

DOI: 10.19650/j.cnki.cjsi.J2514314

一种 GMM-KL 动态预测集成电路测试 设备稳定性的方法^{*}

詹文法, 弥 晨, 胡心怡, 邱 野

(安庆师范大学电子信息与集成电路学院 安徽 246133)

摘 要:随着集成电路测试精度要求的不断提高,测试设备自身的长期运行稳定性已成为影响测试质量与成本的关键因素。传统基于固定置信水平阈值的监测方法因其静态特性,难以适应设备在长期运行中因老化、环境波动等引起的性能动态漂移,常导致误报或漏报,制约了预测性维护的实现。为此,提出一种融合高斯混合模型(GMM)与 KL 散度的动态阈值优化监测方法。该方法首先利用 GMM 对测试数据的多模态分布进行精确建模,有效刻画设备在复杂工况下的运行状态;进而引入 KL 散度实时量化监测数据与健康基准模型之间的分布差异;在此基础上,创新性地基于历史 KL 散度序列滚动更新异常判定阈值,使阈值能够随数据分布的自然漂移而自适应调整。这一机制从根本上克服了静态阈值与动态过程之间的失配问题,提升了监测系统对缓慢性能退化与突发异常的感知能力。实验结果表明,相较于传统的 K 均值聚类固定阈值方法,所提方法在异常检测准确率与 $F1$ 分数上均取得显著提升,能够更灵敏、可靠地识别测试设备的性能波动与早期故障。该方法不仅为集成电路测试设备的稳定性监测与预测性维护提供了有效技术手段,其通过概率建模感知分布变化并实现阈值自适应的核心框架,也具备向其他工业装备健康管理领域推广的潜力。该框架通用性强,为动态运行环境下的设备状态监控提供了具备持续适应能力的新思路。

关键词: 集成电路测试设备;异常检测;高斯混合模型;KL 散度;动态阈值;稳定性分析

中图分类号: TH707 **文献标识码:** A **国家标准学科分类代码:** 510.40

A GMM-KL dynamic prediction method for the stability of integrated circuit testing equipment

Zhan Wenfa, Mi Chen, Hu Xinyi, Qiu Ye

(School of Electronic Information and Integrated Circuit, Anhui 246133, China)

Abstract: With the increasing precision requirements for integrated circuit testing, the long-term operational stability of the test equipment has become a key factor affecting test quality and cost. Traditional monitoring methods based on fixed confidence-level thresholds, due to their static nature, struggle to adapt to the performance drift caused by aging and environmental fluctuations during long-term operation. As a result, they often suffer from false alarms or missed detections, which hinders the implementation of predictive maintenance. To address this issue, a dynamic threshold optimization monitoring method integrating Gaussian mixture model (GMM) and Kullback-Leibler divergence (KL divergence) is proposed. This method first uses a GMM to accurately model the multimodal distribution of test data, effectively characterizing the equipment's operational state under complex multi-condition scenarios. It then introduces KL Divergence to quantify in real-time the distribution difference between the monitoring data and the healthy baseline model. Building on this, it innovatively updates the anomaly detection threshold based on a rolling historical KL Divergence sequence, allowing the threshold to adaptively adjust according to the natural drift in data distribution. This mechanism fundamentally overcomes the mismatch between static thresholds and dynamic processes, enhancing the monitoring system's sensitivity to both gradual performance degradation and sudden anomalies. Experimental results show that compared to the traditional K-means clustering method with a fixed threshold, the proposed method achieves significant improvements in both anomaly detection accuracy and $F1$ -score, enabling more

收稿日期: 2025-07-24 Received Date: 2025-07-24

^{*} 基金项目: 国家自然科学基金面上项目(62474002)、国家自然科学基金重大研究计划项目(92573109)资助

sensitive and reliable identification of performance fluctuations and early-stage faults in test equipment. This method not only provides an effective technical solution for stability monitoring and predictive maintenance of integrated circuit test equipment, but also holds potential for extension to other industrial equipment health management fields due to its core framework of sensing distribution changes through probabilistic modeling and achieving threshold self-adaptation. This framework demonstrates strong generalizability, offering a new approach with continuous adaptation capabilities for equipment condition monitoring in dynamic operational environments.

Keywords: integrated circuit test equipment; anomaly detection; Gaussian mixture model; KL divergence; dynamic threshold; stability analysis

0 引言

集成电路(integrated circuit, IC)测试作为保障芯片最终质量与可靠性的核心环节,其重要性随着半导体工艺迈入纳米尺度而愈发凸显^[1]。现代芯片具有高度的复杂性,这使得测试数据量急剧攀升,测试成本占比已超过35%^[2-4]。在此情况下,测试设备自身的长期运行稳定性成为影响测试精度、生产效率与成本控制的关键因素^[5-7]。设备在持续运行过程中,由于老化、环境波动等因素,会出现性能缓慢漂移的情况,这对监测方法的适应性与精准度提出了严峻挑战^[8]。这种细微却持续的漂移,若不能及时被察觉并预警,将直接导致测试结果不准确、产品良率下降,甚至引发计划外停机,进而造成重大的经济损失。

测试设备稳定性的监测,本质上是识别其性能从“健康”状态向“异常”状态的动态偏移过程。传统方法大多依赖基于固定置信水平的静态阈值或参数化模型。例如,近期研究运用K均值聚类(K-means)算法与正态分布上侧边界值进行稳定性预测^[9],为量化评估提供了有效思路。然而,这类方法存在根本局限性,即假设测试数据的分布是稳定不变的,而实际设备状态处于动态变化之中。静态阈值难以适应动态过程,阈值设置过高会漏报早期退化情况,过低则会导致误报大量增加^[10]。这种局限性源于对设备长期运行中固有的非平稳性与渐进性变化模式的忽视。

为应对上述挑战,研究者们开始采用更具适应性的概率模型。高斯混合模型(Gaussian mixture model, GMM)作为一种强大的概率生成模型,能够通过多个高斯分布的线性组合灵活逼近任意复杂的概率密度函数,在工业健康管理(prognostics and health management, PHM)领域已成为刻画设备多状态、多工况特性的主流工具之一。其应用已广泛涉及多个关键领域:在旋转机械监测方面,GMM用于对轴承、齿轮等部件的振动信号进行健康状态建模与早期故障识别^[11-12];在流程与电力系统监控中,GMM用于多模态过程状态评估^[13];在结构健康监测方面,GMM成功应用于处理时变环境下的导波信号,实现了对飞机结构裂纹^[14]、螺栓连接松动^[15]等损伤的可靠评估与定位;此外,在颤振监测^[16]、绞车故障预

警^[17]、软测量建模^[18]、工厂设备集相似度计算^[19]等多个场景也得到有效应用。这些实践充分证明了GMM在处理高维、非高斯、多模态工业数据方面的显著优势。

与之相辅相成的是,KL散度(Kullback-Leibler divergence)作为一种源于信息论的严格度量,能够量化两个概率分布之间的“距离”或信息差异,在PHM的动态评估环节发挥着不可替代的作用。例如,在多模态过程监控中,KL散度被直接用作统计量,可无延迟地检测过程的细微变化^[20];在机械故障诊断中,KL散度可从振动信号中定向提取与故障相关的敏感特征^[21];在带式输送机监测中,基于信息熵-高斯混合模型(information entropy-Gaussian mixture model, IE-GMM)和KL散度的方法用于检测大块煤^[22]。KL散度将复杂的设备状态变化转化为一个可计算、可追踪的标量,为实时的健康评估与预警决策提供了核心依据^[23]。在轴承状态监测领域,基于深度对比一类分类的方法进一步提升了异常检测的精度^[24],而基于声信号的托辊轴承故障预警^[25]和基于音频处理的轴承劣化预警^[26]也印证了信息论度量在状态评估中的有效性。

尽管GMM与KL散度在各自领域已得到验证并广泛应用,但通过系统分析现有研究发现,将二者深度融合以构建自适应稳定性监测系统时,存在一个普遍的关键局限:即“离线的静态基准”与“在线的动态过程”之间的匹配问题。具体来说,作为健康基准的GMM模型通常基于历史数据离线训练并固定,难以自适应地追踪设备因长期老化、环境累积效应导致的性能基线缓慢漂移;基于KL散度的异常决策阈值大多依据历史健康数据的静态统计设定,无法随数据分布的自然演变进行在线优化调整。这种静态特性致使现有系统在面对设备全生命周期的渐进性衰退时,预警的灵敏度与可靠性降低,难以实现真正的“预测性”维护。

值得注意的是,这一“静-动态不匹配”挑战并非个例,在核电、航天、流程工业等高端装备的智能监测领域,研究者们同样面临如何使模型与阈值适应系统动态演变的核心难题。近期相关研究为解决此问题提供了极具价值的思路:核电厂控制棒驱动机构监测采用多线圈联动图结构与移动图卷积网络捕捉动态耦合关系^[27];航天器遥测数据异常检测则用融合特征增强的长短期记忆网络

(feature-enhanced-long short-term memory, Feen-LSTM) 模型融合 Transformer 与长短期记忆网络 (long short-term memory, LSTM) 提取特征, 搭配指数加权平均动态阈值实现无监督在线检测^[28]; 堆外中子探测器故障检测融合时序卷积网络和图卷积网络提取时空特征, 并设计基于历史残差统计的动态阈值^[29]; 水泥脱硝系统通过滑动窗口斜率异常检测与 Z 分数 (Z-Score) 算法结合修正异常数据, 再结合多步时滞 LSTM 模型提高预测精度^[30]。这些方法虽通过动态建模或阈值优化提升了适应性, 但仍存在不足: 核电厂方法未涉及阈值动态调整^[27], 航天器检测对极端工况的鲁棒性有待验证^[28], 堆外探测器模型复杂度较高^[29], 水泥脱硝算法依赖先验参数设置^[30]。整体而言, 跨领域实践表明通过图模型或注意力机制精准建模系统联动关系、采用在线学习动态阈值策略是构建自适应监测系统的有效模式, 为解决集成电路测试设备稳定性监测的核心矛盾提供了直接技术启示。

针对上述跨领域方法中存在的阈值动态调整缺失、模型复杂度高、依赖先验参数、极端工况鲁棒性不足等共性问题, 本文提出一种基于 GMM 与 KL 散度的动态阈值优化监测方法 GMM-KL。该方法的创新之处在于构建了一个具备内生自适应能力的智能监测闭环, 其核心是设计了一套双重自适应机制: 首先, 通过 GMM 对测试设备多运行工况进行精细化概率建模, 为状态评估确立“动态”可匹配的基准; 更关键的是, 引入基于 KL 散度历史序列的滚动学习策略, 实时更新异常检测阈值, 使其能随设备性能基线的漂移同步演变。该框架本质上致力于解决“静态模型/阈值”与“动态演化过程”之间的失配矛盾, 通过动态基准建模与阈值在线优化的协同作用, 弥补了现有方法在适应性与鲁棒性上的不足。此方法不仅旨在显著提高对 IC 测试设备性能波动与早期故障的检测准确率和鲁棒性, 也为更广泛的工业装备在复杂动态运行环境下的智能健康管理, 提供了一种具备持续学习与适应能力的新范式。

1 GMM-KL 动态预测基本思想

基于 GMM-KL 动态预测集成电路测试设备稳定性的方法采用“离线建模、在线监测”的框架, 主要包括 4 个核心步骤: 1) 在离线建模阶段, 特征工程模块首先对历史测试数据进行清洗、特征选择与归一化处理, 构建高质量输入数据集, 为后续分析奠定数据基础; 2) 工况识别模块利用 GMM 聚类算法对标准化后的数据进行无监督聚类, 划分测试机的典型运行工况, 并通过可视化技术验证聚类合理性; 3) 状态分布建模模块针对每个工况簇, 使用高斯混合模型建立该工况下的健康基准概率密度模型, 然后基于 KL 散度计算所有健康样本与基准模型的偏离程度, 最终通过统计方法确定各工况的动态监测阈

值 (采用 95.45% 经验分位数); 4) 在线监测阶段, 状态监控模块首先建立时间窗口, 对窗口内采集的测试数据进行标准化处理, 并识别其所属工况簇; 接着计算每个数据点与对应健康 GMM 模型之间的 KL 散度值, 并统计该窗口内 KL 散度值超过动态阈值的异常数据数量; 若异常数量持续超过设定阈值, 则判定测试设备进入异常状态并触发报警, 从而实现设备稳定性的动态监测与早期预警。

2 特征工程

测试机的测试数据通常具备数据量庞大、数据维度较高的特性, 同时还存在异常值和缺失值较多等问题。为了提升数据质量, 加快模型训练速度并提高预测的准确性, 引入特征工程模块极为关键。该模块主要涵盖的数据清洗、特征选择和数据归一化处理等步骤。在特征选择阶段, 对测试数据进行分布拟合, 从而降低数据维度, 提高模型训练速度。在数据归一化处理阶段, 采用 Z-Score 标准化方法进行归一化操作, 以消除不同特征之间量纲差异的影响, 进而提高模型预测的准确性。

2.1 数据清洗

数据清洗的关键步骤包括缺失值和异常离群值的处理。对于缺失值, 采用对异常值不敏感的中位数进行填充。针对异常离群值, 在全部特征构成的多维空间上利用局部离群因子算法 (local outlier factor, LOF) 进行检测与剔除。LOF 是一种基于密度的异常检测方法, 适用于识别局部异常点。

2.2 特征选择

IC 测试数据特征维度高, 且不同特征的统计特性与数据质量差异显著。为了提升 GMM 聚类模型的效率与数值稳定性, 并确保后续状态建模的可靠性, 对测试数据进行了分布拟合与分析。在此基础上, 优先选择那些数据质量高、分布集中、且易于用高斯成分进行拟合的特征。这类特征能更有效地被 GMM 模型表征, 从而为构建精准的工况基准模型奠定基础。

分布拟合基于偏度 (度量不对称性)、峰度 (衡量陡峭度)、变异系数 (衡量离散度) 和四分位距 (确定中间分布) 完成。

1) 偏度衡量概率分布的不对称性, 反映数据偏离中心的程度和方向。即:

$$g_1 = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \right)^{3/2}} \quad (1)$$

式中: g_1 是偏度; N 是样本量; x_i 是第 i 个测试数据; $\bar{x}$ 是测试样本均值。

2) 峰度度量分布尾部的厚度和平坦度,反映极端值出现的概率。描述分布是高峰陡峭还是低峰平坦的特征,即:

$$g_2 = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \right)^2} - 3 \quad (2)$$

式中: g_2 是峰度; N 是样本量; x_i 是第 i 个测试数据; $\bar{x}$ 是测试样本均值。

3) 变异系数(coefficient of variation, CV)是相对离散程度的度量,用于比较不同量纲数据集的离散程度,即:

$$CV = \frac{\sigma}{\bar{x}} \times 100\% \quad (3)$$

式中: σ 是标准差; $\bar{x}$ 是测试样本均值。

4) 四分位距(interquartile range, IQR)是描述数据中间 50% 观测值离散程度的鲁棒性指标,不受极端值影响,即:

$$IQR = Q_3 - Q_1 \quad (4)$$

具体来说, IQR 的计算需按照式(5)~(7)依次进行。

(1) 数据按升序排序:

$$x^{(1)} \leq x^{(2)} \leq \dots \leq x^{(N)} \quad (5)$$

(2) 计算第一四分位数 Q_1 :

$$Q_1 = x_{(N/4)} \quad (6)$$

(3) 计算第三四分位数 Q_3 :

$$Q_3 = x_{(3N/4)} \quad (7)$$

基于以上的统计特性,选择常见的 15 种概率分布模型对测试数据特征进行拟合,15 种概率分布模型包括: β 分布、 t 分布、对数正态分布、伽马分布、正态分布、均匀分布、指数分布、威布尔分布、卡方分布、 F 分布、拉普拉斯分布、逻辑斯谛分布、柯西分布、帕累托分布和瑞利分布。通过柯尔莫戈洛夫-斯米尔诺夫检验(Kolmogorov-Smirnov test, KS 检验)来反映数据对每个概率模型的接受程度。KS 检验是一种非参数假设检验方法,用于评估一个样本数据集是否来自特定分布,计算公式如式(8)所示。

$$D_N = \sup_x |F_N(x) - F(x)| \quad (8)$$

式中: D_N 是 KS 检验的统计量; $\sup$ 是上确界; $F_N(x)$ 表示经验分布; $F(x)$ 表示理论分布。

通过 KS 检验比较每个特征的经验分布与多种理论分布,为每个特征选择一个拟合度最高的分布作为其最优分布模型。并且优先筛选出最优分布为形态良好,利于后续 GMM 方法建模的分布的特征,作为最终的训练集,并且所选特征覆盖了所有特征的 95%。

2.3 数据标准化

由于所选特征具有其他量纲,为了统一量纲和 GMM 聚类,提高后续算法的收敛速度和预测精度,对所选取的

特征数据利用 Z-Score 标准化方法进行标准化。

Z-Score 标准化是数据处理的一种常用方法。通过它能够不同量级的数据转化为统一量度的 Z-Score 分值进行比较,计算公式如式(9)所示。

$$x' = \frac{x - \bar{x}}{\sigma} \quad (9)$$

式中: x' 为经过标准化后的分值; $\bar{x}$ 是特征均值; σ 是特征标准差。

经过标准化处理之后,训练集数据中其他测试项之间可以进行聚类,这保证了后续聚类的可行性。

3 工况识别

由于测试机运行工况复杂多变,单一模型难以精准捕获其运行特性。因此,为了提高预测的准确性,需要对测试机不同工况下的运行状态进行有效识别。本章采用 GMM 聚类算法对经标准化处理的测试数据进行工况划分,并通过可视化图形,对聚类的合理性和有效性进行了验证。

GMM 是一种基于概率模型的聚类算法,它假设数据是由多个高斯分布混合而成的。每个高斯分布对应一个聚类簇,数据点以一定的概率属于各个簇。其核心思想是:数据点来自多个高斯分布混合生成,通过期望最大化算法(expectation-maximization algorithm, EM 算法)交替进行 E 步(计算数据点属于每个高斯分布的责任值)和 M 步(用计算出的责任值更新模型参数),直到收敛。最终,每个数据点被分配到概率最大的高斯分布对应的簇,即 GMM 聚类算法可以分为 4 步:1) 指定簇的个数,并随机初始化每个高斯分布的均值向量、协方差矩阵和混合系数(如式(10)~(12)所示);2) E 步:计算每个数据点属于每个高斯分布的后验概率(如式(13)所示);3) M 步:根据 E 步计算的后验概率,重新估计每个高斯分布的参数,使得数据点在该分布下的概率最大化(如式(14)~(16)所示);4) 重复 E 步和 M 步,直到参数收敛(如式(17)~(19)所示)。

1) 初始化参数

高斯权重:

$$\alpha_k^{(0)}, \text{ 满足 } \sum \alpha_k = 1 \quad (10)$$

均值向量:

$$\mu_k^{(0)} \in \mathbb{R}^D \quad (11)$$

协方差矩阵:

$$\Sigma_k^{(0)} \in \mathbb{R}^{D \times D}, \text{ 正定对称矩阵} \quad (12)$$

式中:上标(0)表示该算法从一组初始值开始迭代优化; D 为数据的维度,即每个数据集的特征数量 $\mathbb{R}^{D \times D}$ 表示这是一个 $D \times D$ 的实数矩阵; α_k 为第 k 个高斯分布的权重。

2) E 步: 计算后验概率(责任函数)

对于每个样本 $\mathbf{x}_i$, 计算其属于第 k 个高斯分布的后验概率, 即:

$$\gamma(z_{ik}) = \frac{\alpha_k \cdot \mathcal{N}(\mathbf{x}_i | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \alpha_j \cdot \mathcal{N}(\mathbf{x}_i | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} \quad (13)$$

式中: $\gamma(z_{ik})$ 表示第 i 个样本“属于”第 k 个高斯分布的“责任”, $\alpha_k \cdot \mathcal{N}(\mathbf{x}_i | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$ 表示样本由第 k 个高斯分量生成的联合概率, $\sum_{j=1}^K \alpha_j \cdot \mathcal{N}(\mathbf{x}_i | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)$ 表示样本 $\mathbf{x}_i$ 由所有 K 个高斯分量生成的总概率(全概率公式), 用于归一化。

3) M 步: 更新参数

定义: $N_k = \sum_{i=1}^N \gamma(z_{ik})$ 为第 k 个高斯分布的“有效样本数”。

更新公式如式(14)~(16)所示。

权重更新:

$$\alpha_k^{(t+1)} = \frac{N_k}{N} \quad (14)$$

均值更新:

$$\boldsymbol{\mu}_k^{(t+1)} = \frac{1}{N_k} \sum_{i=1}^N \gamma(z_{ik}) \mathbf{x}_i \quad (15)$$

协方差矩阵更新:

$$\boldsymbol{\Sigma}_k^{(t+1)} = \frac{1}{N_k} \sum_{i=1}^N \gamma(z_{ik}) (\mathbf{x}_i - \boldsymbol{\mu}_k)(\mathbf{x}_i - \boldsymbol{\mu}_k)^T \quad (16)$$

式中: t 表示迭代次数。

4) 迭代与终止:

重复步骤 2) 和 3), 直到满足以下任一情况: (1) 参数变化小于某个阈值; (2) 对数似然变化很小; (3) 达到预设的最大迭代次数。

在迭代过程中可以使用对数似然估计来评估参数的收敛情况, 计算方式如式(17)所示。

$$\log L(\boldsymbol{\theta} | \mathbf{X}) = \sum_{i=1}^N \log \left(\sum_{k=1}^K \alpha_k \cdot \mathcal{N}(\mathbf{x}_i | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right) \quad (17)$$

式中: $\log L(\boldsymbol{\theta} | \mathbf{X})$ 表示在参数 $\boldsymbol{\theta}$ 下, 观测到数据集 $\mathbf{X}$ 的对数似然值, $\boldsymbol{\theta}$ 表示所有参数集合, 即 $\{\alpha_k, \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$, $\mathbf{X}$ 表示观测数据集, 共 N 个样本, $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, 该值会随着迭代次数趋于稳定。

赤池信息准则 (Akaike information criterion, AIC): 用于衡量模型拟合的优劣程度, 计算方式如式(18)所示。

$$AIC = -2 \log L(\boldsymbol{\theta} | \mathbf{X}) + 2m \quad (18)$$

式中: $\log L(\boldsymbol{\theta} | \mathbf{X})$ 为模型的对数似然值; m 为模型的参数数量, 其作用是防止模型出现过拟合情况。

贝叶斯信息准则 (Bayesian information criterion, BIC): 用于衡量模型的拟合效果, 通过加入惩罚项, 避免模型过拟合, 计算方式如式(19)所示。

$$BIC = -2 \log L(\boldsymbol{\theta} | \mathbf{X}) + m \ln(N) \quad (19)$$

式中: $\log L(\boldsymbol{\theta} | \mathbf{X})$ 为模型的对数似然值; m 为模型的参数数量; N 为样本数量。

最终, 依据赤池信息准则 (AIC) 和贝叶斯信息准则 (BIC) 来确定模型的最优聚类数量。表 1 展示了 AIC 和 BIC 与聚类数之间的关系。图 1 展示了聚类数量与对应的 AIC、BIC 分数之间的变化态势。

表 1 聚类数与 AIC 和 BIC 得分

Table 1 Number of clusters and AIC and BIC scores

聚类数	AIC	BIC
1	1 750 879.88	1 751 213.35
2	1 626 411.64	1 627 086.92
3	1 555 514.42	1 556 531.51
4	1 517 846.31	1 519 205.20
5	1 503 714.71	1 505 415.42
6	1 482 092.98	1 484 135.50
7	1 474 740.86	1 477 125.18
8	1 463 935.78	1 466 661.91
9	1 453 413.25	1 456 481.19
10	1 444 732.39	1 448 142.14




图 1 AIC、BIC 分数与聚类数量关系

Fig. 1 Relationship between AIC, BIC scores and number of clusters

可以看出, 当聚类个数处于 1~5 时, 两种准则的分数曲线下降十分迅速 (例如, 当聚类数为 3 时, AIC 值约为 1.56×10^6 , BIC 的值约为 1.56×10^6); 而当聚类个数在 6~10 时, 分数曲线变化渐趋平缓。为了在模型复杂度与表征能力之间达成平衡, 最终选定聚类数 10 作为模型的参数。

为了进一步挖掘测试数据的内在结构特征, 简化数据的理解和分析过程, 引入主成分分析 (principal component analysis, PCA) 算法。该算法可以将数据从高维映射到低维空间中, 通过二维或三维平面直观的展示数据内部的联系, 从而更好呈现出不同工况之间的边界, 其二维视图如图 2 所示, 三维视图如图 3 所示。该结果清晰展示了 GMM 聚类算法的可行性。




图2 测试机数据聚类结果二维可视化

Fig. 2 Two-dimensional visualization of clustering results for test machine data




图3 测试机数据聚类结果三维可视化

Fig. 3 3D visualization of clustering results for test machine data

在聚类完成后,所划分的每个簇就代表测试机实际运行过程中的一种特定的运行状态。

4 状态分布建模

本章通过将 KL 散度加入已经构建好的工况簇中,进行状态分布的建模,从而确定“健康”状态的概率密度模型,并基于该模型确定动态检测的阈值。主要步骤可以分为 3 步:1)为每个工况簇训练高斯混合模型作为健康状态基准;2)计算所有正常样本的 KL 散度;3)基于 KL 散度分布确定动态监测阈值。

4.1 健康基准模型 GMM 模型构建

GMM 的概率密度函数为:

$$q(x) = \sum_{k=1}^K \alpha_k \mathcal{N}(x | \mu_k, \Sigma_k) \quad (20)$$

式中: K 是混合成分的分量; α_k 是第 k 个高斯成分的权

重; $\mathcal{N}(x | \mu_k, \Sigma_k)$ 是多元高斯分布的概率密度函数。

4.2 异常度量指标的选择

在确定了健康状态的基准分布后,选择一个能够灵敏、可靠地度量数据偏离程度的指标至关重要。选择 KL 散度作为该指标,主要考虑了其以下两个关键理论优势,这使其特别适用于工业设备的异常检测。

1) 对非线性退化的高度敏感性

当设备性能发生缓慢、渐进式的非线性退化时,其监测数据在特征空间中的分布会发生微小的漂移或形变。这种变化难以通过固定阈值或简单统计量捕捉。然而,KL 散度能够捕捉到这种分布形态的细微变化。随着退化累积,新数据 x 落在基准 GMM 概率密度较低的区域,导致 $q(x)$ 持续减小,从而使 KL 散度值呈现单调增长趋势。这一特性使得该方法能够实现早期预警,识别传统方法难以发现的缓慢退化过程。

2) 对突发性异常的快速响应机理

对于突发性故障,故障数据点会完全偏离健康数据的分布区域,落入基准 GMM 的极低概率区间。这将导致 $q(x)$ 急剧下降,反映在 KL 散度上则是一个阶跃式的跳变。这种对低概率事件的“放大”效应,确保了该方法对突发故障同样具有快速、准确的检测能力。

因此,鉴于 KL 散度具备捕捉缓慢渐变和瞬时突变的独特能力,最终决定采用 KL 散度作为异常度量的指标。

4.3 KL 散度计算

KL 散度可以量化每个样本与健康状态的偏离程度,在健康模型训练阶段,将正常样本的 KL 散度值存储起来,用于确定健康状态的边界值,即:

$$KL(P \parallel Q) = \int p(x) \log \frac{p(x)}{q(x)} dx \quad (21)$$

式中: P 为真实分布(即待评估的分布); Q 为参考分布(即根据样本数据已构建的模型分布); $p(x)$ 和 $q(x)$ 分别为 P 和 Q 的概率分布。

在在线监测场景中,出于对监测实时性的要求,需要对每一时刻采集的测试样本进行即时评估,然而,原始 KL 散度要求两个输入都为分布,无法直接应用于单点评估。

为了解决该问题,引入关键数学构造:将待评估的样本点视为一个极集中的分布(在数学上可近似为狄拉克 δ 分布),其定义为:1)在 $x = x_i$ 处为“无限大”;2)在 $x \neq x_i$ 处为 0;3)满足归一化条件 $\int_{-\infty}^{\infty} \delta(x - x_i) dx = 1$;4)具有“筛选性质”:对于任意连续函数 $f(x)$,有:

$$\int_{-\infty}^{\infty} \delta(x - x_i) f(x) dx = f(x_i) \quad (22)$$

在实时监测时, P 即为 $\delta(x - x_i)$,于是将其代入 KL 散度公式,并利用其“筛选性质”可得:

$$KL(P \parallel Q) = -\log q(x_i) \quad (23)$$

其中, P 表示将当前待检测的样本点 x_i 看作一个确定的点(在数学上可以建模为一个“狄拉克 δ 分布”,其概率质量完全集中在 x_i 点。 $q(x_i)$ 是健康基准 GMM 模型的概率密度函数在 x_i 点的取值。该值越大表明当前样本与健康状态的偏离程度越高,异常概率越大。

4.4 基于 KL 散度的异常检测动态阈值确定

基于 KL 散度,为每个簇设定健康状态的边界阈值。引入 95.45% 经验分位数 (2σ 准则) 作为动态阈值,即仅有 4.55% 的健康样本在训练数据中的 KL 散度值会超出此阈值。此外,还采用了 99.73% 经验分位数 (3σ 准则) 进行比对,旨在探寻更适用于该批次测试芯片的边界阈值。这种分位数方法不受数据分布具体形态(如正态分布)的约束,因而具备更强的鲁棒性。

具体而言,对于每个工况簇,收集其所有健康训练样本的 KL 散度值,形成从小到大的序列,即:

$$D_{\text{healthy}} = \{d_1, d_2, \dots, d_s\} \quad (24)$$

式中: S 为该簇的样本数。

动态阈值选取该序列的 95.45% 经验分位数,即:

$$\tau = Q_{95.45\%}(D_{\text{healthy}}) \quad (25)$$

式中: $Q_p(\cdot)$ 表示经验分布函数; τ 为用于该簇的动态异常检测阈值。

这意味着:

$$P(D_H \leq \tau) \approx 0.9545 \quad (26)$$

式中: D_H 是基于健康数据得到的 KL 散度随机变量。

通过对比实验,证实采用 95.45% 分位数 (2σ 准则) 作为动态阈值的 GMM-KL 异常检测模型在性能上表现更优。该方法为每个聚类分别构建高斯混合模型,并基于 KL 散度计算各样本的异常分数,最终以 95.45% 分位

数作为动态检测阈值。实验结果表明,该方法的检测效果优于传统的 3σ 方法和马氏距离方法,具体对比结果详见表 2。

表 2 阈值选择模型比对

Table 2 Comparison of threshold selection models

模型	准确率	召回率	F1 分数
2σ	0.997 2	0.979 8	0.989 8
3σ	0.981 3	0.865 7	0.928 0

5 状态监控

5.1 实验环境与数据集

1) 实验环境

实验平台使用 pycharm, 采用 python 3.12.3 编程语言。实验运行环境配置为 AMD Ryzen 7 7435H 中央处理器(CPU), 16 GB 运行内存, Windows 11 操作系统。主要使用的软件库包括 NumPy 库、Pandas 库和 Matplotlib。

2) 数据集

本实验所采用的数据源自实际生产过程中同一批次 IC 的最终测试(final test, FT) 阶段, 其中用于训练健康模型的测试数据共涉及 44 516 个 IC。此外, 实验数据来源于同一批次 IC(型号: ICND2263PN) 的最终测试阶段。该芯片是一款高集成度的电源管理 IC, 其测试数据能够有效反映测试设备在模拟和混合信号测试项上的稳定性。

为清晰说明实验对象的特性, 现将构建健康模型所使用的关键测试参数及其电气含义补充展示在表 3。

表 3 关键测试参数展示

Table 3 Presentation of key test parameters

测试项名称	电气参数类型	单位	在稳定性监测中的意义
SDO_3P3V_L	输出驱动电压(轻载); 测量 3.3 V 输出通道在小负载电流下的输出电压	mA/ μ A	反映电源负载能力与功耗
27K_o5_1	内部偏置/参考电流	mA	反映芯片内部核心电路的基准精度
Vout1, Vout10, Vout12	多路直流电压输出	V	反映电压调整精度与输出稳定性

这些测试项涵盖了静态功耗、直流输出、内部基准源等多个维度, 能够全面地表征测试设备在驱动、测量和供电方面的综合性能。使用这些具有明确物理意义的关键参数进行建模, 确保了所构建的健康基准模型能够有效捕捉测试设备的性能波动。

3) 模型评价指标

为了对 GMM-KL 模型的异常检测能力进行评估, 采用准确度、精确度、召回率、F1 分数($F1\text{-score}$, $F1$) 等公开指标来评估该模型的性能。

5.2 监测方法说明

从同一批次中选取一定数量的 IC 进行测试, 其测试结果作为实验数据。其中测试样本的特征与健康模型特征相同。

由于工厂实际测试数据都有较好的稳定性, 因此, 为了验证方法的有效性, 采用人为注入异常的办法对测试集的数据进行处理。首先, 随机对测试集数据注入 20% 的异常数据, 并进行记录, 随后对测试样本采用前文介绍的标准化方法进行标准化处理, 经标准化处理之后, 该测试集与训练集的特性一致, 可直接应用于监测模型中。

使用训练好的聚类模型对测试集数据所属的工况簇进行预测。对于每个测试数据点,根据其工况簇,加载对应的健康 GMM 模型,计算该数据点的 KL 散度值,比较 KL 散度与该工况簇的动态阈值,如果 KL 散度超过阈值,就将该数据点标记为异常,最终,通过混淆矩阵、精确度、召回率等评价指标对该方法进行性能验证。后续采用同样的测试数据集,对常用的异常监测模型进行了评估,并与 GMM-KL 模型的结果进行了对比。

5.3 对比模型参数说明

1) 3σ 模型

该模型基于正态分布假设,采用正态分布的 $\mu \pm 3\sigma$ 作为异常检测的阈值,其中 μ 和 σ 分别为各特征的均值与标准差。对于多维数据,任一特征值超出对应特征的 3σ 范围即判定为异常样本。

2) 马氏距离模型

该模型基于多元正态分布假设,计算样本点到数据中心点的马氏距离。异常检测的阈值设定为马氏距离分布的均值加 3 倍标准差。

3) LOF 模型

LOF 算法的检测性能对邻域参数的选取较为敏感。为保障模型在不同数据规模下的适应性,本研究运用了基于数据特性的自适应参数优化方法。在确定邻域参数时,全面考量了数据集大小与特征维度所产生的影响。

针对不同规模的数据集,实施了下列分级策略:

(1) 对于小样本数据集 ($n < 100$), 设定邻域数 $k = \max(5, n/10)$, 其中 $[\cdot]$ 表示向下取整运算;

(2) 对于中等规模数据集 ($100 \leq n < 1\,000$), 采用经验值邻域参数 $k = 20$;

(3) 对于大规模数据集 ($n \geq 1\,000$), 设定邻域参数 $k = \min(5, [n/100])$, 其中 $[\cdot]$ 表示向下取整运算。

5.4 异常数据注入机制

为确保异常检测模型评估的全面性和可靠性,本研究设计并实施了两种典型的异常模式,以模拟集成电路测试设备可能出现的真实故障。异常注入比例占测试数据的 20%,其中点异常占 12%,性能退化异常占 8%。具体的异常注入机制如下所述:

1) 点异常:模拟测试机因硬件瞬时故障、外部干扰等因素造成的突发性数据异常。此类异常表现为单个或多个时间点上的数据值明显偏离正常模式。本研究采用基于统计分布的点异常注入方法。具体而言,对于给定的正常数据集,首先计算各特征在训练集(正常数据)中的均值(μ)和标准差(σ)。随后,根据预设的异常点比例,在测试集中随机选择相应数量的时间点作为异常注入位置。对于每个选定的异常点,随机选取其约 70% 的特征

进行篡改。异常值的生成通过以下公式实现:新异常值 $= \mu + \text{direction} \times \text{sigma_multiplier} \times \sigma$, 其中, direction 随机取 +1 或 -1, 表示异常偏离的方向 sigma_multiplier 为一预设的巨大乘数(如 15~30), 以确保注入值在统计意义上极不可能由正常过程产生。此机制能有效模拟特征值突然剧烈波动的故障模式。

2) 性能退化异常:模拟测试机性能的渐进式退化(如设备老化、零部件损耗)。此类异常表现为在一段连续时间内形成的模式或趋势与正常状态存在可区分的差异。本研究设计了性能退化异常注入流程。该机制在时间轴上定义多个连续的、固定长度的“退化段”(如每段 200 个时间点)。在每个退化段内,异常强度并非固定不变,而是随时间推进动态增强。例如,异常值的 σ 乘数可从段起始处的 12σ 线性增加至段结束处的 25σ 。这种动态增强模拟了性能随时间的推移而加速恶化的过程。退化段的总长度占数据集的比例由参数控制。注入完成后,退化段内的所有数据点均被标记为异常,以表征持续性的性能劣化。

为确保实验的可复现性与结论的可信度,异常注入过程被设计为完全由参数控制,并通过设置随机数种子确保每次运行生成的异常模式一致。

5.5 监测能力验证

为了对 GMM-KL 的监测能力进行验证,按照 5.2 节所述的监测流程,对包含 20% 注入异常的测试集进行了实验评估。选择常用的 3σ 模型,马氏距离模型,LOF 模型作为对比模型。

1) 模型性能比对

各对比模型的性能指标展示如图 4 所示。实验结果表明,GMM-KL 模型在异常监测方面的性能明显优于传统的检测方法。




图4 不同异常监测模型性能比较

Fig. 4 Histogram comparing the performance of different anomaly detection models

2) 时间序列验证

为了验证 GMM-KL 模型在监测测试机时间序列依赖性及设备渐进老化过程中的能力,选取了同一批次的另一组独立数据集(包含 13 221 颗 IC 测试芯片)进

行测试。在该数据集中,根据测试时间的先后顺序注入点异常和性能退化异常,以客观评估模型的泛化性能。首先,筛选出与 GMM-KL 建模阶段完全相同的 20 项关键测试参数作为监测指标,确保特征空间的一致性。随后,为了捕捉设备状态随时间推移的潜在变化趋势,按测试时间顺序将数据分组,以每 200 颗 IC 为一个时间窗口(共 66 组),依次输入训练好的 GMM-KL 模型进行在线监测。

实验结果显示,在前 40 个时间窗口内,KL 散度的波动处于正常范围内,表明测试设备运行稳定。然而当监测至第 41 组(即第 8 001~8 200 颗 IC)时,KL 散度异常得分出现显著升高的集群现象,表现为连续多个样本点的 KL 值持续超越基于历史健康数据设定的动态阈值(95.45%分位数)。这一现象表明,测试设备可能开始出现系统性性能偏移或早期退化迹象。基于此,根据异常监测模型,依据 KL 散度的 2σ 法则设置了预警机制,当连续多个样本触发异常阈值时(以 3 组内的平均异常数量为例,即 3 组内平均异常数量超出某个预设值时,就说明该设备出现了异常),系统自动提示技术人员对测试机进行性能检查与维护。实验结果可视化如图 5 所示,该图清晰展示了 KL 分数随时间窗口的变化趋势及异常集群的爆发点。综上所述,本实验通过时间窗口划分与动态阈值监测,有效验证了 GMM-KL 模型对设备性能缓慢退化的敏感性,为实时预警提供了可靠依据。




图5 异常数量随时间变化趋势

Fig.5 Trend chart of abnormal quantity changes over time

6 结 论

针对集成电路测试设备在动态运行环境下的稳定性监测难题,提出了一种基于高斯混合模型与 KL 散度(GMM-KL)的动态阈值优化方法。该方法的核心在于构建了一个“离线建模、在线监测”的智能监测框架。离线阶段,通过系统的特征工程筛选出数据质量高、分布集中的关键参数,并利用 GMM 对测试设备的复杂运行工况进行无监督识别与精细化建模,为每种健康工况建立独立的概率基准。在此基础上,创新性地引入 KL 散度量化数据与基准模型的偏离程度,并据此为各工况设定自

适应的动态监测阈值。在线监测阶段,则通过实时计算 KL 散度并与对应阈值比对,实现异常状态的灵敏感知与早期预警。实验结果表明,相较于传统的静态阈值模型(如 3σ 、马氏距离)及经典异常检测算法(如 LOF),GMM-KL 方法在准确率、召回率与 F1 分数上均展现出显著优势,能够更有效地识别测试设备的性能波动与潜在故障。更为重要的是,所提出的 GMM-KL 方法具备良好的普适性。其技术框架并不依赖于集成电路测试数据的特定属性,其核心机理——即通过 GMM 刻画复杂多模态数据,并利用 KL 散度感知分布变化——对于解决其他工业设备在动态、多工况运行环境下的稳定性监测问题同样具有适用性。该方法为应对数据分布动态漂移的共性挑战提供了一种通用的技术思路与可复现的解决方案,具备推广到更广泛 PHM 场景的潜力。

参考文献

- [1] BUSHNELL M L, AGRAWAL V D. Essentials of electronic testing for digital, memory and mixed-signal VLSI circuits[M]. Boston, MA: Springer US, 2002.
- [2] YU K, QI J H. Evaluation and analysis of domestic ATE based on IC testing application[C]. 2022 IEEE 16th International Conference on Solid-State & Integrated Circuit Technology, 2022: 1-3.
- [3] International Roadmap for Devices and Systems (IRDS). Test technology report[R]. IEEE, 2023.
- [4] MOORE G E. Cramming more components onto integrated circuits[J]. Proceedings of the IEEE, 1998, 86(1): 82-85.
- [5] 王逸飞. 基于 FPGA 的 SoC 全自动化测试平台的设计与实现[D]. 南京: 东南大学, 2021.
WANG Y F. Design and implementation of FPGA-based SoC full-test platform[D]. Nanjing: Southeast University, 2021.
- [6] POEHL F, DEMMERLE F, ALT J, et al. Production test challenges for highly integrated mobile phone SOC—a case study[C]. 2010 15th IEEE European Test Symposium, 2010: 17-22.
- [7] PIMBLEY J M, MCDEVITT-PIMBLEY D A. Optimal testing in semiconductor manufacturing[J]. IEEE Engineering Management Review, 2020, 48(4): 174-180.
- [8] 贾镜材, 钟业奎, 张泽展, 等. 集成电路制造过程中的晶圆温度监测技术[J]. 仪器仪表学报, 2021, 42(1): 15-29.
JIA J C, ZHONG Y K, ZHANG Z ZH, et al. Wafer temperature monitoring technology in integrated circuit manufacturing process[J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 15-29.

- [9] 詹文法, 胡心怡, 郑江云, 等. 基于正态分布上侧边界值的集成电路测试设备稳定性预测[J]. 中国邮电高校学报(英文版), 2024, 31(2): 85-93.
ZHAN W F, HU X Y, ZHENG J Y, et al. Predicting stability of integrated circuit test equipment using upper side boundary values of normal distribution[J]. The Journal of China Universities of Posts and Telecommunications, 2024, 31(2): 85-93.
- [10] QUEIROZ L P, RODRIGUES F C M, GOMES J P P, et al. A fault detection method for hard disk drives based on mixture of Gaussians and nonparametric statistics[J]. IEEE Transactions on Industrial Informatics, 2017, 13(2): 542-550.
- [11] 王庆锋, 卫炳坤, 刘家赫, 等. 一种数据驱动的旋转机械早期故障检测模型构建和应用研究[J]. 机械工程学报, 2020, 56(16): 22-32.
WANG Q F, WEI B K, LIU J H, et al. Research on the construction and application of a data driven early fault detection model for rotating machinery[J]. Journal of Mechanical Engineering, 2020, 56(16): 22-32.
- [12] HE M, GUO W. An integrated approach for bearing health indicator and stage division using improved Gaussian mixture model and confidence value[J]. IEEE Transactions on Industrial Informatics, 2022, 18(8): 5219-5230.
- [13] CHOWDHURY S D, SENROY N, DE S. Data-driven event assessment in power systems using Gaussian mixture models[C]. 2019 IEEE Milan PowerTech, 2019: 1-6.
- [14] 邱雷, 房芳, 袁慎芳, 等. 导波强化裂变聚合概率模型损伤监测方法[J]. 振动、测试与诊断, 2018, 38(3): 438-445.
QIU L, FANG F, YUAN SH F, et al. Damage monitoring method for guided wave enhanced fission aggregation probability model[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(3): 438-445.
- [15] 王刚, 肖黎, 屈文忠. Lamb 波高斯混合模型螺栓松动损伤检测[J]. 机械科学与技术, 2020, 39(4): 493-500.
WANG G, XIAO L, QU W ZH. Lamb wave Gaussian mixture model for bolt loosening damage detection[J]. Mechanical Science and Technology for Aerospace Engineering, 2020, 39(4): 493-500.
- [16] 王丹, 张凤南, 马岩尉, 等. 基于 AE 并融合 GMM 与 K-means 的无监督颤振监测研究[J]. 工具技术, 2025, 59(2): 139-145.
WANG D, ZHANG F N, MA Y W, et al. Research on unsupervised flutter monitoring based on AE and fusion of GMM and K-means[J]. Tool Engineering, 2025, 59(2): 139-145.
- [17] 骆学理, 金艺, 张易, 等. 基于 ISVD-GMM 的绞车故障预警方法探索[J]. 中国设备工程, 2024(6): 19-23.
- [18] 金怀平, 黄成, 董守龙, 等. 基于多相似度局部状态辨识的集成学习自适应软测量方法[J]. 计算机集成制造系统, 2023, 29(2): 460-473.
JIN H P, HUANG CH, DONG SH L, et al. Integrated learning adaptive soft sensing method based on multi similarity local state identification[J]. Computer Integrated Manufacturing Systems, 2023, 29(2): 460-473.
- [19] 覃力, 唐卫清, 陶清华, 等. 基于高斯混合模型的流程工厂设备集相似度计算[J]. 计算机集成制造系统, 2020, 26(3): 732-746.
QIN L, TANG W Q, TAO Q H, et al. Similarity calculation of process factory equipment set based on Gaussian mixture model[J]. Computer Integrated Manufacturing Systems, 2020, 26(3): 732-746.
- [20] CAO Y, JAN N M, HUANG B, et al. No-delay multimodal process monitoring using Kullback-Leibler divergence-based statistics in probabilistic mixture models[J]. IEEE Transactions on Automation Science and Engineering, 2023, 20(1): 167-178.
- [21] MEZNI Z, DELPHA C, DIALLO D, et al. Bearings ball fault detection using Kullback Leibler divergence in the EMD framework[C]. 2018 Prognostics and System Health Management Conference, 2018: 729-734.
- [22] 李博, 刘树彩, 王鹏琪. 基于 IE-GMM 的带式输送机大块煤检测方法[J]. 仪表技术与传感器, 2024(12): 107-111, 119.
LI B, LIU SH C, WANG P Q. A method for detecting large coal blocks in belt conveyors based on IE-GMM[J]. Instrument Technique and Sensor, 2024(12): 107-111, 119.
- [23] 王庆锋, 卫炳坤, 刘家赫, 等. 一种数据驱动的旋转机械早期故障检测模型构建和应用研究[J]. 机械工程学报, 2020, 56(16): 22-32.
WANG Q F, WEI B K, LIU J H, et al. Research on the construction and application of a data driven early fault detection model for rotating machinery[J]. Journal of Mechanical Engineering, 2020, 56(16): 22-32.
- [24] 严如强, 朱启翔, 李亚松, 等. 深度对比一类分类在轴承异常检测中的应用[J]. 振动、测试与诊断,

2025, 45(1): 1-9, 196.

YAN R Q, ZHU Q X, LI Y S, et al. Application of deep comparison classification in bearing anomaly detection[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(1): 1-9, 196.

- [25] 孔华永, 高静, 柳跃, 等. 基于 St-DPMM 的带式输送机托辊轴承声信号故障预警方法[J]. 轴承, 2025(2): 102-110.

KONG H Y, GAO J, LIU Y, et al. A fault warning method for belt conveyor roller bearing sound signal based on St-DPMM[J]. Bearing, 2025(2): 102-110.

- [26] 翟立伟, 王东辉. 基于音频处理技术的轴承劣化预警方法研究[J]. 仪表技术, 2022(3): 42-44, 54.

ZHAI L W, WANG D H. Research on bearing degradation warning method based on audio processing technology[J]. Instrumentation Technology, 2022(3): 42-44, 54.

- [27] 林蔚青, 缪希仁, 江灏, 等. 多线圈联合学习的核电厂控制棒驱动机构动作状态异常检测方法[J]. 仪器仪表学报, 2025, 46(6): 290-303.

LIN W Q, MIAO X R, JIANG H, et al. Anomaly detection method for motion status of control rod drive mechanism in nuclear power plants by multi-coil joint learning[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 290-303.

- [28] 张金奎, 庞景月, 卢晓伟, 等. Feen-LSTM:一种优化的多遥测参数在线无监督异常检测方法[J]. 仪器仪表学报, 2025, 46(1): 247-257.

ZHANG J L, PANG J Y, LU X W, et al. Feen-LSTM: An optimized online unsupervised anomaly detection method for multi-telemetry parameters[J]. Chinese Journal of Scientific Instrument, 2025, 46(1): 247-257.

- [29] 江灏, 叶铭新, 林蔚青, 等. 基于时空动态检测的核电厂堆外中子探测器故障检测方法[J]. 仪器仪表学报, 2024, 45(9): 131-144.

JIANG H, YE M X, LIN W Q, et al. Fault detection for ex-core neutron detectors in nuclear power plants using the spatial-temporal dynamic detection model[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 131-144.

- [30] 陈薇, 何浩然, 李鑫, 等. 融合 SSAD-Z-score 异常检测的 LFLSTM 水泥脱硝系统 NO_x 预测模型[J/OL]. 电子测量与仪器学报, 1-17[2025-12-25].

CHEN W, HE H R, LI X, et al. LFLSTM NO_x

prediction model for cement denitration system incorporating SSAD-Z-score anomaly detection[J/OL]. Journal of Electronic Measurement and Instrumentation, 1-17[2025-12-25].

作者简介



詹文法(通信作者),2000 年于安庆师范学院获得学士学位,2004 年于合肥工业大学获得硕士学位,2009 年于合肥工业大学获得博士学位现为安庆师范大学教授,主要研究方向为集成电路测试。

E-mail:zhanwf@aqnu.edu.cn

Zhan Wenfa (Corresponding author) received his B.Sc. degree from Anqing Normal University in 2000, his M.Sc. degree from Hefei University of Technology in 2004, and his Ph.D. degree from Hefei University of Technology in 2009. He is currently a professor at Anqing Normal University. His main research interest is integrated circuit testing.



弥晨,2024 年于山东交通学院获得学士学位,现为安庆师范大学硕士研究生,主要研究方向为集成电路测试。

E-mail:18791051329@163.com

Mi Chen received his B.Sc. degree from Shandong Jiaotong University in 2024. He is currently a master's student at Anqing Normal University. His main research interest is integrated circuit testing.



胡心怡,2020 年于东南大学成贤学院获得学士学位,2025 年于安庆师范大学大学获得硕士学位,2025 年至今于湖南大学攻读博士学位,主要研究方向为芯片硬件安全与侧信道攻击。

E-mail:734389103@qq.com

Hu Xinyi received her B.Sc. degree from Southeast University Chengxian College in 2020, and her M.Sc. degree from Anqing Normal University in 2025. She has been a Ph.D. candidate at Hunan University since 2025. Her main research interests include chip hardware security and side-channel attacks.



邱野,2018 年于郑州大学获得学士学位。2025 年于中国科学院沈阳自动化研究所获得博士学位。现为安庆师范大学助教,主要研究方向为微纳制造。

E-mail:qiuye@aqnu.edu.cn

Qiu Ye received her B.Sc. degree from Zhengzhou University in 2018, and her Ph.D. from the Shenyang Institute of Automation, Chinese Academy of Sciences in 2025. She is currently a teaching assistant at Anqing Normal University. Her main research interest is micro-and nanofabrication.