



团体标准

T/CI 360—2024

IC 封装基板图像检测系统技术规范

Technical specification for image inspection system of IC package substrate

2024 - 05 - 16 发布

2024 - 05 - 16 实施

中国国际科技促进会

发布

目 次

前言	II
引言	III
1 范围	1
2 规范性引用文件	1
3 术语和定义	1
4 IC 封装基板光学检测装置	2
5 基于主要距离的空域融合主板拼接方法	5
6 基于匹配特征融合的 SMT 贴片元件缺陷检测框架	7
7 基于元迁移学习和多尺度融合网络 SMT 贴装小样本缺陷分割框架	8
8 缓解遗忘性的图像增量学习分类方法	11
9 基于能量分布的未知异常样本检测方法	12
参考文献	16

前 言

本文件按照GB/T 1.1—2020《标准化工作导则 第1部分：标准化文件的结构和起草规则》的规定起草。

本文件由合肥综合性国家科学中心人工智能研究院（安徽省人工智能实验室）提出。

本文件由中国国际科技促进会归口。

本文件起草单位：合肥综合性国家科学中心人工智能研究院（安徽省人工智能实验室）、宿州学院、长沙安牧泉智能科技有限公司、江苏普诺威电子股份有限公司、电信科学技术仪表研究所有限公司、北京国知科苑科技发展中心、北京江海时代科技有限公司。

本文件主要起草人：康宇、许镇义、李恒征、单修洋、郑博宇、徐兰英、杨飞、陆敏晨、路遥、冯超、俞跃、臧江波、姜丽娟。

引 言

本文件的发布机构提请注意，声明符合本文件时，可能涉及到4.2相关实用新型专利（ZL202320228298.6）一种表面贴装元件光学检测装置的使用。

本文件的发布机构对于该专利的真实性、有效性和范围无任何立场。

该专利持有人已向本文件的发布机构承诺，他愿意同任何申请人在公平、合理且无歧视的条款和条件下，就专利授权许可进行谈判。该专利持有人的声明已在本文件的发布机构备案。相关信息可以通过以下联系方式获得：

专利持有人姓名：合肥综合性国家科学中心人工智能研究院（安徽省人工智能实验室）

地址：安徽省合肥市蜀山区望江西路5089号

请注意除上述专利外，本文件的某些内容仍可能涉及专利。本文件的发布机构不承担识别专利的责任。

IC 封装基板图像检测系统技术规范

1 范围

本文件规定了IC基板封装光学检测装置的技术构成、基于主要距离的空域融合主板拼接方法、基于匹配特征融合的SMT贴片元件缺陷检测框架和基于元迁移学习和多尺度融合网络SMT贴装小样本缺陷分割框架要求，提供了缓解遗忘性的图像增量学习分类方法和基于能量分布的未知异常样本检测方法。

本文件适用于工业IC封装基板及SMT贴装图像检测系统的研究、设计、技术路线，可作为IC封装基板和SMT贴装自动光学检测系统设计与研究的技术依据。适用于3C、芯片等泛半导体行业、LED、OLED等新型显示面板行业以及新能源产业电池模组端板、电芯等行业产品工业视觉质检。

2 规范性引用文件

本文件没有规范性引用文件。

3 术语和定义

下列术语和定义适用于本文件。

3.1

RGB 三色光源 RGB three-color light source

一种通过将红、绿、蓝三种颜色的光混合在一起来产生各种不同颜色的模式。

3.2

IC 基板封装 IC substrate package

将硅片上的电路管用导线接引到外部接头处，以便与其它器件连接的装置。

注：封装基板不仅能保护电路、固定线路并分散余热，还为芯片与PCB之间提供电子连接。

3.3

印刷电路板 printed circuit board (PCB)

电子元器件的支撑体和电气连接的载体。

注：它采用电子印刷术制作，因此被称为“印刷”电路板。

3.4

表面贴装技术 surface mounted technology (SMT)

通过一定的工艺、材料将表面贴片元件贴装在印刷电路板上的电子组装技术，是现代电子产品制造中的关键工艺技术之一。

3.5

自动化光学检测 automated optical inspection (AOI)

一种高速、高精度的光学影像检测系统，运用机器视觉技术作为检测标准。

注：这种检测系统可以改良传统上使用人力和光学仪器进行检测的缺点，广泛应用于各个领域，包括高科技产业的研发和制造品管，以及国防、民生、医疗、环保、电力等领域。

3.6

发光二极管 light emitting diode (LED)

一种常用的发光器件，由含镓、砷、磷、氮等的化合物制成，通过电子与空穴复合释放能量发光。

注：LED可高效地将电能转化为光能，因此在现代社会具有广泛的用途，如照明、平板显示、医疗器件等。

3.7

加速版鲁棒特征描述子算法 speed up robust features (SURF)

一种局部特征描述子，用于提取图像的局部几何特征。能够克服仿射变换、光照变化和三维视点变化等传统几何特征描述的不足，提取图像的局部几何特征。

3.8

K 最近邻算法 K-nearest-neighbors (KNN)

一种非参数、有监督的学习分类器，它使用邻近度对单个数据点的分组进行分类或预测。

3.9

卷积神经网络 convolutional neural network

一类包含卷积计算且具有深度结构的前馈神经网络。

3.10

增量学习 incremental learning

一个学习系统能不断地从新样本中学习新的知识，并能保存大部分以前已经学习到的知识。

注：增量学习非常类似于人类自身的学习模式，是一个逐渐积累和更新的过程。

3.11


元迁移学习 meta-transfer learning

涉及在不同学习环境中传输知识，以解决复杂的学习任务，其核心理念是从一个任务学习另一个任务，其中一个任务被称为源任务，另一个任务称为目标任务。

4 IC 封装基板光学检测装置

4.1 表面贴装技术所用贴装元件比起之前的插孔元件来说要微小得多，由于 IC 封装与 SMT 贴装元件的体积和重量只有传统插装元件的 1/10 左右，因此利用 SMT 技术生产的电子产品整体体积缩小约 40%~60%，相应地，重量减轻 60%~80%，检测各种微小的电气元件是否正确贴装以及其电气连接点焊接情况的好坏目前一般采用自动光学检测技术。

4.2 如图 1 所示，IC 基板封装光学检测装置包括固定支架 1、图像采集机构 2 和光源机构 3，图像采集机构 2 设置在固定支架 1 上并且能够在竖直方向上上下移动，该图像采集机构 2 的图像采集镜头竖直朝下，能够调整图像采集镜头到 PCB 距离，实现成像视窗范围的调整，光源机构 3 设置在固定支架 1 上，该光源机构 3 位于图像采集机构 2 镜头的正下方，光源机构 3 在竖直方向上上下移动并且向下垂直发射出红色、绿色、蓝色三段环形照明光照射，实现处于不同高度对电路板进行照射，得到更高成像分辨率，因为现有采用可见光直接成像技术，每个成像像素由 RGB 插值得到 (1R, 2G, 1B)，存在像素损失，导致成像分辨率不高的问题，通过采用红色、绿色、蓝色三段环形照明处于不同的高度对电路板进行照射，每个像素由 RGB 分别单独成像合成 (4R, 4G, 4B)，可以得到更高成像分辨率，同时保证整块电路板受到均匀光照，避免由于视角不同、照明差异所导致成像不一致。




标引序号说明：

- 1——固定支架；
- 2——两个U型架；
- 3——基座连杆；
- 4——两个固定杆；
- 5——第一滑动移杆；
- 6——第二滑动移杆；
- 7——图像采集机构；
- 8——工业相机；
- 9——光源机构；
- 10——半球环形装置。

图1 IC封装基板光学检测装置

如图1所示，固定支架1包括两个U型架2、基座连杆3、两个固定杆4、第一滑动移杆5和第二滑动移杆6，U型架2的开口都朝下并且均竖直设置，基座连杆3水平布置，基座连杆3与两个U型架2的上表面均固定连接，两个固定杆4分别固定连接在基座连杆3下表面的两侧，两个固定杆4与基座连杆3所在的平面垂直，两个固定杆4的相对侧一面分别都设有滑槽，第一滑动移杆5在两个固定杆4上的滑槽滑动上，并且第一滑动移杆5的两端在滑动结束后通过螺栓固定住，第一滑动移杆5水平布置，第二滑动移杆6在两个固定杆4上的滑槽上滑动，并且第二滑动移杆6的两端在滑动结束后通过螺栓固定住，所述第二滑动移杆6也水平布置，第一滑动移杆5在第二滑动移杆6的上方，即第一滑动移杆5和第二滑动移杆6在松开螺栓时可以上下滑动，滑动到需要的位置时通过螺栓将其固定。

如图1及图2所示，所述图像采集机构7为工业相机8，该工业相机8与第一滑动移杆5固定连接，工业相机8拍摄时的拍摄镜头垂直向下，光源机构9包括半球环形装置10、红色环形LED发光二极管灯带11、绿色环形LED发光二极管灯带12和蓝色环形LED发光二极管灯带13，半球环形装置10与第二滑动移杆6固定连接，半球环形装置10横截面小的部分朝上，红色环形LED发光二极管灯带11、绿色环形LED发光二极管灯带12和蓝色环形LED发光二极管灯带13在半球环形装置10从上而下依次紧贴，工业相机8和半球环形装置10处在同一个轴线上。



标引序号说明:

11——红色环形 LED 发光二极管灯带;

12——绿色环形 LED 发光二极管灯带;

13——蓝色环形 LED 发光二极管灯带。

图2 IC 封装基板光源机构

IC封装基板检测具体实施流程如图3所示:

- 首先将该装置安装在 PCB 传送平台的上方,使得工业相机 21 的视角正对于 PCB 的主体部分,松开第一滑动移杆 14 两端的螺栓,使第一滑动移杆 14 在固定杆 13 上上下下滑动,调整工业相机 21 到的距离来实现成像视窗范围调整;
- 其次将红色环形 LED 发光二极管灯带 31、绿色环形 LED 发光二极管灯带 32 以及蓝色环形 LED 发光二极管灯带 33 通过电源线与光源控制器连接;
- 光源控制器打开红色环形 LED 发光二极管灯带后,工业相机 21 采集 PCB 成像,然后光源控制器打开绿色环形 LED 发光二极管灯带,工业相机 21 采集 PCB 图像,最后光源控制器打开蓝色环形 LED 发光二极管灯带,将第二滑动移杆 15 两端的螺栓松开,调节光源机构 3 的高度,使得不同高度的光源机构 3 对电路板进行照射,可以得到更高的成像分辨率,同时保证整块电路板受到均匀光照,避免由于视角不同、照明差异所导致 PCB 成像不一致,至此完成一个视窗下的 PCB 成像采集,如此循环此操作直至所有视窗拍摄完毕。



图3 IC 封装基板检测流程

5 基于主要距离的空域融合主板拼接方法

5.1 图像拼接策略

图像拼接分为硬拼接和软拼接，硬拼接依赖既定的偏移量将两幅图像的像素直接叠加实现拼接，软拼接则依赖于拼接算法将两幅不同视角的图像置于统一的坐标系中，再通过像素映射实现拼接。基于主要距离的空域融合主板拼接算法流程如下图4所示。



图4 空域融合主板拼接算法流程

5.2 图像预处理

采用多种滤波器复合处理的解决方案，即先对原始图像进行双边滤波，再经过一次中值滤波。

- a) 双边滤波是在高斯滤波的基础上加入了像素值权重项，能够很好地对图像进行平滑处理以滤除高斯噪声，并且还能够很好地保留图像的高频细节，公式如下：

$$g(x,y) = \frac{\sum_{k,l} f(k,l) \omega(x,y,k,l)}{\sum_{k,l} \omega(x,y,k,l)} \quad \dots\dots\dots (1)$$

式中：

$g(x,y)$ ——滤波后的输出像素点灰度值；

$f(k,l)$ ——输入像素点灰度值；

$\omega(x,y,k,l)$ ——空间域核与像素范围域核的乘积；

$o(x,y,k,l)$ ——定义域核与值域核的乘积。

$$\omega(x,y,k,l) = \exp \left[-\frac{(x-k)^2 + (y-l)^2}{2\sigma_d^2} - \frac{\|f(x,y) - f(k,l)\|^2}{2\sigma_r^2} \right] \quad \dots\dots\dots (2)$$

式中：

σ_d ——空域高斯函数的标准差；

σ_r ——值域高斯函数的标准差；

$f(k,l)$ ——核函数作用域内的某一点；

$f(x,y)$ ——核函数作用域内的中心点。

- b) 中值滤波是把数字图像一点的值用该点的一个邻域中各点值的中值代替，对处理椒盐噪声非常有效，公式如下：

$$g(x,y) = \text{median}_{(s,t) \in S} \{f(s,t)\} \quad \dots\dots\dots (3)$$

式中：

$g(x,y)$ ——滤波后目标像素点的灰度值；

$f(s,t)$ ——邻域 S 中像素点灰度值。

5.3 SURF 特征点提取

AOI系统中的PCB图像在拍摄过程中是通过置物台的平移逐步获取的，因此相邻图像间具有非常良好的平移特性，同时移动过程中的轻微震动导致小角度的偏移，又使得两幅图像间出现一定的旋转变换。PCBA主板上的存在着各种元器件、孔位、锡膏和字符等，经过平移旋转变换后能够产生大量稳定的点特征，利用好图像间重叠部分的这些特征，将对拼接算法有着非常重要的意义，SURF特征提取算法在PCB图像中表现最佳，兼顾了速度和稳定性。

- a) 在原始图像的基础上构建尺度空间。SURF 首先将原图转换为积分图像，对于图像中某一点 $P(x,y)$ ，其在积分图像上的值为：

$$I_{\Sigma}(P) = \sum_{i=0}^{i \leq x} \sum_{j=0}^{j \leq y} \omega I(i, j) \quad \dots\dots\dots (4)$$

式中:

I ——融合后的像素点;

ω ——权重系数, 范围为[0,1], 表示由原点和该点组成的矩形区域内所有像素的总和。

b) 在此基础上, 采用 Hessian 矩阵建立盒式滤波器 (Box Filter), 来近似替代高斯二阶滤波器, 其中 Hessian 矩阵的数学表达式为:

$$H_{f(x,y)} = \begin{bmatrix} \frac{\partial^2 f}{\partial x^2} & \frac{\partial^2 f}{\partial x \partial y} \\ \frac{\partial^2 f}{\partial x \partial y} & \frac{\partial^2 f}{\partial y^2} \end{bmatrix} \quad \dots\dots\dots (5)$$

式中:

$f(x,y)$ ——图像中某一点的灰度值。

c) 将盒式滤波器带入 Hessian 矩阵, 得到下式:

$$H(x, y, \sigma) = \begin{bmatrix} D_{xx}(x, y) & D_{xy}(x, y) \\ D_{xy}(x, y) & D_{yy}(x, y) \end{bmatrix} \quad \dots\dots\dots (6)$$

式中 D_{xx} 、 D_{xy} 和 D_{yy} 分别代表盒式滤波器的三个滤波模板。然后计算该行列式的值, 得到:

$$\det(H) = \det(H) = D_{xx}D_{yy} - D_{xy}^2 \quad \dots\dots\dots (7)$$

为了平衡近似代替的误差, 通常要在 D_{xy} 前乘上一个加权系数 0.9。如果将 $\det(H)$ 作为判别项, 则可以根据其正负性得出点 (x, y) 是否是极值点。

5.4 特征点精确定位

5.4.1 通过盒式滤波器建立起图像的尺度空间后, 对像素点可以计算出其近似的海森矩阵行列式的正负性, 从而判断该点是否为极值点。然后再将其与 $n_3 \times n_3 \times n_3$ 的邻域内其他 n_26 个点比较, 如果为最大值或者最小值, 就可以初步判断为关键点。由于像素值是离散的, 通过滤波模板拟合的连续空间内的极值点可能处在两点中间, 因此需要采用二次插值来确定亚像素级特征点的精确位置。

5.4.2 在特征点的半径为 $n_6 \times S$ (S 为特征点所在的尺度值) 的圆形邻域内, 统计所有其他点在垂直和水平两个方向上的 Harr 小波 (Harr 小波模板边长为 $n_4 \times S$) 响应, 再对响应值进行高斯函数加权, 得到该点在两个方向上的方向权重。将整个圆域等分为 n_6 份扇形区域, 分别统计通得到该区域内的最大分量, 以最大分量的方向为特征点的主方向。

5.4.3 在以特征点为中心, 周围 $n_20 \times S \times n_20 \times S$ 的正方形邻域内建立笛卡尔坐标系, Y 轴为特征点主方向。再将该区域划分为 $n_4 \times n_4$ 个子块, 每个子块大小为 $n_5 \times S \times n_5 \times S$, 统计每个子块内像素点在垂直和水平方向的 Harr 小波响应值之和, 包括四个分量 $\sum dx$ 、 $\sum dy$ 、 $|\sum dx|$ 和 $|\sum dy|$, 得到一个 $n_4 \times n_4 \times n_4$ 维的特征点描述向量。最后对其归一化处理以消除光照影响, 得到特征点描述向量。

5.5 SMT 子图特征点粗匹配

5.5.1 采用 KNN 算法对 SURF 算法提取的两幅待拼接图像特征点进行配对。在建立两幅图像的两个特征点的集合 M 和 N 后, 下一步需要对两个集合内的特征点建立一对一的配对关系。具体来说, 将两幅图像的特征点集合分别看成训练集和查询集, K 典型值设为 2, 遍历训练集中的特征点, 对每个点在查询集中寻找其配对的两个点。配对的原则为两点之间的欧氏距离, 因此, 训练集中的每个特征点配对的将是查询集中与其欧氏距离最近和次近的特征点, 距离分别为 d_0 和 d_1 。然后对距离比 r 进行评估:

$$r = \frac{d_0}{d_1} \quad \dots\dots\dots (8)$$

如果 r 的值小于某个阈值, 就保留该对匹配点, 反之, 则抛弃。 r 的值越小, 说明匹配度越高。

由于 PCB 重叠主要是因为平移变换造成的, 而偏移距离在 PCB 图像的采集过程中不断变化, 无法用手动设定的值来确定。经过上述论证, 采用 SURF 提取的特征点在配对后, 如果将两幅图像直接拼接在一起, 那么匹配点之间的线段长度就是偏移距离。对所有线段长度进行统计, 将会得到一个距离分布直方图。通过实验发现, 绝大部分的线段长度分布在一个较稳定的范围内, 我们将范围定义为主要距离, 而错误匹配的长度偏差较大, 将其他不在该范围内的匹配对剔除。

5.5.2 将主要距离进一步细化, 得到精确到像素单位的匹配点距离分布直方图。通过在硬拼接的流程

中，每次用 SURF 算法计算两张待拼接图像间的匹配对主要距离中的众数作为偏移量。

5.5.3 基于 OpenCV 库中的 `concatenate` 函数进行相邻图像融合，每次拼接两幅相邻图像。具体来说，对于列拼接，按照设定的列偏移，将左图的重叠区域截断，再将右图与截断后的左图通过 `concatenate` 函数拼接，得到两张图拼接的中间图，再将此中间图作为下一次拼接的左图，与下一张相邻的图像拼接，依次类推，完成整个列的拼接；对于行拼接，同理。

5.5.4 为消除因光照不均造成的拼接缝两边明显色差。将拼接缝两边一定范围内的像素分别用两张图像的原像素加权得到，在空域上进行图像融合，能够很好地解决该问题。假设待拼接的两张图像分别为 A 和 B， I_1 和 I_2 分别代表 A 和 B 中的像素点，则像素加权法过程为：

$$I(x, y) = \begin{cases} I_1(x, y) & (x, y) \in A, A \cap B = \emptyset \\ \omega I_1(x, y) + (1 - \omega) I_2(x, y) & (x, y) \in A \cap B, A \cap B \neq \emptyset \\ I_2(x, y) & (x, y) \in D_2, A \cap B = \emptyset \end{cases} \quad \dots\dots\dots (9)$$

式中：

I ——融合后的像素点；

ω ——权重系数，范围为[0, 1]。

5.5.5 采用 SURF 算法提取出待拼接图像的特征点并配对，再计算出匹配对之间的欧氏距离，取数量占比最多的距离长度为主要距离作为硬拼接的偏移量。巧妙地结合了硬拼接与软拼接的优势，能够适应 PCB 图像在采集过程中偏移距离不断变化的情况，且拥有非常快的拼接速度，满足 SMT 工业场景中图像拼接的要求。

6 基于匹配特征融合的 SMT 贴片元件缺陷检测框架

6.1 在元件贴装环节，电子贴片元件通过锡膏焊接在 PCB 板上后，需要对元件贴片的质量进行检测，如检查是否有立碑、位移、空焊等缺陷。检查这些缺陷是 SMT 生产线中非常重要的一步，现有的工业缺陷检测主要分为人工目检和 AOI。即经过 AOI 检测之后，进行人工复判。

6.2 首先将贴片元件的模板图像与贴片元件的待测图像组成贴片元件样本，并根据贴片元件样本中的两个图像的类型，为贴片元件样本设置标签。从贴片元件的模板图像集中随机选择一张模板图像 I_z ，与从贴片元件的待测图像集中随机选择的一张待测图像 I_T ，组成贴片元件样本 $\{I_z, I_T\}$ ；如果贴片元件样本中两个图像对应的贴片元件属于同一类别，标签设置为 0；如果贴片元件样本中两个图像对应的贴片元件不属于同一类别，标签设置为 1。每一张待测图像都可以与一张模板图像配对组成一个训练样本。

6.3 将贴片元件样本中的两个图像分别输入到两个相同的编码器网络中，得到模板图像的深度特征 p_1 、待测图像的深度特征 p_2 ，并得到模板图像和待测图像的语义差异映射特征 $D(p_1, p_2)$ 。

设计两个相同的编码器网络 Encoder，每个编码器网络 Encoder 包含四层卷积层 Conv0、Conv1、Conv2、Conv3。通过卷积等操作分别从模板图像和待测图像中提取深度特征 p_1 、 p_2 。通过对提取的深度特征 p_1 、 p_2 应用一个相关操作模块，得到模板图像和待测图像的语义差异映射 $D(p_1, p_2)$ ：

$$D(p_1, p_2) = 1 - \frac{\sum_{i=0}^n p_1^i \times p_2^i}{\sqrt{\sum_{i=0}^n p_1^{i^2} \times \sum_{i=0}^n p_2^{i^2}}} \quad \dots\dots\dots (10)$$

式中：

p_1^i —— p_1 的第 i 个特征维度；

p_2^i —— p_2 的第 i 个特征维度；

n —— p_1 、 p_2 的特征维度总数。

利用语义差异映射特征 $D(p_1, p_2)$ 与深度特征 p_1 、 p_2 融合，将得到的融合特征 F 送入解码器网络进行缺陷分割，输出待测图像的缺陷检测结果。采用特征扩展操作实现对语义差异映射特征 $D(p_1, p_2)$ 与深度特征 p_1 、 p_2 的融合，融合特征记作 F 。将融合特征 F 送入解码器网络 Decoder 进行 SMT 缺陷分割，解码器网络 Decoder 包含四层卷积层 Conv4、Conv5、Conv6、Conv7 和三层上采样层 Up1、Up2、Up3 组成，结构为 $\{\text{Conv4}, \text{Up1}, \text{Conv5}, \text{Up2}, \text{Conv6}, \text{Up3}, \text{Conv7}\}$ ；最后连接一个 Softmax 层，输出 SMT 缺陷概率。

6.4 通过损失函数 loss 对缺陷检测模型的网络参数进行训练，当贴片元件样本 $\{I_z, I_T\}$ 的标签为 1 时，表明图像 I_z 、 I_T 对应的贴片元件类型不同，因此期望它们的特征在特征空间中的距离尽可能大；设置一个最大距离 M ，当 $D(p_1, p_2) > M$ 时，表示特征之间的距离足够大，即这两个贴片元件差距越大。同理，当

贴片元件样本 $\{I_z, I_T\}$ 的标签为 0 时, 表明图像 I_z 、 I_T 对应的贴片元件类别相同, 因此期望它们的特征在特征空间的距离尽可能小。损失函数loss设为:

$$\text{loss} = \sum_{i=0}^N (Y, p_1, p_2)^i = \sum_{i=0}^N (1 - Y) L_s(D^i) + Y \times L_D \max\{0, (M - D)^i\} \dots\dots\dots (11)$$

式中:

$(Y, p_1, p_2)^i$ ——第i个标记的贴片元件样本;

Y——第i个贴片元件样本的标签;

N——贴片元件样本的个数;

L_s 、 L_D ——常量, 默认值是0.5。

设定当 $D(p_1, p_2) > M$ 时, 损失函数值为0, 以简化计算。根据损失函数loss, 训练缺陷检测模型, 进行参数调整。

6.5 将训练完成的缺陷检测模型用于待测图像的 SMT 缺陷检测。在检测时, 选择与待测图像具有相同贴片元件类型的模板图像, 将待测图像和模板图像输入至缺陷检测模型, 当两个图像的相似概率大于阈值时, 判断待测图像对应的贴片元件为正常。基于匹配特征融合的 SMT 贴片元件缺陷检测框架如图 5 所示。




图5 基于匹配特征融合的 SMT 贴片元件缺陷检测框架

7 基于元迁移学习和多尺度融合网络 SMT 贴装小样本缺陷分割框架

7.1 整体框架

基于元迁移学习和多尺度融合网络SMT小样本缺陷分割框架如图6所示。




图6 基于元迁移学习和多尺度融合网络 SMT 贴装小样本缺陷分割框架

获取预训练采用的数据集为公共的COCO数据集以及小样本SMT贴装元件采集图像。元学习采用的数据集使用来自笔记本生产工厂流水线实际采集到的6类缺陷，分别是缺件、偏移、假焊、少锡、侧立、立碑。

预训练采用的数据集为公共的COCO数据集，COCO数据集是一个80类别的大规模数据集。COCO-stuff用像素级的东西注释增强了流行的COCO数据集。这些标注可用于场景理解任务，如语义分割、目标检测和图像描述。

7.2 框架构建

7.2.1 预训练

大规模数据上的预训练，即使用公共数据集进行训练。首先初始化一个特征提取器 Θ 和一个分类器 θ ，然后通过梯度下降对它们进行优化，迭代轮数为epochs，如下所示：

$$[\Theta; \theta] = [\Theta; \theta] - \alpha \nabla \ell_D([\Theta; \theta]) \quad (12)$$

特征提取器 Θ ：预训练过程中用到的特征提取器，比如预训练用到了COCO数据集，有 n_class 个类别，那么 Θ 就是将输入转换为一个 n_class 维度的特征向量。分类器 θ 是用来做维度转换的，比如我们最后小样本分类是一个 $target_class$ 分类，那么分类器 θ 作用就是将 n_class 维度的特征向量转换为5维。

其中 L 为以下损失函数：

$$\ell_D([\Theta; \theta]) = \frac{1}{|D|} \sum_{(x,y) \in D} l(f_{[\Theta; \theta]}(x), y) \quad (13)$$

式中：

$f_{[\Theta; \theta]}(x)$ ——预测值；

y ——真实值；

$|D|$ ——数据个数。

之后预训练学习到的分类器 θ 将被丢弃，因为随后的几次任务包含不同的分类目标。

7.2.2 元学习训练

SS操作表示为 $\Phi S1$ 和 $\Phi S2$ ，在学习过程中不改变预训练阶段训练的冻结神经元权值，而FT更新完整的网络。将 $\Phi s1$ 初始化为weight同维度的全1向量， $\Phi s2$ 初始化为bias同维度的全0向量，然后分别扩展为和weight、bias的同尺度，然后分别和weight和bias按元素相乘：其中 Θ 是特征提取器， θ 是基学习器。

整个训练过程可以分为两个阶段，首先将数据集分为支持集和查询集， T (支持集)的损失通过梯度下降来优化当前的基础学习器(分类器) θ' ，公式如下：

$$\theta' \leftarrow \theta - \beta \nabla_{\theta} \ell_{\tau(tr)}([\Theta; \theta], \Phi_{S_{1,2}}) \quad (14)$$

式中：

θ ——用于特征映射的基础学习器；

β ——学习率；

Φ_{S_1} ——缩放参数；

Φ_{S_2} ——位移参数。

T (查询集)的损失通过梯度下降来优化当前的元学习器SS，公式如下：

$$\Phi_{S_i} =: \Phi_{S_i} - \gamma \nabla_{\Phi_{S_i}} L_{T(te)}([\theta; \theta'], \Phi_{S_{\{1,2\}}}) \cdots \cdots \cdots (15)$$

式中：

γ ——学习率；

$L_{T(te)}([\theta; \theta'], \Phi_{S_{\{1,2\}}})$ ——损失函数；

$\nabla_{\Phi_{S_i}}$ ——梯度。

7.2.3 元测试

在元迁移测试阶段，将测试数据的支持集送入网络，调整基础学习器，随后将查询集送入网络，得到最终的分割结果。

7.3 元迁移学习框架构建

7.3.1 特征图融合

构建元迁移学习的框架，多任务学习框架包括用VGG作为主干网络，其中有5个编码器块得到五个初步特征图($F_i, i \in \{1,2,3,4,5\}$)。首先，我们分别对每个编码器块的特征映射进行 3×3 卷积，将通道减少到64个，这样可以减少后续操作所需的参数数量，同时可以帮助后续进行融合特征。接下来，将这些不同级别的特征分别输入到上一层网络，逐步进行融合，最后得到5个增强特征图($Level_i, i \in \{1,2,3,4,5\}$)，高层的特征图聚合了更多的特征，底层的特征图有更多的语义信息。

最后，每个 $Level_i$ 逐步融合并生成最终预测。任意两层之间的融合可以表示为：

$$SU = \text{Conv}(|F_A \ominus F_B|) \cdots \cdots \cdots (16)$$

式中：

F_A ——进行融合的第一个特征图；

F_B ——进行融合的第二个特征图；

$\ominus$ ——按元素相减，可以更好的提取两层网络的差异；

$||$ ——取绝对值；

Conv —— 3×3 的卷积。

不采用常规的拼接融合操作，而是更加注重提取不同层次网络之间的差异信息。

7.3.2 元学习损失函数设计

损失函数主要包括预训练阶段的损失函数，元学习阶段的损失函数，其中预训练阶段的损失函数和元学习阶段的损失函数采用交叉熵损失、Dice loss和Focal loss的组合形式：

$$L_{\text{pre}} = L_{\text{ce}} + L_{\text{dice}} + L_{\text{focal}} \cdots \cdots \cdots (17)$$

式中：

$L_{\text{Dice coff}}$ ——相似系数损失函数，见公式（17）；

L_{Focal} ——Focal损失函数，见公式（18）；

L_{logic} ——逻辑损失函数，见公式（19）。

$$L_{\text{Dice coff}} = \frac{2|X \cap Y| + \varepsilon}{|X| + |Y| + \varepsilon} \cdots \cdots \cdots (18)$$

式中：

X ——预测样本正例的面积；

Y ——真实样本正例的面积；

ε ——防止分母为零设置的参数。

$$L_{\text{Focal}} = -\alpha(1-p)^{\gamma} \log(p) \cdots \cdots \cdots (19)$$

式中:

α ——对不同类别的样本进行减重的参数;

γ ——调制系数;

p ——样本的预测值。

$$L_{\text{logic}} = -\frac{1}{n} \sum [y_i \log(g(x)) + (1 - y_i) \log(1 - g(x))] \cdots \cdots (20)$$

式中:

y_i ——标签的样本值;

$g(x)$ ——真实的样本值。

7.3.3 元迁移测试

将测试数据集中的小样本PCB图像输入到元迁移学习框架,得到最终分割结果。结果采用MIOU进行度量,其通过计算两组真值和预测值的相交和并的比率。公式如下:

$$mIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \cdots \cdots (21)$$

式中:

p_{ij} ——预测为j的真值i的个数;

$K+1$ ——类的个数(包括空类)。

i 是实数。则 p_{ij} 和 p_{ji} 分别表示假阳性和假阴性。分别测试在1shot, 2shot, 3shot, 5shot, 10shot下的miou做为评估指标。

8 缓解遗忘性的图像增量学习分类方法

8.1 缓解增量学习中遗忘性危机的深度学习图像分类算法利用自适应聚合网络来保证模型不会增长的同时,采用蒸馏学习来共同缓解增量学习中对于旧知识的遗忘问题。

缓解遗忘性的图像增量学习分类算法结构如图7所示,其中蓝色的部分被称作塑性模块,用来存放新类图片的知识参数,黄色的部分被称作稳定模块,用来存放旧类图片的知识参数,塑性模块与稳定模块分别是两个卷积神经网络的部分层,这个卷积神经网络可以是ResNet也可以是ResNext等。将图片分别输入两个卷积神经网络,将某一层后的输出引出之后分别得到 $x_{\eta}^{[1]}$ 与 $x_{\varphi}^{[1]}$,经过运算 $x_{\eta}^{[1]} * \alpha_{\eta}^{[1]} + x_{\varphi}^{[1]} * \alpha_{\varphi}^{[1]}$ 后输入两个卷积神经网络之后的层,再分别将之后的层的输出继续进行上述运算之后再输入到下一个层,以此类推,其中 $\alpha_{\eta}^{[1]}$ 与 $\alpha_{\varphi}^{[1]}$ 代表第一个塑性模块与稳定模块的自适应聚合权重,这些权重的数值可以自适应学习优化。




图7 自适应聚合网络结构

8.2 初始训练阶段时,塑性模块部分的卷积神经网络参数以及所有的自适应聚合权重均是不能训练的。此时,将部分基类的图像数据送入稳定模块部分的神经网络进行训练,优化目标为:

$$\varphi = \operatorname{argmin} L(\text{output}, \text{target}) \cdots \cdots (22)$$

式中:

φ ——稳定模块部分神经网络的网络参数;

$L(\cdot)$ ——交叉熵损失函数。

8.3 在增量学习阶段,稳定模块部分的参数将被冻结,即不再变化。并先训练塑性模块的网络模型参数,优化目标为:

$$\eta = \operatorname{argmin} L(\text{output}, \text{target}) \cdots \cdots (23)$$

式中:

η ——塑性模块的网络模型参数。

在塑性模块的网络模型参数收敛之后,也将之暂时冻结,并随机初始化自适应聚合权重,将图像同时输入两个神经网络,并优化自适应聚合权重。优化目标为:

$$\alpha_{\eta}^{[i]}, \alpha_{\phi}^{[i]} = \operatorname{argmin} L(\eta, \phi; \text{output}, \text{target}) \cdots \cdots \cdots (24)$$

式中:

$\alpha_{\eta}^{[i]}$ 和 $\alpha_{\phi}^{[i]}$ ——各个塑性模块和稳定模块的自适应聚合权重;

$L(\cdot)$ ——交叉熵损失函数。

需要说明的是,此时的训练数据为以往训练的旧类图像中具有代表性的图像以及当前的最新图像的合成数据集,其中旧类图像中具有代表性的图像可以通过各种经典的增量学习算法来获取,例如iCaRL、LwF、LUCIR或者数据集蒸馏等。当自适应聚合权重优化完毕之后继续进行增量学习,此时的优化目标为:

$$\eta = \operatorname{argmin} L(\phi; \alpha_{\eta}^{[i]}, \alpha_{\phi}^{[i]}; \text{output}, \text{target}) \cdots \cdots \cdots (25)$$

当增量学习进行到一定的程度时,自适应聚合参数并不能保证输出的准确性了,即此时的遗忘性危机比较严重了,这时就需要进行蒸馏学习阶段。

8.4 在蒸馏学习阶段,将模型的全部参数冻结,并按照稳定模块的神经网络模型的参数复制一个相同的模型出来,但是参数可变,且输出与自适应聚合权重无关。将旧类代表图像与新类图像同时输入自适应聚合网络以及复制的稳定模块网络,分别得到输出 output_T 与 output_S ,将 output_T 作为复制的稳定模块网络的期望输出优化网络参数,优化目标为:

$$\phi = \operatorname{argmin} L_d(\eta, \phi; \alpha_{\eta}^{[i]}, \alpha_{\phi}^{[i]}; \text{output}_T, \text{output}_S) + \lambda * \operatorname{argmin} L(\eta, \phi; \alpha_{\eta}^{[i]}, \alpha_{\phi}^{[i]}; \text{target}, \text{output}_S) \quad (26)$$

式中:

$L_d(\cdot)$ ——蒸馏损失函数;

$L(\cdot)$ ——交叉熵损失函数;

λ ——超参数;

ϕ ——复制的稳定模块网络。

在复制的稳定模块网络参数收敛之后,再将复制的稳定模块网络参数传递给自适应聚合网络中的稳定模块参数。接着即可继续重复增量学习步骤,这样就一定程度上缓解了增量知识过多带来的遗忘性危机。

9 基于能量分布的未知异常样本检测方法

9.1 所构建的基于能量分布的未知异常样本检测框架如图8所示。




图8 基于能量分布的未知异常样本检测方法

9.2 基于T能量分布的未知异常样本检测方法基于能量的传输机制ET和簇间扩展策略Lrep组成，为部分未标记的符合已知缺陷类别的PCB样本分配正确的缺陷类标签，然后让他们参与联合训练。ET引入能量分数作为不确定性度量，并估计基于不确定性的传输成本，以引导所有样本的集群分布。为了进一步促进logit空间中的区分度，不确定性能够显著反映已知/未知缺陷类别样本之间的差异，集群间扩展策略增强了混合已知和未知缺陷样本的全局特征表示，然后增强的表示将被映射到更具区分度的logits中。

同已知PCB缺陷类别检测不同，期目标在未知缺陷样本的干扰下分配标签，提出了一种基于logit空间的基于能量的传输（ET）机制，以更充分地探索未标记集中的语义差异和隐藏的知识。

9.3 具体来说，以与分类器 H_{cls} 并行的方式引入K维度的OT聚类器记为 H_{ot} ，用于将训练样本聚类为K个簇中心。对于给定的N个样本 $\mathcal{X} \in \{x_1, x_2, \dots, x_n\}$ ，以及通过骨干网络提取的特征编码 $z \in \{z_1, z_2, \dots, z_n\}$ ，定义第i个样本所属族类概率：

$$\mathcal{P}(c|x_i) = \text{softmax}(H_{ot}(z_i)) \quad (27)$$

式中：

c——一个K维度的向量，用来表示K个簇。

9.4 然后将最优传输问题中的成本矩阵定义为 $P \in \mathbb{R}^{K \times N}$ 以及公式(27)表示 x_i 属于 c_j 的概率，其中 c_j 是第j个簇。同样，将 $Q \in \mathbb{R}^{K \times N}$ 表示为分配矩阵，公式(28)表示 x_i 分配给 c_j 的后验概率。需要注意的是，分配矩阵Q仅表示将某个簇分配给每个样本，而不是直接为分类训练分配标签。当我们使用N维向量 β 表示N个样本和K维向量 α 表示K个簇的分布时，传输多面体中分配矩阵Q的所有可行解可以表示为公式(29)：

$$\mathcal{P}_{ji} = \mathcal{P}(c_j|x_i) \quad (28)$$

$$Q_{ji} = Q(c_j|x_i) \quad (29)$$

$$U(\alpha, \beta) = \{Q \in \mathbb{R}^{K \times N} | Q\mathbf{1}_N = \alpha, Q^T\mathbf{1}_K = \beta\} \quad (30)$$

式中：

$\mathbf{1}$ ——相应维度的全1向量；

α ——矩阵Q在其行和列上的边际投影；

β ——矩阵Q在其行和列上的边际投影。

随后引入用于区分已知和未知缺陷类别的能量分数 $e \in \mathbb{R}^N$ 引入传输优化模块，其定义如下：

$$e_i \in \log \sum_{j=1}^K e^{l(c_j|x_i)} \dots\dots\dots(31)$$

其中 $l(c_j|x_i)=H_{ot}(z_i)$ ，表示样本 x_i 属于簇 c_j 的逻辑分数。

9.5 基于能量的传输机制（ET）将鼓励具有较高能量分数的样本被分配到同一个簇中，而那些具有较低能量分数的样本，意味着它们在簇分布中具有较大的不确定性，将倾向于均匀分配在 K 个簇之间。基于能量 e 的分配矩阵 Q 可以表示为公式（31），能量传输成本 P 可以表示为：

$$\alpha = \frac{1}{K} \cdot I_K, \beta = \frac{e}{\sum_{i=1}^N e_i} \dots\dots\dots(32)$$

$$P_{en} = P \cdot e \in \mathbb{R}^{K \times N} \dots\dots\dots(33)$$

式中：

$e \in \mathbb{R}^N$ 能量分数；

P --成本矩阵；

K --聚类中心簇个数。

e 首先被广播成一个 $K \times N$ 的矩阵，然后与 P 逐元素相乘。因此， α 和 β 之间的 Wasserstein 距离定义为：

$$OT(\alpha, \beta) = \min_{Q \in \Pi(\alpha, \beta)} - \langle Q, P_{en} \rangle \dots\dots\dots(34)$$

式中：

$\langle *, * \rangle$ —— Frobenius 内积。

为了避免需要大量计算成本的线性规划问题，引入熵正则化项 $H(Q)$ 到 Wasserstein 距离中，并将优化问题表示为：

$$OT(\alpha, \beta) = \min_{Q \in \Pi(\alpha, \beta)} - \langle Q, P_{en} \rangle + \varepsilon H(Q) \dots\dots\dots(35)$$

式中 $\varepsilon > 0$ ， $H(Q) = \sum_{ji} Q_{ji} \log Q_{ji}$ ，以及此时优化 Q ：

$$Q_{\varepsilon}^{\frac{1}{\varepsilon}} = \text{Diag}(u) P_{en} \text{Diag}(v) \dots\dots\dots(36)$$

式中：

$\text{Diag}(u)$ ——以向量 u 为主对角线元素；

$\text{Diag}(v)$ ——以向量 v 为主对角线元素。

在这里，指数运算是逐元素进行的，而通过 Sinkhorn 算法， u 和 v 可以更快地求解。分配矩阵 Q 将 N 个样本映射到 K 个簇。

至此，能够将所有样本通过分配矩阵 Q 分配到 K 个簇中。

9.6 渐进式训练样本构建，在第 t 个训练阶段属于第 k 个簇的样本形成集合 D_k ，记为：

$$D_k^{(t)} = \{x_i | c_i^{(t)} = k\} \dots\dots\dots(37)$$

式中：

第 t 个训练阶段，定义已知 PCBA 缺陷类标签的集合为：

$$y^{(t)} = y_l \cup y_{ot}^{(t)} \in \{1, 2, \dots, M-1\} \dots\dots\dots(38)$$

式中：

M —— PCB 缺陷已知类别数量；

y_l ——有 D_l 中的地面真实标签组成；

$y_{ot}^{(t)}$ ——未标记的样本分配的伪标签。

请注意，在 $t=0$ 时， $y_{ot}^{(t)} = \emptyset$ ，并且在训练过程中会进行更新，而 y_l 保持不变。然后计算属于簇 k 中类别 $y \in y^{(t)}$ 的样本比例如下：

$$rate_{k,y}^{(t)} = \frac{|D_{k,y}^{(t)}|}{|D_k^{(t)}|} \dots\dots\dots(39)$$

当簇 k 中的所有未标记样本的 $rate_{k,y}^{(t)}$ 超过阈值 τ 时将被添加到标记集 D_L ：

$$D_L^{(t)} = D_L \cup \{x_i | x_i \in D_{k,y}^{(t)}, rate_{k,y}^{(t)} > \tau\} \dots\dots\dots(40)$$

同时从未标记的数据集中移除这部分数据。最终渐进式数据集优化目标可以写：

$$L_{cls}^{(t)} = - \sum_{x_i \in D_L^{(t)}} \sum_{y_i \in y^{(t)}} y_i \cdot \log(p(y|x_i)) \dots\dots\dots(41)$$

$$L_{unif}^{(t)} = - \sum_{x_i \in D_U^{(t)}} \frac{l_M}{M} \cdot \log(p(y|x_i)) \quad \dots\dots\dots(42)$$

式中:

$p(y|x_i)$ —— x_i 属于所有已知类别的预测概率;

y_i —— one-hot编码, 表示 x_i 的相应标签;

$\frac{l_M}{M}$ —— 在所有M个PCB已知缺陷类别上的均匀后验分布;

$L_{unif}^{(t)}$ —— 将强制 $D_U^{(t)}$ 中的样本均匀分布在M个PCBA已知类别之间。

9.7 能量分数计算: 考虑到 H_{cls} 和 H_{OT} 的并行结构, 它们都通过不同的全连接层将相同的特征映射到逻辑空间, 他们之间存在一定的相关性。使用由 H_{cls} 输出 $l(y|x_i) = H_{cls}(z_i)$ 中的能量分数作为未知 PCBA 缺陷类别的分数, 在训练后用于检测未知样本, 具体:

$$e(x_i) = \log \sum_{m=1}^M e^{l(y_m|x_i)} \quad \dots\dots\dots(43)$$

式中:

$l(y_m|x_i)$ —— x_i 属于 y_m 的逻辑分数, 分数越高表示越属于已知缺陷类别。

为了能够平滑能量分布, 避免未知类别样本的能力集中在最小能量处, 设置了较大的温度T, 具体T能量分数表示如下:

$$T_e(x_i) = T * \log \log \sum_{m=1}^M e^{l(y_m|x_i)/T} \quad \dots\dots\dots(44)$$

9.8 集群间扩展策略: 为了扩大已知和未知 PCBA 缺陷类别的能量表示, 从而加强能量传输成本, 进而引导未标记样本进入不同簇的能力, 进一步引入了一个称为集群间扩展策略的无监督训练模块来获得改进的特征表示。

在没有标签数据中, 使用两个分别来自DL和DU的数据批次 $\{x_{(l,i)}\}_{i=1 \dots B_1}$ 和 $\{x_{(u,i)}\}_{i=1 \dots B_2}$ 构造联合训练数据 $\{x_i\}_{i=1 \dots B} = \{x_{(l,i)}\} \cup \{x_{(u,i)}\}$, $B=B_1+B_2$ 。之后, 使用两种不同的数据集增强策略获得同一图片增强后的图片记作: $x_i^0 = A^0(x_i)$; $x_i^1 = A^1(x_i)$, 通过同一骨干网络提取特征:

$$z_i^k = H_m(e_{\theta}^k(x_i^k)), k = 0, 1 \quad \dots\dots\dots(45)$$

式中:

e_{θ} —— 骨干网络参数;

H_m —— 多层感知机。

考虑到数据标签的缺失, 使用InfoNCE Loss:

$$L_{rep} = - \sum_{i=1}^N \log \frac{\exp(\cos(z_i^0, z_i^1))}{\sum_{j=1}^{n+B} \exp(\cos(z_i^0, z_j))} \quad \dots\dots\dots(46)$$

式中:

$z_j \in Z^{1,(t)}$, $\cos$ —— 预先相似度。

通过 L_{rep} 获得的增强表示将被映射到低维度的逻辑空间, 在这个空间中, 可以更好地获得特定类别的能量分数, 以更好地反映不同类别样本之间的语义差异, 并为它们分配更具区分性的簇分布。

参 考 文 献

- [1] GB/T 8750-2022 半导体封装用金基键合丝、带
 - [2] YS/T 1595-2023 电子封装用钼铜层状复合材料
-