# 基于AI技术的PCB层间涨缩异常检测与根因分析研究

曾 玲,李子龙,明红星,罗 猛,李智鹏

(广东喜珍电路科技有限公司,广东 肇庆 526000)

**摘 要:** 针对高密度印制电路板(PCB)在多层压合和高精度制造过程中易出现的层间涨缩异常问题,传统检测方法依赖人工抽检与事后分析,存在滞后性强、定位困难及一致性差等不足。文章提出一种基于AI技术的PCB层间涨缩异常检测和根因分析方法,其通过构建多源检测数据融合模型,引入卷积神经网络(CNN)与机器学习分类模型,实现对层间涨缩偏差的自动识别和分类,并结合特征重要性分析与聚类方法实现异常根因定位。实验结果表明,该方法可有效提升检测准确率和分析效率,为PCB智能制造提供技术支撑。

**关键词:** PCB制造;层间涨缩;异常检测;机器学习;根因分析;智能制造

**中图分类号:** TP399 **文献标识码:** A

# Research on PCB interlayer expansion and shrinkage anomaly detection and root cause analysis based on AI technology

ZENG Ling, LI Zilong, MING Hongxing, LUO Meng, LI Zhipeng

(Guangdong SEEGEM Circuit Technology Co., Ltd., Zhaoqing, Guangdong 526000, China)

**Abstract:** For the layer expansion and contraction abnormalities that are prone to occur during the multi-layer lamination and high-precision manufacturing process of high-density Printed Circuit Board (PCB), traditional detection methods rely on manual sampling and post-analysis, which have the shortcomings of strong lag, difficult positioning, and poor consistency. This article proposes a PCB layer expansion and contraction anomaly detection and root cause analysis method based on AI technology. By constructing a multi-source detection data fusion model and introducing Convolutional Neural Network (CNN) and machine learning classification models, the automatic identification and classification of layer expansion and contraction deviations are achieved, and the root cause of the anomalies is located by combining feature importance analysis and clustering methods. Experimental results show that this method can effectively improve the detection accuracy and analysis efficiency, providing technical support for PCB intelligent manufacturing.

**Key words:** PCB manufacturing, interlayer expansion and shrinkage, anomaly detection, machine learning, root cause analysis, intelligent manufacturing

## 1 引言

随着电子产品向高密度、高精度及多层化方向发展,PCB制造工艺复杂度显著提升。其中,多层压合过程中的层间涨缩(Layer Expansion/Contraction)问题已成为影响良率的关键因素之一。层间涨缩异常不仅会导致对位偏差、线路短路或开路,还会在后续蚀刻与钻孔工序中放大误差。传统检测方法主要依赖人工测量和经验判断,存在许多问题,如检测效率低,无法满足批量生产需求;依赖人工经验,主观性强;难以实现异常根因追溯;数据利用率低,无法形成闭环优化[1]。因此,引入AI智能技术实现PCB层间涨缩的自动检测与根因分析,具有重要的工程价值。

## 2 总体方案

本文构建的智能检测和分析方法主要由数据采集层、数据处理层及AI分析层三部分组成。

数据采集层负责多源异构信息的融合感知,采集对象包括AOI自动光学检测图像数据、压合机工艺参数(如温度、压力与时间曲线)、钻孔和层间对位偏差测量数据及材料批次信息(如PP片与铜箔的热膨胀系数等),以实现对PCB制造全过程的全面感知[2]。

数据处理层负责对采集数据进行统一清洗和标准化处理，具体包括异常值剔除、缺失数据补全及基于Z-score的归一化；通过时间戳与生产批次映射实现多源数据的时序对齐，从而保证不同类型数据在分析过程中的一致性和可比性。

AI分析层负责构建“图像+结构化数据”融合分析方法，其分析流程分为两个阶段：(1)在融合分析阶段，采用CNN模型对AOI图像进行层间错位特征提取，实现对涨缩异常的视觉识别，同时引入XGBoost分类模型对工艺参数进行非线性建模，以提升异常类型判别能力；(2)在结果后处理阶段，利用K-means聚类方法对异常样本进行自动分组，实现潜在根因的结构化归类，并结合SHAP特征解释方法量化各工艺参数对异常结果的贡献度。上述步骤共同构成从“检测—分类—聚类—解释”的全流程智能分析闭环，为PCB层间涨缩异常的精准定位与工艺优化提供数据支撑。

## 3　层间涨缩异常检测方法

### 3.1　基于CNN的图像检测模型

在PCB层间涨缩检测任务中，本文采用CNN对AOI对位图像进行特征学习，以实现对微小层间偏移的自动识别。首先，将PCB对位标记图像输入模型，通过多层卷积操作提取边缘、角点及纹理等局部空间特征，使网络能够捕捉层间细微形变信息；其次，通过池化层对特征图进行降维处理，在降低计算复杂度的同时增强模型的平移不变性；最终，经全连接层映射得到层间涨缩等级分类结果，包括正常(Normal)、轻微涨缩(Mild)、中度涨缩(Moderate)和严重涨缩(Severe)4类[3]。

在训练过程中，模型以交叉熵损失函数为优化目标：

$$L=-\sum_{i=1}^{N} y_i \log(\hat{y}_i) \tag{1}$$

其中，$y_i$为真实标签；$\hat{y}_i$为模型预测概率。

### 3.2　机器学习异常分类

在结构化工艺数据分析中，本文引入XGBoost模型对PCB层间涨缩异常进行分类建模。模型输入包括压合温度、压力曲线特征、材料热膨胀系数、铜厚度及层压时间等关键工艺参数，通过对多维特征的非线性组合学习，实现对异常类型的概率输出预测[4]。相较于传统统计方法，XGBoost模型通过梯度提升树结构逐步优化目标函数，能够有效捕捉工艺参数之间的复杂耦合关系。其目标优化函数可表示为：

$$\mathcal{L}=\sum_{i=1}^{n} l(y_i,\hat{y}_i)+\sum_k \Omega(f_k) \tag{2}$$

## 4　根因分析方法

### 4.1　特征重要性分析

在PCB层间涨缩异常分析中，为实现对关键影响因素的精准识别，本文采用SHAP(Shapley Additive Explanations)方法对XGBoost模型输出进行解释分析。该方法基于博弈论思想，将每个工艺参数视为“贡献者”，通过计算其在不同特征组合中的边际贡献，量化其对最终预测结果的影响程度，从而实现模型由“黑箱”向“白箱”的转化。通过对压合温度、压力分布、材料批次及铜厚度等变量进行SHAP值计算，可得到各特征对涨缩异常的贡献排序[5]。

典型分析结果表明，压合温度波动是影响层间涨缩的最主要因素，其次为PP材料批次差异，而压力均匀性则对局部变形具有显著影响。特征贡献度可表示为：

$$\phi_i=\sum_{S\subseteq N\setminus i}\frac{|S|!(|N|-|S|-1)!}{|N|!}\left[f(S\cup i)-f(S)\right] \tag{3}$$

其中，$\phi_i$表示第$i$个特征的SHAP贡献值；$f(S)$为特征子集$S$对应的模型输出。

### 4.2　聚类根因分组

在完成特征重要性分析后，为进一步实现PCB层间涨缩异常的结构化归因，本文采用K-means聚类算法对异常样本进行分组分析。通过对模型输出特征空间进行划分，使相似工艺模式下的异常样本聚集于同一类别，从而实现潜在根因的自动归类。聚类过程中，以欧氏距离作为样本相似度度量标准，通过不断迭代更新聚类中心，直至目标函数收敛。

最终将异常样本划分为3类典型模式：C1为温度异常型，主要表现为压合温度波动较大；C2为材料批次型，主要由PP材料热膨胀系数差异引起；C3为机械压力不均型，通常与压合设备受力分布不均相关。K-means优化目标函数可表示为：

$$J=\sum_{i=1}^{k}\sum_{x\in C_i}|x-\mu_i|^2 \tag{4}$$

其中，$C_i$表示第$i$个簇；$\mu_i$为簇中心。

## 5　实验与结果分析

### 5.1　实验环境

为验证本文方法的有效性，构建完整的实验平台和数据处理环境。硬件方面，采用工业级计算平台，配置Intel i7处理器、32 GB运行内存以及RTX 4060 GPU，以满足深度学习模型在图像特征提取与大规模数据训练中的计算需求，保证模型训练和推理的稳定性与实时性。软件环境方面，实验平台基于Python语言构建，结合OpenCV完成图像预处理和特征增强，使用Scikit-learn进行传统机器学习建模，并引入XGBoost实现高效梯度提升分类，同时利用相关数据分析工具完成特征处理与可视化分析。实验数据来源于实际PCB压合生产线，共采集3 200组有效样本数据，涵盖不同工艺参数组合及多种涨缩异常情况。该数据集具有较强的工业代表性，能够真实反映生产过程中的复杂变化，为模型训练和性

能评估提供可靠基础。

### 5.2 实验结果

在PCB层间涨缩异常检测任务中，对比分析了人工检测、传统统计方法与本文方法的性能表现。由实验结果知，人工检测方法依赖操作人员经验，整体准确率为82.3%，误报率达11.5%，存在明显的不稳定性和主观性。传统统计方法通过固定阈值与简单规则进行判断，准确率提升至86.7%，误报率降至9.2%，但仍难以处理复杂工艺条件下的非线性关系。相比之下，本文方法在整体性能上表现最优，检测准确率达95.8%，误报率降至3.6%。上述结果表明，引入CNN图像特征提取和XGBoost结构化数据建模的融合方法，能够有效提升模型对复杂异常模式的识别能力。同时，多源数据联合建模显著增强了系统的鲁棒性与泛化能力，使其在不同工艺波动条件下仍能保持较高稳定性，验证了本文方法的有效性和工程应用价值。

### 5.3 根因分析效果

在根因分析阶段，本文方法不仅实现了异常检测的高精度识别，还进一步提升了异常定位与追溯能力。实验结果显示，基于SHAP特征解释和聚类分析的联合方法，使根因定位准确率达92.4%，能够较为准确地识别导致层间涨缩异常的关键工艺因素。同时，在实际应用中，平均根因定位时间由传统人工分析的2~3 h缩短至约5 min，显著提升了分析效率。

在闭环优化效果方面，将分析结果反馈至生产工艺调整流程后，异常修复效率整体提升约60%，有效降低了因定位延迟导致的批量不良风险。此外，该方法能够实现从“异常发现”到“原因识别”再到“工艺优化建议”的完整链路，为PCB制造过程提供更加智能化和系统化的质量管理手段，具有较强的工程推广价值与实际应用意义。

## 6 结束语

本文提出了一种基于AI技术的PCB层间涨缩异常检测和根因分析方法，实现了从图像识别到工艺参数分析的全流程智能化检测。实验结果表明，该方法能够有效提高检测精度并显著提升根因定位效率，具有较高的工程应用价值。未来将进一步结合工业大模型与在线学习机制，实现PCB制造过程的实时自适应优化。

### 参考文献：

[1] 袁圣珠，朱武，王光东.融合双层路由注意力机制的PCB缺陷检测算法[J].电子设计工程，2025，33(16)：36-41.

[2] 冯彤英，张俊一，袁煜鑫，等.热处理法改善PCB内铜镀层间裂纹缺陷问题[J].电镀与涂饰，2024，43(9)：51-59.

[3] 邵校.基于光学相干层析成像的PCB三防漆的无损检测[D].苏州：苏州大学，2019.

[4] 赵振朋.PCB层设备压盘平行度检测技术的研究与应用[J].科技与企业，2016(4)：210-210.

[5] 魏文泉，莫宏伟.基于改进YOLOv5s的PCB缺陷检测算法[J].计算机工程，2026，52(5)：226-238.

### 作者简介：

曾玲(1990—)，本科，工程师，研究方向：人工智能应用。