

基于无监督学习的电路板安装缺陷检测

卞钟晗, 张恒, 陆小锋, 刘学锋, 陆风行

(上海大学 通信与信息工程学院, 上海 200444)

摘要: 表面贴装技术是制造电子设备最常见的工业方法, 它将电子元件直接安装在印刷电路板的表面; 这些设备在制造过程中出现的安装缺陷会严重影响设备的性能; 因此, 生产的电子设备在投入使用前需要完成印刷电路板组装质量测试; 文章提出了一种基于无监督学习的自动化电路板安装缺陷检测方法; 该方法一方面具有学习能力, 另一方面又不依赖于大型数据集, 适用于检测印刷电路板中的电子元件安装缺陷; 与其他检测方法相比, 文章所提方法的执行速度也有所提高, 满足工业实际应用需求, 具有实际应用价值。

关键词: 印刷电路板装配; 主成分分析; 无监督学习; 变化检测; 缺陷检测

PCBA Defect Detection Based on Unsupervised Learning

BIAN Zhonghan, ZHANG Heng, LU Xiaofeng, LIU Xuefeng, LU Fengxing

(School of Communication and Information Engineering, Shanghai University, Shanghai 200444, China)

Abstract: A surface mount technology (SMT) is the most common industrial method for manufacturing electronic devices, which directly mounts electronic components onto the surface of a printed circuit board (PCB). During the manufacturing process of these devices installation defects or faults can potentially affect their performance. Therefore, the quality of PCB assembly (PCBA) must be tested before being put into use. This paper proposes an automatic PCBA defect detection method based on unsupervised learning. This method not only has the capability to learn but also does not rely on large datasets, making it suitable for detecting installation defects of electronic components on PCBs. Compared with other detection methods, this method improves execution speed, meeting practical industrial applications, with a real application value.

Keywords: PCBA; principal component analysis; unsupervised learning; change detection; defect detection

0 引言

电子信息产业具有高技术含量、高附加值和低污染的特点。除了传统的数码相机、手机、电脑等 3C (计算机、通信和消费电子) 产品外, 近年来还涌现出了一批新兴的 3C 产品: 智能可穿戴设备、无人机、扫地机器人、娱乐机器人等。传统的 3C 产业是劳动密集型产业, 劳动力是 3C 制造企业的一大成本。同时, 新一代劳动力不愿从事重复、枯燥且附加值低的工作, 导致 3C 制造业面临严重的劳动力短缺问题。基于上述情况, 3C 终端制造商必须通过提高生产自动化水平来减少劳动力短缺、提高生产效率、增强竞争优势, 并完成产业转型升级。

随着工业 4.0 时代的到来, 机器视觉在 3C 制造领

域的作用变得越来越重要。根据应用功能, 主要体现在 4 个方面: 测量、检测、识别和定位, 尤其是基于智能视觉技术的印刷电路板 (PCB, printed circuit board) 电子元件检测。电子元件检测是 PCB 自动化生产监控和硬件逆向工程中的重要步骤。

将电子元件安装在 PCB 的表面包括两种方法: 通孔技术 (THT, through-hole technology) 和表面贴装技术 (SMT, surface mount technology)。早期的 THT 是将元件的引脚穿过电路板, 然后进行焊接。由于所有元器件都需要设计有焊针才能穿过电路板, 因此元器件不能设计得太小, 电路板的尺寸也不能太小。而 SMT 是一种将电气元件安装在印刷电路板表面的技术; SMT 是通过在零件的焊脚上涂上焊膏制成的。该技术可以缩短零件的焊脚, 使零件做得越来越小, 从而减小

收稿日期: 2024-09-13; 修回日期: 2024-12-31。

作者简介: 卞钟晗 (1999-), 女, 硕士研究生。

刘学锋 (1971-), 男, 博士, 教授。

引用格式: 卞钟晗, 张恒, 陆小锋, 等. 基于无监督学习的电路板安装缺陷检测[J]. 计算机测量与控制, 2025, 33(12): 28-33, 41.

电子零件的体积。目前, 由于 SMT 可以提高电子制造的自动化程度, 降低成本、提高质量, SMT 已经广泛取代了 THT 电子零件组装方法。

随着 SMT 的发展, 大多数零件都是自动定位和焊接的。这个过程需要高精度的设备和严格的质量控制, 以确保生产出的电路板具有高可靠性和高性能。然而, 由于电子元器件种类繁多, 质量检测一直以来都是行业难题。而随着自动化系统的发展, 基于视觉的 PCB 电子元件检测可以解决 3C 制造中的缺陷检测问题。印刷电路板组装 (PCBA, printed circuit board assembly) 即是将电子元件安装在印刷电路板上的过程, 包括丝印、贴装、回流焊接和检测。对于批量生产的 PCBA, 其可能出现的安装缺陷非常常见, 这些缺陷可能是由多种因素造成的, 例如原材料和二次生产材料、机械使用不当等^[1]。电路板上的任何元件安装错误, 如元件漏放、元件型号错误、元件歪斜、元件翻转等, 都会导致电路运行失败, 使电子产品出现严重缺陷, 从而导致巨大的损失。为了避免这种情况, 所有电子产品从组件到成品都需要经过严格的测试程序。

据估计, 采用 SMT 方法安装的产品不合格率约为 5%, 其中焊点和错误贴装的问题占据大部分。如今, 根据 PCBA 缺陷的类型, 已经研究开发出了一些符合工业生产要求的检测方法^[2]。最初, PCBA 中的缺陷是靠手动检测的, 通过人工检测员发现异常情况以评估产品质量^[3]。该方法的成功率为 60%~70%, 虽具有即时解决问题的优点, 但由于人工易受疲劳、注意力不集中、经验等因素影响, 其效果存在较大波动, 且随着印刷电路板变得越来越复杂、多层, 人工目视检测变得愈加困难。随后, 自动光学检测 (AOI, automatic optical inspection) 技术^[4]、针对 PCBA 的相关图像处理技术^[5-6]应运而生, 二者的问题均在于处理时间过长。AOI 检测方式是通过光学设备获取图像来检查 PCB 上器件的安装缺陷。大多数 AOI 检测机使用非学习算法, 如图像比较法或规则检查法来检测缺陷, 然而对于不同的检测设备, 会存在图像分辨率和色阶差异的问题。这就会增加检测算法设计的难度^[7-9]。相比于人工目视检测, 自动光学检测和图像处理技术的成功率有了一些提升, 但由于检测速度慢且光学仪器价格昂贵, 其在实际应用中的应用范围一直停滞不前。

为了提高检测速度, 基于人工智能的缺陷检测技术逐渐发展, 人们提出了基于机器学习算法的技术: 有监督学习 (如深度学习), 该技术以降低算法复杂度来减少处理时间, 并提高缺陷检测的可靠性^[10-13]。但由于 PCBA 元件架构变化非常迅速, 大部分情况下很难为其找到足够合适且通用的数据集。

综上, 针对 PCB 板电子元件的安装缺陷检测目前

还存在检测速度慢、精确度不高、通用性不强的问题。针对这些问题, 本文研究基于图像处理和无监督学习的轻量级缺陷检测方法, 用于提取印刷电路板元件安装过程中出现的缺陷区域, 并完成缺陷的分类, 包括装配类别缺陷 (漏件、错件) 和装配位姿缺陷 (歪斜、极性反向)。该方法的优势在于: 一方面不需要一直更新标注数据集, 另一方面又可以执行学习程序, 从数据中提取主要特征, 是一种相对更快、更精确的通用型 PCBA 缺陷检测方法。实验表明, 该方法能较快速、准确地识别出 PCBA 上的安装缺陷, 并且准确度与实时性均能满足实际需求。

1 总体方案

一般来说, 图像变化检测技术可以分为两大类: 监督式和无监督式。监督变化检测方法, 需要先验信息; 而无监督变化检测方法不依赖预先标记的数据进行训练, 符合实际应用中先验变化信息缺失的现实情况, 用于发现图像或数据集中的异常或变化, 因此得到了广泛地研究^[14]。无监督变化检测一般包括以下步骤: 1) 图像预处理; 2) 特征提取; 3) 差异图生成; 4) 变化检测; 5) 变化后处理; 6) 变化分析与验证。

本文所提出的针对 PCBA 图像的变化检测方法可以在不确定印刷电路板设计版图和元件类型的情况下, 显示待检测图像与标准的参考图像之间最显著的变化, 并对识别出的变化区域的元件进行缺陷类别分类, 主要分为 4 个步骤:

1) 图像预处理。预处理阶段可以理解为一个流水线: 首先通过精确直方图规定化去除光照、成像视图等环境差异的影响; 然后通过深度极限切割 (DEXTR, deep extreme cut) 提取 PCBA 轮廓并忽略背景; 最后通过仿射变换将参考图像和待测图像配准。

2) PCA-DBSCAN 变化检测。在本文方法的核心部分, 对两幅图像的特征使用改进的 PCA-DBSCAN 机器学习算法, 先利用主成分分析 (PCA, principal component analysis) 算法从原始数据中提取出特征, 再利用空间聚类算法 (DBSCAN, density-based spatial clustering of applications with noise) 对提取的特征进行分组, 将像素聚类为具有变化意义的类别;

3) 后处理。上一阶段将所有像素聚类, 在后处理阶段根据一定的启发式方法对每个类进行表征, 去除误报、合并相邻的变化区域等, 以确定哪些类以更有意义的方式代表“变化”;

4) 缺陷检测。创建 Brute-Force 匹配器, 使用 KNN 算法进行匹配, 计算相似度, 将变化分类为不同缺陷, 获取最终缺陷检测结果。

本文方法的工作流程如图 1 所示。

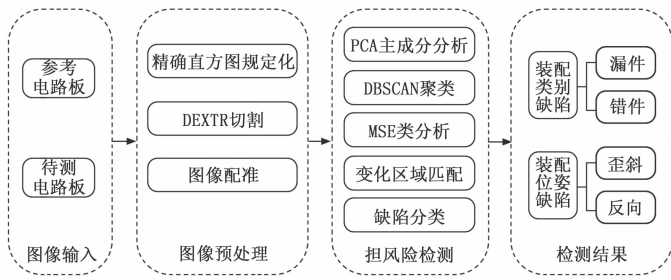


图 1 本文方法流程

2 方法详述

2.1 图像输入

图像输入为整个电路板检测流程的起始阶段，输入的图像包含两个部分：

1) 参考电路板的图像数据，该电路板是经过严格且全面检验流程的，在高精度检测设备的精准判定下被确认为完全合格的标准电路板；

2) 待测电路板的图像数据，此电路板与参考电路板属于相同型号且具备相同功能，在实际的生产或使用过程中，由于各种复杂因素的影响，其可能存在一定程度的安装缺陷，包括：装配类别缺陷（漏件、错件）、装配位姿缺陷（歪斜、极性反向）等。

2.2 图像预处理

变化检测对于两幅图像的照明、定位和图像分辨率等条件比较严格，为了检测到两幅图像之间的真实变化同时避免误判，本文方法通过执行精确直方图规定化和图像配准，放宽了两幅输入图像必须在相同条件下拍摄的标准。

2.2.1 精确直方图规定化

由于光学图像容易受到光照的影响，容易产生较大误差。正常情况下，在光源随时间缓慢衰减的固定捕捉系统中，精确直方图规定化会优化光照差异，可以将输入图像的直方图转换为指定的目标直方图。通过这种方法，可以对图像进行对比度调整、标准化或使其与参考图像在直方图分布上匹配。因此采用精确直方图规定化来减少光照差异对 PCB 图像的影响。

首先计算目标图像的直方图：对于灰度值为 r 的图像到直方图均衡后灰度为 s 的图像有如下公式：

$$s = T(r) = (L-1) \int_0^r p_r(w) dw \quad (1)$$

其次计算输入图像的直方图：现针对该输入图像，存在另一个灰度值集合 z 的图像，其图像内容与灰度值集合为 r 的图像是同一副图像，只是灰度值不同，则 z 对应的灰度图像通过如下函数 $G(z)$ 可以转换为 s 对应的图像：

$$G(z) = (L-1) \int_0^z p_z(t) dt = s \quad (2)$$

即可得：

$$z = G^{-1}[T(r)] = G^{-1}(s) \quad (3)$$

由此，通过计算输入图像和目标图像的直方图，并计算累计分布函数，两副内容相同灰度值不同的图像，可以很方便地找到其灰度映射关系，应用映射函数完成精确直方图规定化。

2.2.2 深度极值切割 (DEXTR)

执行弱监督分割的常见方法之一是在感兴趣对象周围绘制一个边界框。DEXTR 是一种基于深度学习的交互式图像分割方法。它利用每个物体的 4 个极值点（即目标对象的左、右、上、下 4 个边界点）作为输入来精确分割提取物体^[15]。DEXTR 在卷积神经网络 (CNN, convolutional neural network) 的输入中为图像添加一个额外通道，该网络包含以每个极端点为中心的高斯。CNN 学习将该信息转换为与这些极端点匹配的对象的分段。在预处理阶段使用 DEXTR 提取 PCBA 轮廓，可以忽略背景影响。在只需比较 PCBA 的部分内容时，可以提取特定组件，且能够在复杂场景和多目标情况下生成高质量的分割结果，实现高效分割；同时有其鲁棒性强的特点，对于不同类型的图像和目标对象也具有好的适应性。

2.2.3 图像配准

图像配准是在两幅图像之间估计最佳变换的过程，目的是将两幅图像整合到一个坐标系中，从而更容易进行比较。本文选取的是基于特征的配准方法，先提取特征点和描述符并进行匹配，而后使用相应的对来计算变换矩阵，将目标图像转换成与参考图像相同的方向和位置。为了提取和描述 PCB 板中的特征点，本文使用了尺度不变特征变换 (SIFT, scale-invariant feature transform) 算法^[16-17]，该算法特征对图像的缩放、旋转和部分视角变化具有不变性，广泛应用于图像配准、目标识别、三维重建等领域。其流程如图 2 所示。

SIFT 图像配准的步骤：

- 1) 特征检测：在两幅待配准的图像中检测 SIFT 特征点；
- 2) 特征描述：为每个特征点生成特征描述子；
- 3) 特征匹配：在两幅图像之间进行特征匹配，找到对应的特征点对；
- 4) 估计变换模型：利用匹配的特征点对，估计两幅图像之间的仿射变换模型；
- 5) 应用变换：将变换模型应用于其中一幅图像，使其与另一幅图像对齐。

SIFT 通过为一幅图像中的每个特征点寻找另一幅图像中特征点的最佳匹配点（使欧几里得距离最小）来匹配图像对。如果近邻距离与次近邻距离之比大于 0.8（文献 [18] 议数值），就会拒绝匹配。根据实验，这种

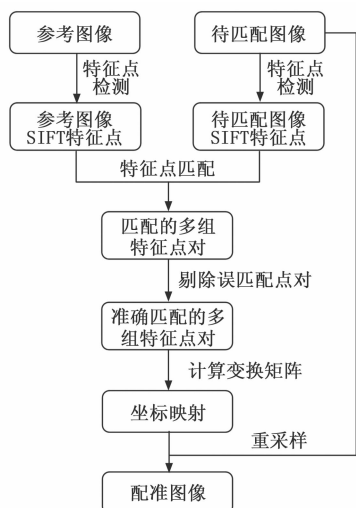


图 2 SIFT 算法流程图

剔除方法可以消除约 90% 的错误匹配, 同时只丢弃不到约 5% 的正确匹配。根据这些不同的匹配结果, 确定变换矩阵, 将一个图像映射到另一个图像上。由于匹配的数量可能超过了定义适当变换所需的最小值, 而且它们可能不遵循单一的线性模型, 因此还需使用随机抽样一致 (RANSAC, random sample consensus) 迭代法对变换矩阵进行稳健估计。对于图像配准中的变换矩阵估计, RANSAC 非常适用, 通过随机抽样和验证模型的一致性, 能够处理特征点匹配中的误匹配 (离群值), 能够在噪声数据中找到稳健的参数估计。

2.3 PCA-DBSCAN 变化检测

在完成精确直方图规定化和图像配准后, 本文使用基于 PCA-Kmeans 改进的 PCA-DBSCAN 算法进行变化检测。PCA-DBSCAN 是一种结合主成分分析 PCA^[19] 和基于密度的聚类算法 DBSCAN 的变化检测方法。如图 3 所示, K-means 聚类算法会根据初始化质心划分成这样 4 个簇, 但实际上应该是里面 3 个簇, 外面再环绕着一个簇。相比于 K-MEANS 算法, DBSCAN 算法可以很好的把这个笑脸进行分簇。该方法可以有效地处理高维数据, 检测其中的变化或异常。




图 3 聚类效果对比图

该算法要求两幅图像具有相同的尺寸 $[1, width] \times [1, height]$, 使用一种描述符, 为每个像素提取一

组特征, 描述该像素从一幅图像到另一幅图像是否发生了“变化”。首先通过 PCA 将高维数据 (即每组描述符) 投影到一个低维空间中, 保留数据的主要信息; 然后使用 DBSCAN 算法进行聚类, 识别数据中的密集区域和噪声点 (即异常或变化点); 最后将 DBSCAN 标记为噪声点的数据点识别为变化或异常。由于 PCA-DBSCAN 算法通过对数据流中的一个窗口 (即数据的一个子集) 进行处理来检测变化或异常, 因此是基于窗口的学习, 这种学习方式可以进一步消除输入图像中存在的噪声。

具体来说, 为每个像素 $(i, j) \in [1, width] \times [1, height]$ 定义一个描述符如下:

$$des[i, j] = \{des_{RGB}[i, j], des_{gray}[i, j]\} \quad (4)$$

$$des_{RGB}[i, j] = [|I_1(S)_R - I_2(S)_R|, |I_1(S)_G - I_2(S)_G|, |I_1(S)_B - I_2(S)_B|] \quad (5)$$

$$des_{gray}[i, j] = [|I_1(S)_{gray} - I_2(S)_{gray}|] \quad (6)$$

其中: $S = (i - \frac{h}{2} : i + \frac{h}{2}, j - \frac{h}{2} : j + \frac{h}{2})$, 表示

围绕像素 (i, j) 的大小为 $h \times h$ 像素窗口的索引子集。 I_1 和 I_2 代表两幅图像, 而 $|I_1(S)_R - I_2(S)_R|$ 表示在窗口 S 内 I_1 和 I_2 的红色通道的差值绝对值。同样的符号也适用于绿色 (G) 和蓝色 (B) 通道, 以及通过以下公式计算的灰度值 (gray), 它表示像素的亮度关系: $gray = 0.3R + 0.59G + 0.11B$ 。对于跨边界的窗口, 采用零填充 I_1 和 I_2 。

像素被分割成大小为 $h \times h$ 的不重叠的窗口 (如 5×5), 将这些窗口的集合记为 W 。对于每个窗口 W 中的窗口, 计算像素 (i, j) 在其中心的 $des_{RGB}[i, j]$ 。通过主成分分析 (PCA) 从窗口集合 $\{des_{RGB}[i, j]\}_{window \in W}$ 中, 提取 $S_{RGB} \leq h^2$ 个正交特征向量, 以创建特征向量空间 $Eigen_{RGB}$ 。随后也将 PCA 应用于集合 $\{des_{gray}[i, j]\}_{window \in W}$, 以获得以特征向量空间 $Eigen_{gray}$, 它包含 $S_{gray} \leq h^2$ 个向量。

每个像素 $(i, j) \in [1, width] \times [1, height]$ 可以表示为一个维度为 $(S_{RGB} + S_{gray})$ 的特征向量, 该向量是 $\{des_{RGB}[i, j]\}$ 在生成的特征向量空间 $Eigen_{RGB}$ 上的投影, 与 $\{des_{gray}[i, j]\}$ 在 $Eigen_{gray}$ 上的投影连接起来。每个 $h \times h$ 的差异图像块可以包含 3 种不同类型的数据: 1) 无变化数据; 2) 变化数据; 3) 变化数据和无变化数据的混合。前两种情况发生在 $h \times h$ 块完全位于差异图像的变化或未变化区域时。最后一种情况发生在 $h \times h$ 块位于变化和未变化区域的边界时。那么, 如果将 S_{gray} 设置为 3, 每种类型的数据可以用单个特征向量来表示。根据大量实验^[20] (在灰度卫星图像数据集上), 当 $3 < S_{gray} \leq h^2$ 时, 相对于 $S_{gray} = 3$ 的情况下, 变化检测性能没有显著变化。因此在本文

中, 选择 $S_{\text{gray}} = 3$, 而对于 RGB 特征, 选择 $S_{\text{RGB}} = 9$ 。经过在自己数据集上进行的实验后发现, 改变这些参数对结果没有显著影响。变化检测是通过将特征向量空间分割成两个簇来实现的。实验发现, 对于 PCB 图像, 需要更高分辨率的聚类来成功地将变化与其他像素分开。其原因是 PCB 图像通常采用高分辨率, 并且相比于卫星图像, PCB 图像具有更大的复杂性。

前一阶段将所有像素聚类成类 $\{C_1, C_2, \dots, C_n\}$ 。在后处理阶段, 使用基于密度的噪声应用空间聚类算法 DBSCAN 对特征进行聚类。DBSCAN 算法是属于无监督学习中的一种基于密度的空间聚类算法, 通过定义一个邻域半径 ϵ 和一个最小密度阈 MinPts 值来划分数据点的集合。

聚类的形成过程:

1) 初始化: 将所有数据点标记为未访问。

2) 选择一个未访问的点 P :

(1) 如果所有点都已访问, 算法终止。

(2) 否则, 从未访问的点中选择一个点 P 。

3) 检查点 P 的 ϵ 邻域:

(1) 计算点 P 的 ϵ 邻域内的所有点。

(2) 选择核心点: 如果 ϵ 邻域内的点数不小于 MinPts , 将点 P 标记为核心点, 创建一个新簇 C , 并将 P 及其 ϵ 邻域内的所有点加入簇 C 。

(3) 如果 ϵ 邻域内的点数少于 MinPts , 将点 P 标记为噪声点, 并将其标记为已访问。

4) 扩展簇 C :

(1) 对簇 C 中的每个点 Q , 检查其 ϵ 邻域。

(2) 如果 Q 是核心点, 将其 ϵ 邻域内的所有点加入簇 C (如果这些点还没有被访问或属于其他簇)。

重复这个过程, 直到簇 C 不再扩展。

5) 处理边界点: 如果点 P 是边界点 (即 P 的 ϵ 邻域内点数少于 MinPts , 但其本身是其他核心点的邻域点), 将其标记为已访问, 并将其加入相应的簇中。

6) 选择下一个未访问的点, 重复步骤 2~5), 直到所有点都被处理完。

DBSCAN 算法适用于不规则形状、大小差异较大的情况, 可以用于各种复杂形状的数据集。其无需指定聚类的数量, 它可以有效地处理不规则形状的簇以及簇大小差异较大的情况, 还能够识别噪声点, 对参数敏感性较低。

2.4 后处理: 使用 MSE 分析

前一阶段将所有像素聚类为 $\{C_1, C_2, \dots, C_n\}$, 聚类后处理主要关注检测数据集中是否发生了显著变化。在后处理阶段, 使用均方误差 (MSE, mean squared error) 的方法来评估聚类质量, 计算每个簇的质心, 并计算每个簇内数据点到质心的 MSE, 即评估点到簇中

心的距离, 以确定哪些类别更有意义地代表了“变化”。计算簇内 MSE, 对每个类别 C_i 的定义如下:

$$MSE(C_i) = \frac{1}{3 |C_i|} \sum_{(i,j) \in C_i} \sum_{c \in \{R,G,B\}} [I_1(i,j)_c - I_2(i,j)_c]^2 \quad (7)$$

根据 MSE 数值对类别进行排序, 每个类别根据其数值获得相应的颜色, MSE 数值最小的类别为蓝色, MSE 数值最大的类别为红色。给类别分配颜色后, 就得到了一张显示了变化的强度的热图。通过舍弃一些 MSE 数值较低的类别, 生成一张只标记出疑似变化的图。

2.5 缺陷分类

本文采用的分类方法为 Brute-Force 匹配器结合 K 近邻算法 (KNN, K-nearest neighbors)。Brute-Force 匹配器是一种暴力搜索算法, 通过逐个比较描述符找到最佳匹配, 使用 Brute-Force 匹配器可以有效地识别图像中的变化区域。具体步骤如下:

1) 特征提取:

使用特征检测器提取图像中的关键点和描述符。

2) 特征匹配:

使用 Brute-Force 匹配器逐个比较描述符, 找到描述符之间的最佳匹配。Brute-Force 匹配器会计算每对描述符之间的距离, 并返回距离最小的匹配。

3) 匹配结果筛选:

根据匹配距离筛选出最好的匹配结果, 使用距离阈值进行筛选。

KNN 是一种基于实例的学习算法, 通过计算待分类点与训练集中的点的距离, 找到最近的 K 个邻居, 根据邻居的标签进行分类。具体步骤如下:

1) 数据预处理: 收集并预处理训练数据, 包括提取特征和标注标签。特征可以是图像的描述符, 标签可以是缺陷类型。

2) 训练模型: 使用预处理后的数据训练 KNN 模型。KNN 模型不需要显式的训练过程, 而是直接使用整个训练集进行分类。

3) 分类: 对于待分类的变化区域, 计算其与训练集中所有点的距离, 找到最近的 K 个邻居, 根据这些邻居的标签进行投票, 确定待分类区域的标签。

本文方法使用 KNN 算法中邻居的相似度作为样本的相似度。当相似度值为 $0.1 \sim 0.6$ 为歪斜, 大于 0.6 为极性翻转。当阈值小于 0.1 时有两种可能: 漏件、错件, 这两种类型的图像相似度都很低, 通过实验发现漏件的颜色相似度不高, 而错件的颜色相似度较高, 因此使用颜色相似度来区分是漏件和错件。

通过 Brute-Force 匹配器结合 KNN 算法进行电路板安装质量检测, 可以有效地识别和分类图像中的缺陷

区域。该方法结合了高效的特征匹配和简单的分类器, 适用于多种缺陷检测任务。具有高效特征匹配, 适应性强的优点, KNN 算法简单易用, 通过实例进行学习和分类, 不需要复杂的模型训练过程。

3 实验及结果分析

3.1 构建缺陷 PCBA 数据集

为了评估本文方法的性能, 创建了一个数据集, 该数据集由 28 对 PCBA 图像组成, 其中共包括漏装样本 42 个, 错装样本 24 个, 歪斜样本 35 个, 芯片极性反转样本 28 个和电解电容极性反转样本 12 个(极性反转的缺陷检测仅限于芯片和电解电容这两类元件)并在它们之间标注了变化。该数据集包括具有装配类别缺陷(漏件、错件)、装配位姿缺陷(歪斜、极性反向)的印刷电路板图像, 如图 4 所示。




图 4 四种缺陷类型示例

3.2 评估方法

本文使用精确率和召回率来评估该算法。精确率是指在所有被算法归类为“变化”(正确或错误)的像素中, 真正的“变化”像素所占的比例。召回率是指在所有真实“变化”像素中, 被算法归类为真实“变化”像素的比例。混淆矩阵如表 1 所示。

表 1 混淆矩阵表

预测	实际正例	实际反例
预测为正例	TP	FP
预测为反例	FN	TN

其中, TP 表示真正例数量, FP 表示假正例数量, FN 表示假反例数量, TN 表示真反例数量:

$$Precision = \frac{TP}{TP + FP} \tag{8}$$

$$Recall = \frac{TP}{TP + FN} \tag{9}$$

由于印刷电路板上的每个缺陷都可能影响其功能, 因此需要高保证的缺陷检测。一方面, 高召回率对于算法能否提供高保障至关重要; 另一方面, 还需要高精度, 以便将重点放在真正的缺陷上。高误报率表明算法在正确描述和提取缺陷方面存在缺陷。

3.3 结果

在数据集上对本文方法进行评估, 其结果如表 2 所

示。虽然精确度看起来略低, 但需要注意的是真实的变化其实非常微小, 因此实际上相对于整个图像而言, 误报的数量非常少。图 4 示了本文对这些缺陷的识别结果。定量结果表明了算法在像素级别上的性能, 而定性结果直观地反映了对象级别。可以看出, 本文方法标记了基本真实图像中存在的几乎所有变化。

表 2 缺陷检测结果统计

缺陷类型	样本数量	正检个数	误检个数	漏检个数	准确率 / %	召回率 / %
漏装	65	53	4	8	92.98	86.89
错装	40	28	5	7	84.85	80.00
歪斜	45	31	6	8	83.78	79.49
IC 反向	36	27	5	4	84.38	87.10
电容反向	25	14	5	6	73.68	70.00
合计	211	153	25	33	85.96	82.26

4 结束语

本文提出了一种基于图像处理和无监督学习方法的轻量级自动变化检测算法, 实现了检测 PCBA 缺陷的综合方法。该方法拥有完整的流程, 包括预处理部分以及缺陷检测部分, 通过以上步骤可以实现比较标准 PCBA 和待检测的 PCBA 之间的差异检测, 完成装配类别缺陷、装配位姿缺陷分类。在检测的精确方面, 精确率和召回率都较高, 为后续阶段的研究提供了扎实基础。

参考文献:

[1] SANKAR V U, LAKSHMI G, SANKAR Y S. A review of various defects in PCB [J]. Journal of Electronic Testing, 2022, 38 (5): 481–491.

[2] 吴一全, 赵朗月, 苑玉彬, 等. 基于机器视觉的 PCB 缺陷检测算法研究现状及展望 [J]. 仪器仪表学报, 2022, 43 (8): 1–17.

[3] CHEN Y, DING Y, ZHAO F, et al. Surface defect detection methods for industrial products: a review [J]. Applied Sciences, 2021, 11 (16): 7657.

[4] MOGANTI M, ERCAL F, DAGLI C H, et al. Automatic PCB inspection algorithms: a survey [J]. Computer Vision and Image Understanding, 1996, 63 (2): 287–313.

[5] ANITHA D B, RAO M. SMT component inspection in PCBA' s using image processing techniques [J]. International Journal of Innovative Technology and Exploring Engineering (IJITEE), 2019, 8 (12): 541–547.

[6] CHAUDHARY V, DAVE I R, UPLA K P. Automatic visual inspection of printed circuit board for defect detection and classification [C] //2017 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET), IEEE, 2017: 732–737.

(下转第 41 页)