

触点零件形貌在线自学习视觉检测系统研究

摘要

触点零件是工业中重要的电器元件，完成关键的切换功能，是决定电器使用寿命的主要因素，触点零件的表面形貌对零件的接触性能起着相当重要的作用。目前国内检测手段落后，采用计算机视觉检测的方法代替人工具有很大的实际应用价值。针对触点零件形貌多样的特点，本文研究开发能够实现自适应学习功能的在线视觉检测系统。

论文通过对检测需求的分析，设计了系统的整体结构和自学习检测流程，详细讨论了系统各个组成部分的功能及选型，并设计了软件系统的功能模块及工作流程。

根据检测系统实时性和准确性的要求，本文在图像处理阶段研究了基于高斯滤波模板的快速有效图像预处理方法，针对触点零件图像特点提出了一种基于改进极小值点的自适应阈值分割算法和多图中值阈值确定算法，并构建了5大类图像特征库，共包含45个特征。

通过对多类别模式识别主要因素的分析研究，提出了特征预处理方法和基于典型变量的特征优化算法，设计了一种两类浮动搜索-多类后向选择算法实现多类别特征选择，并结合支持向量机多级二叉树的多类别分类策略，共同实现了多类别触点零件快速学习和分类检测。

在上述工作基础上，论文搭建了试验硬件平台，开发了实现上述算法的相关软件，对多组零件进行了试验，取得了较好的试验结果。论文也分析了误差来源，提出进一步研究改进的方向。

关键词：触点形貌，计算机视觉，在线检测，图像处理，多类模式识别

RESEARCH ON ONLINE SELF-LEARNING VISION DETECTION SYSTEM OF CONTACT APPEARANCE

ABSTRACT

As an important industrial electrical component, contact component decides electric equipments' life. The surface appearance features of contact component play an important role in contact performance. The detection methods depending on manual stay low level, using computer vision technique to replace human vision in quality detection has great practical value. Aimed to different varieties of contact appearance features, the online vision detection system achieving self-learning function is researched in this thesis.

Firstly, the structure and self-learning process of detection system are designed through the detection requirements analysis. The function parts and their selection methods are discussed in detail. The function modules and workflow of software system are designed.

In image processing, according to real-time and accuracy requirements, the Gaussian filter template is studied as a quick and efficient image pre-processing method. An adaptive threshold segmentation method based on improved minimum point algorithm and multi-graph median algorithm is proposed. And the 5 major categories of image feature library is built, which includes 45 features.

Through the analysis of major factors that influence the multi-category pattern recognition, the feature pre-processing method and optimization method based on canonical variables are put forward. To realize multi-category feature selection, a two-category floating search and multi-category backward selection algorithm is designed. Combined these algorithms with SVM multi-level binary tree classification strategy, the system realizes the multi-category quick self-learning and classification detection.

Based on the work mentioned above, the experimental platform is developed. The experimental system is tested through several groups of contact components and gets good results. The future research direction is proposed after the error analysis.

KEY WORDS: contact component appearance, computer vision, online detection, image processing, multi-category pattern recognition

上海交通大学

学位论文原创性声明

本人郑重声明：所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已经注明引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品成果。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本人完全意识到本声明的法律结果由本人承担。

学位论文作者签名：戴舒文

日期：2009 年 01 月 15 日

上海交通大学

学位论文版权使用授权书

本学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅和借阅。本人授权上海交通大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密口，在____年解密后适用本授权书。
本学位论文属于
 不保密口。

(请在以上方框内打“√”)

学位论文作者签名: 戴舒文 指导教师签名: 吉小军

日期: 2009 年 01 月 15 日 日期: 2009 年 01 月 15 日

第一章 绪论

1.1 触点零件形貌检测系统的研究背景

1.1.1 触点零件及其形貌特征的重要性

触点零件是一种重要的电器元件。在电能得以不断利用的同时，电接触问题也日益得到重视。电接触是指两个导体之间相互接触，并通过接触界面实现电流传递或信号传输的一种物理、化学现象。传递电流或输送信号的两导体称为触点或触头。电触点是开关电器的核心元件，完成关键的切换功能，是决定开关电器如各类空气开关、继电器、交流接触器等通断转换能力、使用寿命和可靠性的关键因素，广泛应用于各类低压电器行业，涉及现代社会中的民用、工业、军事、航天、航空、信息等各个领域。图1-1所示为一些触点零件的实物照片。

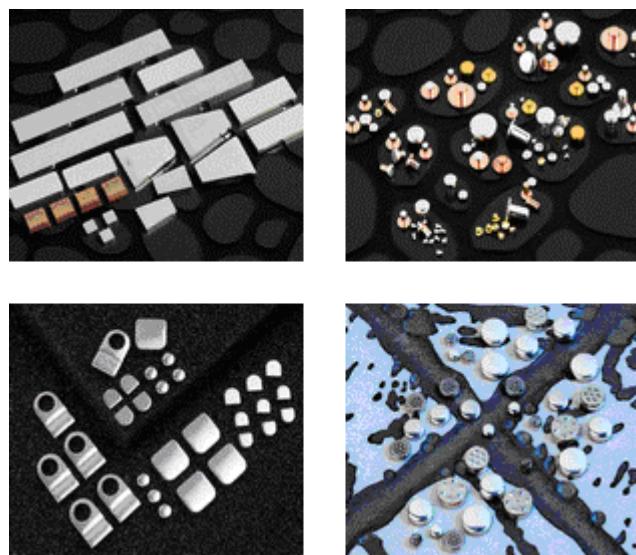


图1-1 触点零件

Fig.1-1 Contact components

据统计，世界继电器的年产量近70亿只，单单我国就达到30亿只，更不用说渗透国民经济和生活各个方面的开关、插座等其它连接件。触点零件的性能是有触点电器产品性能的一个重要方面，特别是对小电容量的有触点类电器（包括小电容量接触器、各类继电器、控制器、启动器等），二者的关系更加密切。例如，对继电

器而言，典型失效模式有结构失效、特性动作失效和误用失效^[2]，无论继电器以何种模式失效，最终都要由触点接触行为的静态及动态的特点进行判断，可以说触点接触失效是各种失效模式的综合反映。国外统计资料表明，接触失效模式所占比例高达80%。因此，触点零件性能的研究对于提高有触点电器产品的性能具有非常重要的意义。

现代化大型电力系统、自动控制系统、遥控遥测系统、通信系统等电气系统中触点电接触无处不在，触点数目常常数以万计，例如阿波罗登飞船系统大约有100多万个连接点，其中分合触点就能达到上千个。若其中一个或几个触点接触不正常或工作失效，则将导致整个系统工作紊乱甚至瘫痪。随着现代工业化程度的不断提高，电气系统日益庞大复杂，触点的接触可靠性与系统庞大化的矛盾更加突出，对触点接触可靠性的要求也越来越高。

在航天、钻井等一些特殊场合中使用的开关电器，对触点性能及可靠性的要求更高。忽视触点的接触问题，可能引发意想不到的故障。国内外多次发生因触点故障导致的卫星发射事故。曾有案例，一架MD-82型飞机的右发恒装CSD（飞机部件）出现航后温升过高现象，多次排查发现右发恒装的温度继电器虽能正常吸合与断开，但接触电阻过大，拆除后发现继电器内部构件非常松弛，触点表面有积炭^[3]。因此对可分合触点而言，不仅要求具有高度的接触可靠性，而且要求具有良好的接触性能^[2]。评估触点的接触性能对提高有触点电器产品的使用可靠性具有重要的意义。触点的外观形貌直接影响触点的接触性能，其特征在评估和提高触点的接触性能上有重要作用，主要表现在以下两个方面：

1. 合理的形貌特征可以提高触点的接触性能。触点的接触性能分为机械接触性能和电接触性能^[1,2,4,5]。触点在使用过程中处于频繁的开、闭状态，因此对这两方面的性能要求非常高。

（1）触点的机械接触性能

触点的机械接触性能主要涉及触点闭合过程中存在的机械碰撞、弹跳、振动和磨损情况。闭合过程中触点碰撞引起的弹跳、振动和磨损是无法避免的，要减少这些不良情况，选择耐磨损性好的触电材料，零件表面的粗糙度、组织状况、平整度和纹理对接触面积和分布起着重要作用。

（2）触点的电接触性能

触点的电接触性能主要分为静态电性能和动态电性能。

静态电性能是指触点在闭合状态下承载电流时表现出的电性能。触点的主要作用是承载电流，起到电能传递和信号输送的作用，这要求触点必须具有低而稳定的

接触电阻，因为接触电阻产生的焦耳热严重时会导致触点导电斑点区域的材料发生熔化而引起电触点焊接的现象。影响接触电阻的因素除了有两触点的物理性能、接触压力外，几何形状和接触表面纹理也是重要因素，它们决定了两触点接触的面积及导电接触点的分布，对接触电阻的阻值有直接影响。

动态电性能也是决定电接触性能的主要因素，包括触点抗电弧侵蚀性能、抗熔焊性能、抗材料转移性能以及触点工作失效问题等。电弧是造成触点工作性能下降及失效的主要因素之一。触点从正常闭合位置开始向断开的方向运动，因接触力逐渐减小，实际接触面和导电面的面积减小，接触电阻相应增大，在接触面最后分离前的一瞬间，焦耳热产生的能量集中加热最后离开点的一个极小的金属体积，使其温度迅速上升到金属的沸点而引起爆炸式气化，在间隙充满高温金属蒸汽的条件下，触点间形成电弧。在电弧作用下，触点表面的材料熔化、汽化、飞溅，接触表面遭到破坏，形成凹坑和凸点，触点材料发生转移，破坏触点的工作性能；随着接触电阻升高，触点表面熔融，当熔焊力大于触点分断力时，就会发生触点的粘连从而延缓开关电器的分断动作，甚至引起分断电路失效。所以研究减轻电弧对触点的危害是非常必要的。除了研究触点材料热物理性质外，合理的表面特征可以减少电弧的产生，减轻触点表面因材料飞溅转移或损耗引起的失效，减少焊接点的面积以减小焊接力。

2. 触点的表面形貌是触点状况最直接的体现，可以直接对零件进行评估。触点生产过程中的一些质量问题可以直接通过观察零件形貌发现，例如缺损、裂纹、变形等，甚至触点材料的成分都可以通过表面颜色得到一定的判断，能够初步判断内部质量的好坏。

综上所述，触点的形貌特征是触点一个重要指标，不仅可以观测到触点零件状况，同时也影响到触点的接触行为，在触点零件生产和使用过程中均有重要的作用。

1.1.2 工业生产中触点形貌检测的现状

工业生产流水线中对触点零件的形貌特征主要检测零件尺寸、边缘及其表面，检测表面够不够平整，边缘是否有毛刺，裂纹、鼓泡、缺边、缺角与明显凹陷及腐蚀斑点等等。分析检测结果，还可以针对各种缺陷相应地改进完善生产工艺，提高零件生产质量。

为了掌握上述形貌参数数据，国内外传统的方法是通过目测或者借助一些工具（如游标卡尺、放大镜、显微镜、投影仪等）和测试设备（如轮廓仪、扫描电镜等）

作表面观察，依靠经验丰富的技术人员进行人眼识别与判断。这种方法较落后，主要缺点有： 检测速度慢，生产效率低，目前触点零件产量非常巨大，工业流水线的生产速度已经很快，人工检测的效率低下影响生产效率； 检测主观性大，没有严格统一的质量标准，技术人员全凭经验判断触点质量的好坏，这种经验有主观的，也有的是企业内部传统得多年的经验积累，其随机性相当大； 检测质量无法保证，人工受外界因素影响较大，如身体不适、视觉疲劳等等，很容易造成漏检误检； 人工检测的数据无法准确及时地纳入质量管理体系，不易进行质量分析，不利于生产工艺的改进完善； 占用大量人力，造成较大的人工成本，生产自动化水平低。

目前，国外已经在零件外观自动化检测方面有了很大的进步，推出了不少产品化的检测设备，并且达到了很高的水平。著名的厂商有COGNEX、Banner、西门子、Photonscope公司等，例如美国COGNEX公司有DVT、In-Sight、Checker等多个自动检测系列产品并提供软件平台，有些型号的检测速度根据不同精度可高达每分钟1500~6000个工作。在国内方面，在零件检测上仍然处于起步阶段，系统化成品化的检测设备较少，且一些检测系统往往只针对特定的零件，针对性比较强，一般只在单一零件的流水线上使用。

随着国内大规模制造业的发展，自动化检测技术及其设备的市场空间十分巨大。触点零件作为产量规模巨大的工业主要零件之一，其检测需求量也很大。但是，对企业而言，如果全部采用国外进口设备，成本很高；而且触点零件的形式多种多样（如图1-1所示），一条流水线可以生产多种外观形貌不同的触点零件，如果针对每一种零件都需要一套特定的检测设备，不仅成本非常高，使用上也不方便。所以，采用先进的现代技术手段，研究针对各种不同触点零件形貌的快速、无损的自动检测原理、方法和初步的应用系统硬、软件，具有十分重要的理论和实践意义，对于国内零件制造业的发展有推动作用，因此该课题研究具有良好的发展和应用前景。

1.2 计算机视觉检测技术对触点零件形貌检测的适用性

1.2.1 计算机视觉检测技术概述

计算机视觉检测技术是通过模拟人的视觉功能，对视觉信息进行获取、传输、处理、存储与理解的技术，它不仅利用图像传感器代替人眼获取图像，更侧重于利用计算机以代替人脑，来分析图像并完成与视觉有关的任务。它是一门涉及神经生理学、认知心理学、物理学、数学、计算机科学、光学、电子学、图像处理、模式

识别和人工智能等多个领域的新兴智能技术，这些领域的迅速发展有力地促进了计算机视觉检测技术的进步，使其已经从最初的实验室研究阶段走向实际工业应用的发展阶段，逐渐形成了丰富、完善的理论体系^[6~11]。

计算机视觉检测的研究发展至今已有约四十年的历程^[12,13]，目前的计算机视觉技术研究大多是在美国麻省理工学院的马尔教授(Dr. Marr)二十年前创立的视觉计算理论框架基础上进行的^[16]。视觉可以看作是从三维环境的图像中抽取、描述和解释信息的过程，它可以划分为六个主要部分：感觉、预处理、分割、描述、识别、解释。Marr的视觉模型将视觉从概念上分成几个独立的模块，各自完成不同的计算任务。底层视觉处理直接对图像数据操作，处理一些不需要智能但在视觉感觉中又是必不可少的过程，恢复有用的2D描述；中层视觉处理利用这些描述对图像进行元素抽取、表达和标记，进行部分3D恢复；高层视觉处理再利用恢复的信息完成景物域的推理和识别，试图模仿人的认知行为。Marr视觉理论的提出，对计算机视觉的发展起到了积极的推动作用^[8,14,15]。

计算机视觉技术在80年代中期到90年代期间获得了蓬勃的发展，新的概念、方法和理论不断涌现。Lowe认为人类视觉对三维目标的识别可以通过二维灰度图像直接完成^[26,27]，它不仅为解决计算机视觉技术的两大重要研究领域——识别和导航提供了强有力的理论基础，而且对于最终揭示人类视觉感知的奥秘将起到重大作用。同时，计算机视觉的研究领域出现了主动视觉的理论框架^[17~20]。主动视觉主要通过研究通过主动控制摄像机的参数，或者更广义的说，通过视觉和行为结合来获得稳定的、实时的感知^[6]。

视觉信息在人类活动所涉及的各种信息中所占比重最大，计算机视觉技术的研究已经成为热点^[15]。目前计算机视觉理论与人类视觉相比还很幼稚，计算机视觉的研究领域充满了挑战和机遇，随着计算机技术和大规模集成电路的迅速发展，计算机视觉的研究在许多应用领域展示了广阔的前景^[21,22]。它在某些领域卓有成效的应用引起了人们的极大兴趣，其应用范围正在日益扩大。目前，计算机视觉检测已在医学、工业、农业和军事等许多领域得到广泛应用，取得了巨大的经济和社会效益^[8,23~25]，具体表现在：

1. 医学方面：医学是计算机视觉检测应用较为成功的一个领域。为人们所普遍接受的对染色体切片、癌细胞切片、X射线图像、超声波图像的自动检查、诊断方式，还有注射器针头的质量检查，药片包装有无缺损等。其中的计算机断层摄影技术(CT)更获得了诺贝尔奖，对人类做出了划时代的贡献。
2. 工业方面：生产线上自动焊接、切割加工，大规模集成电路生产线上自动连

接引线、对准芯片和封装，印刷电路板检查，钢板表面探伤，大型工件平行度和垂直度测量，容器容积检测，汽车车身检测，纸币印刷质量检测，纺织印染业自动分色、配色，木材、焊缝、铸件杂质和断口，瓷片、玻璃产品、印刷品等在线质量检查，IC上的字符识别，零件尺寸测量等。

3. 农业方面：农产品质量自动检验与分级，涉及水果、农作物籽粒、蔬菜、家畜、禽蛋等，如自动分辨并剔除已发芽的土豆，获取作物生长状态信息，农业种质资源管理、植物病理研究、遗传细胞工程研究等。
4. 军事方面：自动识别并监视军事目标，自动发现、跟踪运动目标，自动巡航捕获目标和确定距离。
5. 遥感方面：自动制图，卫星图像与地形图对准，自动测绘地图，森林、水面、土地资源管理，环境、火警自动检测等。
6. 天文方面：获取恒星、行星的结构和位置信息。
7. 商业、生活方面：自动巡视、跟踪、报警，人像安全检查，为盲人引路的“带路机器狗”等。
8. 各领域智能机器人研究也离不开计算机视觉检测技术。

计算机视觉检测技术的发展已达到了较高的实用水平，从单纯地模拟人眼的视觉响应，发展到与具体检测目标相适应的视觉延伸，并强调精度和速度及现场环境下的可靠性，具有无损、高效等优点。作为实现智能化、高效率途径中不可缺少的功能模块，视觉系统逐步与运动控制、网络通讯等先进技术相结合进而改变了传统生产、生活的面貌。

计算机视觉检测虽然在许多领域中应用取得成功，但目前这些检测系统和人的视觉相比仍有很大局限性。许多重要的视觉对人来说是很简单的，但目前几乎任何系统都无法达到人类视觉的水平，对于复杂多变的实际应用环境，视觉检测仍无法胜任。所以，发展计算机视觉技术，提高视觉检测能力，是计算机视觉技术的一个重要的研究方向。

1.2.2 计算机视觉检测技术在工业形貌检测方面的应用及适用性

在工业生产中，用计算机视觉代替人的视觉进行质量检测有不言而喻的优越性，尤其在需要重复、单调的依靠视觉获取信息的场合，如大批量的产品质量检验、分级，能够达到快速、准确、无损等人工无法比拟的效果。

目前，计算机视觉检测系统在工业检测中常见的应用有：光学字符检测/识别

(OCV/OCR)、几何尺寸检测、表面质量检测、玻璃制品质量检测。其中几何尺寸检测和表面质量检测都属于形貌检测^[11]。

计算机视觉形貌检测系统首先在一些效益好的规模型企业得到有效的应用，如人民币生产企业、钢铁企业、烟草生产企业、大型印刷企业、汽车零部件生产企业以及芯片电子产品生产企业等。这些企业长期以来和国外的合作较多，能够很快接受先进的检测技术。规模型企业质量检验方面的人员比较多，比较适合视觉检测系统的应用。尤其随着竞争的加剧，企业强烈需要通过采用视觉检测系统提高产品质量，通过减低废品率来控制生产成本，实现质量管理的数字化。

计算机视觉检测技术在工业形貌检测方面已经有不少成功的实际应用，如印刷在线检测、金属外观的质量检测和外包装检测，如图1-2所示，其检测质量也得到企业的认可。

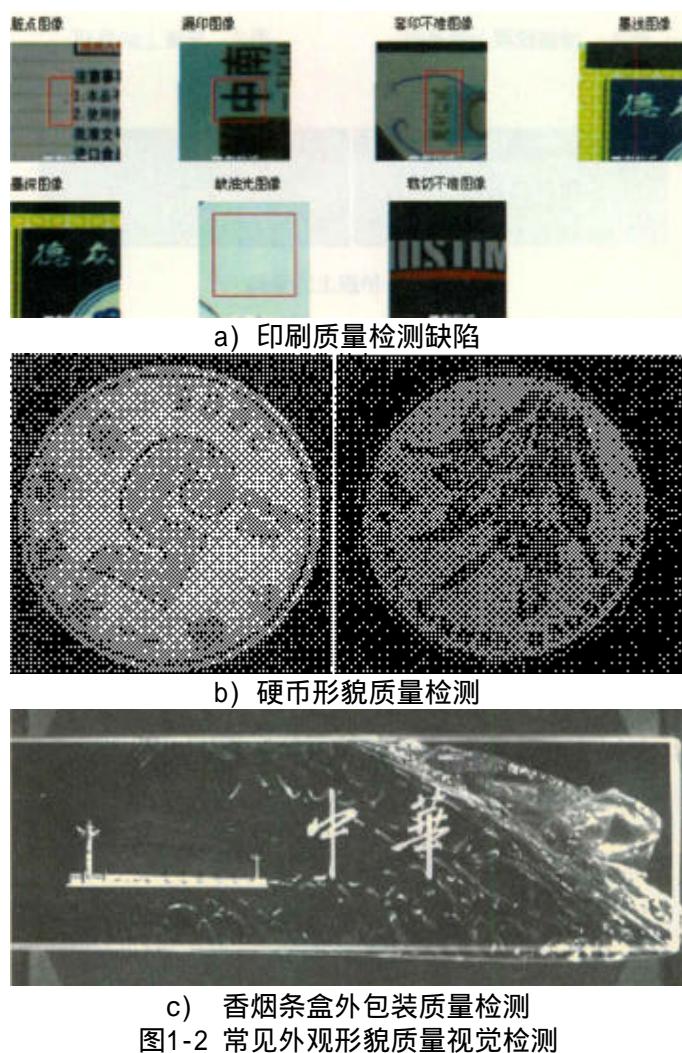


图1-2 常见外观形貌质量视觉检测

Fig.1-2 Common vision detection of appearance quality

计算机视觉形貌检测已有较深厚的理论和实践基础，具有较可靠的算法和技术支持。它不仅是人眼的延伸，更重要的是可以代替人脑的部分工作，将逐渐成为工业检测的主流。一个好的计算机视觉检测的主要优点有以下几点^[28~31]：

- (1) 精度高：随着光学成像系统和图像传感器的精度日益提高，计算机视觉的检测精度也随之提高。
- (2) 无损性：此种检测不需要接触，对脆弱部件没有磨损和危险。
- (3) 连续性：可以使人们免受视觉疲劳之苦，由于没有人工操作者，也没有认为造成操作变化，其检测稳定性和连续性好。
- (4) 成本效率高：随着计算机处理器价格的急剧下降，计算机视觉系统成本效率也变得越来越高；另外，视觉系统的操作和维护费用非常低。
- (5) 灵活性：能够进行各种不同功能的检测。应用有所变化时，只需软件做相应变化或者升级，以适应新的需求即可。
- (6) 便于信息化管理：生成的信息可以纳入数据库，实现网络发布、数据上传和数据库管理，便于自动分类、汇总、统计和报表打印等操作，提高管理水平。

基于上述研究现状和技术基础，本文提出采用计算机视觉检测系统实现触点零件外观形貌自动检测。结合企业实际需求，本文研究开发的检测系统要能够适应大小、形状、纹理都不同的各种不同规格的触点零件，所以在检测与分析时要有足够的应变能力来适应情况的变化，即具有自学和归纳能力。这是本文研究的重点。

1.3 本文主要内容及安排

1.3.1 研究内容及方法

本文研究的主要内容为开发一套基于计算机视觉的触点零件形貌在线自动检测系统，能够检测各种不同规格的触点零件，最终判断其合格性或归类到某种缺陷。因为要满足各种不同规格，无法预先设定固定的检测标准，所以需要设计一种自学习方法，让计算机在检测过程中首先学习零件特征，再以此作为标准实现检测。论文在兼顾系统稳定性、检测精度和速度的前提下重点研究了实现上述功能的算法和软件实现问题。

结合计算机图像处理及模式识别技术，本文通过提取大量样本特征并对特征进

行学习，选择其中优质特征作为识别分类的依据，从而实现了一种适用于不同规格零件，对合格零件和各种不同缺陷零件进行分类检测的方法。在图像处理方面，主要对图像预处理、自适应分割以及大量特征提取等内容进行了研究；在模式识别方面，则重点研究了特征选择的标准和分类器的设计，提出了快速有效的识别方法。

1.3.2 研究的关键问题

开发过程中，影响系统设计和算法研究的两个最关键的因素为：

1. 检测速度

在工业现场及工业生产线上，对于在线实时检测，如何将检测系统嵌入到生产线相应的工序中，必须使检测速度与生产线节拍相一致，是检测系统走上实际应用的关键一步。本文多方面考虑各种用于提高系统速度的方法：通过合理的选择光源以及安装系统使被测零件感兴趣部分在图像中尽可能明显，节约图像预处理时间；通过对被测零件进行限位，可以节约在图像中定位零件的时间；研究开发图像处理的快速算法；选用快速的模式识别方法提高决策效率等，使用这些方法都可以提高检测速度。

2. 检测结果

检测结果是衡量检测系统好坏的最基本的性能指标，决定了系统的成败。为了确保系统检测结果的准确可靠，系统必须要：获取高质量的零件图像，图像质量直接影响系统的稳定性、可靠性及识别结果，是检测的前提和必要保证；选择合适的零件特征作为系统模式识别的标准，好的特征对模式识别有效，否则对识别不起作用甚至不利于识别；保证模式识别决策的准确有效性，分类识别决策的设计是最为重要的环节，直接关系到最终的检测结果。

1.3.3 本文结构安排

针对上述研究内容，论文结构安排如下：

第一章：介绍触点零件形貌检测系统的研究背景；概述计算机视觉检测技术，分析了其实践价值以及在本课题中的适用性；介绍了本文的主要内容、关键问题和结构安排。

第二章：首先介绍了计算机视觉检测原理和自学习功能的实现原理；设计了在线视觉检测系统整体结构和自学习检测流程，并详细讨论了系统各个组成部分，介绍各个部件及其选用原则、技巧。

第三章：结合实际应用介绍计算机视觉检测系统的常用图像处理算法，包括图像预处理、自适应阈值分割、特征提取等，特别介绍了大量图像特征及其提取方法，并对其中一些算法进行了适应性改进。

第四章：对实现系统学习功能的模式识别技术作了详细的介绍，确定了模式识别的方法，并提出改进的特征预处理、选择、优化算法，最后设计了简单有效的分类器，使系统能快速检测出识别结果。

第五章：搭建了系统试验平台，并对几种触点零件进行了试验，得出检测结果并对结果作进一步分析，研究误差来源并提出改进方向。

第六章：对全文的研究工作进行了总结，给出主要的研究成果，并指出研究中存在的问题和进一步研究的方向。

论文内容总体结构框图如图1-3所示。

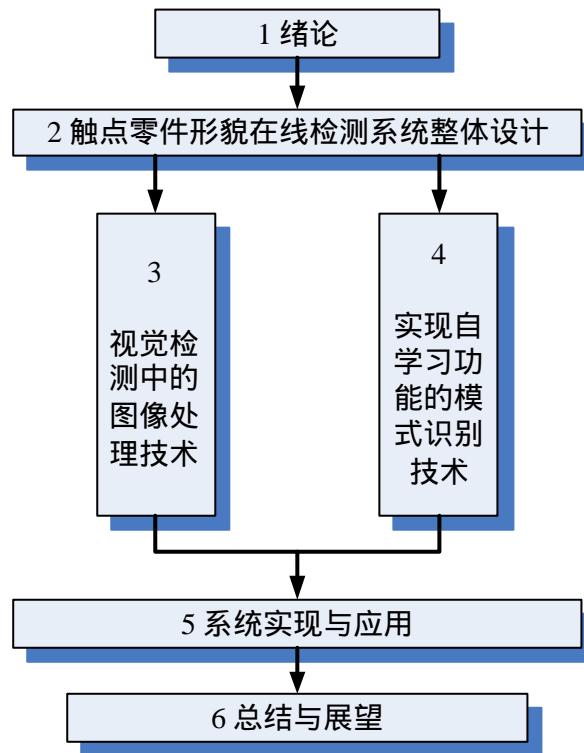


图1-3 论文结构总体框图

Fig.1-3 Structure of paper

第二章 触点零件形貌在线检测系统整体设计

2.1 系统检测原理

2.1.1 计算机视觉检测原理

触点零件形貌在线检测是计算机视觉技术在工业中的应用，因此触点零件形貌在线检测系统本身也是一个计算机视觉检测系统。其检测是通过光学装置和非接触传感器等光电成像系统自动地接收和采集目标图像，然后经计算机或专用的图像处理模块进行数字化处理，根据图像的象素分布、亮度、颜色等信息，来进行尺寸、形状、颜色等的判别，从而把计算机的快速性、可重复性，与人眼视觉的高度智能化和抽象能力相结合，以获得所需的检测信息^[32,33]。

2.1.2 实现自学习功能的检测原理

早期的图像识别采用模板匹配法，以视觉几何形状特性为主要的表达方式，分图像模板、几何参数模型、结构网络。模板匹配主要是用来在二维图像上识别标定所求的目标，原理简单、模型直观。但要选择一个适合于各种输入的较典型的模板十分困难，确定一个合适的匹配准则亦非易事，特别是当属于同一个类型有许多模板时，模板匹配法则很难奏效。通过对触点零件形貌特征的观察，零件只需要符合一定的标准即为合格品，合格零件之间也有一定的差异性，所以不能简单采用模板匹配的方法对其识别。

一种比较好的模式表达法是从对象中选择代表该类型特有的抽象属性，称之为特征。不管输入的具体图像如何变化，但是同一类型的图像其各个特征应该基本相同，而不同类型的特征有明显的不同。

按照特征的数据结构形式不同，它又可分为基于特征参数的判决理论法和基于结构特征的句法研究两大类。句法模式识别方法解决了以结构为特征的对象的识别问题，给出了它的结构化描述，但把对象归结为用严格确定性的文法来描述，有时显得很难实现，例如图像中的噪音、对象本身的多变性等。因此，在实际应用中，它是比较脆弱的，还不如判决式识别那样灵活。本系统采用基于特征参数的判决理

论方法，经过特征提取，将输入的图像用简单的特征值来描述。

确定了系统的分类识别方法后，为了实现系统的学习功能，首先要选择学习对象。根据触点零件形貌特征的缺陷分类，挑选合格零件和各类缺陷零件作为系统的学习对象，称之为样本。通过对一定数量的学习样本提取大量基础特征，构成各个类别样本的特征数据库，再对数据库中的特征进行选择和变换，形成一组能够使类与类之间尽可能分开的特征，以这些特征作为判断依据，完成识别分类的训练。事先设定各步骤的过程和标准并输入计算机，让计算机自动实现对任何一种零件判断依据的合理选择及训练，即实现了系统的自学习功能。其中涉及到大量图像处理及模式识别技术，如图像处理中图像预处理、分割、特征提取等，模式识别中特征选择、特征优化、分类器设计等。

2.2 在线视觉检测系统总体结构设计

触点类零件视觉在线检测系统设计的目标是设计一个可以自动进行触点零件图像采集、处理、识别、定位、分类、测量、检查、判断的在线检测系统。基于计算机视觉的在线检测系统是一个集光、机、电于一体的准自动化系统，一般包括图像采集、图像处理、通信与输入输出三个组成部分。

图像采集部分主要由硬件设备完成，如照明系统、相机、图像采集卡等，实现对印刷图像的数据采集，数字化后将图像数据输送到图像处理部分进行处理。

通信部分则包括检测信号输入、报警与控制信号的输出以及识别结果显示等，完成整个系统中各部分之间的数据通讯，对图像采集部分和图像处理部分发布控制信号，以协调和同步各个部分完成各自任务，同时还可以接收操作人员指令或生产线上其他单元的控制信号，或者向操作人员发出报警信号或向生产线其他单元发出控制信号。

图像处理部分是在线检测系统功能实现的主体，主要是通过计算机来实现对图像进行预处理、分割、识别等一系列必要的实时处理算法，按照检测功能要求对触点零件图像进行处理后，把结果送到输出部分显示或输出。目前也有采用硬件系统来实现图像的一部分预处理功能^[31,34,38]，如噪声滤波、卷积、二值化等基本算法。但由于硬件实现成本高而且难以实现复杂算法，因此只是应用在一些十分特殊的专用系统中用来完成图像的低级处理。

工业流水线中，触点零件的在线视觉检测需要各个部分的密切配合。具体的步骤为：零件到达视觉检测区域时，流水线上的检测触发器感应到零件后，输出一

一个检测启动信号； 计算机接收到检测启动信号，对图像采集卡发出指令，要求采集图像； 通过光学系统和成像元件生成零件图像，以数据形式发送到图像采集卡中，由计算机接收； 计算机通过图像处理和分析，得出检测结果，输出合格或不合格信号，指示外围设备（如筛选器）的操作，等待后续检测信号。在线视觉检测系统总体结构如图2-1所示。

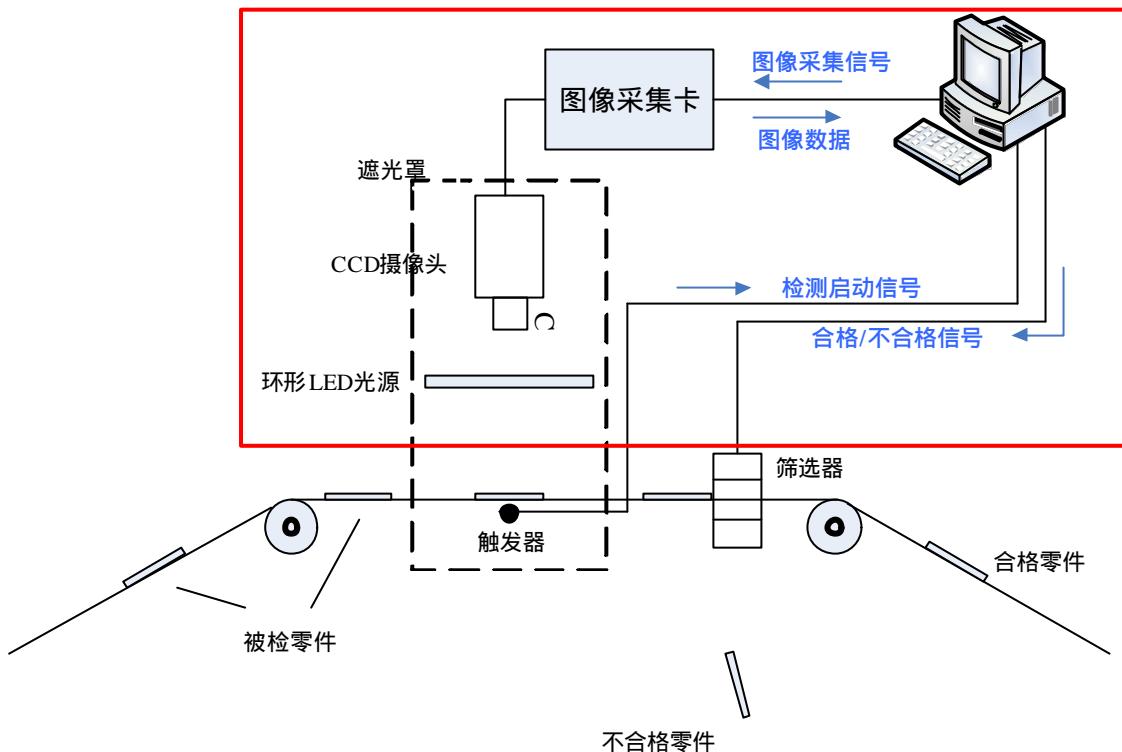


图 2-1 触点零件在线视觉检测系统总体结构
Fig.2-1 Online vision detection system structure for contact components

2.3 实现自学习功能的检测流程

系统工作时分为在线自学习和在线检测两种工作模式，如图2-2所示。

对一种新的零件在进行检测前，首先要对样本零件进行学习训练。即采集若干标准样本零件的图像，对每个样本进行预处理、图像分割及特征提取，综合样本的特征信息后，通过比较和映射转换，自动选出最适合分类器设计、对分类最有效的特征作为判据特征矢量，并利用判据特征矢量对样本进行识别训练，得出分类器的相关参数，完成智能学习过程。

系统对样本学习完成后，可以开始零件的在线检测。采集被测零件的图像，同样进行预处理和图像分割，检测中只需要提取判据特征，采用学习训练过程中得到

的模式识别方法对特征进行识别，得出最后检测结果。

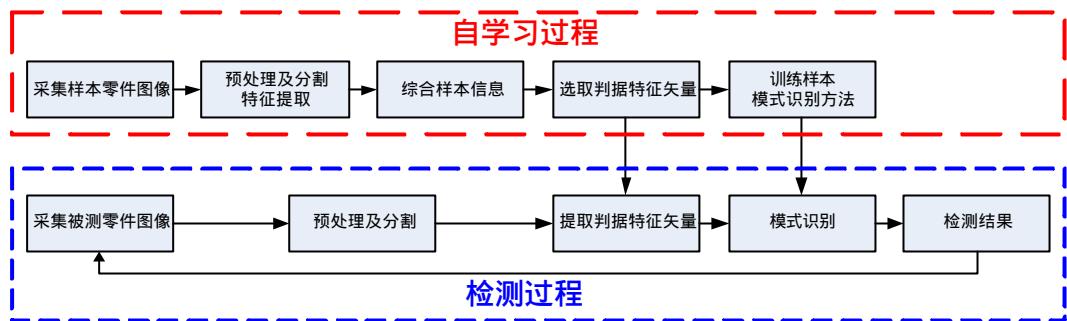


图 2-2 系统检测流程图

Fig.2-2 Detection movement flow chart

2.4 在线自学习视觉检测系统的组成

触点零件视觉在线检测系统从数据传递的角度可以将其分为数据获取模块、数据分析模块、数据通信模块；从具体组成的角度可以将系统分为照明系统、光学成像系统、成像元件、图像采集卡、软件处理系统、外围设备六个子系统。子系统设计的目的就是对系统检测的整体需求进行分析，并将检测需求的实现综合平衡，分散为各个子系统的功能需求。

其中，外围设备需要根据流水线的功能要求进行设计，与本文研究的在线视觉检测系统关系不大，文中不作具体介绍。

2.4.1 照明系统

照明系统是计算机视觉系统中一个重要功能模块，用来以合适的方式将光线投射到被测物体上以突出被测对象的特征，从而满足系统对图像采集质量的保证。一个优秀的照明系统应该能够保证采集得到的图像亮度适中，对比度高，细节清晰，没有反光和眩光，颜色保真度高，能够为图像后期处理减少不必要的麻烦，并能简化软件算法。

照明系统分为光源和照明方式两部分。好的光源与照明方式往往是整个系统成败的关键所在，不是简单的照明而已。光源与照明方式的配合应该尽可能的突出物体特征量，在物体需要检测的部分与那些不重要部分之间应该尽可能的产生明显的区别，尽量的增大背景与物体边缘的灰度反差，增加其对比度。同时，还应该尽可能的保证系统有足够的整体亮度，物体位置的变化不应该影响成像的质量^[35~37]。

1. 光源

光源通常分为天然光源与人工光源。天然光源是自然界中存在的辐射源，如太阳、恒星等。人工光源是人为将各类形式的能量转化成光辐射能的器件，按照发光机理，可分为热辐射光源、气体放电光源、固体发光光源和激光器等。计算机视觉系统工作在工业生产现场，采用合适的人工光源更容易创造有利的视觉环境，提高系统获取的图像质量。

视野大小、相机与被摄物体的距离以及光源与被摄物体的距离均影响光源的选择。被摄物体表面条件(光滑或凹凸不平)和几何形状与光源种类选择有关，被摄物体本身或被检测区域的颜色与光源波长选择有关。具体成像内容也在很大程度上影响光源的选择。光源设备的选择必须符合所需的几何形状、照明显亮度、均匀度、发光的光谱特性等，同时还要考虑光源的发光效率和使用寿命^[37]。

常见的光源有白炽灯、荧光灯、汞灯、钠光灯和LED光源等。表2-1列出了几种主要光源的相关特性。

表 2-1 常用光源对比

Table 2-1 Contrast of several common illumination sources

光源	颜色	寿命(小时)	发光亮度	特点
白炽灯	白色，偏黄	1000	很亮	发热多，众多场合使用光纤导光，便宜。
荧光灯	白色，偏绿	5000-7000	亮	发热少，扩散性好，适合大面积均匀照射，较便宜。
汞灯	绿色、蓝色	6000-16000	很亮	发光效率较高，寿命较长，显色性差，影响对颜色的分辨。
钠光灯	黄色、偏绿	8000-20000	亮	透射性好，适合户外照明。
LED 灯	红、黄、绿、白、蓝、紫	60000-100000	较亮，使用多个达到高亮度	耗能少，寿命长，光照稳定，能做成很多形状，较贵。

白炽灯是热辐射光源，散射较多且工作温度高，容易导致局部成像噪声；荧光灯、汞灯、钠光灯等都属于气体放电灯，工作时光照不稳定，容易受外界因素影响；其他光源例如激光，其照明系统复杂，且单向光照明不符合本系统原理，完全无法工作；而LED光源具有发热少、光照稳定、功耗较低、稳定性好、使用寿命长等优点，而且可以根据用途选择波长和形状^[35,36]。

触点零件尺寸不大，相机视野不需要很大，检测距离短，而且触点零件是金属制品，表面反光大，所以光源的亮度并不需要很高；但是检测过程中光源的稳定性是很重要的，且光源的温度不宜太高，以免影响其他设备的正常工作；另外，由于

工业生产成本的原因，光源的使用寿命也是重要的因素。综合以上几点，本系统选择LED照明光源。

光源的分布方式上，本文选用环形光源^[39]，采用LED按圆周排列，发出的光线向内汇聚，光线方向和相机观察方向垂直或接近90度角，光源发出的光不直接进入摄像机，瑕疵等表面的变化引起光线改变进入镜头，从而实现了高对比度。这种光源多用于金属工件刻印字符、光滑表面划痕、平面工件表面质量等的测量，适合本系统的测量要求，如图2-3所示。



图 2-3 环形光源

Fig.2-3 Loop illumination source

另外，为了避免外界干扰光的影响，还在光源部分加上遮光罩。

目前世界上生产LED光源的厂商主要有日本的CCS公司、美国的Schott公司等，它们均有生产应用于视觉检测的LED光源。

2. 照明方式

常见照明方式有以下几种^[8]：

(1) 传统光源基本上以接近垂直于桌面的方式安置，使得光源亮度集中于照明区域的中心，主要应用于字体的检验、电路板上零件的检测等。

(2) 低角度光源以接近水平于桌面的方式安置，以强化对象的边缘及对象表面的缺陷，适合边缘检测、表面检测等。

(3) 条状光源以LED或雷射光源创造线状光源投射于物体表面，一般配合高分辨率的线扫描CCD (Line Scan CCD) 检验，它主要用于检测条状、筒状产品，例如布匹、钢板、纸张等。

(4) 背光照明光源由对象的背面投射，使得物体成像于CCD时呈现高对比的剪影效果，主要用于物体尺寸测量及轮廓识别。

(5) 间接光源非直接投射于物体表面，而是经由反射板将光源均匀扩散于物体

表面，主要用于强调平滑且规律表面的特性。

(6) 同轴光源由分光镜 (Half Mirror) 将光源以垂直方向投射于物体表面，主要用于检测具有高反光特性的物体表面，例如半导体晶圆表面。

(7) 平行光源如同太阳光般以平行方式照射，主要针对反光表面的缺陷检测，对于规律表面，反射光源的扩散量少，而对于缺陷表面反射光源的扩散量则会大量增加。

(8) 结构式光源以点状、线状或格状方式投影于物体，利用投射图案的变化检测物体的形状。

对于系统检测的触点类零件，最重要的特征是形状特征和表面纹理特征，低角度方式的照明能够满足触点零件视觉检测系统的照明需求。另外，由于触点零件是金属材质，属于反光物体，所以不能采用直接照射方法，需要采用低角度漫反射环形照明，如图 2-4 所示。

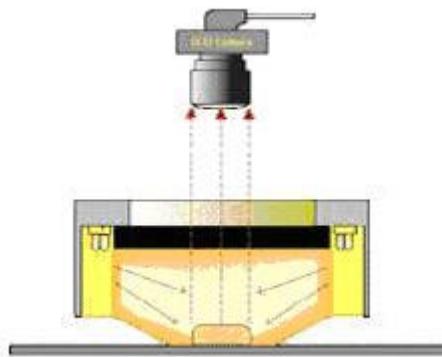


图 2-4 低角度漫反射环形照明方式

Fig. 2-4 Low-angle & diffuse reflectance illumination mode

2.4.2 光学成像系统、成像元件

1. 相机

目前工业用相机主要有 CCD 和 CMOS 两种。CMOS 相机起步较晚，所摄取的画面质量也不是很好，所以主要用在图像品质要求不是很高的产品上，而工业上应用较为普遍的是 CCD 相机。CCD (Charge Coupled Device) 是美国人 Boyle 发明的一种半导体光学器件。该器件具有光电转换、信息存储和延时等功能，并且集成度高、能耗小，故一出现就在固体图像传感、信息存储和处理等方面得到广泛应用。在选择相机时，主要有以下几个方面的问题要考虑：

(1) 相机扫描方式：分为面扫描和线扫描两种。线扫描运动平稳、速度精度高，适于动态目标连续无遗漏的高精度检测；面扫描一次只能拍摄一幅图片，符合本系统的要求，所以系统采用面扫描相机。

(2) 黑白和彩色相机：黑白相机比彩色相机的分辨率高，数据采集速度快；彩色相机可以提供更强的观察和区分能力，随着相机制造技术的发展，彩色相机也越来越多地得到应用。在本系统试验阶段，暂时先采用黑白相机，如果实际应用中有需要，可以换成彩色相机。

(3) 相机的输出接口形式：相机输出接口形式有 RS422、RS644、USB、IEEE1394 以及 Camera-link 等，在选择图像采集卡时应注意其是否支持所选用相机的输出形式。

现在世界上有很多公司都在生产 CCD 相机，这其中比较著名的有德国的 Basler 公司、丹麦的 JAI 公司、加拿大的 Dalsa 公司等。

本文中 CCD 图像传感器选用松下的 WV-BP330(AC220V-240V)。它的主要特点如下：

(1) 具有 768 (H) × 582 (V) 像素的 1/3 型 (英寸) CCD 转换元件，提供 57 线的水平清晰度。

(2) 垂直数字 2H 增强和数字光圈校正提高了水平和垂直边缘的信号强度，再现了清晰的图像。

(3) 数字调节背光补偿 (BLC) 功能。

(4) 当观察光线明亮的物体时，拐点电路有效地扩大了动态范围。

(5) 50db 信噪比实现了自然的图像观察。

(6) 最低照度：F1.4 时 0.08 lx，F1.2 时 0.06 lx，F0.75 时 0.02 lx。

(7) 特殊开发的镜头卡口结构可以适合 C 和 CS 镜头卡口的安装，同时适合 ALC 镜头的直流和视频伺服。

(8) 通过电子光线控制 (ELC) 功能，可以使用价格低廉的固定光圈镜头，实现成本更低的系统。

(9) 具备同步锁相功能，用于实现系统的扩展性和各种同步模式 (电源同步，VD2 即多工垂直驱动，内同步，外同步)。

2. 镜头

光学镜头相当于人眼的晶状体，对视觉系统的成像质量关系重大。针对不同的检测目标所选用的镜头也不同。在选用镜头时需要考虑以下问题：

(1) 成像面大小：成像面是入射光通过镜头后所成像的平面，这个面是一个圆形。一般使用的 CCD 相机，其芯片大小有 1/3, 1/2, 2/3 及 1 英寸 4 种大小，在选

用镜头时要考虑就是该镜头的成像面与所用的 CCD 相机是否匹配。

(2) 焦距、视角、工作距离、视野：焦距是镜头到成像面的距离；视角是视线的角度，也就是镜头能“看”多“宽”；工作距离是镜头的最下端到景物之间的距离；视野是镜头所能够覆盖的有效工作区域。以上四个概念相互之间是有关联的，其关系是：焦距越小，视角越大，最小工作距离越短，视野越大。视角越大，成的像也越大，也就是说图像放大率越大。

在本系统中，零件的尺寸是不固定的，无法事先设定零件图像的放大倍数，而 CCD 接收器尺寸是一定的，所以选用变焦镜头。

现在世界上专业生产镜头的厂家也有很多，其中比较有名的有日本的 Utron 公司、佳能公司、松下公司等。

本文中选用 CCD 专用镜头，型号为 AFT-10200M，它的技术参数与特点如下：

- (1) 放大倍数：连续变倍6-31倍；
- (2) 物镜：标准1.0X大平场；
- (3) 焦距：10-200mm；
- (4) 视场角：42.36° -4.36°；
- (5) 调焦机构：V型导轨与钢球组合的调焦机构，保证调焦灵活舒适、稳定可靠；

3. 照度匹配

在 CCD 传感器的图像测量应用中，光照度是 CCD 成像质量的关键。光敏面上任何像敏单位上的曝光量 Q_v 均应低于其饱和曝光量 Q_{sat} ，否则将产生画面亮度的失真，或产生较大的测量误差。但如果某些点的照度低于 CCD 器件的灵敏阈，这些较暗部分便无法测出，从而降低画面亮度的层次或产生测量误差。因此，最好把光敏面上的最大照度 E_{max} 调节为略低于 Q_{sat} / t ，以充分利用器件的动态范围。

可用合理选择照明光源的功率及照明系统的参数来调节被观测对象的亮度值，但是照度的细微调节很难由控制光源完成，而通过调节光学系统中光圈孔径的大小，就可以调节光通量的大小。光圈有手动光圈和自动光圈之分，在系统试验阶段，采用手动光圈以便于调试。需要注意的是，触点零件为金属材质，所以在检测时，应调小光圈，抑制金属表面的反光，防止曝光过度。

2.4.3 图像采集卡

在计算机视觉系统中，图像采集卡是控制摄像机拍照，完成图像采集与数字化，

协调整个系统的重要设备。它一般具有以下功能模块：(1)图像信号的接收与 A/D 转换模块，负责图像信号的放大与数字化；(2)摄像机控制输入输出接口，主要负责协调摄像机进行同步或实现异步重置拍照、定时拍照等；(3)总线接口，负责通过计算机内部总线高速输出数字数据，一般是 PCI 接口，传输速率可高达 130Mbps，完全能胜任高精度图像的实时传输，且占用较少的 CPU 时间；(4)显示模块，负责高质量的图像实时显示；(5)通讯接口，负责通讯。

目前，图像采集卡种类很多，按照不同的分类方法，有黑白图像和彩色图像采集卡，有模拟信号和数字信号采集卡，有复合信号和 RGB 分量信号输入采集卡。在选择图像采集卡时，主要应考虑到系统的功能需求、图像的采集精度和与摄像机输出信号的匹配等因素。

根据系统要求，图像采集卡选用大恒图像的 QP300，它的主要指标如下：

- (1) 二组复合视频输入，一组四路复合视频同时输入同屏显示，一组复合视频输入可与 QP-MPEG 的输出连接作为同时采集的视频源，支持四路单声道音频采集。
- (2) 支持 PAL、NTSC 彩色/黑白视频输入，信号幅度 = 1Vp-p。
- (3) 图像分辨率最高：PAL 制：768 × 576 × 24 位；NTSC 制：640 × 480 × 24 位。
- (4) 可编程亮度、对比度、色度、色饱和度。
- (5) 支持 YUV422、RGB8888、RGB888、RGB565、RGB555 及 Y8 模式。
- (6) 图像数据数值范围，亮度：0-255 或 16-253 可选；色度：2-253。
- (7) 支持计算机内容与图像同屏显示图形覆盖功能。
- (8) 支持图像的裁剪与比例压缩模式。
- (9) 支持单场、单帧、连续场、连续帧的采集方式
- (10) 支持 Win9x/WinNT/Win2000/WinXP 等操作系统，支持多种开发环境。

2.4.4 软件处理系统

软件处理系统是整个自学习视觉检测系统的中心。图像数据经由 CCD 和图像数据采集卡存入计算机，经过一系列的处理才能获得系统所需要的数据，是实现自学习视觉检测的关键步骤。软件模块的准确性、精确性和实时性直接影响到整个系统的性能指标，决定了系统能否提供直观可靠的检测数据和结果以及整个系统设计的成功与否。

1. 软件系统需求分析

软件系统的设计原则是基于检测系统设计的需要进行软件设计。该原则是指导

系统软件部分设计的最基本依据，具体在指导软件模块设计中，该原则的实现从以下几个方面进行讨论与说明：

(1) 本文中设计的检测系统检测对象为触点零件形貌在线质量检测，从检测要求来看，其检测的目标是对触点零件中存在的各种外观形貌缺陷进行在线检出和分类，建立零件图像数据库，同时对零件图像进行实时显示。出现缺陷时，对流水线给出指示信号。

(2) 零件的规格多样，无法事先对检测系统指定质量标准，所以计算机每次对一种零件进行检测前，必须由质量专家事先对样本零件分类，监督计算机自动学习样本零件特征并录入数据库，认识合格零件与各种缺陷零件之间的不同，然后实现检测。

(3) 触点零件形貌在线检测的要求是能在线完成触点图像摄取，对所摄取图像进行在线实时识别，并能将图像特征与识别结果录入数据库保存。

2. 软件设计概述

(1) 软件方案设计

按照软件功能分类进行了模块化的系统软件设计，软件总体结构如图2-5所示。

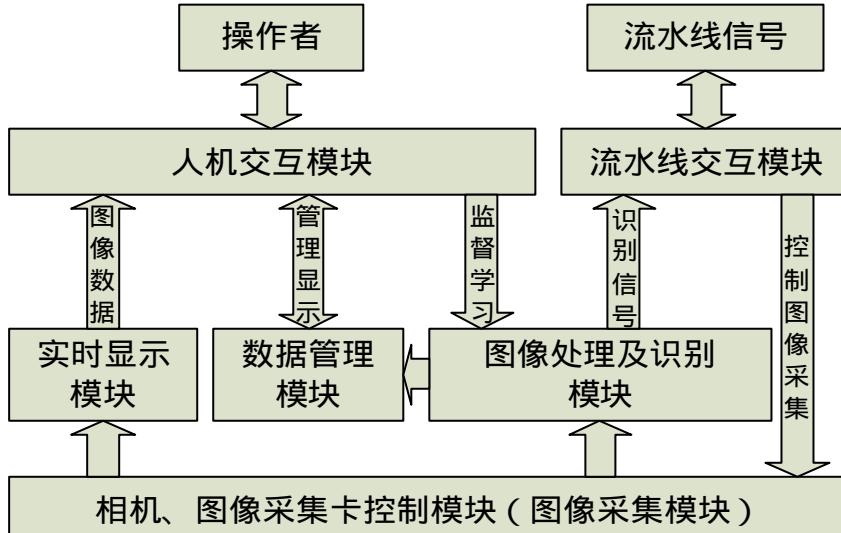


图 2-5 系统软件的总体设计示意图

Fig.2-5 General design of software system

上述软件模块中，属于输入输出单元的包括人机交互模块和流水线交互模块。流水线交互模块实现流水线检测信号输入控制图像采集，以及检测结果输出指示流水线操作。人机交互模块则主要实现检测系统学习过程中的监督，如样本零件的分类、学习过程的结束标志等，并管理数据库。

实时显示模块主要实现把图像数据实时传输到显示器屏幕输出。数据管理模块

功能主要包括图像特征数据库的建立、检测历史纪录的管理与维护等。

图像处理与识别模块实现在线质量检测的主要功能模块，主要是按照检测要求对各种检测算法进行系统化和模块化的软件实现，具体算法内容将在后面章节作详细介绍。

(2) 软件系统工作流程设计

图2-6所示为检测软件系统工作流程图。

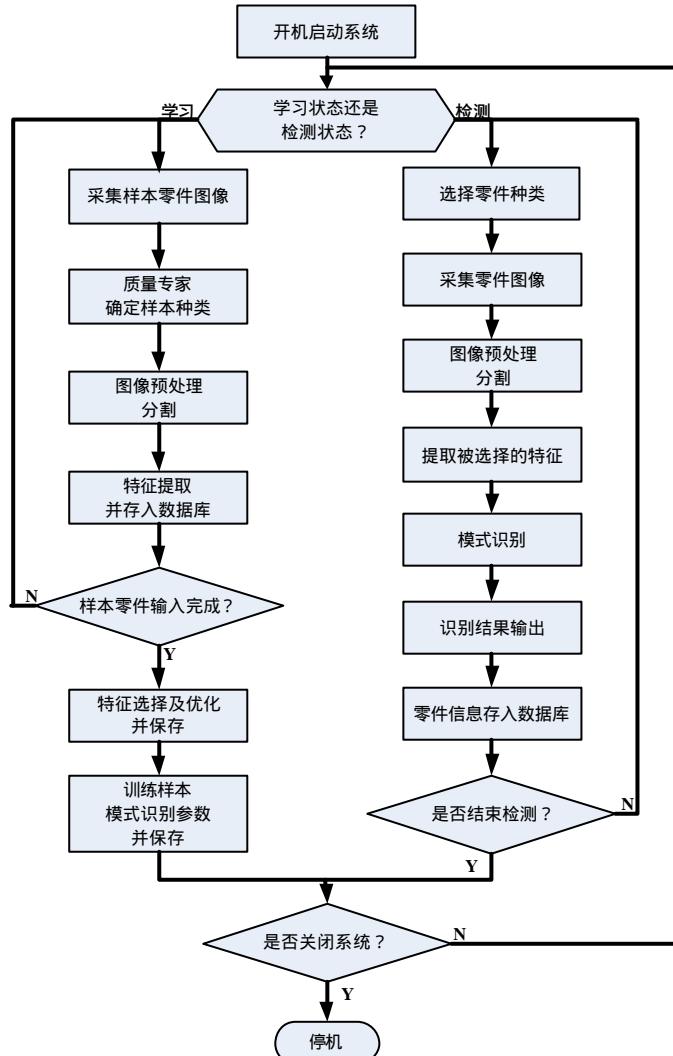


图 2-6 系统软件工作流程图

Fig.2-6 Movement flow of software system

(3) 设计工具的选取

设计工具选取Microsoft公司产品VC++为开发工具，选取原则基于如下考虑：

系统设计中所选取的图像采集卡^[11]的驱动程序中有lib静态链接库可以采用，其可以被VC、VB等开发工具使用。

该项目涉及到检测处理算法较多，且图像数据较大，在程序运行过程中内存开销很大，处理器时间占用也较多，使用C++语言进行处理要比解释执行的语言运行得快。目前以没有经过优化器优化的代码执行，其速度能满足在线检测的通常要求。同时通过在程序中使用自定义类进行数据处理，便于进行程序的后续功能扩展。

VC开发工具^[12]便于开发操作人员习惯使用的用户界面。

2.5 本章小结

本章介绍了触点零件形貌在线检测系统的视觉及自学习检测原理，并根据流水线在线检测的要求搭建了系统的总体结构，以及实现自学习功能的系统检测流程图。介绍了系统中的各个组成部分：照明系统、成像系统、成像元件、图像采集卡的功能特性及选择方法。根据软件系统需求，设计了在线检测软件的整体架构，将软件功能分散到各个功能模块，最后设计了软件系统的工作流程图。

第三章 视觉检测中的图像处理技术

3.1 图像处理概述

计算机视觉检测系统通过光学系统和光电成像传感器等自动地接收和采集目标图像，经计算机或专用的图像处理模块进行数字化处理，将原本的模拟光信号转化成数字电信号，本文研究的图像处理技术不包含模拟图像处理，只针对数字图像处理。

数字图像处理就是用计算机对各种图像信息进行转换、加工、分析和处理，以期得到某种预期的效果或从图像中提取有用的信息，以改善其视觉效果，满足实际应用需要，或达到识别理解的目的。本系统中，输入计算机的图像信息只是原始的二维数字信号，经过图像采集卡的采样量化，形成各像素的灰度值，这样的高维信息计算机无法对其进行识别理解，必须对图像进行处理以便用低维空间来表示。本文主要研究的图像处理内容包括：图像预处理，改善图像质量；图像分割，把目标图像从背景中提取出来；及目标特征提取。

在线视觉检测对图像处理的实时性要求很高。工业自动化中在线检测中的实时性是指任务实时性，即能够在一定时间内完成一定处理任务（如满足生产流水线任务的检测）就可以称为达到了实时性要求，是工业应用中对计算机视觉系统主要追求的指标^[40]。图像处理的数据量大，处理过程复杂，一个好的图像处理算法能够使系统获得比提高计算机硬件配置更高的实时性能。传统图像处理算法研究多偏重于算法的稳定性与识别精度，对实时性指标重视不足。因此，研究更为高效的图像处理算法能够更为有效地改变检测系统的实时性能。

本章就系统中涉及的图像处理技术进行深入探讨和研究，综合考虑图像处理算法的速度和效果，满足系统对图像处理技术各方面要求。

3.2 图像预处理

触点零件图像在摄取、传输、储存和处理过程中，由于成像系统、记录设备、传输介质和处理方法的不完善，及周围环境的影响等，不可避免地受到噪声影响，如曝光强度引入的噪声、LED 照明不均匀性产生的高频噪声、量化噪声等，降低了

图像质量，给后续的图像处理和分析造成障碍。为了稳定地进行特征提取等处理，必须消除噪声，校正失真，以得到更好更有用的图像。

图像预处理是图像分析处理的第一步，其目的是改善图像的“视觉效果”。针对给定图像的应用场合，有目的地强调图像中感兴趣的整休或局部信息，抑制不需要的噪声信息，增强对所需信息的辨别能力，使处理后的图像更适合于人的视觉特性或计算机的识别系统，为图像的信息提取及其他分析技术奠定良好的基础。

本文的图像预处理主要是指图像去噪过程。噪声反映在图像中，会使原本均匀和连续变化的灰度突然变大或变小，形成一些虚假的边缘或轮廓。减弱、抑制或消除图像中的噪声成份叫做图像的平滑化或滤波操作，是图像增强的一种方式。滤波的目的有两个：一是抽出对象的特征作为图像识别的特征模式；二是为适应计算机处理的要求，消除图像数字化时所混入的噪声，保留有用数据。对滤波处理的要求有两条：一是不能损坏图像轮廓及边缘等重要信息；二是使图像清晰，视觉效果好。图像滤波能够去除或衰减图像上的噪声和假轮廓，常见的去噪滤波方式基本上可分为^[41~44]：

1. 空间域平滑滤波

空间域滤波直接对图像的像素灰度值进行操作，是基于领域处理的增强方法，它应用某一模板对每个像素与其周围领域的所有像素进行某种数学运算得到该像素的新的灰度值，输出值的大小不仅与该像素的灰度值有关，而且还与其领域的像素灰度值有关。常用的方法包括领域平均法、阈值平均法、加权平均法、模板平滑法、多图像平均法等。

2. 频率域低通滤波

频率域滤波是在图像的变换域中，对图像的变换值进行操作，然后经逆变换获得所需的滤波结果。根据信息（包括信号和噪声）在空域和频域的对应关系，即随空间位置突变的信息在频域是高频，而缓变的信息在频域是低频。具体到图像中，边缘和噪声对应于频域的高频区域，而背景及信号缓变部分则对应于频域的低频区域，利用频域的低通滤波法来达到滤除高频噪声的目的。频域低通滤波法等效于空域中模板平滑法。常用的几种低通滤波器包括理想低通滤波器（ILPF）、Butterworth低通滤波器（BLPF）、指数低通滤波器（ELPF）、梯形低通滤波器（TLPF）等。

3. 中值非线性滤波

在含噪图像中，噪声往往以孤立点的形式出现，尤其是干扰脉冲和椒盐类噪声。这些噪声所占的像素数很少，而图像则是由像素数目较多、面积较大的小块组成。中值滤波的原理是对一个窗口内的所有像素灰度值进行排序，取排序结果的中间值

作为窗口中心点处像素的灰度值。中值滤波方法是一种非线性处理技术，在消除噪声的同时，避免采用平均滤波带来的目标物细节模糊的问题，对脉冲干扰及图像扫描噪声非常有效；但是，对一些细节多，特别是点、线、尖顶细节较多的图像则不宜采用中值滤波。而且中值滤波在抑制随机噪声上要比其他方法差一些。

4. 其他方法

其他主要方法主要有维纳滤波、同态滤波及小波去噪等。维纳滤波根据最小均方误差准则（滤波器的输出信号与需要信号之差的均方值最小），求得最佳线性滤波器的参数；同态滤波利用非线性的对数变换将乘性的噪声转化为加性的噪声，用线性滤波器消除噪声后再进行非线性的指数反变换以获得原始的无噪声图像；小波去噪是特征提取和低通滤波功能的综合，小波变换的多分辨率特性能够很好地保留信号的细节，小波变换后，对应信号细节处的系数幅值较大，而且在相邻尺度层间具有很强的相关性，所以便于特征提取和保护。

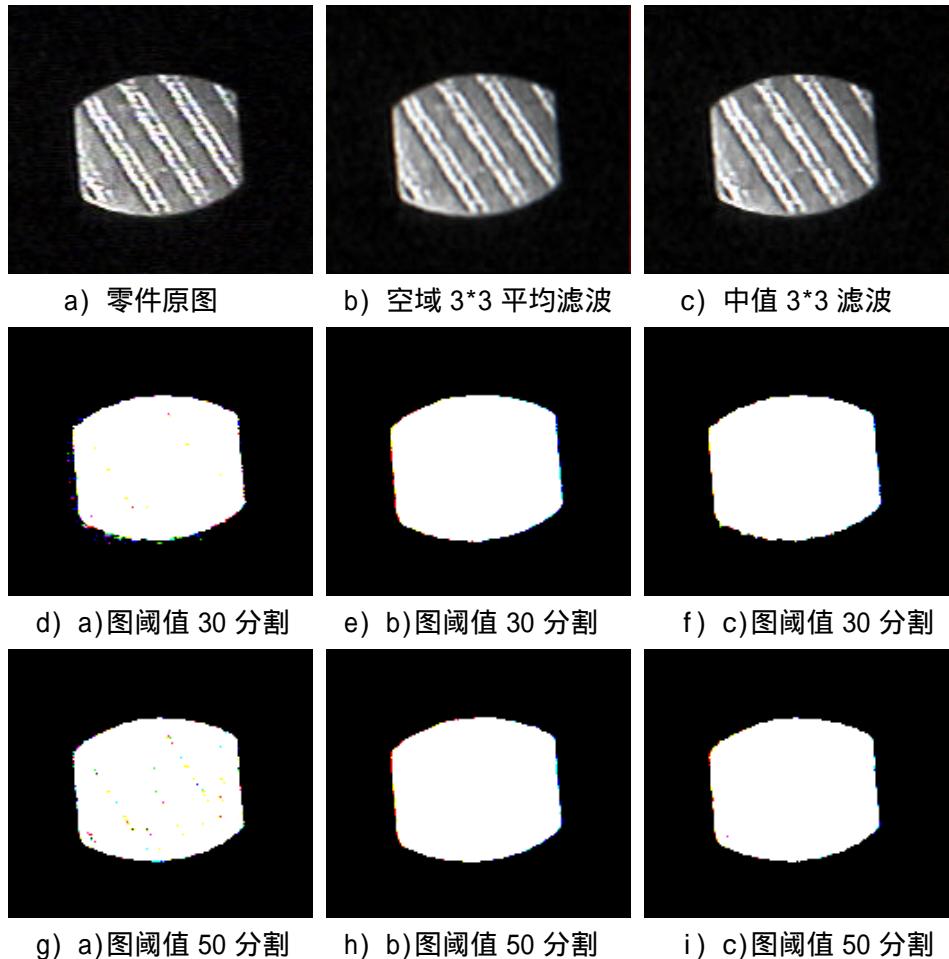


图 3-1 零件图像滤波去噪效果比较

Fig.3-1 Contrast of noise-elimination results

其中频率域低通滤波方法等效于空域中模板平滑法，但是需要在空域与频域之间互相转换，维纳滤波方法需要统计整个图像的参数，同态滤波用于消除乘性噪声，小波去噪法则要进行多尺度小波变换，这些方法比较复杂，运算量大，处理速度慢，不适合系统的实时性要求，所以不考虑采用以上方法。

图 3-1 是对零件图像分别进行空域平滑滤波和中值滤波的结果。其中图 a 是图像原图，图 b 是 $3*3$ 空域平均滤波之后的图像，图 c 是 $3*3$ 中值滤波之后的图像。为了对图像噪声有更直接的观察，分别对图像进行不同阈值的二值分割，如图 d-i 所示。

从图中可以看出，没有经过去噪处理的原始图像噪声明显，在分割阈值较小时，无法去除背景中的噪声（图 d），分割阈值较大时，则可明显观察到零件区域中的噪声（图 g）。空域平滑滤波会模糊图像的轮廓和边缘细节，图像看上去不清晰（图 b），但是对各种噪声的抑制能力较强（图 e、h）。中值滤波能够较好地保留图像细节（图 c），但是对一些较强噪声的抑制能力还不够（图 f、i）。

另外，为了比较两种滤波器的时间开销，编写程序实现了两种算法，并对零件图像（像素数为 $300*250$ ）进行了滤波运算试验，表 3-1 是两种算法对图像进行滤波所需要的时间对比，采用 10 次运算平均时间（编程语言为 VC++6.0，计算机为 Intel T2300，1.66GHz，512M 内存，此为本论文中通用试验条件）。

从表中可以看出，同样采用 $3*3$ 区域滤波，中值滤波法运算的时间比较长，其主要原因是中值滤波需要对运算区域内像素值进行大小排序以找出中值，如果采用优化排序算法能够缩短一些运算时间，但是对一些较大的图像进行处理时，仍然需要较长时间。

表 3-1 采用不同算法去噪所用时间对比

Table 3-1 Time contrast of different noise-elimination algorithms

算子类型	平均运算时间 (ms)
空域 $3*3$ 平均滤波算子	5
中值 $3*3$ 滤波算子	40

比较分析后发现，中值滤波法有一定的局限性，它对某些噪声的处理效果比较差，对一些点、线、尖顶细节较多的图像也不适用，但是系统的检测对象并不固定，中值滤波法不能满足系统的通用性。同时其运算速度也不及空域平滑滤波法。空间域平滑滤波方法易于实现，适用于大部分图像和噪声，效果也比较好，综合系统的实时性与通用性要求，决定采用空间域平滑滤波方法实现图像去噪。

空间域平滑滤波法的滤波效果与模板大小及模板中系数有关。如果模板大，去噪效果会更明显，但是计算量大，所涉及的像素多而且容易把细节抹去，造成模糊。图 3-1 中采用的 $3*3$ 的平均滤波模板，模板中的系数均相同，平均法的缺点是使图中

的边缘变模糊，为了解决平滑噪声与保持边缘的矛盾，系统采用 3*3 的空域高斯滤波。

高斯平滑滤波器无论在空间域还是在频率域都是十分有效的低通滤波器，且在实际图像处理中得到了有效使用。高斯函数具有五个重要的性质，这些性质使得它在早期图像处理中特别有用^[45]：

(1) 二维高斯函数具有旋转对称性，即滤波器在各个方向上的平滑程度是相同的。一般来说，一幅图像的边缘方向是事先不知道的，因此，在滤波前是无法确定一个方向上比另一方向上需要更多的平滑。旋转对称性意味着高斯平滑滤波器在后续边缘检测中不会偏向任一方向。

(2) 高斯函数是单值函数。这表明，高斯滤波器用像素邻域的加权均值来代替该点的像素值，而每一邻域像素点权值随该点与中心点距离的增加单调增减。这一性质是很重要的，因为边缘是一种图像局部特征，如果平滑运算对离算子中心很远的像素点仍然有很大作用，则平滑运算会使图像失真。

(3) 高斯函数的傅里叶变换频谱是单瓣的。这一性质是高斯函数傅里叶变换等于高斯函数本身这一事实的直接推论。图像常被不希望的高频信号所污染（噪声和细纹理）。而所希望的图像特征（如边缘），既含有低频分量，又含有高频分量。高斯函数付立叶变换的单瓣意味着平滑图像不会被不需要的高频信号所污染，同时保留了大部分所需信号。

(4) 高斯滤波器宽度（决定着平滑程度）是由模板大小表征的，而且模板大小和平滑程度的关系是非常简单的。模板越大，高斯滤波器的频带就越宽，平滑程度就越好。通过调节平滑程度，可在图像特征过分模糊（过平滑）与平滑图像中由于噪声和细纹理所引起的过多的不希望突变量（欠平滑）之间取得折衷。

(5) 由于高斯函数的可分离性，大高斯滤波器可以得以有效地实现。大规模的二维高斯函数卷积可以分两步来进行，首先将图像与一维高斯函数进行卷积，然后将卷积结果与方向垂直的相同一维高斯函数卷积。因此，二维高斯滤波的计算量随滤波模板宽度成线性增长而不是成平方增长。

高斯滤波器的采样值或者高斯滤波器的二项式展开系数可以形成离散高斯滤波器，考虑到模板不宜过大，所以采用模板大小为 3*3 的空域高斯滤波，其模板表达式为

$$\frac{1}{16} \begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix}$$



图 3-2 空域 3×3 高斯滤波去噪效果图

Fig.3-2 Noise-elimination result of 3×3 Gaussian template

其运算速度和平均法差不多，去噪结果如图 3-2 所示。高斯滤波可以突出计算像素点本身的重要性，在一定程度上减少失真，且可消除大部分白噪声和高频噪声，能够较好地保持轮廓信息和准确的边缘，为后续的匹配及测量提供保证。

3.3 图像分割

当触点零件图像输入到计算机时，图像不仅包含目标零件图像还包含背景图像。在触点零件图像分析中，我们只对其中的触点零件即目标物感兴趣，要对图像中的目标物进行检测和特征参数测量，首先必须把图像按一定要求分成一些“有意义”的区域，这就是图像分割要完成的工作。图像分割是把图像分成若干个有意义的区域的处理技术。这里“有意义”是指分割后这些区域能分别和图像中的目标物或背景相对应，即把目标物区域和背景区域分开，以便于对目标物进行分析和理解。图像分割作为图像分析和理解的一个关键步骤，其结果将直接影响到目标物特征提取和描述，以及进一步的目标物识别、分类和图像理解。

3.3.1 常见图像分割方法分析

图像分割的方法大致可以分为三大类：基于阈值选取的方法、基于边缘检测的方法和基于区域生成的方法^[41~44,46]。

1. 基于阈值选取的方法

阈值法是把图像的灰度特性分成不同等级，然后用设置灰度阈值的方法确定有意义的区域或欲分割的物体之边界。常用的方法有直方图阈值分割、最大熵阈值分割、二维阈值分割、局部阈值分割。

2. 基于边缘检测的方法

首先检出局部特性的不连续性，再将它们连成边界，这些边界把图像分成不同

的区域，从而分割出各个区域，常用的边缘检测方法有线检测（Hough 变换）、边缘检测算子方法。

3. 基于区域生成的方法

是将像素分成不同的区域，根据相应的区域特性在图像中找出与其相似的部分并进行处理，常用的方法有区域生长、分裂-合并分割方法。

观察各种触点类零件图像，可以发现边缘检测方法和区域生成方法对于一些纹理特征较多的触点零件，其分割得到的结果不太理想，过多的细节特征影响了整个零件目标和背景的分割。且这两种方法计算较复杂，不适合图像处理实时性要求，所以提取目标区域阶段不采用这两种方法。但是在特征提取时，可以使用这两种方法提取零件的细节特征。

同时通过分析可以发现基于阈值选取的分割方法对于目标与背景有较强对比度的图像，其应用特别有效。触点类零件由金属制成，在视觉检测中其图像较亮，对应的灰度值较大，所以可以将检测背景设置成较暗的颜色，例如黑色，与零件本身灰度值形成较强的对比度，此时目标内部灰度分布较一致，背景在另一个灰度级上也分布一致，利用阈值可以将目标与背景分割得很好。而且阈值分割法一旦确定阈值，其处理速度非常快，适合在线检测的实时性要求。

综上，系统采用基于阈值选取的图像分割方法。

3.3.2 图像分割阈值的自适应选择

用阈值法分割图像的关键在于阈值的选择。选择太低的阈值，会有过多的背景或噪声被误认为目标；阈值选择太高，会有一些真实物体图像被消去。由于：零件检测方位不固定，导致零件表面光照度的不固定性；本系统需要适用于各种触点零件，其金属材质、表面纹理都不固定，相应的灰度值不固定；工作环境变化等造成的影响，所以很难选取固定的先验阈值，所以采用自动选取阈值的算法。

经典的阈值选取以灰度直方图为处理对象，经过对背景的设置，检测过程中的图像其灰度直方图有两个较大的波峰，其中一个波峰及其周围概率较大的灰度为背景色灰度，另一个波峰为零件灰度，选择两峰之间的谷值作为阈值，便可以将目标与背景分开。图 3-3 是原始图像经过高斯滤波后的图像（图 3-2）的灰度直方图，其中图 a 是原始灰度直方图，图 b 是将图 a 中底部数据放大以后的直方图，以便于观察分别代表背景和零件的灰度波峰之间的谷地区域。图中可以看出背景和零件图像的灰度区别，使其分开的界限大概在 30~60 灰度值之间。

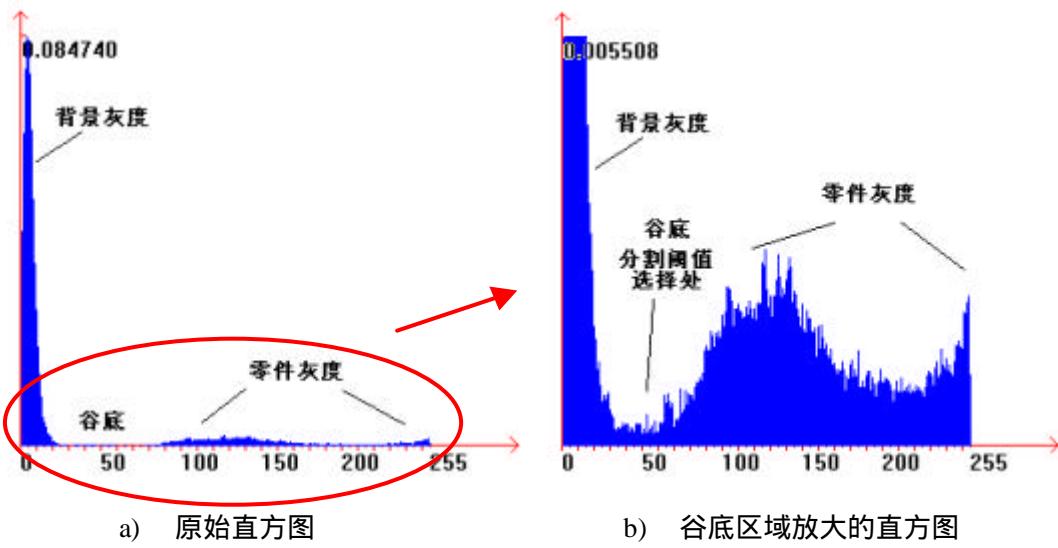


图 3-3 零件图像直方图

Fig.3-3 Component's image histogram

阈值的选取方法有很多种：

1. 极小值点阈值

极小阈值点的方法是以图像的灰度直方图为依据的，将灰度直方图的包络看作是一条曲线，选择该曲线的极小值点作为阈值。设有直方图 $h(z)$ ，则 $h(z)$ 的极值点应满足：

$$\frac{\partial h(z)}{\partial z} = 0 \quad \text{且} \quad \frac{\partial^2 h(z)}{\partial z^2} > 0 \quad (3-1)$$

满足上式的灰度值 z 即可作为分割阈值 $T^{[46]}$ 。

这个方法虽然简单，但是当图像中不同区域对应的灰度值往往互相重叠，或者存在较多的噪声，造成实际直方图有很多起伏时，可能会造成虚假阈值。

在本系统中由于待检零件形貌复杂多样，且实际生产线上图像受各种外界影响较大，容易引起图像直方图的多峰谷，计算出的极小值点可能对应虚假谷点，这使得极小值点分割法划分零件和背景的可靠性不高。

为了减弱噪声的影响，除了对图像本身进行去噪滤波，这里提出一种改进的极小值点方法 对灰度直方图进行平滑处理，减少直方图中的毛刺现象(如图 3-3 所示)，如使用高斯函数和直方图卷积平滑直方图，再找出新直方图中的极小值点作为阈值。

2. 最优阈值

图像的直方图表达了像素灰度值的概率分布密度函数，即代表了图像中包含的目标和背景两类区域的混和概率密度，也就是目标和背景的两个单峰分布密度函数之和。从统计的角度，若已知密度函数形式，就可以找到一个最优阈值，使误分割

概率最小^[46]。因为该方法要求已知背景和目标物像素出现的先验概率及灰度分布，现实中无法实现，一般通过直方图来估计这些参数，并且需假定其分布方式，使理论式和实际直方图中的均方误差为最小。确定这些参数是一件困难的事情，只能通过例如共轭梯度或者牛顿法等数学求解方法解得。这种方法运算繁琐，且现实中的灰度分布多变，假定其分布方式并不准确，考虑到系统实时性与可靠性，不采用此种方法求取自适应阈值。

3. 迭代阈值

通过迭代方法求出分割最佳阈值，具体实现步骤如下：

(1) 求出图像中最大和最小灰度值 t_1 和 t_k ，求出其平均值作为初始阈值

$$T^0 = \frac{t_1 + t_k}{2}$$

(2) 根据阈值 T^k 将图像分割成目标物 0 和背景 B 两部分，再求出这两部分的平均灰度值 t_O 和 t_B 。

$$\left\{ \begin{array}{l} t_O = \frac{\sum_{t(i,j) > T^k} t(i,j) \times N(i,j)}{\sum_{t(i,j) < T^k} N(i,j)} \\ t_B = \frac{\sum_{t(i,j) < T^k} t(i,j) \times N(i,j)}{\sum_{t(i,j) > T^k} N(i,j)} \end{array} \right. \quad (3-2)$$

式中， $t(i,j)$ 为图像中 (i,j) 点的灰度值； $N(i,j)$ 为 (i,j) 的加权系数，一般为 1。

(3) 求出新的阈值 $T^{k+1} = \frac{t_O + t_B}{2}$ 。

(4) 如果 $T^k = T^{k+1}$ ，则迭代结束，否则 $k \leftarrow k + 1$ ，转到第 (2) 步继续迭代。

迭代方法求解阈值法比较简单，运算速度较快，具有一定的自适应性。

4. 最大类间方差阈值

最大类间方差法是一种自适应的阈值确定方法，简称 OTSU 法，它是在判决分析最小二乘法原理的基础上推导得出的。按图像的灰度特性，将图像分成背景和目标两部分。背景和目标之间的类间方差越大，说明这两部分区别越大，当有部分目标或者背景被错分的时候会导致方差变小，也就是说，使类间方差最大的分割意味着错分率最小^[47]。

设原始图像灰度级为 Z ，灰度直方图为 $h(z)$ ，按灰度级用阈值 t 划分为两类：

$C_0 = (0, 1, 2, \dots, t)$ 和 $C_1 = (t+1, t+2, \dots, Z-1)$ 。 C_0 和 C_1 的出现概率及均值分别为

$$\mathbf{w}_0 = P_r(C_0) = \sum_{z=0}^t h(z) = \mathbf{w}(t) \quad (3-3)$$

$$\mathbf{w}_1 = P_r(C_1) = \sum_{z=t+1}^{Z-1} h(z) = 1 - \mathbf{w}(t) \quad (3-4)$$

$$\mathbf{m}_0 = \sum_{z=0}^t \frac{zh(z)}{\mathbf{w}_0} \quad (3-5)$$

$$\mathbf{m}_1 = \sum_{z=t+1}^{Z-1} \frac{zh(z)}{\mathbf{w}_1} \quad (3-6)$$

类间方差为

$$\mathbf{S}_B^2 = \mathbf{w}_0 \mathbf{w}_1 (\mathbf{m}_1 - \mathbf{m}_0)^2 \quad (3-7)$$

所以最佳阈值 t^* 为

$$t^* = \arg \max_{0 \leq t \leq Z-1} \mathbf{S}_B^2 \quad (3-8)$$

5. 最大熵阈值

应用信息论中熵的概念，使选择的阈值分割图像目标区域、背景区域两部分灰度统计的信息量为最大。根据目标区域和背景区域的概率灰度分布得到两个区域熵，两个区域的熵相加为最大时，对应的灰度值就是最佳阈值。

设分割阈值为 t ，则目标 O 与背景 B 的概率相关的熵为

$$H(O) = \ln P_t + \frac{H_t}{P_t} \quad (3-9)$$

$$H(B) = \ln(1 - P_t) + \frac{H_{Z-1} - H_t}{1 - P_t} \quad (3-10)$$

其中

$$P_t = \sum_{z=0}^t h(z) \quad (3-11)$$

$$H_t = - \sum_{z=0}^t [h(z) \ln h(z)] \quad (3-12)$$

$$H_{Z-1} = - \sum_{z=0}^{Z-1} [h(z) \ln h(z)] \quad (3-13)$$

两个熵值相加为

$$Y(t) = H(O) + H(B) \quad (3-14)$$

使 $Y(t)$ 最大的灰度值 t^* 即是所求的最优阈值

$$t^* = \arg \max_{0 \leq t \leq Z-1} \mathbf{y}(t) \quad (3-15)$$

图 3-4 是 3 种零件的图像(像素数为 300*250)及其底部经过放大的灰度直方图 , 其中零件图像都经过去噪预处理。从图中可以看到 , 零件 1、2 由于表面纹理色差较大 , 灰度直方图中有多个波谷 ; 零件 2、3 图像中没有很亮的区域 , 直方图中灰度值较高的地方取值很小 ;3 种零件的直方图中背景灰度值占比重大 , 零件本身灰度值占比重小 , 且直方图中都有较多毛刺。

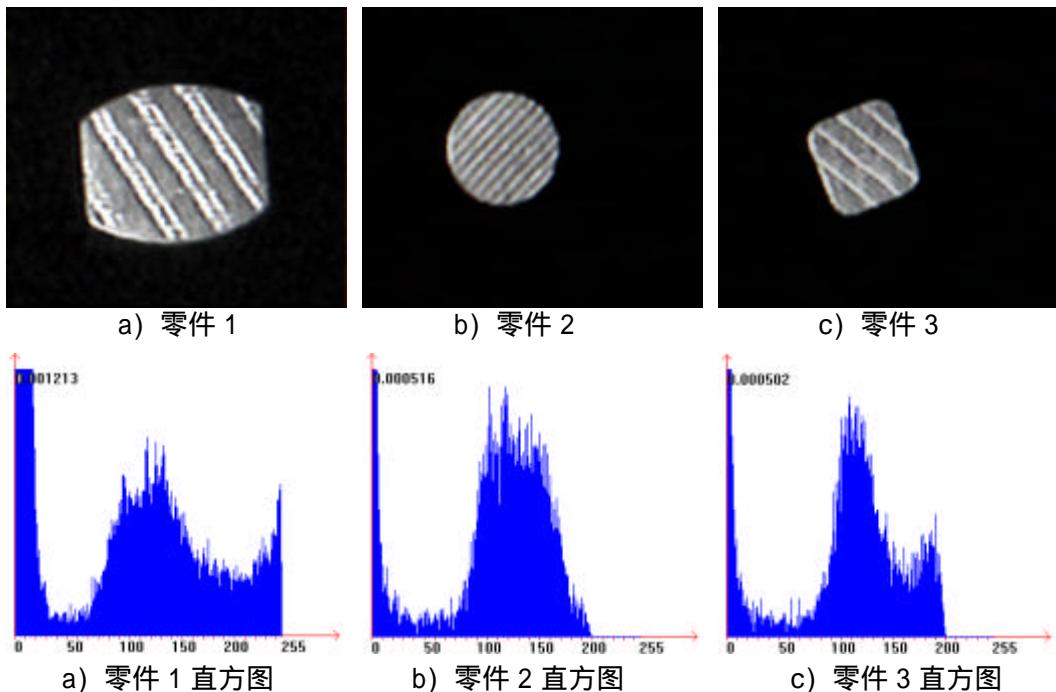


图 3-4 3 种零件及其直方图

Fig.3-4 3 components' images & histograms

本文使用以上几种方法 , 分别对3种零件图像进行了阈值计算试验 , 其中改进的极小值点法采用了高斯函数的5点逼近模板进行直方图平滑。试验结果如表3-2所示 , 其中运算时间采用10次运算平均时间 , 试验条件为本论文中的通用试验条件。

从表中可以看出 , 极小值点法在选取零件2图像阈值时找到了灰度值覆盖不高的高亮灰度区 , 确实容易受到虚假谷点的影响 ; 迭代法和最大类间方差法选取的阈值较大 , 其抗噪声能力较强 , 但同时也极易丢失零件图像的细节特征 ; 最大熵法则与迭代法、最大类间方差法相反 , 选取的阈值较小 , 保留了细节特征的同时也留下过多的噪声 ; 而改进的极小值点法较好地克服了极小值点法的缺点 , 其选择的阈值基本都对应了灰度直方图中的谷底位置 , 分割效果好 , 实时性也很高。综合以上试验和分析 , 系统决定采用改进的极小值点法选择零件图像的自适应分割阈值。

表 3-2 自适应阈值分割方法试验结果

Table 3-2 Image segmentation results of adaptive threshold methods

阈值选取方法	图像 1 阈值	图像 2 阈值	图像 3 阈值	时间 (ms)
极小值点法	50	209	26	1
改进的极小值点法	51	43	58	1.5
迭代法	81	68	69	3
最大类间方差法	83	70	70	1
最大熵法	20	6	5	3.5

另外，针对触点零件的成像情况，系统可以把阈值选取的范围限制在 10 ~ 200 之间，这样既可以缩短阈值选择的时间，也可以降低遇到虚假谷点的概率，提高改进最小极点法的可靠性。

3.3.3 多幅图像中值法确定检测阈值

上一小节中讨论的图像阈值自适应选择是为了适应不同零件种类和检测环境的阈值分割，但是在同一检测环境下的同一种类零件图像却应该采用同样的阈值，因为不仅有缺陷的零件和合格零件之间的灰度分布有区别，合格零件之间也有差异，其灰度分布也会有不同，如果因为图像灰度分布的变化而改变每幅图像的分割阈值，处理后的图片就不能起到对比的作用。另外，采用同样的阈值还可以提高检测的实时性。

对于同种类零件图像的分割阈值，可以通过系统对样本零件的学习过程来确定。利用上一小节中的自适应方法对样本中的多幅合格零件图像进行阈值选择，综合这些阈值信息并选用最适合此类零件的分割阈值。这里采用中值法来确定最终统一的阈值，可以避免极小值点法可能会出现的一些虚假阈值的影响：首先利用上一小节中的改进极小点法求出每个样本零件图像的自适应阈值，统计所有样本的阈值，找出“中值”作为最终检测阈值。

$$T = \text{medium}\{T_0, T_1, \dots, T_N\} \quad (3-16)$$

其中 N 为合格样本零件数。

经过对合格样本零件图像的一系列阈值选择和确定，最终确定了每一种零件的检测阈值，在实际流水线检测过程中，只需直接采用学习过程中已经确定的阈值对检测图像进行分割处理，可以实现很高的准确性和实时性。

3.4 图像特征提取

图像经过预处理及分割处理后，零件图像即目标图像已经从背景中提取出来。但是图像的表示仍然是各个像素的灰度值，其描述处于一个高维表达空间，计算机很难对其进行识别学习。为了便于计算机理解和分析图像，必须把图像描述降到低维空间。图像特征是指图像中可用作标志的属性，图像特征提取就是通过映射或变换的方法用低维空间来表示样本的过程。

3.4.1 特征空间的选择

本检测系统中需要针对不同规格的零件，事先无法确定选取哪些特征作为判断依据，所以在最开始对样本零件进行学习及构建特征数据库的过程中，特征的全面性是必要的，以免漏掉一些重要的判据特征。但是在线检测的实时性要求很高，所以进行特征空间的选择时，需要按照以下几个原则：

1. 应该选择图像中显著的特征。所谓显著的特征通常是指在图像中更容易辨别处理的有意义的一些特殊像素。
2. 应该选择容易从上一个处理步骤结果中得到的特征，减少计算复杂度，提高算法运行效率。
3. 应该选择对传感器噪声和其他变形敏感度低的特征（如亮度、不变矩等）。
4. 应该选择在识别过程中具有更小计算代价的特征，以提高算法的实时性。
5. 应该选择在类之间具有足够多的对应性和一致性的特征。

特征包括很多方面，如：频域特征、灰度特征、边缘特征、颜色特征、纹理特征、几何形状特征、拓扑特征、以及结构特征等。其中针对触点零件外观形貌检测，最直观的特征是几何形状特征、纹理特征和边缘特征；灰度特征作为一种统计特征应用广泛，其通用性好；颜色特征针对彩色图像，在试验阶段系统采用黑白图像，不需要颜色信息；提取结构特征时，结构元的选取十分重要，但是触点零件形状多样，事先无法选取合适的结构元；频域特征和拓扑特征计算相对复杂，对触点零件图像的意义也不直观，可以适当选取一些简单特征。

综上，本系统主要提取的特征包括：灰度特征、几何形状特征、纹理特征、边缘特征，以及一些简单的频域特征和拓扑特征。下面分别介绍系统中采用的各种特征。

3.4.2 灰度特征

灰度分布的特征参数直接和图像象素的灰度值相关，比较容易得到。

1. 灰度平均值

$$\overline{t(m,n)} = \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} t(m,n) \quad (3-17)$$

上式是图像整体范围内的灰度平均值，零件区域内的灰度平均值则如下式

$$\overline{t(m,n)}' = \frac{1}{A} \sum_{(m,n) \in A} t(m,n) \quad (3-18)$$

式中，A 代表了零件区域面积。

2. 灰度标准差

整体和零件区域内的灰度标准差分别为

$$s = \left(\frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} [t(m,n) - \overline{t(m,n)}]^2 \right)^{1/2} \quad (3-19)$$

$$s' = \left(\frac{1}{A} \sum_{(m,n) \in A} [t(m,n) - \overline{t(m,n)}']^2 \right)^{1/2} \quad (3-20)$$

3.4.3 几何特征

几何特征作为目标物特征中的重要参数，对于图像识别分类与理解有重要作用。

以下是几种最典型的几何特征：

1. 区域面积

面积是物体总尺寸的一个方便的度量，面积只与该物体的边界有关，而与其内部灰度级的变化无关。在数字图像中，区域面积可定义为区域内所包含的像素个数。对于已经经过预处理的触点零件图像，在图像分割时背景灰度值处理为 0，零件面积就是所有灰度值不为 0 的像素个数。

$$A = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f(m,n) \quad (3-21)$$

式中 $f(m,n) = \begin{cases} 0 & t(m,n) = 0 \\ 1 & t(m,n) \neq 0 \end{cases}$ ， $t(m,n)$ 为图像中 (m,n) 点的灰度值。

2. 区域周长

在数字图像中，基于 8 连通的周界，其水平和垂直方向上相邻的两像素点之间

的距离可看为 1，对角方向上相邻的两像点的距离为 $\sqrt{2}$ ，那么曲线长度就等于按上述定义的两点距离逐点累加。当区域边界曲线闭合时，长度即为区域边界周长。对于触点零件图像，其边界一定是闭合的，可以求出零件的周长。

$$P = \sum_{i=1}^M l_i \quad (3-22)$$

式中， $l_i = \begin{cases} 1 & \mathbf{e}_i = 0, 2, 4, 6 \\ \sqrt{2} & \mathbf{e}_i = 1, 3, 5, 7 \end{cases}$ ， $\mathbf{e}_i (i = 0, 1, \dots, 7)$ 代表 8 键码中 8 个方向的码元。

3. 区域质心

由于目标物在图像中总有一定的面积大小，面积中心就是单位面积质量恒定的相同形状图形的质心。对于 $M \times N$ 的数字图像，其质心坐标定义为：

$$\begin{cases} \bar{m} = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N m f(m, n) \\ \bar{n} = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N n f(m, n) \end{cases} \quad (3-23)$$

式中 $f(m, n) = \begin{cases} 0 & t(m, n) = 0 \\ 1 & t(m, n) \neq 0 \end{cases}$ ， $t(m, n)$ 为图像中 (m, n) 点的灰度值。

在触点零件图像中，零件位置不固定，质心特征不作为直接特征，但是它是计算平均半径、半径标准差等的参数，所以也是需要提取的间接特征。

4. 区域平均半径

$$\mathbf{m}_R = \frac{1}{K} \sum_{k=0}^{K-1} \|(m_k, n_k) - (\bar{m}, \bar{n})\| \quad (3-24)$$

式中， $(m_k, n_k), k = 0, 1, \dots, K-1$ 位于区域的周界 P 上。

5. 区域半径标准差

$$s_R = \left(\frac{1}{K} \sum_{k=0}^{K-1} \|(m_k, n_k) - (\bar{m}, \bar{n})\| - \mathbf{m}_R \right)^2 \quad (3-25)$$

6. 区域圆形度^[14]

圆形度用来刻画物体边界的复杂程度，本系统采用 3 种圆形度测量。

(1) 致密度 C

致密度又称复杂度，也称分散度，其定义为区域周长 (P) 的平方与面积 (A) 的比：

$$C = \frac{P^2}{A} \quad (3-26)$$

致密度描述了区域单位面积的周长大小。致密度大，表明单位面积的周长大，即区域离散，为复杂形状；反之，致密度小，为简单形状。当图像区域为圆时， C 有最小值 $4p$ ；其他任何形状的图像区域， $C > 4p$ ，且形状越复杂， C 值越大。

(2) 圆形性

圆形性 (Circularity) C 是一个用区域 R 的所有边界点定义的特征量，即：

$$C = \frac{m_R}{s_R} \quad (3-27)$$

式中： m_R 为区域平均半径， s_R 为区域半径标准差。当区域 R 趋向圆形时，特征量 C 是单调递增且趋向无穷的，它不受区域平移、旋转和尺寸变化的影响。

(3) 面积与平均半径平方的比值

$$g = \frac{A}{m_R^2} \quad (3-28)$$

7. 区域球状性^[14]

球状性 (Sphericity) S 在二维情况下，定义为：

$$S = \frac{r_i}{r_c} \quad (3-29)$$

式中， r_i 代表区域内切圆的半径， r_c 代表区域外接圆的半径，两个圆的圆心都在区域质心上。当区域为圆时，球状性的值 S 达到最大值 1.0；而当区域为其他形状时，则 $S < 1.0$ 。 S 不受区域平移、旋转和尺度变化的影响。

8. 区域空间矩^[53]

(1) 二阶行矩

$$m_{mn} = \frac{1}{A} \sum_{(m,n) \in R} (m - \bar{m})^2 f(m,n) \quad (3-30)$$

(2) 二阶混合矩

$$m_{mn} = \frac{1}{A} \sum_{(m,n) \in R} (m - \bar{m})(n - \bar{n}) f(m,n) \quad (3-31)$$

(3) 二阶列矩

$$m_{nn} = \frac{1}{A} \sum_{(m,n) \in R} (n - \bar{n})^2 f(m,n) \quad (3-32)$$

式中， $f(m,n) = \begin{cases} 0 & t(m,n) = 0 \\ 1 & t(m,n) \neq 0 \end{cases}$ ， $t(m,n)$ 为图像中 (m,n) 点的灰度值。

3.4.4 纹理特征

纹理图像中灰度分布具有某种周期性，即便灰度变化是随机的，它也具有一定的统计特性。纹理是以像素的邻域灰度空间分布为特征，它可以反映图像像素颜色或亮度的空间分布的属性。

1. 粗糙度^[41]

粗糙度是最常用的纹理分析度量之一。粗糙的程度与局部结构的空间重复周期有关，周期大的纹理粗，周期小的纹理细。可以用粗糙度说明纹理变化的倾向。

用空间自相关函数作为纹理测定的方法如下：

$$C(\mathbf{e}, \mathbf{h}, j, k) = \frac{\sum_{m=j-w}^{j+w} \sum_{n=k-w}^{k+w} f(m, n) f(m - \mathbf{e}, n - \mathbf{h})}{\sum_{m=j-w}^{j+w} \sum_{n=k-w}^{k+w} [f(m, n)]^2} \quad (3-33)$$

它是对 $(2w+1) \times (2w+1)$ 窗口内的每一像素 (j, k) 与偏移值 $\mathbf{e}, \mathbf{h} = 0, \pm 1, \pm 2, \dots, \pm T$ 的像素之间的相关值作计算。一般粗纹理区对给定偏移 (\mathbf{e}, \mathbf{h}) 时的相关性要比细纹理区高，因而纹理粗糙度与自相关函数的变化方向成正比。自相关函数的变化可以用二阶矩来描述，即

$$T(j, k) = \sum_{\mathbf{e}=-T}^j \sum_{\mathbf{h}=-T}^k \mathbf{e}^2 \mathbf{h}^2 C(\mathbf{e}, \mathbf{h}, j, k) \quad (3-34)$$

纹理粗糙度和 T 成正比，因此，可以用 T 作为度量粗糙度的一种参数。

2. 灰度差分统计^[41]

灰度差分统计法是纹理分析最常见的方法。首先设图像中某点为 (x, y) ，它与距它的距离较短的点 $(x + \Delta x, y + \Delta y)$ 的灰度差值为

$$g_\Delta(x, y) = g(x, y) - g(x + \Delta x, y + \Delta y) \quad (3-35)$$

其中 $g_\Delta(x, y)$ 称为灰度差分。通过将点 (x, y) 在整幅图片上遍历，得到各点的 $g_\Delta(x, y)$ ，设灰度差分值可取 m 级，则计算出取各个数值的次数，这样就可以绘出直方图，最后根据直方图来确定取各值时对应的概率 $P_\Delta(i)$ 。

当 i 的值较小，对应的概率 $P_\Delta(i)$ 较大时，说明纹理粗糙；反之，说明纹理细密。

一般常见的统计量：

(1) 对比度

$$CON = \sum_i i^2 P_\Delta(i) \quad (3-35)$$

(2) 能量

$$ASM = \sum_i [P_\Delta(i)]^2 \quad (3-36)$$

(3) 平均值

$$MEAN = \frac{1}{m} \sum_i iP_\Delta(i) \quad (3-37)$$

(4) 熵

$$ENT = - \sum_i P_\Delta(i) \log P_\Delta(i) \quad (3-38)$$

上述各式中， $P_\Delta(i)$ 较平坦，则 ASM 较小， ENT 较大， $P_\Delta(i)$ 越分布在原点附近， $MEAN$ 越小。

3. 等灰度游程长度^[42]

灰度游程长度是指在某方向 q 上连续、共线并有相同灰度级的像素个数。在粗纹理区域的灰度游程长度较长，而细纹理区域短游程长度的情况较多。一般将等灰度游程长度的分析方法用在线形结构的纹理上。

对于某个可以计算灰度的游程矩阵 M^q ，设其第 g 行，第 l 列的元素 m_{gl} 表示图像在 q 方向上灰度为 g ，游程长度为 l 的灰度串出现的总次数（包括灰度点本身）。设 N_g 为图像的灰度级别， N_l 为图像的灰度游程数，则纹理描述可用的矩阵统计量有：

(1) 短游程因子

$$RF1 = \left[\sum_{g=1}^{N_g} \sum_{l=1}^{N_l} (m_{gl} / l^2) \right] / \left[\sum_{g=1}^{N_g} \sum_{l=1}^{N_l} m_{gl} \right] \quad (3-39)$$

式中， m_{gl} / l^2 说明对短游程赋予大的加权值，短游程的数目越多，则 $RF1$ 值越大，分母是进行归一化处理。

(2) 长游程因子

$$RF2 = \left[\sum_{g=1}^{N_g} \sum_{l=1}^{N_l} (m_{gl} l^2) \right] / \left[\sum_{g=1}^{N_g} \sum_{l=1}^{N_l} m_{gl} \right] \quad (3-40)$$

式中， $m_{gl} l^2$ 说明对长游程赋予大的加权值，长游程的数目越多，则 $RF2$ 值越大。

(3) 灰度的不均匀因子

$$RF3 = \left[\sum_{g=1}^{N_g} \left(\sum_{l=1}^{N_l} m_{gl} \right)^2 \right] / \left[\sum_{g=1}^{N_g} \sum_{l=1}^{N_l} m_{gl} \right] \quad (3-41)$$

如果图像中各灰度的游程长度接近均匀分布，则 $RF3$ 取最小值，也就说明整个

图像的灰度分布并不均匀。如果图像中某种游程出现较多，即灰度都比较均匀，则 RF3 的值就越大。

(4) 游程长度的不均匀因子

$$RF4 = \left[\sum_{l=1}^{N_g} \left(\sum_{g=1}^{N_s} m_{gl} \right)^2 \right] / \left[\sum_{g=1}^{N_g} \sum_{l=1}^{N_s} m_{gl} \right] \quad (3-42)$$

如果图像中各灰度的游程长度接近均匀分布，说明灰度游程长度的长短并不均匀，此时 RF4 有最小值。如果图中某种游程长度出现较多，说明各游程长度比较一致，此时 RF4 的值也越大。

(5) 游程总数的百分比

$$RF5 = \left(\sum_{g=1}^{N_s} \sum_{l=1}^{N_s} m_{gl} \right) / P \quad (3-43)$$

式中，P 是图像中像素的总个数，代表的是游程长度为 1 的总游程数；RF5 是直接反映线形结构纹理的一个度量，因为图中具有长线性结果纹理，则具有长游程的灰度会增加，短游程长度相对减少，对于 RF5 的值也越小。

4. 傅里叶功率谱^[52]

图像中变化较快的细小特征（即细纹理）对应于频率域的高频部分，而变化较慢的粗大特征（粗纹理）对应于图像的低频成分，因此，图像频率域的频率成分及频率方向能够反映图像纹理的粗糙程度及其纹理密度与方向的变化，即频率也是图像纹理的一种测度。傅立叶变换的频率可由其功率谱来反映，所以功率谱可以作为描述图像纹理特征的一种测度。

$F(u, v)$ 是图像函数 $f(x, y)$ 的傅里叶变换，傅里叶功率谱计算公式为

$$P(u, v) = (\text{Re}(F(u, v))^2 + \text{Im}(F(u, v))^2)^{1/2} \quad (3-44)$$

傅里叶功率谱的纹理特征参数包括水平方向能量、垂直方向能量、环形区域能量和扇形区域能量。由于触点零件的方向性必定，所以只采用环形区域与方向无关的频率带，环形区域能量为

$$E = \left(\sum_{(u,v) \in C_r} (P(u, v))^2 \right)^{1/2} \quad (3-45)$$

本文将功率谱分为 4 个环形区域，分别求出 4 个区域的能量值。

5. Laws 纹理能量^[52]

Laws 提出了纹理能量方法，度量一个大小固定的窗口内的变化量。用 9 个 5*5 的卷积模板计算纹理能量，模板根据以下的向量算出

$$\begin{aligned}
 L5(\text{水平}) &= [1 \ 4 \ 6 \ 4 \ 1] \\
 E5(\text{边缘}) &= [-1 \ -2 \ 0 \ 2 \ 1] \\
 S5(\text{点}) &= [-1 \ 0 \ 2 \ 0 \ -1] \\
 R5(\text{波纹}) &= [1 \ -4 \ 6 \ -4 \ 1]
 \end{aligned}$$

计算向量对的外积得到 2D 卷积模板。

Laws 过程的第一步是去除光照的干扰：通过在图像上移动一个小窗口，从每个像素中减去窗口的局部平均值，这样产生一副经过预处理的图像，其中每个领域的平均亮度值接近 0。然后用 16 个 5*5 的模板对预处理的图像进行滤波，得到 16 幅结果滤波的图像。设 $F_k[i, j]$ 是在像素 $[i, j]$ 处的第 k 个模板的滤波结果，那么对滤波器 k 的纹理能量 E_k 定义如下

$$E_k[r, c] = \sum_{i=r-7}^{r+7} \sum_{j=c-7}^{c+7} |F_k[i, j]| \quad (3-46)$$

一旦产生了 16 个能量，某些对称的则可以互相组合，最终产生 9 个能量，每一对用它们的平均值代替，这 9 个合成的能量是

$$\begin{array}{lll}
 L5E5/E5L5 & L5S5/S5L5 & L5R5/R5L5 \\
 E5E5 & E5S5/S5E5 & E5R5/R5E5 \\
 S5S5 & S5R5/R5S5 & R5R5
 \end{array}$$

3.4.5 边缘特征

边缘特征是重要的特征信息，边缘特征是图像上灰度不连续变化，或灰度剧烈变化所表现出的一类重要信息，它包含有物体形状的重要信息。边缘特征常常对应于目标的轮廓线或边界位置，或者对应纹理（或颜色）特性明显不同的两个区域的边界，或纹理内部细微结构之间的边界。系统采用边缘提取算子处理零件图像，提取图像边缘，再统计边缘特征。

1. 边缘面积

边缘面积定义为边缘点的个数

$$A_E = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f_E(m, n) \quad (3-47)$$

式中 $f_E(m, n) = \begin{cases} 0 & e(m, n) = 0 \\ 1 & e(m, n) \neq 0 \end{cases}$ ， $e(m, n)$ 为边缘算子得出的 (m, n) 点值。

2. 边缘密度

区域单位面积内边缘点的个数

$$r_E = A_E / A \quad (3-48)$$

其中 A 为零件区域面积。

3. 边缘均值

$$m_E = \frac{1}{A_E} \sum_{k=0}^{A_E-1} e(m_k, n_k) \quad (3-49)$$

4. 边缘标准差

$$s_E = \left(\frac{1}{A_E} \sum_{k=0}^{A_E-1} [e(m_k, n_k) - m_E]^2 \right)^{1/2} \quad (3-50)$$

3.4.6 其他特征

1. 拓扑特征^[46]

拓扑特征是对图像中区域结构形状的总体描述。它的特点是不受“橡皮被单”式畸变的影响，即当图像由于拉伸、压缩、扭曲等而变形时，拓扑特征不变，但不能有撕裂和折叠。常用的拓扑特征有：

(1) 连通分量个数 C

(2) 孔的个数 H

(3) 欧拉数 E = C - H

2. 频域特征

傅里叶频率谱特征已在纹理特征中提及，这里不再介绍。

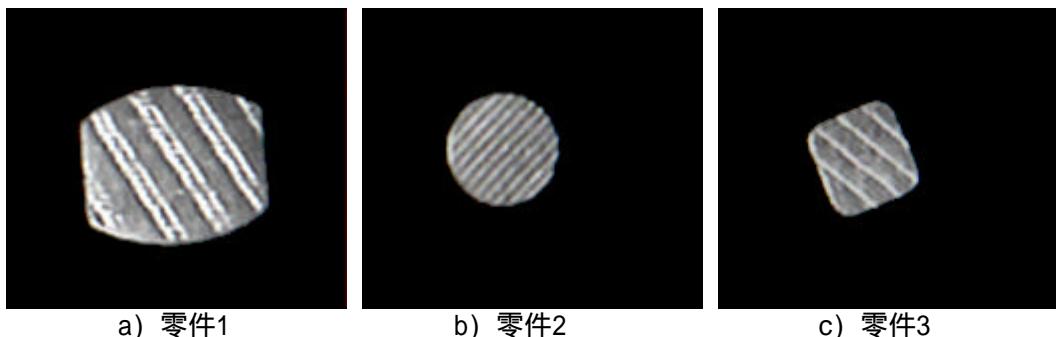


图 3-5 3 种零件阈值分割处理图像

Fig.3-5 3 components' images after threshold segmentation

图3-5是对图3-4中零件图像进行阈值分割处理后的图像，分别提取上述5大类图像特征，检测结果如表3-3所示，其中运算时间采用10次运算平均时间，试验条件为

本论文中的通用试验条件。

表 3-3 触点零件图像特征值

Table 3-3 Image features' values of contact components

特征	零件 1 特征值	零件 2 特征值	零件 3 特征值	时间(ms)
灰度特征				
图像灰度平均值	13.3289	4.55412	4.10993	< 1
零件区域灰度平均值	153.019	133.421	135.671	1
图像灰度标准差	44.0898	24.6119	23.7509	3
零件区域灰度标准差	52.9454	33.7578	36.2355	1.5
几何特征				
零件面积	6533	2560	2272	< 1
零件周长	310.738	189.324	186.738	1.5
零件质心 (间接特征)	(145.2, 131.0)	(114.7, 139.0)	(107.0, 160.3)	< 1
零件平均半径	45.2821	28.0961	26.5035	1
零件半径标准差	3.7781	0.3846	2.1124	1.5
圆形度 1	14.7801	14.0014	15.3482	3
圆形度 2	11.9854	73.0519	12.5465	2
圆形度 3	3.1861	3.2430	3.2345	1.5
球状性	0.7509	0.9186	0.7582	1
二阶行矩	630.814	202.766	178.034	2
二阶混合矩	18.9067	1.1970	-5.5722	2
二阶列矩	437.493	204.827	192.53	2
纹理特征				
粗糙度	1.5538	3.4724	5.3773	15
对比度	0.9408	0.9767	0.9787	13
能量	0.8999	0.9558	0.9608	13
熵	0.3271	0.1297	0.1170	13
平均值	0.6355	0.1798	0.1933	13
短游程因子	4.7632	47.8653	35.6868	27
长游程因子	78.5738	3.6784	9.4568	27
灰度不均匀因子	87.4784	35.5724	56.4573	24
游程长度不均匀因子	44.8593	5.6583	4.5721	24
游程总数百分比	0.8463	0.7654	0.6826	21
傅里叶功率谱能量 1	79.4	53.22	56.34	17
傅里叶功率谱能量 2	2.24	5.23	2.63	17

表 3-3 触点零件图像特征值 (续表)

Table 3-3 Image features' values of contact components (continued)

傅里叶功率谱能量 3	2	2.65	1.34	17
傅里叶功率谱能量 4	1.78	0.45	0.57	17
LawsE5E5	676.132	667.072	465.508	34
LawsS5S5	62.564	64.447	56.565	34
LawsR5R5	84.689	104.723	91.515	34
LawsE5L5	3660.116	1874.017	2753.510	34
LawsS5L5	1088.422	1176.902	965.907	34
LawsR5L5	658.151	533.171	555.976	34
LawsS5E5	170.988	119.369	151.953	34
LawsR5E5	107.309	115.558	104.410	34
LawsR5S5	49.490	58.138	51.492	34
边缘特征				
边缘面积	2358	975	792	19
边缘密度	0.3609	0.3809	0.3486	19.5
边缘均值	43.5249	40.5008	37.8228	19.5
边缘标准差	36.4953	27.1015	35.6257	20.5
其他特征				
拓扑连通分量个数	1	1	1	4
拓扑孔的个数	0	0	0	4
拓扑欧拉数	1	1	1	5

3.5 本章小结

本章主要研究了触点形貌在线自适应学习视觉检测系统中涉及的图像处理技术。根据系统实时性和准确性的要求，首先分析了各种图像滤波方法，研究了基于高斯滤波模板的快速有效图像预处理方法；针对触点零件图像特点提出了一种基于改进极小值点的自适应阈值分割算法和多图中值阈值确定算法，实现了快速分割零件目标图像和背景；并研究了各种图像特征，构建了 5 大类图像特征库，共包含 45 个特征。

第四章 实现学习功能的模式识别技术

4.1 模式识别概述

模式识别是一门从应用中发展而来的学科，目的是将对象进行分类。在计算机视觉中，模式识别是非常重要的。计算机视觉系统通过成像系统捕捉图像，然后通过分析生成图像的描述信息。如何根据这些信息对目标进行分类识别，例如将生产线上的产品分为“合格”和“不合格”，使生产线可以根据分类结果采取相应的行动，这就是模式识别的主要工作。

模式识别在不同的文献中给出的定义不同。一般认为，模式是通过对具体的事物进行观测所得到的具有时间与空间分布的信息，模式所属的类别或同一类中模式的总体称为模式类，其中个别具体的模式往往称为样本。模式识别就是研究通过计算机自动地（或者人为进行少量干预）将待识别的模式分配到各个模式类中的技术^[48]。

根据有无标准样本，模式识别可分为监督识别方法和非监督识别方法^[48~50]。

1. 监督识别方法是在已知训练样本所属类别的条件下设计分类器，通过该分类器对待识别样本进行识别的方法。标准样本集中的样本经过预处理、选择与提取特征后设计分类器，分类器的性能与样本集的大小、分布等有关。待检样本经过预处理、选择与提取特征后进入分类器，得到分类结果或识别结果。

2. 非监督模式识别方法是在没有样本所属类别信息的情况下直接根据某种规则进行分类决策。这种情况下，给定一组特征向量来揭示潜在的相似性，并且将相似的特征向量分为一组，称为聚类。

应用于图像处理中的模式识别方法大多为有监督模式识别法，例如人脸检测、车牌识别等。无监督的模式识别方法主要用于图像分割、图像压缩、遥感图像的识别等。

本系统检测中，需要实现各种缺陷情况统计的功能，以便于生产线上加工工艺的改进，因此样本零件的类别信息十分重要，在学习阶段必须明确指出其类别，即是模式识别中有监督的识别方法。监督识别方法主要涉及的内容包括特征选择、特征优化及分类器的设计。

另外，在本系统的模式识别中，学习阶段的实时性要求不如检测阶段的要求高，实时性对特征选择、特征优化及设计分类器的过程并不十分重要，但是学习阶段得出的方案必须能够快速分类，这影响到检测阶段的实时性。这也是本章重点研究的问题之一。

4.2 特征预处理

触点零件的情况多变，而图像处理阶段虽然已经对各种噪声进行了一定的处理，但是去噪后图像特征情况仍存在不确定性，各种特征值的数值范围也不同，所以在选择特征前，应该对特征本身进行预处理。

4.2.1 剔除离群点

离群点的定义是与相应随机变量的平均值距离很远的点。图像处理阶段由于噪声的存在，可能影响最后的特征结果，偏离特征的中心值。在模式识别训练学习阶段，远离中心值的点可能造成较大误差，甚至可能带来灾难性的后果。所以系统在预处理阶段，首先应将类内远离中心点的离群点剔除。

离群点到平均值的距离标准由给定的阈值来度量，通常是标准差的整数倍。对于正态分布随机变量，标准差的 2 倍距离内包含了 95% 的点，3 倍距离内包含了 99% 的点^[50,51]。所以，如果离群点非常少，就可以使用标准差将其剔除。但是，如果特征具有其他分布（如长尾分布），就不能贸然用标准差标准剔除特征点。因此，本系统在剔除离群点时，先采用标准差的 2 倍作为标准，如果 2 倍标准差距离外的点数量少于总数的 5%，则认为这些点是离群点加以剔除，否则保留这些特征点。

4.2.2 数据归一化

各种特征值具有不同的动态范围，在计算各种指标时，大值特征比小值特征的影响更大。但是，在分类器设计中，这并不能反映它们所具有的重要程度。将特征数据归一化可以解决这个问题，从而使它们位于相似范围。

归一化方法分为线性方法和非线性方法。在对触点零件图像特征作预处理阶段，不宜改变特征数据原始的分布特性，以免对后续特征选择造成影响，所以采用线性方法。由于特征的实际均值和标准差事先无法知道，所以使用已知样本图像的特征统计值作为估计值做归一化，对于第 k 个特征的 N 个数据，有

$$\begin{aligned}
 \bar{x}_k &= \frac{1}{N} \sum_{i=1}^N x_{ik}, \quad k = 1, 2, \dots, l \\
 s_k^2 &= \frac{1}{N-1} \sum_{i=1}^N (x_{ik} - \bar{x}_k)^2 \\
 \hat{x}_{ik} &= \frac{x_{ik} - \bar{x}_k}{s_k}
 \end{aligned} \tag{4-1}$$

所有归一化后的特征具有零均值和单位方差。

这里需要特别指出的是，剔除离群点的处理对象是类内特征，目的是使类内致密度更高；而归一化的处理对象则是一种特征在零件合格类和缺陷类中的全部特征值，得出特征在类间的分布，对于不同的缺陷类和合格类之间要分别给出归一化的值。两种方法的处理目的不同，所以对象范围也不同。

4.3 特征选择

系统在图像处理阶段，为了达到较高的识别率和识别可靠性，提取大量的特征，以利于找出最有效的特征。但这并不意味着特征选的越多越好，各个特征的物理意义有时不是很直观，往往很难看出各个特征对分类的影响，有的特征可能无助于分类器的设计，甚至会降低分类器的性能。同时，过多的特征会导致所谓的维数灾难，使得设计分类器的计算复杂度很高。另外，对于在线检测系统来说，检测阶段提取特征过多不能满足系统的实时性要求。

因此必须在这些特征中选出最适合分类器设计的特征。换句话说，特征选择就是以某种分类判别规则为准则，从一组特征中选择一些对分类贡献较大、最有效的特征，删除贡献较小的特征。经过特征选择，特征空间维数被压缩，如果选择了具有充分辨别类别信息的特征，还将极大地简化分类器的设计。

特征选择主要考虑的内容是选择多少个特征以及选择哪些特征。所谓“好”的特征是指在特征向量空间中，类间距离大而类内方差小的特征，也就是说，不同类间的特征量距离较远，而同一类内的特征值致密聚集。图 4-1 给出了不同位置和不同类内方差的三种情况，其中最好的情况是类间距离大、类内方差小的情况（如图 c 所示），最坏的情况反之（如图 b 所示）。

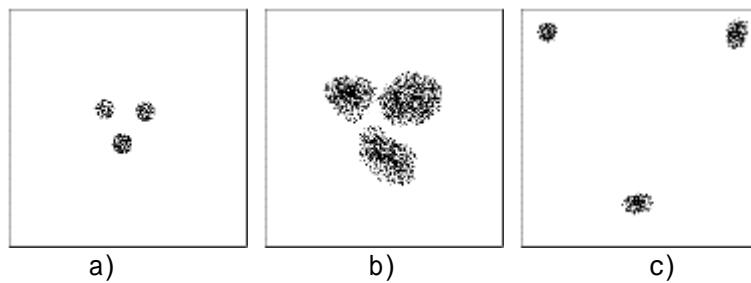


图 4-1 类分布的三种情况
 a) 类内方差小、类间距离小的类
 b) 类内方差大、类间距离小的类
 c) 类内方差小、类间距离大的类
 Fig.4-1 Category distribution situations

4.3.1 基本选择方法分析

选择特征子集的基本方法有两类^[50]：

1. 标量特征选择

每个特征被单独处理，按照任意类可分性测量标准，计算每一个特征的准则值，排列顺序，选择其中准则值最好的几个特征来生成特征向量。标量特征选择方法具有计算简单的优点，然而这种方法没有考虑特征之间存在的相互关系，对于复杂的问题和高相关性的特征没有效果。

2. 特征向量选择

直接从特征中选择一些组成特征向量，计算特征向量的准则值，选择其中最好的一个特征向量作为分类特征。特征向量选择方法最主要的限制因素是计算量的开销，如果要找出最优的特征向量，则要用特征组成的所有可能的向量，对每一种组合使用可分性准则，再选出最好的特征向量组合。

在触点零件形貌检测中，往往存在多种缺陷，其分类情况较多，问题复杂度高，各个特征之间也不可避免存在一些联系，标量特征选择方法生成的特征向量很可能不能满足实际生产检测系统要求的分类能力。为了达到更高的分类准确性，系统采用特征向量选择方法作为特征子集选择的基本方法。

特征向量选择方法通过穷举法可以得到特征选择的最优解，本系统现共有 45 种特征，如果采用穷举法共需计算 $(2^{45}-1)$ 个特征向量，所以当特征个数比较多时，这种方法由于计算量太大而难以实现。现有不少搜索技术可以减小复杂度，如分支和定界算法、顺序前进法、顺序后退法、遗传算法、模拟退火算法等。

4.3.2 类可分性准则的选择

类可分性准则是度量一个特定的特征对于不同的类是否具有可分性的标准。最直接最有效的判据是计算分类器错误概率，但一般情况下，错误概率的计算很复杂，有时甚至无法计算。最简单的判据是用于可分性判据的类内类间距离判据，其基本原则是类内距离最小、类间距离最大的特征为最优特征，这一判据物理意义明显，计算方便，但是距离的定义不同，得到的特征不同。基于概率分布的可分性判据，这类判据计算比较复杂，也很难得到和错误概率的直接解析关系式^[48]。

现今常用的准则有如 ROC、FDR、发散性、熵函数、Chernoff 界、Bhattacharyya 距离和散布矩阵等等^[50~53]。其中 ROC、FDR、发散性和熵函数准则都是基于单个特征的度量准则；Chernoff 界和 Bhattacharyya 距离是基于特征向量的度量准则，但是都是基于概率分布判据的，除非假设为高斯分布，否则不容易计算。散布矩阵准则考虑在特征维数空间中特征向量样本分布的关系，是类内类间距离判据在特征向量选择方法中的应用，计算简单，符合系统的要求。

散布矩阵准则中，定义的矩阵有：

(1) 类内散布矩阵

$$S_w = \sum_{i=1}^M P_i S_i \quad (4-2)$$

其中 S_i 是 w_i 类的协方差矩阵

$$S_i = E[(\bar{x} - \bar{m}_i)(\bar{x} - \bar{m}_i)^T] \quad (4-3)$$

P_i 是 w_i 类的先验概率， $P_i \approx n_i / N$ ，其中 n_i 是 N 个总样本中属于 w_i 类的样本数。

S_i 是对称矩阵，所以 S_w 也是对称矩阵，它的迹 Tr （对角元素之和）是所有类的特征方差的平均测度。

(2) 类间散布矩阵

$$S_b = \sum_{i=1}^M P_i (\bar{m}_i - \bar{m}_0)(\bar{m}_i - \bar{m}_0)^T \quad (4-4)$$

其中 \bar{m}_0 是全局平均向量

$$\bar{m}_0 = \sum_{i=1}^M P_i \bar{m}_i \quad (4-5)$$

$Tr \{ S_b \}$ 是每一类的均值和全局均值之间平均距离的一种测度。

(3) 混合散布矩阵

$$S_m = E[(\bar{x} - \bar{m}_0)(\bar{x} - \bar{m}_0)^T] \quad (4-6)$$

即 S_m 是全局均值向量的协方差矩阵，可以推导出

$$S_m = S_w + S_b \quad (4-7)$$

$Tr\{S_m\}$ 是特征值关于全局均值的方差和。

散布矩阵准则中，衡量一个特征向量的好坏是基于类内类间距离，最优的特征向量应该满足类内方差小、类间距离大，所以得出散布矩阵准则值为

$$J = Tr\{S_w^{-1}S_m\} \quad (4-8)$$

J 值越大，特征向量的类可分性越好。

4.3.3 多类别特征子集的选择方法

触点零件形貌自动检测中，缺陷的种类是多样的，在选择特征子集的时候必须满足多类别的分类要求。散布矩阵准则可以实现特征向量对多类别分类能力的度量，但是多类别的准则值是对整体分类的综合度量，不能保证多类中某两类的分类能力。一些特征对某些特定分类特别有效，对大多数分类不敏感，例如触点零件的面积特征可以很好地分开合格类和缺角类，但是在纹理模糊、气泡、裂纹等缺陷类和合格类之间区别则不大，这类特征的多类准则值往往较低，因而被排除在特征子集之外。在触点零件检测系统中，第一位的是保证合格零件和不合格零件的分类，然后才是缺陷类别之间的分类，所以直接根据多类别的散布矩阵准则值决定特征子集不是最佳方案。如果分别针对多类中的两类，挑选对其分类能力强的特征子集，能够较好地保障各类之间的分类能力，但是多个特征子集覆盖的特征面较广，很可能无法满足在线检测系统的实时性要求。

针对这个问题，本文提出一种两类浮动搜索-多类后向选择的方法，其基本思想是：首先对两类问题进行特征子集选择，对特征子集中包含的所有特征进行统计，如果提取这些特征能够满足系统的实时性要求，特征子集选择结束；如果不能满足系统实时性要求，再评判特征的多类别分类能力，剔除特征，直到满足系统实时性要求为止。在剔除过程中，注意保留一些对特定分类特别有效的特征。这样在选择特征子集的过程中，最大限度地保留了对分类有效的特征，并满足了系统的实时性。其中，浮动搜索法和后向选择法都是特征向量选择的优化搜索方法，相对于穷举法减小了计算量，降低了复杂度。具体的实现过程如下：

(1) 两类浮动搜索法选择两类特征子集

浮动搜索法是一种特征相量优化搜索方法。首先任意选择两个类别，设其具有

m 个特征的样本集合，寻找其中最好的特征子集，使代价准则 J 最优。令 $X_k = \{x_1, x_2, \dots, x_k\}$ 是 k 个特征的最好组合集， Y_{m-k} 是其余 $m-k$ 个特征的集合。初始化特征向量 X_2 ， $k=2$ ，在以后每一步中，通过从 Y_{m-k} 中借用一个特征来形成第 $k+1$ 个最好子集 X_{k+1} ；然后转向以前选择的低维子集，检验包含新特征后是否改进了准则 J 。如果是，用新特征替换以前选择的特征。步骤如下：

Step1:

$$x_{k+1} = \arg \max_{y \in Y_{m-k}} J(\{X_k, y\}) \text{, 即从 } Y_{m-k} \text{ 中选择与最好 } J \text{ 值对应的特征, 它与 } X_k \text{ 组合,}$$

$$X_{k+1} = \{X_k, x_{k+1}\}.$$

Step2:

$$x_r = \arg \max_{y \in X_{k+1}} J(X_{k+1} - \{y\}) \text{, 即找到特征 } x_r \text{, 将它从 } X_{k+1} \text{ 中剔除时, 对代价影响}$$

最小;

如果 $J(X_{k+1} - \{x_r\}) \leq J(X_k)$ ，且 $J(X_{k+1}) \geq J(X_k)$ ，令 $k=k+1$ ，转向 Step1；

如果 $J(X_{k+1} - \{x_r\}) \leq J(X_k)$ ，且 $J(X_{k+1}) < J(X_k)$ ，选择结束，即移走 x_r 和新增加特征都不能提高以前选择的 k 个最好组的代价，就不需要继续搜索了；

如果 $k=2$ ，令 $X_k = X_{k+1} - \{x_r\}$ ， $J(X_k) = J(X_{k+1} - \{x_r\})$ ，转向 Step1。

Step3:

$$X_k' = X_{k+1} - \{x_r\} \text{, 即剔除 } x_r;$$

$$x_s = \arg \max_{y \in X_k'} J(X_k' - \{y\}) \text{, 即在新集合中找到最不重要的特征;}$$

如果 $J(X_k' - \{x_s\}) < J(X_{k-1})$ ，那么 $X_k = X_k'$ ，并转向 Step1，不再进行后向搜索；

令 $X_{k-1}' = X_k' - \{x_s\}$ ，并且 $k=k-1$ ；

如果 $k=2$ ，令 $X_k = X_k'$ ，并且 $J(X_k) = J(X_k')$ ，并转到 Step1；

转到 Step3。

(2) 检验两类特征子集的实时性

统计每个特征子集包含的特征，并计算所有特征的耗时，如果耗时累加值在系统实时性允许的范围内，特征子集选择结束；否则，继续下一步。

(3) 多类后向选择搜索方法剔除多余特征

后向选择搜索方法是一种从已有特征向量中剔除特征的优化搜索方法。其选择方法是找到特征 x_t ，将它从 X_k 中剔除时，对代价影响最小，即 $x_t = \arg \max_{y \in X_k} J(X_k - \{y\})$ ， $X_{k-1} = X_k - \{x_t\}$ 。可以看到这种方法在浮动搜索中已有涉

及。

如果直接综合多类别进行后向选择，也有可能会剔除对特定分类特别有效的特征。所以在综合多类别之前，必须标记这些特征，在后向选择中保留它们。找到这些特征的方法也采用后向选择方法，但并不是选择对代价影响最小的特征，而是对代价影响最大的，即 $x_b = \arg \min_{y \in X_k} J(X_k - \{y\})$ 。

除了这些特征外，对所有特征进行后向选择搜索，计算多类判断准则值，逐个剔除特征，直到提取特征耗时累加值满足系统实时性要求为止。

两类浮动搜索-多类后向选择方法可以在满足系统实时性要求的情况下，最大限度地保留对分类有用的特征。但是该方法为了更好地保留对特定分类有效的特征，没有直接采用多类特征选择方法，而是以增加计算复杂度为代价，先对两类特征进行选择，再进行多类特征剔除。不过系统在学习阶段的实时性要求并不太高，可以牺牲一些时间来提高性能。

4.4 特征优化

系统选择出适合分类器设计的特征子集后，虽然已经压缩了特征空间，但是对于分类器来说，往往特征数量越少，设计分类器越容易。特征优化即是在保留特征子集信息的同时，通过映射变换等方法对特征子集进一步优化压缩，便于分类器设计的过程。

特征优化的关键在于消除特征之间存在互相关性和自相关性。现常使用的方法有主元分析法（PCA）偏最小二乘法（PLS）和典型变量法（CVA）等。主元分析和偏最小二乘等降维技术只消除了数据的互相关性，典型变量分析从相关性出发，不仅解决了数据变量之间的相关性，而且解决了变量自身的时序相关性。典型变量是一种能够明显地反映出不同类别样本间差异的线性特征，是从两组变量各自的线性组合中找出的少量有代表性且相关较好的综合变量^[53,54]。

本系统采用典型变量法实现特征优化。典型变量法把原始特征子集视为一个向量，对其进行线性变换得到一组新向量，向量中第一个典型变量最大限度地描述原始向量差异，第二个典型变量最大限度地描述剩余的原始向量差异，如此进行下去，直至前几个典型变量可以解释原始向量的绝大部分差异，这几个典型变量构造出能够表达出原始判据特征全部信息或主要信息的新特征子集。前面的典型变量贡献率越高，特征优化的效果越好。

获取典型变量时，假设有 g 个类别，第 k 个类别有 n_k 个学习样本，分别是

$x_{k,i}^{\omega}, i \in \{1, \dots, n_k\}$ ，其中均值为 \bar{m}_k^{ω} 。设样本特征是 p 维的。

令 \bar{m} 为类平均值的平均值，即

$$\bar{m} = \frac{1}{g} \sum_{k=1}^g \bar{m}_k^{\omega} \quad (4-9)$$

再令

$$\bar{b} = \frac{1}{g-1} \sum_{k=1}^g (\bar{m}_k^{\omega} - \bar{m})(\bar{m}_k^{\omega} - \bar{m})^T \quad (4-10)$$

协方差矩阵 Σ^{ω} 为

$$\Sigma^{\omega} = \frac{1}{N-1} \sum_{k=1}^g \left\{ \sum_{i=1}^{n_k} (\bar{x}_{k,i}^{\omega} - \bar{m}_k^{\omega})(\bar{x}_{k,i}^{\omega} - \bar{m}_k^{\omega})^T \right\} \quad (4-11)$$

其中 $N = \sum_1^g n_k$ 。

矩阵 $\Sigma^{\omega-1} b^{\omega}$ 有 d 个特征值，按从大到小排列，排列后特征值所对应的单位特征向量为 $\bar{n}_1^{\omega}, \bar{n}_2^{\omega}, \dots, \bar{n}_d^{\omega}$ ，其中 \bar{n}_1^{ω} 是最大的特征值对应的单位特征向量。选择 $\bar{n}_1^{\omega}, \bar{n}_2^{\omega}, \dots, \bar{n}_d^{\omega}$ 的前 k 个特征向量集 $\{\bar{n}_1^{\omega}, \bar{n}_2^{\omega}, \dots, \bar{n}_k^{\omega}\}$ 构成典型变量，它是所有 k 维特征向量集中保持原数据样本集类间可分性最好的一个。

在检测过程中，只需提取学习过程中已经确定的用于模式识别的原始判据特征，再经过典型变量的线性变换，得到最终用于模式识别的判据特征适量。假设检测中提取的原始判据特征为 x^{ω} ，典型变量特征集为 $\{\bar{n}_1^{\omega}, \bar{n}_2^{\omega}, \dots, \bar{n}_k^{\omega}\}$ ，则最终判据特征 \bar{x}^{ω} 为

$$\bar{x}^{\omega} = \begin{pmatrix} \bar{n}_1^{\omega} & \bar{n}_2^{\omega} & \dots & \bar{n}_k^{\omega} \\ \bar{n}_1^{\omega} & x^{\omega} \\ \bar{n}_2^{\omega} & x^{\omega} \\ \vdots & \vdots \\ \bar{n}_k^{\omega} & x^{\omega} \end{pmatrix} \quad (4-12)$$

本文对典型变量方法进行了试验，为了便于观察数据分布，这里只采用二维数据。原始数据由随机数处理后得到，其分布如图 4-2 a) 所示，其中蓝色和红色的数据点分别代表两个类别，二维坐标系分别代表 2 个特征。从图中可以看出，两个类别可以完全分开，但是由单个特征是无法实现分类的。计算出这两类特征的典型变量，并生成新的特征，其分布如图 4-2 b) 所示，图中可以发现，两个类别可以被其中一个新特征完全分开，其分类效果很好。

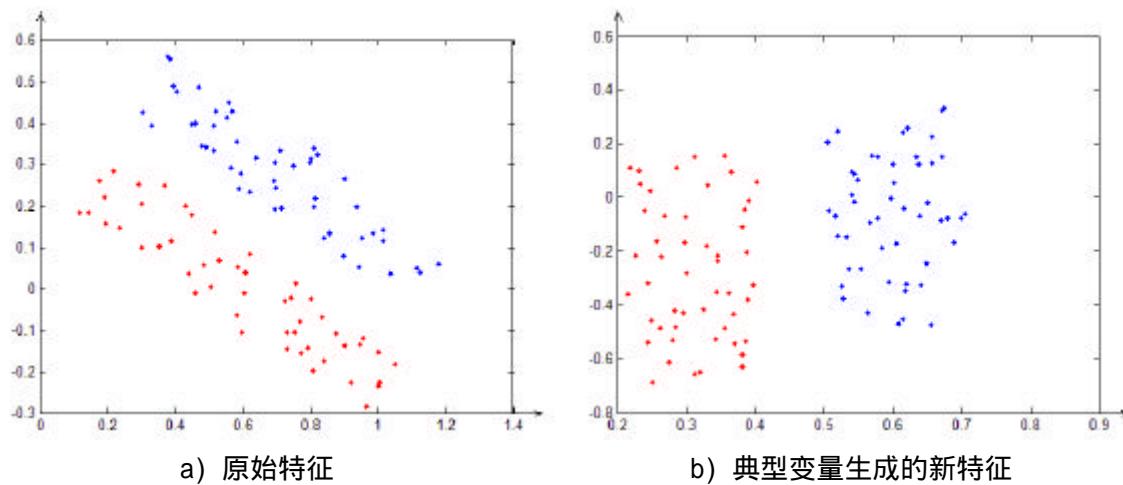


图 4-2 典型变量试验数据分布图

Fig.4-2 Data distribution map in CVA experiment

通过理论分析和数据试验可以看出，典型变量能够确定一组使类间尽可能分开的新的特征子集，压缩了特征空间，对后面训练模式识别的分类器设计有很大的帮助。

4.5 分类器设计

4.5.1 分类器设计方法分析

提取、选择和优化特征之后，分类和识别效果的优劣取决于所设计的分类器的性质。设计分类器的主要方法也就是模式识别的主要方法。模式识别方法大致可以分为以下几类：

1. 统计决策法^[48~53]

统计决策法以概率论和数理统计为基础，包括参数方法和非参数方法。

参数方法有两类：一类是将参数作为非随机量处理，如矩阵估计、最大似然估计等；另一类方法是将参数作为随机变量，贝叶斯估计就属此类。参数估计方法的理论基础是样本数目趋近于无穷大时的渐进理论。在样本数目很大时，参数估计的结果才趋近于真实的模型。然而实际样本数目总是有限的，很难满足这一要求。另外参数估计的另一个前提条件是特征独立性，这一点有时和实际差别较大。

当不知道类的模型时，就要采用非参数方法，也称为总体推断，有 p -窗法、有限项正交函数逼近法、随机逼近法、线性分类器、最近邻方法、 K 均值聚类法等。在样本数量不是很大的情况下，这类方法物理意义直观，但所得的结果和错误率往

往没有直接联系，所设计的分类器不能保证最优。

2. 结构模式识别方法

结构模式识别是利用模式的结构描述与句法描述之间的相似性进行分类。每个类别由它的各个子部分（称为子模式或模式基元）的组合来表示。识别中常以句法分析的方式进行，即依据给定的一组句法规则来剖析类别中模式的结构。当每一个基元被辨认后，识别过程就可通过执行语法分析来实现。选择合适的基元是结构模式识别的关键。基元应具有“结构简单、含义明确、能方便地描述数据、易于抽取、结构信息少”等特点。

结构模式识别方法的特点是识别方便，能够反映模式的结构特征，能描述模式的性质，对图像畸变的抗干扰能力较强。如何选择基元是本方法的一个关键问题，尤其是当存在干扰及噪声时，抽取基元更困难，且易失误。由于基元选择的不确定性以及基元特征的多样性，实际应用中有时很难找到合适的基元。

3. 模糊模式识别方法

模糊模式识别是在解决模式识别问题时引入模糊逻辑的方法或思想。同一般的模式识别方法相比较，模糊模式识别具有客体信息表达更加合理，信息利用充分，各种算法简单灵巧，识别稳定性好，推理能力强的特点。

模糊模式识别的关键在隶属度函数的建立，目前主要的方法有模糊统计法、模糊分布法、二元对比排序法、相对比较法和专家评分法等。虽然这些方法具有一定的客观规律性与科学性，但同时也包含一定的主观因素，准确合理的隶属度函数很难得到，如何在模糊模式识别方法中建立比较合理的隶属度函数是需要进一步解决的问题。

4. 人工神经网络模式识别方法

人工神经网络是近年来发展起来的一支十分活跃的交叉学科，以大量处理单元为结点，处理单元间实现互联的拓扑网络，模拟动物神经系统的某些功能。这种方法是对原始特征空间进行非线性变换，产生一个新的样本空间，使得变换后的特征线性可分。同传统统计方法相比，其分类器是与概率分布无关的。

人工神经网络的主要特点在于其具有信息处理的并行性、自组织和自适应性、具有很强的学习能力和联想功能以及容错性能等，在解决一些复杂的模式识别问题中显示出其独特的优势。

但是人工神经网络是一种复杂的非线性映射方法，其物理意义比较难解释，在理论上还存在一系列亟待解决的问题。在设计上，网络层数的确定和节点个数的选取有很大的经验性和盲目性，缺乏理论指导，网络结构的设计仍是一个尚未解决

的问题。在算法复杂度方面，神经网络计算复杂度大，在特征维数比较高时，样本训练时间比较长；在算法稳定性方面，学习过程中容易陷入局部极小，并且存在欠学习与过学习的现象，范化能力不容易控制。这些也是制约人工神经网络进一步发展的关键问题。

5. 支持向量机方法

近些年来基于统计学习理论的支持向量机 SVM 在模式识别方法表现出出色的学习性能和范化能力，成为目前模式识别领域中又一个研究热点。

支持向量机是在结构风险最小化原则基础上建立起来的小样本学习理论，其基本原理是寻找一个最优分类超平面，使两类样本距离最优超平面的距离最大化。SVM 方法通过内积计算比较有效地解决了维数灾难问题，通过在高维空间设计最优分类面，比较好地实现了 VC 维最小的问题；在数学上支持向量机的训练问题可转化为一个求解受约束的二次型规划(QP) 问题，这个问题存在惟一解，避免了神经网络训练结果不稳定、容易陷入局部极小的问题。由于 SVM 的范化能力比较好，常常获得比其他方法更好的识别效果，因而 SVM 方法是一种比较好的模式识别方法。

6. 仿生模式识别方法

传统模式识别从特征空间中不同类样本的划分出发设计分类器。而仿生模式识别是在引入特征空间同类样本的连续性规律，实现对一类事物的“认识”，实际上是对这类事物的全体在特征空间中形成的无穷点集合的“形状”的分析和认识，根据这种规律性建立起“多维空间中非超球复杂几何形体覆盖”的识别原理。

仿生模式识别提出了一种新的模式识别思想，为模式识别的研究开辟了一个崭新的研究方向。但是到目前为止，这种思想还处于起步阶段，各方面技术仍不成熟，其实现模型有待于进一步的研究。

以上各种模式识别方法中，统计决策法和结构模式识别法发展得比较早，理论相对也比较成熟，在早期的模式识别中应用较多。但是统计决策理论主要集中在数量的统计关系上，受样本限制大，对于很复杂的图像，要求的特征量非常巨大，要把某一模式准确分类很困难；且为了准确地对某一类的分布进行统计决定，往往只使用该类的样本，即在各类内对该类独立进行估计，忽略了类间的区别，分类效果不十分理想。而结构模式识别法中的基元选择和抽取问题始终不能得到很好的解决，在上一章特征提取小节也提到过结构特征提取的劣势，不能满足本系统的通用性要求，所以也不作为考虑对象。仿生模式识别法仍处于起步阶段，目前作为工业流水线上检测系统中模式识别方法的契机还未成熟。

目前应用较多的模式识别方法是模糊方法、神经网络方法和支持向量机法。其

中模糊方法更合乎逻辑，但是建立合理隶属度函数有一定困难。神经网络方法具有较强的解决复杂模式识别的能力，但是算法复杂度高不易实现，且算法稳定性不容易控制。SVM 具有很强的学习能力和泛化性能，能够较好地解决小样本、高维数、非线性、局部极小及过学习等问题，可以有效地进行分类、回归、密度估计等，同神经网络相比，有效地克服局部极小、维数灾难等问题，近年来 SVM 作为一种简单、可靠、有效的分类技术，得到了广泛的应用。本检测系统对通用性和准确率的要求很高，因此采用 SVM 作为本系统的模式识别主要方法。

4.5.2 支持向量机实现分类过程

支持向量机是从线性可分情况下的最优分类面发展而来的，其本质就是寻找一个最优分类超平面，使两类样本离超平面的距离最大化，如图 4-3 所示。

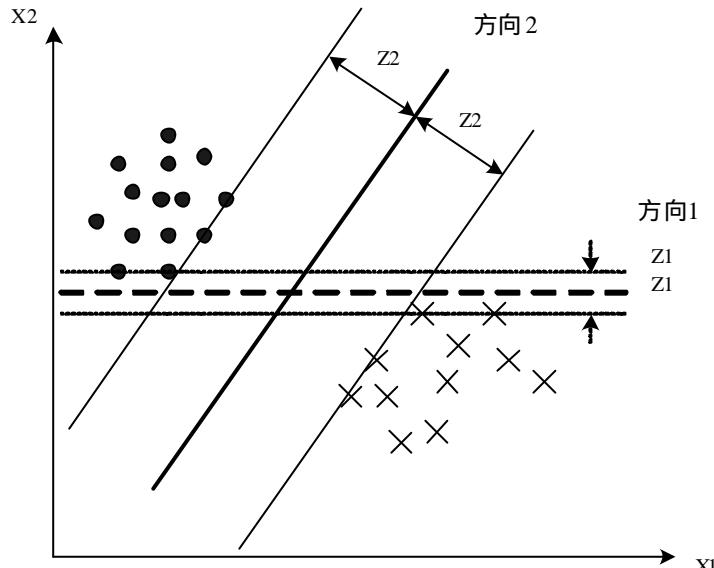


图 4-3 支持向量机最优分类超平面

Fig.4-3 SVM optimal separating hyper-plane

图中，实心点和交叉点代表两类样本，将其分类的超平面可以有很多个，如方向 1 和方向 2 上的超平面都可以将两类样本分开，但是明显方向 2 上的超平面分类更优。所谓最优化分类面或最大间隔超平面就是要求不但能将两类正确分开(训练错误率为 0)，而且使分类间隔最大^[50,53,55]。

训练支持向量机过程如下：

(1) SVM 参数初始化

已知一个容量为 N 的样本训练集 $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)\}$ ，其中 y_i 的取值为 1 或 -1，

分别表示两个类别。寻找某个合适的 ω 和 b (表示一个超平面) 使得对训练集上的任意一个样本都满足 :

$$y_i(\omega \cdot x_i + b) > 0$$

经过简单推导 , 可以得到如下的对偶问题 :

$$\text{使 } \sum_i^N a_i - \frac{1}{2} \sum_{i,j=1}^N a_i (y_i y_j \omega \cdot \omega) a_j \text{ 最大化}$$

$$\text{受限于 } a_i \geq 0$$

$$\text{和 } \sum_{i=1}^N a_i y_i = 0$$

这个问题的约束条件是二次的 , 称为二次规划问题 , 是一个典型的最优化问题。

(2) SVM 二次规划问题求解

二次规划是非线性规划的一种特殊类型 , 在本系统 SVM 中目标函数是二次的而约束是线性的。它的一般形式为 :

$$(QP) \quad \begin{cases} \min f(x) = \frac{1}{2} x^T H x + c^T x \\ \text{s.t. } Ax = b \quad x \geq 0 \end{cases}$$

其中 $c \in R^n$, H 是一个 $n \times n$ 的实对称矩阵。目前 , 二次规划算法的主流为不可行内点算法 , 其求解过程如下^[56~58] :

初始化 : 给出 QP 的对偶问题

$$(QD) \quad \begin{cases} \max d(x) = b^T y - \frac{1}{2} x^T H x \\ \text{s.t. } A^T y + s - H x = c \\ \text{s.t. } x, s \geq 0 \end{cases}$$

取 $(x^0, y^0, s^0) = r(e, 0, e)$, $0 < b_1 < b_2 < 1$, $e > 0$, $e_p > 0$, $e_d > 0$, $k = 0$, $q^0 = 1$ 。

Step1 : 如果下列条件之一成立 , 则算法停止 :

$$(x^k)^T s^k \leq e, \quad \|Ax^k - b\| \leq e_p, \quad \|Hx^k + c - A^T y^k - s^k\| \leq e_d$$

$$\|(x^k, s^k)\|_1 > \frac{2}{q^k r} (x^k)^T s^k, \quad q^k > 0$$

Step2 : 令 $m = \frac{b_1 (x^k)^T s^k}{n}$, 在点 (x^k, y^k, s^k) 处求得迭代方向 $(\Delta x, \Delta y, \Delta s)$, 这里采

用 Newton 方向作为迭代方向 , 求解方程组

$$\begin{bmatrix} A & 0 & 0 \\ H & -A & -I \\ S^k & 0 & X^k \end{bmatrix} \begin{bmatrix} \Delta x \\ \Delta y \\ \Delta s \end{bmatrix} = - \begin{bmatrix} Ax^k - b \\ Hx^k + c - A^T y^k - s^k \\ X^k S^k e - \mathbf{m} \end{bmatrix} \quad (4-13)$$

其中 $S^k = \text{diag}(s^k)$, $X^k = \text{diag}(x^k)$, $e = (1, 1, \Lambda, 1)^T$ 。

Step3 : 取 a^k 为 $\bar{a} \in (0, 1]$ 中的最大值 , 使得对于 $\forall a \in (0, \bar{a}]$ 有

$$(x^k, y^k, s^k) + a(\Delta x, \Delta y, \Delta s) \in N$$

$$a\Delta x^T \Delta s + \mathbf{b}_1(x^k)^T s^k \geq 0$$

$$(x^k + a\Delta x)^T (s^k + a\Delta s) \leq (1 - a(1 - \mathbf{b}_1))(x^k)^T s^k$$

Step4 : 令 $\mathbf{q}^{k+1} = (1 - a^k) \mathbf{q}^k$, $(x^{k+1}, y^{k+1}, s^{k+1}) = (x^k, y^k, s^k) + a(\Delta x, \Delta y, \Delta s)$, $k = k + 1$,

然后返回 Step1。

最后求得的 x 即为 SVM 所需参数 a_i 。

(3) SVM 实现分类

对求得的所有不为 0 的 a_i , 计算 $\mathbf{w} = \sum_i^N a_i y_i \mathbf{x}_i$, 再根据 $y_i(\mathbf{w} \cdot \mathbf{x}_i + b) = 1$, 可以计算出 b 。

根据训练结果 , 对任意一个新的样本特征 x , 可以通过计算下面的符号函数进行分类

$$\begin{aligned} f(x) &= \text{sign}(\mathbf{w} \cdot \mathbf{x} + b) \\ &= \text{sign}\left(\sum_i^N (a_i y_i \mathbf{x}_i \cdot \mathbf{x} + b)\right) \end{aligned} \quad (4-14)$$

4.5.3 基于支持向量机的多类分类器设计

SVM 最初用来解决两类问题 , 表现出优越的性能 , 但是不能直接用于解决多类问题。目前解决多类问题的 SVM 分类识别主要有两种方法 : 一是根据多类样本集直接设计分类器 , 此时分类器的设计问题可转化为一个考虑所有样本的优化问题 , 在样本比较多时 , 这种方法求解比较复杂 ; 另一种是分解法 , 将多类样本分类器的设计转化为多个两类问题的分类器设计问题 , 由于这类方法比直接法求解简单 , 在实际中应用很广^[48,55,59]。

直接分类法常用的方法有决策树(decisive tree)和有向无回路图(directed acyclic graph)方法等。分解法中比较有代表性的训练和预测多类 SVM 的方法有一对一 OAO(one against one)和一对多 OAA(one against all) 方法等。本文只讨论分解方法。

1. 一对多 OAA 多分类算法

用 SVM 解决多分类问题最早的算法中用的就是一对多支持向量机^[50]。一对多方法的基本思想是先将一类训练样本同其它余下类的训练样本区分开来构造所有可能的两分类 SVM，再采用某种结合策略训练得到全部两分类 SVM 组合起来解决多分类问题。对 k 类问题，该方法仅需构造 k 个支持向量机。

一对多方法简单直观，需构造的两分类 SVM 数量少，训练时间较短。缺点是：

存在不可分的区域；当类别较多时，某一类训练样本将远远少于其他训练样本的总和，这种训练样本分布的不均衡将对精度产生影响；每次都必须对全部样本训练来构造二分类 SVM，因此就单个二分类 SVM 来说，计算和时间复杂度就增加了；泛化能力差。

2. 一对一 OAO 多分类算法

一对一方法与一对多 SVM 不同的是，不用全部的 k 类样本来构造每一个两分类 SVM，每次只选取其中的两类样本，对所有可能的两类组合构造 SVM，总共需要构造 $\frac{1}{2}k(k-1)$ 个 SVM。

该方法的优点是每个两分类 SVM 只用到某两类样本，克服了一对多 SVM 每次均要处理全部样本的缺点，提高了构造单个分类器的速度，也在一定程度上减少了样本分布不平衡的可能性。训练精度与测试精度都明显高于一对多 SVM。但是，一对一 SVM 也存在如下问题：仍然存在不可分区域；需要构造的分类器比一对多 SVM 多很多，因此当问题的规模比较大时，分类的速度会很慢；泛化能力差。

一对多算法和一对一算法各有千秋，在很多情况下，OAO 的分类精度要优于 OAA。但该方法学习和分类过程中计算量要明显高于后者，而且随着类别数的增加，运算量将迅速上升。本系统决定采用一对一算法以得到更高的分类精度，但是需要克服一对一算法中计算量过高的缺点。由于零件检测系统的主要功能为筛选不合格零件，设计分类器只需能区分合格类和各种缺陷类即可，所以本系统的多类分类识别过程可以简化，如图 4-4 所示，其分类过程即为 SVM 多级二叉树结构，其中 $SVM_1, SVM_2, \dots, SVM_N$ 为合格类与每个缺陷类的一对一训练结果。

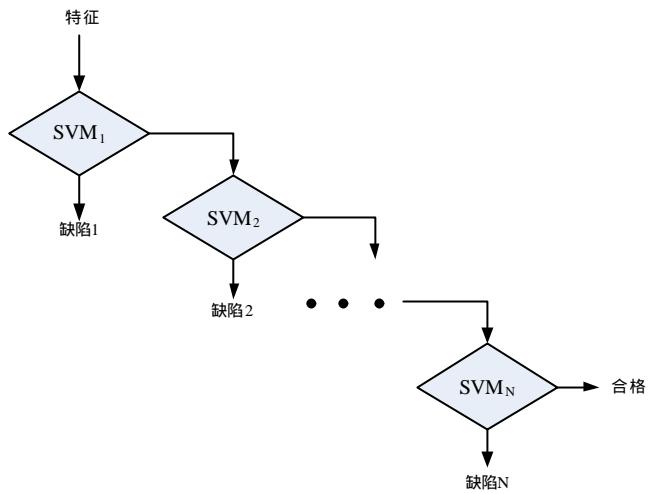


图 4-4 SVM 多级二叉树结构实现多类识别

Fig.4-4 SVM multi-level binary tree structure

完成模式识别训练后，将训练结果用于在线检测：提取学习过程中选择的特征子集，归一化后使用典型变量对特征向量进行线性变换，再使用多个 SVM 实现最后分类。由于归一化使用的数据、典型变量及 SVM 均已在学习过程中训练完成，特征向量只需实现简单的内积加减判断，所以分类识别速度很快。

4.6 本章小结

本章主要研究了能够实现自适应学习功能的多类别模式识别技术。通过对多类模式识别主要因素的分析研究，分别对特征预处理、选择、优化和分类器设计的方法进行了探讨研究。首先剔除特征离群点减少噪声对训练样本的影响，并归一化特征数据使其位于统一范围，便于系统评估；根据触点零件检测的特点，设计了一种两类浮动搜索-多类后向选择算法实现多类别特征选择，可以更好地保留对特定分类有效的特征，并在有限时间内最大限度地保留有用特征；采用了典型变量法对特征进行优化，消除了特征相关性，压缩了特征空间，可以简化分类器设计；最后根据触点分类检测的主要需要区分合格类和缺陷类，设计了支持向量机多级二叉树的简化一对一分类策略，实现了多类别触点零件自学习和快速分类检测功能。

第五章 系统试验及误差分析

5.1 系统试验平台介绍

根据本文上述章节的系统设计和识别算法研究，本章在实验室构建了完整的实验系统，如图5-1所示，由面阵CCD摄像机、光学系统、图像采集卡和计算机构成图像获取、处理与识别系统。其中编程语言为Visual C++ 6.0，计算机为Intel T2300，1.66GHz，512M内存，为本文中通用试验条件。



图 5-1 实验硬件系统

Fig.5-1 Experimental hardware system

本文设计开发的检测程序，其目的是能够应用于各种触点零件产品的分类识别场合，在满足通用性的同时，还要保证该程序的识别精度和准确性。另外，在实际在线检测中还要满足很高的实时性要求。检测中，当零件发生变更或是应用环境发生变化时，只需在新的条件下，重新采集待分类零件的图像并重新进行训练学习，即可快速建立一套适用于新零件或新环境的分类器，进一步应用识别程序，即可进行新零件或新环境的分类识别。

本文试验检测程序预置了图像去噪滤波、自适应阈值图像分割、45种特征提取、特征预处理、自适应特征选择及优化、SVM自动训练和识别等多个函数，程序主界面如图5-2所示。程序通过对多组实际触点零件进行试验考核，以期进一步验证本文设计的系统的通用性、准确性和实时性。

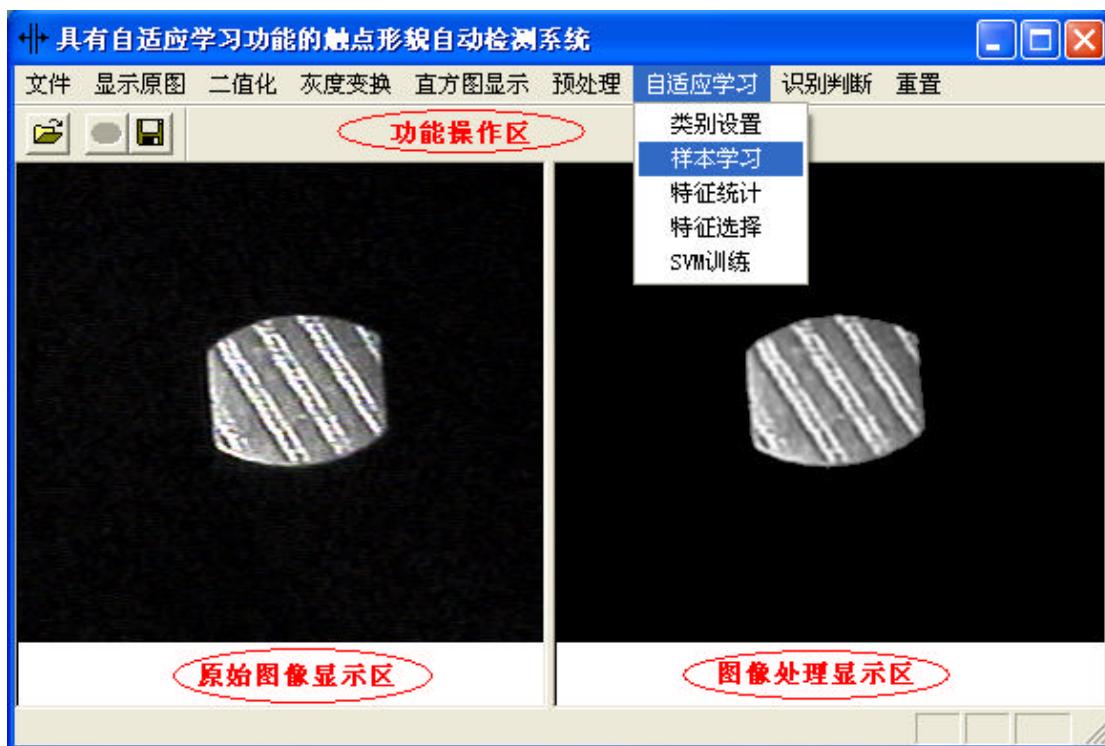


图 5-2 实验软件主界面

Fig.5-2 Main interface of experimental software

5.2 试验步骤

本试验系统共实现了学习功能和检测功能两大模块，下面分别对两大功能模块的试验步骤作一简单介绍。

5.2.1 学习模块试验步骤

当系统检测新零件或检测条件发生变化时，必须通过学习模块重新采集待分类零件的图像并进行训练学习，快速建立一套适用于新零件或新环境的分类器。

1. 测试前根据实际情况设置检测环境和图像检测处理软件的相关参数：如光源环境及待测对象的背景、视频亮度、对比度、饱和度等。

2. 打开试验软件，选择学习模块。首先设置触点零件各种不合格形式，如图5-3所示。触点零件始终分为合格与不合格两大类，因此图中的第1类始终默认为合格类。但是不同零件的不合格形式多种多样，需要进行设置以便加以区分。这一步统计零件不合格形式的种类名称和数量。



图 5-3 设置触点零件不合格类形式

Fig.5-3 Unqualified category setting

3. 开始样本学习。采集零件图像，并显示在主界面左边，对其进行去噪和分割后的图像显示在主界面右边，对每个零件提取系统中预设的所有特征，显示特征值并让监督学习人员设置每个样本零件的类别，如图5-4所示。

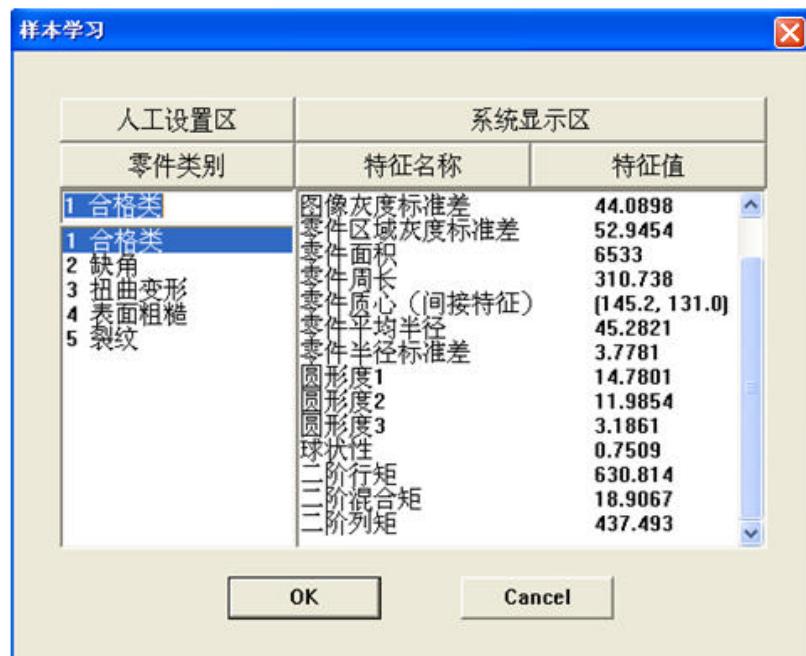
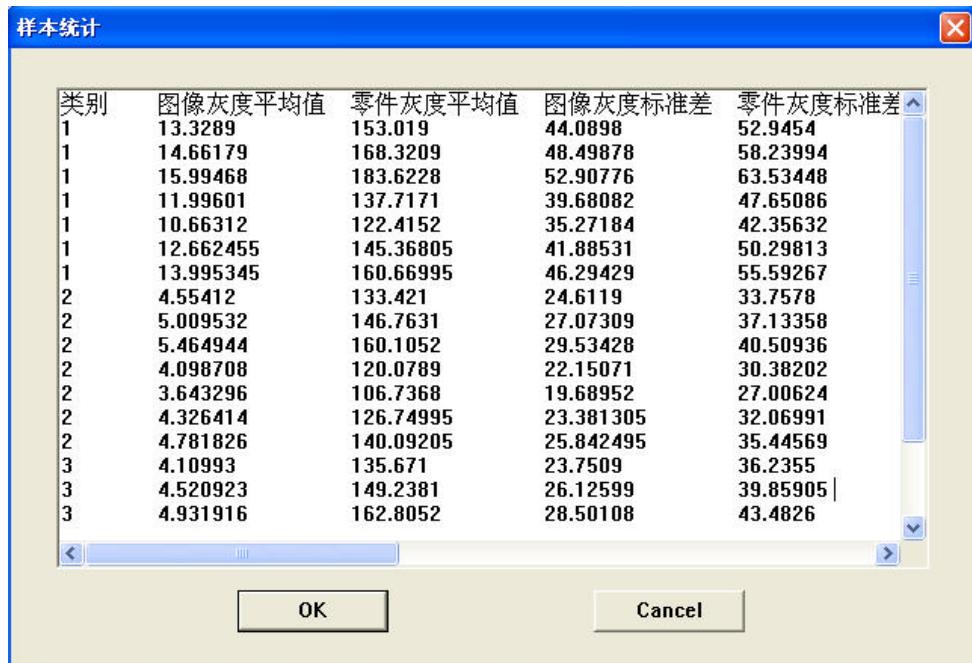


图 5-4 设置样本零件类别及特征显示

Fig.5-4 Sample category setting & feature display

4. 样本学习过程中，可以查看目前样本的统计情况，如图5-5所示。



类别	图像灰度平均值	零件灰度平均值	图像灰度标准差	零件灰度标准差
1	13.3289	153.019	44.0898	52.9454
1	14.66179	168.3209	48.49878	58.23994
1	15.99468	183.6228	52.90776	63.53448
1	11.99601	137.7171	39.68082	47.65086
1	10.66312	122.4152	35.27184	42.35632
1	12.662455	145.36805	41.88531	50.29813
1	13.995345	160.66995	46.29429	55.59267
2	4.55412	133.421	24.6119	33.7578
2	5.009532	146.7631	27.07309	37.13358
2	5.464944	160.1052	29.53428	40.50936
2	4.098708	120.0789	22.15071	30.38202
2	3.643296	106.7368	19.68952	27.00624
2	4.326414	126.74995	23.381305	32.06991
2	4.781826	140.09205	25.842495	35.44569
3	4.10993	135.671	23.7509	36.2355
3	4.520923	149.2381	26.12599	39.85905
3	4.931916	162.8052	28.50108	43.4826

图 5-5 样本统计情况

Fig.5-5 Sample statics

5. 样本采集完成后，开始特征选择，在这一步中，会实现特征预处理和选择两个功能。并且选择特征时，可以设定检测过程中的时间上限，用来限制特征选择数，保证检测的实时性要求，如图5-6所示。



a) 时间设定

b) 特征选择结果

图 5-6 特征选择

Fig.5-6 Feature Selection

6. 根据样本集中被选择的特征，训练优化特征的典型变量及实现分类的SVM。完成所有学习过程后，生成零件模板，如图5-7所示。



The dialog box is titled '训练结果' (Training Results). It contains two tables: '典型变量' (CVA) and 'SVM'. The '典型变量' table has columns v1, v2, v3, SVM1, SVM2, and SVM3. The 'SVM' table has columns SVM1, SVM2, and SVM3. Below the tables is a '模板名称' (Template Name) input field containing '椭圆零件实验室1'. At the bottom are '生成模板' (Generate Template) and '取消' (Cancel) buttons.

典型变量			SVM		
v1	v2	v3	SVM1	SVM2	SVM3
-0.049	-0.376	-0.49	-0.258	0.1555	-0.43
0.42	-0.17	0.29	-0.004	0.0242	-0.07
0.495	-0.494	0.26	-0.279	0.0017	-0.11
0.413	-0.19	0.31	-0.069	-0.0486	-0.13
0.473	0.2	-0.26	0.242	-0.0820	-0.01
0.179	0.476	0.02	0.003	0.0133	-0.02
0.291	0.449	0.11	-0.032	-0.0403	-0.10
0.272	-0.332	0.03	0.01855	-25.696	99.5
0.239	-0.113	-0.22			
0.151	-0.296	-0.00			
-0.189	0.256	0.462			

图 5-7 典型变量、SVM 训练结果及模板生成

Fig.5-7 CV & SVM training results and template generating

5.2.2 检测模块试验步骤

检测模块根据学习模块生成的零件模板实现对零件的检测，其过程相对简单。

试验步骤如下：

1. 测试前根据实际情况设置检测环境和图像检测处理软件的相关参数：如光源环境及待测对象的背景、视频亮度、对比度、饱和度等。
2. 打开试验软件，选择检测模块。首先选择零件模板，如图5-8所示。



图 5-8 零件模板选择

Fig.5-8 Template selection

3. 选择检测模块后，可以开始检测零件。只需提取判据特征并用模板中的典型变量和SVM实现检测分类，检测结果如图5-9所示。

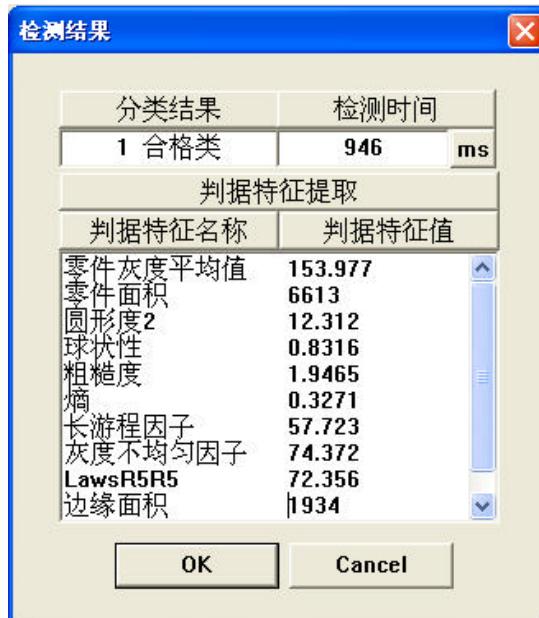


图 5-9 检测结果显示

Fig.5-9 Detection result display

5.3 系统性能试验

5.3.1 样本容量试验

样本容量又称样本数。抽样误差的大小直接影响样本指标的代表性，必要的样本数是保证抽样误差不超过某一给定范围的重要因素之一。样本容量过小，会影响样本的代表性，使抽样误差增大而降低了系统统计学习的精确性；而样本容量过大，虽然减小了抽样误差，但可能增大过失误差，而且无意义地增大系统计算开销。因此，在系统设计时，必须确定合适的样本容量。

在样本容量试验中，暂时不限制系统的检测时间。图5-10所示为一种触点零件的合格类和不合格类的图像，其中不合格类共分为缺角、纹理模糊和表面粗糙3种形式。

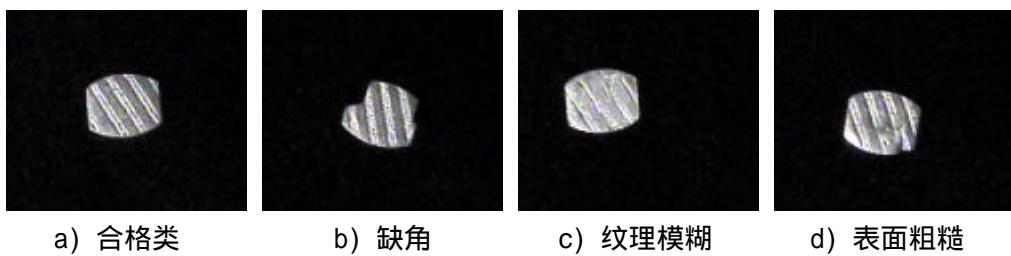


图5-10 触点零件1图像

Fig.5-10 Contact component 1 images

每一类零件各选用5个、10个、15个、20个样本，分别对样本学习训练后，对这种零件进行检测，检测结果如表5-1所示。

表5-1 样本容量试验检测结果

Table 5-1 Detection results in sample size experiment

样本容量	检测指标	合格类	不合格类		
			缺角	纹理模糊	表面粗糙
5	正确数/正确率	82 / 82%	46 / 92%	28 / 93.3%	34 / 68%
	误判数/误判率	18 / 18%	4 / 8%	2 / 6.7%	16 / 32%
10	正确数/正确率	86 / 86%	48 / 96%	30 / 100%	44 / 88%
	误判数/误判率	14 / 14%	2 / 4%	0 / 0%	6 / 12%
15	正确数/正确率	95 / 95%	50 / 100%	30 / 100%	46 / 92%
	误判数/误判率	5 / 5%	0 / 0%	0 / 0%	4 / 8%
20	正确数/正确率	100 / 100%	50 / 100%	30 / 100%	50 / 100%
	误判数/误判率	0 / 0%	0 / 0%	0 / 0%	0 / 0%

由表中可以看出，随着样本容量的增大，检测正确率不断提高，当样本容量到达一定数量后，检测正确率可以达到100%。因此，在样本训练过程中，学习样本容量对系统的精度确实有不小的影响，要充分发挥系统的识别功能，应具有一定数量的学习样本，一般每类取20个以上为宜，但不要超过50个，以免学习过程中系统开销过大。

5.3.2 实时性试验

实时性是工业在线检测的重要指标，系统的检测速度必须与生产线节拍相一致或者耗时更短，才能应用到实际生产中。本系统检测过程中，图像预处理和分割的耗时基本不变且时间较短，特征归一化、优化和SVM判别的速度也很快，主要的时间都花费在图像特征提取上，而每一个特征提取的时间是较固定的，所以要提高系统实时性，关键在于学习过程中尽量选择对分类贡献大的特征。

实时性试验主要为了观察检测时间对检测准确性的影响，同时也可以观察模式识别中特征提取和分类器分类的可靠性。本次试验仍然采用图5-9所示的触点零件，样本容量设定为每类30个样本，零件图像像素数为300*250，采用本论文中的通用试验条件，运算时间取10次平均时间。

首先直接对零件样本进行学习训练，不设定时间限制，学习完成后系统共选择了27个特征作为判据特征，实现检测分类过程的耗时为285ms，其中提取图像特征的耗时约为276ms，检测结果正确率100%。

检测时间分别设定为200ms、150ms、100ms、50ms，重新训练样本后，系统检测结果如表5-2所示。

表5-2 实时性试验检测结果

Table 5-2 Detection results in real-time experiment

检测时间	检测指标	合格类	不合格类		
			缺角	纹理模糊	表面粗糙
200ms	正确数/正确率	100 / 100%	50 / 100%	30 / 100%	50 / 100%
	误判数/误判率	0 / 0%	0 / 0%	0 / 0%	0 / 0%
150ms	正确数/正确率	100 / 100%	50 / 100%	30 / 100%	50 / 100%
	误判数/误判率	0 / 0%	0 / 0%	0 / 0%	0 / 0%
100ms	正确数/正确率	98 / 98%	50 / 100%	30 / 100%	44 / 88%
	误判数/误判率	2 / 2%	0 / 0%	0 / 0%	6 / 12%
50ms	正确数/正确率	75 / 75%	50 / 100%	26 / 86.7%	28 / 56%
	误判数/误判率	25 / 25%	0 / 0%	4 / 13.3%	22 / 44%

观察试验数据发现：

(1) 总体来说，缩短检测时间会降低系统分类准确性。这是由于压缩检测时间后，必须删除一些判据特征来满足系统实时性要求（这一部分由多类后向选择方法实现），因此这些特征中包含的分类有效信息丢失了，对分类准确性造成影响。

(2) 检测时间压缩度不高时，检测精度能够保持在较高水平，表中当检测时间设为200ms和150ms时，正确率仍然达到100%。由于两类浮动搜索-多类后向选择算法最大限度地保留了分类有效信息，最先剔除的特征对分类影响最小，所以缩短的时间不多时，检测准确性受到的影响较小。

(3) 缩短检测时间对有些种类的分类准确性影响较大，对有些种类则没有影响，例如缺角零件就对时间压缩完全不敏感。分析缺角零件图像特征后发现，区分此种零件最有效的特征是零件面积，可以直接根据这个特征值实现判断分类，系统在特征选择时很好地保存了这个有效特征，所以缩短检测时间对该类零件的判断准确性

没有影响。而其他种类没有特别有效的判据特征，所以当时间压缩度大的时候，不可避免会受到影响。

通过以上试验可以得知，检测时间会影响到系统的检测精度，如果系统需要实现更高的实时性，往往要以牺牲准确性为代价。但是如果存在特别有效的判据特征，可以减少这种牺牲。在实际检测中，如果检测时间可以调整，可以先设定不同的检测时间进行试验，综合考虑实时性和准确性两方面指标确定实际检测时间。

5.3.3 通用性试验

本自适应学习检测系统是针对触点零件形貌多样的特点设计的，所以通用性也是系统一个重要指标。以上两个试验都只基于一种零件，本组试验在这种零件基础上另外添加了两种零件，分别如图5-11、5-12所示。

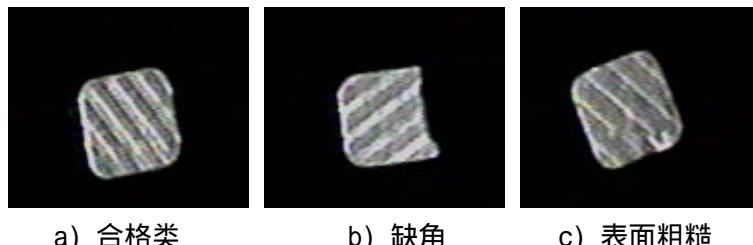


图5-11 触点零件2图像

Fig.5-11 Contact component 2 images

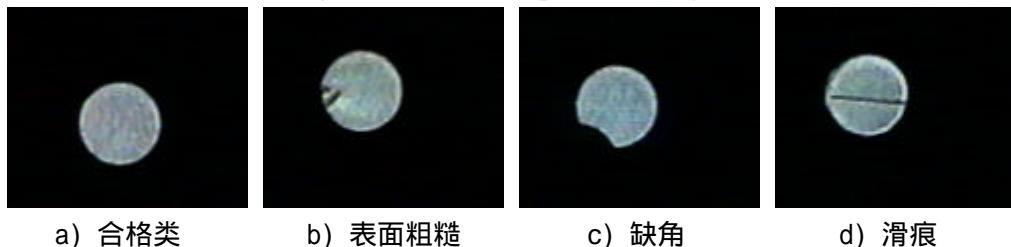


图5-12 触点零件3图像

Fig.5-12 Contact component 3 images

本次试验中，样本容量设定为每类 30 个样本，检测时间设定为 200ms，零件图像像素数为 300*250，采用本论文中的通用试验条件。在同一条件下，分别测试 3 种零件，系统检测结果如表 5-3 所示。

表5-3 通用性试验检测结果

Table 5-3 Detection results in universality experiment

零件1	合格类	不合格类		
		缺角	纹理模糊	表面粗糙
正确数/正确率	100 / 100%	50 / 100%	30 / 100%	50 / 100%
误判数/误判率	0 / 0%	0 / 0%	0 / 0%	0 / 0%
零件2	合格类	不合格类		
		缺角	表面粗糙	
正确数/正确率	98 / 98%	49 / 98%	25 / 100%	
误判数/误判率	2 / 2%	1 / 2%	0 / 0%	
零件3	合格类	不合格类		
		表面粗糙	缺角	滑痕
正确数/正确率	97 / 97%	40 / 100%	40 / 100%	30 / 100%
误判数/误判率	3 / 3%	0 / 0%	0 / 0%	0 / 0%

以上试验结果表明，本系统能有效克服干扰，对各类形貌触点零件进行较精确的分类识别，实现了自适应学习功能，系统的通用性、实时性和准确性均取得了比较满意的结果。

5.4 误差分析

上述系统试验结果中存在一定程度的误差，为了降低系统误差，进一步提高系统的识别精度，本文对误差形成的原因进行了分析，主要包括以下几个方面：

1. 外部环境因素

系统所在的外部环境如光源亮度、光源颜色、照射角度、电磁干扰、背景颜色、机械振动、流水线上传送速度等，都会对图像采集的质量产生不同程度的影响，从而影响检测的准确性。

2. 硬件设备因素

系统所使用的硬件设备，如CCD相机的分辨率和景深、镜头的规格参数、图像采集卡的性能、数据线的抗干扰能力等，都直接影响到采集过程中的图像质量，进一步影响检测的准确性。所以硬件设备都必须根据实际的使用条件和精度进行合理的选择。

3. 图像特征库因素

系统通过特征来检测零件，如果系统的特征库不能很好地描述某种零件的特性

或者类与类之间的区别，则系统根本无法对其进行识别检测。特征库是识别检测的基础，所以必须保证特征库的全面性和准确性。

4. 类别数量和系统实时性因素

在线检测的实时性要求很高，即检测可用时间很少，不少情况下势必对判据特征数量有一定限制；需要识别的类的数量越多，对判据特征的数量限制也越大。若判据特征数量过少不能包含检测必须的有用信息，则直接对检测准确性产生影响。所以实时性和类别数量对检测准确性的影响是一致的，即时间与精度不能两全，往往需要在两者间进行一定的取舍。

5. 学习训练样本容量因素

特征选择结果的可靠性和学习训练样本容量有关，如果样本个数太少或代表性不强，样本集中包含的分类信息不足，特征选择的结果和实际最优特征有时差别很大。因此，学习训练样本的个数必须能足够覆盖样本集的分类信息。

6. 模式识别方法即分类器因素

由于目前人类对自身认知世界的方法和标准还不清楚，分类器的好坏很难评价，一个分类器在不同情况下性能可能会有很大差异，对系统的稳定性和准确性有一定影响。

7. 其他因素

除了上述介绍的几个因素之外，系统中可能还存在着其它因素的影响。图像采集过程中的人员走动、光源上的油污、背景上的斑点与灰尘等因素也都可能对系统的识别精度有不同程度的影响。

总之，造成系统误差的因素是多方面的，一些随机的因素不容易被发现，这些问题都有待在进一步的使用中去解决，以便提高系统的精度和准确性。

5.4 本章小结

本章对实际触点零件检测进行了试验。首先搭建了系统试验的软硬件平台，介绍了试验操作步骤，并针对系统检测中关键的样本容量、实时性、通用性和准确性指标进行试验和分析，取得了比较满意的结果，达到了本系统预期的研究目标。最后，分析了系统中主要的误差来源，并提出了一些解决思路和方法。

第六章 总结与展望

6.1 研究总结

本文课题“触点零件形貌在线自学习视觉检测系统研究”是针对大规模触点零件生产检测的需求，以及触点零件形貌多样的特点而确立的。本文对有关自适应学习在线检测的一些关键性技术的理论算法与系统设计进行了研究，主要工作总结如下：

(1) 通过对检测需求的分析，确定了实现自学习功能的检测原理，并根据流水线在线视觉检测的要求设计了系统的总体结构和系统检测流程。详细讨论了系统各个组成部分：照明系统、成像系统、成像元件、图像采集卡的功能特性及选择方法。根据软件系统需求，设计了在线检测软件的整体架构，将软件功能分散到各个功能模块，并设计了软件系统的工作流程图。

(2) 详细研究了本系统视觉检测中涉及的图像处理技术。针对在线检测的实时性以及准确性要求，对各种图像去噪及分割算法进行了分析比较，最终确定了 $3*3$ 高斯模板滤波方法，快速有效地实现了图像预处理；针对触点零件图像特定提出了一种改进极小值点法求得图像的自适应阈值，并统计多幅图像的自适应阈值，取其中值确定为最终分割阈值，实现了图像分割的自适应性和准确性。对图像特征及提取方法进行了研究，构建了5大类图像特征库，共包含45个特征。

(3) 对特征选择的原理及方法进行了研究。通过剔除特征少数离群点及线形归一化，实现了原始特征数据空间预处理，有效减少了噪声的影响，且便于系统评估。根据触点零件检测需主要确保区分合格类和缺陷类的特点，设计了一种两类浮动搜索-多类后向选择算法实现多类别特征选择，更好地保留了能有效区分两类的判据特征，且能在有限时间内最大限度地保留有用特征。

(4) 提出了给予典型变量的特征优化方法，有效压缩了特征空间，简化了分类器设计；根据触点分类检测的主要需要区分合格类和缺陷类，设计了支持向量机多级二叉树的简化一对一分类策略，有效解决了多类别触点零件自学习和快速分类检测问题。

(5) 为了对本文所研究的检测系统的准确性、通用性、实时性进行验证，搭建

了系统试验软硬件平台，并对多组实际触点零件进行试验考核，并且取得了较好的试验结果。经过对试验结果的分析，探讨了系统指标相互之间的影响，并进一步分析误差来源，提出研究改进的方向。

6.2 课题展望

由于触点形貌在线自适应视觉检测系统本身是一个十分复杂的系统，且系统初期开发研究工作仍然在进行中，因此本论文的研究工作仍有许多待完善的地方：

(1) 本系统与实际触点零件生产流水线的连接尚未实现。当前本系统仍在试验研究阶段，未投入实际生产使用，与流水线的连接和配合工作是系统功能实现的关键步骤，是下一步要做的主要工作。

(2) 图像处理算法实时性的进一步提高。目前本文所设计的图像处理算法能够满足每分钟600个零件的实时检测需要，与世界先进水平相比差距仍然很大。当前工业生产线速度仍在不断提升，可以考虑采用硬件处理加软件处理的方法进行在线检测，但是需要考虑成本问题，这也是需要进一步研究的内容。

(3) 触点零件更准确的识别与分类。目前人类对于自身识别事物的方法仍在探索中，模式识别分类方法也会随着不断改进，识别分类结果也会更加准确。支持向量机在检测时不存在“拒检类”，新类别或其他零件也同样得出判断结果，可能造成较严重的误判，因此需要进一步研究更有效的识别和分类算法。另外，也可以进一步研究图像特征完善图像特征库，以及更为有效的特征提取、优化算法，用以提高检测准确性。

(4) 图形质量的改善。检测过程中，采集触点零件图像时可能会出现较强噪声或金属材质反光现象，在图像中形成伪特征，很难通过软件算法进行消除而造成误检。如何优化图像采集装置和照明系统来消除图像噪声和反光需要进一步研究。

(5) 零件数据管理库的构建。目前零件的检测数据未得到有效保存管理，不利于信息化管理及工艺改进，需要进一步构建数据库，将生成的检测信息纳入数据库，使系统具有更好的实用性。

参 考 文 献

- [1] 姚芳. 触点电接触失效预测的研究. 博士学位论文, 河北工业大学, 2004
- [2] 陆俭国. 电器可靠性理论及其应用. 北京: 机械工业出版社, 1996
- [3] 李志华. 接触电阻引发的飞机重复性故障. 航空工程与维修, 1999(1): 32-33
- [4] 荣命哲. 电接触理论. 北京: 机械工业出版社, 2004
- [5] 尹娜. 新型银基导电陶瓷复合电接触材料研究. 博士学位论文, 山东大学, 2007
- [6] 马大国. 原木表面结子的计算机视觉检测. 硕士学位论文, 东北林业大学, 2002
- [7] 孙慧. 用双目立体视觉技术重建电器触头立体图像. 硕士学位论文, 河北工业大学, 2002
- [8] 成芳. 稻种质量的机器视觉无损检测研究. 博士学位论文, 浙江大学, 2004
- [9] 吴健康, 肖锦玉. 计算机视觉基本理论和方法. 合肥: 中国科学技术大学出版社, 1993
- [10] 钟玉琢, 乔秉新, 李树青. 机器人视觉技术. 北京: 国防工业出版社, 1994
- [11] 房超. 机器视觉及其在工业检测中的应用. 自动化博览, 2007(8): 46-48
- [12] Yiannis Aloimonos, Aeds Rosenfield. Computer Vision Science, 1991(253): 1181-1324
- [13] Theo Pavlidis. Algorithms for Graphics and Image Processing. Computer Science, 1982
- [14] 赵荣椿. 数字图像处理导论. 西安: 西北工业大学出版社, 1995
- [15] 吴健康. 计算机视觉基本理论和实践. 合肥: 中国科学技术大学出版社, 1993
- [16] 夏良正, 李久贤. 数字图像处理. 南京: 东南大学出版社, 1999
- [17] 任潇潇. 复杂曲面坐标测量的建模与应用. 硕士学位论文, 合肥工业大学, 2003
- [18] Halioua M, Liu H C. Optical three-dimensional sensing by phase measuring profilometry. Optics and Lasers in Engineering, 1989,11(3): 185-215
- [19] 于起峰, 陆宏伟, 刘肖琳. 基于图像的精密测量与运动测量. 北京: 科学出版社, 2002
- [20] 孙长库. 激光测量技术. 天津: 天津大学出版社, 2000
- [21] Anil K. Jain, Chitra Dorai. Practicing Vision: Integration, Evaluation and Application Pattern Recognition, 1997(30): 183-196

- [22] Wen Hsiang Tsai. Moment-preserving thresholding: A new approach Computer Vision, Graphics and Image Processing, 1998(41): 11-14
- [23] 卞铭. 机器视觉在线检测中的应用. 硕士学位论文, 合肥工业大学, 2006
- [24] 孟然. 基于机器视觉的工件特征识别与分类方法研究. 硕士学位论文, 天津科技大学, 2006
- [25] 谢立. 双测点机器视觉玻壳产品动态识别系统的开发. 硕士学位论文, 天津科技大学, 2005
- [26] David G. Lowe. Distinctive image features from scale-invariant keypoints. International Journal of Computer Vision, 2004(60): 91-110
- [27] Kunio Osada, Takahiko Furuya, Ryutarou Ohbuchi. SHREC'08 Entry: Local Volumetric Features for 3D Model Retrieval. Shape Modeling and Applications, 2008(6): 245-246
- [28] 廖强, 蔡飞, 吴存学. 基于机器视觉技术的精确定位方法研究及应用. 仪器仪表与检测, 2005(4): 101-103
- [29] 刘焕军, 王耀南, 段峰. 空瓶的智能检测算法研究. 湖南大学学报(自然科学版), 2005.32(1): 20-24
- [30] 马金奎, 路长厚, 程英. 机器视觉测试系统. 工具技术, 2004,38(9): 129-132
- [31] 郑威. 基于嵌入式机器视觉的缺陷检测系统硬件设计. 硕士学位论文, 武汉理工大学, 2006
- [32] CCD&CMOS 图像和机器视觉产品手册. 凌云光视数字图像公司, 2005
- [33] 尚会超. 印刷图像在线检测的算法研究与系统实现. 博士学位论文, 华中科技大学, 2006
- [34] Mahmoud Meribout, Mamoru Nakanishi, Takeshi Ogura. Accurate and Real-time Image Processing on a New PC-compatible Board. Real-time Imaging, 2002,8(1): 35-51
- [35] 周太明. 光源原理与设计. 上海: 复旦大学出版社, 2006
- [36] 李福建, 张元培. 机器视觉系统组成研究. 自动化博览, 2004(2): 61-63
- [37] 唐向阳, 张勇, 李江有等. 机器视觉关键技术的现状及应用展望. 昆明理工大学学报(理工版), 2004,29(2): 63-93
- [38] 李洪宇. 机器视觉图像采集设计及研究. 硕士学位论文, 大庆石油学院, 2007
- [39] 李俊. 机器视觉照明光源关键技术研究. 硕士学位论文, 天津理工大学, 2006
- [40] J. Batlle, J. Marti, P. Ridao. A New FPGA/DSP-Based Parallel Architecture for Real-Time Image Processing. Real-Time Imaging, 2002,8(5): 345-356
- [41] 陈兵旗. 实用数字图像处理与分析. 北京: 中国农业大学出版社, 清华大学出版

社, 2008

[42] 何明一, 卫保国. 数字图像处理. 北京: 科学出版社, 2008

[43] Tinku Acharya, Ajoy K. Ray. Image processing: principles and applications. 北京: 清华大学出版社, 2007

[44] Rafael C. Gonzalez, Richard E. Woods. Digital image processing. 北京: 电子工业出版社, 2007

[45] 许景波. 高斯滤波器逼近理论与应用研究. 博士学位论文, 哈尔滨工业大学, 2007

[46] 余松煜, 周源华, 张瑞. 数字图像处理. 上海: 上海交通大学出版社, 2007

[47] 张健. 一种图像分割关键技术的研究和实现. 硕士学位论文, 北京邮电大学, 2008

[48] 张新峰, 沈兰荪. 模式识别及其在图像处理中的应用. 测控技术, 2004, 23(5): 28-32

[49] 范立南, 韩晓微, 张广渊. 图像处理与模式识别. 北京: 科学出版社, 2007

[50] Sergios Theodoridis, Konstantinos Koutroumbas. Pattern recognition. 北京: 电子工业出版社, 2004

[51] 钟珞, 潘昊, 封筠等. 模式识别. 武汉: 武汉大学出版社, 2006

[52] Linda G. Shapiro, George C. Stockman. Computer vision. 北京: 机械工业出版社, 2005

[53] David A. Forsyth, Jean Ponce. Computer vision: a modern approach. 北京: 电子工业出版社, 2004

[54] 曹玉萍, 田学民. 基于典型变量分析状态残差的故障检测方法. 控制工程, 2007, 7(14): 74-76

[55] 吴换妮. 基于支持向量机的多类模式识别模型. 硕士学位论文, 重庆大学, 2007

[56] 袁亚湘. 非线性优化计算方法. 北京: 科学出版社, 2008

[57] 王言金. 最优化的不可行内点算法研究. 博士学位论文, 武汉大学, 2004

[58] 雍龙泉. 二次规划的算法研究. 硕士学位论文, 西安电子科技大学, 2005

[59] Hu Fangxia, He Xin, Niu Tiangui. Study on the key image processing technology in the inspection of packing quality for small-pack cigarettes. Computer Science, 2007, 32(6): 67-71

致 谢

本论文是在导师吉小军副教授的精心指导下完成的。感谢吉老师近三年来学术上的指导和帮助，以及生活上无微不至的关怀。吉老师渊博的学术知识、严谨的治学态度、务实的工作作风和无私的奉献精神将使作者终身受益。在此论文完成之际，谨向尊敬的导师致以衷心的感谢和崇高的敬意！

在课题研究和论文完成的过程中，特别感谢材料学院陈乐生老师对本研究给予的经费支持和技术指导，以及已退休的施文康教授、梯队课题组的蔡萍教授、韩韬副教授对本人无私的指导和帮助，他们在方案研究上的独到见解使我得到许多有益的启发，在此表示衷心的感谢。同时研究所的同学于烨军、师妹阮晓红、师弟黄峰一和宫延伟也积极参加与合作，使得本项目得以顺利进行，在此向他们表示感谢。

作者在学习和工作期间，研究所提供了良好的研究条件和宽松工作氛围，使作者得以不断提高，使本文的研究工作得以顺利完成，在此，向研究所的所有老师表示感谢，向研究所里相互勉励、相互支持的各位同学致谢。

感谢赵鼎鼎、武博师兄对作者研究工作的勉励和帮助；感谢与阮晓红、黄峰一、宫延伟等师弟师妹们在一起愉快的工作和融洽的相处；感谢同窗好友于烨军、刘佳、陈晨佳等 2006 级仪器系硕士全体同学的关心和帮助。

最后，衷心感谢父母给予本人最宝贵的支持、鼓励、信心、勇气、关爱和照顾，他们是我一直克服困难，潜心研究完成学业，不断进步的最大动力。

谨以此文献给所有关心、支持和帮助过我的师长、亲人、朋友和同学们！

攻读硕士学位期间所发表的学术论文目录

- [1] 戴舒文, 吉小军, 裴揆. 具有自学习功能的触点类零件视觉检测系统研究. 上海交通大学学报, 已录用 (EI 中文杂志)