

天津大学

毕业设计（论文）说明书



学 院 计算机科学与技术

专 业 计算机科学与技术

年 级 2004 级

姓 名 杨斌

指导教师 何英华

2008 年 6 月 16 日

天津大学

毕业设计（论文）任务书

题目：人脸特征提取的研究

学生姓名 杨斌

学院名称 计算机科学与技术

专 业 计算机科学与技术

学 号 3004204111

指导教师 何英华

职 称 讲师

一、原始依据（包括设计或论文的工作基础、研究条件、应用环境、工作目的等。）

工作基础：人脸识别研究目前已成为计算机视觉和模式识别领域中一个重要的研究课题，而人脸特征的提取工作是人脸识别中的一个重要阶段，提取出的特征的优劣直接影响人脸识别阶段的性能。本课题的提出希望能在目前已有的人脸特征提取算法的基础上发展创新，利用 OpenCV 开源计算机视觉库以及 FastICA 2.5 软件包中的一些通用算法，设计并实现出有效的人脸特征提取算法。

研究条件：一台 CPU 为 AMD Athlon™ 64 X2 Dual Core 3800+，内存为 2 G 的 PC 机。实验采用 C++语言和 Matlab 语言作为编程语言,使用 Visual Studio 2005 和 Matlab 7.5 作为编辑和测试程序的平台，另外我们还用到了 OpenCV 开源计算机视觉库以及 FastICA 2.5 软件包。测试用的图像中，部分由数码相机采集，部分通过互联网下载。

应用环境：灰度图像和彩色图像¹的人脸特征提取，支持的文件格式有：Windows 位图文件—BMP，DIB；JPEG 文件—JPEG，JPG，JPE；便携式网络图片—PNG；便携式图像格式—PBM，PGM，PPM；Sun rasters—SR，RAS；TIFF 文件—TIFF，TIF。

工作目的：设计并实现一个基于人脸代数特征的特征提取算法，将图像中出现的人脸表示成为一系列“特征脸”的线性组合。该算法要能适应各种复杂的环境，能对任意背景下的人脸进行特征提取，另外，作为一个实时人脸识别系统的一部分，该算法要具有快速的提取速度。

二、参考文献

- [1]袁殿国. 基于 PCA 的人脸识别研究[D]. 大连: 大连理工大学, 2007.
- [2]刘小华. 人脸识别技术及其应用研究[D]. 吉林: 吉林大学, 2005.
- [3]刘小军. 人脸识别技术研究[D]. 北京: 中国科学院, 2001.
- [4]黄福珍, 苏剑波. 人脸检测[Z]. 上海: 上海交通大学出版社, 2006.
- [5]刘永俊. 小样本问题下人脸图像的鉴别特征抽取方法研究[D]. 扬州: 扬州大学, 2007.
- [6]Sir Francis Galton. Personal Identification and Subscription-1[J]. Nature, 1906, 1888 (21): 173-177
- [7]靳艳峰. 基于相位一致性和模 PCA 的人脸识别算法研究[D]. 兰州: 兰州理工大学, 2007.

¹ 我们设计实现的算法只能对灰度图像进行特征提取，为此，我们必须先对彩色图像进行灰度转换。

- [8]Bertillon. Identification of human beings by the system of Alphonse[J], Journal of the Franklin Institute, 1909, Vol. 167, Issue 5: 321-358
- [9]王先基. 基于统计学习的自动人脸识别算法研究[D]. 北京: 中国科学技术大学, 2005.
- [10]孙涛. 特征提取技术研究及其在人脸识别中的应用[D]. 长沙: 中南大学, 2007.
- [11]张春雨. 基于子空间的人脸识别算法研究[D]. 吉林: 吉林大学, 2006.
- [12]李欣. 人脸识别技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2007.
- [13]栗塔山. VC++和 BC++数值分析类库[M]. 北京: 清华大学出版社, 2005. 18—19.
- [14]王峻峰. 基于主分量、独立分量分析的盲信号处理及应用研究[D]. 武汉: 武汉大学, 2003.
- [15]陈颖. 基于特征的人脸检测系统的设计与实现[D]. 天津: 天津大学, 2007.
- [16]周岩. 基于独立分量分析(ICA)的人脸识别方法的研究[D]. 长春: 长春理工大学, 2007.
- [17]王明祥. 独立分量分析方法及在图像处理中的应用研究[D]. 上海: 上海大学, 2005.
- [18]戴娇月. 基于高阶统计量的含噪模糊图像辨识和复原[D]. 长春: 长春工业大学, 2006.
- [19]王明祥. 独立分量分析方法及在图像处理中的应用研究[D]. 上海: 上海大学, 2005.
- [20]何付志. 独立分量分析在脑电信号分析中的应用[D]. 山东: 山东大学, 2005.
- [21] Intel. Open Source Computer Vision Library (OpenCV) [EB/OL].
[Online]: [http:// www.opencv.org.cn](http://www.opencv.org.cn), 2007-6-1.

三、设计(研究)内容和要求(包括设计或研究内容、主要指标与技术参数,并根据课题性质对学生提出具体要求。)

1. 研究内容

- (1) 熟悉数字图像处理的基本内容以及人脸特征提取与选择的基本知识。
- (2) 熟悉 OpenCV 中的基本函数,包括图像的输入、输出、显示、缩放等等。
- (3) 熟悉 Matlab 中的基本函数,包括图像的输入、输出等等。
- (4) 熟悉 OpenCV 中的 PCA 方法部分的函数。

(5) 熟悉 FastICA 2.5 中的 ICA 算法。

(6) 实现人脸特征选择部分的功能。

2. 主要指标与技术参数

人脸特征提取与人脸识别的准确率之间的关系。

3. 具体要求

学习并掌握 OpenCV 开源计算机视觉库和 FastICA 2.5 软件包中的一些通用算法；熟悉 VC++ 和 Matlab 编程。

指导教师（签字）

年 月 日

审题小组组长（签字）

年 月 日

天津大学本科毕业设计（论文）开题报告

课题名称	人脸特征提取的研究		
学院名称	计算机科学与技术	专业名称	计算机科学与技术
学生姓名	杨斌	指导教师	何英华
（内容包括：课题的来源及意义，目前出现的一些方法，本课题的研究目标、研究内容、研究方法、研究手段和进度安排，实验方案的可行性分析和已具备的实验条件以及主要参考文献等。） 人脸特征提取问题来源于人脸识别。近年来，随着社会经济的迅速发展以及信息化的不断深入，安全问题越来越为人们所关注，社会各个方面对快速有效的自动身份验证的需求也与日俱增。人脸识别凭借其具有的非侵犯性、友好、直接以及方便等特点，成为最有潜力的生物身份验证方式之一，而人脸特征提取是人脸识别工作中的一个重要环节，提取出的特征的优劣直接影响着整个识别工作的效率。因此，也有越来越多的人把精力投入到对人脸特征提取算法的研究中。 随着人们不断的探索、研究，现在已经出现了很多人脸特征提取方法。目前，进行人脸特征提取的方法主要可以分为如下几类： 1. 用于提取人脸图像几何特征的特征提取方法； 2. 用于提取人脸图像灰度统计特征的特征提取方法； 3. 用于提取人脸图像变换系数特征的特征提取方法； 4. 用于提取人脸图像代数特征的特征提取方法。 现在，我们来逐一介绍上述的几种方法。 第一种方法就是提取出人脸图像的一些几何特征，如人脸的五官尺寸和相对位置等，通过合适的算法，计算机可以很容易的获取这些特征，而且，这些特征也不会对计算机内存又很大的要求。但是，由于人脸表情以及外部光照条件的变化，可能会导致这些特征发生一些变化。 第二种方法用于提取人脸图像的灰度特征，如直方图，这种方法可以达到降维的效果，但提取出的特征往往没有太大实用价值。 第三种方法用于提取人脸图像的变换系数特征，其本质就是对图像做一系列数学变化，如傅立叶变换、小波变换，得到的一系列变换系数。 第四种方法用于提取出人脸图像的代数特征，所谓代数特征，就是人脸图像的代数特征矢量的线性表示，即人脸图像在“特征脸”张成的低维空间中的投影。用于求取上述低维空间的方法大致分为线性子空间方法和非线性子空间方法两类。前者主要包括 PCA、ICA 和 LDA 方法，而 PCA 和 ICA 方法是本课题的主			

题；后者主要包括 KPCA、KLDA 方法等。

本课题的研究目标是利用 OpenCV 开源计算机视觉库和 FastICA 2.5 提供的一些算法，设计并实现出基于 PCA 和 ICA 的特征提取算法，这些算法可以用于计算出给定的一幅人脸图像的“投影向量”。

本课题的研究内容如下：

1. 熟悉数字图像处理的基本内容以及人脸特征提取的基本知识。
2. 熟悉 OpenCV 中的基本函数，包括图像的输入、输出、显示、缩放等等。
3. 熟悉 Matlab 中的基本函数，包括图像的输入、输出等等。
4. 熟悉 OpenCV 中的 PCA 方法部分的函数。
5. 熟悉 FastICA 2.5 中的 ICA 算法。
6. 实现人脸特征提取部分的功能。

本课题进度安排如下：

2008 年 3 月初，完成开题报告，熟悉数字图像处理的基本内容。

2008 年 3 月中—2008 年 4 月，熟悉 OpenCV 和 FastICA 2.5 中的基本图像处理函数以及和人脸特征提取有关的函数。

2008 年 4 月—2008 年 5 月，编程实现人脸特征提取功能，并对程序完成调试。完成论文初稿。

2008 年 6 月，完善算法，完成论文终稿并进行答辩。

下面对实验方案的可行性作简要分析。主成分分析（PCA）和独立成分分析（ICA）都有严格的理论保证，而且这些方法也在许多图像处理工作中获得了成功，实验中许多关键的数学操作都有非常成熟的算法支持。本课题中我用到 OpenCV 开源计算机视觉库和 FastICA 2.5 软件包提供的部分算法来实现一些关键的函数，这使得算法的成功可能大大增加。当然人脸拍摄的复杂环境及人脸模式的多样性等因素会给系统带来一定问题，不过我们可以通过一些预处理操作尽可能的来削弱这些影响，总体来说，本课题的方案是可行的。

本课题的实验条件如下：

一台 CPU 为 AMD Athlon™ 64 X2 Dual Core 3800+，内存为 2 G 的 PC 机。实验采用 C++ 语言和 Matlab 语言作为编程语言，使用 Visual Studio 2005 和 Matlab 7.5 作为编辑和测试程序的平台，另外我们还用到了 Intel 开源计算机视觉库和 FastICA 2.5 软件包中提供的一些算法，测试用的图像中，部分由数码相机采集，部分通过互联网下载。

主要参考文献如下：

- [1]袁殿国. 基于 PCA 的人脸识别研究[D]. 大连：大连理工大学，2007.
- [2]刘小华. 人脸识别技术及其应用研究[D]. 吉林：吉林大学，2005.
- [3]刘小军. 人脸识别技术研究[D]. 北京：中国科学院，2001.

- [4]黄福珍, 苏剑波. 人脸检测[Z]. 上海: 上海交通大学出版社, 2006.
- [5]刘永俊. 小样本问题下人脸图像的鉴别特征抽取方法研究[D]. 扬州: 扬州大学, 2007.
- [6]Sir Francis Galton. Personal Identification and Subscription-1[J]. Nature, 1906, 1888 (21): 173-177
- [7]靳艳峰. 基于相位一致性和模 PCA 的人脸识别算法研究[D]. 兰州: 兰州理工大学, 2007.
- [8]Bertillon. Identification of human beings by the system of Alphonse[J], Journal of the Franklin Institute, 1909, Vol. 167, Issue 5: 321-358
- [9]王先基. 基于统计学习的自动人脸识别算法研究[D]. 北京: 中国科学技术大学, 2005.
- [10]孙涛. 特征提取技术研究及其在人脸识别中的应用[D]. 长沙: 中南大学, 2007.
- [11]张春雨. 基于子空间的人脸识别算法研究[D]. 吉林: 吉林大学, 2006.
- [12]李欣. 人脸识别技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2007.
- [13]栗塔山. VC++和 BC++数值分析类库[M]. 北京: 清华大学出版社, 2005. 18—19.
- [14]王峻峰. 基于主分量、独立分量分析的盲信号处理及应用研究[D]. 武汉: 武汉大学, 2003.
- [15]陈颖. 基于特征的人脸检测系统的设计与实现[D]. 天津: 天津大学, 2007.
- [16]周岩. 基于独立分量分析(ICA)的人脸识别方法的研究[D]. 长春: 长春理工大学, 2007.
- [17]王明祥. 独立分量分析方法及在图像处理中的应用研究[D]. 上海: 上海大学, 2005.
- [18]戴娇月. 基于高阶统计量的含噪模糊图像辨识和复原[D]. 长春: 长春工业大学, 2006.
- [19]王明祥. 独立分量分析方法及在图像处理中的应用研究[D]. 上海: 上海大学, 2005.
- [20]何付志. 独立分量分析在脑电信号分析中的应用[D]. 山东: 山东大学, 2005.
- [21] Intel. Open Source Computer Vision Library (OpenCV) [EB/OL].
[Online]: [http:// www.opencv.org.cn](http://www.opencv.org.cn), 2007-6-1.

选题是否合适： 是 ☐ 否 ☐	指导教师（签字） 年 月 日
课题能否实现： 能 ☐ 不能 ☐	
选题是否合适： 是 ☐ 否 ☐	审题小组组长（签字） 年 月 日
课题能否实现： 能 ☐ 不能 ☐	

摘 要

特征提取工作是整个人脸识别工作中的一个非常重要的部分,通过特征提取可以对输入的人脸图像数据进行有针对性的降维,从而简化后续工作的复杂性。本文的主要介绍了利用 PCA 和 ICA 对人脸图像进行特征提取的方法。

本文首先简要的介绍了人脸识别的研究背景、发展过程 and 关键步骤;接着,本文又粗略介绍了人脸特征的种类以及一些特征提取方法。之后,本文详细的介绍了使用 PCA 和 ICA 进行人脸特征提取的原理和方法,并且设计和实现了相关的算法,实验采用英国 Essex 大学的人脸识别数据库中 10 个人(每人 20 幅)的图像作为输入数据,分别采用两种方法对每人的图像进行特征提取,得到相应的“特征脸”和“投影向量”。本文以 1 个人的图像作为实例介绍了两种方法的工作过程。最后,本文也对这两种方法进行了对比。

关键字: 特征提取; PCA; ICA;

ABSTRACT

Feature extraction is a very important part of the entire work of face recognition. By the feature extracting, the source facial image data could be reduced to lower-dimension, making the following work more and more easier. The subject of this paper is the way of feature extraction by PCA and ICA.

Firstly, this paper discussed the background, the development and the key step of the face recognition briefly, and then, the paper also sketched out the type of facial features and a number of feature extraction methods. Besides giving a minute description of the principles and methods of work extracting facial features by PCA and ICA, we designed and implemented the algorithms for PCA and ICA. In the experiment, 10 individuals (20 image of each person) image, from the face recognition database of the University of Essex, U.K. is used as the input data. Using the methods as stated above, we can get the "EigenFace" and the "Projection Vector". In this paper, 20 images of a person were used as an example to show the process of two methods. Finally, we also compared the two methods.

Key Words: Feature extraction; PCA; ICA;

目 录

第一章 前言.....	1
1.1 引言.....	1
1.2 人脸识别的研究背景.....	2
1.3 人脸识别的发展过程.....	3
1.4 国内外人脸识别理论研究机构.....	4
1.5 本课题研究内容.....	4
1.6 全文结构.....	5
第二章 人脸特征提取以及特征选择的相关理论.....	6
2.1 特征提取概述.....	6
2.2 几何特征.....	6
2.2.1 人脸几何特征的提取方法	7
2.2.2 可变形模板.....	7
2.3 代数特征.....	8
2.3.1 线性子空间.....	8
2.3.2 非线性子空间.....	9
2.4 小结.....	10
第三章 基于 PCA 的人脸特征提取.....	11
3.1 引言.....	11
3.2 PCA 方法所涉及的数学知识	11
3.2.1 协方差和相关系数.....	11

3.2.2 协方差矩阵.....	12
3.3 PCA 方法原理	12
3.4 使用 PCA 方法对人脸图像进行特征提取.....	15
3.5 实验.....	17
3.5.1 实验说明.....	17
3.5.2 实验流程图.....	17
3.5.3 实验数据.....	17
3.6 小结.....	22
第四章 基于 ICA 的人脸特征提取.....	24
4.1 引言.....	24
4.2 ICA 方法所涉及的数学知识	24
4.2.1 随机变量的统计量.....	24
4.2.2 负熵.....	27
4.2.3 统计独立与相关.....	28
4.3 ICA 方法概述	29
4.3.1 ICA 的定义	30
4.3.2 一般算法.....	31
4.3.3 FastICA 方法	32
4.4 使用 ICA 方法对人脸图像进行特征提取.....	34
4.5 实验.....	35
4.5.1 实验说明.....	35
4.5.2 实验流程图.....	35

4.5.3 实验数据.....	36
4.6 小结.....	38
第五章 PCA 与 ICA 特征提取结果对比与分析	39
5.1 引言.....	39
5.2 根据二维数据的分布对两种方法的比较.....	39
5.3 结合人脸图像对两种方法的比较.....	40
5.4 小结.....	40
第六章 总结与展望.....	42
6.1 全文总结.....	42
6.2 研究展望.....	42
参考文献.....	43
外文资料	
中文译文	
致 谢	

第一章 前言

1.1 引言

生物特征是人的内在属性，具有很强的自身稳定性^[1]，因此越来越多的研究将它作为身份验证的依据，现在，基于生物特征的识别技术（也称生物特征识别技术）已经逐渐成为国际上的研究热点。生物特征识别技术就是指通过计算机利用人体所固有的生理特征和行为特征来进行身份识别和（或）个体验证的一门技术^[2]。与传统的身份验证手段相比，基于生物特征识别的身份验证方法具有很多优势，例如：

1. 该特征不存在被遗忘和丢失的问题；
2. 该特征一般不易被伪造；
3. 该特征随时可以被使用等。

正是由于生物特征本身所具有的这些优势，使基于生物特征的识别技术获得了长足的发展，其在国家安全、司法、海关、边境及保险等领域也必将具有极广阔的应用前景。

在诸多的生物特征识别技术中，人脸识别技术更是凭借着对人体无侵害、以及良好的交互性等优势，成为最容易被接受的生物特征识别技术。所谓人脸识别，就是在给定某一场景的静态图片或动态视频图像，根据所存储的脸面数据库识别或确认一个或更多的人^[3]。

在计算机视觉领域里，人脸识别过程主要可分为人脸检测 (Face Detection)、特征提取 (Feature Extraction)，识别或确认 (Face Recognition) 三部分^[4]。特征提取是其中一项非常重要的组成部分，它有针对性的对输入图像的数据进行简化，使后续工作能够更好的进行。

在不同的特征提取方法中，主成分分析 (PCA) 方法是重要的提取方法之一，它提取出原始数据中互不（线性）相关的特征（基向量），这就在很大程度上减少了数据之间的冗余，与此同时，原始数据的绝大部分的主要信息也被保存下来，这就使得数据可以在一个低维的有效的特征空间里进行处理^[5]。当输入数据的分布服从高斯分布时，该方法可以提取出相互独立基向量，它们之间没有任何冗余信息，能非常好的体现数据的本质特征。

然而，从根本来说，PCA方法仅仅能够消除数据之间的二阶相关信息，当输入数据的分布不满足高斯分布时，该方法提取出的基向量之间还存在着很多的高阶相关信息，由于这些冗余信息的存在，使得后续工作的复杂程度还是很大。为了消除这些高阶冗余信息，ICA方法应运而生，也在很多方面成功的发挥了作用，ICA方法可以保证提出的基向量相互独立，有效的去除了它们之间的高阶冗余信

息，从而大大简化了后续工作的复杂程度。

1.2 人脸识别的研究背景

随着社会经济的迅速发展以及信息化的不断深入，安全问题越来越为人们所关注，因此，社会各个方面对快速有效的自动身份验证的需求也与日俱增。经过人们不断的研究探索，目前已经可以将很多的信息作为身份验证的依据，如密码、磁卡、人体生物特征等等，而且其方法也各具特点。其中，基于人体生物特征的识别技术（生物特征识别技术）是近些年来发展最快、应用最多一种识别技术，它提供了一种基于唯一、高可靠性和稳定性的人体生物特征的身份验证途径。

生物特征，如人脸、指纹、虹膜、DNA 等，都是人体的内在属性，因而具有较强的自身稳定性和个体差异性^[1]，从而成为进行身份验证的理想依据。另外，与传统的身份验证方法相比，基于生物特征识别的身份验证方法具有多方面的优点：

首先，与传统的身份验证方法相比，基于生物特征的识别方法更为方便。传统的身份验证方法中，有的需要用户要费心去记住密码、口令；有的需要用户随身携带钥匙、智能卡之类的东西。而基于生物特征的识别方法完全不需要用户去做这些工作，这也大大减少了由于遗忘密码、忘带钥匙而带来的麻烦，极大的方便了用户的使用。

其次，与传统的身份验证方法相比，基于生物特征的识别方法更为安全。传统的身份验证方法中往往会出现口令、IC 卡、条形码、磁卡或钥匙的丢失、被盗用等诸多问题，使安全性受到威胁；而基于生物特征的识别方法认定的是人本身，每个人的生物特征具有与其他人不同的唯一性和在一定时期内不变的稳定性，不易伪造和假冒，所以基于生物特征的识别方法会更可靠、更准确。

此外，基于生物特征的识别方法均是借助现代计算机技术来实现的，很容易与计算机以及一些监控、管理系统相结合，实现远程的自动化管理。

正是由于基于生物特征的识别方法所具有的这些优势，使得其获得了长足的发展，在国家安全、公安、司法、金融、民航、边境、口岸、保险等领域具有极广阔的应用前景。例如，该技术可用于公安布控监控、监狱监控、司机驾照验证、司法认证、边境身份验证、各类银行卡、信用卡、储蓄卡的持卡人的身份验证、民航安检、社会保险身份验证等多个方面，而且，它还可以应用于医疗和视频会议等方面。

在诸多基于生物特征的识别方法中，利用人脸特征进行身份验证的自动人脸识别方法又是最自然、直接的方式。自动人脸识别技术是利用计算机分析人脸图像，并从人脸图像中提取有效的识别信息，用来“辨认”身份的一门技术^[1]。与

指纹、虹膜、DNA 等其它人体生物特征识别方法相比，自动人脸识别方法具有直接、友好和方便等特点，比如说，自动人脸识别不需要对被测试的人进行强迫约束，因此，相比于虹膜和 DNA 等测试方法更加友好和方便，也对被测试人没有任何侵害性，因而它成为最容易被接受的生物特征识别方法，受到人们越来越多的重视。另外，系统还可以通过分析用户面部表情，获得一些如心理反应等其它识别系统难以获得的信息。也正是因为存在这些优势，自动人脸识别技术未来可以广泛的应用于公安系统的罪犯身份识别、驾驶执照及护照等与持证人身身份核实，银行及海关的监控系统及保密部门的自动门卫系统等领域，帮助相关人员更轻松地完成工作。

上面，我们谈到的都是自动人脸识别技术的优势，但是，凡事都有两面性，自动人脸识别技术也有一些不足，这些问题也是影响它得到更大发展的限制因素。例如，自动人脸识别技术研究的对象是人脸，而人脸图像的获取过程会受到很多方面如拍摄角度、光照条件、发型等诸多因素的影响，另外，随着人的年龄以及心情的变化，同一个人的“人脸”可能会呈现出不同的样子，在这个问题上，自动人脸识别方法相比于其他方法（如 DNA 识别）要做更多的工作，这些工作往往又非常困难，因此人脸自动识别也是一项极具挑战性的工作。

1.3 人脸识别的发展过程

人们对人脸识别方法的研究已经有很长的历史了，最早可以追溯到 19 世纪，法国人 Galton 曾经用一组数字代表不同的人脸侧面特征^{[1]、[6]}。人脸识别的输入图像大致可以分为三种：正面图像、倾斜图像、侧面图像^[7]。其中，正面的人脸图像由于信息量大、对称等特点，更多的被人们当作输入数据进行研究，人们对正面图像的研究大致可以分为三个阶段^[9]：

第一阶段是研究人脸识别所需要的面部特征，以 Bertillon^[8]，Allen^[1]和 Parke^[9]为代表。Bertillon 通过编写一个简单程序与数据库中的人脸的关联，同时，他还结合指纹分析方法，研发了一个较强的识别系统；Allen 为待识别人脸设计了一个有效、逼真的描述方法，该方法使得对脸部的识别率大为提高；Parke 用计算机实现了 Allen 的方法，生成了具有较高质量的人脸灰度图模型；当然，还有其他一些人也做出了很大的贡献。但是，这一阶段的工作主要是依赖于手工操作，还不能完成自动的人脸识别工作^[1]。

第二阶段是人机交互识别阶段，以 Goldstion，Harmon^[9]和 Lesk^[1]为代表。他们探索出使用几何特征参数来表示正面人脸图像的方法，即采用二十一高维特征矢量表示人脸面部特征的方法；另外，Kara 和 Kobayashi^[1]探索出了基于统计的识别方法，用欧氏距离对人脸特征进行表征；还有 T.Kanade^[9]的方法，先使用

积分投影方法计算出一簇人脸特征参数，再利用模式分类技术与标准人脸匹配等等。但这此方法需要利用操作员的某些先验知识，仍然摆脱不了人的干预。

第三阶段是机器自动人脸识别阶段。近年来随着高性能、高速度计算机的问世，自动人脸模式识别方法也取得了较大的进展。目前人脸自动识别技术主要分为三大类：几何特征法、统计特征法和连接机制法。基于几何特征法如模板匹配法、弹性图匹配法等，基于统计特征法如主分量分析、独立分量分析和线性判别式法分析等，基于连接机制法如神经网络方法、HMM 方法、SVM 方法等。这些方法各有优点，也各有不足。为了使用于不同条件下的人脸识别，目前更多的人脸识别系统是将各种方法有机地融合在一起，发挥优长，克服缺点，以适应不同条件下的人脸识别需求，达到降低运算量，提高识别率的目的。

1.4 国内外人脸识别理论研究机构

目前，国内外许多科研机构都设立了专门的研究组从事人脸检测和识别的理论研究。国外著名的人脸检测和识别研究机构有美国的卡奈基梅隆大学(CMU)机器人研究所、麻省理工学院(MIT)媒体实验室和人工智能实验室、英国的 Surey 大学视觉语音和信号处理研究中心、法国的 INRIA 研究所、芬兰的赫尔辛基大学 CIS 研究所、瑞士 IDIAP 研究所和日本 ART 研究所等^[3]。

国内关于人脸识别的研究开始于 20 世纪 80 年代，目前主要有北京大学、清华大学、中国科技大学、中科院自动化研究所和计算机研究所、北京交通大学、北京工业大学、浙江大学、西北大学、西安交通大学、大连理工大学、南京理工大学和哈尔滨工程大学等，其中中科院自动化研究所和计算机研究所的研究工作处于国内领先水平^[9]。

1.5 本课题研究内容

在这里，我们首先对人脸识别工作的基本过程进行一些说明。

广义的人脸识别研究内容通常包括人脸检测、人脸表征、人脸鉴别、表情识别、物理分类五个方面^[1]，如图1-1所示：



图 1-1 广义的人脸识别过程

狭义的人脸识别研究方法，不涉及表情识别和物理分类两个方面。一个狭义

的人脸识别系统应包括三个主要技术环节——人脸检测、人脸表征和人脸识别（也称匹配识别）^[3]，如图1-2所示：




图 1-2 狭义的人脸识别过程

首先是人脸检测，即检测图像中有没有人脸，并确定人脸在图像中的位置。此步骤易受以下因素的影响：即人脸在图像中的位置、旋转角度、尺度，发型以及在拍摄过程中出现的噪声等。

其次是人脸表征，即特征提取及表示。其中，对人脸的特征提取是本课题的主要研究方向，特征提取之前一般需要作一些预处理工作，本实验是在一个已成型的人脸检测系统的基础上来做的，实验中对已有的人脸图像做了Gamma校正（该方法由人脸检测系统提供）。然后，本实验分别采用PCA方法和ICA方法对人脸特征提取，相关的内容将在后续章节中介绍。

最后是人脸识别，人脸识别就是将待识别的人脸图像或相关的特征值和数据库里预先存放的人脸图像或有关的特征值进行比较。这里提到的人脸识别只是整个人脸识别工作中的一个子过程，是一个相对狭义的概念。本部分一般又可分为两大类^[2]：一类是确认（一对一的匹配），另一类是查询（一对多的匹配）。

1.6 全文结构

第二章的主题介绍人脸特征提取以及特征选择的相关理论，本章粗略的介绍了特征提取的意义以及几种特征提取方法。

第三章的主题是利用PCA进行人脸特征提取，本章中我们对PCA方法的原理以及用PCA方法提取人脸特征的步骤进行了详细的介绍。

第四章的主题是利用ICA进行人脸特征提取，本章中我们对ICA方法的原理以及用ICA方法提取人脸特征的步骤进行了详细的介绍。

第五章的主题是PCA与ICA特征提取结果对比与分析，本章中，我们就两种方法的思路进行比较，给出了我们的结论。

第六章我们总结了全篇文章的内容，并就此工作进行了展望。

第二章 人脸特征提取以及特征选择的相关理论

2.1 特征提取概述

人脸图像在其原始样本空间中的分布往往并不集中,这就不利于对其进行有效的归类识别^[7]。为了能区分不同的人脸图像,可以把原始的人脸图像通过一些变换(包括线性或者非线性变换)方法转换到另外一个空间中,使得同类(同一个人)的人脸图像在此空间中分布更加紧凑,从而便于归类和识别。所谓特征提取,就是通过映射或者变换的方法将高维的原始特征转换到低维的特征空间中,得到人脸特征的低维表示。人脸识别中人脸的特征主要有以下几类^[10]:

1. 几何特征;
2. 灰度的统计特征;
3. 变换系数特征;
4. 代数特征等。

有关几何特征和代数特征以及相应的提取方法等部分的内容我们将在后面详细说明,这里只对灰度的统计特征和变换系数特征方面的内容进行简要说明。

人脸的灰度的统计特征,就是人脸图像中的所有像素灰度值的一些统计特性,如直方图特征。提取人脸灰度的统计特征的工作就是将人脸图像看作是一个二维的随机过程,然后计算出的各阶矩的值^[10]的过程。

人脸的变换系数特征,就是对人脸的图像进行一些数学变换——如 Fourier 变换, Hough 变换和小波变换等——之后得到的一系列变换系数^[10],而这也是提取人脸的变换系数特征的方法。

2.2 几何特征

人脸由眼睛、鼻子、嘴巴、下巴及耳朵等部分构成,也正因为这些部分的形状、大小以及结构上的差异才构造出世界上千差万别的人脸,所以,我们使用一些几何方法对这些部分的形状以及结构关系进行描述,然后将描述结果作为依据进行人脸识别。人脸的几何特征通常是以人脸器官形状和几何关系为基础的特征矢量,其分量一般包括人脸指定两点间的欧式距离,曲率,角度等^[1]。如图2-1所示(见下页):

典型的人脸几何特征分量包括:

1. 眉毛的弧度;
2. 眉毛的厚度及其对应眼睛中心处的垂直距离;
3. 眼睛中心处到耳朵的水平距离;



图 2-1 典型的人脸几何特征

- 4. 两个内眼角的水平距离；
- 5. 鼻子的垂直位置和宽度；
- 6. 嘴的垂直位置、宽度、高度以及上下嘴唇的厚度；
- 7. 鼻子处脸的宽度；
- 8. 半脸宽（鼻尖与眼睛中心位置处的宽度）；
-

2.2.1 人脸几何特征的提取方法

在本节开始时，我们讨论了一些关于几何特征的知识，对于这些特征进行提取，首先要对人脸图像中各器官进行定位，然后计算出上节中提出的那些特征即可。关于各器官定位的方法，现在已经出现了很多，由于这不是我们的主题，故在这里不再详细讨论。

这种提取方法有很多优点，例如，在一个好的定位算法的支持下，计算机可以很快的对这些几何特征进行计算，而且得到的这些特征占用也不会占有很多内存。但是，为了能够计算出各几何特征的准确值，必须要求输入图像的质量很好。当人脸图像被腐蚀，或者人脸区域被遮挡（即含有一些噪声）时，提出的几何特征不再准确，也就不再适合作为识别的依据了。尽管我们可以对该图像进行相关的预处理（如图像恢复、均衡化等），来保证提出特征的效果。但是，预处理过程会相当复杂。

还有一点，在第一章我们曾提到过，随着人的年龄、心情的变化，人脸都会有一些变化，因此，即使是同一个人的两幅图像，提出的几何特征也未必相同，因此根据这些特征进行识别工作，效果不会很好。

2.2.2 可变形模板

可变形模板可以视为上述几何特征提取方法的一种改进，其基本思想是：设

计一个参数可调的器官模型，并定义一个能量函数，通过调整模型参数使能量函数最小化，此时的模型参数即作为该器官的几何特征。这种方法思想很好，但是存在两个问题，一是能量函数中各种代价的加权系数只能凭经验确定，致使该项技术难以推广；二是能量函数优化过程的计算量很大，十分耗时，致使该方法在实际中难以得到普遍的应用^[1]。

综上所述，这类基于参数的人脸表示虽然可以实现对人脸显著特征的一个高效描述，但为了达到这个目标，我们需要对原数据进行大量的前处理，而且还要精细的选择参数。另外，采用一般的几何特征仅仅能描述部件的基本形状与结构关系，而忽略了其局部的细微特征，造成部分信息的丢失^[1]。也正是由于这些因素，目前已有的基于几何特征的人脸识别技术在精确率方面并不能满足实际的要求。

2.3 代数特征

人脸的代数特征是人脸图像的代数特征矢量表示，即人脸图像在“特征脸”张成的低维空间中的投影。人脸的代数特征就是人脸的统计特征。最早，Kirby 等人^[9]把主成分分析中的子空间思想引入到人脸识别中，并取得了很大的成功，随后，子空间分析方法受到人们的广泛关注，成为当前人脸识别的主流方法之一。

子空间方法的思想就是根据一定的性能目标来寻找线性或非线性的空间变换^[1]，并把原始信号数据压缩到低维子空间，使数据分布更加紧凑，为数据的更好描述提供了支持，另外，通过降维，使得后续的计算处理工作的复杂度大大降低。子空间方法亦可分为线性子空间方法和非线性子空间方法。

2.3.1 线性子空间

线性子空间方法就是利用线性的空间变换，将原始的人脸图像数据压缩到一个低维的子空间中。常见的线性子空间方法有：主成分分析（PCA）、线性判别分析（LDA）和独立成分分析（ICA）。其中，PCA 和 ICA 方法是本实验的研究的重点，PCA 部分的内容将在第三章进行讨论，ICA 部分的内容将在第四章中进行讨论，这里，仅对 LDA 方法进行简要说明。

LDA 方法是以样本可分性为目标的，其思想是从高维特征空间里提取出最有判别能力的低维特征，这些低维特征使得每类类内离散度最小（使得同一个类别的所有样本聚集在一起），同时使得类间的离散度达到最大（使得不同类别的样本尽量分开）。经典的 LDA 方法是使用 Fisher 准则函数，所以又称 LDA 分析又称为 Fisher LDA（FLDA）方法。

高维空间的样本向量的类间离散度矩阵定义为^[11]：

$$S_w = \sum_{i=1}^c p_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (2-1)$$

其中, μ_i 是 C_i 类向量的均值, μ 是所有样本向量的均值, p_i 是样本各类的先验概率。样本向量的类内离散度矩阵定义为:

$$S_b = \sum_{i=1}^c p_i S_i \quad (2-2)$$

其中, $S_i = E((x - \mu_i)(x - \mu_i)^T)$, $x \in C_i$ 。

投影方向的选择要满足一些条件, 即在投影后的低维空间里不同的类的向量要能分开, 并且同类向量要尽量密集。如果 S_w 是非奇异矩阵, 最优的投影方法 W_{opt} 就是使得样本类内离散度矩阵和类间离散度矩阵的行列式比值最大的那些正交向量^[11]。所以相应的 Fisher 准则函数定义为:

$$J(W_{opt}) = \max_w \frac{|W^T S_b W|}{|W^T S_w W|} \quad (2-3)$$

根据线性代数的有关知识, 我们可以知道 W_{opt} 就是满足下等式的解:

$$S_b W_i = \lambda_i S_w W_i \quad (2-4)$$

其中, $i = 1, 2, \dots, m$ 。也可以说, W_{opt} 就是对应于较大特征值 λ_i 的特征向量。

但是, 由于 FLDA 方法往往需要大量的样本, 这使得该方法的计算复杂度大大增加。目前, 有很多研究在尝试使用 FLDA 来进行小样本的识别^[12]。由于 LDA 方法并不是本课题讨论的重点, 故在此处就不再展开说明了。

基于线性子空间分析人脸特征提取, 实际上只是把人脸图像中存在的表情、姿态以及光照等复杂的变化进行了线性简化, 因此很难对人脸进行充分的描述。为了更充分的对人脸进行描述, 人们开始考虑使用非线性子空间方法表征人脸。

2.3.2 非线性子空间

在诸多的非线性子空间方法中, 非线性核技术是当前的一大主流。核技术的思想就是利用非线性映射, 把原空间的数据映射到隐特征空间中, 然后, 再隐特征空间中对数据进行分析。在计算上, 该方法不需要明确的计算这个非线性变换, 只需要通过一点核积函数来计算在隐特征空间中两向量的点积即可, 常用的和函数有三种: 多项式核、径向基核和 Sigmoid 核^[1]。

基于核的非线性子空间分析就是把核技术和线性子空间方法有机的结合起来的方法, 目前已经使用在人脸识别中的有核主成分分析 (KPCA) 和核 Fisher 判别决策 (KFLDA)^[5]。由于非线性空间方法也不是本课题讨论的重点, 故在此也不展开说明。

2.4 小结

特征提取就是通过对原始的人脸图像进行一系列的变换（包括线性或者非线性变换），将其转换到另外一个空间中，使得同类（同一个人）的人脸图像在此空间中分布更加紧凑，更有利于对其进行分类和识别。

人脸特征主要包括几何特征和代数特征，根据不同的特征，人们也研究出不同的算法。

首先，我们对基于几何特征的人脸识别方法，该方法速度快，占用内存少，但对图像质量要求较高，接着，我们介绍了这种方法的一个改进方法，即基于可变形模板法的人脸识别，该方法的思想是好的，但由于一些技术问题，难以在实际中得到应用。

最后，我们又介绍了一些基于代数特征的人脸识别方法，这些方法中较有代表性的是子空间方法，子空间方法分为线形子空间方法和非线性空间方法。常见的线性子空间方法有：主成分分析（PCA）、线性判别分析（LDA）和独立成分分析（ICA）等方法；在诸多的非线性子空间方法中，非线性核技术是当前的一大主流。目前已经使用在人脸识别中的有核主成分分析（KPCA）和核 Fisher 判别决策（KFLDA）。

第三章 基于 PCA 的人脸特征提取

3.1 引言

目前，在诸多的统计学分析方法中，主成分分析（Principal Component Analysis，即PCA）方法算得上是一个典型的分析方法。它是一种基于K-L变换的简单、有效的方法，现在已经被广泛的应用于对各种数据（包括信号、图像等）进行特征提取的工作中。使用PCA方法对原始数据进行处理，一方面是可以对原数据进行降维，从而降低数据复杂程度；另一方面，可以尽可能多地保留数据主要信息，有助于我们对数据更好的把握。总之，我们使用PCA方法对输入数据进行处理后，大部分的冗余信息（这里主要是指二阶统计信息）都被消除了，在后续的工作（即人脸识别）中，我们只需要处理剩下的信息，这大大减轻了我们的工作负担。

3.2 PCA 方法所涉及的数学知识

为了能够顺利的对PCA方法进行讨论，在这里我们首先来介绍一些该方法所涉及到的数学知识。PCA方法中主要使用到了二维随机变量的协方差、相关系数以及多维随机变量的协方差矩阵等知识。

3.2.1 协方差和相关系数

设 (X, Y) 为二维随机变量，若 $E((X - E(X))(Y - E(Y))^T)$ 存在，则称它为随机变量 X 与 Y 的协方差，记为 $Cov(X, Y)$ ，即：

$$Cov(X, Y) = E((X - E(X))(Y - E(Y))^T) \quad (3-1)$$

由于协方差与 X 、 Y 的量纲有关，为了更好的反映 X 与 Y 之间的关系，我们首先对 X 和 Y 进行归一化，得到 X^* 和 Y^* ，即：

$$X^* = \frac{X - E(X)}{\sqrt{D(X)}}, \quad Y^* = \frac{Y - E(Y)}{\sqrt{D(Y)}} \quad (3-2)$$

然后，我们求取 X^* 与 Y^* 的协方差，即：

$$Cov(X^*, Y^*) = \frac{Cov(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}} \quad (3-3)$$

如果 $D(X) > 0$ 且 $D(Y) > 0$ ，则称 $\frac{Cov(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}}$ 为随机变量 X 与 Y 的线性相关系

2. 在 $X_1, X_2, \dots, X_n$ 的所有线性组合中, Y_1 的方差是最大的, 即: $A_1 X^T$ 的方差是最大的; Y_2 与 Y_1 不相关的, 而且其方差是第二大的; 依此类推, Y_m 与 $Y_1, Y_2, \dots, Y_{m-1}$ 都不相关, 并且其方差是第 m 大的^[14]。

3. Y_i 被称为随机变量 X 的第 i 个主成分分量。

对于 Y_i ($i=1, 2, \dots, m$), 其方差^[14]:

$$\begin{aligned} D(Y_i) &= D(A_i X^T) \\ &= E((A_i X^T - E(A_i X^T))(A_i X^T - E(A_i X^T))^T) \\ &= A_i E((X^T - E(X^T))(X^T - E(X^T))^T) \\ &= A_i C (A_i)^T \end{aligned} \quad (3-8)$$

其中, C 是 X^T 的协方差矩阵, 在前面我们已经讨论过协方差矩阵的问题, 这里, 随机变量 X^T 的协方差矩阵 C 是一个对称矩阵, 又由于本实验所处理的人脸图像中每个像素的灰度值都是实数, 所以根据公式 (3-6) 计算出的 C 的每个元素也都是实数, 所以, C 是一个实对称矩阵。

前面我们对 Y 的说明中提到过, 在 $X_1, X_2, \dots, X_n$ 的所有线性组合中, Y_1 的方差是最大的。所以, 求取第 1 个主成分分量 Y_1 就等价于求取一个能使公式 (3-8) 达到最大的向量 A_1 ^[14]。

现在, 我们已经找到了对 Y_1 进行求解的方法, 但是, 我们如何来求解 A_1 呢? 又如何保证公式 (3-8) 达到最大呢? 经过前人的不断探索, 终于找到了一个解决该问题的方法, 该方法先从 X^T 的协方差矩阵 C 入手。

对于 C , 我们可以计算出它的 n 个特征值和特征向量, 再将这 n 个特征值进行排序得到 $\lambda_1, \lambda_2, \dots, \lambda_n$, 其中 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$, 之后, 再对相应的特征向量进行正交化, 得到一组标准正交基 $U_1, U_2, \dots, U_n$, 每个 U_i 是一个 n 维的列向量, 根据这组标准正交基可以求得正交阵 $U = [U_1, U_2, \dots, U_n]$ 。注意, 本实验中求得的每组 λ 中, 都有 $\lambda_i \neq \lambda_j$ ($i < j, i, j = 1, 2, \dots, n$), 所以上面只是对 U 的简化说法, 下面的计算也都用这个结果, 如果存在某 k 重特征值 λ_i , 可以求得它的一组基础解析 $U_{i_1}, U_{i_2}, \dots, U_{i_k}$, 并对其作正交化和单位化, 之后再以作出的结果构造 U 。

根据已有的特征值和正交阵, C 可以表示为^[14]:

$$\begin{aligned} C &= U \begin{pmatrix} \lambda_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \lambda_n \end{pmatrix} U^T \\ &= \sum_{i=1}^n \lambda_i U_i (U_i)^T \end{aligned} \quad (3-9)$$

若向量 A_1 为 n 维单位向量，公式（3-8）可以写为：

$$\begin{aligned} D(Y_1) &= A_1 C (A_1)^T \\ &= \sum_{i=1}^n \lambda_i A_1 U_i (U_i)^T (A_1)^T \end{aligned}$$

由于 λ_1 是 C 的最大的特征值，所以有^[14]：

$$\begin{aligned} D(Y_1) &= \sum_{i=1}^n \lambda_i A_1 U_i (U_i)^T (A_1)^T \\ &\leq \lambda_1 \sum_{i=1}^n A_1 U_i (U_i)^T (A_1)^T \\ &= \lambda_1 A_1 U (U)^T (A_1)^T \\ &= \lambda_1 A_1 (A_1)^T \\ &= \lambda_1 \end{aligned}$$

即：

$$D(Y_1) \leq \lambda_1 \quad (3-10)$$

当 $A_1 = U_1$ 时，有：

$$\begin{aligned} D(Y_1) &= \sum_{i=1}^n \lambda_i U_1 U_i (U_i)^T U_1 \\ &= \lambda_1 \end{aligned} \quad (3-11)$$

因此，在PCA方法中，我们选取 U_1 作为对 A_1 的估计。于是， Y_1 可以由下式求取：

$$Y_1 = U_1 X \quad (3-12)$$

对于 $Y_2, Y_3, \dots, Y_n$ 的求解方法也可以仿照求解 Y_1 的方法去做。于是有：

$$Y_i = U_i X \quad (3-13)$$

当然，在实际中有时我们仅仅需要 m ($m < n$) 个新变量 Y_i ($i = 1, 2, \dots, m$) 就可以完成我们的工作，这时，我们就要对 n 个 Y_i 进行挑选，关于挑选原则我们将在下节中介绍。

根据以上方法得到的 $Y = (Y_1, Y_2, \dots, Y_m)^T$ 能保证任意的 Y_i 和 Y_j ($i \neq j$) 是不相关的。

$$\begin{aligned} \text{Cov}(Y_i, Y_j) &= \text{Cov}(U_i X, U_j X) \\ &= E((U_i X - E(U_i X))(U_j X - E(U_j X))^T) \\ &= U_i E((X - E(X))(X - E(X))^T) (U_j)^T \\ &= U_i C (U_j)^T \\ &= U_i (\sum_{k=1}^n \lambda_k U_k (U_k)^T) (U_j)^T \\ &= \sum_{k=1}^n \lambda_k U_i U_k (U_k)^T (U_j)^T \\ &= \sum_{k=1}^n \lambda_k (U_i U_k) (U_j U_k)^T \end{aligned}$$

$$= 0 \quad (3-14)$$

由于 $\text{Cov}(Y_i, Y_j) = 0$ ，所以 Y_i 和 Y_j ($i \neq j$) 是不相关的。

至此，我们已对 PCA 方法原理进行了详细的说明，下面，进入本课题的一个核心问题——使用 PCA 对人脸图像进行特征提取。

3.4 使用 PCA 方法对人脸图像进行特征提取

使用 PCA 方法进行人脸识别，其核心思想是假设所有的人脸都处于一个低维的线性空间中，而且，在这个空间中，不同的人脸具有不同的属性。其具体做法可以描述为：假设共有 K 个人待识别，而我们拥有他们每个人各 M 张“人脸”图像，那么，我们就可以通过每个人的 M 幅图像，来为这个人设计一个分类器，将来，当我们得到一幅图像时，就将它分别送到已有的 K 个分类器中，根据各个分类器提供得识别结果（通常是百分比，来估计该图像属于这个人得可能性）来估计图像中的人是谁。当然，我们的工作仅仅是使用 PCA 方法来提取人脸图像的特征，为训练分类器提供数据。

M.Turk^[1]提出的“特征脸”方法的核心就是利用 PCA 方法提取人脸的特征向量(也称特征脸)，再将每一张人脸图像看成是许多特征脸的线性组合。其思想是以训练样本集（某个人的 M 幅人脸图像）的总体散布矩阵为产生矩阵，经 PCA 变换后得到一组具有人脸的形狀的特征向量，该向量就是所谓的“特征脸”。之后，可以使用以上求得的“特征脸”向量张成一个子空间，再将每一幅该人的人脸图像（共 M 幅）投影到该子空间上可以获得一组表示人脸在子空间中位置的坐标系数，这组坐标系数就是上述线性组合的一组权值。这 M 组坐标系数就是我们的实验要求得的结果。重复上述过程，为每个人（共 K 个人）生成类似的 M 组结果。

下面，我们来介绍“特征脸”方法的具体实现过程。

设人脸图像由 $N=R \times C$ 个像素组成（ R 行， C 列），像素点灰度值被保存在 $R \times C$ 的矩阵中。将该矩阵按行堆叠成 N 维列向量 Y_i ， Y_i^T 可以表述为：

$(Y_i(1,1), Y_i(1,2), \dots, Y_i(1,L), Y_i(2,1), \dots, Y_i(2,L), \dots, Y_i(K,L))$ ，其中， $Y_i(i,j)$ 为矩阵第 i 行第 j 列的值。相应的， M 幅人脸图像(相同人的不同表情图像)构成一个 N 行， M 列的人脸矩阵 Y ：

$$Y = (Y_1, Y_2, \dots, Y_i, \dots, Y_M)。$$

Y 就是一个训练样本集的总体散布矩阵，我们以它为产生矩阵进行进一步处理，来求取需要的特征脸空间，以及原图像投影到“特征脸”子空间上的一组坐

标系数。

第一步：去均值。将训练集中的人脸图像 Y_i 减去人脸图像的平均值 $\bar{Y}$ ，得到一组具有零均值的人脸图像 $\tilde{Y}_i$ 。

$$\begin{aligned}\bar{Y} &= E(Y_i) \\ &= \frac{1}{M} \sum_{i=1}^M Y_i\end{aligned}\quad (3-15)$$

$$\tilde{Y}_i = Y_i - \bar{Y} \quad (3-16)$$

其中， $i = 1, 2, \dots, M$ 。

第二步：求零均值人脸矩阵 $(\tilde{Y})^T$ 的协方差矩阵 $C^{[14]}$ 。其中， $\tilde{Y} = (\tilde{Y}_1, \tilde{Y}_2, \dots, \tilde{Y}_M)$ 。

$$C = \frac{1}{N} (\tilde{Y})^T \tilde{Y} \quad (3-17)$$

计算所得的 C 是 M 阶方阵，另外，根据前面讨论可知， C 是实对称矩阵。

第三步：求 C 的 M 个特征值及其对应的特征向量 U 。

$$C U_i = \lambda_i U_i \quad (3-18)$$

其中， $i=1, 2, \dots, M$ 。上式的矩阵形式为：

$$C U = U \Lambda \quad (3-19)$$

其中， $U = (U_1, U_2, \dots, U_M)$ 是以 C 的特征向量 U_i 为列向量的 M 阶方阵。而

$\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_M)$ 是以对应的特征值为对角元素的对角阵。因为协方差矩阵 C 是实对称阵，由矩阵理论可知，它特征值都是实数，且属于不同特征值的特征向量是正交的，即 $U U^T = E$ ，所以， U 是正交矩阵，且有 $U^T = U^{-1}$ 。

第四步：求取特征脸向量。根据公式（3-12）和公式（3-13）可知：

$$\text{Eigen}_i = U_i (\tilde{Y})^T \quad (3-20)$$

其中 $i = 1, 2, \dots, M$ 。

第五步：对 M 个特征值进行排序，取最大的前 m 个特征值，及其对应的特征向量，即主分量，由这 m 个特征向量构成特征脸空间 $\widetilde{\text{Eigen}}$ 。

下面讨论几种不同的特征向量个数选取方法^[1]：

1. 标准的特征空间投影

所有的 $m(m < M)$ 个对应于非零特征值的特征向量均被用于创建特征脸子空间，该方法在 m 值比较大的时候，计算速度比较慢，而且不利于分类，另外，该方法并没有达到降维的效果。

2. 保留前面的 $c-1$ 个特征向量

将特征值按照降序排列，同时只保留最前面的 $c-1$ 个特征向量。其中 c 为训练图像的类别数。

3. 通过计算阈值来确定维数

该方法采用保证所保留的特征向量所对应的特征值之和与总体特征值之和的比值大于一定的阈值。

我们的选择第3种方法来进行实验。即保证剩余的特征向量所包含的信息与总的信息量相比大于一定的阈值 e ，实验中 e 的值取为0.9。

$$e_j = \frac{\sum_{i=1}^j \lambda_i}{\sum_{i=1}^M \lambda_i} \quad (3-21)$$

令 $e_j > 0.9$ ，我们可以确定 m 的值，进而构造特征脸空间 $\widetilde{\text{Eigen}}$ 。

第六步：将训练集中的零均值人脸图像投影到上述空间，得到 m 维的低维向量 R 。

$$R = \widetilde{\text{Eigen}} \tilde{Y} \quad (3-22)$$

其中， $R = (R_1, R_2, \dots, R_M)$ ， R_j 为 $m \times 1$ 的矩阵，表示第 j 幅人脸图像在特征脸子空间中的坐标系数。

将上述过程重复 k 次，为每个人建立一组坐标系数，这也是本实验主要做的工作。

3.5 实验

3.5.1 实验说明

本部分的工作采用C++语言作为编程语言，使用了Visual Studio 2005作为编辑和测试程序的平台，另外，本部分还用到了Intel开源计算机视觉库OpenCV中提供的一些算法。

3.5.2 实验流程图

图 3-1 为本实验的流程图，简要的列举了本实验的全部步骤，见下页。

3.5.3 实验数据

本实验使用了英国 Essex 大学的人脸识别数据库中的 10 个人（每人 20 副图像）共 200 幅图像进行实验。这些图像具有相同的大小（ 180×200 ）、较单一背




图 3-1 实验流程图

景色的 24 位的 JPEG 图像，每幅图像中都类似于“大头像”，同一个人的 20 幅图像中，人脸尺寸基本相同，而且光照条件近似，没有强光照射。另外，我们所

选取的这 10 个人的肤色也很接近。这里，我仅仅使用一个人的 20 幅图像说明我的工作，这部分图像请参见图 3-2：

图3-1展示的是同一个人不同表情的20幅人脸图像，下面，来介绍一下我的工作过程。

首先，使用已有的人脸检测系统autofaceGFB^[15]对人脸图像进行Gamma 校正，




图 3-2 原输入图像

并检测和提取人脸区域图像，提出的图像均为 60×60 的小图像。提出的图片如图3-3所示：

图3-3所示的图片是根据原图片进行裁减出来的，我们可以看出，原图像在




图 3-3 截取得到的图像

经过Gamma 校正处理后，背景色明显减弱，另外，人脸区域的光照效果也明显减弱，所以，Gamma校正有效的取出了一些噪声影响。但是，提取出来的图像依然是彩色图像，而我们的程序只能处理灰度图像，因此，我们必须先将提取出来的彩色图像转换成为灰度图像，本实验中我们采用OpenCV的图像加载函数直接进行转换，部分内容参见[http:// www.opencv.org.cn](http://www.opencv.org.cn)^[21]，转换后的结果如图3-4所示：



图 3-4 根据截取图像获得的灰度图像

图3-4是根据图3-2转换成的灰度图像，这种转换实际上就是通过一个线性变换将原图像的R、G、B三个通道的值叠加成一个单通道值，转换过程很简单，这

里就不再赘述了。

我们将转换后得到的灰度图像作为输入数据提供给PCA算法，得到如图3-5所示的“特征脸”图像：



图 3-5 用PCA方法计算出的特征脸图像

这些“特征脸”对应的特征值分别为：

33873, 171834, 137433, 67198.3, 54860.1, 46941.4, 36677.1, 32251.3, 25225.4, 22449.3, 19481.2, 16481.8, 12798.2, 8315.84, 6681.1, 5299.76, 4499.3, 3797.03, 2289.08, 5.05799×10^{-12} 。

根据公式（3-21）可以得出，在这20幅“特征脸”图像中，选取前9副图像就可以满足人脸表示的需要。

将提取出的人脸图像分别投影到由这九个“特征脸”向量张成的特征脸子空间里，可以得到如下的特征向量。

$R_1^T = (8.5475, 6.9486, 7.4304, 6.7959, 7.8846, 7.5774, 8.0714, 8.2439, 7.9967)$ ；

$R_2^T = (6.9486, 8.5076, 6.8325, 7.4182, 6.8701, 7.5515, 7.2207, 7.2910, 7.1807)$ ；

$R_3^T = (7.4304, 6.8325, 8.5672, 7.1619, 7.7765, 6.9148, 7.2586, 7.5227, 7.4685)$ ；

$R_4^T = (6.7959, 7.4182, 7.1619, 8.5247, 7.4263, 7.7412, 7.4883, 7.4206, 7.5766)$ ；

$R_5^T = (7.8846, 6.8701, 7.7765, 7.4263, 8.6408, 7.6199, 8.0576, 8.1897, 8.2086)$ ；

$R_6^T = (7.5774, 7.5515, 6.9148, 7.7412, 7.6199, 8.5308, 8.2871, 8.1727, 8.1303)$ ；

$R_7^T = (8.0714, 7.2207, 7.2586, 7.4883, 8.0576, 8.2871, 8.6898, 8.5625, 8.4057)$;

$R_8^T = (8.2439, 7.2910, 7.5227, 7.4206, 8.1897, 8.1727, 8.5625, 8.7010, 8.5042)$;

$R_9^T = (7.9967, 7.1807, 7.4685, 7.5766, 8.2086, 8.1303, 8.4057, 8.5042, 8.6079)$;

$R_{10}^T = (8.0790, 7.3013, 7.0370, 6.9071, 7.5970, 7.8214, 8.0284, 8.1336, 8.0585)$;

$R_{11}^T = (6.6161, 6.5654, 7.6306, 7.3573, 7.2892, 6.8050, 6.9488, 6.9471, 7.0082)$;

$R_{12}^T = (7.4627, 7.0659, 7.8828, 7.6320, 8.0300, 7.4018, 7.7547, 7.8515, 7.8308)$;

$R_{13}^T = (7.8706, 7.4793, 7.4380, 7.7148, 8.1377, 8.0678, 8.2656, 8.3796, 8.4750)$;

$R_{14}^T = (7.9395, 7.6567, 7.5837, 7.7236, 8.0857, 8.0390, 8.1871, 8.3885, 8.4161)$;

$R_{15}^T = (7.6224, 7.0475, 8.1898, 7.4803, 8.1369, 7.3499, 7.7133, 7.8646, 7.8034)$;

$R_{16}^T = (7.9640, 7.5389, 6.9490, 6.8594, 7.4666, 7.7192, 7.8783, 8.0244, 7.8491)$;

$R_{17}^T = (7.9357, 6.8680, 6.7002, 6.4080, 7.2689, 7.4020, 7.7980, 7.9120, 7.7308)$;

$R_{18}^T = (7.3849, 7.1420, 7.7791, 7.1600, 7.3544, 6.9539, 7.2565, 7.3913, 7.2210)$;

$R_{19}^T = (7.8721, 6.3380, 6.8283, 6.4307, 7.4415, 7.1919, 7.6033, 7.7594, 7.6740)$;

$R_{20}^T = (7.6333, 7.8779, 7.3108, 7.4140, 7.5108, 7.6049, 7.6526, 7.8270, 7.6856)$;

这些就是各个原图像在前9个特征脸向量上的投影值，我们可以将其作为数据来为这个人训练一个分类器，当然，这不是本实验的主题，在这里就不再赘述了。

3.6 小结

主成分分析（PCA）是一种从原始数据中提取特征的传统方法，其在以数理

统计方法进行数学建模的过程中得到了广泛的应用。PCA 的一种方法是通过计算数据协方差矩阵的特征值和特征向量来实现的。其思想是保留不相关的，且具有最大特征值的特征向量，但是，我个人觉得这种方法还不足以保证前面的约束条件，即 Y_i 的方差实在 $X_1, X_2, \dots, X_n$ 的所有线性组合中第 i 大的，因为根据前面的讨论，我们只能保证 Y_1 的方差实在 $X_1, X_2, \dots, X_n$ 的所有线性组合中是最大的，对于其他的 Y_i ($i=2, 3, \dots, m$)，好像没有更严密的证明它的方差实在 $X_1, X_2, \dots, X_n$ 的所有线性组合中第 i 大的。但是，该方法却能够有力的保证任意的 Y_i 和 Y_j ($i \neq j$) 是不相关的，我想正是由于存在这方面的优势，该方法可以被广泛的应用。

第四章 基于 ICA 的人脸特征提取

4.1 引言

我们在第四章已经介绍了有关主成份分析（PCA）方法的一些知识，该方法使用互不相关的基向量构成一个低维的子空间，从而使新数据（如信号、人脸图像等）在这个子空间中各个基向量方向上的投影系数也是不相关的，所以，使用 PCA 方法可以消除原数据在各基向量上的投影系数之间的二阶相关性。但是，如果当所有数据的分布都服从高斯分布时（在高斯分布的前提下，随机变量之间互不相关和随机变量相互独立是等价的），使用 PCA 方法可以构造出相互独立的特征向量，它们之间不存在任何冗余信息。然而，在现实世界里，并不是所有的数据都服从高斯分布，甚至在绝大部分情况下，数据都是非高斯分布的，因此，使用 PCA 方法得到的在各个基向量方向上的投影系数之间还存在大量的高阶相关信息，而其中有很多都是冗余信息。为了尽可能去掉这些冗余信息，独立成分分析（Independent Component Analysis，即 ICA）方法应运而生，并很快的获得了成功，目前已经被广泛的应用于语音信号分析、金融数据分析、特征提取等领域。

4.2 ICA 方法所涉及的数学知识

同第四章一样，为了能够顺利的对 ICA 方法进行讨论，在这里我们也首先来介绍一些该方法所涉及到的数学知识。ICA 方法中主要使用到了随机变量的统计量（包括矩、累积量等）、负熵以及独立和相关的知识。

4.2.1 随机变量的统计量

随机变量的统计量有很多，这里，我们仅仅对与本课题相关的矩和累积量等知识进行说明。

4.2.1.1 矩

1. X 的 n 阶原点矩为：

$$M_{\text{原点}}^n = E(X^n) \quad (4-1)$$

特别的，当 $n=1$ 时， $M_{\text{原点}}^1$ 是 X 的均值 $E(X)$ ，记为 m_X ；当 $n=2$ 时， $M_{\text{原点}}^2$ 是 X 的均方。

2. X 的 n 阶中心矩为:

$$M_{\text{中心}}^n = E((X - E(X))^n) \quad (4-2)$$

特别的, 当 $n=2$ 时, $M_{\text{中心}}^2$ 是 X 的方差 σ_X^2 , 记为 D_X , 它反映随机变量在其均值附近的集中程度, 方差越小, 随机变量取值越集中, 另外 $\sigma_X = \sqrt{D_X}$ 称为 X 的标准差。

当 n 取 1 或者 2 时, 对应的原点矩和中心矩称为随机变量的低阶矩, 而 n 大于 2 时对应的原点矩或中心矩称为随机变量的高阶矩。

3. 混合原点矩和混合中心矩

对于随机变量 X, Y , 若 $E(X^k Y^l)$ 存在, 则称它为 X 与 Y 的 $k+l$ 阶混合原点矩;

若 $E((X - E(X))^k (Y - E(Y))^l)$ 存在, 则称它为 X 与 Y 的 $k+l$ 阶混合中心矩。

4.2.1.2 累积量

如同前面提到的矩一样, 累积量也是描述随机变量性质的一个重要的统计量。

1. 单个随机变量的 k 阶累积量

设 X 是一连续型随机变量, 其第一特征函数定义为^[16]:

$$\Phi(\omega) = \int_{-\infty}^{+\infty} p(X) e^{j\omega X} dx = E(e^{j\omega X}) \quad (4-3)$$

其中, $p(X)$ 是 X 的概率密度函数。根据傅立叶变换的知识可以看出, X 的特征函数实际上就是 $p(X)$ 的傅立叶变换。

X 的第二特征函数定义为^[16]:

$$\psi(\omega) = \ln \Phi(\omega) \quad (4-4)$$

$\psi(\omega)$ 也称为累积量生成函数, 它可以按泰勒级数展开^[17], 得:

$$\psi(\omega) = \sum_{k=1}^n \frac{c_k}{k!} (j\omega)^k + O(\omega^n) \quad (4-5)$$

其中, c_k 称为 X 的 k 阶累积量, 显然, c_k 与 $\psi(\omega)$ 的 k 阶导数存在着一些关系。即^[17]:

$$\begin{aligned} c_k &= \frac{1}{j^k} \left[\frac{d^k \ln \Phi(\omega)}{d\omega^k} \right] \Big|_{\omega=0} \\ &= (-j)^k \frac{d^k \psi(\omega)}{d\omega^k} \Big|_{\omega=0} \\ &= (-j)^k \psi^{(k)}(0) \end{aligned} \quad (4-6)$$

其中 $k \leq n$ 。

为了后面的讨论更加方便, 我们在这里给出 X 的前四阶累积量的计算公式, 它们分别为^[18]:

$$\begin{aligned}
 c_1 &= M_{\text{中心}}^1 \\
 c_2 &= M_{\text{中心}}^2 - \left(M_{\text{中心}}^1\right)^2 \\
 c_3 &= M_{\text{中心}}^3 - 3M_{\text{中心}}^2 M_{\text{中心}}^1 - 2\left(M_{\text{中心}}^1\right)^3 \\
 c_4 &= M_{\text{中心}}^4 - 3M_{\text{中心}}^2 M_{\text{中心}}^2 - 4M_{\text{中心}}^3 M_{\text{中心}}^1 + 12M_{\text{中心}}^2 \left(M_{\text{中心}}^1\right)^2 - 6\left(M_{\text{中心}}^1\right)^3 \quad (4-7)
 \end{aligned}$$

当随机变量均值为零时，公式（4-7）可以得到简化。一阶累积量 $c_1 = M_{\text{中心}}^1 = 0$ ，它是X的均值；二阶累积量 $c_2 = M_{\text{中心}}^2$ ，它就是X的方差；三阶累积量 $c_3 = M_{\text{中心}}^3$ ，它是X的三阶中心矩，可以用来描述X概率分布函数偏离均值的程度；四阶累积量 $c_4 = M_{\text{中心}}^4 - 3M_{\text{中心}}^2 M_{\text{中心}}^2$ ，其被称为X的峭度，也可以记为 $\text{kurt}(X)$ ，它是用来度量X的非高斯性程度的。当峭度为0时，X的分布为高斯分布；峭度大于0时，称X的分布为超高斯分布；而峭度小于0时，称X的分布为亚高斯分布。

2. 多维随机变量的联合累积量

对于n维随机变量 $X = (X_1, X_2, \dots, X_n)$ ，定义其第一联合特征函数为^[18]：

$$\Phi(\omega_1, \omega_2, \dots, \omega_n) = E(\exp(j(\omega_1 X_1 + \omega_2 X_2 + \dots + \omega_n X_n))) \quad (4-8)$$

定义其第二联合特征函数为^[18]：

$$\Psi(\omega_1, \omega_2, \dots, \omega_n) = \ln \Phi(\omega_1, \omega_2, \dots, \omega_n) \quad (4-9)$$

公式（4-9）可以按泰勒级数展开，阶数 $r = k_1 + k_2 + \dots + k_n$ 的联合累积量可用第二特征函数定义为^[18]：

$$\begin{aligned}
 C_{k_1 k_2 \dots k_n} &= (-j)^r \frac{\partial^r \Psi(\omega_1, \omega_2, \dots, \omega_n)}{\partial \omega_1^{k_1} \partial \omega_2^{k_2} \dots \partial \omega_n^{k_n}} \Big|_{\omega_1=\omega_2=\dots=\omega_n=0} \\
 &= (-j)^r \frac{\partial^r \ln \Phi(\omega_1, \omega_2, \dots, \omega_n)}{\partial \omega_1^{k_1} \partial \omega_2^{k_2} \dots \partial \omega_n^{k_n}} \Big|_{\omega_1=\omega_2=\dots=\omega_n=0} \quad (4-10)
 \end{aligned}$$

假设 $\{x(n)\}$ 为零均值的k阶平稳随机过程，则该过程的k阶累积量 $c_{kx}(\tau_1, \tau_2, \dots, \tau_{k-1})$ 是k-1个独立变元的函数。它被定义为随机变量 $(x(n), x(n + \tau_1), \dots, x(n + \tau_{k-1}))$ 的k阶累积量，即^[14]：

$$c_{kx}(\tau_1, \tau_2, \dots, \tau_{k-1}) = \text{cum}(x(n), x(n + \tau_1), \dots, x(n + \tau_{k-1})) \quad (4-11)$$

其中， $\text{cum}(\cdot)$ 代表联合累积量。

从上面可以知道，平稳随机过程 $\{x(n)\}$ 的 k 阶累积量实际上就是取 $x_1 = x(n)$, $x_2 = x(n + \tau_1)$, $x_3 = x(n + \tau_2)$, $\dots$, $x_k = x(n + \tau_{k-1})$ 之后的随机向量 $(x(n), x(n + \tau_1), \dots, x(n + \tau_{k-1}))$ 的 k 阶累积量，由于 $\{x(n)\}$ 是 k 阶平稳的，所以其 k 阶累积量均只有 $k-1$ 个独立的变元，它们仅仅是滞后的 $\tau_1, \tau_2, \dots, \tau_{k-1}$ 的函数，与时间 n 无关^[14]。

如果随机变量 $X_i (i = 1, 2, \dots, n)$ 和 $Y_i (i = 1, 2, \dots, n)$ 互相独立，则：

$$\begin{aligned} & \text{cum}(X_1 + Y_1, X_2 + Y_2, \dots, X_n + Y_n) \\ &= \text{cum}(X_1, X_2, \dots, X_n) + \text{cum}(Y_1, Y_2, \dots, Y_n) \end{aligned} \quad (4-12)$$

这是一个非常重要的性质：两个统计独立的随机过程之和的累积量等于各个随机过程累积量之和。因此，如果一个非高斯信号在与之独立的加性高斯有色噪声中被观测的话，那么观测过程的高阶累积量就与原非高斯过程的高阶累积量相等。

4.2.2 负熵

负熵的概念来源于信息论中熵的概念，和上节中提到的峭度一样，它也是衡量非高斯性的一种重要方法。在介绍负熵之前，我们要对熵和微分熵的概念做一个了解。

熵的概念是基于离散型随机变量的，也称概率空间熵，表示信源的平均自信息量。设有离散型随机变量 X ，其所有可能取值为 x_i ， p_i 为随机变量 X 的概率分布 $(i = 1, 2, \dots, n)$ ，熵 $H(X)$ 可以定义为^[19]：

$$H(X) = -\sum_i p_i \log(p_i) \quad (4-13)$$

将式4-13的定义推广到连续型随机变量，我们可以得到微分熵的定义。

微分熵可以表示连续型随机变量 X 中包含信息量的多少。设有连续随机变量 X ，其概率密度函数为 $p(X)$ ，微分熵 $H(X)$ 可以定义为^[19]：

$$H(X) = -\int p(X) \log(p(X)) dX \quad (4-14)$$

对于 n 维随机变量 $X = (X_1, X_2, \dots, X_n)$ ，其联合微分熵的定义为^[19]：

$$H(X) = -\int p_{X_i}(X_i) \log(p_{X_i}(X_i)) dX_i \quad (4-15)$$

其中， $p_{X_i}(X_i)$ 为 X_i 的边缘概率密度函数。如果 X 的各个分量相互独立，则联合微分熵等于各个边缘微分熵之和，即：

$$H(X) = \sum_{i=1}^n H(X_i) \quad (4-16)$$

根据平均功率受限最大熵定理可知，在信号的平均功率受限时，具有高斯分

布的信号的熵最大^[19]，我们定义一个新的概念——负熵来描述与高斯信号有相同功率的非高斯信号的熵，负熵的定义为^[19]：

$$J(X) = H(X_{\text{gauss}}) - H(X) \quad (4-17)$$

其中， X_{gauss} 是具有与 X 相同方差的高斯随机变量。负熵表示两个具有相同方差的随机变量的微分熵的差值，若果 Y 是 X 经过线性变换的到的，则 $J(Y) = J(X)$ ，另外，对于所有的随机变量 X ， $J(X)$ 总是非负的，只有当 X 的分布服从高斯分布时， $J(X)$ 才为零。负熵的值越大，表明 X 的微分熵是越远离高斯分布的微分熵，所以，负熵可以用来衡量随机变量非高斯程度。

由于源信号和观察信号的概率密度函数往往是未知的，所以，人们常常使用累积量去近似概率密度函数。例如，采用Gram-Charlier方法去近似概率密度函数时，有：

$$p(X) \approx a(X) \left[1 + \frac{c_3}{3!} H_3(X) + \frac{c_4}{4!} H_4(X) \right] \quad (4-18)$$

其中， $a(X)$ 是标准的高斯分布， c_3 、 c_4 分别是 X 的三阶和四阶累积量， $H_i(X)$ 是 i 阶Hermite多项式，其定义为标准高斯分布的概率密度函数的导数：

$$H_i(X) a(X) = (-1)^i \frac{\partial^i a(X)}{\partial^i X} \quad (4-19)$$

可以导出^[19]：

$$\begin{aligned} H_0(X) &= 1; \\ H_1(X) &= X; \\ H_2(X) &= X^2 - 1; \\ &\dots\dots \dots \end{aligned}$$

$$H_{k+1}(X) = XH_k(X) - kH_{k-1}(X) \quad (4-20)$$

将公式(4-18)分别代入公式(4-14)和公式(4-17)，并利用 $\log(1 + \varepsilon) = \varepsilon + \frac{\varepsilon^2}{2+O(\varepsilon^3)}$ 式展开，得^[19]：

$$H(X) = \frac{1}{2} \log(2\pi e) - \frac{(c_3)^2}{2 \times 3!} - \frac{(c_4)^2}{2 \times 4!} \quad (4-21)$$

$$J(X) = \frac{1}{12} E(X^3)^2 + \frac{1}{48} \text{kurt}(X)^2 \quad (4-22)$$

这样，微分熵和负熵都可以用随机变量的高阶累积量来近似。

4.2.3 统计独立与相关

1. 独立的概念

我们首先给出两个随机变量独立性的定义，设 X 和 Y 是两个随机变量，其

联合概率密度函数为 $p(X, Y)$ ，其边缘概率密度函数分别为 $p_X(X)$ 和 $p_Y(Y)$ ，如果有：

$$p(X, Y) = p_X(X)p_Y(Y) \quad (4-23)$$

则称 X 与 Y 相互独立。

统计独立有一个重要的性质：对于两个随机变量 X 和 Y ，设有其任意两个函数 f_1 和 f_2 ，则有：

$$E(f_1(X)f_2(Y)) = E(f_1(X))E(f_2(Y)) \quad (4-24)$$

公式（4-23）也可以推广到 n 维随机变量的情况，设一个 n 维随机向量 $X = (X_1, X_2, \dots, X_n)$ ，若其联合密度函数 $p(X)$ 满足：

$$p(X) = \prod_{j=1}^n p_j(X_j) \quad (4-25)$$

其中， $p_j(X_j)$ 表示 X_j 的边缘概率函数，则称 n 维随机向量 X 的各分量相互独立。

公式（4-24）也可以推广到 n 维的情况下，这里就不再赘述了。

2. 统计独立与相关

在第三章中，我们回顾了协方差及相关系数的一些内容，我们知道，相关系数 ρ_{XY} 能够表明随机变量 X 与 Y 是否是线性相关的。而且，在第三章中我们也证明了由 PCA 方法提出的特征脸向量之间是非线性相关的，但是，非线性相关并不等价于完全的不相关，因此，我们有必要在这里对“不相关”进行进一步的说明，然后，我们会对独立与相关进行比较。

我们仍以两个随机变量 X, Y 为例，来对“不相关”进行定义。“不相关”的定义为：

对于两个随机变量 X, Y ，如果有 $E(XY) = E(X)E(Y)$ 成立，则称 X 和 Y 是不相关的。

结合公式（4-24）我们可以看出，如果 X 和 Y 相互独立，当我们令 $f_1(X) = X$ ， $f_2(Y) = Y$ 时， $E(XY) = E(X)E(Y)$ 显然成立，所以，独立的条件要比不相关要强。一般情况下，若变量独立，则必不相关；反之不成立。但也有例外，如果 $X_1, X_2, \dots, X_n$ 的联合分布为高斯分布时，独立和不相关等价。从这个角度来说，对高斯分量进行独立分量分析没有实际意义，也可以说，独立分量分析对高斯变量不敏感。

4.3 ICA 方法概述

早在20世纪八十年代，人们就开始采用盲源分离 (Blind source separation,

即BSS)的方法来对信号进行分离^{[19]、[20]}，这种方法算得上是ICA方法的雏形。在1994年，P.Comon^[20]第一次正式提出了ICA方法。该方法的核心思想是从消除信息相关性的角度来对数据进行分析处理，使得变换以后的得到的新数据之间相互独立。

从那以后，人们探索出了很多不同的ICA实现方法，其中比较成功的有：Bell 和Sejnowski 根据信息最大化原则的提出的InfoMax算法；Hyvarinen根据负熵最大的原则提出了一个固定点算法：fastICA方法等等^[1]。总的来说，从最初ICA的思想被成功地应用在盲信号分离上之后，ICA方法已经得到了广泛的应用。

4.3.1 ICA 的定义

在给出独立成份分析的定义之前，我们先简单介绍一个著名的“鸡尾酒会”问题(Cocktail-Party Problem)。假设在一间房间里有三个人正在交谈，又有三个麦克风放在房间的三个不同角落，它们实时地记录下了三个人的声音信号，“鸡尾酒会”问题就是如何仅用这三个麦克风纪录的声音信号估计出这三个人各自的声音信号。我们可以用公式表示这个问题，设 $x_1(t)$, $x_2(t)$, $x_3(t)$ 分别是这三个麦克风纪录的声音信号， $s_1(t)$, $s_2(t)$, $s_3(t)$ 是三个谈话者的声音信号， t 是时间变量。我们可以将每个麦克风记录下的声音信号都看作是三个人的声音信号 $s_1(t)$, $s_2(t)$, $s_3(t)$ 的叠加，我们可以将这个问题表示为：

$$\begin{aligned} x_1(t) &= a_{11}s_1(t) + a_{12}s_2(t) + a_{13}s_3(t) \\ x_2(t) &= a_{21}s_1(t) + a_{22}s_2(t) + a_{23}s_3(t) \\ x_3(t) &= a_{31}s_1(t) + a_{32}s_2(t) + a_{33}s_3(t) \end{aligned} \quad (4-26)$$

其中， a_{ij} 是未知的权值。问题变为已知 $x_1(t)$, $x_2(t)$, $x_3(t)$ ，如何估计出 $s_1(t)$, $s_2(t)$, $s_3(t)$ 。如果我们知道权值 a_{ij} 的值，这个问题就是一个简单的线性方程组求解问题。但遗憾的是，我们并不知道权值 a_{ij} 的值。为此，我们不得不先做一些假设，进而能够继续我们的工作。我们假设 $s_1(t)$, $s_2(t)$, $s_3(t)$ 是统计独立的，尽管这个假设看着有些不合理（因为我个人认为人们的声音多多少少还是存在一些相关性的，我们可以对它进行处理，来保证它们近似独立，但直接假设人们的声音是相互独立的有些不合理），对问题的求解却是很有帮助的。然后我们用ICA方法分离出这三个对立的的声音信号，这三个信号分别对应于这三个人。那么ICA究竟是如何分离出它们的呢？我们必须先对ICA方法进行了解。在这里，我们首先给出ICA的定义。

ICA的定义：假设 $Y^T = (Y_1, Y_2, \dots, Y_i, \dots, Y_M)$ 是已知的 M 维随机向量，

而 $S^T = (S_1, S_2, \dots, S_i, \dots, S_M)$ 是未知 N 维随机向量, $A = (a_{ij})$ 是未知的 $M \times N$ 实数矩阵。ICA 的基本模型定义为:

$$Y = AS \quad (4-27)$$

这里, A 被称为混合矩阵 (mixture matrix)。 S_i 被称为源信号 (source) 或者独立成分 (independent component), Y_i 是观察信号 (observed signal)。为使公式 (4-27) 可解, 我们还需要设置一些限定条件:

首先, 假设独立成分是统计独立的, 这是求解 ICA 问题的前提;

其次, 要求最多只有一个源信号是高斯分布的, 因为高斯分布的高阶统计量为 0, 所以当有两个以上 (包括两个) 的信号源都服从高斯分布时, 该方法将失效。

最后, 要求 $M \geq N$ 。但为了便于求解, 我们通常假设未知的混合矩阵是方阵, 即 $M = N$ 。

4.3.2 一般算法

一般的 ICA 求解方法是寻找一个分离矩阵 W , 使得:

$$U = WY = WAS \quad (4-28)$$

这里, U 是对源信号 S 的估计。当 W 是 A^{-1} 的置换或尺度变换时, 源信号 S 可以被准确的估计。

ICA 方法一般是采用数值方法来求取数值解的。为了使算法更健壮、收敛速度更快, 大多数 ICA 方法都选择对原始数据进行预处理操作。预处理操作主要包括中心化 (centering)、白化 (whitening) 等。

1. 中心化方法

中心化方法非常简单, 该方法先是求得观察信号 Y 的期望 $E(Y)$, 然后用每个观察信号 Y_i 减去 $E(Y)$ 即可, 通过此方法得到的新的信号之和为零, 即 $\sum_{i=1}^M \tilde{Y}_i = \sum_{i=1}^M (Y_i - E(Y)) = 0$ 。

2. 白化方法

比起中心化方法, 白化方法要麻烦一些, 但也更有效。白化方法的目的是使得处理后的观察变量的各个分量之间是不相关的, 即: $E(\tilde{Y}\tilde{Y}^T) = I$ 。我们可以通过对观察信号的协方差矩阵的进行特征值分解得到白化变换 (这一步其实是以 PCA 方法为基础的), 即: $E(Y Y^T) = V \Lambda V^T$, 这里, V 是特征向量矩阵, $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_M)$ 是特征值矩阵。白化变换可以按如下方式进行:

$$\tilde{Y} = V \Lambda^{-\frac{1}{2}} V^T Y \quad (4-29)$$

显然，

$$\begin{aligned}
 E(\tilde{Y}(\tilde{Y})^T) &= E\left(V\Lambda^{-\frac{1}{2}}V^T YY^TV(\Lambda^{-\frac{1}{2}})^T V^T\right) \\
 &= E\left(V\Lambda^{-\frac{1}{2}}V^T V\Lambda V^TV(\Lambda^{-\frac{1}{2}})^T V^T\right) \\
 &= E\left(V\Lambda^{-\frac{1}{2}}\Lambda(\Lambda^{-\frac{1}{2}})^T V^T\right) \\
 &= E\left(V\Lambda^{-\frac{1}{2}}\Lambda\Lambda^{-\frac{1}{2}}V^T\right) \\
 &= E(VV^T) \\
 &= I
 \end{aligned} \tag{4-30}$$

结合公式（4-27），得到：

$$\tilde{Y} = V\Lambda^{-\frac{1}{2}}V^TAS = \tilde{A}S \tag{4-31}$$

又：

$$E(\tilde{Y}(\tilde{Y})^T) = E(\tilde{A}S(S)^T(\tilde{A})^T) = E(\tilde{A}(\tilde{A})^T) = I \tag{4-32}$$

根据公式（4-32）我们可以得知 $\tilde{A}$ 是正交矩阵，这样，ICA问题就从寻找 $M \times N$ （ $M=N$ ）个参数的矩阵 A 变成求一个正交矩阵的问题。我们可以根据ICA方法计算出分离矩阵 W ，进而估计出 S 的值。

本实验中，我们采用FastICA方法来求取 $\tilde{A}$ 。下面，我们对FastICA方法进行简要介绍。

4.3.3 FastICA 方法

FastICA方法，也就是定点算法，它是一种基于不动点迭代的盲分离算法，其核心思想就是建立一个优化问题，并使该问题的解满足相互独立^[20]。该方法的关键就是构造优化问题的目标函数。为了找到这些目标函数，我们先从中心极限定理入手。假设 N 维随机变量 $S_1, S_2, \dots, S_i, \dots, S_N$ 是独立同分布的，它们的方差有限且不等于0。根据中心极限定理可知：当 $N \rightarrow \infty$ 时，它们的和 $\sum_{i=1}^N S_i$ 经过变换后近似服从标准高斯分布，也就是说原本“非高斯的”随机变量线性混和而成的变量会更接近高斯。这是一个很好的特性，它使我们知道了混合随机变量的分布的情况，接着，我们来求解各个相互独立的随机变量，显然，它们的分布

一定是越“非高斯”得越好。这样，ICA问题就可以转化为求解能得到最“非高斯”随机变量的线性组合问题。这里，为了更好的衡量“非高斯”性，我们用到在第三章中提到的一个概念——负熵，它是衡量非高斯性的一种重要方法，

FastICA方法是以负熵最大的原则来分离盲信号的。

在这里，我们先对FastICA的两种方法——紧缩逼近法和均衡逼近法进行介绍。

紧缩逼近法又称一元定点算法，其思想是找到一个方向，即 $\mathbf{W}$ 的一个权值矢量 $\mathbf{W}_i$ ，使得投影 $\mathbf{U}_i = (\mathbf{W}_i)^T \mathbf{Y}$ 具有最大的非高斯性，它每次只从观测信号 $\mathbf{Y}$ 中分离出一个独立分量。该方法以负熵来衡量 $\mathbf{U}_i$ 的非高斯性。负熵可以用信号的峭度来近似，这个内容我们已经在第三章中提到过，但是，由于峭度对数据的依赖性较强，为此，A.Hyvarinen提出了一种更稳健、更快速的方法来近似负熵^[20]：

$$J(\mathbf{U}_i) \propto E\left((G(\mathbf{U}_i)) - E(G(\mathbf{v}))\right)^2 \quad (4-33)$$

其中， G 是一个任意非二次型函数， $\mathbf{U}_i$ 是具有零均值和单位方差的随机变量， $\mathbf{v}$ 是具有零均值和单位方差的高斯随机变量。将 $\mathbf{U}_i = (\mathbf{W}_i)^T \mathbf{Y}$ 代入公式（4-33）可以得到^[20]：

$$J_G(\mathbf{W}_i) \propto \left(E\left(G((\mathbf{W}_i)^T \mathbf{Y})\right) - E(G(\mathbf{v}))\right)^2 \quad (4-34)$$

由此可见，使负熵 $J_G(\mathbf{W}_i)$ 达到最大，就是在 $\|\mathbf{W}_i\|^2 = 1$ 的约束条件下，使得 $E\left(G((\mathbf{W}_i)^T \mathbf{Y})\right)$ 达到最大，用拉格朗日乘子算法可以得到定点算法的目标函数为^{[19]、[20]}：

$$L(\mathbf{W}_i) = E\left(G((\mathbf{W}_i)^T \mathbf{Y})\right) - \beta \|\mathbf{W}_i\|^2 \quad (4-35)$$

对公式（4-35）求权值 $\mathbf{W}_i$ 的一次梯度得：

$$L'(\mathbf{W}_i) = \frac{\partial L(\mathbf{W}_i)}{\partial \mathbf{W}_i} = E\left(\mathbf{Y} g((\mathbf{W}_i)^T \mathbf{Y})\right) - \beta \mathbf{W}_i \quad (4-36)$$

其中， g 为 G 的导数，在本实验中，我们取 $g(Y) = Y^3$ ，对公式（4-36）再次求取权值 $\mathbf{W}_i$ 的梯度得：

$$L''(\mathbf{W}_i) = \frac{\partial L'(\mathbf{W}_i)}{\partial \mathbf{W}_i} = E(\mathbf{Y} \mathbf{Y}^T g'((\mathbf{W}_i)^T \mathbf{Y})) - \beta \mathbf{I} \quad (4-37)$$

其中 g' 为 g 的导数，因为 $E(\mathbf{Y} \mathbf{Y}^T g'((\mathbf{W}_i)^T \mathbf{Y})) \approx E(\mathbf{Y} \mathbf{Y}^T) E(g'((\mathbf{W}_i)^T \mathbf{Y}))$
 $= E(g'((\mathbf{W}_i)^T \mathbf{Y})) \mathbf{I}$ ，由牛顿迭代法求出方程 $L'(\mathbf{W}_i) = 0$ 的近似根为：

$$\mathbf{W}_i(k+1) = \mathbf{W}_i(k) - \frac{E(\mathbf{Y} g(\mathbf{W}_i^T(k) \mathbf{Y})) - \beta \mathbf{W}_i(k)}{E(g'(\mathbf{W}_i^T(k) \mathbf{Y})) - \beta} \quad (4-38)$$

由于 $L'(\mathbf{W}_i) = 0$ ，而且 $\|\mathbf{W}_i\|^2 = 1$ ，有 $\beta = E(\mathbf{W}_i^T \mathbf{Y} g(\mathbf{W}_i^T \mathbf{Y}))$ ，代入公式（4-38）

得：

$$W_i(k+1) = W_i(k) - \frac{E(Yg(W_i^T(k)Y)) - E(W_i^T(k)Y g(W_i^T(k)Y))W_i(k)}{E(g'(W_i^T(k)Y)) - E(W_i^T(k)Y g(W_i^T(k)Y))} \quad (4-39)$$

将公式（4-39）两边同乘 $E(g'(W_i^T(k)Y)) - E(W_i^T(k)Y g(W_i^T(k)Y))$ 可得：

$$\begin{aligned} & \left(E(g'(W_i^T(k)Y)) - E(W_i^T(k)Y g(W_i^T(k)Y)) \right) W_i(k+1) \\ &= \left(E(g'(W_i^T(k)Y)) - E(W_i^T(k)Y g(W_i^T(k)Y)) \right) W_i(k) - E(Yg(W_i^T(k)Y)) \\ & \quad + E(W_i^T(k)Y g(W_i^T(k)Y)) W_i(k) \\ &= E(g'(W_i^T(k)Y)) W_i(k) - E(Yg(W_i^T(k)Y)) \end{aligned}$$

得：

$$W_i(k+1) = E(Yg(W_i^T(k)Y)) - E(g'(W_i^T(k)Y)) W_i(k) \quad (4-40)$$

为一元定点算法的迭代公式。其中， k 为迭代次数，在每次迭代后需要对 $W_i(k+1)$ 进行归一化处理，即：

$$W_i(k+1) = \frac{W_i(k+1)}{\|W_i(k+1)\|} \quad (4-41)$$

均衡逼近法，又称多元定点算法，其思想是运行 M 次一元定点算法，得到分离矩阵 $W^T = (W_1, W_2, \dots, W_M)$ ，为了阻止不同的最大熵收敛到同一个向量，我们必须将 $W_1, W_2, \dots, W_M$ 正交化，如果我们已经估计出 p 个独立分量对应的权值，在估计第 $p+1$ 个独立分量对应的权值时，采用下面的方法使权值之间正交化和归一化：

$$W_{p+1}(k+1) = W_{p+1}(k) - \sum_{j=1}^p W_{p+1}^T(k) C W_j W_j \quad (4-42)$$

$$W_{p+1}(k+1) = \frac{W_{p+1}(k+1)}{\sqrt{W_{p+1}^T(k+1) C W_{p+1}(k+1)}} \quad (4-43)$$

4.4 使用 ICA 方法对人脸图像进行特征提取

下面，我们来介绍这种方法的具体实现过程。

该方法的部分步骤同第三章介绍的 PCA 方法的步骤相同，我们也将人脸图像 (R 行, C 列) 按行堆叠成 $N=R \times C$ 维的列向量，同时，为了方便对该问题进行处理，我们将 M 幅人脸图像 (同在第三章中提到的一样，也是相同人的不同表情图像)

构成一个 M 行， N 列的人脸矩阵 $Y^T = (Y_1, Y_2, \dots, Y_i, \dots, Y_M)$ 。根据本章前面介绍的知识，我们假设 A 是一个 M 阶的混合矩阵，这 M 幅人脸图像是由 M 幅独立的基图像 $S^T = (S_1, S_2, \dots, S_i, \dots, S_M)$ 线性混合而成，即： $Y=AS$ 。这里， Y 的每一行代表一幅人脸图像， S 是一个 $M \times N$ 矩阵，它的每一行代表一幅基图像。用 FastICA 方法求出分离矩阵，使得： $U = WY = WAS$ ，其中 $U = (U_1, U_2, \dots, U_i, \dots, U_M)$ 是对 S 的估计。

4.5 实验

4.5.1 实验说明

本部分我采用 Matlab 语言作为编程语言，使用了 Matlab 7.5 作为编辑和测试程序的平台，另外，本部分还用到了 FastICA 2.5 软件包中提供的一些算法。

4.5.2 实验流程图




图 4-1 实验流程图

图 4-1 表示出了本实验的全部工作。

4.5.3 实验数据

本章中所使用的数据和第三章中使用的数据完全相同，这里就不再重复了。我们仍以第三章中提到的那几幅图为例，介绍我们的实验结果。

首先，我们给出用ICA方法提取出的“特征脸”图像，如图4-2所示：



图 4-2 使用ICA方法计算出的特征脸

将提取出的人脸图像分别投影到由二十个“特征脸”向量张成的特征脸子空间里，可以得到如下的特征向量。

$$\mathbf{R}_1^T = (5.2562, 3.8711, 8.3538, -0.3277, 1.9202, 0.2899, 1.1468, 6.8299, 5.7610, 11.6480, 5.8440, -5.0147, 0.0124, 4.1824, -5.4841, 2.4314, -1.3494, 6.4759, -41.8086, 11.6925) ;$$

$$\mathbf{R}_2^T = (-3.3850, -2.0611, -4.2426, -4.7785, -4.7408, -2.8209, -6.5779, 7.9616, -9.1381, 10.4941, 3.3192, 2.5921, -8.9905, 1.8946, 1.3500, 4.5668, -6.5318, 7.7285, -41.1895, 7.2229) ;$$

$$\mathbf{R}_3^T = (-1.3397, -4.3030, -1.1111, -0.4130, -8.4416, -1.9454, 3.5375, 8.1639, 4.2162, 1.2062, 3.0353, -3.8905, 2.7487, 6.3692, -4.6528, 4.8374, 3.7139, -5.2251, -43.7048, 10.7652) ;$$

$$\mathbf{R}_4^T = (-2.9598, -5.0370, -3.5753, -2.0643, -8.0593, 0.9185, -4.5983, 0.6658, -7.3692, 1.9156, 3.3409, 3.7974, 9.2073, 1.0478, -6.1102, 0.1971, -3.2961, 11.2787, -42.8896, 6.7104) ;$$

$$\mathbf{R}_5^T = (3.4789, -3.4282, 7.2227, -7.7909, -4.3042, -4.9291, -1.6922, 5.6193, 7.3198, 0.6602, 6.1789, -3.9570, 6.8963, 1.6613, -0.6126, 2.9701,$$

-1.0514, 7.0170, -43.0751, 10.6330) ;

$R_6^T = (-3.5308, -0.8098, 7.3441, -2.6801, -0.1055, -4.1736, -4.9880, 6.1450, -6.6446, 9.3754, 6.7261, 2.2647, 4.4228, 4.7549, -0.4602, -4.2033, -1.2300, 3.1026, 40.8653, 14.8872)$;

$R_7^T = (-3.7275, 3.8841, 8.0899, -2.5288, 0.1067, -0.5549, -6.3611, 7.6525, 2.2172, 7.7347, 5.9752, -4.5891, 5.9351, 3.6106, -0.0912, -2.9705, -1.2748, 2.3323, 42.3609, 15.1101)$;

$R_8^T = (-2.6222, 3.4975, 5.9316, -4.5899, 0.3234, -3.2324, -0.5843, 6.5435, 2.9473, 8.9165, 7.6207, -6.8801, 4.6135, 3.9476, -1.3105, -1.0190, -2.7066, 0.3949, 43.1888, 13.7872)$;

$R_9^T = (-2.0308, -4.3061, 4.6288, -3.4962, 0.7374, -3.5551, -1.7601, 6.5674, 3.9191, 9.0285, 5.9820, -6.2773, 7.2955, 4.0715, -0.8597, -0.5887, -2.0523, -0.2535, 42.3547, 14.4681)$;

$R_{10}^T = (2.6610, -1.6102, 4.5353, 1.7631, 2.0166, -4.9769, -4.5166, 3.7808, 4.3498, 12.3812, 7.3156, -5.9408, -5.7662, 2.2140, -3.2120, -4.1232, -5.9347, 3.3921, 41.3670, 14.8006)$;

$R_{11}^T = (-0.2174, -3.6598, -4.7665, 1.9270, 2.8602, -1.9898, -6.5870, 4.6627, -1.7991, -5.0009, 5.1736, 2.2328, 10.3197, -0.0566, -2.4095, 6.0985, -1.5649, -5.4143, 45.2453, 1.1242)$;

$R_{12}^T = (3.5371, 1.8925, -4.8502, 1.0787, -6.9382, -6.7893, -5.1599, 7.2680, 3.4159, 2.8238, 7.3204, -2.3633, 10.6122, 1.7440, 0.4561, 5.4271, 0.4400, -5.4470, 43.4849, 10.6783)$;

$R_{13}^T = (1.0522, -2.9981, -0.9265, -7.9448, -1.2295, -4.6871, -5.6397, 6.1127, 3.9470, 11.8009, 4.5310, -3.8229, 6.3270, 2.9981, -2.4488, -0.7702, -3.6205, 0.0490, 42.4021, 13.0670)$;

$R_{14}^T = (1.6161, -3.2792, -1.9524, -7.3820, -1.9959, -4.1851, -2.8954, 5.9140, -0.3148, 11.8225, 5.9764, -7.3939, 4.1713, 2.2764, -2.1672, -0.6654, -3.6346, 0.7802, 42.6429, 14.7158)$;

$R_{15}^T = (5.4232, -0.7641, -0.1509, 0.4870, -8.5405, -4.8736, -3.5633, 7.1958, 2.4389, 2.2688, 7.1947, -4.8378, 7.9057, 3.6807, 0.0337, 3.8890, -0.7851, -4.3052, 44.8045, 7.0074)$;

$R_{16}^T = (6.1822, 1.2985, 0.1115, -2.6116, 3.5561, -2.9206, -4.2983, 5.6691, 1.1236, 9.2597, 6.9966, -5.7146, -8.0620, 7.8141, -1.0506, -4.4167, -4.0763, 3.0481, 40.9200, 16.6229)$;

$R_{17}^T = (3.9371, 2.0436, 2.3203, 1.6030, 2.9086, 1.5657, 2.0936,$

7.0499, 9.3449, 11.6530, 7.5480, -2.8906, -6.9480, 0.5560, 1.8606, -9.8166, -0.6627, 9.4841, 40.7080, 14.5468) ;

$R_{18}^T = (3.3205, 2.4966, -6.4323, 1.8780, -5.1572, 1.6912, -4.7781, -2.5422, 3.0395, 7.5681, 7.7872, -0.0332, 1.8941, 6.7887, 3.3709, 6.5969, 1.4511, -7.3030, 43.4263, 9.6600)$;

$R_{19}^T = (7.0438, 3.8406, 7.2193, 2.4874, 2.8134, -5.0188, 5.4378, 3.4298, 7.7104, 11.1223, -7.1109, -3.5421, 1.9764, -1.6918, 0.9205, -2.3511, -1.4369, 3.2158, 42.0772, 11.9697)$;

$R_{20}^T = (7.2683, 1.5002, -3.5374, -4.6120, -4.6411, 0.3856, -4.0095, 7.2543, -5.7310, 9.5661, 6.5357, -5.1091, -2.5839, 1.9646, 0.6914, 6.0044, -1.4303, -6.3669, 42.1031, 12.8895)$;

同上一章介绍的一样，我们可以使用这些数据来为一个人训练分类器。这里也不再深入讨论。

4.6 小结

ICA方法源于盲信号分离(BSS)问题，是PCA从二阶统计方面到高阶统计方面的扩展，本章中，我们介绍了ICA方法的一般算法，也结合牛顿迭代方法对FastICA方法作了详细的说明。ICA方法的目标是将原图像表示成为一组相互独立的基向量的线性组合，这种方法可以很大程度的消除基向量的高阶冗余信息，有利于后续工作的简化。

第五章 PCA 与 ICA 特征提取结果对比与分析

5.1 引言

PCA方法的目的是去除输入随机向量间的相关性,以获得原始数据中隐含的内在特征。但由于PCA只涉及到输入数据概率分布函数的二阶统计特征,即仅利用信号的协方差矩阵参与运算,并未考虑其高阶统计特性,所以得到的主分量满足不相关(非线性相关)却不满足相互独立。

在实际应用中,特别是从信息保留的精度和丰富量角度考虑,对于服从高斯分布的数据,高阶统计特性并非不重要;但对于非高斯数据,统计独立与不相关不再等价,于是PCA显示出了固有的局限性,在提取景物图像,语音、脑电信号等非高斯信号的特征时效果不理想,由此,人们把注意力转向了ICA方法。

ICA方法实质上是PCA的一般化,它们同属多维数据的线性描述方法,ICA的思想是寻求一种线性变换,将一组随机变量表示成一组统计意义上互相独立变量的线性组合。它不仅考虑了信号的两阶统计特性,还考虑了高阶统计特性。

ICA方法更多的用于非高斯数据,ICA可以利用它们的高阶统计特性,从多通道观测数据中分离出独立元,而不仅仅是一、二阶意义上的统计独立,故此比PCA显示出优越性。

5.2 根据二维数据的分布对两种方法的比较

这里,我们根据数据在二维空间中的分布来对PCA和ICA方法进行比较^[14],参见图5-1:




图 5-1 数据在二维空间的分布及PCA和ICA基向量在二维空间的投影

在图5-1中,左图主要显示了PCA求得的基向量在二维空间里的投影,右图显示的是ICA求得的基向量在二维空间里的投影。在两幅图中,我们可以发现,右图中两个投影轴的方向更符合数据的分布情况,这些轴上的投影就有很少的交叠产生;相反,左侧的投影轴虽然是正交的,但不符合数据的分布,以此这些轴

上的投影产生了很多的交叠。究其原因，就是由于PCA方法的求取的基向量往往还存在着一定的相关性，它们还不能很好的表现元数据的本质。经过ICA方法得到的基向量彼此之间相互独立，之间没有任何关联，所以能更好的体现数据的本质。

5.3 结合人脸图像对两种方法的比较

结合本实验，我们的实验对象是“人脸”图像，其本质上是一种非高斯数据，所以，PCA 方法得到的各个特征脸向量虽然满足线性独立，但也有很多人脸之间的统计信息并未得到利用，ICA 恰恰能够解决这一问题，该方法不仅能提取并利用多像素间隐藏的信息，同时还具备良好的局部特征表征能力，所以，从理论上说，ICA 方法比起 PCA 方法更有效。

我们也结合实验结果来进行一些说明。在图 5-2 中和图 5-3 中我们列出了部分特征脸向量。



图 5-2 PCA方法提取出的特征脸向量



图 5-3 ICA方法提取出的特征脸向量

图 5-2 中显示的是使用 PCA 方法提取出的特征脸向量，图 5-3 中显示的是使用 ICA 方法提取出的特征脸向量，我们可以看出好像后者更加的“清晰”，原因也是由于 PCA 方法提取出的特征向量之间存在一定的相关性，因此，如果直接使用由 PCA 方法提取的特征向量进行人脸识别，只会增加我们的工作难度，而识别结果却不见得好。

作为 PCA 方法的一种扩展，ICA 方法以 PCA 方法为基础，即在“不相关”的基础上进一步构造“独立”，使得计算出的特征向量彼此完全不相关，能更好的体现数据的本质。

5.4 小结

本章中我们对PCA方法和ICA方法进行了一下比较，通过比较，我们发现ICA

方法要优于PCA方法，它是PCA方法的扩展，是对PCA方法的一种改进。

第六章 总结与展望

6.1 全文总结

第一章我们介绍了人脸识别的背景、发展过程、国内外人脸识别理论研究机构以及本课题的研究内容。

第二章的主题介绍人脸特征提取以及特征选择的相关理论，本章粗略的介绍了特征提取的意义以及几种特征提取方法。

第三章的主题是利用 PCA 进行人脸特征提取，本章中我们对 PCA 方法的原理以及用 PCA 方法提取人脸特征的步骤进行了详细的介绍。

第四章的主题是利用 ICA 进行人脸特征提取，本章中我们对 ICA 方法的原理以及用 ICA 方法提取人脸特征的步骤进行了详细的介绍。

第五章的主题是 PCA 与 ICA 特征提取结果对比与分析，本章中，我们就两种方法的思路进行比较，给出了我们的结论。

6.2 研究展望

特征提取技术作为模式识别领域中的关键技术，近年来取得了很大的发展。线性降维技术发展的已经比较成熟，随着 SVM 理论的提出以及不断的发展，基于核技术的非线性降维技术取得了很大的成功，已经也越来越引起人们的关注和兴趣。

参考文献

- [1]袁殿国. 基于 PCA 的人脸识别研究[D]. 大连: 大连理工大学, 2007.
- [2]刘小华. 人脸识别技术及其应用研究[D]. 吉林: 吉林大学, 2005.
- [3]刘小军. 人脸识别技术研究[D]. 北京: 中国科学院, 2001.
- [4]黄福珍, 苏剑波. 人脸检测[Z]. 上海: 上海交通大学出版社, 2006.
- [5]刘永俊. 小样本问题下人脸图像的鉴别特征抽取方法研究[D]. 扬州: 扬州大学, 2007.
- [6]Sir Francis Galton. Personal Identification and Subscription-1[J]. Nature, 1906, 1888 (21): 173-177
- [7]靳艳峰. 基于相位一致性和模 PCA 的人脸识别算法研究[D]. 兰州: 兰州理工大学, 2007.
- [8]Bertillon. Identification of human beings by the system of Alphonse[J], Journal of the Franklin Institute, 1909, Vol. 167, Issue 5: 321-358
- [9]王先基. 基于统计学习的自动人脸识别算法研究[D]. 北京: 中国科学技术大学, 2005.
- [10]孙涛. 特征提取技术研究及其在人脸识别中的应用[D]. 长沙: 中南大学, 2007.
- [11]张春雨. 基于子空间的人脸识别算法研究[D]. 吉林: 吉林大学, 2006.
- [12]李欣. 人脸识别技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2007.
- [13]栗塔山. VC++和 BC++数值分析类库[M]. 北京: 清华大学出版社, 2005. 18—19.
- [14]王峻峰. 基于主分量、独立分量分析的盲信号处理及应用研究[D]. 武汉: 武汉大学, 2003.
- [15]陈颖. 基于特征的人脸检测系统的设计与实现[D]. 天津: 天津大学, 2007.
- [16]周岩. 基于独立分量分析(ICA)的人脸识别方法的研究[D]. 长春: 长春理工大学, 2007.
- [17]王明祥. 独立分量分析方法及在图像处理中的应用研究[D]. 上海: 上海大学, 2005.
- [18]戴娇月. 基于高阶统计量的含噪模糊图像辨识和复原[D]. 长春: 长春工业大学, 2006.
- [19]王明祥. 独立分量分析方法及在图像处理中的应用研究[D]. 上海: 上海大学, 2005.
- [20]何付志. 独立分量分析在脑电信号分析中的应用[D]. 山东: 山东大学, 2005.
- [21]Intel. Open Source Computer Vision Library (OpenCV) [EB/OL]. [Online]: <http://www.opencv.org.cn>, 2007-6-1.

外文资料

Author: Andy Adler and Michael E. Schuckers

Title: Comparing Human and Automatic Face Recognition Performance

In: IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART
B: CYBERNETICS, VOL. 37, NO. 5, OCTOBER 2007

中文译文

关于人工人脸识别和自动人脸识别的性能比较

作者：Andy Adler 和 Michael E.Schuckers

摘要：

在过去 10 年中，人脸识别技术在性能方面已经有了非常大的提高，而且，相关的系统现在已经被广泛的应用于安全和商业等领域。由于人类有着非常好的人脸识别能力，所以，人们常常想要对人工人脸识别（HFR）系统和自动人脸识别（AFR）系统在生物特征识别方面的性能进行比较。本文将从以下方面阐述这个问题：

- 一方面指导志愿者（HFR 系统）参加验证测试实验，另一方面是对一些商业的自动人脸识别（AFR）系统进行验证测试；
- 尝试一种新的统计学方法来对两种生物特征识别系统的测试结果进行比较。

HFR 的测试内容是向志愿者提供一系列人脸图像组并要求志愿者判断每组中的两幅图像中所显示的人具有哪种关系。志愿者可以在“是同一个人”、“可能是同一个人”、“不确定是不是同一个人”、“可能不是同一个人”和“不是同一个人”这 5 个选项中选择自己认为正确的结果，测试系统会将其转换为相应的生物特征匹配值；相同的图像组也会被提供给 AFR 系统来进行验证测试，并计算相应的生物特征匹配值。我们会尝试两种新的统计学方法来处理上述的生物特征匹配值。第一种方法是归一化匹配值分布，我们令归一化匹配值 $\hat{t}$ 计算为角度值的函数，其中的角度值是由某点在极坐标下的[误匹配率, 漏匹配率]来表示的。根据这个归一化方法，我们可以尝试另一种平均检测错误权衡（DET）曲线的方法，而且我们会说明该方法等价于利用沿中心点的每个夹角直接平均 DET 数据的方法。我们将用这个方法对 1999, 2001, 2003, 2005, 2006 年中最好的自动人脸识别算法的测试结果和每个参与者的测试结果进行比较。实验表明在这几年里，自动人脸识别算法在性能上有了很大的进步。在与 2006 年中最好的 AFR 系统的性能进行比较时，我们发现 HFR 系统有 29.2% 的部分的运行结果优于 AFR 系统，但是，37.5% 的部分的运行效果已经不如 AFR 系统。

关键字：

生物特征识别技术、检测错误权衡、人脸识别、性能分析

一、介绍：

生物特征识别技术是根据个体行为或其生物特性进行自动（也就是基于计算机的）身份确认工作的基础^[32]。得益于近年来这种技术突飞猛进的发展，一些

用于识别生物特性（如人脸、指纹和虹膜等）的系统可以被实现并应用在许多国家安全机关、警察机关和商业领域中。在上述的诸多技术中，只有自动人脸识别

本文原稿在2006年5月1日完成，于2006年12月8日经过修订。加拿大自然科学与工程研究院对A. Adler的工作提供了支持，国家科学基金会（NFS）在被授权的CNS-0325640工程中对M. E. Schuckers的工作提供了支持，该工程由NFS和美国国家安全部门共同投资开展。本文被K. W. Bowyer编辑推荐出版。

A. Adler在加拿大渥太华的 K1S 5B6号的Carleton大学获得系统和计算机工程学位。
(e-mail: adler@site.uOttawa.ca)。

M. E. Schuckers在美国纽约的NY 13617号的St. Lawrence大学取得数学，计算机科学及统计学学位，并在Morgantown 的WV 26506-6286号的West Virginia大学的验证技术研究中心学习过。(e-mail: schuckers@stlawu.edu)。

本文中的彩色图片可在<http://ieeexplore.ieee.org> 网站获得。

刊物数字标识：10.1109/TSMCB.2007.907036

（AFR）技术与人的能力的可比性最好。AFR系统不同于指纹和虹膜的识别系统，因为除了那些受过专业训练的人以外，几乎再没有人可以通过识别指纹或虹膜图像来进行身份识别。然而，几乎所有的人在日常生活中都会使用到人脸识别技术来进行身份识别。另外，早在19世纪40年代，就有一些警察机构以对照片进行的人脸识别的结果进行身份确认工作^[10]。

AFR技术就是指将已注册的图像和一个新得到的图像进行比较，然后计算出用于进一步估计它们的匹配程度的匹配值（相似值）。计算出的匹配值越高，两副图像中显示的人越可能是同一个人。在每一个生物特征识别系统中，都有一个与具体应用相关的阈值被选取。如果计算所得的匹配值高于该阈值，系统将断定两副图像中所显示的人是同一个人；相反，系统断定两副图像中所显示的人不是同一个人。然而，这种评估方法也会导致两种可能的错误：误匹配——系统判断两副图像中显示的人是同一个人，但事实上是不同的人；漏匹配——系统判断两副图像中显示的人不是同一个人，但事实上是同一个人。生物特征验证系统的性能可以用错误率来衡量，其中包括误匹配率（FMR）和漏匹配率（FNMR）。一种典型的方法是计算出检测错误权衡（DET）曲线——在不同阈值条件下的FMR与FNMR的值构成的曲线。FMR和FNMR等术语指^[21]错误接受和错误拒绝（包括申请错误（如三次尝试后拒绝接受）和接受失败等）。

在过去的15年间，AFR技术取得了非常大的进步。其实，早在20世纪60年代，便有关于通过计算机进行人脸识别的可能性的研究，而20世纪90年代时 Turk 和 Pentland^[30]的科研成果更是极大的促进了这一领域的发展。从那时起，许多公司和学术团体开始开发关于AFR的应用软件。另外，U.S. NIST也组织了一系列的实验，例如 FERET^[25]、FRVT 2000^[2]、FRVT 2002^[27]以及FRVT 2006^[35]来对

AFR系统的性能进行测试。

人们精心的对AFR系统性能进行着测试，但却以完全不同的方法来研究人工人脸识别（HFR）系统。人们对HFR系统的研究的主要是为了了解人脑如何识别和处理图像，而对其性能方面的问题并不是很关心。Gong^[12] 和 Zhao^[33] 等人在回顾一些关于HFR认知机制的工作时表示了如上观点。

以前，很少有助于衡量HFR系统性能的标准，而现在这却成了一个很大的问题。许多政府和安全机构希望实现用于边境控制和护照发行的AFR系统，而且，他们也需要了解相对于他们已有的员工，这类系统在处理相同的工作时的表现如何。Burton 等人^[5] 曾对基于PCA的人脸识别算法^[30] 的AFR系统和HFR系统进行过直接的比较。在文献[4]中也提到，在生物特征识别方面，AFR系统对于10个主题（人）识别的正确率要优于人类。本文中所讨论的AFR系统实现时间比较早，其性能还比较差，无疑这也会对本实验造成一定影响。另外，数据库所提供的都是年代比较接近的图像，这对AFR系统来说是件好事，因为它们在处理年代差距较大的图像时会有非常大的困难^[27]。

人们对HFR性能方面的问题进行了大量的研究^{[4]、[6]、[19]}，总结出了许多不同的性能级别。除了一些已经出版的关于该领域的研究成果的文学作品外，一些政府机构也开展了对这一领域的研究。例如，Kemp 等人^[19] 曾对超级市场的出纳员通过信用卡上的照片识别购物者的能力进行过研究，他们发现这些出纳员的表现很差。Bruce等人^[4] 也对一个年轻的白人实习警员从数据库中识别人脸的能力进行过研究。还有一些对该课题有兴趣的学生也参与了这个实验，他们在实验中不会受到时间限制。总体来说，他们的答案的错误率很高（仅68%–79%的回答是正确的）。Liu等人^[6]研究人们分析低质量视频胶片 and 高质量照片的能力，结果显示有75% 的正确率。评估HFR系统性能的一个困难是很多外部因素对其实验结果影响很大，例如动机、疲劳度、是否经过训练以及识别速度等。例如，在文献[6]和文献[19]中提到的实验结果的差异可以用动机不同来解释。超级市场出纳员^[19]没有认真地进行人脸识别工作，而是在关心其它事情。

本文中，我们描述了一种用于衡量和比较HFR系统和AFR系统性能的方法。本文结构组织如下：

首先，我们会在第二部分说明此次实验的相关问题；

其次，我们会在第三部分尝试一种新的用于比较生物特征识别算法性能的统计学方法；

最后，我们在第四部分比较AFR系统和HFR系统的实验结果并评论他们各自的意义。

二、方法：人脸识别实验

为了能够直接比较HFR系统和AFR系统性能的优劣，我们将提出了一个新的测试方法。在这里，我们先明确以下术语的含义：实验中提到的“参与实验的系统”和“人脸识别器”既可以指AFR软件，也可以指人。为了更加准确，实验中提到的“性能”仅仅是指使用错误率来表示的匹配性能。我们在本文所提到的实验中不考虑匹配速度、系统吞吐量以及其他一些指标。所有的被测试的AFR系统只需要具备识别两副人脸图像的能力即可，尽管一些系统能够处理更多信息，例如处理多重图像、不同姿势的图像、视频数据或者是一些三维信息等。这样，我们就可以以每组两张的正面图像作为实验数据，来测试所有AFR系统。我们为参与测试的系统提供每组两张的“不是很像的”图像，并要求系统判断两幅图像中所显示的人是否是同一个人。我们的系统是模仿生物特征验证来计算匹配结果的，而不是为了模拟人类进行身份确认的过程^[5]。

A. 测试用数据库

实验中所用到的图像均取自于NIST的MID的每人多幅图像的数据库部分，该部分提供了关于131个不同主题的总共338幅正面图像。另外，这个数据库中的图像数据（正面及侧面图像）都是通过法律手段采集的。由于图像之间的质量差异很大，而且有些取自同一个人的不同时期的图像的时间间隔较大，因此，AFR



图1 该图是用于进行HFR性能测试的应用软件的屏幕截图，志愿者“登陆”系统以后，应用软件向参与者提供一系列的图片组（每组两张），志愿者在仔细比较两幅图像后，要判断两幅图像中显示的人是否是同一个人，并选择自己认为最正确的选项，此选择过程不受时间限制。

系统处理起来存在着很大的困难^{[26]、[31]}。MID中每幅图像都是分辨率较高的（至少是 600×600 像素）灰度照片，这些图像的质量有的非常好，也有一部分比较差。数据库中的图像大多是正面的，而且，几乎所有的主题都是关于男性的（338副图像中有327幅图像是关于男性的，或者131个主题中有126个主题是关于男性的）。数据库中提供的所有照片采集的时间都较早，平均“年龄”是32.2岁，最新的图像是17年前采集的，最早的图像是60年前采集的。有关每个人的图像的平均年龄差是 6.55年，最新的是现在采集的，最早的则是在37年前采集的。在图1中显示是同一个人在不同时期的两幅图像，该图显示了AFR系统通过分析时间间隔较大的图像进行身份确认存在个很大的困难。数据库所提供的每组正面图片都是随机产生的，产生这些图像的唯一约束条件是：所有随机产生的图片组中，两幅图片取自不同的人的组约占到总数2/3，两幅图像取自同一个人的组约占到总数的1/3。共有540组图像对被创建，（其中356组中的图片取自不同人，184组中的图片取自同一个人）。由于MID中每个人最多有5幅图片，而且其中任意两幅都是不同的（即在184组中每组的两幅图片不会相同）。我们在创建另外356组中的图片时，没有考虑到每组中两幅图片所显示的人的性别以及种族的差异。这与文献[9]中实验所采取的策略是不同的，文献[9]中所提到的实验对两幅图片所显示的人的性别以及种族的问题进行了处理。我们认为是这种处理对于AFR系统是有偏私的帮助，因为实验设计者进行了对图片的“预处理”对人来说没有什么困难，但对AFR系统来说却有很大的帮助。

B. HFR性能

为了能够估计出HFR系统性能的上限，我们设计了用于衡量对该项目感兴趣的参与者的实验结果的测试，另外，这些参与者在进行实验时不受时间的限制。

1) 实验设计：

参与者可以通过网络参与本实验，实验软件用Perl语言编写，以Apache服务器作为平台。参与者首先“登陆”测试软件系统，之后，系统会向参与者提供测试内容（如图1所示），界面由一对人脸图像组和一系列选择按钮组成，参与者不受时间限制。系统会随机的选取人脸图像组并将其提供给每个参与测试的志愿者（不会重复，每一个参与者所得到的所有图片的顺序也不相同），另外，没有关于所做选择是否正确反馈信息提供给参与者。参与者的每一个选择以及该选择所用的时间会被统计并记录到测试系统的数据库当中。

图1所示的是一个测试的实例，在每轮实验中，系统会提供给参与者一组图像，并要求参与者判断组中两幅图像中所显示的人具有下述的哪种联系，如“是同一个人”、“可能是同一个人”、“不确定是不是同一个人”、“可能不是同一个人”和“不是同一个人”；参与者的选择将被测试系统转换为匹配值，例如，“是同一个人”的值为5和“不是同一个人”的值为1，其他值分布在这两个

值之间。

2) 实验说明:

实验中系统会为参与者提供实验说明, 首先, 这个实验说明会向参与者阐述此次实验的目的——测试人工识别人脸和自动人脸识别系统的性能。其次, 实验说明会指导参与者登陆软件系统, 以及为参与者提供一个用例说明(如图1所示)。参与者会被指导尽量给出正确的反映, 并且完成尽可能多的测试, 还要尽量保持不疲劳, 以免影响实验结果。在这里不会考虑“误匹配”和“漏匹配”的问题, 也不会对“正确率”的目标进行更加深入地要求。特别的, 没有提示参与者是否出现了误匹配或漏匹配的信息。只有当系统提示参与者对人脸识别技术的认识有帮助, 参与者才会得到酬劳。

3) 主题:

AiT公司(现在的3M系统安全公司)的职员在公司会议上被邀请参加此项测试, 该测试是在参与者办公室的个人计算机上进行的, 没有人对此进行管理。参与者在他们各自办公室的微机上通过网页浏览器参与实验。该实验是在1999年7月进行的, 共有21人参加实验(其中16名为男性, 5名为女性), 他们的年龄在20到40岁之间, 而且都是非常出色的工作人员。每个参与者平均要参与123轮测试, 他们平均使用10.0秒处理一组图片, 所消耗时间的标准偏差是7.7秒。

C. AFR性能

从1999年起到手本文创作的这段时间里, 我们有机会测试由7个不同的出售者提供的15个商业AFR软件包, 测试数据是由第二部分A节中所提到的MID提供的, 如果可以的话, 每组图片都会提供给所有的AFR系统, 然后计算出匹配值。在所有参与此项测试的软件中, 一些是通过命令行方式编写的, 一些是利用一些软件包实现界面化的, 还有一些是利用了web和GUI自动化工具实现的。一些AFR软件需要用到人脸标本数据库来进行特征提取与分割算法的训练。对于这些软件包来说, 由MID提供的部分图像并不是用于本实验(性能比较)的, 而是用来支持手工选择标记位置(如眼睛、鼻子、嘴等)的。

基于这个方案, 所有的人脸识别器, 不论是人还是软件, 都能以同样的方式分析, 每个系统都会被提供一系列图片组之后计算出每组的匹配值。这些匹配值的取值范围或者是从1到5(对于人类来说), 或是一个实数(对于每一个软件包的匹配值的取值范围)。

三、方法: 统计学

本部分, 我们将尝试一种新的统计学方法, 用于分析上一部分得到的数据。实验中的一个主要问题是每一个参与测试的系统都有不同的取值范围, 而它们的匹配值都是根据各自取值范围来计算的。例如, 一个AFR系统的取值范围是从0

到10，其在EER上的决策阈值为7.0；另一个系统的取值范围是从0到1，阈值为0.85。除此以外，一些参与测试的人在不能确定两副图像中显示的人是否是同一个人（值为5）时，其中一部分人趋向于选择不确定（值为3），而另为一些人趋向于选择“可能不是同一个人”（值为2）。由于存在着这些不同，直接比较不同系统的匹配值从统计角度来说是不正确的。为了解决这个问题，我们将尝试一种计算归一化匹配值的方法，来对实验结果进行处理。

一个普遍用于描述一个生物特征分类系统性能的方法是绘制DET曲线，具体方法为将一系列的样本图像组（包括两两匹配和两两不匹配）提供给生物特征识别系统并计算出匹配值 t ，再用 t 来估计 $g(t)$ 和 $f(t)$ 的匹配值分布。之后，利用上面的结果，我们可以根据不同的阈值来绘制DET曲线（其x轴方向是FMR，y轴方向是FNMR），其中 $FMR(\tau) = \int_{\tau}^{\infty} f(x) dx$ ， $FNMR(\tau) = \int_{-\infty}^{\tau} g(y) dy$ 。通过对样本集的如上计算所得到的DET曲线可以表示出生物特征识别算法的性能。这些数据也可以用于绘制DET曲线的变种——ROC曲线（y轴方向为TMR（ $TMR = 1 - FMR$ ），x轴方向为FMR）。在FRVT^[22]和 FpVTE^[27]测试中就用到了 DET 或是 ROC曲线的评估技术来描述生物特征验证的结果。

本文中，我们主要动机为如何将用于表示人的测试结果的各个分离DET曲线进行平均化。

因为DET曲线本身是一个二维曲线，很难找出一种平均化方法使所有二维特性能被完全保持。为了解决这个问题，我们尝试一种基于重建归一化匹配值和分布的方法来对DET曲线进行平均化，在后面，我们还将讨论该方法与直接几何平均DET曲线的方法的等价性。

这里，我们集中精力于尝试一种新的处理复合DET曲线的方法，该方法在多种条件中提出了分类对 $(FMR(\tau), FNMR(\tau))$ ，而忽略了两两匹配样本和两两不匹配样本分布，另外，匹配值 t 也会在另外的空间中重新被计算。到现在为止，已经有四种用于平均化DET或ROC曲线的方法被提出，Bradley^[3]提出根据DET空间中阈值的排列顺序进行归一化的方法，但是当各个DET曲线中阈值的数目差异很大时，这种方法会很困难。Provost等人^[28]提出垂直（沿着FMR方向）平均化的方法，但该方法仅适用于理论情况下——当某种错误率相对于其它错误率更加重要的情况。当被归一化的数据有不同的错误率时，这种方法会产生一些非直观的结果，例如当FMR非零时， $FNMR=1.0$ 。Fawcett^[8]提出平均化阈值的方法，然而当各个系统的匹配值使用不同的取值范围时，该方法也将实效。还有，Karduan提出了对某个错误率进行log-odds变换的平均化方法。本文中，我们尝试一种基于Macskassy 和Provost 提出^[20]的径向扫描理论的平均化方法。这种方法将DET曲线从 $(FMR, FNMR)$ 空间转换到极坐标空间。

假设一个包含J个生物特征值集合被选用，每个生物特征识别算法估计得到

一个分布 j ，该算法还为两两匹配的样本提供了 N_j^g 个匹配值 $G_i^{(j)}$ ，其中 $1 \leq i \leq N_j^g$ 。与之类似，为两两不匹配的样本提供 N_j^f 个匹配值 $F_i^{(j)}$ ，其中 $1 \leq i \leq N_j^f$ 。对于这些匹配值，除了要求它们为实数以及可能会随着匹配作增长外，没有其它要求。每个系统都用它自己的匹配值 t_j 来表征，连续的两两匹配样本分布 $f^{(j)}(t_j)$ 和两两不匹配样本分布 $g^{(j)}(t_j)$ 计算方法如下：

$$g^{(j)}(t_j) = \frac{1}{N_j^g} \sum_{i=1}^{N_j^g} \delta(t_j - G_i^{(j)}) \quad (1)$$

$$f^{(j)}(t_j) = \frac{1}{N_j^f} \sum_{i=1}^{N_j^f} \delta(t_j - F_i^{(j)}) \quad (2)$$

其中， δ 表示单脉冲函数。我们提出连续的匹配值分布公式是为了进一步在归一化匹配值空间中的重建这些分布。通过上面的计算， $FMR_j(\tau)$ 和 $FNMR_j(\tau)$ 可以由如下方法得到

$$FMR_j(\tau) = \int_{\tau-}^{\infty} f^{(j)}(t)dt = 1 - \int_{-\infty}^{\tau+} f^{(j)}(t)dt \quad (3)$$

类似的有

$$FNMR_j(\tau) = \int_{-\infty}^{\tau-} g^{(j)}(t)dt \quad (4)$$




图2 用样本分布和用极坐标系计算FMR 和 FNMR，左边显示的是假设的两两匹配样本和两两不匹配样本的离散分布，DET曲线如右图所示。以 (c_x, c_y) 为中心，为每一个 $(FMR, FNMR)$ 点计算角 θ 和距离 r 。归一化匹配值 t 的计算将会用到 θ 。在本例中，分布是离散的，DET曲线在两点间使用直线连接的。

图2表示了该运算。这里，计算FMR或FNMR（但不是全部）随 τ 的变化的结果是很重要的，我们将令FMR随 τ 变化而变化。不失一般性，这里假设如果匹配值不小于阈值，处理结果就是正确的。

A. 极坐标系下的归一化匹配值

为了能够更加深入地分析多个DET曲线，计算出对于所有DET曲线都适用的归一化匹配值是很有必要的。在这一部分，我们将对一个基于极坐标表示（如图2）的方法进行描述。

我们拥有一系列FMR，FNMR坐标对 $(x_i^{(j)}, y_i^{(j)})$ ，其中 $i = 1, \dots, N_j$ ； $j = 1, \dots, J$ ， $N_j = N_j^g + N_j^f$ ，对于一系列J的DET曲线。由于DET曲线的单调性，可知 $x_1^{(j)} \leq x_2^{(j)} \leq \dots \leq x_{N_j}^{(j)}$ ，且 $y_1^{(j)} \leq y_2^{(j)} \leq \dots \leq y_{N_j}^{(j)}$ 。对于DET曲线上的任何点，我们以 (c_x, c_y) （我们后边将指出 $c_x = c_y = 1$ 的好处）为中心计算角度 θ 和距离 r 。计算方法如下：

$$\theta = \tan^{-1} \left(\frac{c_x - x}{c_y - y} \right) \quad (5)$$

$$r = \sqrt{(c_x - x)^2 + (c_y - y)^2} \quad (6)$$

我们在DET曲线上的最右下角处定义了一个角度，此时 $\tau = -\infty$ ， $FMR = 1$ ， $FNMR = 0$ 。随着 τ 的增大，DET曲线向左上方延伸。 θ 的最小值 $\theta_{\min} = \tan^{-1}((c_y - 1)/c_x)$ ，最大值 $\theta_{\max} = \tan^{-1}(c_y/(c_x - 1))$ 。因为我们想要将通过 θ 计算出的归一化匹配值的取值范围限制在0到1之间，我们以如下方法定义归一化匹配值 $\hat{t}$ ：

$$\hat{t} = \frac{\theta - \theta_{\min}}{\theta_{\max} - \theta_{\min}} \quad (7)$$

B. DET曲线的比较

到目前为止，我们还是无法通过直接比较用上面方法计算出的匹配值来评价两个不同的生物特征识别系统性能的优劣，因为这些匹配值不是通用的。归一化匹配值的一个应用是比较相应算法的错误性能，进而判断是否一个算法优于另一个算法。为了通过归一化匹配值 $\hat{t}$ 来比较两个算法性能的优劣，我们要为每一个算法计算 r 值。如果径向轴与DET曲线不相交，我们会在最近的两点间进行线性插值。然后我们可以通过 r 来进行如下计算：

$$FNMR(\hat{t}) = c_y - r \cos \theta$$

$$FMR(\hat{t}) = c_x - r \sin \theta$$

其中 $\theta = \theta_{\min} + (\theta_{\max} - \theta_{\min}) \hat{t}$ 。

我们可以根据在 $r_A > r_B$ 的条件下，匹配值 $\hat{t}$ 的比较情况来方便的评价算法A是否优于算法B。但相对于这个只比较单个的匹配值的方法，我们更常用到是通过比较在一个匹配值范围 $\hat{t}_{\min} \leq \hat{t} \leq \hat{t}_{\max}$ 内 r 值的情况的方法来评价两个算法




图3 显示了以图2中DET曲线为基础重建的两两匹配样本 $\hat{g}(\hat{t})$ 和 两两不匹配样本 $\hat{f}(\hat{t})$ 的分布。本图左上方的是FMR($\hat{t}$)曲线, 左下方的是FNMR($\hat{t}$)曲线。通过这些曲线, 可以分别的用个公式 (8) 和 (9) 计算出两两不匹配样本分布曲线 (右上方所示) 和两两匹配样本分布曲线 (右下方所示)。

性能的优劣。如果在这个范围内都有 $r_A > r_B$, 那么我们说算法A的性能优于算法B, 反之亦然。如果在这个范围内既出现 $r_A > r_B$, 又出现 $r_B > r_A$ 的情况时, 我们将无法比较两个算法的优劣。

C. DET曲线的分布

本部分中, 我们将在极坐标系下表示重建的两两匹配样本的分布 $\hat{g}(\hat{t})$ 和两两不匹配样本的分布 $\hat{f}(\hat{t})$ 。基于公式 (3) 和 (4), 我们对DET曲线的特性j进行如下计算:

$$f^{(j)}(\hat{t}) = -\frac{dFMR_j}{d\hat{t}} \quad (8)$$

$$g^{(j)}(\hat{t}) = \frac{dFNMR_j}{d\hat{t}} \quad (9)$$

图3说明了该计算。FMR 和FNMR的数据是从DET曲线中提取的, 他们是不连续的, 该分布必须用离散逼近法来定义, 虽然使用该方法得到的 $\hat{g}$ 和 $\hat{f}$ 会受到“噪声”干扰, 但是不会对本实验造成影响。

通过此计算, 我们获得了一个基于通用的匹配值 $\hat{t}$ 的 $\hat{g}^{(j)}$ 和 $\hat{f}^{(j)}$ 分布的集合, 其中 $j=1, \dots, J$ 。现在可以组合以各个样本的数目为权值的分布。如果样本数未知, 我们假设 N_j^f 和 N_j^g 均为 j 。平均的 $\bar{f}$ 和 $\bar{g}$ 的分布可如下进行计算:

$$\bar{f}(\hat{t}) = \frac{1}{N^f} \sum_{j=1}^J N_j^f \hat{f}_j(\hat{t}) \quad (10)$$

$$\bar{g}(\hat{t}) = \frac{1}{N^g} \sum_{j=1}^J N_j^g \hat{g}_j(\hat{t}) \quad (11)$$

其中， $N^f = \sum N_j^f$ ， $N^g = \sum N_j^g$ 分别是是两两不匹配样本和两两匹配样本的总数。

当然，该方法都要等价于在 (FMR, FNMR) 空间对 DET 曲线进行的平均化方法。我们下面来说明这个问题。

$$\begin{aligned} \widehat{FNMR}(\hat{t}) &= \int_{-\infty}^{\tau^-} \bar{g}(t) dt \\ &= \int_{-\infty}^{\tau^-} \frac{1}{N^g} \sum_{j=1}^J \frac{1}{dt} dFNMR_j(t) dt \\ &= \int_{-\infty}^{\tau^-} \frac{1}{N^g} \sum_{j=1}^J N_j^g \frac{1}{dt} dFNMR_j(t) d\hat{t} \\ &= \frac{1}{N^g} \sum_{j=1}^J N_j^g \left(dFNMR_j(\hat{t}) - dFNMR_j(-\infty) \right) \\ &= \sum_{j=1}^J \frac{N_j^g}{N^g} FNMR_j(\hat{t}) \end{aligned} \quad (12)$$

类似的有：

$$\widehat{FMR}(\tau) = \sum_{j=1}^J \frac{N_j^f}{N^f} FMR_j(\hat{t}) \quad (13)$$

至此，每一个 DET 曲线上的点的角度 θ 可以通过一个改点到 (c_x, c_y) 点的平均距离（如果必要可以加权）得到。

四、结果

参与人脸识别性能实验的有 21 名志愿者和 15 个 AFR 系统，实验中他们遵循相同的原则。图 4 中描述了各个系统的 DET 曲线计算结果。AFR 系统的 DET 曲线使用 $c_x=c_y=1$ 为中心为 100 个点计算归一化匹配值（结果用线表示）。关于该中心（即 $c_x=c_y=1$ ）的选择将在下面进行讨论。为了与 HFR 的平均结果进行比较，我们使用第三部分中 C 节的算法来计算 HFR 结果的 DET 曲线（如图 4 所示）。当然，少数能力较差的参与者的实验结果对该实验结果影响较大。

AFR 系统的实验结果参差不齐，一些性能较差的系统的实验结果如同是“随机选择”的一样。由于与 AFR 系统提供方有相关协议，我们不能公布所有的 AFR 系统的实验结果以及供应商的名字。因此，在图 4 中我们仅描述了各年份中性能最好的 AFR 的实验结果，另外，我们未对该系统的提供商进行说明。总体来说，在过去的 8 年中，AFR 系统的性能有很大的提高，每一年中 AFR 系统也有很大的发展。

不同参与者的实验结果也有很大的不同，能力最好参与者比较差的参与者的




图4 该图是用于测试HFR和AFR系统性能的DET曲线。HFR结果是关于匹配值阈值的函数。HFR的平均DET曲线是根据相邻得点连成的直线的。而那些连续的曲线表示的是1999, 2001, 2003, 2005, 2006年中最好的AFR系统的测试结果。曲线显示了重建的归一化匹配值。

错误率小的多。在错误率方面，男性和女性参与者的差距并不大，尽管女性参与者的实验结果中，漏匹配的比率更大（相比较于男性参与者）。虽然MID中大部分图像都是关于男性的，但是女性良好的识别男性脸部的能力并没有表现出来。AFR系统的实验结果中，漏匹配率的比例更大（相对于人的实验结果）。这可能因为AFR系统经过了一些调整，使它在生物特征验证中的FMR性能更好。

为了对HFR和AFR人脸识别性能结果进行比较，我们使用了在第三部分B节中提出的方法来对每年中性能最好的AFR的DET曲线和HFR曲线进行比较。其中，我们选取的归一化匹配值的范围是 $[0.4, 0.6]$ ，相应的，以FMR和FNMR均为 $[0, 0.15]$ 的曲线部分进行研究。该部分HFR与AFR性能比较的结果如表1所示。HFR比AFR性能好的部分以及HFR比AFR性能差的比例也在表中有所显示。该比例在该研究进行的这段时间不断的增大。在1999年，几乎所有的HFR系统都要好于

表1 HFR和每年中最好的AFR系统的性能比较

Year	HFR better(%)	HFR worse(%)	Indeterminate(%)	Better/Worse
1999	87.5	4.2	8.3	21.0
2001	87.5	8.3	4.2	10.5
2003	45.8	16.7	37.5	2.75
2005	37.5	33.3	29.2	1.13
2006	29.2	37.5	33.3	0.78

AFR系统，然而现在，AFR系统的性能已经等于甚至高于人的平均水平。

五、讨论

本文中，我们尝试了一种比较HFR系统和AFR系统的性能的方法，人们组织和指导志愿者和软件算法进行人脸测试实验，并提出一种新的统计学算法来分析实验结果。

人脸图像数据库是基于“three bears”的原则进行选择^[21]。开始，我们认为有必要通过人工的方式对MID的子集进行选择^[23]，这当然会很困难，但是通过实验，我们可以证明该方式不是必要的。人们可以处理一些低质量图片，非正面图像，光照条件较差的图像以及一些户外的复杂图像（本文中并未涉及），而且效果还不错。显然，人们可以有效地使用一些额外的信息，可以通过识别熟人（如一些名人，或一些熟人）的方法得到证明^[33]。另外，由于MID是开放性的，AFR算法的提供者很可能也曾使用过MID中的图像来开发或测试他们的算法，我们不能说出这将会对本实验有何影响。但是，本实验使用的仅仅是MID中很少的部分，我们认为这种影响可以忽略。

本文描述了对这一复杂现象的初步研究。我们已经对那些未经过训练的而且对该课题感兴趣的志愿者判断两张照片上所显示的并不相似的人是否是一个人的能力进行了研究。由于任务条件的不同，人们的实验结果也有很大差异，我们试图创造一个能使志愿者不受限制的条件，以便估计人类识别能力的极限水平，然而，本文中并未对一些重要的问题做出解释，如随着两张照片相似性增大时人们如何处理？动力问题究竟会有什么影响？无趣，呆板的问题会有什么影响？专家会比没有经过训练的人做的好吗？如何评价识别者的好与坏？人或软件对哪些特定类型的图像的处理会好于对其他类型图像的处理？

本文中，我们也提出了一种用于合并和平均化DET和ROC曲线新的统计学方法。该方法是为了适应评价人脸识别性能的复合DET曲线的需要而产生的。该方法独立于文献^[20]所提出的方法，尽管他们都用到了径向扫描线与DET曲线交叉求取归一化匹配值的基础技术。它允许产生归一化的FMR和FNMR分布，这个分布是若干个单独的DET曲线的组合。这个归一化本身就是一个进步，并且发展成为其它方法的一部分^[17]。

我们已经使用该归一化方法来平均化和比较归一化的半径匹配值。由于统计理论是普遍存在的，但是只有很少统计学方法被用于分析和解释生物计量分类的DET数据，这会令人有些意外。另一方面，对别的一些学科的很大一部分的研究都使用了统计学知识，例如Zhou等的研究^[34]，还有一部分用到了机器学习和人工智能技术，例如Hernández-Orallo等的研究^[16]和Drummond和Holte的研究^[7]。ROC分析被广泛的应用于各种分类方法，例如X光线照相技术、人类感知以及工业质量控制。Zhou等人^[34]对本文给出了很高评价。关于ROC推理工具的一个局限是 $g(t)$ 和 $f(t)$ 的高斯分布的公共假设，例如Green和Swets的工作^[11]。本文中我们所提出的方法不依赖于任何分布假设。这个研究的另一个焦点是AUC方面的

性能,例如Hanley 和 McNeil的工作^[14]。生物计量验证将EER作为衡量系统性能的指标,而不去过多关心AUC。

DET曲线的径向扫描的方法也引出了很多问题。第一个问题是以什么地方为扫描中心。由于我们不想依赖于各个坐标变量的变化,我们限定 (c, c) 作为扫描中心,其中 c 为常量, $c_x=c_y=c$ 。显然,在 $FMR = FNMR$ 直线上选取扫描中心,可以使求得的平均曲线独立于坐标变量的选择以及相应的EER。我们认为 c 的可能取值有0, 1和 ∞ 。选择0会导致接近坐标原点处的角度非常大,这个结果是非直观的。而且这一问题对于生物特征识别尤为重要,因为他常会研究FMR去很小值的情况。当选取 $c=1$ 和 $c=\infty$ 时曲线的差异并不大。然而,我们更趋向于将 c 的值定为1,因为扫描角度与典型的DET曲线的曲率相当,还有这更可能使这些DET正交化。选择 $c = \infty$ 容易使平均曲线与一组平行的,斜率为 45° 直线相交,影响实验结果。

基于扫描理论的推理方法意味着需要对DET曲线进行更深入研究。这里,我们为一个独立的曲线创建置信区间^[20],而不是为两个DET曲线的不同之处创建置信区间。测试一个观测得到的DET曲线与假想的DET曲线,也是一个让人感兴趣的工作,这部分的工作可以采取Kolmogorov - Smirnov方式进行测试。

六、结论:

本文提出了一种基于比较正面图像的实验来对HFR 和AFR的性能进行估量和比较方法,为了分析这种方法所得的结果,我们尝试了出了一个新的统计学方法用于分析DET曲线,通过比较HFR和AFR两类系统,我们可以得到如下结论:

- 人类识别人脸的能力因人而异,我们也发现了错误率数量级的差异。
- 在过去的8年里, AFR技术已经有了非常大的发展。1999年时的最好的AFR系统性能只相当于最差的人工识别系统的性能。然而,在与2006年中最好的AFR系统的性能进行比较时,我们发现HFR系统有29.2% 的部分的运行结果优于AFR系统,但是, 37.5%的部分的运行效果已经不如AFR系统。

参考文献:

- [1] A. Adler and J. Maclean, "Performance comparison of human and automatic face recognition," in Proc. Biometrics Consortium Conf., Washington, DC, Sep. 20-22, 2004.
- [2] D. M. Blackburn, J. M. Bone, and P. J. Phillips, FRVT 2000 evaluation report, 2001. [Online]. Available: http://www.frvt.org/DLs/FRVT_2000.pdf
- [3] A. P. Bradley, "The use of the area under the ROC curve in the evaluation of machine learning algorithms," Pattern Recognit., vol. 30, no. 7, pp. 1145-1159, Jul. 1997.
- [4] V. Bruce, Z. Henderson, K. Greenwood, P. Hancock, M. Burton, and P. Miller, "Verification

- of face identities from images captured on video,” *J. Exper. Psychol., Appl.*, vol. 5, no. 4, pp. 339–360, Dec. 1999.
- [5] A. M. Burton, P. Miller, V. Bruce, P. J. B. Hancock, and Z. Henderson, “Human and automatic face recognition: A comparison across image formats,” *Vis. Res.*, vol. 41, no. 24, pp. 3185–3195, Nov. 2001.
- [6] C. H. Liu, H. Seetzen, A. M. Burton, and A. Chaudhuri, “Face recognition is robust with incongruent image resolution: Relationship to security video images,” *J. Exper. Psychol., Appl.*, vol. 9, no. 1, pp. 33–41, Mar. 2003.
- [7] C. Drummond and R. C. Holte, “What ROC curves can’t do (and cost curves can),” in *Proc. 1st Workshop ROCAI*, 2004, pp. 19–26.
- [8] T. Fawcett, “ROC graphs: Notes and practical considerations for data mining researchers,” HP Labs., Palo Alto, CA, Tech. Rep. HPL-2003-4, 2003.
- [9] N. Furl, A. J. O’Toole, and P. J. Phillips, “Face recognition algorithms as models of the other race effect,” *Cogn. Sci.*, vol. 96, pp. 1–19, 2002.
- [10] K. Gates, “The past perfect promise of facial recognition technology,” ACDIS (Arms Control, Disarmament, and International Security) GAT:1.2004, [Online]. Available: <http://www.acdis.uiuc.edu/Research/OPs/Gates/GatesOP.pdf>
- [11] D. M. Green and J. A. Swets, *Signal Detection Theory and Psychophysics*. New York: Wiley, 1966.
- [12] S. Gong, S. J. McKenna, and A. Psarrou, *Dynamic Vision: From Images to Face Recognition*. London, U. K.: Imperial College Press, 2000.
- [13] P. J. B. Hancock, V. Bruce, and M. A. Burton, “A comparison of two computer-based face identification systems with human perceptions of faces,” *Vis. Res.*, vol. 38, no. 15/16, pp. 2277–2288, Aug. 1998.
- [14] J. A. Hanley and B. J. McNeil, “The meaning and use of the area under a receiver operating characteristic (ROC) curve,” *Radiology*, vol. 143, pp. 29–36, 1982.
- [15] C. L. Herlitz, “Sex differences in face recognition—Women’s faces make the difference,” *Brain Cogn.*, vol. 50, no. 1, pp. 121–128, Oct. 2002.
- [16] J. Hernández-Orallo, C. Ferri, N. Lachiche, and P. A. Flach, Eds., *Proc. 1st Int. Workshop, ROCAI*, Valencia, Spain, 2004.
- [17] A. K. Jain, K. Nandakumar, and A. Ross, “Score normalization in multimodal biometric systems,” *Pattern Recognit.*, vol. 38, no. 12, pp. 2270–2285, Dec. 2005.
- [18] J. Karduan and O. Karduan, “Comparative diagnostic performance of three radiological procedures for the detection of lumbar disk herniation,” *Methods Inf. Med.*, vol. 29, no. 1, pp. 12–22, Jan. 1990.

- [19] R Kemp, N. Towell, and G. Pike, “When seeing should not be believing: Photographs, credit cards and fraud,” *Appl. Cogn. Psychol.*, vol. 11, no. 3, pp. 211–222, Jun. 1997. ADLER AND SCHUCKERS: COMPARING HUMAN AND AUTOMATIC FACE RECOGNITION PERFORMANCE 1255
- [20] S. Macskassy and F. Provost, “Confidence bands for ROC curves: Methods and an empirical study,” in *Proc. 1st Workshop ROCAI*, 2004, pp. 61–70.
- [21] T. Mansfield and J. L. Wayman, *Best Practices in Testing and Reporting Performance of Biometric Devices*, 2002. [Online]. Available: www.cesg.gov.uk/site/ast/biometrics/media/BestPractice.pdf
- [22] NIST, *Fingerprint Vendor Technology Evaluation (FpVTE) 2003*. [Online]. Available: <http://fpvte.nist.gov/>
- [23] NIST, *NIST Special Database 18: Mugshot Identification Database(MID)*. [Online]. Available: <http://www.nist.gov/srd/nistsd18.htm>
- [24] A. J. O’Toole, D. Roark, and H. Abdi, “Recognizing moving faces: A psychological and neural synthesis,” *Trends Cogn. Sci.*, vol. 6, no. 6, pp. 261–266, Jun. 2002.
- [25] P. J. Phillips, A. Martin, and C. L. Wilson, “An introduction to evaluating biometric systems,” *Computer*, vol. 33, no. 2, pp. 56–63, Feb. 2000.
- [26] P. J. Phillips and E. M. Newton, “Meta-analysis of face recognition algorithms,” in *Proc. IEEE Int Conf. Autom. Face Gesture Recog.*, 2002, vol. 5, pp. 224–230.
- [27] P. J. Phillips, P. Grother, R. J. Micheals, D. M. Blackburn, E. Tabassi, and J. M. Bone, *FRVT 2002: Evaluation report*, 2003. [Online]. Available: http://www.frvt.org/DLs/FRVT_2002_Evaluation_Report.pdf
- [28] F. J. Provost, T. Fawcett, and R. Kohavi, “The case against accuracy estimation for comparing induction algorithms,” in *Proc. 15th Int. Conf. Machine Learning*, 1998, pp. 445–453.
- [29] D. A. Roark, A. J. O’Toole, and H. Abdi, “Human recognition of familiar and unfamiliar people in naturalistic video analysis and modeling of faces and gestures,” in *Proc. IEEE Int. Workshop Anal. Model. Faces Gestures*, Oct. 17, 2003, pp. 36–41.
- [30] M. Turk and A. Pentland, “Eigenfaces for recognition,” *J. Cogn. Neurosci.*, vol. 3, no. 1, pp. 71–86, Mar. 1991.
- [31] F. Wallhoff, S. Muller, and G. Rigoll, “Recognition of face profiles from the MUGSHOT database using a hybrid connectionist/HMM approach,” in *Proc. IEEE Int. Conf. Acoust. Speech Signal*, Salt Lake City, UT, Jul. 2001, pp. 1489–1492.
- [32] J. L. Wayman, “Fundamentals of biometric authentication technologies,” in *Proc. Card Tech/Secure Tech.*, 1999. [Online]. Available:

<http://www.engr.sjsu.edu/biometrics/nbtccw.pdf>

- [33] W. Zhao, R. Chellappa, P. J. Phillips, and A. Rosenfeld, "Face recognition: A literature survey," *ACM Comput. Surv.*, vol. 35, no. 4, pp. 399–458, Dec. 2003.
- [34] X.-H. Zhou, D. K. McClish, and N. A. Obuchowski, *Statistical Methods in Diagnostic Medicine*. Hoboken, NJ: Wiley, 2002.
- [35] P. J. Phillips, W. T. Scruggs, A. J. O'Toole, P. J. Flynn, K. W. Bowyer, C. L. Schott, and M. Sharpe, "FRVT 2006 and ICE 2006: Largescale results," *Nat. Inst. Standards and Technol.*, Gaithersburg, MD, NISTIR 7408, Mar. 2007.

致 谢

光阴似箭，转眼间四年的大学学习生活就要结束了，在这里要向所有关心帮助我的老师、同学及亲友们致以衷心的感谢！

首先感谢我的导师何英华老师。本论文是在何英华的精心指导和亲切关怀下完成的。值此论文完成之际，我对何老师在百忙之中对我的辛勤培养和教导表示衷心的感谢！在做毕业设计期间，何老师一直关心课题的进展，并提出了很多意见和建议，使我对课题的认识不断深入，为我打开了通向科研的一扇大门。

感谢我的父母、家人，感谢他们对我的学业、生活给予的关心和支持！

最后感谢天津大学四年来对我的教育和栽培，今后无论本人从事什么工作，必定会尽心尽力，做出成绩，为母校争光！