

文章编号:1001-9081(2010)11-2970-04

# 基于多通道 Log-Gabor 小波与 $(2D)^2$ PCALDA 的人脸识别方法

火元莲

(西北师范大学 物理与电子工程学院, 兰州 730070)

(huoyuanlian@163.com)

**摘要:**为了降低光照变化对基于子空间的人脸识别方法性能的影响,结合多通道 Log-Gabor 策略与  $(2D)^2$ PCALDA 特征提取方法,提出了一种新的人脸识别方法。将不同尺度与方向作为独立通道,在每个通道内采用  $(2D)^2$ PCALDA 对人脸图像的 Log-Gabor 表示进行特征提取、分类,然后对各通道分类结果进行决策融合得到最终的类别归属。在 CAS-PEAL-R1、ORL 与 Yale 人脸数据库上的实验结果表明,该算法具有较好的识别性能。

**关键词:**多通道 Log-Gabor;主成分分析;线性判别式分析;  $(2D)^2$ PCALDA;人脸识别

**中图分类号:**TP391.41 **文献标志码:**A

## Face recognition method based on multi-channel Log-Gabor and $(2D)^2$ PCALDA

HUO Yuan-lian

(College of Physics and Electronic Engineering, Northwest Normal University, Lanzhou Gansu 730070, China)

**Abstract:** To reduce the influence resulting from lighting variations on the performance of face recognition methods based on images, a new face recognition method, which combined the multi-channel strategy with  $(2D)^2$ PCALDA feature extraction technique, was proposed. Different scale and orientation as an independent channel, the features were extracted using  $(2D)^2$ PCALDA and classification was performed in each channel, and the final classification could be obtained by fusing different channel classification results. The experimental results in the CAS-PEAL-R1, ORL and Yale face database show that the proposed method has better recognition performance.

**Key words:** multi-channel Log-Gabor; Principal Component Analysis (PCA); Linear Discriminant Analysis (LDA);  $(2D)^2$ PCALDA; face recognition

## 0 引言

在过去的几十年里,研究者提出了许多人脸识别方法,在这些方法中,基于子空间的方法得到了广泛的研究<sup>[1]</sup>。通常,基于子空间的方法提取的图像特征是由像素灰度值表示的,图像像素灰度值本质上不表示任何结构与纹理信息,且对光照很敏感。因此,为了提高算法的识别性能,应该用更好的方法表示人脸。由于 Gabor 小波良好的方向选择性与频率选择性,其表征的人脸图像对光照与表情变化不敏感,可产生鲁棒的人脸表示(简称 GaborFaces),在人脸识别中经常被使用<sup>[2-4]</sup>。但是, Gabor 滤波器有存在直流分量与过度表达低频分量而对高频分量表达不足等缺点,这些缺点将影响图像特征的提取效果。与 Gabor 小波相比较, Log-Gabor 不存在直流分量,其传递函数高频端的延长也能弥补 Gabor 滤波器过度表达低频分量而对高频分量表达不足的缺点。因此,用 Log-Gabor 将产生更好的人脸表示(Log-GaborFaces)。传统 GaborFaces 是人脸图像与不同方向、尺度的 Gabor 核的卷积结果,用这种方法表征人脸将产生非常高维的样本空间,通常通过子采样来降低样本空间。采样将导致部分有用信息的丢失。为了能够更有效地提取特征,本文采用多通道策略,也就是将每个 Log-Gabor 核看做一个通道,在每一个通道内用  $(2D)^2$ PCALDA<sup>[5]</sup>进行特征提取、用最近邻准则进行分类。这样 8 个方向、5 个尺度的 Log-Gabor 小波将形成 40 个平行通

道,最后融合各通道分类结果得到测试样本最终的类别归属。在 ORL、Yale 与 CAS-PEAL-R1 人脸数据库上的实验表明,本文提出的方法在性能上优于 2DPCA<sup>[6]</sup>、2DLDA<sup>[7]</sup>、 $(2D)^2$ PCA<sup>[8]</sup>、 $(2D)^2$ LDA<sup>[9]</sup>、 $(2D)^2$ PCALDA<sup>[5]</sup>、Gabor + LDA<sup>[4]</sup>与 Gabor + 2DLDA<sup>[2]</sup>方法。

## 1 人脸的 Log-Gabor 表示(Log-GaborFaces)

二维 Log-Gabor 滤波器的构造包括两个部分:控制频率带宽的径向分量和控制方向选择的方向分量。在极坐标中,频域的二维 Log-Gabor 可表示为<sup>[10]</sup>:

$$g(f, \theta) = \exp\left[\frac{-(\ln(f/f_0))^2}{2(\ln(\sigma_f/f_0))^2}\right] \times \exp\left[\frac{-(\theta - \theta_0)^2}{2\sigma_\theta^2}\right] \quad (1)$$

其中:  $f_0$  是中心频率;  $\theta_0$  为滤波器的角度方向;  $\sigma_f$  用于确定径向带宽  $B_f$ ,  $B_f = 2 \sqrt{2/\ln 2} \times |\ln(\sigma_f/f_0)|$ ;  $\sigma_\theta$  用于确定方向带宽  $B_\theta$ ,  $B_\theta = 2 \sqrt{2/\ln 2} \sigma_\theta$ ,  $\sigma_\theta = s\Delta\theta$ ,  $s$  为比例因子,  $\Delta\theta$  为滤波器之间的方向间隔。

人脸图像的 Log-Gabor 表示(Log-GaborFaces)就是人脸图像与一组 Log-Gabor 核卷积的结果。假设人脸图像为  $I(x, y)$ , 则人脸图像的 Log-GaborFaces 为:

$$G_{\mu, v} = I(x, y) * \varphi_{\mu, v}(x, y) \quad (2)$$

其中:  $*$  表示卷积;  $\varphi_{\mu, v}(x, y)$  表示在尺度为  $v$ , 方向为  $\mu$  的 Log-Gabor 核, 本文选择 8 个方向, 5 个尺度, 即  $\mu \in \{0, 1, \dots, 7\}$ ,  $v \in \{0, 1, 2, 3, 4\}$ 。图 1 显示了人脸图像与其对应的各通

收稿日期:2010-04-22;修回日期:2010-06-18。

作者简介:火元莲(1973-),女,甘肃兰州人,副教授,主要研究方向:图像处理、模式识别。

道的 Log-GaborFace。

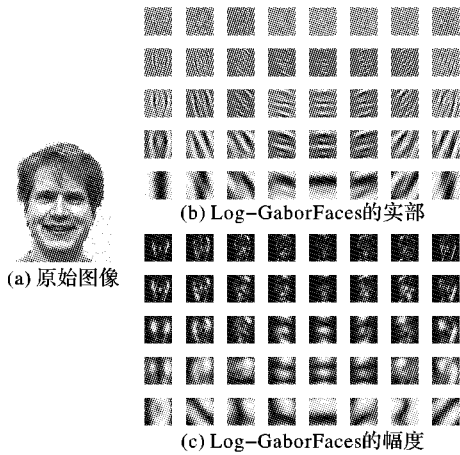


图 1 人脸图像与 Log-Gabor 的卷积结果

## 2 基于 Log-GaborFaces 的多通道 (2D)<sup>2</sup>PCALDA

### 2.1 基于 Log-GaborFaces 的 2DPCA

假设训练集由  $M$  个人脸图像  $A^i \in \mathbb{R}^{m \times n} (i = 1, \dots, M)$  组成,  $G_{\mu,v}^i (\mu = 0, 1, 2, \dots, 7; v = 0, 1, 2, 3, 4)$  表示  $A^i$  在第  $\mu v$  个通道的 Log-GaborFaces。令  $X_{\mu,v} \in \mathbb{R}^{n \times d}$  是一个列相互正交的矩阵,  $n > d$ , 将  $G_{\mu,v}^i$  投影到  $X_{\mu,v}$  上可得到一个  $m \times d$  的特征矩阵  $Y_{\mu,v}^i = G_{\mu,v}^i X_{\mu,v}$ 。各通道投影矩阵  $X_{\mu,v}$  可通过最大化相应通道特征矩阵  $Y_{\mu,v}^i$  的总体散度来选择, 即:

$$J(X_{\mu,v}) = \text{tr}\{E[(Y_{\mu,v}^i - E(Y_{\mu,v}^i))^T(Y_{\mu,v}^i - E(Y_{\mu,v}^i))]\} = \text{tr}\{E[(G_{\mu,v}^i X_{\mu,v} - E(G_{\mu,v}^i X_{\mu,v}))^T(G_{\mu,v}^i X_{\mu,v} - E(G_{\mu,v}^i X_{\mu,v}))]\} \quad (3)$$

令  $\Psi_{\mu,v} = E[(G_{\mu,v}^i - E(G_{\mu,v}^i))^T(G_{\mu,v}^i - E(G_{\mu,v}^i))]$ , 则  $\Psi_{\mu,v}$  可通过式 (4) 得到:

$$\Psi_{\mu,v} = \frac{1}{M} \sum_{i=1}^M (G_{\mu,v}^i - \bar{G}_{\mu,v})^T (G_{\mu,v}^i - \bar{G}_{\mu,v}) \quad (4)$$

$$\bar{G}_{\mu,v} = \frac{1}{M} \sum_{i=1}^M G_{\mu,v}^i$$

所以式 (3) 可写为:

$$J(X_{\mu,v}) = X_{\mu,v}^T \Psi_{\mu,v} X_{\mu,v}; \mu = 0, 1, \dots, 7; v = 0, 1, \dots, 4 \quad (5)$$

这样, 通道  $\mu v (\mu = 0, 1, \dots, 7; v = 0, 1, \dots, 4)$  的最佳投影矩阵可通过求  $\Psi_{\mu,v} (\mu = 0, 1, \dots, 7; v = 0, 1, \dots, 4)$  的前  $d$  个最大特征值对应的特征向量得到, 即  $X_{\mu,v, \text{opt}} = [\mathbf{x}_{\mu,v,1}, \dots, \mathbf{x}_{\mu,v,d}]$ 。

### 2.2 基于 Log-GaborFaces 的 2DLDA

假设训练集由  $C$  类人脸图像构成, 每类包含有  $N_i$  个样本, 总共有  $M = N_i \times C$  个样本。令大小为  $m \times n$  的矩阵  $A_m^i$  表示第  $i$  类人脸的第  $m$  个样本;  $G_{m,\mu,v}^i (i = 1, 2, \dots, C; m = 1, 2, \dots, N_i; \mu = 0, 1, \dots, 7; v = 0, 1, \dots, 4, m = 1, 2, \dots, N_i)$  表示样本  $A_m^i$  在第  $\mu v$  个通道中的 Log-GaborFaces。各通道投影矩阵  $Z_{\mu,v} \in \mathbb{R}^{m \times d} (\mu = 0, 1, \dots, 7; v = 0, 1, \dots, 4)$  的列向量相互正交。将  $G_{m,\mu,v}^i$  投影到对应的  $Z_{\mu,v}$  可得到其特征矩阵  $Y_{m,\mu,v}^i = Z_{\mu,v}^T A_m^i$ , 为了使不同类样本特征很好地分离, 投影矩阵的选择至关重要, 2DLDA 采用式 (6) 所示准则来决定投影矩阵:

$$J(Z_{\mu,v}) = \frac{\text{tr}(S_{\mu,v}^B)}{\text{tr}(S_{\mu,v}^W)} \quad (6)$$

其中  $S_{\mu,v}^B$  和  $S_{\mu,v}^W$  分别表示中  $Y_{m,\mu,v}^i$  在通道  $\mu v$  的类间散度矩阵与类内散度矩阵。

$$S_{\mu,v}^B = \frac{1}{M} \sum_{i=1}^C N_i (\bar{Y}_{\mu,v}^i - \bar{Y}_{\mu,v}) (\bar{Y}_{\mu,v}^i - \bar{Y}_{\mu,v})^T = \frac{1}{M} \sum_{i=1}^C N_i [Z_{\mu,v}^T (\bar{G}_{\mu,v}^i - \bar{G}_{\mu,v})] [Z_{\mu,v}^T (\bar{G}_{\mu,v}^i - \bar{G}_{\mu,v})]^T \quad (7)$$

$$S_{\mu,v}^W = \frac{1}{M} \sum_{i=1}^C \sum_{k=1}^{N_i} (Y_{k,\mu,v}^i - \bar{Y}_{\mu,v}^i) (Y_{k,\mu,v}^i - \bar{Y}_{\mu,v}^i)^T = \frac{1}{M} \sum_{i=1}^C \sum_{k=1}^{N_i} [Z_{\mu,v}^T (G_{k,\mu,v}^i - \bar{G}_{\mu,v}^i)] [Z_{\mu,v}^T (G_{k,\mu,v}^i - \bar{G}_{\mu,v}^i)]^T \quad (8)$$

于是:

$$\text{tr}(S_{\mu,v}^B) = Z_{\mu,v}^T \left[ \frac{1}{M} \sum_{i=1}^C N_i (\bar{G}_{\mu,v}^i - \bar{G}_{\mu,v}) (\bar{G}_{\mu,v}^i - \bar{G}_{\mu,v})^T \right] Z_{\mu,v} = Z_{\mu,v}^T \Psi_{\mu,v}^B Z_{\mu,v} \quad (9)$$

$$\text{tr}(S_{\mu,v}^W) = Z_{\mu,v}^T \left[ \frac{1}{M} \sum_{i=1}^C \sum_{k=1}^{N_i} (G_{k,\mu,v}^i - \bar{G}_{\mu,v}^i) (G_{k,\mu,v}^i - \bar{G}_{\mu,v}^i)^T \right] Z_{\mu,v} = Z_{\mu,v}^T \Psi_{\mu,v}^W Z_{\mu,v} \quad (10)$$

$$\Psi_{\mu,v}^B = \frac{1}{M} \sum_{i=1}^C N_i (\bar{G}_{\mu,v}^i - \bar{G}_{\mu,v}) (\bar{G}_{\mu,v}^i - \bar{G}_{\mu,v})^T \quad (11)$$

$$\Psi_{\mu,v}^W = \frac{1}{M} \sum_{i=1}^C \sum_{m \in C_i} (G_{m,\mu,v}^i - \bar{G}_{\mu,v}^i) (G_{m,\mu,v}^i - \bar{G}_{\mu,v}^i)^T \quad (12)$$

其中  $\bar{G}_{\mu,v}^i$  和  $\bar{G}_{\mu,v}$  分别表示通道  $\mu v$  内第  $i$  类样本的 Log-GaborFaces 特征均值与所有样本的 Log-GaborFaces 特征均值。这样, 式 (6) 可被重写为:

$$J(Z_{\mu,v}) = \frac{Z_{\mu,v}^T \Psi_{\mu,v}^B Z_{\mu,v}}{Z_{\mu,v}^T \Psi_{\mu,v}^W Z_{\mu,v}} \quad (13)$$

显然, 在通道  $\mu v$  的投影矩阵可通过求解  $\Psi_{\mu,v}^{W-1} \Psi_{\mu,v}^B$  的广义特征向量得到, 即  $Z_{\mu,v, \text{opt}} = [\mathbf{z}_{\mu,v,1}, \mathbf{z}_{\mu,v,2}, \dots, \mathbf{z}_{\mu,v,d}]$ , 其中  $\mathbf{z}_{\mu,v,i} (i = 1, 2, \dots, d)$  为  $\Psi_{\mu,v}^{W-1} \Psi_{\mu,v}^B$  前  $d$  个最大特征值对应的特征向量。

### 2.3 特征提取与分类

假设通道  $\mu v$  的最佳投影矩阵为  $X_{\mu,v, \text{opt}}$  与  $Z_{\mu,v, \text{opt}}$ , 将大小为  $m \times n$  的 Log-GaborFaces  $A$  同时投影到  $X_{\mu,v, \text{opt}}$  与  $Z_{\mu,v, \text{opt}}$  可得到一个  $d \times d$  的特征矩阵  $F_{\mu,v}$ :

$$F_{\mu,v} = (Z_{\mu,v, \text{opt}}^T)^T A X_{\mu,v, \text{opt}}; \mu = 0, 1, 2, \dots, 7; v = 0, 1, \dots, 4 \quad (14)$$

这样, 对于一个给定的测试图像  $A$ , 可在 40 个通道分别得到一个特征矩阵, 然后在各个通道内用最近邻分类器对  $A$  进行分类, 最后采用多数票原则对分类结果进行决策, 得到图像  $A$  的最准类别归属。

## 3 实验结果

本文提出的算法的性能在 ORL、Yale 与 CAS-PEAL-R1 人脸数据库上进行评估, 并与 2DPCA、2DLDA、(2D)<sup>2</sup>PCA、(2D)<sup>2</sup>LDA、(2D)<sup>2</sup>PCALDA、Gabor + LDA、Gabor + 2DLDA 方法进行比较。其中 ORL 数据库用来评估算法在人脸的姿态、表情和大小有一定变化条件下的识别性能; Yale 数据库用来评估在光照与表情有变换条件下算法的识别性能; CAS-PEAL-R1 数据库用来评估人脸图像在光照与表情有变化情况下算法的识别性能。

### 3.1 在 CAS-PEAL-R1 数据库上的实验结果

CAS-PEAL-R1 数据库包含 1 040 人的 30 900 幅图像, 分为正面图像子库和姿态图像子库。本实验在正面图像子库的表情变化图像与光照变化图像上进行。表情变化图像包含有 377 人的 1 884 张图像, 除了 1 人有 4 张图像外, 其余 376 人每

人有5张不同表情的图像。光照变化图像包含有233人、每人至少有9种光照变化的图像,本实验选择了199人在9种光照条件下的1791张图像与5种表情变化图像进行测试。为了提高计算效率,本实验将图像一律缩放为 $32 \times 32$ 像素大小,图2给出了一个人的样本图像。



图2 CAS-PEAL-R1数据库一个人样本图像

为了测试算法在光照条件变化时的识别性能,每人选择3种光照条件下的图像作为训练样本,其余6种光照条件下的图像作为测试样本,样本选择如图2所示。图3(a)给出了本文方法、 $(2D)^2PCA$ 、 $(2D)^2LDA$ 、 $(2D)^2PCALDA$ 、2DPCA与2DLDA方法识别率随特征维数变化的曲线;图3(b)给出了本文方法、Gabor+2DLDA与Gabor+LDA识别率随特征维数变化的曲线。从图3不难发现本文方法识别率优于其余方法,当各通道特征维数为 $13 \times 13$ 时达到了最大值87.0%。从实验中也容易发现,基于LDA的方法比基于PCA的方法识别率更高。




图3 在CAS-PEAL-R1数据库光照变化图像上的识别性能比较

其次,每人选择表情变化图像中的前两张作为训练样本,其余3张作为测试样本,对算法进行表情变化条件下的识别性能测试。从图4(a)可以看出,本文方法识别率优于其余5种方法;由于提取了图像的判别信息, $(2D)^2LDA$ 、2DLDA、 $(2D)^2PCALDA$ 方法的识别率也略优于2DPCA与 $(2D)^2PCA$ ;

从图4(b)可以看出,当特征维数较少,本文方法优于Gabor+2DLDA,当特征维数大于20时,本文方法识别率与Gabor+2DLDA的识别率接近,当各通道特征维数为 $5 \times 5$ 时,本文方法识别率达到99.87%。




图4 在CAS-PEAL-R1数据库表情子集上的识别性能比较

### 3.2 在ORL数据库与Yale数据库上的实验结果

ORL人脸数据库有来自40个不同个人的脸图像,每人10张,共400张,图像大小为 $112 \times 92$ 像素。Yale数据库包含有15个不同个人,每人11张,共165张人脸图像,图像大小为 $243 \times 320$ 像素。为了节省存储容量,在实验中将图像缩放至 $64 \times 64$ 像素。

实验中,每人随机选择 $n(n=2,3,4,5,6)$ 个图像作为训练样本,其余图像作为测试样本。为了得到稳定的识别率,在每个 $n$ 下实验独立进行20次,取平均识别率作为 $n$ 个训练样本下的最终识别率。表1与表2分别给出了本文提出方法与 $(2D)^2PCA$ 、 $(2D)^2LDA$ 、 $(2D)^2PCALDA$ 、2DPCA、2DLDA、Gabor+2DLDA、Gabor+LDA方法在ORL与Yale数据库上的最佳平均识别率。

从表1实验结果可看到,在光照变化较小时,各种算法都有较好的识别性能。由于采用了Log-Gabor/Gabor表示,本文方法、Gabor+LDA与Gabor+2DLDA有更好的识别性能。表2的实验结果表明光照变化对 $(2D)^2PCA$ 、 $(2D)^2LDA$ 、 $(2D)^2PCALDA$ 、2DPCA与2DLDA算法识别性能影响较大,由于人脸图像的Log-Gabor/Gabor表示对光照具有一定的鲁棒性,基于Log-Gabor/Gabor表示的3种算法有较好的识别性能。从表2数据也能发现,基于LDA准则的识别方法在光照变化较大时识别性能优于基于PCA的识别方法。从表1与表2的实验结果也能发现,在训练样本数较少时,本文方法明显优于Gabor+LDA与Gabor+2DLDA,这是由于本文采用了多通道策略,从而提取了更多的有用信息。

## 4 结语

通过结合多通道Log-Gabor策略与 $(2D)^2PCALDA$ 特征提取方法,本文提出了一种新的人脸识别方法。与像素灰度



值相比较,Log-Gabor 小波能更好地表征人脸特征,但其产生的高维样本空间对特征提取造成了一定的难度,通过采用多通道策略,将这种高维样本空间分解成多个较低维数的样本空间,这将大大降低算法复杂度。(2D)<sup>2</sup>PCALDA 结合了

2DPCA 与 2DLDA 算法的优点,提取的特征既包含了样本的描述信息又包含了判别信息。在 ORL、Yale 与 CAS-PEAL-R1 数据库上的实验表明,结合本文方法是可行的、有效的与鲁棒的。

表 1 8 种方法在 ORL 数据库上的最佳平均识别率

%

算法	训练样本数					
	2	3	4	5	6	7
本文方法	87.50( $\sigma=1.13$ )	94.07( $\sigma=1.56$ )	96.00( $\sigma=0.97$ )	97.80( $\sigma=1.66$ )	98.50( $\sigma=1.32$ )	99.00( $\sigma=0.89$ )
(2D) <sup>2</sup> PCA	82.41( $\sigma=2.01$ )	89.50( $\sigma=2.16$ )	92.17( $\sigma=2.37$ )	94.95( $\sigma=1.74$ )	96.69( $\sigma=2.97$ )	96.83( $\sigma=2.13$ )
(2D) <sup>2</sup> LDA	83.43( $\sigma=1.71$ )	92.03( $\sigma=2.03$ )	93.55( $\sigma=1.56$ )	96.20( $\sigma=2.17$ )	97.28( $\sigma=1.71$ )	98.42( $\sigma=1.27$ )
(2D) <sup>2</sup> PCALDA	84.36( $\sigma=1.21$ )	92.66( $\sigma=1.45$ )	93.98( $\sigma=1.08$ )	96.02( $\sigma=1.34$ )	97.56( $\sigma=1.67$ )	98.56( $\sigma=1.31$ )
2DPCA	83.06( $\sigma=1.51$ )	88.69( $\sigma=1.20$ )	92.35( $\sigma=1.34$ )	94.10( $\sigma=1.55$ )	96.06( $\sigma=1.34$ )	97.25( $\sigma=1.22$ )
2DLDA	86.75( $\sigma=1.08$ )	90.54( $\sigma=1.17$ )	93.92( $\sigma=1.77$ )	95.40( $\sigma=1.91$ )	96.19( $\sigma=1.28$ )	97.08( $\sigma=0.97$ )
Gabor + LDA	79.56( $\sigma=2.17$ )	91.12( $\sigma=1.49$ )	95.75( $\sigma=2.38$ )	97.36( $\sigma=2.51$ )	98.29( $\sigma=2.03$ )	98.92( $\sigma=1.72$ )
Gabor + 2DLDA	84.33( $\sigma=1.61$ )	93.29( $\sigma=1.29$ )	95.87( $\sigma=1.48$ )	97.38( $\sigma=2.03$ )	98.30( $\sigma=1.77$ )	99.00( $\sigma=1.02$ )

表 2 8 种方法在 Yale 数据库上的最佳平均识别率

%

算法	训练样本数					
	2	3	4	5	6	7
本文方法	84.44( $\sigma=2.78$ )	89.33( $\sigma=3.02$ )	92.67( $\sigma=3.27$ )	93.56( $\sigma=3.81$ )	95.83( $\sigma=3.77$ )	96.22( $\sigma=3.19$ )
(2D) <sup>2</sup> PCA	71.41( $\sigma=3.79$ )	74.42( $\sigma=3.01$ )	77.05( $\sigma=4.11$ )	79.67( $\sigma=4.30$ )	80.33( $\sigma=3.16$ )	80.67( $\sigma=4.27$ )
(2D) <sup>2</sup> LDA	72.45( $\sigma=3.14$ )	83.50( $\sigma=4.05$ )	87.33( $\sigma=3.28$ )	91.22( $\sigma=4.27$ )	92.33( $\sigma=3.30$ )	93.56( $\sigma=3.97$ )
(2D) <sup>2</sup> PCALDA	72.87( $\sigma=2.37$ )	80.06( $\sigma=3.15$ )	84.27( $\sigma=4.06$ )	88.22( $\sigma=2.75$ )	89.97( $\sigma=3.31$ )	91.58( $\sigma=3.07$ )
2DPCA	70.82( $\sigma=4.12$ )	73.01( $\sigma=4.51$ )	76.57( $\sigma=3.78$ )	79.22( $\sigma=3.19$ )	80.69( $\sigma=4.37$ )	80.66( $\sigma=3.41$ )
2DLDA	70.15( $\sigma=4.17$ )	79.75( $\sigma=3.13$ )	84.10( $\sigma=3.76$ )	85.84( $\sigma=3.69$ )	90.13( $\sigma=4.02$ )	90.33( $\sigma=4.15$ )
Gabor + LDA	75.59( $\sigma=4.15$ )	84.29( $\sigma=3.78$ )	89.81( $\sigma=3.24$ )	90.90( $\sigma=4.11$ )	95.80( $\sigma=4.09$ )	96.22( $\sigma=3.21$ )
Gabor + 2DLDA	80.07( $\sigma=4.84$ )	86.04( $\sigma=4.09$ )	89.12( $\sigma=3.67$ )	91.33( $\sigma=3.39$ )	95.67( $\sigma=4.32$ )	96.17( $\sigma=3.68$ )

## 参考文献:

- [1] ASHOK R, NOUSHATH S. Subspace methods for face recognition [J]. Computer Science Review, 2010, 4(1): 1-14.
- [2] 程万里, 李伟生. 基于 Gabor-2DLDA 方法的人脸识别研究[J]. 计算机工程与应用, 2008, 44(35): 179-181.
- [3] WANG LIN, LI YONGPING, WANG CHENGBO, *et al.* 2D Gabor-face representation method for face recognition with ensemble and multichannel model [J]. Image and Vision Computing, 2008, 26(6): 820-828.
- [4] LIU CHENGJUN, WECHSLER H. Gabor feature based classification using the enhanced Fisher linear discriminant model for face recognition [J]. IEEE Transactions on Image Processing, 2002, 11(4): 467-476.
- [5] QI YONGFENG, ZHANG JIASHU. (2D)<sup>2</sup>PCALDA: An efficient approach for face recognition [J]. Applied Mathematics and Computation, 2009, 213(1): 1-7.
- [6] WANG JIAN, ZHANG D, FRANGI A F, *et al.* Two-dimensional PCA: A new approach to appearance based face representation and recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-137.
- [7] LI MING, YUAN BAOZONG. 2D-LDA: A statistical linear discriminant analysis for image matrix [J]. Pattern Recognition Letters, 2005, 26(5): 527-532.
- [8] ZHANG DAOQIANG, ZHOU ZHI-HUA. (2D)<sup>2</sup>PCA: Two-directional two-dimensional PCA for efficient face representation and recognition [J]. Neurocomputing, 2005, 69(1/3): 224-231.
- [9] NOUSHATH S, H KUMAR G, SHIVAKUMAR P. (2D)<sup>2</sup>LDA: An efficient approach for face recognition [J]. Pattern Recognition, 2006, 39(7): 1396-1400.
- [10] FIELD D J. Relations between the statistics of natural images and the response properties of cortical cells [J]. Journal of Optical Society of America, 1987, 4(12): 2374-2394.

(上接第 2951 页)

- [3] JOHNSON T, KWOK I, NG R. Fast computation of 2-dimensional depth contours [C]// Proceedings of the fourth International Conference on Discovery and Data Mining. New York: AAAI, 1998: 224-228.
- [4] KNORR E M, NG R T. Algorithms for mining distance-based outliers in large datasets [C]// Proceedings of the 24th VLDB Conference. San Francisco: Morgan Kaufmann, 1998: 392-403.
- [5] HAWKINS D. Identification of outliers [M]. London: Chapman and Hall, 1980.
- [6] YAMANISHI K, TAKEUCHI J. A unifying framework for detecting outliers and change points from non-stationary time series data [C]// Proceedings of the eighth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2002: 676-681.
- [7] MUTHUKRISHNAN S, SHAH R, VITTER J S. Mining deviants in time series data streams [C]// Proceedings of the 16th International Conference on Scientific and Statistical Database Management. Washington, DC: IEEE Computer Society, 2004: 41-51.
- [8] HAN F, WANG Y M, WANG H P. Odabk: An effective approach to detecting outlier in data stream [C]// Proceedings of the Fifth International Conference on Machine Learning and Cybernetics. Washington, DC: IEEE, 2006: 1036-1041.
- [9] 周晓云, 孙志挥, 张柏礼, 等. 高维类别属性数据流离群点快速检测[J]. 软件学报, 2007, 18(4): 933-942.
- [10] HULTEN G, SPENCER L, DOMIGOS P. Mining time-changing data streams [C]// Proceedings of the 7th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2001: 97-106.
- [11] 李洋, 方滨兴, 郭莉, 等. 基于只推式方法的网络异常检测方法[J]. 软件学报, 2007, 18(10): 2595-2604.