

DOI:10.19651/j.cnki.emt.2106827

# 一种基于 AI 的 Chip 类元件 AOI 自动复判方法

王瑞丰<sup>1</sup> 魏嘉莉<sup>1</sup> 周静<sup>1</sup> 冀运景<sup>2</sup> 罗守华<sup>1</sup>

(1.东南大学 生物科学与医学工程学院 南京 210096; 2.明锐理想科技有限公司 深圳 518000)

**摘要:** 贴片元件 AOI 自动复判可提高检测的直通率和精度,降低人工目检带来的时间与经济成本。Chip 元件作为 PCB 电路贴片元件中的最常用元件,其错误类型繁多,包括焊接的少锡、多锡、缺焊、水平与垂直偏移,以及本体的缺件、错件等问题。针对 Chip 元件,提出了一种基于 AI 的 AOI 复判检测方法,包括了本体与焊盘的定位、本体颜色或丝印的检测和元件焊接检测等 3 个步骤,每个步骤根据需求不同设计了相应的网络模型,并对上述模型分别进行了训练和测试。测试结果表明,本体与焊盘检测网络在 IOU 阈值为 0.7,置信度阈值 0.6 的条件下,mAP 为 0.93,检测准确率 94.94%;颜色判断网络平均准确率为 99.41%;丝印字符检测网络检测准确率为 97.6%;焊接问题检测网络准确率为 92.27%。最后,跟据收集到 233 幅 NG 数据以及 30 000 幅 OK 数据对整体流程进行测试,在保证 233 幅 NG 数据不出现漏判的前提下,该方法整体的误判率为 11.2%,平均每幅运行耗时 97.5 ms。目前,该方法已在生产线上进行了试用,初步结果表明,该方法能够有效降低生产线上元件的误报率,降低人工成本,具有较好的应用前景。

**关键词:** 工业应用;AOI;AI;深度学习;神经网络

**中图分类号:** TP23;TP391 **文献标识码:** A **国家标准学科分类代码:** 520.2024

## An AI-based AOI automatic reassessment method for Chip components

Wang Ruifeng<sup>1</sup> Wei Jiali<sup>1</sup> Zhou Jing<sup>1</sup> Ji Yunjing<sup>2</sup> Luo Shouhua<sup>1</sup>

(1. School of Biological Science and Medical Engineering, Southeast University, Nanjing 210096, China;

2. Magic Ray Technology Co., Ltd., Shenzhen 518000, China)

**Abstract:** SMD components AOI automatic re-judgment can improve the detection of straight-through rate and accuracy, reduce the time and economic costs of manual visual inspection. Chip components as the most commonly used PCB circuit SMD components, its error types are numerous, including solder insufficient, more tin, open solder, horizontal and vertical offset, and the body of the missing parts, wrong parts and other issues. For Chip components, proposes an AI-based AOI re-judgment detection method, including the body and solder positioning, body color or silk screen detection and component soldering detection, each step according to the different needs of the design of the corresponding network model, and the above models were trained and tested. The test results show that the body and solder detection network has a mAP of 0.93 and a detection accuracy of 94.94% under the condition that the IOU threshold is 0.7 and the confidence threshold is 0.6; the average accuracy of the color judgment network is 99.41%; the detection accuracy of the screen-print character detection network is 97.6%; and the accuracy of the welding problem detection network is 92.27%. Finally, the overall process was tested according to the 233 NG data collected and 30 000 OK data, and the overall false alarm rate of the method was 11.2%, with an average run time of 97.5 ms per frame, under the premise of ensuring that 233 NG data were not missed. currently, the method has been tried on the production line, and the preliminary results show that the method can effectively reduce the component false alarm rate and reduce the labor cost, which has a good application prospect.

**Keywords:** industrial application;AOI;AI;deep learning;neural network

## 0 引 言

自动光学检测(automated optical inspection,AOI)是

当前 PCBA 领域不可或缺的缺陷检测系统,其主要应用于表面装贴(surface mounted technology,SMT)生产流水线,可有效检出印刷、装贴以及焊点等缺陷。AOI 系统通常被

置于生产线上的关键位置,监控具体的生产状况,并为生产线工艺的调整提供必要的依据<sup>[1]</sup>。较人工日检而言,AOI 检测虽已实现较高的自动化以及检测精度,但应用过程中仍具有一定的局限性:如炉后 PCB 板的弯曲变形将导致检测框偏离实际元件;其次受物料和工艺的变化,焊点形态变化多端,为 AOI 检测带来困难。除此之外,还存在来料变化(元件来料色差以及引脚长短变化等)、白色丝印干扰以及良品与不良品图像相近等各种复杂情况,使 AOI 误报率居高不下。AOI 的高误报率使生产线不得不利用人工进行二次检测,带来了检测效率的下降以及人力成本的增加。

随着大数据时代的发展,人工智能(artificial intelligence, AI)得到广泛的关注,应用 AI 来辅助 AOI 检测势必将成为 PCB 领域的一大重要发展方向。深度学习作为 AI 领域的一个重要方向,能够对各种故障状态及信息进行特征提取,同时可抑制噪声有利于故障信息的收集<sup>[2-3]</sup>。目前关于 AOI 自动光学检测的研究主要针对焊接缺陷的检测,Cai 等<sup>[4]</sup>应用级联的卷积神经网络对 IC 元件引脚焊接情况进行检测,取得了较好的效果;韩航迪等<sup>[5]</sup>针对航天电子焊点缺陷人工检测效率低下的问题,提出了基于改进的 Tiny-YOLOv3 缺陷检测网络,实现了 5% 的检测误差;殷政<sup>[6]</sup>对 AlexNet 进行改进并对 IC 引脚缺陷进行自动检测。该方法在虚焊、短路等 5 种焊接问题中的测试准确率达到 94.23%。然而,实际生产中 AOI 检测项目众多,通常包含焊接缺陷检测、元件表面丝印、本体颜色检测等。现有研究均着力于单项问题的研究而未给出全面整体的元件检测方法。在本研究的了解范围内,日前仍未有一套完整的基于 AI 的元件检测方案。此外,现有方法对模型

的实时性讨论不足,对于其是否能真正应用于实际的 PCBA 生产领域有待进一步讨论。

本研究将深度学习应用到 AOI 自动光学检测中,以 Chip 类元件的检测为例,结合工厂的实际需求给出一套较为完整的元件检测方案,以期用于对传统 AOI 光学检测的检测结果进行复判。针对 AOI 检测的 AI 复判,旨在应用于 AOI 检测之后,对 AOI 抛出的异常结果(NG-No Good)进行二次检测,来弥补 AOI 检测的不足,降低元件的误报率。本文的研究过程与实际生产过程紧密结合,研究使用的 Chip 数据均从产线上直接获取,数据分布范围广,真实性强。在此基础上实现了焊接问题检测、本体丝印与颜色检测等多种检测项目为一体的 Chip 元件复判检测方案。在研究方案的选择和设计过程中,均衡考虑了各个检测步骤所用模型的准确率和实时性,期望其能真正应用于实际的 AOI 辅助检测中,达到提高生产效率的目的。

## 1 模型及方法

### 1.1 Chip 类元件 AOI 自动复判算法框架

元件的检测分为本体检测与焊点检测,因此在检测前首先要对元件的本体与焊点进行分割,分割出来的本体与焊点将分别送入到本体质量检测网络以及焊接质量检测网络当中。本体质量检测网络主要针对 Chip 元件的错件进行检测,包括本体颜色分类网络以及丝印检测网络;焊接质量的检测网络运用异常检测模型来判断焊点是否正常。当本体与焊点的检测结果均为 OK 时,系统输出结果为 OK,如果其中一项检测为异常,整体输出结果为 NG,具体工作流程如图 1 所示。

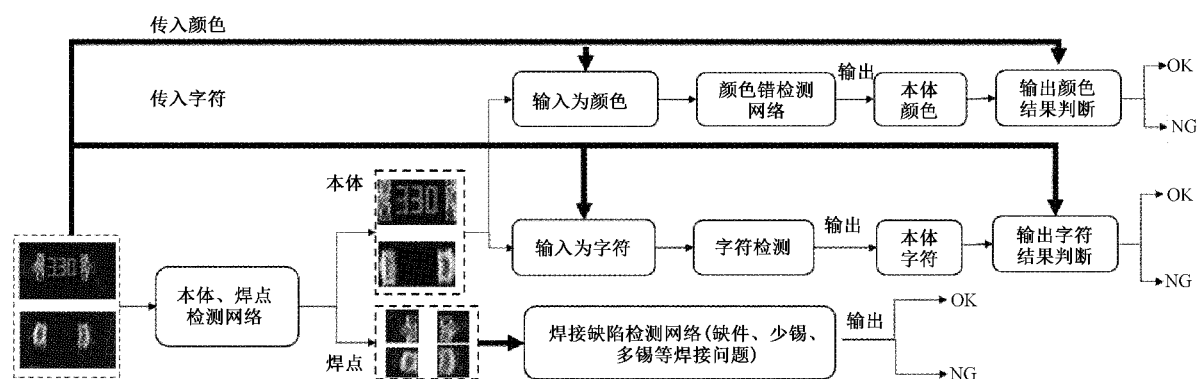


图 1 AI 复判流程

### 1.2 本体、焊点定位模型

本体、焊点定位网络借鉴了 SSD<sup>[7]</sup>的网络结构,该算法采用全卷积结构并摒弃了候选框的设置,直接从网络中回归坐标集类别<sup>[8-9]</sup>。为保证网络运行的实时性,以 mobilenetv2 网络<sup>[10]</sup>作为特征提取的骨架,去掉其最后的平均池化层以及全连接层,新增两层卷积层分别用于坐标与类别的回归。另外,由于 Chip 类元件纹理简单,样式较为单一,因此网络构建过程中,舍去了原始 SSD 网络中的

多尺度输出,仅在最后一个特征提取层进行坐标的回归与类别的判断,网络结构如图 2 所示。

### 1.3 本体颜色识别网络

本体颜色识别网络主要针对 Chip 类元件的错件问题,错件主要指本应在 PCB 板上某个位置使用的元件型号,由于某些原因被替换成了其他型号的元件。针对 Chip 类元件,其错件可以通过颜色以及丝印进行判断。在 Chip 类元件中,大致将各类元件分为 3 个颜色,其中电容与电感主




图 2 本体、焊点定位网络框架

要分为黑色、白色与棕色，而电阻元件主要分为黑色、绿色与蓝色。由于 Chip 元件本身包含的纹理信息很少，加上光照条件的不同，很多情况下导致各种颜色的界限比较模糊。以电容元件为例，其中存在部分被标记为白色的电容元件，其本体因为光线较暗或污渍导致中间呈现出较浅棕色，而边界部分基本呈现白色，而棕色电容中由于其棕色的深浅不同，这种情况下白色电容与标注为浅棕色的电容区分度将变小，而深棕色电容在光照较暗的情况下较为接

近黑色，容易与真实的黑色电容混淆。

由此可见，在分类过程中需注意颜色细节的区分，才能达到较为满意的结果，因此本文引入细粒度分类方面的双线性卷积神经网络<sup>[11]</sup>，如图 3 所示。由于 Chip 类元件纹理特征较少且颜色特征属于浅层特征，因此在特征提取阶段不需要很深的网络结构。因此，本模型仍使用 mobilenetv2 的结构，模型层数只用到第 3 个 Residual Block。




图 3 改进的双线性分类网络框架<sup>[11]</sup>

### 1.4 丝印字符检测网络

字符检测网络采用了目前主流的 CRAFT+CRNN+CTC 的网络架构。其中 CRAFT 网络<sup>[12]</sup>主要用于丝印字符的定位与分割，CRNN+CTC 的网络架构<sup>[13]</sup>用于分割后的字符识别。CRAFT 网络由编码网络和解码网络构成，其编码网络采用 VGG-16 的网络架构，在解码阶段跳过全连接层，并使用类似 U-net<sup>[14]</sup>的结聚合低级特征，最后将该特征分别送入两个卷积层进行最后的概率回归，得到字符中心概率与字符间连接的中心概率，网络结构如图 4 所示。CRNN+CTC 网络结构如图 5 所示，其主要由卷积网络、循环神经网络以及翻译网络构成。卷积网络同样使用 VGG-16 网络结构；循环神经网络部分由两层双向 LSTM 网络构成<sup>[15]</sup>；翻译层通过全连接网络得到序列每个位置的概率，然后通过连接主义时间分类器 (connectionist temporal classification, CTC) 计算网络损失，该损失中引入了空白占位符，实现了不定长文本的编码。

### 1.5 焊接缺陷检测网络

焊接缺陷检测可归结为异常检测问题，由于 NG 数据

难以获取且类型繁多，难以获得大量数据和相对应的标签<sup>[16]</sup>。为此选用了半监督模型 GANomaly<sup>[17]</sup>，该模型在训练过程中不需要 NG 数据，仅 OK 数据便可得判别模型。模型由 1 个自编码器、1 个二次编码器和 1 个判别器组成，自编码器主要用于对输入数据进行编码与重建，二次编码器将对重建的图像进行编码，而判别器主要体现了 GAN 网络<sup>[18]</sup>的思想，用于评价重建图像的好坏，网络结构如图 6 所示。其中， $\mathcal{L}_{enc}$  为两次编码的损失， $\mathcal{L}_{con}$  表示图像重建损失， $\mathcal{L}_{adv}$  为网络的对抗损失。

## 2 实验结果

### 2.1 本体、焊盘检测结果

数据处理与训练: Chip 类元件数据来源于明锐理想有限公司，选取有丝印与无丝印的数据共 3 173 幅进行图像标注构成训练数据集。如图 7 所示，在本体标注上，无论有无丝印，其本体均标注为 body，焊点标注为 land。网络训练时，首先将数据进行大小调整操作，尺寸为 300×300；



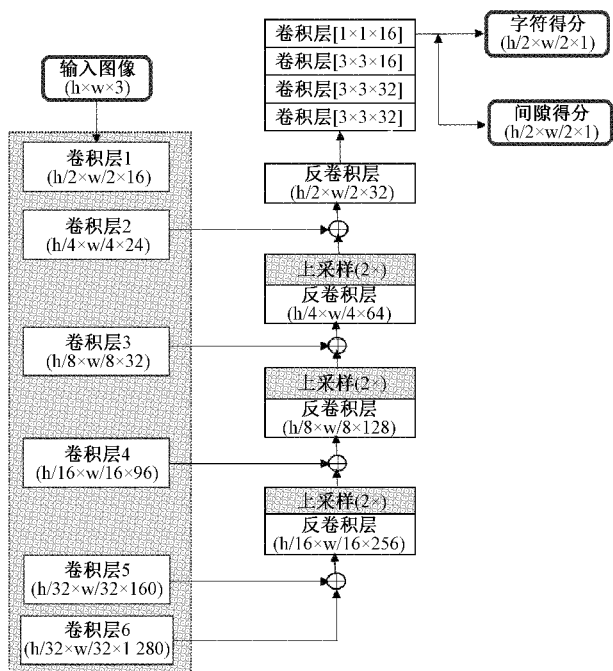


图4 CRAFT网络框架<sup>[12]</sup>

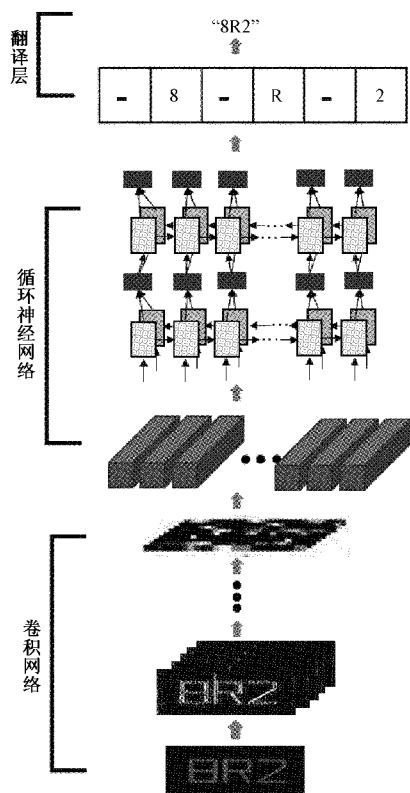


图5 CRNN+CTC网络框架<sup>[13]</sup>

然后进行随机镜像、随机光照等操作进行数据增强,对增强后的数据进行归一化与标准化。

模型测试结果:本体、焊盘检测训练数据集共包含3 173幅图片,其中训练集2 535幅、测试集623幅。针对





图6 GANomaly网络框架



(a) 包含字符的数据 (b) 不含字符的数据

图7 图片标注结果

测试集,本研究采用各类平均精度(average precision, AP)与总平均精度(mean average precision, mAP)对网络性能进行评价。另外,由于该数据集每幅图片均包含一个本体与两个焊点,且需要全部检出才算成功的定位,本文还对测试集的检测准确率进行了评价,即全部检出的图片数量与总的图片数量的比值。本文研究针对AP与mAP的计算采用VOC数据集中计算相应指标的方法,取输出置信度前10的预测框进行归类,得到每个类别预测框的个数,设定交并比(intersection over union, IOU)阈值为0.7,置信度从0.5取到1.0,步长为0.05,计算得到一系列各个类别的精度与召回率,绘制P-R曲线如图8所示。

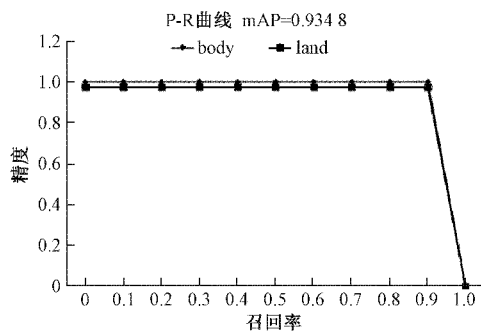


图8 P-R曲线

经计算,得到body的AP为0.95,land的AP为0.9195, mAP为0.93。在IOU阈值为0.7,置信度阈值为0.6的情况下,计算测试集的检测准确率为0.9494。通过测试可以发现,本体与焊盘检测网络具有足够高的检测精度,取几组未在测试集中的数据进行测试,结果如图9所示,从该测试结果中可以看出对于各类型的本体与焊点均可做出有效地检测。




图9 各种样式Chip元件的测试结果


2.2 本体颜色检测结果

数据处理与训练:训练数据集来源于本体、焊盘定位网络分割出来的本体数据。其中电容分为黑色、棕色、白色,训练数据 20 000 幅;电感分为黑色、棕色、白色,数据量 8 000 幅;电阻分为蓝色、绿色、黑色,训练数据 24 000 幅,每类每种颜色的数据量基本持平。考虑实际应用场景,如电阻元件不存在棕色与白色,因此模型建立过程中,分别对电感、电阻、电容进行单独的训练,共得到 3 个网络。


模型测试结果:电容测试数据共 4 271 幅图片;电阻测试数据共 16 976 幅图片;电感测试数据共 4 357 幅图片。测试结果以混淆矩阵与准确率给出,混淆矩阵与准确率如图 10 与表 1 所示。



(a) 电容测试结果的混淆矩阵



(b) 电阻测试结果的混淆矩阵



(c) 电感测试结果的混淆矩阵

图 10 测试结果混淆矩阵

表 1 电容、电阻、电感颜色分类测试结果

| 元件类型  | 电容    | 电阻    | 电感    |
|-------|-------|-------|-------|
| 准确率/% | 99.98 | 98.26 | 99.98 |

从测试结果来看,3 类元件在颜色分类上均达到了一个较高的准确率。电阻数据由于存在部分蓝色数据在图像采集过程中光线过暗,导致错误分类为黑色,准确率相对较低,其他两类则达到了一个较为满意的准确率。

2.3 本体字符检测结果

数据处理与训练:CRAFT 网络训练集数据共 13 356 幅,除包含丝印的 Chip 类元件,还包括 IC 等其他元件的数据。随机选取其中 10 017 幅作为训练集,剩余数据作为测试集进行训练。训练前用高斯热值图对数据进行标注,如图 11 所示,训练过程中对输入图像进行随机亮度变化,随机噪声等数据增强。CRNN+CTC 网络的训练数据集来自定位网络截取后获得的文本区域图像。为保证字符不产生剧烈形变,在图像大小调整的方法上采用保持图像长宽比的调整方法。




图 11 字符定位网络图像标注

模型测试结果:本体字符检测网络分为字符检测网络与字符识别网络,针对字符检测网络,本研究使用召回率,准确率以及  $F_1$  值作为网络的评价指标,测试结果如表 2 所示,所有结果均在 IOU 阈值为 0.75 的条件下测试得到。

表 2 基于 CRAFT 网络的文本定位网络测试结果

| 网络结构  | 召回率/% | 准确率/% | $F_1$ 值 |
|-------|-------|-------|---------|
| CRAFT | 98.9  | 97.6  | 98.2    |

对于字符识别网络,本研究采用准确率与编辑距离作为性能评价指标,同时对比了 3 种网络结构的识别效果,测试结果如表 3 所示,其中编辑距离是用来评价两字符串之间相似度的指标,其值越小代表字符串之间相似度越高。

表 3 测试准确率与平均编辑距离

| 网络结构         | 准确率/% | 平均编辑距离 |
|--------------|-------|--------|
| CRNN         | 90.29 | 1.08   |
| CRNN+注意力     | 93.12 | 0.74   |
| CRNN+注意力+FAN | 94.53 | 0.69   |

如表3所示,加入了注意力机制后准确率提升了2.83%,平均编辑距离降低了0.34;再加入FAN后测试准确率得到进一步提升,达到了94.53%,平均编辑距离下降至0.69。由此可见基于CRNN+注意力+FAN的网络组合较为合理。

#### 2.4 焊接缺陷检测

数据处理与训练:训练数据集来源于本体、焊盘定位网络分割得到的焊点数据,共15 233幅,其中OK数据15 000幅,NG数据233幅,NG数据仅用于模型性能的测试。为了网络能够有效编码OK数据的纹理以及语义信息,所有数据均被处理到了一个方向,如图12所示。训练过程中,生成器的损失函数由自编码器的重构损失、两次编码的编码损失以及判别器的真假损失共同构成,判别器只采用其自身的真假分类损失构成,生成器与判别器采用交替训练的模式。网络在推理时,只以编码损失作为OK与NG的评价标准,当该损失小于设定的阈值时,认为数据为OK,否则为NG。



图12 将训练数据处理到一个方向

模型测试结果:本文应用233幅NG数据与7 000幅OK数据进行测试,数据均为本体、焊盘定位后的单个焊点数据,样例如图13所示。由于OK数据与NG数据的数据比例严重不对称,本研究采用ROC曲线与AUC作为模型性能的评价指标,结果如图14所示。




图13 NG与OK样本示例




图14 Ganomaly测试ROC曲线

根据图13中的ROC曲线可以看出,当误差阈值取0.045 2时,AUC达到了0.996 3,此时存在12幅NG图被

漏判,即在允许极少的NG被误判成OK的情况下,网络对OK数据的判断准确率达到了较高的水平。但实际使用过程中,由于NG数据被漏判的严重性要远大于OK数据被误判的严重性,因此,本研究选取了NG数据中两次编码的最小误差作为判别阈值,再次选取80 000幅OK图片进行测试,最终获得92.27%的准确率,基本达到预期的效果。

#### 2.5 Chip元件复判检测框架整体性能测试

在AOI实际应用中对当前的检测流程整体性能进行了全面的测试。为适应AOI环境需要,本文所用测试数据均由明锐理想V5000系列AOI检测设备采集获得,测试代码用C++重新做了实现,推理部分采用英特尔公司研发的神经网络推理框架Opencvino,推理过程全部在CPU下完成。测试内容包括单幅推理时间,整体误判率,由各部分网络单独引起的误判数据量及误判率等。测试计算机CPU为Intel Core i5-7300HQ,内存8 GB。测试数据共30 000幅,其中包含丝印字符的数据15 000幅,包含颜色的数据15 000幅。测试结果整体误判率为11.2%,由本体颜色检测错误导致的误判共92幅,误判率0.6%;由焊点缺陷检测导致的误判共3 418幅,误判率10.91%;由于丝印识别错误导致的误判共768,误判率5.12%。平均每幅运行耗时97.5 ms,其中不包含丝印检测平均单幅耗时33 ms,包含丝印检测平均单幅耗时149 ms。

### 3 讨论

本研究结合业界的实际需求,针对Chip类元件的AOI检测提出了基于AI的复判检测框架,分别对每个检测任务设计了相应的模型。训练与测试结果表明,各个模型从耗时到准确率上均初步达到了复判的要求,实现了对Chip类元件大部分常见异常类型的判断。据本文所知,目前将AI运用到AOI检测上的研究多数只针对单独的焊接问题,尚未有成熟的端对端应用方案。本方案在整体应用上做了一些有益的尝试,说明AOI的AI复判检测方案是可行的。

目前,本课题研究基于AI的AOI复判检测仍处于较初步阶段。首先,检测项目只包含了常见问题的检测,而本体偏位、破损等问题仍不能判断,需要在后续工作中逐步更新;其次,本研究对网络模型进行了初步的选择和调整,多数网络模型仍具有很大的优化空间。下面将对当前流程中的各个环节进行详细的讨论。

1) 本体颜色检测:本体颜色检测网络本质上是对颜色的分类,再通过比对正确的颜色来判断是否发生了错件问题。从2.2节中给出的结果(图10)可知,当前网络模型未能达到100%的识别准确率,这也就意味着在长期的测试过程中,漏判的问题必然会发生,如何再次提升网络识别的准确率,或者增加其他限制条件来讲该类型的漏判降到最低,将是后续工作可研究的问题之一。



2) 字符检测:字符检测基于标准自然场景字符检测网络优化得到。由于自然场景下字符复杂度高,网络复杂度也随之提高,带来高耗时的问题,使其难以适应产线要求的低时延。在现有硬件条件下,需要继续研究更加轻量级的特征提取网络,在不降低准确率的情况下提升识别效率。

3) 焊接缺陷检测:对于焊接缺陷检测网络,由于其中涉及到的错误类型复杂,且可获取到的 NG 焊点数据很少,这需要网络能够舍弃对 NG 数据的学习,从大量 OK 数据中学习到正确焊接情况下焊点的特征。而从第 2 章中给出的结果(图 14)来看,当前网络模型在最佳的 AUC 值下,会有 12 幅 NG 数据产生漏判。对这 12 幅 NG 数据与训练集中的 OK 数据再次进行分析,提取中间层编码,并采用 Umap<sup>[19]</sup>进行降维,其中深色为 NG 特征,浅色为 OK 特征。如图 15 所示,这 12 幅 NG 数据的编码混叠在了训练的 OK 数据当中且 OK 特征分布在多个区域,这表明网络虽然擅长对训练中的 OK 数据进行重建,但网络并未获取到 OK 数据共通的特征,因此对部分 NG 数据不敏感。针对此问题可对网络结构修改,引入深浅层特征的融合,或增加损失函数的约束,将是本研究后续工作中的重点工作之一。

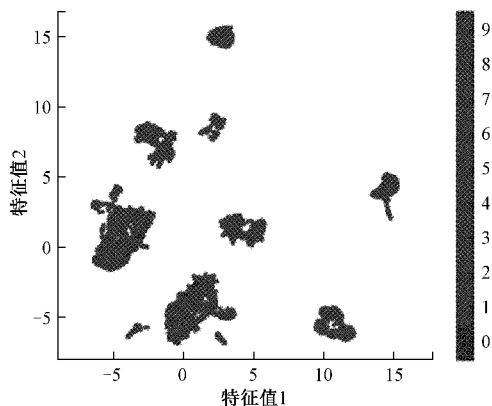


图 15 基于 Umap 特征压缩结果

4) 整体工作流程:AI 复判课题研究目的希望能够真正用到生产中,为此需要综合考虑该算法流程在工作时的内存占用率与耗时。在此给出当前各个模型的参数量大小与耗时,如表 4 所示。耗时内存占用率及耗时最高网络为字符检测网络,如之前分析,除了更换轻量级网络外,还可以考虑通过共享各个网络的特征提取层来降低算法耗时,同时也能相应的降低算法整体参数量。由于各个模型执行的任务不同,这将是一个相当有挑战性的工作。

基于 AI 的 Chip 类元件 AOI 复判检测虽然是 AOI 复判检测中的一个重要部分,但是除 Chip 类元件外,AOI 复判检测还涉及诸多其他类型的元件,如排插类元件、IC 类元件、插针类元件等,样例如图 16 所示。未来工作计划将在 Chip 类原件完善检测基础上,继续将检测范围扩大,使

表 4 各模型参数量与耗时

| 模块名称    | 参数量/MB | 平均耗时/ms |
|---------|--------|---------|
| 本体、焊盘检测 | 11.6   | 26      |
| 本体颜色检测  | 10.2   | 14      |
| 本体字符检测  | 130.88 | 149     |
| 焊接缺陷检测  | 2.7    | 6       |
| 总体      | 155.38 | 97.5    |

基于 AI 的 AOI 复判检测上形成完整的检测体系。预计工作计划如表 5 所示。




图 16 各元件样例图

表 5 进一步工作计划

| 元件类别     | 研究内容                    |
|----------|-------------------------|
| Chip 类元件 | 当前算法框架与模型的优化            |
| 排插类元件    | 缺件、短路、反向、针脚弯曲等异常的研究     |
| IC 类元件   | 缺件、短路、反向等异常的研究          |
| 插针类元件    | 缺针、短路、少锡、开焊、露铜、气孔等异常的研究 |

## 4 结 论

目前,在 PCBA 领域中,基于 AI 的 AOI 检测的研究均致力于单项检测问题,而未有整体的元件检测方案。本文结合业界的实际需求,应用 AI 技术对 Chip 类元件的 AOI 检测构建了完整的自动复判流程,在整体应用上做了有益的尝试。该方案从 Chip 类元件的实际检测需求出发,将多种功能不同的网络模型进行了有效地组合,实现了对 Chip 元件缺件、错件、缺焊、开焊等常见异常类型的有效检测。目前该解决方案已在生产线上进行全面的测试,初步测试结果表明,该解决方案能够有效降低产线上的元件误报率,降低人工成本,具有较好的应用前景。

## 参考文献

- [1] 秦立娟. AOI 系统在 PCB 中的应用及误报分析[J]. 科学与财富, 2018(16):207-209.
- [2] 陈星. 基于卷积神经网络算法的飞机发电机故障诊断研究[J]. 国外电子测量技术, 2020, 39(11):57-60.
- [3] 王永利, 曹江涛, 姬晓飞. 基于卷积神经网络的 PCB 缺陷检测与识别算法[J]. 电子测量与仪器学报, 2019, 33(8):78-84.
- [4] CAI N, CEN G, WU J, et al. SMT solder joint inspection via a novel cascaded convolutional neural

- network [J]. IEEE Transactions on Components, Packaging, and Manufacturing Technology, 2018;1-8.
- [5] 韩航迪,徐亦睿,孙博,等.基于改进 Tiny-YOLOv3 网络的航天电子焊点缺陷主动红外检测研究[J].仪器仪表学报,2020,41(11):42-49.
- [6] 殷政.基于深度学习的IC引脚焊接缺陷自动检测技术研究[D].江门:五邑大学,2019.
- [7] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multiBox detector [J]. Springer, Cham, 2016;21-37.
- [8] 周晓彦,王珂,李凌燕.基于深度学习的目标检测算法综述[J].电子测量技术,2017,40(11):89-93.
- [9] 陈为,梁晨红.基于SSD算法的航空发动机内部凸台缺陷检测[J].电子测量技术,2020,43(9):29-34.
- [10] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks [J]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018; 4510-4520.
- [11] LIN T Y, ROYCHOWDHURY A, MAJI S. Bilinear CNN models for fine-grained visual recognition [J]. Proceedings of IEEE International Conference on Computer Vision, 2015;1449-1457.
- [12] BAEK Y, LEE B, HAN D, et al. Character region awareness for text detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019; 9365-9374.
- [13] SHI B, BAI X, YAO C. An end-to-end trainable neural network for image-based sequence recognition and its application to scene text recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(11): 2298-2304.
- [14] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [J]. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015;234-241.
- [15] KADARI R, ZHANG Y, ZHANG W, et al. CCG supertagging via bidirectional LSTM-CRF neural architecture [J]. Neurocomputing, 2017, 283: 31-37.
- [16] 戴俊,王俊,朱忠奎,等.基于生成对抗网络和自动编码器的机械系统异常检测 [J]. 仪器仪表学报, 2019, 40(9):16-26.
- [17] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. Ganomaly: Semi-supervised anomaly detection via adversarial training [C]. Asian Conference on Computer Vision, Springer, Cham, 2018; 622-637.
- [18] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [19] MCINNES L, HEALY J. UMAP: Uniform manifold approximation and projection for dimension reduction [J]. The Journal of Open Source Software, 2018, 3(29):861.

#### 作者简介

王瑞丰,工学硕士,主要研究方向为计算机视觉、人工智能、自动光学检测等。

E-mail:w1318201312@outlook.com

魏嘉莉,工学硕士,主要研究方向为计算机视觉、人工智能、字符检测等。

E-mail:carrieweiseu@163.com

周静,工学硕士,主要研究方向为计算机视觉、人工智能、目标检测。

E-mail:1021937079@qq.com

冀运景,深圳明锐理想科技董事长,从事自动光学检测相关工作。

E-mail:leon.ji@magic-ray.com

罗守华(通信作者),教授,博士生导师,主要研究方向为医学图像处理、CT图像重建、模式识别。

E-mail:luoshouhua@seu.edu.cn