

一种基于局部 Gabor 滤波器组及 PCA + LDA 的人脸表情识别方法

邓洪波 金连文

(华南理工大学电子与信息学院, 广州 510640)

摘要 针对传统的 Gabor 滤波器组存在特征提取时间较长以及特征数据存在冗余性的缺点,提出了一种新颖的局部 Gabor 滤波器组。为了评估该方法的识别性能,提出了一个基于 Gabor 特征的人脸表情识别系统。该系统首先对经过预处理之后的纯表情图像提取 Gabor 特征,然后用 PCA + LDA 方法对采样后的特征进行特征选择,最后采用 K 近邻分类方法识别人脸表情。实验结果表明,这种方法无论在计算量还是识别性能上都比传统的 Gabor 滤波器组更具有优势。该方法的创新之处在于选取局部 Gabor 滤波器,最高平均识别率达到了 97.33%,表明其适合于人脸表情图像的分析。

关键词 局部 Gabor 滤波器组 特征提取 主元分析 线性判别分析 人脸表情识别

中图分类号: TP391.41 **文献标识码**: A **文章编号**: 1006-8961(2007)02-0322-08

Facial Expression Recognition Based on Local Gabor Filter Bank and PCA + LDA

DENG Hong-bo, JIN Lian-wen

(School of Electronic and Information Engineering, South China University of Technology, Guangzhou 510640)

Abstract This paper proposes a new local Gabor filter bank to overcome the disadvantage of the traditional Gabor filter bank, which needs a lot of time to extract Gabor feature vectors and the high-dimensional Gabor feature vectors are very redundant. In order to evaluate the performance of local Gabor filter bank, a Facial Expression Recognition(FER) system based on Gabor feature is presented. Firstly the FER system extracts Gabor feature of pure facial expression images after preprocess, then it uses a two-stage method PCA plus LDA to select and compress the sub-sampled Gabor feature, finally it adopts K nearest neighbor classifier to recognize facial expression. Experimental results show that the method is effective for both dimension reduction and recognition performance. The novelty of the method is to select partial Gabor filter bank with part of m scales and n orientations to extract Gabor feature. The best average recognition rate of 97.33% was achieved, which indicated this method was suit for facial expression analysis.

Keywords local Gabor filter bank, feature extraction, PCA, LDA, facial expression recognition

1 引言

人脸表情传递着丰富的个人情感信息,并且在人与人之间的交流中扮演着重要的角色,因此为了

推动更加智能和自然的人机交互,人脸表情识别在过去几十年得到广泛研究,并且成为一个研究热点。人脸表情识别涉及的领域非常广泛,包括图像分析、心理学、模式识别和机器视觉。到目前为止,针对人脸表情识别提出了许多的方法,其区别表现在以下

基金项目:国家自然科学基金项目(60275005);广东省自然科学基金项目(2003C50101, 04105938)

收稿日期:2005-05-08;**改回日期**:2005-10-19

第一作者简介:邓洪波(1980~),男。现为华南理工大学电子与信息学院硕士研究生。主要研究方向为数字图像处理、模式识别与计算机视觉。E-mail:hbdeng@scut.edu.cn

3 个方面:使用的数据(图像序列和静态图像)、特征提取方法和分类器。

对图像序列的人脸表情识别主要采用光流估计^[1-4]提取特征。Mase^[1]用光流估计面部肌肉的运动,然后用 k 近邻分类器识别。Yacoob 和 Davis^[2]用光流去跟踪眉毛、眼睛、鼻子和嘴巴的运动,通过查找表识别 6 种基本的表情。Otsuka 和 Ohya^[3]计算光流的 2 维 Fourier 变换系数,用隐 Markov 模型对人脸表情分类。Donato 和 Bartlett^[4]结合光流和主元分析(PCA)用于人脸表情识别。这些方法的性能与光流估计的可靠性密切相关,并且很难定义一种易于控制的标准表情图像序列。

本文将着重于静态图像的人脸表情识别,对静态图像的人脸的表示方法^[5-8]很多, Turk 和 Pentland^[5]提出 Eigenfaces,该方法是一种非监督学习方法,其没有利用类别信息,所以提取的特征的识别性能欠佳。Belhumeur 和 Hespanha^[6]提出的 Fisherface 是一种监督学习方法,充分利用类别信息

增强特征的区分度,从而使识别性能有所提高。Lyons^[7]用 Gabor 滤波器^[9,10]对人脸表情编码得到 Gabor 特征,Gabor 特征通常采用一系列的 Gabor 滤波器组提取特征,一般选用 5×8 、 4×8 和 3×8 等^[4,7,11,12]。Zhang^[8]采用多层感知器比较了 Gabor 特征和几何特征的识别性能,发现 Gabor 特征具有更好的识别性能,但是其计算量和内存需求很大,而且特征维数非常高。

针对以上两点,提出一种局部 Gabor 滤波器组用于提取特征,大大提高了特征提取的速度,减少了存储量,然后使用 PCA + LDA 方法选择特征和降维,得到了比较好的识别结果。

2 系统概要

基于 Gabor 特征提取,设计了一个人脸表情识别系统,该系统包括 3 个模块:预处理、特征提取和分类器,其结构框图如图 1 所示。

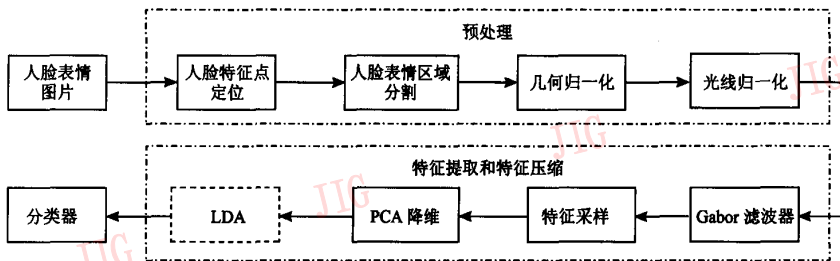


图 1 人脸表情识别系统的结构框图

Fig. 1 System architecture of the Facial Expression Recognition system

3 预处理

在人脸表情识别系统中,预处理是一个非常重要的过程,其首要工作是面部特征点的定位以及人脸图像的分割。另外,由于 Gabor 特征在本质上依赖于图像灰度在空间上的分布,故还特别需要对人脸图像进行一系列的处理,以达到位置校准、光线归一化的目的。预处理过程的理想输出是纯表情区域,使其具有统一的大小、形状和归一化的亮度值,并且去除光线和光照强度的影响。在本文中预处理过程包括如下 5 个步骤,把原始的 JAFFE (Japanese Female Facial Expression database) 人脸表情图像转换为归一化的纯表情图像:

(1) 手工定位面部特征点,如眼睛、眉毛、鼻子

和嘴巴的中心点。

(2) 根据左右两眼位置旋转图像,使 E_l 和 E_r 的连线 $E_l E_r$ 保持水平,以保证人脸方向的一致性。其中 E_l 和 E_r 分别为人脸图像的左、右两眼中心位置,两者间距离为 d , O 点为 $E_l E_r$ 的中点,如图 2 所示。

(3) 根据面部特征点和几何模型^[13]确定矩形特征区域,裁剪该矩形区域获得纯表情区域。该矩形高 $2.2d$,宽 $1.8d$,在裁剪区域内 O 点固定于 $(0.6d, 0.9d)$ 处,如图 2 所示,这保证了人脸位置的一致性。

(4) 图像经过尺度变换,得到统一大小的校准图像,本文设定校准图像的大小为 128×96 像素点,即保证了人脸大小的一致性,实现了几何归一化。

(5) 采用直方图均衡,以部分消除光线和光照强度的影响。




图 2 面部几何模型及相关距离
Fig. 2 Facial model

图 3 是预处理过程的实例图像。经过上述一系列预处理,得到归一化的纯表情图像,如图 4 所示,以下的识别过程是对归一化的纯表情图像进行的。实验表明预处理过程在整个识别系统中发挥着重要作用,同时我们发现几何归一化和光线归一化对于识别性能特别重要。

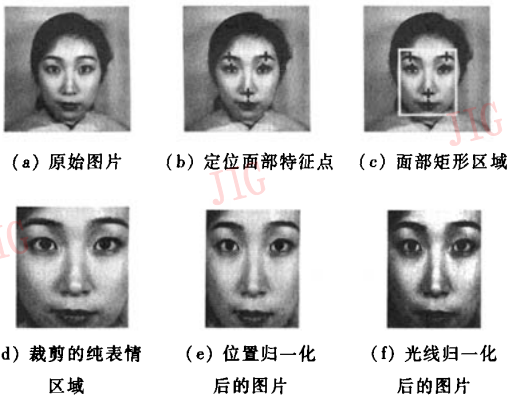


图 3 预处理过程的实例图片
Fig. 3 Examples of the preprocessing procedure



图 4 部分归一化的纯表情图片

Fig. 4 Examples of pure facial expression images

4 Gabor 特征提取

Gabor 小波核函数具有与人类大脑皮层简单细胞的 2 维反射区相同的特性^[9,10],即能够捕捉对应于空间频率(尺度)、空间位置及方向选择性的局部结构信息,在计算机视觉和图像分析领域得到广泛的应用^[4,7,10,11,12,14],并且被证实 Gabor 滤波器非常适用于图像分析和图像表征。

4.1 Gabor 滤波器

在空间域 Gabor 滤波器可以看作是一个被 Gaussian 函数调制的正弦平面波^[10],2 维 Gabor 滤波器的定义为

$$\psi(x, y, \omega, \theta) = \frac{1}{2\pi\sigma^2} e^{-\left(\frac{x'^2+y'^2}{2\sigma^2}\right)} [e^{i\omega x'} - e^{-\frac{\omega^2\sigma^2}{2}}] \quad (1)$$

$x' = x\cos(\theta) + y\sin(\theta)$, $y' = -x\sin(\theta) + y\cos(\theta)$ 式中, (x, y) 是空间域像素位置坐标, ω 是径向中心频率(尺度), θ 是 Gabor 滤波器的方向, σ 是 Gaussian 函数沿 x 轴和 y 轴的均方差。二元 Gaussian 函数横截面的一般形式是椭圆,在这里取圆形这一特殊形式。指数函数(即正弦平面波)经过 Gaussian 函数调制之后的正弦成分具有零均值,而余弦成分不具有零均值,所以减去 $e^{-\omega^2\sigma^2/2}$ 以使正弦平面波具有零均值。 σ 和 ω 的关系可以由下式来表示:

$$\sigma = \sqrt{2\ln 2} \left(\frac{2^\varphi + 1}{2^\varphi - 1} \right) / \omega \quad (2)$$

φ 是倍频程的带宽(the bandwidth in octaves)^[10],一般取 1~1.5,这里取 1。

根据以上的叙述可知 Gabor 滤波器的特性由尺度 ω 和方向 θ 决定,选取一系列的尺度 ω 和方向 θ , 则可以获得一组 Gabor 滤波器,称之为 Gabor 滤波器组。在人脸表情识别中通常选用 5 个尺度和 8 个方向^[4,12], 即 $\omega_m = \omega_{\max} \times \lambda^{-(m-1)}$, $m = \{1, 2, 3, 4, 5\}$, $\lambda = \sqrt{2}$, $\theta_n = (n-1)\pi/8$, $n = \{1, \dots, 8\}$ 。选取最大的尺度 $\omega_{\max} = \pi/2$, 5 个尺度和 8 个方向的 Gabor 滤波器组的实部如图 5 所示,从图 5 中可以看出其强大的局部特性和方向选择性。

4.2 Gabor 特征表征

图像 $I(x, y)$ 的 Gabor 表征是图像 $I(x, y)$ 与 Gabor 滤波器 $\psi(x, y, \omega_m, \theta_n)$ 的卷积

$$O_{m,n}(x, y) = I(x, y) * \psi(x, y, \omega_m, \theta_n) \quad (3)$$

图像的卷积输出为复数形式,该复数的量值即为提取的 Gabor 特征值。对应图 5 的 Gabor 滤波器组,




图 5 5 个尺度和 8 个方向的 Gabor 滤波器组的实部 (行对应不同的尺度 ω_m , 列对应不同的方向 θ_n)

Fig. 5 The real part of the filters with five frequencies and eight orientations (the row corresponds to different frequency ω_m , the column corresponds to different orientation θ_n)

图 6 为一幅人脸表情图像(图 4(a))的 Gabor 特征值。在实际中 Gabor 特征提取时间长,其特征维数相当高。例如,预处理之后的图像大小为 128×96 ,那么 40 个滤波器得到的 Gabor 特征矢量的维数一共是 491 520 ($128 \times 96 \times 5 \times 8$) 维。




图 6 一幅人脸表情图像的 Gabor 特征表征

Fig. 6 The magnitudes of the Gabor feature representation of the first face image in Fig. 4

4.3 基于局部 Gabor 滤波器组的特征参数选择

从图 6 可以看出,对于相同方向不同频率的

Gabor 滤波器提取的特征值具有非常相似的特性,特别是在相邻的两个频率上尤其明显,如图 6 第 1 列对应的 Gabor 特征,其特征值具有很大的冗余性和相关性。 m 个尺度和 n 个方向所构成的所有滤波器,称之为全局滤波器组,用 $G(m \times n)$ 表示。针对全局滤波器组 $G(m \times n)$ 特征提取时间较长以及特征数据存在的冗余性,提出了一种新颖的局部滤波器组,即选用 m 个尺度和 n 个方向所构成的部分滤波器进行特征提取,选取的滤波器覆盖了全局滤波器组的 m 个尺度和 n 个方向,在同一方向上选取一个或多个尺度(小于 m),用 $LG(m \times n)$ 表示。局部滤波器组包含了全局滤波器组多尺度和多方向的特征信息,而且减少了特征值之间的冗余性,这样可以达到缩短特征提取时间、降低特征维数和减少存储量的目的,同时又保证了识别性能。图 7 给出了几种全局滤波器组和局部滤波器组实例。 $LG1(m \times n)$ 的选取方法是尺度 m 从小到大递增,到最大值后返回重新开始,对应的方向 n 从 1 开始逐次加 1。 $LG2(m \times n)$ 的不同之处在于尺度 m 从大到小递减,到最小值后返回重新开始。 $LG3(m \times n)$ 则是隔点选取尺度 m 和方向 n 。

表 1 给出了一些 Gabor 滤波器组的计算量和存储量,从表 1 可以看到局部滤波器组与全局滤波器组相比具有降低特征维数、缩短特征提取时间、减少计算量和存储量等优点。

为了包含不同的空间局部特性和方向选择性,把每个 Gabor 滤波器的图像表征连接起来,形成原始的 Gabor 特征矢量。由于原始特征维数特别高(如图 6 的原始 Gabor 特征有 491 520 维),因此通常先对每个滤波器的输出特征进行采样,然后经过归一化,再连接起来形成新的 Gabor 特征矢量。比较两种不同的采样方法:整体采样和局部采样^[15],整体采样是对整幅图像采样,局部采样则是对图像的

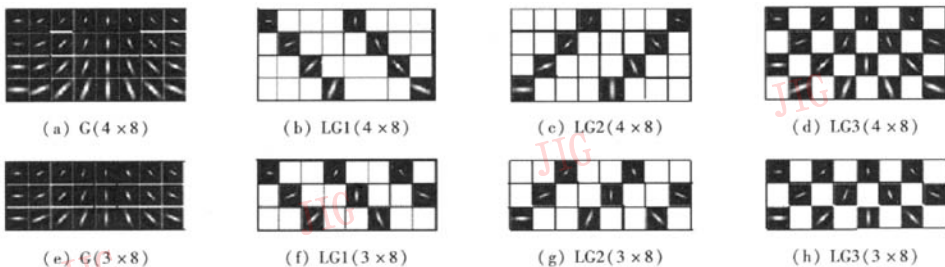


图 7 全局滤波器组和局部滤波器组实例,局部滤波器组 $LG(m \times n)$ 由显示的那些滤波器构成

Fig. 7 Examples of several global and local Gabor filter bank, the black blocks are the selected filter for $LG(m \times n)$

表 1 不同特征参数对应的计算量、特征提取时间和存储量
Tab.1 Computation and memory required by different Gabor filter bank

Gabor 滤波器组	滤波器数目	原始特征维数	特征提取时间 (ms)*	整体采样(采样间隔 8)		局部采样(采样间隔 8)	
				特征维数	PCA 变换矩阵	特征维数	PCA 变换矩阵
G(5 × 8)	40	491 520	2 167	7 680	7 680 × 128	3 400	3 400 × 128
G(4 × 8)	32	393 216	1 775	6 144	6 144 × 128	2 720	2 720 × 128
G(3 × 8)	24	294 912	1 357	4 608	4 608 × 128	2 040	2 040 × 128
LG1(3 × 8)	8	98 304	435	1 536	1 536 × 128	680	680 × 128
LG3(3 × 8)	12	147 456	681	2 304	2 304 × 128	1 020	1 020 × 128

注: * 表示在 P4 2.8GHz 的微型计算机上的执行时间

局部区域(眼睛和嘴巴)采样,如图 8 所示(其采样间隔为 8 个像素)。表 1 的后 4 列给出了整体采样和局部采样后的特征维数和 PCA 变换矩阵,局部采样与整体采样相比具有特征维数更低、PCA 变换矩阵更小的优点。



(a) 整体采样

(b) 局部采样

图 8 两种采样方法(黑点表示采样点)

Fig. 8 Two different sample methods

5 特征选择及分类器设计

采样后的 Gabor 特征矢量的维数已经明显降低,但仍然是高维特征,一种处理高维特征问题的方法是通过组合特征来降低维数,其中线性组合特征特别引人注目。从本质上说,线性组合方法是把高维数据投影到低维数据空间,在这里称为特征选择。目前两种最常用的特征选择方法是主分量分析(PCA)^[5,6,16,17]和线性判别分析(LDA)^[6,16,17]。PCA 的目的是寻找在最小均方意义下最能够代表原始数据的投影方法,而 LDA 的目的是寻找在最小均方意义下最能够区分各类数据的投影方法。

5.1 PCA

假设 N 个样本图像用 t 维的特征矢量 x_i ($i=1, 2, \dots, N$) 表示,PCA 可以找到一个线性变换矩阵将 t 维的原始特征矢量映射到 f 维的子空间,其中,

$f \ll t$ 。在进行 PCA 变换之前,首先对每个训练样本 x_i 进行归一化(即减去平均值,然后除以方差),转换为符合正态分布 $N(0, 1)$ 的矢量 x'_i ,然后再组合构成矩阵 $X = [x'_1, x'_2, \dots, x'_N]$,其协方差矩阵 $Q = XX^T$,求协方差矩阵 Q 的本征矢量^[16,17]

$$\lambda E = QE \quad (4)$$

其中, E 为本征矢量, λ 为本征值,将本征矢量按照本征值的大小排序,取前 f 列本征矢量即得到 $t \times f$ 的线性变换矩阵 W_{pca} 。新的特征矢量可以表示为

$$y_i = W_{\text{pca}}^T x_i \quad (i = 1, 2, \dots, N) \quad (5)$$

其中, x_i 为 t 维的列向量, W_{pca}^T 为 W_{pca} 的转置, y_i 为 f 维的列向量。PCA 可以大幅降低原始特征维数,其不足之处在于 PCA 对不同类别不加区分,丢失了一些重要的判别信息。

5.2 LDA

如果说 PCA 是寻找最能描述原始数据的矢量空间,那么 LDA 则是寻找最能区分各类数据的矢量空间,其充分利用了训练样本的类别信息。LDA 的目标是最小化类内距离,同时最大化类间距离。在数学形式上说,类内散度矩阵 S_w 和类间散度矩阵 S_b 定义如下:

$$S_w = \sum_{j=1}^c \sum_{i=1}^{N_j} (x'_i - \mu_j)(x'_i - \mu_j)^T \quad (6)$$

$$S_b = \sum_{j=1}^c (\mu_j - \mu)(\mu_j - \mu)^T$$

其中, x'_i 是类别 j 的第 i 个样本, μ_j 是类别 j 的平均值, μ 是所有类别的平均值, c 是类别个数, N_j 是类别 j 的样本个数。

要得到 LDA 的变换矩阵 W_{lda} ,一种常用的方法就是最大化比率 $\det |S_b| / \det |S_w|$ 。如果 S_w 是非奇异矩阵,那么要使比率 $\det |S_b| / \det |S_w|$ 达到最大

值,只需求出矩阵 $S_w^{-1}S_b$ 的本征矢量^[4,16,17],选取最大的 g 个本征值对应的本征矢量作为列向量构成变换矩阵 W_{lda} ,新的特征矢量可以表示为

$$z_i = W_{lda}^T y_i \quad (i = 1, 2, \dots, N) \quad (7)$$

其中, y_i 为 f 维的列向量, W_{lda} 为 $f \times g$ 的变换矩阵, z_i 为 g 维的列向量。需要注意的是:采用 LDA 最多有 $c - 1$ 个非零的本征矢量,因此子空间最多是 $c - 1$ 维,这里把表情分为 7 类,所以 LDA 的子空间最多是 6 维。

5.3 PCA + LDA

为了保证 S_w 是非奇异矩阵,需要 $t + c$ 个训练样本,当特征维数 t 特别大时,在实际应用中往往难以满足要求。为了解决训练样本不够的情况,在文献^[6]、^[16]中提出了中间过渡子空间,即先将 t 维的高维空间经过 PCA 降到 f 维的过渡子空间,再在此空间进行 LDA 变换,得到最终的 g 维子空间。更确切地说,可以表示为

$$z_i = W_{lda}^T W_{pca}^T x_i \quad (i = 1, 2, \dots, N) \quad (8)$$

为了比较经过 PCA 和 PCA + LDA 两种方法降维后的特征矢量的识别性能,分别测试了 PCA 特征和 PCA + LDA 特征的识别率。

6 实验及结果

为了评估和验证所提方法的识别性能,采用日本的 JAFFE^[7,14] 女性人脸表情数据库进行测试,该数据库包括 10 个人的表情图像,每人有 7 种表情(愉快、恐惧、愤怒、惊奇、悲伤、厌恶和中性),每种表情有 3 到 4 张样本,一共有 213 张表情图像。在每个人的各种表情中,取 2 张表情图像作为训练样本,剩下的作为测试样本,每次实验中有 138 个训练样本和 75 个测试样本。由于该数据库的样本比较少,所以遍历 3 种情况,得到平均识别率。对 PCA 特征和 PCA + LDA 特征分别进行测试,根据训练样本的特征矢量求出每个类别的平均值作为模板,采用 K 近邻分类方法进行分类,在实验中使用两种距离测度,分别是欧式距离 (Euclidean) 和街区距离 (Cityblock)。

6.1 不同特征参数对应的识别结果

为了选取合适的特征参数,表 2 列出了不同的采样方法和不同的 Gabor 滤波器组对应的识别结果,并比较了两种特征矢量 (PCA 和 PCA + LDA) 的识别性能。

表 2 不同的特征参数对应的识别结果

Tab. 2 Recognition rates corresponding to different Gabor filter bank

特征参数		分类方法和距离测度			
		PCA		PCA + LDA	
		Euclidean	Cityblock	Euclidean	Cityblock
整体采样	G(5 × 8)	80.00	89.33	97.33	97.33
	G(4 × 8)	79.56	88.44	96.89	96.89
	G(3 × 8)	80.00	87.56	95.56	95.11
	LG1(3 × 8)	79.11	84.89	95.11	95.56
	LG2(3 × 8)	76.89	83.56	96.00	95.56
	LG3(3 × 8)	79.56	87.11	96.44	95.56
局部采样	LG3(4 × 8)	78.22	90.67	96.44	96.00
	G(3 × 8)	80.00	82.22	96.89	96.44
	LG1(3 × 8)	75.11	82.22	96.89	95.11
	LG2(3 × 8)	78.22	81.33	95.56	93.33
	LG3(3 × 8)	81.78	84.44	96.89	96.44

由表 2 可知,PCA 特征的识别结果在 75.11% 到 90.67% 之间,其中街区距离比欧式距离的识别性能高 5 ~ 7 个百分点。采用 PCA + LDA 特征的识别率比 PCA 特征提高了几个百分点,欧式距离要略好于街区距离,其最高平均识别率达到了 97.33%,说明 PCA + LDA 除了明显降低了特征维数之外,还增加人脸表情的区分度,使其更易于分类。

对比各种特征参数的识别结果发现:全局滤波器组 G(5 × 8) 的识别率最高,而随着滤波器的减少,G(4 × 8) 和 G(3 × 8) 的识别率略有降低。但是 5 × 8、4 × 8 和 3 × 8 的全局滤波器组与局部滤波器组的识别率相差不大,而且在某些情况下局部滤波器组的识别率超过了全局滤波器组,如 LG3(3 × 8)/PCA + LDA 的识别率比 G(3 × 8)/PCA + LDA 高。实验结果表明选取局部滤波器组,除了缩短特征提取时间、降低特征维数、减少计算量和存储量之外,识别率基本维持不变甚至有所提高。

比较两种采样方法发现:局部采样的特征维数远少于整体采样(表 1),在相同 Gabor 特征参数下,两者的识别率相差不大。但局部采样在 PCA + LDA/Euclidean 下得到的最高识别率要略高于全局采样,可见局部采样的部分(即眼睛和嘴巴)为脸表情的显著特征区域。

6.2 光线归一化对识别性能的影响

该实验将比较光线归一化前后对识别性能的影响。以局部采样和欧式距离为例,选取 $G(3 \times 8)$ 、 $LG2(3 \times 8)$ 和 $LG3(3 \times 8)$ 进行特征提取,其识别性能如表 3 所示。光线归一化对 PCA 特征的识别性能的影响非常明显,经过光线归一化后识别率提高

表 3 光线归一化前后的识别结果
Tab.3 Recognition rates with and without illumination normalization

光线归一化	PCA			PCA + LDA		
	$G(3 \times 8)$	$LG2(3 \times 8)$	$LG3(3 \times 8)$	$G(3 \times 8)$	$LG2(3 \times 8)$	$LG3(3 \times 8)$
否	76.00	72.44	74.67	95.56	95.11	95.11
是	80.00	78.22	81.78	96.89	95.56	96.89

表 4 删除 PCA 前 1~9 维特征对应的识别结果

Tab.4 Recognition results by eliminating the first one to nine principal components

特征参数	分类方法	删除的 PCA 的特征维数									
		0	1	2	3	4	5	6	7	8	9
$G(3 \times 8)$	PCA	87.56	88.44	88.44	91.11	89.78	86.67	84.89	82.22	83.11	84.00
	PCA + LDA	95.56	96.44	96.44	96.44	96.44	96.00	95.56	94.22	93.78	93.78
$LG3(3 \times 8)$	PCA	87.11	87.11	88.89	91.11	89.33	87.56	85.33	81.78	82.67	84.89
	PCA + LDA	96.44	95.56	97.33	95.56	94.67	94.67	95.11	94.22	93.33	93.33

从表 4 可以知道,对于 PCA 特征,删除前 3 维使识别率提高了 2~4 个百分点,最高平均识别率达到 91.11%。对于 PCA + LDA 特征和 $LG3(3 \times 8)$,删除前 2 维 PCA 特征达到最高识别率 97.33%。随着删除 PCA 的特征维数增加,识别率先升高后降低,即可以找到一个最高识别率。实验表明对于人脸表情识别,删除前 3 维 PCA 特征同样可以提高识别率,但是此时不一定是最高识别率,在实际应用中要根据实验情况对比删除前几维特征的识别结果可以得到最高识别率。

7 结论

本文给出了一个基于 Gabor 特征提取的人脸表情识别系统,提出了一种新颖的局部 Gabor 滤波器组进行特征提取的方法,结合了 PCA 和 LDA 进行特征选择,采用 K 近邻分类方法评估各种特征参数对应的识别性能。本文研究的主要意义有:

(1) 局部 Gabor 滤波器组比通常采用的全局滤

波器组具有很大的优势,表现在特征提取时间减少,特征维数明显降低,计算量和内存需求减少,在某些情况下识别率有所提高。

6.3 删除 PCA 前几维特征的识别结果

在文献[5]中指出 PCA 前三维特征主要区别光线的不同,删除前三维特征将使人脸识别性能能进一步提高,验证其在人脸表情识别中的通用性。该实验选取 $G(3 \times 8)$ 和 $LG3(3 \times 8)$ 滤波器组进行特征提取,采样方法为整体采样,对于 PCA 特征选用街区距离作为距离测度,对于 PCA + LDA 特征则选用欧式距离。删除 PCA 前 1 至 9 维特征对应的识别性能如表 4 所示。

波器组具有很大的优势,表现在特征提取时间减少,特征维数明显降低,计算量和内存需求减少,在某些情况下识别率有所提高。

(2) 在人脸表情识别中,PCA 降维可以大幅降低特征维数,从而使计算量大幅降低。用 PCA 降维后的特征进行分类,在 K 近邻分类方法中使用街区距离的识别性能要高于欧式距离,实验表明光线归一化对 PCA 特征获得高的识别性能具有重要意义。

(3) 经过 PCA 降维后的特征,采用 LDA 可以把特征维数进一步降低,并且识别性能明显提高。PCA + LDA 特征还可以降低光线对识别的敏感性。

(4) 删除前 3 维 PCA 特征可以提高识别率,但是并不一定达到最高识别率,随着删除的特征维数增加,识别率先升高后降低,从而可以确定一个最高识别率,本文实验得到的最高识别率为 97.33%。

参考文献 (References)

- Mase K. Recognition of facial expression from optical flow[J]. IEICE Transactions, 1991, 74(10): 3474 ~ 3484.
- Yacoub Y, Davis L. Recognizing human facial expressions form long

- image sequences using optical flow[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1994, 16(6): 636 ~ 642.
- 3 Otsuka T, Ohya J. Recognizing multiple persons facial expressions using HMM based on automatic extraction of significant frames from image sequence[A]. In: *Proceedings of the International Conference on Image Processing[C]*, California, USA, 1997: 546 ~ 549.
- 4 Donato G, Bartlett M S, Hager J C, *et al.* Classifying facial actions [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1999, 21(10): 974 ~ 989.
- 5 Turk M, Pentland A. Eigenfaces for recognition [J]. *Journal Cognitive Neuro-science*, 1991, 3(1): 71 ~ 86.
- 6 Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. fisherfaces: recognition using class specific linear projection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(7): 711 ~ 720.
- 7 Lyons M J, Akamatsu S, Kamachi M, *et al.* Coding facial expressions with Gabor wavelets[A]. In: *Proceedings of the Third IEEE International Conference on Automatic Face and Gesture Recognition[C]*, Nara, Japan, 1998: 200 ~ 205.
- 8 Zhang Z, Lyons M, Schuster M, *et al.* Comparison between geometry-based and Gabor-wavelets-based facial expression recognition using multi-layer perceptron[A]. In: *Proceedings of the Third IEEE International Conference on Automatic Face and Gesture Recognition[C]*, Nara, Japan, 1998: 454 ~ 459.
- 9 Daugman J G. Complete discrete 2-D Gabor transforms by neural networks for image analysis and compression[J]. *IEEE Transactions on Acoustic, Speech and Signal Processing*, 1988, 36(7): 1169 ~ 1179.
- 10 Lee T S. Image representation using 2D Gabor wavelets[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1996, 18(10): 959 ~ 971.
- 11 Liu C, Wechsler H. A Gabor feature classifier for face recognition [A]. In: *Proceedings of the Eighth IEEE International Conference on Computer Vision[C]*, Vancouver, Canada, 2001, 2: 270 ~ 275.
- 12 Liu C, Wechsler H. Independent component analysis of Gabor features for face recognition [J]. *IEEE Transactions on Neural Networks*, 2003, 14(4): 919 ~ 928.
- 13 Shih F Y, Chuang C. Automatic extraction of head and face boundaries and facial features [J]. *Information Sciences*, 2004, 158(1): 117 ~ 130.
- 14 Lyons M J, Budynek J, Akamatsu S. Automatic classification of single facial images[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1999, 21(12): 1357 ~ 1362.
- 15 Liu D H, Lam K M, Shen L S. Optimal sampling of Gabor features for face recognition[J]. *Pattern Recognition Letters*, 2004, 25(2): 267 ~ 276.
- 16 Martinez A M, Kak A C. PCA versus LDA[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(2): 228 ~ 233.
- 17 Duda R O, Hart P E, Stork D G. *Pattern Classification (second edition)* [M]. New York: Wiley, 2001.