

中南民族大学

硕士学位论文

人脸识别技术及其应用

姓名：王娟

申请学位级别：硕士

专业：计算机应用技术

指导教师：汪红

20090522

## 摘要

人脸识别技术是基于生物特征的识别方式，与指纹识别等传统的识别方式相比，具有实时、准确和非侵扰等特性，较容易被用户接受，因此人脸识别技术在诸多领域都有广泛的应用。人脸识别技术中的人脸特征提取及模式识别是近年来基于生物特征研究的热点之一。

本文从构建一个动态的人脸识别系统着手，讨论了整个构建工作的流程，对各环节所需的技术、算法作了介绍和研究。其中包括通过多媒体设备获取视频序列流、在图像中检测人脸、对人脸图像进行预处理后提取脸部特征、最后进行模式分类识别。整个过程所作的具体工作如下：

(1) 阐述了人脸检测及预处理的重要性，介绍了几种图片预处理的方法，包括尺度归一化，灰度归一化，直方图均衡化等，并运用小波分解过滤出人脸图片中含有较稳定特征的低频部分用于特征提取。

(2) 讨论了三种基于统计特征的特征提取方法，即 PCA( 主成分分析方法 )、LDA ( Fisher 脸方法 )、KPCA ( 核主成分分析方法 )。分别阐述了这三种特征提取方法的主要思想，介绍了各自的算法流程及实现方法，并对各自的优缺点及适用环境进行了总结和分析。

(3) 分析了支持向量机方法，探讨了线性和非线性支持向量机的原理及实现方法，讨论了如何获取较好的核函数，另外介绍了支持向量机如何实现用 SVM 解决多分类问题。

(4) 由文中讨论的各种特征提取和分类方法进行了大量的实验，并获取了相应的实验数据，对前文总结的各种方法的特点及优缺点进行了对比和验证。根据人脸识别系统流程以及具体算法搭建了一个由摄像头获取视频流的动态人脸识别系统。测试了多个角度，多种障碍物，多种表情等外界条件干扰下各种算法的识别精度及效率，并对实验结果进行了归纳和总结。

关键词：人脸检测；人脸识别；PCA；KPCA；支持向量机

## Abstract

Face recognition technology is based on biometric identification methods such as fingerprint recognition and identification of the traditional methods, with real-time, accurate and non-intrusive, such as features, making it easier for people to accept, the face recognition technology in many fields and have extensive applications. Face Recognition Technology Face feature extraction and pattern recognition in recent years based on the biological characteristics of one of the hot spots.

In this paper, to build a dynamic face recognition system to proceed to discuss the entire process of building a work of the various sectors of the technology required, the algorithm was introduced and studied. Including through multi-media equipment to obtain video stream. Detection in face images, face images of people after pretreatment facial features in advance, the final classification model. Made the whole process work as follows:

(1) first proposed a face detection and the importance of pretreatment on the concentration of image pre-processing methods, including scale normalized, normalized gray-scale, histogram equalization, and the use of wavelet analysis to filter out people face of the low-frequency part of the picture.

(2) described in detail based on statistical characteristics of the three feature extraction methods, namely, PCA (principal component analysis) 、 LDA (Fisher face method) 、 KPCA (Kernel Principal Component Analysis).

(3) Introduced a support vector machine method, discussed how to obtain a better kernel function, and introduced the support vector machine how to use SVM multiclass classification problem to solve.

(4) In this paper, the system processes, methods and specific algorithms to build a camera recorded images of the dynamic face recognition system. Test a number of point of view, a variety of obstacles, a variety of expression conditions such as interference with the outside world under a variety of algorithms to identify the accuracy and efficiency, and experimental results are summarized and concluded.

**Keywords:** Face Detection; Face Recognition; PCA; KPCA; Support Vector Machine

# 中南民族大学

## 学位论文原创性声明

本人郑重声明：所呈交的论文是本人在导师的指导下独立进行研究所取得的研究成果。除了文中特别加以标注引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写的成果作品。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后果由本人承担。

作者签名：

日期： 年 月 日

## 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。本人授权中南民族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。

本学位论文属于

1、保密，在\_\_\_\_\_年解密后适用本授权书。

2、不保密。

(请在以上相应方框内打“ ”)

作者签名：

日期： 年 月 日

导师签名：

日期： 年 月 日

# 第1章 引言

## 1.1 研究的背景与意义

随着网络技术的飞速发展，在电子商务中数字产品占据了非常大的份额。在日常生活中，人们可以方便快捷地借助网络获得图像，音频和视频等数字产品，并且，人们可以利用各种各样的多媒体处理软件，因此多媒体数字产品成了解决我们现实问题的主要帮手。从人脸识别技术逐渐进入研究者视线至今，已有接近四十年的历史。在这些年里，人脸识别技术逐渐成为目前基于生物特征研究的一大热点，被诸多领域纳入研究范围，其中包括模式识别、人机交互、人工智能等。与指纹识别等传统的识别模式相比，人脸识别的非侵扰性，快速便捷等特性都较容易使被识别者接受，因此人脸识别技术在商业，安全，出入控制等诸多领域得到了广泛的应用。人脸识别就是利用各种各样的多媒体设备，通过这些媒体设备和处理软件获取实时的图片输入流，然后再经过各种算法对图像进行人脸的检测、人脸的识别以及分类，最终判定识别的结果并计算精度等。

人脸识别技术是基于生物特征的识别方式<sup>[1]</sup>，所谓生物特征识别，就是利用人类自身所拥有的、并且能够唯一标识其身份的生理特征或者行为特征进行身份验证技术。一般意义上生物特征分生理特征和行为特征两种。由于生物特征的多变性，背景的多样性以及环境的复杂性等因素，人脸识别技术发展的道路上存在着很多难关，如提高系统的鲁棒性、提高算法的泛化能力、增强抗干扰能力等。早期的人脸识别技术仅限于条件充分的情况下，即满足没有各种外界干扰、没有任何饰物阻挠也没有表情影响等苛刻条件下，能获得很好的识别效果；这些年来这样的情况有了变化，由于对人脸识别技术的研究日益深入，研究团队也日益精良，所以新的更高质量的算法层出不穷，而一旦有一种处理方法问世，就会有更多研究者对它进行研究和改进，以获得更好的识别和匹配效果，所以目前这个技术的发展状况已达到可以实时地对人脸进行操作<sup>[2]</sup>。由于这种方法是直接地通过多媒体设备进行，不通过网络，可以排除网络的各种不安全因素，如截取修改，获取到本地后修改等，所以在很多特定领域都有极高的实用价值，如安全领域。

目前的人脸识别方法主要是通过从视频流的图像中提取稳定的特征量，随后通过

一定的算法对它们进行分析匹配，提取出的较稳定的特征量，将得到的特征量与待识别图像中提取的特征量进行比较，以此来判断二者是否匹配。由此可以看出，人脸识别系统中最关键的就是人脸特征提取和模式识别这两个模块，好的特征提取方法可以将非线性特征转换到高维空间实现线性分类，如 KPCA 算法，这样可以简化后面的分类工作，达到更好的模式识别效果。同样，好的分类器也可以简化前一个特征提取步骤，降低这个步骤的计算复杂度和减少计算量。所以这两个模块是相辅相成又相互制约的。

## 1.2 现实情况和进展速度

在人脸识别技术发展的最初阶段，识别方法相对单一，主要就是通过简单的脸部特征和可以唯一表示个体特征的指纹相结合来进行识别，这个方法需要工作人员的全程跟踪以及被识别者的配合，因此在这一阶段的识别过程几乎全部依赖于操作人员，这显然不属于自动识别系统的范畴，存在着很大的限制，实现起来很不方便，也满足不了使用者的要求。由于这些限制，很多对此技术感兴趣的研究者对这个方法进行了改进，思路就是利用人脸中相对比较稳定的某些特征比例来进行对人脸的检测和识别匹配，这一个时期使用的是欧式距离法来表示人脸中比较稳定的比例，比如眉眼之间，嘴鼻之间，额眉之间等，人脸特征中的这些比例值比较不受外界各种因素的干扰，即使年龄变化比例的调整也相对比较小<sup>[3]</sup>。由于这些比例的稳定性，这个时期的技术获得了一定的发展，识别的效率和精度都得到了很大程度的提高，但由于这个方法的前提是必须准确地提取各种人脸的特征比例，也需要有操作人员才能保证精确地完成提取工作，仍然摆脱不了人的干预，而且需要利用操作员的某些先验知识，所以还是有很多缺陷。最近这些年里，由于网络及各种网络技术的快速发展，真正多侧面、系统的，实时的检测系统才开始初见端倪。已经实现了的性能优良的识别系统基本上是使用了以下几种识别方法：几何识别方法，代数识别方法和连接机制识别方法。这些方法很大程度上促进了人脸识别技术的发展，也使人脸识别技术被应用于很多领域，比如监控系统，缉凶，寻人等，具有很大的实际意义和用途。

## 1.3 人脸识别的开放性问题和技术趋势

### 1.3.1 人脸识别的难点

经过近四十年的发展，人脸识别技术有了很大程度的发展。目前最优的系统识别率在样本数字比较大的情况下可以达到 96%以上，错误验证率也控制在了 3%以下，但这种性能的系统并不能看作是真正最优的系统，也不能说明这个技术已经很完美，技术在进步但是使用者的要求也越来越高，他们希望识别系统的效率能越来越高，识别精度能越来越好，所以这个技术的精进也迫在眉梢。如 1.1 节提到的，这个技术的精进道路上存在着很多难题，这些难题现在还没有得到很好的解决，比如不同年龄的人，脸部的特征会由于皱纹、松弛、眉色、发色发生一些变化，虽然变化不是很大，但对检测和识别匹配的结果存在着很大的影响；不同的阳光或是灯光的照射也会使特征提取的过程受到很大的限制，直接对最后的识别结果产生很大的影响，本文第五章通过实验获得的实验数据可以清楚地证实这一点；不同环境下人们的穿着打扮也会影响人的脸部特征的获得，比如之前不戴眼镜的戴上眼镜，遮住了重要的眼部特征，不同的留刘海状况会改变所提取的额头信息等；不同的姿势获取角度也是必然会影响结果的；现在整容技术越来越普及和发达，这个技术的发展也对我们提取人的脸部特征产生很大的阻碍，对结果也是有致命的影响<sup>[4]</sup>；以上都是自然和人自身条件变化对识别结果的影响，另外还有些科技上的影响也不能被我们忽视，比如多媒体设备选取的不同，这个会影响对源文件的识别；还有技术实现过程中使用的算法本身就不是完美的，或多或少存在着缺陷，所以克服这些不足也是在精进人脸识别技术过程中必须要尽力去做的。

另外，由于现实生活中识别环境很复杂，而且干扰因素不可预测，人脸识别技术面临的更大的难点是以上列举出和未列出的各种难题从来都不是单独出现的，一般情况下这些干扰都是结伴出现，现实生活中很多识别环境都是同时满足以上很多项难点特征，所以如何精湛识别进程，强化识别算法以有效地分离和解决各种难题，融合所有方法的优点以解决相互融合的干扰等，需要我们做的工作还有很多，精进的道路也还很长。

### 1.3.2 趋势

难题虽然很多但我们必须步步为营，个个击破以达到我们的目的。现在整体技术领域的努力方向大致是找到更好的算法或是减少算法本身的不足来提高识别的效率和精度。另外可以通过提高整体多媒体设备的性能来提高获取高质量的源文件的能力，使识别过程在运行初期就能奠定很好的基础；最后就是要深层次地摸索能够更好识别

人脸的技术模型，现在这些技术和模型也都在研发过程中<sup>[5][6]</sup>。（如图 1.1 所示）

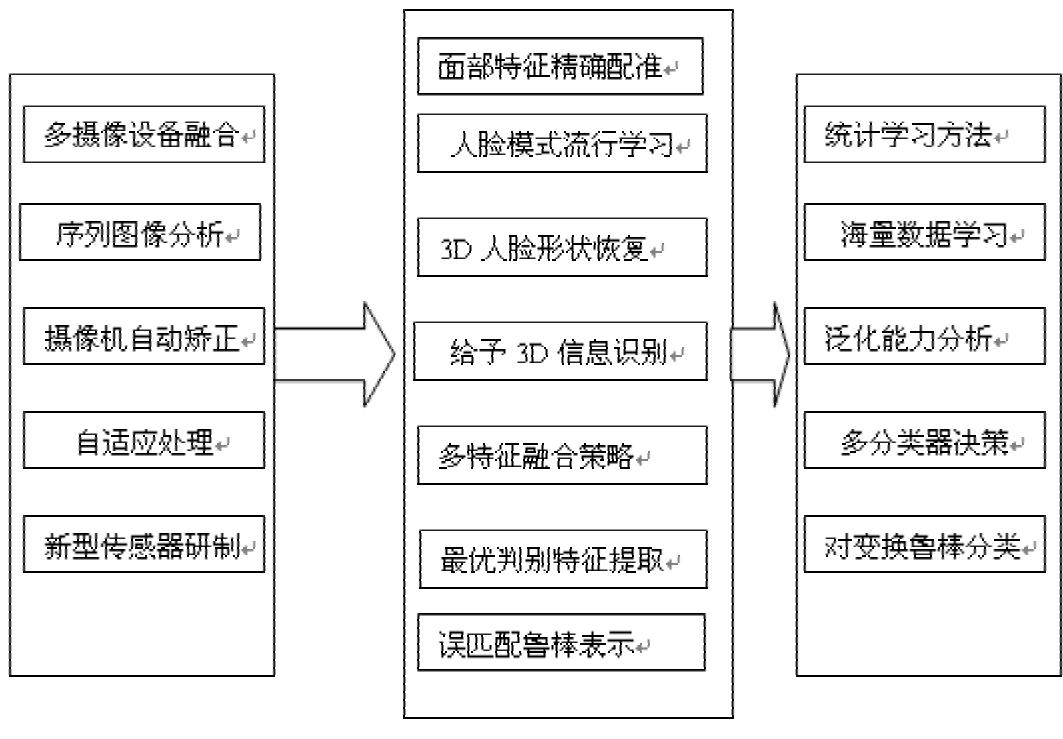


图 1.1 技术发展大致方向

总体的识别过程<sup>[7]</sup>如图 1.2 所示。

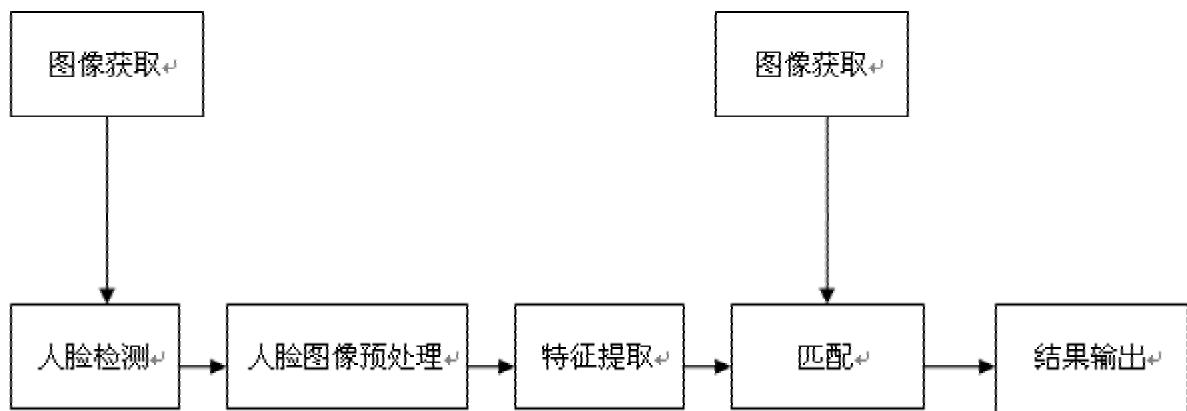


图 1.2 识别过程

如图所示，识别过程的第一步是通过多媒体设备获取源图像，通过人脸检测方法得到有人脸的图像并对该图像进行一定的预处理，如归一化、小波分解等；通过预处理后的图像保留了人脸最本质、对特征提取最有利的部分，滤去了外界的部分干扰因

素，如光照、饰物等。然后选定一种特征提取算法对该预处理过的图像进行特征提取的步骤，最后根据与测试图像的比对来获得匹配结果。

## 1.4 所做工作及内容安排

本文从构建一个动态的人脸识别系统着手，讨论了整个构建工作的流程，对各环节所需的技术、算法作了介绍和研究。整个过程所作的具体工作如下：

(1)首先阐述了人脸检测及预处理的重要性，介绍了几种将获取的源文件进行初步的预处理的方法，包括尺度灰度归一化，直方图处理等，并加入了小波分解过滤出人脸图片中的低频部分，对待识别的图片进行一次或二次的小波变换分离出不易受各种外在条件干扰的低频子图片。然后再对该子图片进行特征提取，这样可以提高识别系统的抗干扰能力，提高识别精度。

(2)详细介绍了三种基于统计特征的特征提取方法，即 PCA(主成分分析方法)、LDA(Fisher 脸方法)、KPCA(核主成分分析方法)。列出了个算法的实现步骤以及实验结果。总结可得出，KPCA 相对于 PCA 各有优缺，PCA 易实现，计算量相对较小；KPCA 更适合处理非线性问题，但也存在一些问题，如计算量大，有的核函数矩阵灵敏度太高，不易得到好的结果等。LDA 方法是在 PCA 方法的基础上找到一个由最大类间和类内距离比的模式样本的最佳鉴别向量空间，即最终实现将样本的线性分离。各种实验表明，KPCA 具有比前两种方法更优的识别能力，它的识别率更高，但它仍存在计算量过大等问题。

(3)介绍了支持向量机方法，并分别介绍了线性和非线性支持向量机的原理及实现方法，讨论了如何获取较好的核函数，另外介绍了支持向量机如何实现用 SVM 解决多类分类问题。

本文的篇幅安排：

第 1 章 介绍课题的研究背景、意义以及发展中遇到的和亟需解决的困难，介绍了本文的主要工作和篇幅。

第 2 章 介绍动态人脸检测技术。包括动态检测方法和图片的预处理过程。

第 3 章 详细阐述了基于统计特征，即代数特征的三种人脸特征提取方法及其实现算法，论述了他们各自的优缺点。

第 4 章 研究了支持向量机用于人脸分类操作的方法。

第 5 章 主要系统的实现与对实验结果进行分析。

## 第2章 动态人脸检测技术和人脸识别的预处理

### 2.1 动态人脸检测技术

检测运动中的人的脸部特征是根据早期检测图片，照片之类的静态图片技术发展而来的，主要是根据摄取到的各个角度的动态特征和一些实用的运动框架来达到检测动态特征的目的<sup>[8]</sup>。这项技术有个很重要的特点就是检测的量大，因为要获得高质量的识别效果就必须综合多张视频序列流中的图片，以提取比较鲜明稳定的特征用于识别匹配。这个特点对算法的检测速度提出了很高的要求，因为实时检测是没有时间缓冲的，如果速度过慢，就只能获取少量而且是间断的源图片，不能很好地描述被识别者的人脸运动轨迹和角度，这样就会对最后的识别匹配结果产生影响，甚至无法识别<sup>[9]</sup>。基于知识的人脸检测方法就可以快速的对人脸进行检测<sup>[10]</sup>。人脸识别技术发展初期的检测方法因为是基于静态图片的，所以只对识别的精度非常关注，对效率没有很高的要求。而现在的识别系统一般是基于动态人脸提取，对效率的要求相当高，同时又不能降低精度，所以难度非常大<sup>[11]</sup>。如何同时提高识别匹配的最初获取效率和最终实现精度是我们必须努力的方向。目前所使用的方法主要是利用获取的源文件的运动信息，将物体从背景和其他的一些干扰、障碍物中分离出来单独识别匹配。该信息的分离主要有以下两种方法<sup>[12,13]</sup>：

#### (1)光流法

光流法是以高计算复杂度和低抗噪性的代价来换取检测较大帧之间位移的方法。这种方法通过利用物体运动的光流动信息来判断是否有人脸出现在图片中，由于它的计算复杂度相当大，所以需要很强大的硬件条件做支持，而且很难做到实时检测，另外抗噪效果也不佳，所以很难满足现代技术发展的要求。

#### (2)帧间差分法

帧间差分是判断两幅邻帧之间的变化，通过两帧之间的变化来判断是否有人脸图像出现在这两帧里，主要使用所判断图像的灰度值以及计算阈值来获得这两帧之间的变化。具体算法如下：

二值差分图  $D(x,y)$ ，表示是第  $k$  帧  $f_k(x,y)$  和第  $k+1$  帧  $f_{k+1}(x,y)$  之间的变化。

$$D(x, y) = \begin{cases} 1 & \text{if } |f_{k+1}(x, y) - f_k(x, y)| > T \\ 0 & \text{others} \end{cases} \quad (2-1)$$

其中阈值为  $T$ 。为 0 的情况是稳定的部分反之为 1 的部分就是我们需要判断的运动的部分。

由于这种方法存在一些缺陷，所以有些对该技术感兴趣的研究者对该技术做了些改进，改进思路主要是由原来的两帧判断增加到利用三帧进行判断，计算式如下：

$$D(x, y) = \begin{cases} 1 & \text{if } |f_k(x, y) - f_{k-1}(x, y)| > T \text{ and } |f_{k+1}(x, y) - f_k(x, y)| > T \\ 0 & \text{others} \end{cases} \quad (2-2)$$

## 2.2 人脸识别的预处理

### 2.2.1 样本的标准化操作

由于人脸识别的源文件都是由多媒体设备采集到的，而目前的多媒体设备采集的源文件一般都为彩色 RGB 图像，人脸识别技术也可以对彩色图像进行很好的人脸检测和跟踪<sup>[14,15]</sup>，但由于我们所使用的 PCA 算法需要的是灰度图像，所以必须将我们所获取的彩色 RGB 图像转换为灰度图像，所使用的公式如下(( 2-3 ) 所示)：

$$\begin{aligned} Gray &= (W_R R + W_G G + W_B B) / (W_R + W_G + W_B) \\ Gray &= 0.30 \times R + 0.59 \times G + 0.11 \times B \end{aligned} \quad (2-3)$$

转换为灰度图像后，为了使检测图像和对比图像能很好地统一，便于识别和匹配，下一步就必须对图像进行预处理，主要有以下几种方法：

#### 1. 尺寸归一化

由于我们获取的图像不一定跟我们所比对的人脸库中的图像尺寸一致，所以在识别前期就必须将获取的图像尺寸转换成对比人脸库中图像的尺寸，具体方法如下：

设原始样本图像为  $[F(x, y)]_{P \times Q}$ ，图像 Width 和 Height 分别为 P 和 Q，尺寸归一化后为  $[G(x, y)]_{W \times H}$ ，试验中人脸样本取 W=92，H=112(ORL 库中直接规定)；尺寸归一化后，源图像与符合规格图像的对应比例为：

$$G(x, y) = F(x/r_x, y/r_y) \quad (2-4)$$

$x$  和  $y$  方向的尺度变换因子为  $r_x$  和  $r_y$ ，它们的值分别是： $r_x = Q/H$ ， $r_y = P/W$ ；

因为  $x/r_x$ ,  $y/r_y$  的取值一般情况下为小数 , 所以必须对  $F(x/r_x, y/r_y)$  值进行估计。对于固定  $(x, y)$  , 令 :

$$\begin{cases} x/r_x = x_0 + \Delta_x, 0 \leq \Delta_x, \Delta_x < 1 \\ y/r_y = y_0 + \Delta_y, 0 \leq \Delta_y, \Delta_y < 1 \end{cases} \quad (2-5)$$

里面  $x_0$ ,  $y_0$  的值分别为:  $\begin{cases} x_0 = [x/r_x], \Delta_x = x/r_x - x_0 \\ y_0 = [y/r_y], \Delta_y = y/r_y - y_0 \end{cases}$ , 可得 :

$$\begin{aligned} G(x, y) = F(x_0 + \Delta_x, y_0 + \Delta_y) &= F(x_0, y_0)\Delta_x\Delta_y + F(x_0 + 1, y_0)(1 - \Delta_x)\Delta_y \\ &+ F(x_0, y_0 + 1)\Delta_x(1 - \Delta_y) + F(x_0 + 1, y_0 + 1)(1 - \Delta_x)(1 - \Delta_y) \end{aligned} \quad (2-6)$$

## 2. 直方图均衡化

直方图表示的是待检测图片中所有像素点的亮度值及其分布 , 依此也可以判断整张图片的亮度主要集中在哪些区域 , 哪些范围。如图 2.1 所示。

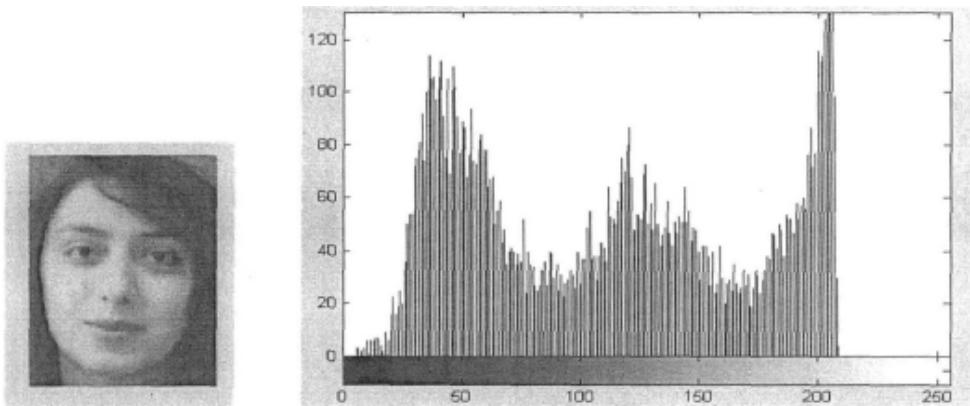


图 2.1 原始的直方图

一般的灰度图亮度主要集中在几个范围 , 整张平面上的灰度分布并不平均 , 有的亮度值在整张图里所占的比例很大 , 有的亮度值可能在整张图里都没有相应的像素点。因此直方图均衡化的作用就是将所有的灰度值平均分布到各个区域 , 削减占有比例很高的灰度值同时填补占有比例很低甚至没有的灰度值 , 这种方法可以部分减少阳光 , 灯光等光源对脸部不同角度的照射而引起的特征提取困难。图 2.2 为直方图均衡化后的直方图。

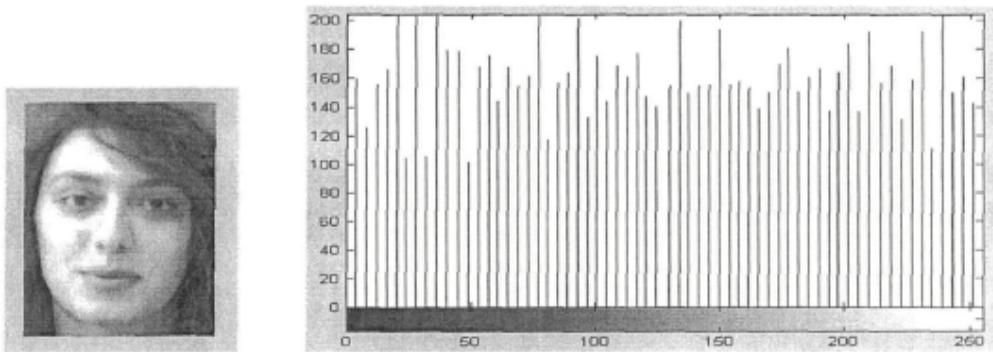


图 2.2 均衡化后直方图

对于数字图像， $N_k$  为第 k 级灰度的出现的频率值：

$$H(k) \in E[0,1] = \sum_{i=0}^k \frac{N_k}{N} = \sum_{i=0}^k p(i), k = 1, 2, GL - 1 \quad (2-5)$$

式中， $N_k$  为灰度级为 k 的像素数，N 为图像中总的像素数。可得到直方图

变换函数：

$$H(k) = \sum_{i=0}^k \frac{N_k}{N} = \sum_{i=0}^k p(i) \quad (2-6)$$

因此  $H(k) \in E[0,1]$ ，且  $H(k)$  在区间  $[0,1]$  内单调递增。

在这篇文章里，我们采用的统一化公式如下：

设统一化后图像的均值为  $M_0$ ，方差为  $v_0$ ，经过统一化变换后的一个随机坐标  $(i, j)$  的像素点的灰度值设为  $N_0(i,j)$ ， $N(i,j)$  为源人脸图像的灰度值， $v$  和  $M$  为源人脸图像的方差和均值。

由于有

$$\frac{[N_0(i,j) - M_0]}{v_0} = \frac{[N(i,j) - M]^2}{v} \quad (2-7)$$

所以

$$N_0(i,j) = M_0 + \sqrt{v_0(N(i,j) - M)^2 / v} \quad N(i,j) \geq M \quad (2-8)$$

$$N_0(i,j) = M_0 - \sqrt{v_0(N(i,j) - M)^2 / v} \quad N(i,j) < M \quad (2-9)$$

## 2.3 小波分解用于人脸识别

小波，实际上就是一种以一种很小的“波”的函数表达，很小的意思是在 0 附近定义，其余的区间很快衰减到零。经过平移，伸缩，形成很多个这种函数，利用这些小的“波”，可以表示某一个函数<sup>[16]</sup>。伸缩，造成了小波函数使用时的分辨率的效果。举个例子，从远处看一个人，只有轮廓，分辨率低，走近一些，分辨率提高，就能更清楚地看到这个人的特征。对函数的小波分解，就是这种带有分辨率效果的分解。函数被分成很多部分，这些部分分为低频的部分，也就是函数的大致轮廓，高频部分，也就是函数的细节部分。图像，也可以看作是一个函数。对图像做过小波变换之后，低频的部分和原来的图像很相似，但少了细节，因为细节都在高频部分，经过小波变换后就可以被过滤。这个特性可以过滤掉外界因素对人脸的干扰，留下最本质的部分供后面的算法运算。所以在提取人的脸部特征之前先进行小波变换可以提高特征提取的质量，有利于提高识别的效率和精度<sup>[17]</sup>。

另外可以根据要处理图像的分辨率来判断是否进行多次小波变换，如果分辨率较低则只适合进行一次小波变换。图 2.3、图 2.4 分别为一维和二维的小波分解的示意图

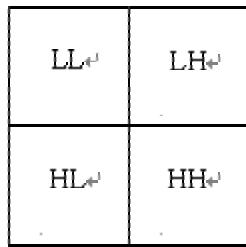


图 2.3 一维小波分解

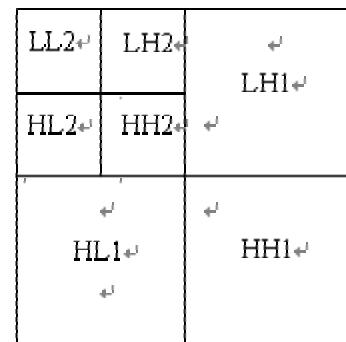


图 2.4 二维小波分解

其中 LL 就是指的图像的低频部分，也就是人脸的比较本质、相对稳定的特征，而其他三个部分则分别代表人脸其他比较容易受干扰的部分，识别过程中我们不予采纳。

小波分解可以实现对图像的降维处理，并分离出图像中不易受表情等外界因素干扰的低频部分用于识别。对于处理彩色图像，小波分解方法也有很好的获取低频信息的

效果<sup>[18]</sup>，但由于本文中使用的基于代数特征的特征提取方法，这种类型的特征提取方法是对灰度图进行特征提取，所以必须先将图像进行灰度归一化处理后在进行小波分解获取人脸的稳定特征。

## 2.4 本章小结

本章主要介绍了两种人脸检测方法，即光流法和帧间差分法，其中光流法是利用物体运动的光源信息来对图像中是否存在人脸进行检测，这种方法对硬件要求极高，检测速度较慢。帧间差分法是较实用的一种方法，主要是利用两帧之间的差值变化来判断是否存在人脸。另外介绍了几种对图像进行预处理对方法，包括归一化方法（灰度、尺寸）、直方图均衡化方法以及小波分解方法。小波分解方法是通过小波变换来过滤图像中有较多干扰信息的高频部分，留下特征比较稳定的低频部分信息来进行特征提取。

## 第3章 人脸图像的特征抽取

人脸识别的基础是特征提取，如何提取出有效的特征用于后期的识别匹配，对于提高人脸识别的效率和精度至关重要。目前的特征提取方法主要有三大类，基于几何特征的，基于代数特征的和基于连接机制的人脸的特征提取方法<sup>[19]</sup>。本章介绍的三种方法都是基于代数特征的人脸特征提取方法。其中 PCA 算法是一种降维算法，其实质是过滤图像中的高频干扰信息，留下比较本质的，识别效果较好的低频部分特征信息来提高识别匹配的效率。但高频部分的一些有效信息也同时被过滤，这样就降低了系统的识别率。LDA 算法就是对 PCA 算法对高频部分提取的一种改进和补充，它的主要目标是使样本的类间和类内离散度比值尽量大，使它们最大程度地分离以达到更好的匹配识别效果。KPCA 算法是对 PCA 算法的一种非线性扩展，它主要是利用映射空间，用非线性方法来提取人的脸部特征进行识别匹配。这种算法因为是将非线性特征向高维空间进行映射，然后使用 PCA 算法，所以计算量相当大，这是它的一大缺点，但它可以降低分类环节的设计难度作为补偿<sup>[20]</sup>。

### 3.1 PCA 算法

对同一个体进行多项观察时，必定涉及多个随机变量  $X_1, X_2, \dots, X_p$ ，它们都带有相关性，一时难以综合，图像就是这样。这时就需要借助主成分分析 (principal component analysis) 来概括诸多信息的主要方面。我们希望有一个或几个较好的综合指标来概括信息，而且希望综合指标互相独立地各代表某一方面的性质。

任何一个度量指标的好坏除了可靠、真实之外，还必须能充分反映个体间的变异。如果有一项指标，不同个体的取值都大同小异，那么该指标不能用来区分不同的个体。由这一点来看，一项指标在个体间的变异越大越好。因此我们把“变异大”作为“好”的标准来寻求综合指标。

#### 3.1.1 主成分的一般定义

设有随机变量  $X_1, X_2, \dots, X_p$ ，样本标准差记为  $S_1, S_2, \dots, S_p$ 。首先作标准化变换我们有如下的定义：

- (1) 若  $C_1 = a_{11}x_1 + a_{12}x_2 + \dots + a_{1p}x_p$ ，且使  $Var(C_1)$  最大，则称  $C_1$  为第一主成分；

- (2) 若  $C_2 = a_{21}x_1 + a_{22}x_2 + \dots + a_{2p}x_p$ ,  $(a_{21}, a_{22}, \dots, a_{2p})$  垂直于  $(a_{11}, a_{12}, \dots, a_{1p})$ , 且使  $Var(C_2)$  最大, 则称  $C_2$  为第二主成分;
- (3) 类似地, 可有第三、四、五...主成分, 至多有  $p$  个。

### 3.1.2 主成分的性质

主成分  $C_1, C_2, \dots, C_p$  具有如下几个性质:

- (1) 主成分间互不相关, 即对任意  $i$  和  $j$ ,  $C_i$  和  $C_j$  的相关系数

$$Corr(C_i, C_j) = 0 \quad i \neq j$$

- (2) 组合系数  $(a_{i1}, a_{i2}, \dots, a_{ip})$  构成的向量为单位向量

- (3) 各主成分的方差是依次递减的, 即

$$Var(C1) \geq Var(C2) \geq \dots \geq Var(Cp)$$

- (4) 总方差不增不减, 即

$$Var(C1) + Var(C2) + \dots + Var(Cp) = Var(x1) + Var(x2) + \dots + Var(xp) = p$$

这一性质说明, 主成分是原变量的线性组合, 是对原变量信息的一种改组, 主成分不增加总信息量, 也不减少总信息量。

- (5) 主成分和原变量的相关系数  $Corr(C_i, x_j) = a_{ij} = a_{ij}$

- (6) 令  $X_1, X_2, \dots, X_p$  的相关矩阵为  $R$ ,  $(a_{i1}, a_{i2}, \dots, a_{ip})$  则是相关矩阵  $R$  的第  $i$  个特征向量(eigenvector)。而且, 特征值  $\lambda_i$  就是第  $i$  主成分的方差, 即

$$Var(C_i) = \lambda_i$$

其中  $\lambda_i$  为相关矩阵  $R$  的第  $i$  个特征值(eigenvalue)

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$$

### 3.1.3 主成分的数目的选取

前已指出, 设有  $p$  个随机变量, 便有  $p$  个主成分。由于总方差不增不减,  $C_1, C_2$  等前几个综合变量的方差较大, 而  $C_p, C_{p-1}$  等后几个综合变量的方差较小, 严格说来, 只有前几个综合变量才称得上主(要)成份, 后几个综合变量实为“次”(要)成份。实践中总是保留前几个, 忽略后几个。

保留多少个主成分取决于保留部分的累积方差在方差总和中所占百分比(即累计贡献率), 它标志着前几个主成分概括信息之多寡。实践中, 粗略规定一个百分比便可决

定保留几个主成分；如果多留一个主成分，累积方差增加无几，便不再多留。

PCA 的基础是 K-L 变换，下面对 K-L 变换作一个简单的算法介绍<sup>[22, 23]</sup>：

设  $X$  为  $n$  维的随机变量，可以用  $n$  个基向量的加权和，来表示  $X$ ：

$$X = \sum_{i=1}^n \alpha_i \phi_i \quad (3-1)$$

式中： $\alpha$  为加权系数， $\phi$  为基向量，此式还可以用矩阵的形式表示：

$$X = (\phi_1, \phi_2, \dots, \phi_n)(\alpha_1, \alpha_2, \dots, \alpha_n)^T = \Phi \alpha \quad (3-2)$$

其中

$$\Phi = (\phi_1, \phi_2, \dots, \phi_n), \alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)^T \quad (3-3)$$

取基向量为正交向量，得：

$$\Phi_i^T \Phi_j = \begin{cases} 1 & j = i \\ 0 & j \neq i \end{cases} \quad (3-4)$$

由于  $\Phi$  是由正交向量构成，所以  $\Phi$  为正交矩阵，则

$$\Phi^T \Phi = I \quad (3-5)$$

将公式(3-2)两边都左乘上  $\Phi^T$ ，得：

$$\alpha = \Phi^T X \quad (3-6)$$

则：

$$\alpha = \Phi_i^T X \quad (3-7)$$

我们希望向量  $\alpha$  的各个向量间互不相关，要保证  $\alpha$  的各个分量互不相关，需要取决于选取什么样的正交向量集  $\{\Phi_j\}$ 。

设随即向量的总体自相关矩阵为：

$$R = E[X^T X] \quad (3-8)$$

将(3-2)代入(3-8)式，得

$$R = E[X^T X] = E[\Phi \alpha \alpha^T \Phi^T] = \Phi E[X^T X] \Phi^T \quad (3-9)$$

我们要求向量  $\alpha$  的各个分量间互不相关，即满足下列关系：

$$E[\alpha_j \alpha_k] = \begin{cases} \lambda_j & j = i \\ 0 & j \neq i \end{cases} \quad (3-10)$$

写成矩阵的形式是：

$$\begin{pmatrix} \lambda_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \lambda_n \end{pmatrix} = \Lambda \quad (3-11)$$

则：

$$R = \Phi \Lambda \Phi^T \quad (3-12)$$

将上式两边都右乘上  $\Phi$ ，得：

$$R\Phi = \Phi \Lambda \Phi^T \Phi \quad (3-13)$$

由于  $\Phi$  是正交矩阵，则得：

$$R\Phi = \Phi \Lambda \quad (3-14)$$

则：

$$R \Phi_j = \Lambda_j \Phi_j \quad (j=1,2,\dots,n) \quad (3-15)$$

可以看出， $\lambda_i$  是  $X$  的自相关矩阵  $R$  的本征值， $\Phi_j$  是对应本征向量。因为  $R$  是实对称矩阵，其不同本征值对应的本征向量应正交。

自相关矩阵的求法简单地来说就是：如果有  $n$  个数据，自相关矩阵是  $n*n$  的方阵。它的主对角线上都是  $R(0)$ ，主对角线旁边两个是  $R(1)$ ，然后再旁边两个是  $R(2)$ ，等等，最右上角和最左下角是  $R(N)$ 。在上面的式子中  $R(m)=[x(n)*x(n+m)]/n$ ， $m=0,1,2,\dots,n$ 。

主要实现代码为：

```
R1=zeros(m,m);
r=zeros(m,1);
for mm=1:m
    for n1=(mm+1):m
        r(mm)=r(mm)+Z(n1)*conj(Z(n1-mm))/m;
    end
end
for l1=1:m
    for l2=l1:m
        R1(l1,l2)=r(l2-l1+1);
    end
end
```

```

for l3=2:m
    for l4=1:l3-1
        R1(l3,l4)=conj(r(l3-l4+1));
    end
end

```

## 3.2 LDA 算法

### 3.2.1 LDA 算法

LDA 算法是线性鉴别分析的简称，也称为 Fisher 鉴别分析。它是在 PCA 算法的基础上发展起来的，是对 PCA 算法的补充，它的原理是对 PCA 算法中过滤掉的高维特征同样进行再次提炼，分析出里面有识别价值的信息用于后面的识别匹配过程。处理方法是在找到一个合适的投影空间的基础上，将需识别的图像的高维特征空间投影到这个空间上，然后获取识别所需的低维的信息用于识别匹配，它的优点在于可以改变样本类间和类内的离散度，以更好地分离出我们所需的识别信息来进行匹配。它的数据表述就是使类间和类内离散度的比值最大，即类间离散度尽量大、类内离散度尽量小，这样就可以提取出最有价值的特征。其主要算法描述如下：

设有一个含有  $N$  个样本的集合  $F$ ， $F$  中每一样本  $X$  为  $n$  维向量，设模式类别有  $c$  个： $\omega_1, \omega_2, \dots, \omega_c$ ，每类有样本  $n_i$  个，它们的总体散度矩阵  $S_t$ （即总体协方差矩阵）、类内散度矩阵  $S_b$  和类间散度矩阵  $S_w$  分别定义如下：

$$S_b = \sum_{i=1}^c P(\omega_i) (m_i - m_0) (m_i - m_0)^T \quad (3-16)$$

$$S_w = \sum_{i=1}^c P(\omega_i) E\{ (X - m_i)(X - m_i)^T / \omega_i \} \quad (3-17)$$

$$S_t = S_b + S_w = E\{ (X - m_0)(X - m_0)^T \} = \sum_{i=1}^N (X - m_0)(X - m_0)^T \quad (3-18)$$

其中， $P(\omega_i) = n_i/N$  为第  $i$  类训练样本的先验概率， $m_i = E\{X/\omega_i\}$  为第  $i$  类训练样本的均值， $m_0 = E\{X\} = \sum_{i=1}^m P(\omega_i) m_i$  为全体训练样本的均值。

Fisher 鉴别准则函数定义为(19)式，另一等价的 Fisher 鉴别准则函数由(20)给出：

$$J_f(\varphi) = \frac{\varphi^T S_b \varphi}{\varphi^T S_w \varphi} \quad (3-19)$$

$$J(\varphi) = \frac{\varphi^T S_b \varphi}{\varphi^T S_t \varphi} \quad (3-20)$$

其中， $\varphi$  为任一 n 维非零列矢量。

要最大程度地分离样本，就必须是类间和类内的离散度比值最大，因此，如果  $S_w$  是非奇异矩阵，最优的投影方向  $W_{opt}$  就是使得类间和类内的离散度比值最大的那些正交特征向量。因此，Fisher 准则函数定义为：

$$W_{opt} = \arg \max \frac{W^T S_b W}{W^T S_w W} = [w_1, w_2, \dots, w_n] \quad (3-21)$$

$W_{opt}$  是满足如下等式的解

$$S_b W_t = \lambda S_w W_t \quad (i=1, 2, \dots, m) \quad (3-22)$$

也就是对应于矩阵  $S_w^{-1} S_b$  较大的特征值  $\lambda_i$  的特征向量。

### 3.2.2 PCA+LDA 的识别方法

设 PCA 方法得到的第  $i$  类第  $j$  个人脸向量的特征投影为  $p_j^i (j=1, 2, \dots, S; i=1, 2, \dots, C)$ ，每类的样本数为  $S$ ，训练样本总数为  $C$ 。  
首先计算  $\mu$ ，即总样本均值，和各类样本的均值  $\mu_i$ ，将各样的图像减去对应的类均值，即中心化各类训练样本：

$$\forall x \in X_i, X_i \in X, x = x - \mu_i \quad (3-23)$$

然后，将各类均值减去总样本均值：

$$\hat{\mu}_i = \mu_i - \mu \quad (3-24)$$

接下来组成一个数据矩阵，数据矩阵中的值为所有中心化的训练样本图像，并寻找这个数据矩阵的正交基。我们使用的求取正交基的方法是 PCA 方法，设  $U$  为所求出的正交基，将所有中心化的图像投影到这个正交基  $U$  上。

$$\bar{\mu}_i = U^T \hat{\mu}_i \quad (3-25)$$

最后往 LDA 的以下公式中代入以上所求得的参数：

(1) 求解类间集散度矩阵  $S_B$  和类内离散度矩阵  $S_w$

对于第  $i$  类有：

$$S_i = \sum_{x \in X_i} \bar{x}\bar{x}^T \quad (3-26)$$

则得到：

$$\begin{aligned} S_w &= \sum_{i=1}^C S_i \\ S_B &= \sum_{i=1}^C P_i \tilde{\mu}_i \tilde{\mu}_i^T \end{aligned} \quad (3-27)$$

(2) 根据所求得的类间集散度矩阵  $S_B$  和类内离散度矩阵  $S_w$ ，计算出  $\Lambda$  即广义特征值，以及相对应的特征向量  $V$

$$S_B V = \lambda S_w V \quad (3-28)$$

(3) 特征向量的选取

将特征向量按照对应特征值从大到小的顺序进行排列，并仅保留前  $C-1$  个特征向量。与 PCA 方法一样，LDA 方法投影空间维数的选取依然需要通过实践检验才能确定正交基保留的百分比。

(4) 投影和分类

将原始图像投影到正交基  $U$  上，然后把得到的投影图像继续投影到 Fisher 基向量  $W$  上。然后进行分类工作。

### 3.3 核 PCA 的人脸识别方法

#### 3.3.1 核 PCA 算法

核 PCA 算法又叫 KPCA 算法，它是对 PCA 算法的一种非线性扩展，它主要是利用映射空间，用非线性的方法来提取人的脸部的特征进行识别匹配。由于这种算法是对非线性特征进行向高维空间的映射，然后使用 PCA 算法，所以计算量相当大。但它可以简化分类器的设计工作，因此也可作为补偿。

其算法步骤如下：

## 1 所要使用的人脸库数据

$$X = (x_1, x_2, \dots, x_n)$$

## 2 矩阵的点积的计算

$$K_{ij} = (k(x_i, x_j))_{ij} \quad i, j = 1, 2, \dots, n \quad (3-29)$$

$$K_{ij} = K_{ij} - \frac{1}{N} \sum_{m=1}^N I_{im} K_{mj} - \frac{1}{M} \sum_{n=1}^N K_{in} I_{nj} + \frac{1}{N^2} \sum_{mn=1}^N I_{im} K_{mn} I_{nj} \quad (3-30)$$

## 3 计算 $\tilde{K}_{ij}$ 的向特征值 $\lambda_j$ 及和特征向量 $v_j$

## 4 对所求的特征向量进行归一化处理

$$\alpha^k = \frac{1}{\sqrt{\lambda_j}} v_j, \quad j = 1, 2, \dots, n \quad (3-31)$$

## 5 测试样本对特征空间进行投影

$$(kPC)_n(x) = (V^n \bullet \Phi(x)) = \sum_{i=1}^N \alpha_i^k k(x_i \bullet x) \quad (3-32)$$

部分实现代码如下：

```
clear all;
```

```
close all;
```

```
t=0;
```

```
Variances=0.040;
```

```
k=0;
```

```
h=0;
```

```
Vsum=0;
```

```
for i=1:1:100
```

```
    t=t+0.01;
```

```
    x(i,1)=t;
```

```
    x(i,2)=t^2-3*t;
```

```
    x(i,3)=-t^3+3*t^2;
```

```
end
```

```
randn('seed',0);
```

```
e=[0.1*randn(100,1),0.1*randn(100,1),0.1*randn(100,1)];  
xe=x+e;  
  
modelXe_normalization=zscore(xe);  
Vmean=mean(xe(1:100,:));  
Vstd=std(xe(1:100,:));  
  
for m=1:1:100  
    for n=m:1:100  
        mediaVector=modelXe_normalization(m,:)-modelXe_normalization(n,:);  
        KernelMatrix(m,n)=exp(-norm(mediaVector)^2/(2*Variances^2));  
        KernelMatrix(n,m)=KernelMatrix(m,n);  
    end  
end  
  
ell=size(KernelMatrix,1);  
In=ones(ell,ell)./ell;  
centralKernelMatrix=KernelMatrix-KernelMatrix*In-  
In*KernelMatrix+In*KernelMatrix*In;  
  
[U,S] = svd(centralKernelMatrix);  
while(h<=ell)&&(Vsum<99)  
    h=h+1;  
    Vsum=Vsum+S(h,h)/sum(diag(S)) * 100;  
end  
  
k=23;  
V=U(:,1:k);  
L=S(1:k,1:k);  
inverseL=diag(1./diag(L));
```

```

sqrtL=diag(sqrt(diag(L)));
invesqrtL=diag(1./diag(sqrtL));
KernelMatrixFeature=invesqrtL*V'*centralKernelMatrix;
allKernelMatrixFeature=diag(1./(sqrt(diag(S))))*U'*centralKernelMatrix;
for i=1:1:100
    time(i)=i;
    modelT2(i)=KernelMatrixFeature(:,i)'*inverseL*KernelMatrixFeature(:,i)*10;
end

```

### 3.3.2 核 PCA 算法的优缺点分析

KPCA 算法是基于非线性特征的提取，它可以提取到像素间的相关性特征信息，图像中的高阶部分往往携带者部分细节信息，这些信息对于识别结果有着很大的帮助，所以相比 PCA 算法的完全线性提取，KPCA 算法有更好的特征提取效果，同时 KPCA 算法也可以简化下一步的分类设计工作。但由于它属于非线性提取，所以投影的计算复杂度相当大。

## 3.4 本章小结

本章中介绍了三种基于统计特征，即代数特征的特征提取方法，分别为 PCA(主成份分析)方法、LDA ( Fisher 脸 ) 方法以及 KPCA(核主成份分析)方法。分析了这三种方法的实质，列出了各自的实现流程、主要算法及部分实现代码。综合分析得出 PCA 方法是对图像进行去除相关性处理，然后对特征进行线性提取，这种方法适用于图像的压缩与还原；LDA 方法是对 PCA 方法的优化和补充，主要是对 PCA 方法再进行一次特征提取，可以获得相对更多的特征信息。KPCA 方法是对 PCA 方法的非线性扩展，它直接对图像的非线性特征进行操作，由于非线性特征中也含有较多的人脸细节信息，所以这种方法的识别效果比 PCA 方法要好。

## 第 4 章 人脸特征的分类与识别

### 4.1 支持向量机

#### 4.1.1 支持向量机简介

像如何利用一条直线将一个平面上的两类不同的点分开之类的分类问题，我们可能无法在平面上将其完成，但是我们可以通过某种映射，将这些点映射到其它空间（比如说球面上等），这样就有可能在另外一个空间中很容易找到这样一条所谓的“分隔线”，将这些点分开。SVM 基本上就是这样的原理，SVM 的基础是 VC 维理论和结构风险最小原理。它的主要优势体现在小样本、高维模式和非线性等方面，但是 SVM 本身比较复杂，因为它不仅仅是应用于平面内点的分类问题<sup>[21]</sup>。

支持向量机是一种机器学习方法，它的理论基础是统计学习理论。机器学习本质上就是一种对问题真实模型的逼近（选择一个认为比较好的近似模型，这个近似模型就叫做一个假设），但毫无疑问，真实模型一定是不知道的，既然真实模型不知道，那么我们选择的假设与问题真实解之间究竟有多大差距，我们就没法得知。所以假设的选择也带有先验性<sup>[22,23]</sup>。

SVM 的一般做法是：将所有待分类的点映射到“高维空间”，然后在高维空间中找到一个能将这些点分开的“超平面”，这在理论上是成立的，已经通过实践证明，而且在实际计算中也是可行的<sup>[24]</sup>。但是仅仅找到超平面是不够的，因为在通常的情况下，满足条件的“超平面”的个数不是唯一的。SVM 需要的是利用这些超平面，找到这两类点之间的“最大间隔”。

SVM 的基本原理里有两个重要的概念，一个就是上面说到的“最大分类间隔面”，“最大分类间隔面”的优势在于可以提高 SVM 的“推广能力”，因为分类间隔越大，对于未知点的判断会越准确，也可以说是“最大分类间隔”决定了“期望风险”，总结起来就是：SVM 要求分类间隔最大，实际上是对推广能力的控制。另一个是关于“VC”维的概念。VC 维 (Vapnik-Chervonenkis Dimension) 的概念是为了研究学习过程一致收敛的速度和推广性，由统计学习理论定义的有关函数集学习性能的一个重要指标，它是对函数类的一种度量，可以简单的理解为问题的复杂程度，VC 维越高，一个问题就越

复杂。正是因为 SVM 关注的是 VC 维 , SVM 解决问题的时候 , 和样本的维数是无关的 , 这使得文本分类之类的问题很适合用 SVM 来处理。传统的定义是 : 对一个指标函数集 , 如果存在  $H$  个样本 , 能够被函数集中的函数按所有可能的  $2^H$  种形式分开 , 则称函数集能够把  $H$  个样本打散 ; 函数集的 VC 维就是它能打散的最大样本数目  $H$  。若对任意数目的样本都有函数能将它们打散 , 则函数集的 VC 维是无穷大 , 有界实函数的 VC 维可以通过用一定的阈值将它转化成指示函数来定义<sup>[25]</sup>。

另外 , VC 维反映了函数集的学习能力 , VC 维越大则学习机器越复杂 ( 容量越大 ) , 遗憾的是 , 目前尚没有通用的关于任意函数集 VC 维计算的理论 , 只知道一些特殊函数集的 VC 维 , 例如在  $N$  维空间中线形分类器和线形实函数的 VC 维是  $n+1$  。

#### 4.1.2 线性支持向量机

线性支持向量机是目前操作最简单 , 分类效果也很好的分类器形式 , 它的具体原理及实现过程如下<sup>[27]</sup> :

图 4.1 为二维线性可分情况<sup>[46]</sup> , 图中  $H_2$  两边的为两类训练样本 , 它们之间的最近距离越大 , 即这两类样本分得越开 , 最后的识别效果也就越好。如图就是  $H_1, H_3$  之间的距离越大越好。

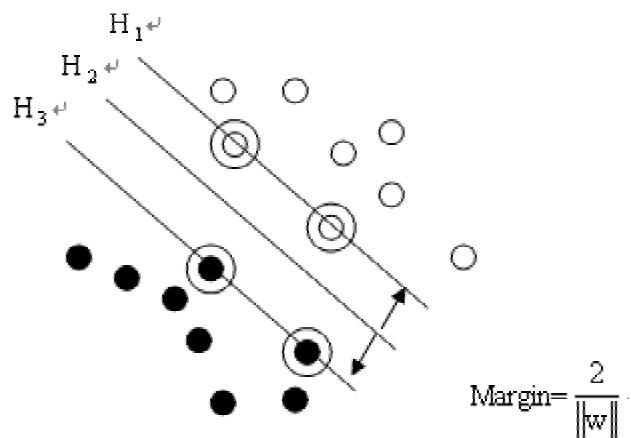


图 4.1 线性可分线性超平面

给定有标识的训练样本集合  $(x_1, y_1), \dots, (x_n, y_n)$ ,  $x_i \in R^n$ ,  $y_i \in \{-1, 1\}$  是  $x_i$  的标识。超平面方程  $(w \cdot x) + b = 0$  满足 :

$$(w \cdot x_i) + b \geq 0 \quad \text{if} \quad y_i = 1$$

$$(w \cdot x_i) + b \leq 0 \quad \text{if} \quad y_i = -1 \quad (4-1)$$

则分类函数就是  $g(x) = (w \cdot x) + b$ 。将分类函数归一化，使两类所有样本都满足  $|g(x)| \geq 1$ （对扩展频谱进行了简单的介绍，然后对视频认证系统，视频认证技术，以及视频认证的目标做了进一步介绍只要样本集是线性可分的，就可以做到这一点），使离分类超平面最近的样本的  $|g(x)| = 1$ ，对扩展频谱进行了简单的介绍，然后对视频认证系统，视频认证技术，以及视频认证的目标做了进一步介绍，这样分类的间隔就等于  $\frac{2}{\|w\|}$ ，因此，使间隔最大等价于使  $\|w\|$  最小。要求分类线对所有样本正确分类，即满足：

$$y_i [(w \cdot x_i) + b] - 1 \geq 0, \quad i=1,2,\dots,n \quad (4-2)$$

SVM 分类器找到最优的超平面，可以正确分类数据点使每一类到超平面的距离最大，不同推广性的 SVM 分类器如图 4.2 所示。

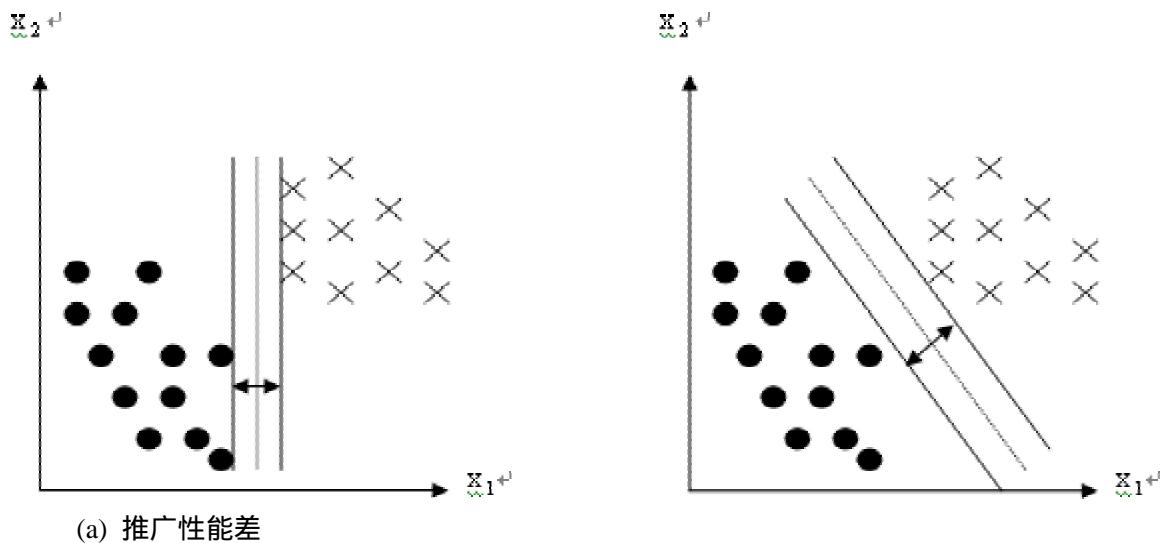


图 4.2 各种推广性能线性超平面的比较

因  $\frac{1}{\|w\|}$  为支持向量与超平面之间的距离， $\frac{2}{\|w\|}$  为支持向量之间的距离，则构造超

平面的问题就转换成求式(4-3)的最小值问题，同时必须受式(4-1)的约束。

$$\Phi(w) = \|w\|^2 \quad (4-3)$$

显然这就是一个二次规划问题，其最优解为(4-4)式 Langrange 函数的鞍点：

$$L(w,b,a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i y_i (wx + b) + \sum_{i=1}^N \alpha_i \quad (4-4)$$

由于 w 和 b 在鞍点处的梯度为零，则：

$$w = \sum_{i=1}^N \alpha_i y_i x_i \quad (4-5)$$

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (4-6)$$

由此可得到最优解满足：

$$\alpha_i (y_i (wx+b) - 1) = 0 \quad (4-7)$$

因为最终分类结果是由支持向量决定的。则 w 可表示如下：

$$w = \sum_{\text{SupportVector}} \alpha_i y_i x_i \quad (4-8)$$

将式(4-5)和式(4-6)代入式(4-4)中，同时必须受式(4-9)和式(4-10)的约束，最大化式如下(4-11)：

$$\alpha_i \geq 0, \quad i=1,2,\dots,n \quad (4-9)$$

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (4-10)$$

$$W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (4-11)$$

如果  $\alpha_0 = (\alpha_1^0, \alpha_2^0, \dots, \alpha_n^0)$  为解空间的一个解，则 w 的范数可以表示如下：

$$\|w\|^2 = 2W(\alpha_0) - \sum_{\text{SupportVector}} \alpha_i^0 \alpha_j^0 y_i y_j (x_i \cdot x_j) \quad (4-12)$$

式(4-11)中的目标函数  $W(\alpha)$  在处理线性不可分问题时的最大值将为无穷大。这个问题必须得到解决，所以 Vapnik 就引入非负的松弛变量  $\xi_i$ ，将式(4-2)变为：

$$y_i [(w \bullet x_i) + b] \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i=1,2,\dots,n \quad (4-13)$$

$\sum_i \xi_i$  是错分训练集中的向量数上界。将错误惩罚分量引入其中，式(4-2)就变为如下形式：

$$\Phi(w, \xi) = Q \left( \sum_{i=1}^n \xi_i \right) + \|w\|^2 \quad (4-14)$$

式中的可调参数 Q 越大，将越严重地惩罚错误。

构造最优超平面的问题可分问题一样处理线性最小式(4-14)，同时必须受式(4-13)的约束，其最优解为(4-15)式 Langrange 函数的鞍点即为最优解，如(4-15)式：

$$L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \left\{ \alpha_i y_i (wx + b) - 1 + \xi_i \right\} - \sum_{i=1}^N \mu_i \xi_i \quad (4-15)$$

其满足下式：

$$\frac{\partial L}{\partial \xi_i} = Q - \alpha_i - \mu_i = 0 \quad (4-16)$$

$$\alpha_i (y_i (wx + b) - 1 + \xi_i) = 0, \forall i \quad (4-17)$$

$$\alpha_i, \mu_i, \xi_i \geq 0, \forall i \quad (4-18)$$

$$\mu_i, \xi_i = 0, \forall i \quad (4-19)$$

由上可得在(4-20)的约束下，最大化式(4-12)

$$0 \leq \alpha_i \leq Q, i=1,2,\dots,n \quad (4-20)$$

若  $\alpha_i \leq Q$ , 则  $\xi_i$  为零。  $b$  的值只需选择  $i$  满足  $0 \leq \alpha_i \leq Q$  即可求出。

在规范的超平面子集中，它的 VC 维  $h$  满足以下不等式：

$$h \leq \min(R^2 A^2, n) + 1 \quad (4-21)$$

#### 4.1.3 非线性支持向量机

非线性支持向量机是通过映射函数将特征空间映射到高维空间，然后再进行分类，它的表示过程如下：

首先有高维空间  $H$ ，并将  $x$  映射到该空间中，映射函数为  $\Phi : R^N \rightarrow H$ ，设核函数  $K$  满足下式：

$$K(x_i, y_i) = \Phi(x_i) \bullet \Phi(y_i) \quad (4-22)$$

$$\begin{aligned} W(\alpha) &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j k_i k_j \{ \Phi(x_i) \bullet \Phi(x_j) \} \\ &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j k_i k_j K(x_i, y_i) \end{aligned} \quad (4-23)$$

$$f(x) = \sum_{SupportVector} \alpha_i y_i \Phi(x_i) \bullet \Phi(x) + b = \sum_{SupportVector} \alpha_i y_i K(x_i, x) + b \quad (4-24)$$

#### 4.1.4 核函数的选择

模型选择得好的支持向量机才会拥有比较好的性能。选择好的模型无疑可以将特征空间很好的分类，大大提高特征匹配的准确率；但如果模型选择得不好，不能将特征空间很有效的分开，那么将会对后面的特征匹配造成很大的阻碍，更甚者使训练样本完全无法匹配到对应的测试样本<sup>[28]</sup>。模型选择是指如何针对所给的训练样本，确定一个比较合适的核函数。这个过程包含两方面的工作：一方面是核函数类型的选择。以目前的技术，选择哪种核函数类型基本还是由经验来判定的，这就存在着隐患；另一方面是通过选定的核函数类型后，通过该函数计算出各个相关的参数。常用的核函数有以三种：

(1) 多项式核函数，如下：

$$k(x,y)=(x \bullet y + 1)^d \quad (4-27)$$

(2) 径向基核函数，如下：

$$k(x,y)=\exp\left(-\frac{\|x-y\|^2}{2\alpha^2}\right) \quad (4-28)$$

(3) 神经元网络类型核函数，如下：

$$k(x,y)=\tanh((x \bullet y) + b) \quad (4-29)$$

### 4.2 多分类支持向量机

由于识别问题的复杂性，多分类问题用 SVM 处理的方法主要有两种，一个是 1-V-A 方法即一对多方法，另一个就是 1-V-1 即一对一的方法<sup>[29]</sup>，下面就会分别对两种方法进行简单地介绍：

#### 4.2.1 一对多多分类支持向量机

一对多多分类支持向量机算法是最早用 SVM 解决多分类问题时所使用的方法。该方法可以构造出  $k$  个 SVM 分类器，SVM 分类器的构造方法如下：第  $i$  个 SVM 对第  $i$  类的所有训练样本标识为大于 0 的数，即 1，而对其他样本标识为小于 0 的数，即 -1。

对于属于  $k$  类中的  $m$  个训练样本  $(x_1, y_1), \dots, (x_m, y_k)$ ，式中  $x_i \in \mathbb{R}^n$ ， $i=1, \dots, m$  同时

$y_i \in \{1, \dots, k\}$ ：

$$\begin{aligned}
 & \min \frac{1}{2} (\mathbf{w}^i)^T \mathbf{w}^i + Q \sum_{j=1}^m \xi_j^i \\
 & (\mathbf{w}^i)^T \Phi(\mathbf{x}_j) + b^i \geq 1 - \xi_j^i \quad \text{if } y_i = i \\
 & (\mathbf{w}^i)^T \Phi(\mathbf{x}_j) + b^i \leq 1 - \xi_j^i \quad \text{if } y_i \neq i
 \end{aligned} \tag{4-32}$$

$\xi_j^i \geq 0, j=1, \dots, m$

$\frac{1}{2} (\mathbf{w}^i)^T \mathbf{w}^i$  最小就可以使  $\|\mathbf{w}^i\|$  大，惩罚  $Q \sum_{j=1}^m \xi_j^i$  能降低样本数的错误率。由以上运算可得出决策函数如下：

$$\begin{aligned}
 & (\mathbf{w}^1)^T \Phi(\mathbf{x}) + b^1 \\
 & \vdots \\
 & (\mathbf{w}^i)^T \Phi(\mathbf{x}) + b^i
 \end{aligned} \tag{4-33}$$

$$\text{Class of } \mathbf{x} \equiv \arg \max_{i=1, \dots, k} (\mathbf{w}^i)^T \Phi(\mathbf{x}) + b^i \tag{4-34}$$

#### 4.2.2 一对多分类支持向量机

一对多分类支持向量机方法在每两类间构造一个分类器，对于一个  $k$  类问题，将有  $k(k-1)/2$  个分类函数<sup>[30]</sup>。对于第  $i$  类和  $j$  类的训练样本，解决下列问题：

$$\min \frac{1}{2} (\mathbf{w}^{ij})^T \mathbf{w}^{ij} + Q \sum_{j=1}^m \xi_j^{ij} \tag{4-35}$$

$$\begin{aligned}
 & (\mathbf{w}^{ij})^T \Phi(\mathbf{x}_j) + b^{ij} \geq 1 - \xi_j^{ij} \quad \text{if } y_i = i \\
 & (\mathbf{w}^{ij})^T \Phi(\mathbf{x}_j) + b^{ij} \leq 1 - \xi_j^{ij} \quad \text{if } y_i \neq i
 \end{aligned} \tag{4-36}$$

$\xi_j^{ij} \geq 0$

#### 4.3 多分类支持向量机用于人脸识别

##### 4.3.1 多分类支持向量机用于人脸训练

多分类支持向量机用于人脸训练的流程需先对测试图像通过几种方法进行预处理，如灰度，尺寸处理，小波分解等；然后对预处理后的图片进行特征提取，使用的

算法是 KPCA 算法；特征提取后通过 SVM 训练器分类<sup>[31]</sup>。

图 4.3 是这篇文章中支持向量机识别的操作流程。

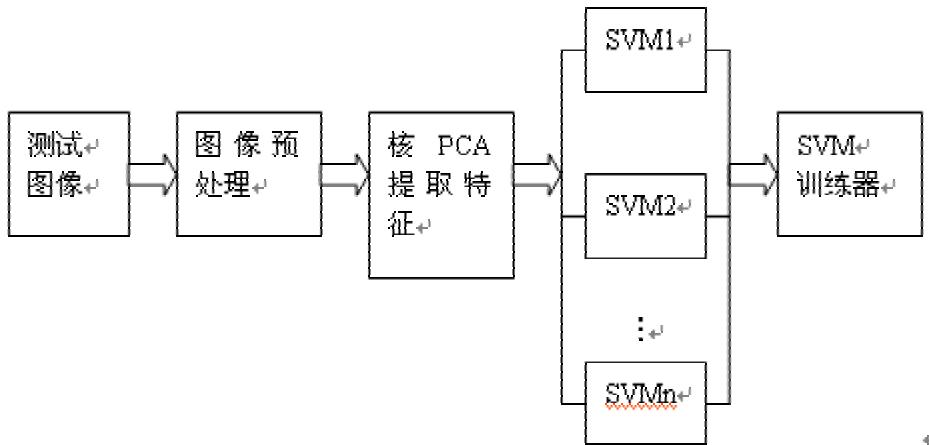


图 4.3 支持向量机操作过程

如图 4.3 所示，第一步输入测试图像，然后对测试的图像进行尺寸、灰度归一化，小波分解等预处理，预处理后的图片再通过 KPCA 方法来提取人的脸部特征，然后根据选定的人脸样本作为正样本，库中其他的人脸样本作为负样本的方法获得 SVM1-SVMn 这 n 个支持向量机，最后组成 SVM 分类器进行分类。

#### 4.3.2 多分类支持向量机用于人脸识别

多分类支持向量机识别过程如图 4.4 所示。

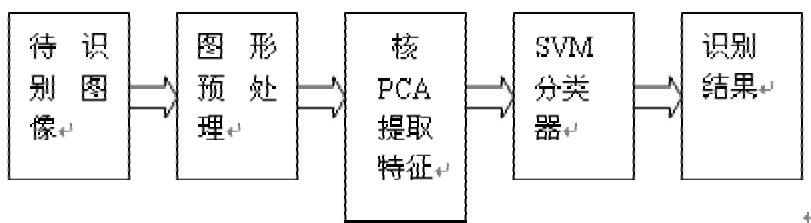


图 4.4 支持向量机识别

如图上图所示，多分类支持向量机的识别过程如下：首先通过多媒体设备获取源文件，然后通过人脸检测方法来获取待识别的图像，获取图像后对该图片进行一系列预处理，如归一化、小波分解等，以获取较稳定的脸部特征图片，然后通过 KPCA 算法提取该图片的脸部特征，最后输入 SVM 分类器中与测试样本特征空间进行分类匹配<sup>[32]</sup>，SVM 分类器的形成过程见上节。最后输出匹配结果。

## 第 5 章 人脸识别系统实现及实验结果分析

### 5.1 各种特征提取方法和不同分类算法相结合的实验结果与分析

#### 5.1.1 维数和样本量与识别率的关系

我们选用的是 ORL 人脸库，其中有 40 人，每人有 10 张不同表情的图像（如图 5.1 所示）。由于人脸识别的方法首先必须从视频中提取人脸部分较稳定的特征量，随后对它们进行一定的算法分析匹配。所以特征提取是人脸识别中很重要的一个环节。我们通过实验，利用 PCA 方法，选取不同特征空间维数和不同样本个数进行训练，采用标准距离分类计算识别率，所得到的实验数据如表 5.1 所示。



图 5.1 ORL 人脸库部分样本

表 5.1 不同维数和样本数对应的识别率

|       | 5 幅   | 4 幅   | 3 幅   | 2 幅   | 1 幅   |
|-------|-------|-------|-------|-------|-------|
| 180 维 | 87.9% | 88.2% | 85.8% | 87.5% | 86.2% |
| 150 维 | 86.8% | 87.5% | 86.9% | 87.2% | 85.2% |
| 120 维 | 88.4% | 86.8% | 87.1% | 86.1% | 81.7% |
| 80 维  | 87.3% | 87.6% | 88.3% | 84.3% | 80.6% |
| 20 维  | 84.5% | 82.6% | 81.9% | 81.4% | 77.2% |
| 5 维   | 65.4% | 62.8% | 61.2% | 57.4% | 54.9% |

分析以上实验数据可得出，在总的子空间维数较少的情况下，子空间的维数越多，识别率也就越高。从实验结果中还可看出，在 120 维和 80 维分别对应 5 幅和 3 幅人脸图像作为训练样本时，识别率可以达到极值，但再增加子空间的维数，识别率并没有相应地继续提高，这就体现了 PCA 方法基于灰度统计原理的缺陷，可能有价值的细节信息会被列入到无效信息不不保存，从而造成识别率的下降<sup>[33]</sup>。

### 5.1.2 三种特征提取方法的试验结果的比较

我们选用 ORL 人脸库，其中有 40 人，每人前 5 张图像作为人脸训练样本，每人后 5 张图像作为人脸测试样本。比较第三章介绍的三种特征提取方法的识别率，如表 5.2 所示，核函数取径向基函数( $\alpha=1$ )。

表 5.2 各种特征提取方法的识别率对比

|       |               | 每人前五张图像 | 每人后五张图像 |
|-------|---------------|---------|---------|
|       |               | 为训练样本   | 为训练样本   |
| 标准距离法 | PCA(主分量)      | 85.1%   | 89.4%   |
|       | Fisher 线性鉴别分析 | 87.9%   | 92.4%   |
|       | KPCA          | 94.5%   | 93.8%   |
| SVM   | PCA(主分量)      | 91%     | 92.1%   |
|       | Fisher 线性鉴别分析 | 91.6%   | 93.2%   |
|       | KPCA          | 95.8%   | 95.3%   |

由实验结果可以看出使用 SVM 支持向量机进行分类可以得到较好的识别效果，

PCA 算法、LDA 算法、KPCA 算法相比较则是 KPCA 的识别效果略胜一筹。但由于 KPCA 算法的计算量相当大，所以当样本量不是很大的情况下，PCA 算法也是一个不错的选择。

### 5.1.3 基于小波分解的核 PCA 特征提取算法的比较

人脸识别技术有较好的识别效果，特征量的提取是前提。而在特征提取之前对图像进行的预处理工作也十分重要，它直接影响所提取的特征量的价值。所以实验首先对原始图像进行小波变换，得到表示人脸低频特征的子图像，然后用 KPCA 方法提取特征，最后根据标准距离法进行分类。另外，还进行了对原始图像直接采用 KPCA 方法提取人脸特征而不经过小波变换的实验以显示区别，实验数据如表 5.3 所示。KPCA 中的核函数取多项式核函数为： $k(x, y) = (x \cdot y + 1)^d$  其中  $d = 1$ 。小波基则选取 Daub(2)。

表 5.3 基于小波分解的核 PCA 特征提取算法的比较

| ORL 人脸库 | 特征维数 | 分类识别率(%) | 运行时间(S) |
|---------|------|----------|---------|
| KPCA    | 199  | 93.8%    | 0.11    |
| 2 维小波变换 |      |          |         |
| +KPCA   | 199  | 95.9%    | 0.18    |

在这个实验中可以看出，特征维数相同的情况下，在前期使用了小波分解来对图片进行预处理的方法识别率比较高，但相对运行时间比较长，即以小部分运行效率的代价来换取较高的识别率。

### 5.1.4 不同小波基的选择对识别率的影响

在小波变换中，不同的小波基能影响不同区域的能量分布和特征提取的效果，并且得到不同识别率。上一节我们通过实验证明在对人脸进行特征提取之前，采用小波变换的方法对待处理图像进行预处理，可以提高识别的精度。而小波变换的效果则有所选取的小波基来决定。目前对小波基的选择还没有很好的理论指导，一般都是通过大量的试验来选择最好的小波基。Daubechies 小波中的 Daub(2)、Daub(4)、双正交小波(bior N)、Sym、小波等是目前使用得最多的。根据不同的图像使用这不同小波基可以不同程度地获得人脸图像的低频部分用于脸部的特征提取。

鉴于小波基选择的重要性，我们通过实验对小波基进行选择。实验所选用的人脸

库仍然是 ORL 人脸数据库，选择的 ORL 人脸集为 20 人，训练样本数分别是 2、3、4 和 5，预处理时采用的是两层小波分解，应用 PCA 方法进行特征提取，并使用标准距离法进行分类，基于不同小波基的识别率的实验结果如表 5.4 所示。

表 5.4 基于不同小波基的识别率

| 小波    | Daub(2) | Daub(4) | Daub(6) | Bior(2.4) | Bior(4.4) | Sym(2) |
|-------|---------|---------|---------|-----------|-----------|--------|
| 识别率 2 | 89.6    | 86.9    | 85.7    | 92.8      | 89.7      | 89.6   |
| 识别率 3 | 91.8    | 89.7    | 90.6    | 95.3      | 94.6      | 92.3   |
| 识别率 4 | 92.8    | 93.5    | 90.2    | 93.6      | 92.9      | 92.0   |
| 识别率 5 | 94.7    | 94.5    | 92.6    | 95.4      | 93.2      | 93.1   |

从这个实验结果可以看出，不同的小波基对识别率的影响。分析试验结果可得，小波基为 Bior (2.4) 时识别率最高。

## 5.2 动态人脸检测与识别系统实现

通过对检测、特征提取以及分类等方法和具体算法的研究，综合大量实例<sup>[34]</sup>，本文构建了动态人脸检测和识别系统，其实现过程及实验数据如下：

我们对视频中截取的 20 人的人脸做视频人脸识别试验，这些人脸图片包括每个人在不同角度，不同光照，不同饰物遮挡情况下的状态，将这些图片分为训练样本和测试样本，先对测试样本进行训练，得到测试样本的特征空间，再通过对训练样本进行一系列变换获取其特征空间，然后与测试样本的特征空间进行比较来获得识别结果。对训练样本采用的操作方法为先对图片进行各种归一化，然后通过小波分解获取低频部分的子图像用于后面的特征提取，特征提取方法我们使用的是 KPCA 算法，最后通过标准距离法来进行最后的判定。识别结果如表 5.5。

表 5.5 视频识别结果

| 正面  | 饰物变化  | 偏转<20 度 | 光照变化  |
|-----|-------|---------|-------|
| 识别率 | 98.8% | 92.5%   | 86.6% |

从实验结果可以看出，正面图片的识别效果最佳，其次是饰物变化情况下的识别率，由此可以看出该方法对各种饰物类障碍物有很好的抗干扰性。而对光照变化的情况识

别效果不佳。

### 5.3 本章小结

本章通过大量实验来论证了不同维数和不同样本量对识别率的影响。得到的结果是高维数可以得到较好的识别率，但利用 PCA 算法，在维数达到一定数量时即使维数增加，识别率也不会得到相应的提高，这是由 PCA 算法的特性决定的，而样本量越大的情况下，识别率越高，这符合概率学的理论。另外通过实验总结了不同特征提取方法、利用小波分解对图片进行预处理方法以及不同小波基对最终识别结果的影响，并对实验结果进行了总结分析。最后通过构建一个动态识别系统，通过获取图片，小波分解预处理，KPCA 特征提取、标准距离法等流程来进行人脸识别，也对实验结果进行了总结分析。

## 总结与展望

### 总结

本文从人脸识别的流程出发，讨论了人脸识别过程中的各个环节，以及使用的技术和算法，列举了各种算法所需的数学理论支持，总结了各自的优缺点和适用环境。集中讨论了特征提取和支持向量机方法，通过大量实验证明了各种算法的识别精度和效率。在理论论证和算法分析的同时构建了一个由摄像设备提供识别源的识别系统，主要做的工作有：

(1)首先阐述了人脸检测及预处理的重要性，在识别初期编码并无很大的实际意义，而对图像进行预处理操作以获得能更有效地提取人的脸部特征的输入图片才是最重要的，所以在近些年来，图片的预处理工作开始被重视，即对获取的视频序列流中检测到的人脸图像，在特征提取之前进行一些合理的预操作，以获取干扰因素较少的子图像用于特征提取。

(2)详细介绍了三种基于统计特征的特征提取方法，即 PCA (主成分分析方法)、LDA (Fisher 脸方法)、KPCA (核主成分分析方法)，并介绍了 PCA 与 LDA 相结合的人脸识别方法。介绍了算法的流程，以及各种算法所需的数学理论支持，并总结了各种算法提取特征的优缺点。

(3)介绍了支持向量机方法，通过理论说明支持向量机可以很好地对多个类别进行分类进而从整体上提高人脸识别的效率和精度。讨论了如何获取较好的核函数，另外介绍了支持向量机如何实现用 SVM 解决多类分类问题。

(4)通过大量实验证明了文中提及的各种方法，并对实验结果进行了分析。另外由文中介绍的各种方法以及具体算法，利用 Matlab 工具搭建一个由摄像头录入的动态图像人脸识别系统。测试了多个角度，不同环境及障碍物干扰情况下，该系统的识别精度和效率，得到了大量的实验数据，并对实验数据进行了分析和总结，从实验结果分析，搭建的动态人脸识别系统对正面图片的识别效果最佳，其次是饰物变化情况下的识别率。而对光照变化的情况识别效果不佳。

## 对未来工作的展望

读研期间，出于对人脸识别技术的兴趣，阅读了大量与之相关的文献和书籍，研究了一些相关算法的流程和思想，并部分进行了实验和比较，并一直在寻找更优的方法来更好地达到识别的目的，提高识别的效率和准确度。在这篇论文所涉及的工作外，下一步的工作展望是：

在 KPCA 方法中尽量消除经验性的选择原则，能有保障地选择最理想的核函数并据此求得其他各参数，更好地提高算法的性能，提高对训练样本的识别率。

在现在的支持向量机技术中，如果使用较少的 SVM，所获得的分类效果不理想，消弱的 SVM 在分类方面的优势，研究出如何在准确定位的核函数和参数之后，使用较少的 SVM 获得较优的分类效果是识别算法好坏的关键所在。

摄取更多更全面的特征提取方法和分类方法，总结分析各自的特性、优缺点及适用环境，将各种算法的优点有机融合、取长补短以达到更好的识别效果也是值得努力的方向。

## 参考文献

- [1] Ahn, W.,&Brewer, W.F.(1993). Psychological studies of explanation-based learning[J]. In G. DeJong(Ed.),Investigating explanation-based learning. Boston: Kluwer Academic Publishers.
- [2] 李刚 , 高政.人脸识别理论研究进展[J].计算机与现代化 , 2003(3):1-6.
- [3] C. Kotropoulos, I. Pitas. Face authentication based on morphological grid Matching[J]. IEEE inter. Conf. on Image Processing, 1997, pages:106-108.
- [4] Jonathon Philips P. Matching Pursuit Filters Applied to Face Identification[J]. IEEE Trans.Image Processing, 1998,8(7):1150-1164.
- [5] T.Sakai, M. Nagao, S. Fujibayashi, Line Extraction and Pattern Detection in a Photograph[J], Pattern Recognition, 1969,1:233-248.
- [6] 蔡兀龙. 模式识别[M]. 西安 : 西安电子科技大学出版社 , 1992.
- [7] Luis T, Josep V. Automatic Face Recognition for Video Indexing Applications[J]. Pattern Recognition , 2002 , 35(3):615-62.
- [8] Juell P, Marsh R .A hierarchical neural network for human face detection[J]. Pattern Recognition,1996,29(5).
- [9] M.H. Yang, D. Kriegman, N. Ahuja, Face Detection Using Multimodal Density Models[J], Computer Vision Understanding, 84,2001:264-284.
- [10] 姜军 , 张桂林. 一种基于知识的快速人脸检测方法[J].中国图像图形学报版) , 2002 , 7(1):6-10.
- [11] A. Mohan, C. Papageorgiou, T. Poggio. Example-based object detection in images by components[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.23, No.4, pp.349-361, April 2001.
- [12] Doug DeCarlo. Model-based Face Tracking. Department of Computer Science at Rutgers University[D]. 1997.
- [13] 吕琳 人脸检测方法综述[J] 电脑知识与技术 2005.10 159-162
- [14] Srisuk S.Kurutach W.A new robust face detection in color images[A]. Int Conf on Aut Face and Ges Rec.2002. 20-21.

- [15] Rein-Lien Hsu, Mohamed Abdel-Mottaleb, Anil K.Jain. Face Detection in Color Images[J], IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(5):696-706.
- [16] Zhu J K, Vai M I, Mark P U, Gabor wavelets transform and extended nearest feature space classifier for face recognition[J]. Third International Conference Proceedings on Image and Graphics, Hong Kong, 2004:246-249.
- [17] 李云峰. 基于 Gabor 小波变换的人脸识别[D] : (博士学位论文). 大连 : 大连理工大学 , 2005.
- [18] Karlekar J , Desai U B. Finding faces in color images using wavelet transform[J]. In : Proc IEEE Conference on Image Analysis and processing . Venice , Italy , 1999,1086-1089.
- [19] Intrator N el al. Face recognition using a hybrid supervised/unsupervised neural network[J], Patter Recogniton Letters, 1996,17(1):68-77.
- [20] Pablo Navarrete, Javier Ruiz-Del-Solar. Analysis and Comparison of Eigenspace-Based Face Recognition Approaches[J]. International Journal of Pattern Recognition and Artificial Intelligence, Volume 16,Number 2/March 2004.
- [21] 张学工 , “ 关于统计学习理论与支持向量机 ”[J] , 《自动化学报》 , 2000 , 26(1):32-42.
- [22] Cooper, G., et al.(1997). An evaluation of machine-learning methods for predicting pneumonia mortality[J]. Artificial Intelligence in Medicine.(to appear).
- [23] W Bledsoe. Man- machine facial recognition[J]. Panoramic Research Inc , Palo Alto , CA , 1996 , Rep PRI:22.
- [24] S.S.Keerthi Convergence of a generalized SMO algorithm for SVM classifier Design[J]. TR CD-00-01, Deppt. Of Mecha and Prod. Engin. National Uni of Singapore, 2000.
- [25] 张燕昆 , 杜平 , 刘重庆. 基于主元分析与支持向量机的人脸识别方法 [J]. 上海交通大学报 , 2002 , 36(6):884-886.
- [26] S. Y. Lee, Y. K. Ham and R. H. Park. Recognition of Human Front Faces Using Knowledge-based Feature Extraction and Neurofuzzy Algorithm[J]. Pattern Recognition, 2000, 29(11):1865-1876.
- [27] Richard O Duda Peter E.Hart David G.Stork (李宏东 , 姚天翔译) “ Pattern Classification ” [M] (<<模式分类>>), 第二版 , 机械工业出版社 , 2003.

- [28] A.Selinger , D.Socolinsky. Appearance-based facial recognition using visible and thermal imagery: a comparative study[J]. Technical Report 02-01 , Equinox Corporation , 2002.
- [29] Hsu, C.-W, C.-J.Lin.A comparison of methods for multi-class support vector machines[J]. IEEE Transactions on Neural Networks.
- [30] Liu X M, Chen T, Kumar B K V. Face authentication for multiple subjects using eigenflow[J]. Pattern Recognition, 2003,36(2) : 313-328.
- [31] I. Buciu, C.Kotropoulos, I. Pitas, Combining Support Vector Machines for Accurate Face Detection[J],In:Proc International Conference on Image Processing,2001:1055-1057.
- [32] Osuna E , Freund R , Girosi F. Training Support Vector Machines an application to Face Detection[J]. Proc. Computer Vision and Pattern Recognition , 1997:130-136.
- [33] 金忠. 人脸图像特征提取与维数研究[J] , [博士学位论文] , 南京 :南京理工大学 , 1999.
- [34] 徐慧 等. Visual C++数字图像实用工程案例精选[M]. 北京 :人民邮电出版社 ,2004.3

## 致 谢

在准备及书写该论文的过程中，包括整个读研期间，汪红老师，也就是我的导师给了无微不至的照顾和孜孜不倦的指导。她温和细腻的指导方式给了我很大的自由发挥空间和广袤的学习天地。同时她也在理论上给了我很多启发，实践上给了我很多实际的建议，以此帮我解决了无数的难题，度过了无数的难关。同时她一丝不苟的处事风格和待人接物的谦和态度也给我树立了榜样，她的博学更是给了我在学术上奋斗的目标。

在感谢汪老师之余，我也很感激计算机学院其他的老师们对我的帮助，不管是理论上的授予还是实践中的指导，每每都让我受益匪浅，对我的一些潜移默化的帮助将让我受益终身！

另外，我要感谢我的同学们，感谢他们对我的帮助和支持。感谢他们在学术上给我的建议，在生活上给我的帮助和关怀，在整个读研期间因为有了他们，我一直都觉得很温暖和踏实，我将永远保留这份同学情谊，这将是我一生的财富！

最后，我要感谢把我带到世上并不遗余力给我最好教育的父母，感谢他们在任何时刻的默默支持，感谢他们为我所做的一切！

## 附录 A 攻读学位期间所发表的学术论文目录

[1]王娟 , 汪红 , 陈文峰.人脸识别技术的比较与结合.电脑知识与技术.2008.04.

# 人脸识别技术及其应用

作者:

王娟

学位授予单位:

中南民族大学

本文链接: [http://d.g.wanfangdata.com.cn/Thesis\\_D071022.aspx](http://d.g.wanfangdata.com.cn/Thesis_D071022.aspx)