

文章编号 1004-924X(2011)09-2154-09

印刷电路板焊点的智能检测

谢宏威, 张宪民*, 邝泳聪, 欧阳高飞

(华南理工大学机械与汽车工程学院, 广东广州 510640)

摘要: 为了提高在线自动光学检测系统(AOI)的自动化程度, 提出了一种基于增量聚类的智能焊点检测方法。首先, 设计了在线智能 AOI 的系统框架。然后, 根据焊点外观进行归纳分类, 将关键子区域的面积特征应用于焊盘特征的量化与提取, 将每类样本聚类为若干子类从而实现多批次焊点的检测。最后, 提出一种增量聚类算法, 在线检测过程中系统可根据人工维修站反馈信息自动学习新的样本并调整相关检测参数。为了提高增量学习的效率, 每次增量学习之前选择少量代表样本用于增量学习。采用提出的 AOI 系统检测焊点, 准确率可达 96.5%, 平均每个焊点耗费 9.3 ms。结果表明, 本文提出的检测方法不仅可以对多批次的焊点缺陷进行有效识别, 且对生产中工艺条件的变化有自适应能力, 智能化程度较高, 具有较强的实用价值。

关键词: 自动光学检测; 增量聚类; 分类器; 印刷电路板; 焊点检测

中图分类号: TP274.5; TP391.4 **文献标识码:** A **doi:** 10.3788/OPE.20111909.2154

Intelligent detection of solder joints on printed circuit boards

XIE Hong-wei, ZHANG Xian-min*, KUANG Yong-cong, OUYANG Gao-fei

(School of Mechanical and Automotive Engineering,
South China University of Technology, Guangzhou 510640, China)

* Corresponding author, E-mail: zhangxm@scut.edu.cn

Abstract: To automate present Automatic Optical Inspection (AOI) systems, an intelligent method based on incremental clustering for solder joint inspection is proposed in this paper. Firstly, to meet the demands of practical production, the framework for an intelligent AOI system is designed. Then, all the defects of solder joints are classified into several different types according to their appearances, and the color features in critical regions are extracted. The samples in each class are clustered into several subclasses so that the system is able to inspect solders from different batches. Finally, a new incremental clustering algorithm is proposed. The AOI system can automatically adjust inspection parameters according to the feedback from the repair station. To improve training efficiency, only a few samples are selected. The method proposed is used in an AOI to inspect solder joints, and the inspecting accuracy can reach 96.5% while each solder inspection takes 9.3 ms. The experimental result demonstrates that the proposed method can detect accurately a solder defect from different patches, and can be modified for different manufacturing processes. The intelligence level of the system using

收稿日期: 2011-01-10; 修订日期: 2011-02-27.

基金项目: 国家杰出青年科学基金资助项目(No. 50825504); 广东省科技攻关重点项目(No. 2008A010300002); 中央高校基本科研业务费专项资金资助项目(No. 2009ZM00731, No. 2009ZM0132)

the proposed method is high, and it can be used in practical application.

Key words: automatic optical inspection; incremental clustering; classifier; printed circuit board; solder joint inspection

1 引言

电子元件微小化、细密化的发展趋势,使得人工目检越来越难以满足实际生产的需要。自动光学检测(Automatic Optical Inspection, AOI)系统能有效提高印刷电路板(Printed Circuit Board, PCB)焊点检测的速度和准确率,并及时反馈信息,逐渐成为表面贴装技术(Surface Mounted Technology, SMT)生产中主要的焊点检测手段^[1-2]。

现有的焊点检测算法主要分为图像分析法^[3-5]、图像对比法^[6-7]和基于神经网络的方法^[8-10]。图像分析算法使用灵活,可以使用先验知识指导编程,因而误报率较低,但智能化程度不高,有较多的参数需要编程人员来设定,因而对操作者要求较高。图像对比算法操作方便、检测速度快,但要求训练样本有足够的代表性,且焊点定位必须非常精确,否则误检率会很高。近年来,神经网络方法越来越多地应用于焊点检测,但在实际工业生产中这种方法的效果并不稳定,一个重要原因是较多的参数需要人工设置。

以上3种算法已经应用于AOI系统,并在实际生产中发挥了作用,但智能化程度仍然有待提高,主要存在以下问题:(1)同类焊点由于生产用料或者工艺条件不同,因而外观不同,这样的焊点称为不同批次焊点。现有算法使用单一的一组检测参数,因而在检测不同批次焊点时误报率较高。(2)当生产过程中的工艺条件发生变化时,原有的检测参数将不适用于新的焊点检测。当前的解决方法是先暂停在线检测,并收集新样本重新训练,然后将新的检测参数重新用于在线检测。这种解决方法无法及时对检测参数做出相应调整,因此会降低生产效率。

为了提高AOI的智能化程度,本文提出一种

基于增量聚类的焊点检测方法。将每类样本聚类为若干子类,从而实现了对多批次焊点的检测。当系统误报率升高时,可根据反馈自动学习误报样本调整相关检测参数,增强了AOI系统对生产工艺变化的适应能力。文章分别阐述了印刷电路板炉后焊点的主要缺陷类型,基于缺陷判别特征的提取,基于聚类的焊点分类器的建立,以及分类器的增量学习方法,最终给出了实验结果。

2 系统框架

在实际智能化AOI系统开发中结合企业要求提出了:(1)系统必须能识别不同批次的焊点;(2)当生产环境发生变化时,在线检测系统能及时自动调整相关检测参数,以保证较高的正确率;(3)检测速度必须达到在线检测的要求;(4)自动调整检测参数的速度必须足够快从而不会对在线检测产生影响;(5)操作必须方便,避免过多的参数设置。

本文建立了一种基于增量聚类的焊点检测系统。在线检测时系统可根据反馈信息自动调整检测参数。图1所示为系统的框架图,在线检测流程分为以下几个部分:

(1)在线检测前,对一定数目已知缺陷类型的焊点图像进行训练,得到初始的焊点分类器;

(2)将分类器用于在线检测下一批次的焊点,真实的缺陷类型由工人在维修站确认,收集误检焊点的图像,并计算AOI检测该批次焊点的误报率;

(3)如果误报率保持在正常水平,返回至步骤(2);否则,转到步骤(4);

(4)误报率异常表明有新批次的焊点,将该批次误检的焊点图像用于增量聚类,并更新分类器,然后返回至步骤(2)。

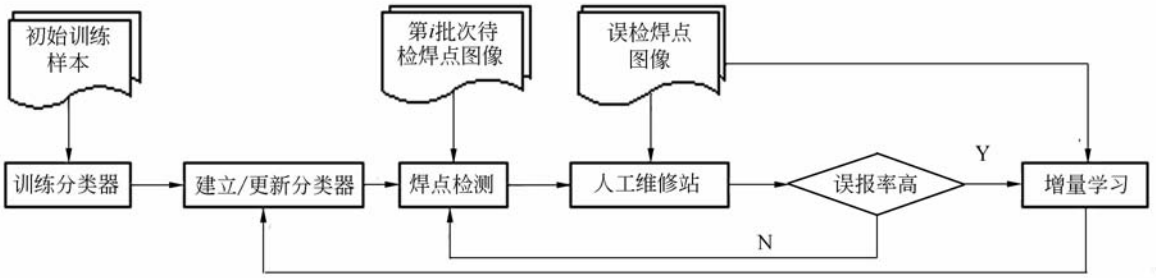


图 1 系统框架图

Fig. 1 Framework of the system

3 焊点初始分类器

3.1 焊点分类与特征提取

本文中, AOI 系统采用 RGB 三色环形光和彩色相机获取焊点图像。光源位置和角度经过优化设计, 在获取的焊点图像中, 红色、绿色和蓝色分别与焊锡表面的平坦、斜坡和陡坡部分相对应, 从而反映了焊点的三维信息^[3,11]。SMT 炉后焊点的缺陷类型主要分为多锡、少锡、虚焊和立碑等, 如图 2 所示, 从左至右分别为不同类型焊点的实际图像、侧面视图和模型图。将彩色焊点图像分解为红、绿、蓝 3 种单色图像, 并对各单色图像




图 3 焊点的子区域划分

Fig. 3 Sub-regions of solder joint


进行阈值分割提取焊点的特征。将焊点分为电极 (D_1)、焊锡中央 (D_2)、焊锡前端 (D_3) 和贴装 (D_4) 4 个区域^[3], 如图 3 所示。在每个区域分别计算红、绿、蓝的面积用来表征焊点特征的分布情况。令 $p(i, j)$ 为某单色图像坐标 (i, j) 处的像素, S_D 为区域 D 的面积, 则 D 内相应某单色图像的面积百分比 f_k 可表示为

$$f_k = \sum_{i,j \in D} p(i, j) / S_D \quad (1)$$

焊点特征向量可以表示为 $\mathbf{F} = [f_1, f_2, \dots, f_{12}]$, 其中, $f_1-f_3, f_4-f_6, f_7-f_9, f_{10}-f_{12}$ 分别对应区域 D_1, D_2, D_3 和 D_4 的红、绿、蓝颜色特征, 对焊点分类即为对特征空间中的焊点特征点进行

3.2 特征分析

随机选取来自不同批次的焊点样本, 其中正常样本 351 个, 缺陷样本 215 个。为了在二维图中显示样本分布, 每个区域仅选择两种颜色特征, 将焊点分为正常和有缺陷两类, 如图 4 所示。观察图 4 可知, 这两类样本在特征空间有明显的分界线, 容易区分正常与有缺陷焊点。因此, 可有效




(a) 正常 (b) 多锡 (c) 少锡 (d) 虚焊 (e) 立碑
(a) Normal (b) Surplus solder (c) Lacking solder
(d) Pseudo joints (e) Tombstone

图 2 各种类型焊点对比图


Fig. 2 Images of solder joints from different types

利用焊点不同区域的颜色特征建立分类器对焊点进行分类。




(a) 电极区域颜色特征分布

(a) Distribution of color features in polarity region




(b) 焊锡中央区域颜色特征分布

(b) Distribution of color features in middle solder region



(c) 焊锡前端区域颜色特征分布

(c) Distribution of color features in tip solder region



(d) 贴装区域颜色特征分布

(d) Distribution of color features in mounting region

图 4 不同区域特征分布图

Fig. 4 Distribution of characters in different regions

3.3 基于马氏距离的焊点分类器

最小距离分类器^[12]计算速度快,适用于实时性要求较高的分类任务,本文使用最小距离分类器对焊点进行分类。最小距离分类器的基本思想如下:已知有 k 个类别的样本集合 $\{U_1, U_2, \dots, U_k\}$,根据算术平均依次计算得到每个类的中心点向量 $\mu_1, \mu_2, \dots, \mu_k$ 。定义样本 x 与类的距离为 x 与类中心点向量的距离,在分类时判定 x 属于与之距离最近的类。

如何计算向量间的距离成为一个关键问题,欧氏距离是最常用的方法,但欧氏距离将向量中每个指标的差别同等看待,但实际上并非如此。马氏距离比欧氏距离表示了更多的信息,样本 x 和类别 Ψ 的马氏距离定义为^[13]

$$d_M(x, \Psi) = \sqrt{(x - \mu)^T E^{-1} (x - \mu)}, \quad (2)$$

其中, μ 为 Ψ 的中心点, n 为 Ψ 中的样本数, E 为 Ψ 中所有样本的协方差矩阵

$$E = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)(x_i - \mu)^T. \quad (3)$$

E 为非满秩时,逆矩阵 E^{-1} 不存在,可用 E 的伪逆 E^+ 来代替。使用基于马氏距离的分类器对样本进行分类,当样本满足多元正态分布时,同类别样本呈超椭球面分布,类别中心点和形状分别由样本均值和协方差矩阵决定。

3.4 同类焊点聚类方法

定义 1 对于 C_1 和 C_2 两个类,如果存在 $x \in C_1$,且 $d_M(x, C_1) > d_M(x, C_2)$,或者 $x \in C_2$,且 $d_M(x, C_2) > d_M(x, C_1)$,则称 C_1 和 C_2 存在样本重叠。

在图 4 中,同类样本并不一定围绕一个中心点分布,因此仅使用一个类中心无法完整描述这种类的结构。以图 4(a)为例,对每类样本进行 k -均值聚类^[14],将正常样本分割为子类 A_1 和 A_2 ,缺陷样本分割为子类 B_1 和 B_2 ,如图 5(a)所示。观察图 5(a)可知,绝大多数不同类的样本被分

并将这些聚类后的子集加入到 C 中;

(4)重新标记 C 中的子集为 C_1, C_2, \dots, C_n ,然后返回至步骤(2)。

如图 5(b)所示为根据上述步骤对图 5(a)的聚类进一步细分的结果, A_2 被细分为 A_2 和 A_3 两个子集, B_2 被细分为 B_2 和 B_3 两个子集。分割完成后,任意两个不同类的子集之间不再有重叠样本。在对子类进行细分的过程中,如果不同类别之间的界限较模糊,则需要细分为较多的子集。考虑极端的情况,最终子集可能只有一个样本,这会导致分类器的过拟合。为了避免这种情况,在细分时可将子集的最少样本个数作为约束条件,对于仍会导致子类重叠的样本在后文的增量学习中再做考虑。

4 焊点的增量学习

4.1 增量学习方法

增量学习可以使分类器增加新的知识,但如果每次增量学习时将所有新旧焊点样本放在一起,在多次增量学习之后样本数量不断增加,学习效率会很很低。本文在每次增量学习之前,在旧样本中只选择有代表性的样本与新样本放在一起进行增量学习从而在保证分类精度的同时,提高增量学习的效率。

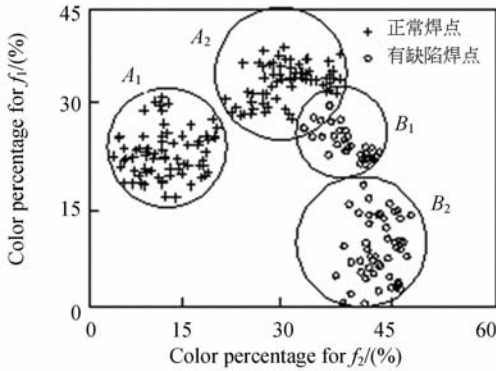
新样本可能属于已有类,也可能属于已有类之外的其它类。如果属于已有类,则将其直接加入到已知类的集合即可;如果不属于已有类,则需要创建新的类,同时还要消除新建类与已有类之间的样本重叠。设分类器中所有子集组成集合 G ,对新样本进行增量学习的步骤如下:

(1)用已有分类器对新样本依次进行分类,如果属于已有类,则将该样本加入对应的子集中;否则,将该样本加入到集合 N ;

(2)对 G 中的每个子集,按照 4.2 节的方法筛选有代表性的样本,并重新计算中心点和协方差矩阵,并更新集合 G ;

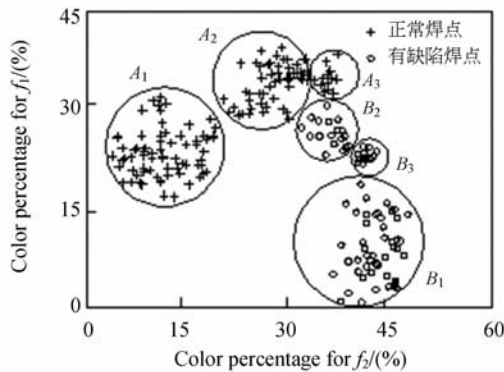
(3)如果 N 为空,则算法结束;如果 N 不为空,对 N 中每个同类的样本集合分别使用 k -均值方法进行聚类得到若干子集,将这些子集加入到 G 中,并清空 N ;

(4)如果 G 中不同类的子集间有样本重叠,则按 3.4 节的方法对有样本重叠的子集进行细



(a)初步聚类结果

(a)Initial cluster result



(b)最终聚类结果

(b)Final cluster result

图 5 样本聚类结果

Fig. 5 Cluster results of samples

开,但子类 A_2 和 B_1 之间存在样本重叠,因此必须对分类器进行改进。本文将有样本重叠的子类进一步细分为更小的子类,直到不同类的子类之间不再有样本重叠为止。对两个存在样本重叠的子类 C_1 和 C_2 进一步细分的步骤如下:

(1)定义集合 Π 和 C ,初始化 Π 为空,将当前所有子类加入 C ;

(2)如果 $C_i \in C, C_j \in C$,且 C_i 和 C_j 有样本重叠,则将 C_i 和 C_j 都从 C 中移除,并加入到 Π 中;

(3)如果 Π 为空,则分类完成;否则,设定聚类个数为 2,对 Π 中的每个集合进行 k -均值聚类,

分,并重新计算相应子集的中心点和协方差矩阵;

(5)使用新的分类器对新样本重新分类,将分类错误的样本加入到集合 N 。

在增量学习的过程中,由于同时使用了代表样本和新样本对分类器进行训练,因而分类器在保留原有样本的知识的的同时,增加了对新样本的识别能力。完成学习后,再使用新的分类器对新样本进行分类,分类错误的样本形成集合 N ,在下次增量学习时与新样本一起学习。

4.2 代表样本的选取

本文对新样本学习之前,选择一些代表样本来保持原来的知识。代表样本在特征空间的分布与原来样本的分布基本一致,才能真实反映原有知识。学习样本在特征空间中的分布是不均匀的,选择代表样本时,先将样本聚类为密度相对均匀的若干个子集,然后分别在每个子集内部对样本进行筛选,这样筛选出的样本与原始样本集的分布基本一致,只是密度降低。

定义2 样本 x 的密度定义为 x 与同类别的 k 近邻样本的距离之和的倒数:

$$\rho_s(x) = \frac{1}{\sum_{i=1}^k d_E(x, x_i)}, \quad (4)$$

式中, x_i 为 x 的 k 近邻样本之一。

定义3 假设 x_i 和 x_j 互为 k 近邻样本,如果 $\rho_s(x_i)/\rho_s(x_j)$ 的值在 $[\eta_{\min}, \eta_{\max}]$ 内,其中 $0 < \eta_{\min} \leq 1, \eta_{\max} \geq 1$,则 x_i 和 x_j 属于同一个子类。即密度相差不大的 k 近邻样本构成一个子类。

定义4 子集 C 的密度定义为

$$\rho_c(C) = \frac{1}{n} \sum_{i=1}^n \rho_s(x), \quad (5)$$

其中, x_k 为子类 C 中第 k 个样本。

设 X 为某类样本的一个子集, x_0 为 X 的第一个样本,则对 X 根据密度进行聚类的步骤如下:

输入:子类 X , 密度阈值 η_{\min} 和 η_{\max}

(1)初始化样本 $x = x_0, i = 0$, 新建子类 $C_i = \Phi$;

(2)计算 x 的密度 $\rho_s(x)$, 然后搜索 x 的 k 近邻样本并计算各样本的密度,将这些样本中密度在 $[\eta_{\min}\rho_c(C_i), \eta_{\max}\rho_c(C_i)]$ 内的样本加入 C_i 中,并计算 C_i 的密度 $\rho_c(C_i)$;


(3)依次搜索 C_i 中的每个样本的 k 近邻样

本,如果该样本未分配到任何一个聚类,且密度在 $[\eta_{\min}\rho_c(C_i), \eta_{\max}\rho_c(C_i)]$ 范围内,则将该样本添加到 C_i 中。重复本步直到没有符合条件的样本为止,将 C_i 添加到集合 Out 中;

(4)在 X 中搜索没有分配到任何聚类的样本 x_1 , 如果符合条件的 x_1 不存在,则算法结束;如果 x_1 存在,则 $x = x_1, i = i + 1$, 并新建一个子类 C_i 并初始化为 Φ , 然后返回步骤(2)。


输出:集合 Out

完成基于密度的聚类后,对于每个子类代表样本选择方法如下:首先,计算聚类中心点;然后,将子类中的样本按其与中心点的马氏距离升序排列;最后,在排序好的样本中按照相同的间隔均匀取一些样本出来作为代表样本,例如,要保留 $1/4$ 的样本,可每隔 3 个样本取一个作为代表样本。最终 X 的代表样本由所有子类的代表样本组合而成,图 6 所示为代表样本选择过程的示意图。




(a) 原始样本

(a) Original samples



(b) 基于密度的聚类

(b) Cluster result based on density



(c) 代表样本

(c) Representative samples

图 6 代表样本的选择过程

Fig. 6 Selection of representative samples

5 实验结果与分析

为了验证本文算法的有效性,本文将其应用于 AOI 系统中进行了实验。实验平台为本课题组与某公司联合研发的在线 AOI 系统,PC 配置为 CPU Intel Pentium 2.8 GHz,内存 2G,算法用 VC.NET2005 实现。

5.1 焊点检测性能

选取实际生产 PCB 板上的焊点为实验对象,实验样本分为 4 个部分,样本类别和数目如表 1 所示。其中类别 I、II 与 III、IV 的样本分别为在两种不同生产条件下获得的焊点样本图像,如图 7 所示。

表 1 焊点样本

Tab. 1 Solder joint samples

样本类别	焊点类型	样本数目
I	合格	12 001
	不合格	10 017
II	合格	10 800
	不合格	12 358
III	合格	1 040
	不合格	1 173
IV	合格	10 406
	不合格	11 745

使用类别 I 的样本训练得到焊点的初始分类器,对批次 II 的样本对初始分类器进行测试。然




图 7 不同批次的焊点

Fig. 7 Solder joints from different patches

后使用 4.2 的方法,设定 $\eta_{\min}=0.7$, $\eta_{\max}=1.5$,在各子集中选择代表样本,代表样本数目只占原有样本数目的 1/8 左右,结果如表 2 所示。

表 2 代表样本筛选

Tab. 2 Represent sample selection

焊点类型	样本数目	子集数目	筛选的样本数
正常	12 001	5	1 532
不合格	10 017	11	1 103

AOI 系统的性能可通过以下几个指标来评价:(1)正确率:给出正确检测结果的焊点的比率;(2)误判率:将合格焊点判定为缺陷焊点的比率;(3)错判率:将一种缺陷判定为另一种缺陷的焊点的比率;(4)漏报率:将缺陷判定为合格的焊点所占的比率;(5)平均检测时间:检测每个焊点平均耗费的时间。将本文方法与其它几种焊点检测方法进行了对比,焊点检测准确率与平均时间结果统计如表 3 所示。

表 3 4 种算法性能比较

Tab. 3 Performance comparison of four methods

算法	正确率/%	误判率/%	错判率/%	漏判率/%	平均时间/ms
图像对比法 ^[6]	91.7	3.6	4.7	0	3.7
特征分析法 ^[3]	95.1	1.7	3.2	0.1	7.5
神经网络方法 ^[9]	94.6	1.4	4.0	0.1	6.1
本文方法	96.5	0.9	2.6	0	5.9

由表 3 可知,在检测速度方面,图像对比法最快,但检测正确率最低,仅为 91.7%。本文方法的检测准确率最高,为 96.5%,每个焊点平均检测时间为 5.9 ms,可以达到生产线实时检测的要求。

5.2 增量学习性能

关于增量学习性能的实验分为两部分:第一部分,将全部新旧样本放在一起进行增量学习;第二部分,将筛选出的代表样本和新样本放在一起进行增量学习。假设数据已全部读入内存,表4给出了用这两种方法进行增量学习的效率对比结果。

表4 增量学习的速度

Tab.4 Efficiency of incremental learning algorithm

原有样本数目	筛选后代表样本数目	新样本数目	不经筛选训练时间/s	经过筛选训练时间/s
222 081	2 635	1 277	161.9	5.7

由表4可知,对所有新旧样本直接进行增量学习、以及先筛选样本再进行增量学习的时间分别为161.9 s和5.7 s,使用代表样本进行增量学习时间耗费大幅降低。假设每块PCB板有1 000个焊点,则检测每块板耗费5.9 s。设定每检测10块PCB板,维修站计算一次检测正确率,当系统检测正确率降为90%时,自动对误检焊点图像进行增量学习,此时维修站收集的误检样本大约为 $1\ 000 \times 10\% \times 10 = 1\ 000$ 个,少于上面实验中的1 277个。如果在筛选代表样本时确保代表样本数不高于实验中的2 635个,则对误检样本的增量学习时间少于5.7 s,还不到一块PCB板的检测时间,完全可以实现在线检测的同时对错检样本进行在线增量学习。一般来说,如果生产工艺不是频繁变化,则每个类的子集数量不会太多,那么代表样本的数目也不会太多,因而本文方法基本可以达到在线学习和在线检测的速度要求。

分别使用初始分类器,增量学习过的分类器,以及用批次I的样本调试出的基于其它方法的检

测参数检测4个批次的焊点样本,检测准确率统计结果如表5所示。

表5 增量学习性能

Tab.5 Performance of incremental learning (%)

算法	样本类型			
	I	II	III	IV
初始分类器	97.4	96.5	81.3	84.5
增量学习分类器	96.9	96.1	97.1	96.8
图像对比法 ^[6]	98.8	91.7	72.3	69.1
特征分析法 ^[3]	96.9	95.1	81.7	85.2
神经网络方法 ^[9]	95.6	94.6	84.5	83.1

由表5可知,其它几种算法因为未融入新批次样本的知识,因而对新样本的检测准确率明显降低。只有增量学习过的分类器对旧样本和新样本的检测准确率都很高。本文算法在增量学习之后,对旧样本的检测准确率有所降低,这是由于增量学习过程中经历了样本筛选,因而包含旧样本的知识有所损失,但仍然维持在较高的水平。

6 结 论

本文提出了一种智能焊点检测方法,该方法使用聚类技术对焊点建模,可检测多批次的焊点缺陷。通过使用增量聚类方法,实现了检测参数对生产工艺变化的自动调整。实验证明,本方法在工艺条件变化的情况下可有效识别多锡、少锡、虚焊和立碑等焊点缺陷,准确率达96.5%,焊点平均检测时间为5.9 ms。本文方法可实现AOI系统的在线学习和在线检测,有较强的实用价值。目前该系统已经成功应用于生产线,提高了生产效率。如何减少训练过程中子类过多的情况,以及如何进一步提高训练速度,是下一步需要深入研究的问题。

参考文献:

[1] KUANG J H, HSU CH M, CHIU W CH, *et al.*. The variation of shear strength of the lead free Sn/3.0Ag/0.5Cu solder balls[C]. *IEEE Proceedings of the ninth Electronics Packaging Technology Conference, Singapore*, 2007:910-913.

[2] KOMKRIT C, SOTOSHI Y, MASAYOSHI I.


Bare PCB inspection system with Sv-GMR sensor eddy-current testing probe[J]. *IEEE Sensors Journal*, 2007,7(5):890-896.

[3] 吴福培, 卞泳聪, 张宪民, 等. 基于模式匹配及其参数自适应的PCB焊点检测[J]. *光学精密工程*, 2009,17(10):2586-2593.

WU F P, KUANG Y C, ZHANG X M, *et al.*. Pattern matching and based PCB solder parameter adaptive joint inspection[J]. *Opt. Precision Eng.*,

- 2009,17(10):2586-2593. (in Chinese)
- [4] CHIU S N, PERN M H. Reflection-area-based feature descriptor for solder joint inspection [J]. *Machine Vision and Applications*. 2007,8:95-106.
- [5] LOH H H, LU M S. Printed circuit board inspection using image analysis[J]. *IEEE Transactions on Industry Applications*, 1999, 5(2):426-432.
- [6] XIE H W, KUANG Y C, ZHANG X M. A High Speed AOI Algorithm for Chip Component Based on Image Difference[C]. *IEEE International Conference of Information & Automation, Zhuhai, China*, 2009(4):969-974.
- [7] IBRAHIM Z, AL-ATTAS S A R, ASPAR Z. Analysis of the wavelet-based image difference algorithm for PCB inspection[C]. *Proceedings of the 41st SICE Annual Conference, Osaka, 2002*:1525 - 1530.
- [8] KUK W K, HYUNG S C. Solder Joints Inspection Using a Neural Network and Fuzzy Rule-Based Classification Method [J]. *IEEE Transactions on Electronics Packaging Manufacturing*, 2000, 39(2):93-103.
- [9] 卢盛林,张宪民,邝泳聪.基于神经网络的PCB焊点检测方法[J]. *华南理工大学学报(自然科学版)*, 2008,36(5):135-139.
LU SH L, ZHANG X M, KUANG Y C. Neural Network Based Inspecting Method of PCB Solder Joint [J]. *Journal of South China University of Technology (Natural Science Edition)*, 2008, 36(5):135-139. (in Chinese)
- [10] 黄杰贤,李迪,叶峰,等.挠性印制电路板焊盘表面缺陷的检测[J]. *光学精密工程*, 2010,18(11):2443-2453.
HUNAG J X, LI D, YE F, *et al.*. Detection of surface deflection of solder on flexible printed circuit [J]. *Opt. Precision Eng.*, 2010, 18(11):2443-2453. (in Chinese)
- [11] 卢盛林,张宪民.无铅焊点检测光源的分析与优化设计[J]. *光学精密工程*, 2008,16(8):1377-1383.
LU SH L, ZHANG X M. Analysis and optimal design of illuminator for leadless tin solder joint inspection [J]. *Opt. Precision Eng.*, 2008,16(8):1377-1383. (in Chinese)
- [12] DUDANI, SAHIBSINGH A. The distance-weighted k-nearest-neighbor rule [J]. *IEEE Transactions on Systems, Man and Cybernetics*, 1976(6):325-327.
- [13] WANG D F, YEUNG D S, and TSANG E C. Weighted mahalanobis distance kernels for support vector machines[J]. *IEEE Transactions on Neural Networks*. 2007 18(5):1453-1462.
- [14] TOU J T, GONZALEZ R C. *Pattern Recognition Principle*[M]. Boston:Addison Wesley, 1974.

作者简介:



谢宏威(1981—),男,湖北孝感人,博士研究生,2003年、2006年于北京航空航天大学分别获得学士和硕士学位,主要研究方向为视觉检测,模式识别。E-mail:xhw_cn@foxmail.com



邝泳聪(1970—)广东台山人,男,副教授,2003年于华南理工大学获得博士学位,主要研究方向为机器视觉,精密制造。E-mail:kuangyongcong@21cn.com



张宪民(1964—),男,河北涿州人,教授,博士生导师,1993年于北京航空航天大学获得博士学位,主要研究方向为精密制造装备与现代控制技术。E-mail:zhangxm@scut.edu.cn



欧阳高飞(1978—),男,湖南永州人,副研究员,2007年于华南理工大学获得博士学位,主要从事自动光学检测与模式识别方面的研究工作。E-mail:scut_gaofei@yahoo.com.cn