.2~0.8 区间内的晶粒称为边界类; 而当晶粒 BNR 值处于 0.8~1 之间时, 绝大多数的晶粒都是故障晶粒, 此时晶粒为故障聚集类。

表 1 不同 BNR 区间故障晶粒的概率

BNR	0~0.2	0.2~0.4	0.4~0.6	0.6~0.8	0.8~1
$P_{\text{故障}} / \%$	0.63	16.03	51.12	68.87	95.24

2 细粒度适应性测试方法

本节将详细描述所提出的细粒度适应性测试方法。如图 3 所示,该方法分为 3 个阶段:1)质量预测;2)空间验证;3)测试集选择。在阶段 1),训练空间模型并对待测晶粒进行质量预测。然而并不是所有类型的晶圆都可以被空间模型准确预测,较大的预测误差会影响 BNR 的计算结果。因此,在阶段 2)中提出一种空间验证方法来判断空间模型的有效性。对于有效的晶圆,在阶段 3)中依据 BNR 值对晶粒进行细粒度的测试集选择;而无效的晶圆将采用测试项相关性模型补充预测。

2.1 质量预测

1) 数据预处理

为了实现整个测试流程,需要在训练模型之前对测试数据进行预处理,预处理阶段要解决的两个问题:(1)数据缺失;(2)测试数据不平衡。在实际的测试数据集上,由于测试过程中电压不稳定,电流过大等原因,造成部分数据缺失。同时,由于测试过程中采用“首败即停”的策略,即晶粒只有在通过当前测试项的前提下才会对下一项进行测试,因此当晶粒未通过某一测试项,则无法获取后面的数据。对于这部分缺失的数据将按如下方式处理:使用同一测试项目下无故障晶粒测试值的中位数填充。

在晶圆测试过程中,不平衡数据的存在是因为大多数

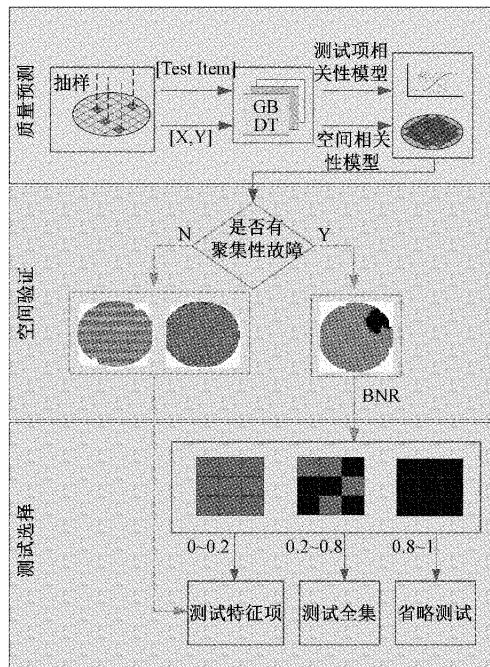


图 3 基于邻域信息的细粒度适应性测试流程

芯片都会通过所有测试项目,而机器学习算法在不平衡数据面前常常会表现得不尽人意。因此将算法应用于数据之前,需要先进行数据平衡处理。为了解决这一问题,本文利用自适应综合过采样算法对故障晶粒数据赋予更高的权重,从而生成更多的故障晶粒数据,这种过采样算法的优点在于它不会改变无故障晶粒数据的分布,有利于减少不同类别数据之间的重叠。

2) 测试项筛选

测试项筛选的目的是在保证测试质量的前提下,获得一个降低测试成本的测试项子集,也称作特征测试项。这些筛选出的测试项将被用于建立测试项相关性模型。本文中使用的测试项筛选算法是基于互信息的最大相关最小冗余(max-relevance and min-redundancy, mRMR)算法,这种算法在考虑测试项之间关系的同时也考虑了测试项对最终良率的影响。互信息是一种用于评估 CP 测试项之间的冗余性和测试项与最终良率之间相关性的指标。mRMR 算法依据互信息对测试项进行排序,排序结果并不会受到后续建模算法的影响,因此这种测试项筛选方法具有很好的移植性。

mRMR 作为一种过滤式的特征选择算法,它只会得到测试项的重要性排序,而并不会给出最优的测试项子集。在本项工作中,将利用训练集的晶粒来确定最优子集。首先从训练集部分的晶粒抽样 70%,利用这部分晶粒信息可以得到基于 mRMR 的测试项重要性排序,接下来建模预测训练集剩下 30% 的晶粒,不断往最终测试项集合 f_{select} 中添加测试项,找到均方根误差(root mean square error, RMSE)对应最低的 f_{select} , RMSE 反应的是预测值和实际

值之间的偏差程度,越小则代表预测效果越好。如图4所示为不同测试项数对应的均方根误差,图中横坐标代表测试项数目,纵坐标代表RMSE,虚线标注的是所选测试子集中测试项的个数,虚线的位置是通过寻找RMSE的局部最小值来确定的。

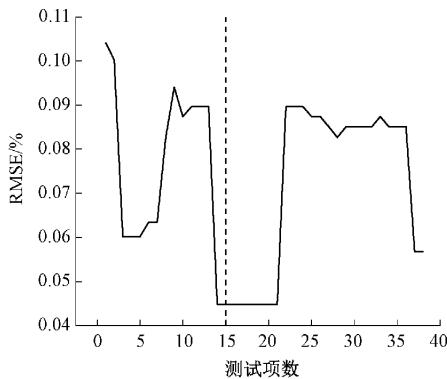


图4 不同测试项数的均方根误差

3) 质量预测

在数据预处理和测试项筛选之后,可以训练机器学习算法建立质量预测模型。本文选取的机器学习算法为梯度提升决策树(gradient boosting decision tree, GBDT)。该算法的主要步骤如下:GBDT模型由M棵决策树组成,首先需要初始化第一棵决策树 $f_0(x)$,使它的损失函数 $L(y_i, \gamma)$ 最小化;其次迭代训练 $m=1, 2, \dots, M$ 棵树,计算每个样本 $i=1, 2, \dots, N$ 的负梯度 r_{im} ,将负梯度作为下一棵树的残差估计并拟合得到新树,新树上的叶子节点区域为 R_{jm} ($j=1, 2, \dots, J_m$)。对每个叶子节点 $j=1, 2, \dots, J_m$ 计算最佳拟合,即让损失函数最小,拟合叶子节点最好的输出值 γ_{jm} 。接下来更新强学习器 $f_m(x)$,第 m 轮下的强学习器等于第 $m-1$ 轮下的强学习器加上第 m 轮的弱学习器。最后,更新最终的学习器 $\hat{f}(x)$ 并由它给出晶粒的预测结果。

利用训练好的GBDT算法建立质量预测模型,并对待测晶粒进行质量预测。如图5所示为两组原始晶圆图和通过预测得到晶圆图的对比。从图中可以看出当晶圆上故障晶粒呈随机分布时,空间模型对故障晶粒的预测结果绝大部分都是错误的,这将导致较大的测试逃逸。此时认为空间模型在此块晶圆上并不适用。当晶圆上故障晶粒呈聚集性分布时,空间模型对故障聚集区能够有效地预测,但对于好晶粒和故障晶粒边界处预测效果不佳。因此为了有效提升空间模型的预测准确度,首先需要验证晶圆上是否有聚集性故障;其次针对有聚集性故障的晶圆需要重点解决边界处和故障晶粒随机分布处预测错误较多的问题。

2.2 空间验证

为了验证空间模型的有效性,本文引入了一种空间验证方法。所提出的空间验证方法仅依赖于第一阶段中的训练集晶粒。假设 $S_1 = (y_1 | X_1, y_2 | X_2, \dots, y_Q | X_Q)$ 代表

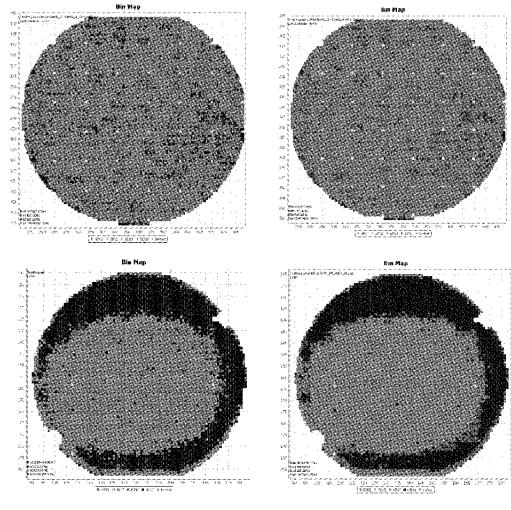


图5 原始晶圆图和预测晶圆图对比

训练集晶粒,其中 y 代表训练集晶粒的测试结果(1代表通过,0代表故障), X 代表晶粒的笛卡尔坐标, Q 代表训练集晶粒的个数。接下来计算训练集中晶粒 i 周围 3×3 邻域晶粒预测的平均值:

$$y_i = \frac{1}{v} \sum_{j=1}^v \hat{y}_j \quad (2)$$

v 表示训练集晶粒周围实际的晶粒的个数 \hat{y}_j 表示第 j 个邻域的预测标签($j < v$)。计算出平均值后,可以得到平均值和实际值之间的差值:

$$\epsilon_i = y_i - \bar{y}_i \quad (3)$$

最后,计算空间验证指标:

$$\epsilon = \frac{1}{Q} \sum_{k=1}^Q \epsilon_k \quad (4)$$

影响空间模型预测准确度的根本问题在于晶圆上故障晶粒分布是聚集性还是随机性。空间模型对故障晶粒随机分布的晶圆会预测出与训练样本差距很大的邻域值 y_i ,这种差异会导致式(2)中的 ϵ_i 较大,因此计算出的空间验证指标 ϵ 较大;而对有聚集性故障的晶圆会预测出与训练样本差距较小的邻域值 \bar{y}_i ,因此计算出的空间验证指标 ϵ 较小。特别地,当晶圆上故障晶粒较少时,空间模型会将整个测试集都预测为无故障,此时计算出的空间验证指标会比有聚集性故障晶圆的更小。只用空间模型预测这类晶圆会造成较多的测试逃逸,因此需要对这类晶圆进行测试项模型补充预测。本文将依据空间验证指标对下一阶段测试做出指导, ϵ_1 和 ϵ_2 为用于判断晶圆是否存在聚集性故障晶粒的上下限值。

1)当 $\epsilon_1 > \epsilon$ 或 $\epsilon_2 < \epsilon$,则认为该晶圆上故障晶粒分布没有聚集性,对它采用测试项模型补充预测。

2)当 $\epsilon_1 \leq \epsilon \leq \epsilon_2$ 时,则认为该晶圆上故障晶粒分布有聚集性,它将进入下一阶段的测试集选择。

2.3 测试集选择

为了进一步解决有聚集性故障晶圆边界处和随机分布处预测效果不佳的问题,提出了基于 BNR 的细粒度测试集选择。首先计算待测晶粒的 BNR,并基于 BNR 将它们划分为三种类型:故障随机类($0 \leq BNR < 0.2$)、边界类($0.2 \leq BNR \leq 0.8$)、故障聚集类($0.8 < BNR \leq 1$)。如图 6 所示,故障随机类中故障晶粒占少数但是分布比较随机,邻近晶粒的测试结果没有明显的关联性,此时空间模型难以抓取其中的相关性。而测试项相关性模型不会受到故障晶粒随机分布的影响,它只考虑测试项之间的关系,因此对故障随机类晶粒采用测试项模型测试。而边界类晶粒分布在好晶粒和故障晶粒的边界区域,这类晶粒数量相对较少并且质量差异性大,因此不适合采用质量预测的方法。故对边界类的晶粒将采用更加严格的标准测试,即施加完整的测试集。在故障聚集类中,故障晶粒占据了主要部分,这也意味着这类晶粒的空间相关性较强。对于这一类的晶粒将不再增加额外的测试,而是选择相信空间模型的预测结果。

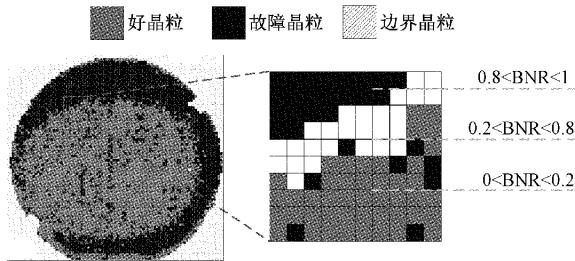


图 6 基于 BNR 的晶粒分类

3 实验结果

3.1 实验平台设置以及数据描述

本次实验运行环境为 Intel i7-7700 CPU, 16 G 运行内存, Windows 10 系统。实验所用仿真平台为 python3.7, 主要用到的库为 scikit-learn。实验数据选取了来自实际工业生产过程中 3 个不同批次的模拟芯片测试结果, 每个批次 8 块晶圆, 总计 488 536 块晶粒。本次实验中抽样的训练集晶粒占 30%, 测试集的比例占 70%。在 3 个批次数据中, 批次 2 是有聚集性故障晶粒的晶圆, 批次 1 和 3 则是故障晶粒随机分布的晶圆。实验数据具体信息如表 2 所示。

表 2 实验数据分布

批次	平均晶粒个数	平均良率/%	测试项数
Lot1	15 992	88.18	22
Lot2	31 970	89.48	66
Lot3	10 668	98.91	39

3.2 计算空间验证指标

对 3 个批次的晶圆分别使用空间模型之后, 对模型进行空间验证指标计算, 计算结果如图 7 所示。图中横坐标

表示每个批次的晶圆 ID, 纵坐标表示空间验证指标。本次实验基于历史数据的计算, 在权衡了测试逃逸和预测准确度之后, 最终设置 $\epsilon_1 = 3\%$, $\epsilon_2 = 8\%$ 。从图中可以观察到批次 1 中整体 ϵ 是高于 8% 而批次 3 整体 ϵ 是低于 3%, 因此批次 1 和批次 3 是 2.2 节中定义的第(i)类晶圆; 而批次 2 的 ϵ 是分布在 3%~8%, 因此批次 2 中的晶圆对应于第(ii)类型。

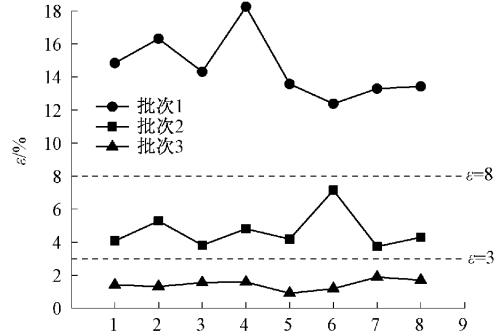


图 7 3 个批次空间验证指标分布

根据空间验证指标的计算结果, 对批次 1 和批次 3 的晶圆将采用测试项模型补充预测。两个批次实验结果如图 8 所示, 从图中可以看出本文方案的测试逃逸数少且整体波动较小, 这说明本文方案在批次 1 和 3 的晶圆上具有低测试逃逸和高稳定性等特点。

3.3 测试集选择结果

根据上述结果, 批次 2(有聚集性故障)的晶圆将进行进一步的测试集选择处理。如表 3 所示为批次 2 中待测晶粒的测试集选择结果, 表中展示了不同类型晶粒的测试逃逸数, 测试项数以及该类型的晶粒个数。从表中可以看出批次 2 中晶圆的测试逃逸和使用的测试项均在较低的水平。图 9 所示为仅用空间模型预测和增加测试集选择后预测准确率的对比。从图中可以看出在增加测试集选择后, 批次 2 中八块晶圆在预测准确率上均有提升, 并且在测试集选择后平均预测准确度达到了 99.9% 以上。因此, 本文提出的测试集选择方法能够有效提升空间模型对有聚集性故障的预测准确度。

3.4 方案对比

本次实验与 2017 年提出的动态部分平均测试方法^[12]、2020 年提出的间接测试方法^[15]以及标准测试方法进行比较, 实验主要比较了平均测试逃逸, 测试项节省率, 单个晶粒平均测试时间。测试项节省率表示相较于标准测试节省测试项的比例。该指标的计算公式如下:

$$TIR = 1 - \frac{N_{Train} \times T_{All} + N_{Test} \times T_{Select}}{N \times T_{All}} \quad (5)$$

式中: N_{Train} , N_{Test} , N 分别代表训练集, 测试集和总晶粒的个数; T_{All} 代表所有的测试项; T_{Select} 表示通过测试项筛选算法选择出的测试项集合。

由于不同 ATE 测试成本不同, 因此在本文中采用单个

表3 批次2测试集选择结果

0≤BNR<0.2			0.2≤BNR≤0.8			0.8<BNR≤1		
测试逃逸	测试项数	晶粒数	测试逃逸	测试项数	晶粒数	测试逃逸	测试项数	晶粒数
晶圆1	2	16	22 960	0	66	517	3	0
晶圆2	2	27	21 650	0	66	652	0	7 274
晶圆3	1	28	24 114	0	66	279	2	0
晶圆4	1	23	24 759	0	66	271	0	2 422
晶圆5	2	25	24 571	0	66	382	0	2 212
晶圆6	2	26	26 475	0	66	489	2	1 814
晶圆7	3	26	21 214	0	66	370	0	3 994
晶圆8	1	26	23 678	0	66	324	0	3 264

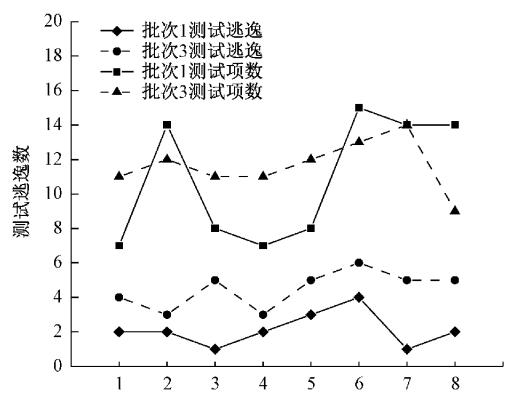


图8 批次1和批次3测试结果

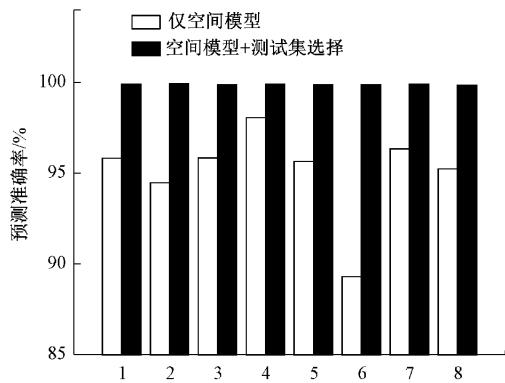


图9 批次2测试集选择前后预测准确率对比

晶粒的平均测试时间作为成本衡量的标准,平均测试时间越低说明测试的成本越低。此外,为了对比方案的稳定性,对每个批次中八块晶圆的测试逃逸做了标准差计算,标准差越小代表方案对于测试逃逸的稳定性越强。

表4~6分别展示了3个批次的实验结果对比,从表中可以看出本文方法相较于其他3种测试方法在测试逃逸,测试项节省以及测试时间上均体现了一定的优越性,并且本方案对于测试逃逸的稳定性也优于其他两种方法。因此,本文所提出的测试方法在保证测试质量的前提下,有效地缩减了测试成本。

表4 批次1对比实验结果

	平均测试 逃逸	测试项 节省率/%	平均测试 时间/ms	标准 差值
本文方案	2.13	42.43	1 162.03	0.99
文献[12]	75.75	40.45	1 231.98	12.12
文献[15]	47.3	36.25	1 321.85	6.75
标准测试	0	0	1 718	0

表5 批次2对比实验结果

	平均测试 逃逸	测试项 节省率/%	平均测试 时间/ms	标准 差值
本文方案	2.63	49.36	720.62	1.41
文献[12]	24	17.73	1 141.62	14.93
文献[15]	16.75	26.74	940.54	8.92
标准测试	0	0	1 461.42	0

表6 批次3对比实验结果

	平均测试 逃逸	测试项 节省率/%	平均测试 时间/ms	标准 差值
本文方案	4.5	44.23	397.84	1.07
文献[12]	10.5	25.4	550.24	4.99
文献[15]	15.5	30.45	500.44	6.42
标准测试	0	0	943.12	0

4 结 论

本文提出了一种基于邻域信息的细粒度在线适应性测试方法,能够提升空间相关性模型的预测准确度,并且有效降低了晶圆测试的成本。该方法通过BNR对晶粒进行分类,BNR介于0~0.2的晶粒采用测试项相关性模型预测,BNR介于0.8~1.0的晶粒采用空间模型预测,而BNR介于0.2~0.8的晶粒则采用更为严格的标准测试。为保证模型预测准确度以及减少不必要的BNR计算,在进行BNR分类前引入空间验证步骤。使用来自多个批次

CP 测试数据的实验结果表明,本文相较于标准测试方法,能够达到 54% 的平均测试项节省和 51% 的平均单个晶粒测试时间节省。与以往的适应性测试方法相比,本文在测试逃逸和测试成本上都体现出优越性。

参考文献

- [1] XIAO B, XIONG J, SHI Y. Novel applications of deep learning hidden features for adaptive testing[C]. 2016 21st Asia and South Pacific Design Automation Conference(ASP-DAC). IEEE, 2016: 743-748.
- [2] PAN R, ZHANG Z, LI X, et al. Black-box test-cost reduction based on Bayesian network models[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2020, 40(2): 386-399.
- [3] CHANG H M, CHENG K T, ZHANG W, et al. Test cost reduction through performance prediction using virtual probe[C]. 2011 IEEE International Test Conference. IEEE, 2011: 1-9.
- [4] ZHANG W, LI X, LIU F, et al. Virtual probe: A statistical framework for low-cost silicon characterization of nanoscale integrated circuits [J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2011, 30(12): 1814-1827.
- [5] ZHANG W, BALAKRISHNAN K, LI X, et al. Spatial variation decomposition via sparse regression[C]. 2012 IEEE International Conference on IC Design & Technology, IEEE, 2012: 1-4.
- [6] LIAO C, TAO J, ZENG X, et al. Efficient spatial variation modeling of nanoscale integrated circuits via hidden Markov tree [J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2015, 35(6): 971-984.
- [7] JANG S J, KIM J S, KIM T W, et al. A wafer map yield prediction based on machine learning for productivity enhancement[J]. IEEE Transactions on Semiconductor Manufacturing, 2019, 32(4): 400-407.
- [8] LI K S M, LIAO P Y Y, CHENG K C C, et al. Hidden wafer scratch defects projection for diagnosis and quality enhancement[J]. IEEE Transactions on Semiconductor Manufacturing, 2020, 34(1): 9-16.
- [9] LI K S M, CHEN L L Y, CHENG K C C, et al. TestDNA-E: Wafer Defect Signature for Pattern Recognition by Ensemble Learning [J]. IEEE Transactions on Semiconductor Manufacturing, 2022, 35(2): 372-374.
- [10] LI K S M, CHEN L L Y, LIAO P Y Y, et al. Wafer Scratch Pattern Reconstruction for High Diagnosis Accuracy and Yield Optimization [J]. IEEE Transactions on Semiconductor Manufacturing, 2022, 35(2): 272-281.
- [11] STRATIGOPOULOS H G, STREITWIESER C. Adaptive test flow for mixed-signal ICs[C]. 2017 IEEE 35th VLSI Test Symposium (VTS). IEEE, 2017: 1-6.
- [12] 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, 2017, 37(10): 2125-2138.
- [13] LIU M, PAN R, YE F, et al. Fine-grained adaptive testing based on quality prediction [J]. ACM Transactions on Design Automation of Electronic Systems(TODAES), 2020, 25(5): 1-25.
- [14] EL BADAWI H, AZAIS F, BERNARD S, et al. Implementing indirect test of RF circuits without compromising test quality: a practical case study[C]. 2020 IEEE Latin-American Test Symposium(LATS), IEEE, 2020: 1-6.
- [15] EL BADAWI H, AZAIS F, BERNARD S, et al. Investigations on the use of ensemble methods for Specification-Oriented indirect test of RF circuits[J]. Journal of Electronic Testing, 2020, 36(2): 189-203.
- [16] LIN F, HSU C K, CHENG K T. Learning from production test data: Correlation exploration and feature engineering[C]. 2014 IEEE 23rd Asian Test Symposium, IEEE, 2014: 236-241.
- [17] LIN F, HSU C K, CHENG K T. AdaTest: An efficient statistical test framework for test escape screening [C]. 2015 IEEE International Test Conference(ITC), IEEE, 2015: 1-8.
- [18] KYEONG K, KIM H. Classification of mixed-type defect patterns in wafer bin maps using convolutional neural networks [J]. IEEE Transactions on Semiconductor Manufacturing, 2018, 31(3): 395-402.
- [19] HSU C K, LIN F, CHENG K T, et al. Test data analytics—Exploring spatial and test-item correlations in production test data[C]. 2013 IEEE International Test Conference(ITC), IEEE, 2013: 1-10.
- [20] PAN R, ZHANG Z, LI X, et al. Black-box test-cost reduction based on Bayesian network models[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2020, 40(2): 386-399.
- [21] KATRAGADDA V, MUTHEE M, GASASIRA A, et al. Algorithm based adaptive parametric testing for outlier detection and test time reduction[C]. 2018 IEEE International Conference on Microelectronic Test

- Structures(ICMTS), IEEE, 2018; 142-146.
- [22] KUO Y T, LIN W C, CHEN C, et al. Minimum operating voltage prediction in production test using accumulative learning [C]. 2021 IEEE International Test Conference(ITC), IEEE, 2021; 47-52.
- [23] YANG C H, YEN C H, WANG T R, et al. Identifying good-dice-in-bad-neighborhoods using artificial neural networks[C]. 2021 IEEE 39th VLSI

Test Symposium(VTS), IEEE, 2021; 1-7.

作者简介

汤宇新,硕士研究生,主要研究方向为集成电路适应性测试。

E-mail: tyx18756342937@163.com

梁华国(通信作者),教授,博士生导师,主要研究方向为容错计算与硬件安全、嵌入式系统综合与测试。

E-mail: huagulg@hfut.edu.cn