

# 融合小波变换和张量 PCA 的人脸识别算法

温 浩, 卢朝阳, 高全学

(西安电子科技大学 综合业务网理论及关键技术国家重点实验室, 陕西 西安 710071)

**摘要:** 张量主成分分析(PCA)方法用于人脸识别能获得比 PCA 方法更高的识别率. 小波变换具有良好的时频分析特性, 同时还能起到降维的作用. 综合利用这两个算法的优点, 提出了一种新的人脸识别算法, 对人脸图像先采用小波变换做预处理得到 4 个子带图像, 然后对每个子带图像用张量 PCA 进行特征提取, 实现人脸图像的高效识别. 仿真结果表明, 新算法的识别率比张量 PCA 方法提高了 6%, 识别时间为张量 PCA 方法的 35.74%.

**关键词:** 人脸识别; 张量主成分分析; 小波变换; 特征提取

**中图分类号:** TP391.41 **文献标识码:** A **文章编号:** 1001-2400(2009)04-0602-06

## Face recognition algorithm based on wavelet preprocessing and tensor PCA

WEN Hao, LU Zhao-yang, GAO Quan-xue

(State Key Lab. of Integrated Service Networks, Xidian Univ., Xi'an 710071, China)

**Abstract:** The accuracy rate of the face recognition by tensor PCA is higher than that by PCA. And wavelet has two abilities to capture localized time-frequency information and to reduce the dimension of images. According to the two advantages of the above algorithms, a new face recognition algorithm based on wavelet transform and tensor PCA is proposed. Wavelet transform is firstly used and then tensor PCA is used to extract the feature of subband images, and the efficient recognition of face images can be realized. The recognition rate of the proposed algorithm is 6% higher than that of the tensor PCA algorithm, and the recognition time of the proposed algorithm is 35.74% that of the tensor PCA algorithm, which is illustrated in experimental results.

**Key Words:** face recognition; tensor principal component analysis; wavelet transforms; feature extraction

人脸图像是每个人固有的生物特征, 与指纹、虹膜等其他生物特征图像相比, 人脸图像具有采集方式友好, 采集设备隐蔽性高等优点, 所以人脸识别在身份识别、检索、安全监控等方面有着广泛的应用, 是模式识别领域的一个研究热点<sup>[1-2]</sup>. 对人脸图像进行有效的特征提取是人脸识别的关键因素之一. 人脸识别的特征提取方法可分为基于几何特征和基于统计特征, 近些年来提出人脸特征提取方法大都是基于统计特征<sup>[2]</sup>. 其中, 主成分分析(PCA)方法是一种经典的基于统计特征的方法<sup>[3]</sup>. Kirby 等<sup>[4]</sup>和 Turk 等<sup>[5]</sup>首次把 PCA 方法引入到人脸识别中. PCA 方法进行特征提取的主要思想是: 把人脸图像展开成高维的列或行向量, 然后根据这些向量组成的训练样本来计算训练样本的协方差矩阵的特征向量所组成的投影矩阵, 最后通过投影矩阵把原始训练样本的高维向量投影成低维向量. 这样就会造成两个问题: (1) 图像展开成向量破坏了图像的原始空间结构; (2) 图像展开成高维向量容易造成“维数灾”, 并且需要大量的存储空间和计算量来求解样本的协方差矩阵. 近年来发展的张量 PCA 人脸识别算法<sup>[6-8]</sup>解决了 PCA 算法的两个不足, 提高了识别率.

小波变换有良好的时频局部化能力<sup>[9]</sup>, 在数字图像处理领域得到了广泛的应用. 文献<sup>[10-11]</sup>提出了采用二维离散小波变换(2D-DWT)对人脸图像进行特征提取. 2D-DWT 在图像处理中的应用主要是通过图像的多尺度分解将当前图像分解成 4 个子带图像, 每个子带图像的面积为当前图像的 1/4. 其中的一个子带图

收稿日期: 2008-12-10

基金项目: 国家自然科学基金资助(60802075)

作者简介: 温 浩(1979-), 男, 西安电子科技大学博士研究生, E-mail: smczg@162.com.

像对应图像的低通部分保留了当前图像的主要信息,而其他 3 个子带图像对应当前图像的高通部分保留了当前图像的细节信息.文献[10-11]的不足之处是只保留了低频部分而舍弃了其他 3 个子带,而这 3 个子带对识别能起到辅助作用.

为了有效地提取人脸图像的特征,笔者融合了 2D-DWT 和张量 PCA 方法,提出了一种新的人脸识别方法.该方法首先对人脸图像做小波变换,然后再用张量 PCA 方法进行特征提取,进行更有效地识别.笔者在 3 个不同的人脸图像库进行了实验,即 ORL<sup>[12]</sup>,UMIST<sup>[13]</sup>和笔者所在的实验室采集的人脸图像库(简称自建库),实验结果表明笔者的方法提高了识别率并且具有较高的识别速度.

## 1 小波变换

小波变换是一种常用的数字图像处理工具.一维离散信号的小波变换是一个一维信号和一组高通和低通滤波器组成的滤波器组进行卷积,每个滤波器具有“下二采样性质”<sup>[9]</sup>.小波变换的每一级的输入是上一级低通滤波器的输出.可表示为

$$D_{WT_{x(n)}} = \begin{cases} d_{j,k} = \sum x(n)h_j^*(n-2^j k) & , \\ a_{j,k} = \sum x(n)g_j^*(n-2^j k) & , \end{cases} \quad (1)$$

其中  $d_{j,k}$  对应信号的细节部分, $a_{j,k}$  对应信号的近似部分; $h(n)$  和  $g(n)$  分别代表小波的高通和低通滤波器.

二维离散小波变换是一维离散小波变换的扩展.一幅图像经过一层二维离散小波变换后的图像被分成了 4 个子带:LL(低频部分),LH(水平低频,垂直高频部分),HL(水平高频,垂直低频部分),HH(对角线方向上的高频部分),LL 部分反映了图像的近似特征,而其他子带反映了图像的细节特征.因为离散小波变换具有“下二采样”性质,所以每个子带图像的长宽为原始图像的一半,对图像有降维的作用.后续若干层 2D-DWT 都对上一层的 LL 部分进行变换.

图 1 表示了两层 2D-DWT 的基本过程.图 2 是“ORL”库中的一幅图像和它经过一层小波变换的结果,其中左边的图像是原始图像,右边的图像是经过小波变换后的 4 个子带图像.从图 2 中可以看出,“LL”部分保留了原始图像的主体信息,其他 4 子带图像保留了部分边缘信息.

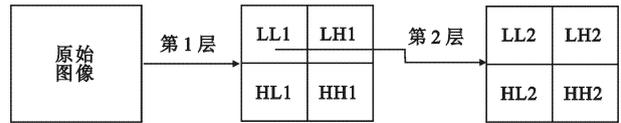


图 1 两层小波变换示意图

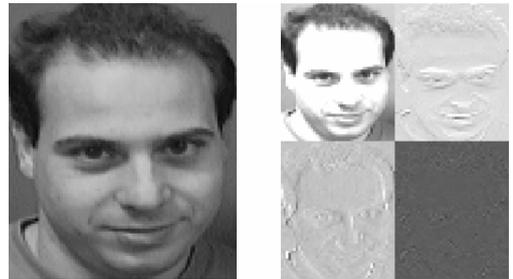


图 2 “ORL”库中图像和一层小波变换图像

## 2 张量 PCA

经过小波变换后的每个子带图像还需要进一步的特征提取,而每个子带图像是一个矩阵或者是一个二阶张量,所以这里采用二阶张量 PCA 方法对每个子带图像进行特征提取.二阶张量 PCA 方法不需要把图像展开成向量,这样能充分利用原始图像的空间结构也避免了“维数灾”出现.假设一个图像矩阵为  $\mathbf{X} \in \mathfrak{R}^{W \times H}$ ,用二阶张量 PCA 方法对  $\mathbf{X}$  进行特征提取就是要得到两个投影矩阵  $\mathbf{U} \in \mathfrak{R}^{W \times l_1}$  和  $\mathbf{V} \in \mathfrak{R}^{H \times l_2}$ ,把  $\mathbf{X}$  投影到低维矩阵子空间

$$\mathbf{Y} = \mathbf{U}^T \mathbf{X} \mathbf{V} \in \mathfrak{R}^{l_1 \times l_2} \quad (2)$$

两个投影矩阵  $\mathbf{U}, \mathbf{V}$  的最佳解是通过计算  $\mathbf{Y}$  和  $\mathbf{X}$  的最小重构平方误差而得到的<sup>[10]</sup>, $\mathbf{U}, \mathbf{V}$  的最佳解和  $\mathbf{X}, \mathbf{Y}$  之间的关系为

$$(\mathbf{U}^*, \mathbf{V}^*) = \arg \min_{\mathbf{U}, \mathbf{V}} \|\mathbf{U} \times \mathbf{Y} \times \mathbf{V}^T - \mathbf{X}\|_F^2 \quad (3)$$

上式中的  $\|\cdot\|_F$  表示矩阵的 Frobenius 范数.  $\mathbf{U}, \mathbf{V}$  闭合形式的最佳解,可以通过循环迭代得到<sup>[14]</sup>.文献[14]给出了求解  $\mathbf{U}, \mathbf{V}$  的步骤.但是文献[14]给出求解方法的前提假设是训练样本的均值矩阵为全 0 矩阵,并且文献[14]方法需要计算样本与样本之间相关度的协方差矩阵.笔者认为:(1)实际中的训练样本很难满足零

均值条件；(2)小波变换已经对人脸图像做了降维处理，即使直接用原始的人脸图像矩阵计算得到的协方差矩阵的维数也是比较低的，而文献[14]的算法在训练样本数量较多时也会产生高维的协方差矩阵。所以参照文献[15]并对文献[14]中的迭代过程做了改进，计算两个投影矩阵的具体迭代过程如下：

输入：样本集合  $\mathbf{X} = \{\mathbf{X}_i | \in \mathfrak{R}^{W \times H}\}, i = 1, 2, \dots, n$ , 最大化迭代次数： $T$ 。

输出：投影矩阵  $\mathbf{U}_{(t)} \in \mathfrak{R}^{W \times l}, \mathbf{V}_{(t)} \in \mathfrak{R}^{H \times m}$ 。

初始化设置： $\mathbf{U}_{(t)} = \mathbf{I}(W, l), \mathbf{V}_{(t)} = \mathbf{I}(H, m)$  (可以假定  $\mathbf{U}_{(t)}$  或  $\mathbf{V}_{(t)}$  其中之一为单位矩阵，另一个不用设置。为了编程方便  $\mathbf{U}_{(t)}$  和  $\mathbf{V}_{(t)}$  做了相同的设置)， $t = 1$  时， $\mathbf{U}_{(t)}$  和  $\mathbf{V}_{(t)}$  分别为  $W \times l$  和  $H \times m$  的单位矩阵； $\mathbf{Y} = \{\mathbf{Y}_i | \in \mathfrak{R}^{l \times H}\}, \mathbf{Z} = \{\mathbf{Z}_i | \in \mathfrak{R}^{W \times m}\}, \mathbf{Y}$  和  $\mathbf{Z}$  中的所有元素全为“0”。

for  $t = 1$  to  $T$  {  $\mathbf{Y}_i = (\mathbf{U}_{(t)})^T \times \mathbf{X}_i$ ;

计算  $\mathbf{Y}$  的均值矩阵： $\mathbf{E}_Y = \frac{1}{n} \sum_{i=1}^n \mathbf{Y}_i$ ;

计算  $\mathbf{Y}$  的协方差矩阵： $\mathbf{C}_Y = \frac{1}{n} \sum_{i=1}^n (\mathbf{Y}_i - \mathbf{E}_Y)^T (\mathbf{Y}_i - \mathbf{E}_Y)$ ;

计算  $\mathbf{C}_Y$  的特征值和特征向量： $\mathbf{C}_Y \mathbf{V}_{(t)} = \mathbf{A} \mathbf{V}_{(t)}$ ,

$\mathbf{A} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_m)$  为  $\mathbf{C}_Y$  的前  $m$  个最大特征值组成的对角阵， $\mathbf{V}$  为这些特征值对应的特征向量组成的矩阵；

$\mathbf{Z}_i = \mathbf{X}_i \times \mathbf{V}_{(t)}$ ;

计算  $\mathbf{Z}$  的均值矩阵： $\mathbf{E}_Z = \frac{1}{n} \sum_{i=1}^n \mathbf{Z}_i$ ;

计算  $\mathbf{Z}$  的协方差矩阵： $\mathbf{C}_Z = \frac{1}{n} \sum_{i=1}^n (\mathbf{Z}_i - \mathbf{E}_Z)(\mathbf{Z}_i - \mathbf{E}_Z)^T$ ;

计算  $\mathbf{C}_Z$  的特征值和特征向量： $\mathbf{C}_Z \mathbf{U}_{(t+1)} = \mathbf{A} \mathbf{U}_{(t+1)}$ ,

$\mathbf{A} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_l)$  为  $\mathbf{C}_Z$  的前  $l$  个特最大征值组成的对角阵， $\mathbf{U}_{(t+1)}$  为这些特征值对应的特征向量组成的矩阵；

} end for

当迭代循环超过 5 或 6 次时， $\mathbf{U}_{(t)}$  和  $\mathbf{V}_{(t)}$  的值就不再变化，这时的  $\mathbf{U}_{(t)}$  和  $\mathbf{V}_{(t)}$  的值就是所要求的投影矩阵  $\mathbf{U}$  和  $\mathbf{V}$ 。所以  $T$  的值一般设置成 7。

### 3 融合小波变换和张量 PCA 人脸识别算法及其实现过程

根据张量 PCA 方法和离散二维小波变换两种线性变换的优点，笔者提出了一种融合小波变换和张量 PCA 方法人脸图像识别算法。即首先采对人脸图像做离散二维小波变换得到 4 个子带图像，然后再用张量 PCA 对小波子带图像做特征提取，最后用“最近邻”方法进行识别。图像经过小波变换后的“LL”子带保留了大量的原始图像信息，而其他 3 个子带图像分别保留了部分细节特征。每个子带对识别的贡献不同所以给它们赋予不同的权值，权值满足下面的计算公式：

$$\omega_1 + \omega_2 + \omega_2 + \omega_4 = 1 \quad (4)$$

其中  $\omega_1, \omega_2, \omega_3, \omega_4$  分别对应“LL”，“LH”，“HL”，“HH”的权值。 $\omega_1$  赋予较大的权值。下面给出文中算法的具体实现过程。

图 3 中的“训练样本图像”是从图像库中的每类图像中抽取的一些图像组成的。相应的这个类别中的另一些样本作为测试样本；由所有的训练样本组成的集合构成训练样本集，由所有的测试样本组成的集合构成测试样本集。假设用  $X_i$  表示训练样本集中的某一幅图像，用  $X_j$  表示测试样本集中的某一幅图像，那么框图中的“待识别图像”就是  $X_j$ 。对于每一个  $X_i$  经过“二维离散小波变换”得到 4 个子图，再经过“张量 PCA”特征提取后得到 4 个特征矩阵： $\mathbf{Y}_{i1}, \mathbf{Y}_{i2}, \mathbf{Y}_{i3}, \mathbf{Y}_{i4}$ ；所有的训练样本图像经过上述变换后得到的 4 个特征矩阵一起构成图 3 中的“训练样本特征集合”框图。对于某个  $X_j$  也要经过“二维离散小波变换”和“张量 PCA”特征提取后得到 4 个特征矩阵： $\mathbf{Y}_{j1}, \mathbf{Y}_{j2}, \mathbf{Y}_{j3}, \mathbf{Y}_{j4}$ ，这 4 个矩阵组成图 3 中的“待识别图像特征”。最后计算“待识别图像特征”和“训练样本特征集合”中的所有训练样本特征矩阵之间的距离，根据和  $X_j$  距离最小的  $X_i$  的所属

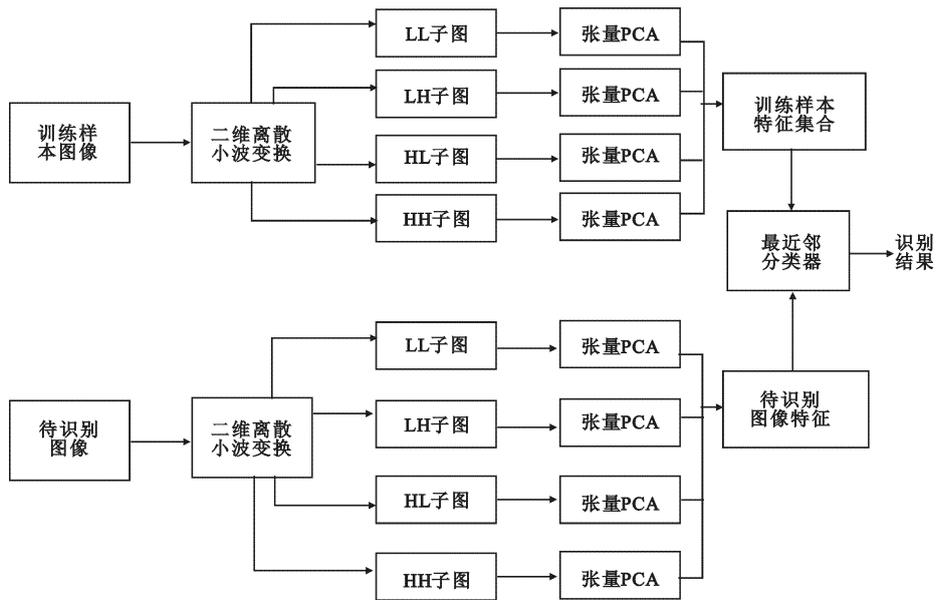


图 3 文中算法实现框图

类别来判定  $X_j$  的所属类别,即得出“识别结果”.采用下面的公式来计算测试样本特征矩阵和训练样本特征矩阵之间的距离:

$$\begin{aligned} \text{dist}(X_j, X_i) &= \omega_1 \text{dis}(\mathbf{Y}_{j1}, \mathbf{Y}_{i1}) + \omega_2 \text{dis}(\mathbf{Y}_{j2}, \mathbf{Y}_{i2}) + \omega_3 \text{dis}(\mathbf{Y}_{j3}, \mathbf{Y}_{i3}) + \omega_4 \text{dis}(\mathbf{Y}_{j4}, \mathbf{Y}_{i4}) \quad , \\ \text{s. t. } \omega_1 + \omega_2 + \omega_3 + \omega_4 &= 1 \quad . \end{aligned} \quad (5)$$

式(5)中的  $\text{dis}(\cdot)$  算子的计算方法如下:假设  $\mathbf{X} \in \mathfrak{R}^{W \times H}$ ,  $\mathbf{Y} \in \mathfrak{R}^{W \times H}$ ,

$$\text{dis}(\mathbf{X}, \mathbf{Y}) = \sum_{i=1}^W \left( \sum_{j=1}^H (x_{ij} - y_{ij})^2 \right)^{1/2} . \quad (6)$$

## 4 实验仿真与分析

采用 3 种人脸图像数据库进行实验,这 3 种数据库分别是:“ORL”,“UMIST”和“自建库”.“ORL”库是

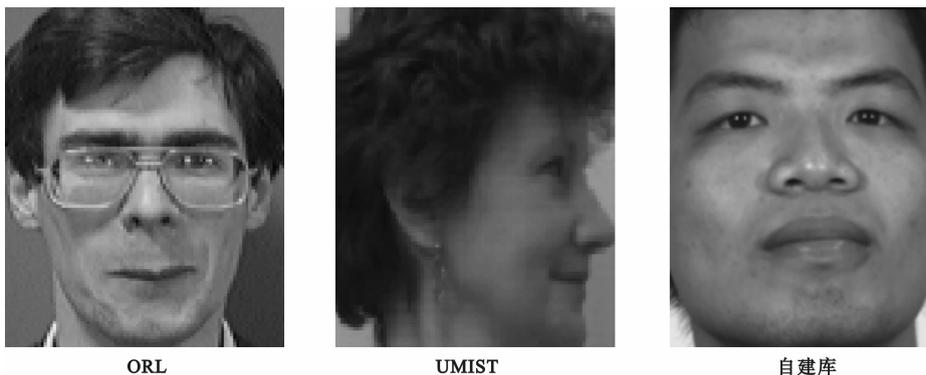


图 4 数据库中部分图像

一种常用的人脸实验数据库.它由 40 个人,每个人 10 幅  $112 \times 92$  的灰度人脸正面图像组成,每张人脸图像的表情姿势和光照都有细微的变化.“UMIST”库由 20 个人的从不同角度拍摄的人脸图像组成,每个人的图像数目不同,选取每个人的前 16 张图像进行实验.“自建库”是由 11 个人组成,每个人 6 幅  $520 \times 400$  的人脸正面灰度图像组成.图 4 中给出了以上 3 种数据库中的部分样本的图像.

图 4 中,第 1 幅为“ORL”库中的某个图像,第 2 幅为“UMIST”库中的某个图像.第 3 幅为“自建库”中某个图像.根据不同的数据中的图象维数的不同,采取不同层数的小波变换以得到较低维数的子带图像.对于

“ORL”和“UMIST”库,采用一层小波变换,而对“自建库”采用 3 层小波变换,保留最后一层变换得到的 4 个子带图像做进一步处理.为了验证文中算法的有效性,也采用了其他的一些算法进行比较,实验结果见表 1~3.所采用的实验环境是 IBM Pentium(R)笔记本电脑,编程语言为 MATLAB6.5.

表 1 在 ORL 库上的实验结果比较

方法	每个类别训练样本数	每个类别测试样本数	特征维数	正确识别率/%	每个样本平均识别时间/ms
文中方法 *	2	8	60×4	90.0625	8.90
	3	7	60×4	92.5000	14.00
	5	5	60×4	96.0000	31.70
张量 PCA 方法	2	8	68	87.8125	20.75
	3	7	64	89.2857	32.70
	5	5	48	94.5000	57.42
PCA 方法	2	8	69	82.5000	1.40
	3	7	107	86.0714	3.00
	5	5	183	90.5000	6.70

\*  $\omega_1$  为 0.75,  $\omega_2$  为 0.10,  $\omega_3$  为 0.10,  $\omega_4$  为 0.05.

表 2 在 UMIST 库上的实验结果比较

方法	每个类别训练样本数	每个类别测试样本数	特征维数	正确识别率/%	每个样本平均识别时间/ms
文中方法 *	4	12	34×4	78.750	6.3
	5	11	33×4	79.090	7.2
	8	8	33×4	88.125	11.8
张量 PCA 方法	4	12	60	72.500	22.8
	5	11	76	76.800	29.2
	8	8	72	84.375	47.8
PCA 方法	4	12	51	64.167	1.7
	5	11	54	67.727	1.4
	8	8	62	72.500	2.5

\*  $\omega_1$  为 0.85,  $\omega_2$  为 0.05,  $\omega_3$  为 0.05,  $\omega_4$  为 0.05.

表 3 在“自建库”上的实验结果比较

方法	每个类别训练样本数	每个类别测试样本数	特征维数	正确识别率/%	每个样本平均识别时间/ms
文中方法 *	3	3	42×4	78.790	17.30
张量 PCA 方法	3	3	133	72.730	58.50
PCA 方法	3	3	32	66.667	31.24

\*  $\omega_1$  为 0.7,  $\omega_2$  为 0.10,  $\omega_3$  为 0.10,  $\omega_4$  为 0.10.

“ORL”库和“UMIST”库中每个类别中的样本数目较多,每个类别采用 3 组不同的训练样本数和测试样本数进行实验,“自建库”中的样本数量较少,只采用一组训练样本和测试样本数进行实验.又因为“UMIST”库中每个类别的样本相对于“ORL”库中每个类别样本数目较多,所以实验中“UMIST”库的训练样本数比“ORL”库的多.表格中“文中方法”对应的特征维数“×4”是采用了 4 个子带图像,而每个子带图像经过特征提取后得到的维数是相同的,“×”左边表示达到最高识别率时每个子带的特征维数.由表 1~3 中的数据可见,文中的算法在 3 种数据库上的识别率都优于其他方法,在同等条件下,识别率都明显高出其他方法几个百分点.识别速度也是比较高的.虽然文中方法提取的特征的维数明显高于其他两种方法,但是识别速度却没有降低.这是因为通过二维小波变换后,只有“LL”子带的矩阵是非稀疏的,而“LL”子带是原始图像的维数的 1/4 或 1/64,而其他子带图像矩阵都是稀疏矩阵,所以后续的计算量减少,识别速度会提高,所有实验的平均识别时间为张量 PCA 方法的 35.74%.从表格中也可以看出,在相同的数据库中,选用不同的训练和测试样本数目时,达到最高识别率的样本的特征维数基本是固定的.实验选用的所有方法在“ORL”库上的识别率是最高的,在“UMIST”和“自建库”上的识别率都相对较低.这是因为“ORL”库中的图像表情,姿势等细节特征变化比较少,而其他两个库的变化较大.“UMIST”库每类中的相邻两个图像的角度变化不大,但所有图像组成的序列角度变化很大,前 8 幅基本可以看作是侧面图像,而后 8 幅基本可以看作是正面图像.所以

采用前几幅做训练后几幅做测试进行实验识别率不会很高。“自建库”中每类中每个图像的表情和姿势变化很大,眼睛和嘴部的区别都很明显,并且每类中的第5幅和第6幅图像较前4幅有明显戴饰物区别,第5幅是戴眼镜的图像,第6幅是戴帽子的图像。其他两个库中没有出现这样的情况。所以“自建库”的识别率不高。

## 5 结束语

人脸识别是模式识别学科中的一个研究热点,如何对人脸图像进行有效地特征提取是人脸识别的关键。笔者提出了一种融合小波变换和张量PCA的人脸识别方法。该方法利用张量PCA方法对小波变换后的子图像矩阵进行特征提取,得到了具有良好分类能力的图像特征。在国际通用人脸库和笔者所在实验室建立的人脸库上的实验表明,笔者的方法具有比其他相关方法好的性能。

### 参考文献:

- [1] Chellapp A R, Wilson C L, Srohey S. Human and Machine Recognition of Faces: a Survey[J]. Proc IEEE, 1995, 83(5): 705-741.
- [2] 刘青山, 卢汉青, 马颂德. 综述人脸识别中的子空间方法[J]. 自动化学报, 2003, 129(16): 900-911.  
Liu Qingshan, Lu Hanqing, Ma Songde. A Survey: Subspace Analysis for Face Recognition[J]. ACTA Automatica Sinica, 2003, 129(16): 900-911.
- [3] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs Fisherfaces: Recognition Using Class Specific Linearprojection[J]. IEEE Trans on Pattern Anal Machine Intell, 1997, 19(7): 711-720.
- [4] Kirby M, Sirovich L. Application of the Karhunen-Loeve Procedure for the Characterization of Human Faces[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1990, 12(1): 103-108.
- [5] Turk M, Pentland A. Eigenfaces for Recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1): 72-86.
- [6] Xu D, Yan S, Zhang L, et al. Concurrent Subspace Analysis[C]//Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). San Diego: IEEE, 2005: 203-208.
- [7] He Xiaofei, Cai Deng, Niyogi P. Tensor Subspace Analysis[EB/OL]. [2008-7-1]. [http://books.nips.cc/papers/files/nips18/NIPS2005\\_0249.pdf](http://books.nips.cc/papers/files/nips18/NIPS2005_0249.pdf)
- [8] Yan Shuicheng, Xu Dong, Lin Stephen, et al. Element Rearrangement for Tensor-Based Subspace Learning[C]//Proceedings of the 2007 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'07). Minneapolis: IEEE, 2007: 1-8.
- [9] Mallat S G. A Theory for Multiresolution Signal Decomposition the Wavelet Representation[J]. IEEE Trans on Pattern Analysis and Machine Intelligence 1989 11(7): 674-693.
- [10] Puyati W, Walairacht S, Walairacht A. PCA in Wavelet Domain for Face Recognition[C]//The 8th International Conference on Advanced Communication Technology, ICACT 2006. Phoneix Park: IEEE, 2006: 450-456.
- [11] Chien J T, Wu C C. Discriminant Wavelet Faces and Nearest Feature Classifiers for Face Recognition for Face Recognition[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2002, 24(12): 1644-1649.
- [12] AT&T Laboratories, Cambridge, U K. The ORL Face Database. [DB/OL]. [2008-07-10]. <http://www.orl.co.uk/facedatabase.html>
- [13] University of Manchester Institute of Science and Technology. The UMIST Face Database. [DB/OL]. [2008-07-10]. <http://images.ee.umist.ac.uk/danny/database.html>
- [14] Xu D, Yan S, Zhang L, et al. Coupled Subspaces Analysis[EB/OL]. [2008-07-10]. <ftp://ftp.research.microsoft.com/pub/tr/TR-2004-106.pdf>
- [15] Tao Dacheng, Li Xuelong, Wu Xindong, et al. General Tensor Li Discriminant Analysis and Gabor Features for Gait Recognition[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2007, 29(10): 1700-1715.

(编辑: 齐淑娟)