第 39 卷 第 12 期
Vol.39 No.12

计 算 机 工 程
Computer Engineering

2013 年 12 月
December 2013

·人工智能及识别技术· 文章编号：1000—3428(2013)12—0191—05 文献标识码：A 中图分类号：TP18

M-FPCA 在彩色人脸图像识别中的应用

王 赟[1a,1b,1c]，朱嘉钢[1a,1b,1c]，陆 晓[1c]，黄可望[2]

(1. 江南大学 a. 物联网工程学院；b. 物联网应用技术教育部工程研究中心；c. 晓山股份联合实验室，江苏 无锡 214122；
2. 无锡职业技术学院物联网技术学院，江苏 无锡 214122)

摘 要：将因子化主成分分析(FPCA)算法应用于人脸图像特征提取时，需要使用迭代算法，但该算法应用于高分辨率图像时实时性较差，并且可能导致维数灾难。针对上述问题，提出一种模块化 FPCA(M-FPCA)的新型特征提取方法。将原始数字图像样本进行模块化，对模块化后得到的各个子图像矩阵采用 FPCA 算法进行特征提取，合并子图像特征矩阵得到原图的特征矩阵。彩色图像由 R、G、B 3 个分量来表示，根据现有彩色信息融合方法的不足，对其进行改进，并结合 M-FPCA 算法，提出一种彩色 M-FPCA 新方法。在 CVL 和 FEI 人脸库上进行的实验结果表明，M-FPCA 方法能提高 FPCA 算法的实时性，解决维数灾难问题。彩色 M-FPCA 方法能有效提取彩色人脸图像的色彩信息，得到较高的人脸识别率。

关键词：主成分分析；因子化主成分分析；模块化 FPCA；彩色 M-FPCA；特征提取；彩色图像识别

Application of M-FPCA in Color Face Image Recognition

WANG Yun[1a,1b,1c], ZHU Jia-gang[1a,1b,1c], LU Xiao[1c], HUANG Ke-wang[2]

(1a. School of IoT Engineering; 1b. Engineering Research Center of IoT Applied Technology, Ministry of Education; 1c. Hillsun-Ltd Co-laboratory, Jiangnan University, Wuxi 214122, China; 2. School of IoT Technology, Wuxi Institute of Technology, Wuxi 214122, China)

【Abstract】Using Factored Principal Components Analysis(FPCA) feature extraction algorithm in the high resolution images has bad real-time performance and may cause dimension disaster because it needs to use iterative algorithm to implement FPCA algorithm. In order to solve the problem above, this paper developes a new method called Modular-FPCA(M-FPCA) for image feature extraction. This method modularizes the original digital image samples, implements FPCA algorithm on every sub-image matrix, and gets feature matrix of original image by merging sub-image features. Color images can be represented by three components of R, G, B. For existing shortcomings of color information fusion method, it combines M-FPCA with the improved color information fusion method and names it as color M-FPCA. Experimental results on CVL, FEI color face image library show that M-FPCA method can improve the realation of FPCA algorithm, solve dimesion disaster problems, color M-FPCA method extracts color information from color face image effectively, and has higher recognition rate.

【Key words】Principal Components Analysis(PCA); Factored PCA(FPCA); Modular-FPCA(M-FPCA); color M-FPCA; feature extraction; color image recognition

DOI: 10.3969/j.issn.1000-3428.2013.12.041

1 概述

人脸图像是高维数据，而实际上人脸图像在这样的高维空间中的分布很不紧凑，直接在原始图像基础上进行人脸识别，不但加大了算法的计算复杂度，并且对计算机的硬件性能也是一个挑战。因此，做好数据的特征提取(矩阵降维)是人脸识别技术的一个基本而又十分重要的环节，也是解决人脸识别问题的关键。到目前为止，人们研究出了许多种特征提取方法[1]。

文献[2]将主成分分析(Principal Component Analysis, PCA)法应用于人脸图像的特征提取，并成为最经典且运用最广泛的线性特征提取方法。在此基础上，为了能直接压缩矩阵的行和列，文献[3-5]提出了二维主成分分析(Two Dimensional Principal Component Analysis, 2DPCA)法。根据文献[6]提出的使用二级迭代估计正态分布矩阵参数的算法，文献[7]提出一种新型的具有统计学基础的特征提取方法，称之为因子化主成分分析(FPCA)。此方法在理论上较之于其他 PCA 方法有更好的泛化性能。但是使用 FPCA 算法对图像样本训练需要使用迭代计算，这使得 FPCA 算法的实时性能变差，应用场合局限于低分辨率的黑白图像。

基金项目：国家自然科学基金资助项目(61170120)；江苏省自然科学基金资助项目(BK2011147)

作者简介：王 赟(1986－)，男，硕士研究生，主研方向：图像处理，模式识别；朱嘉钢，副教授；陆 晓，本科生；黄可望，硕士研究生

收稿日期：2012-12-03 **修回日期：**2012-12-27 **E-mail：**wangyun86@hotmail.com

随着各类彩色高清摄像头的普及，FPCA 算法在处理这些高维数据时往往会面临维数灾难，致使算法不能正确执行。本文借鉴文献[8-10]中将原图像模块化之后再进行特征提取的思想，提出了一种模块化 FPCA(M-FPCA)算法。模块化的方法是将大矩阵分成若干个小矩阵，再对各个小矩阵运用 FPCA 特征提取，这样做有利于减小特征提取算法的时间复杂度及空间复杂度，有效避免维数灾难。FPCA 算法提取的是图像的全局特征，当图像中人脸的表情和光照变化较大时，使用模块化特征提取算法可以捕捉人脸的局部信息特征，有利于人脸识别。

文献[11-13]将彩色人脸图像应用于人脸识别，并提出了一种色彩信息融合的方法。本文改进已有的色彩信息融合方法，并将其与 M-FPCA 结合，应用于彩色人脸图像的特征提取，可取得较好的识别率。

2 因子化主成分分析

2.1 正态分布矩阵的最大似然法参数估计

服从正态分布的 $r\times c$ 维矩阵组成的样本集合如下：$\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_n$，记作 $\boldsymbol{X}\sim N_{r,c}(\boldsymbol{M},\boldsymbol{U},\boldsymbol{V})$，其中，参数 $\boldsymbol{M}$ 是 $r\times c$ 的矩阵；$\boldsymbol{U}$ 是 $r\times r$ 的矩阵；$\boldsymbol{V}$ 是 $c\times c$ 的矩阵。$\boldsymbol{X}$ 的概率密度函数可以写成：

$$f_X(\boldsymbol{X})=c^{-1}\exp\left\{-\frac{1}{2}tr\left[\boldsymbol{U}^{-1}(\boldsymbol{X}-\boldsymbol{M})\boldsymbol{V}^{-1}(\boldsymbol{X}-\boldsymbol{M})^{\mathrm{T}}\right]\right\} \tag{1}$$

其中，$c=(2\pi)^{(1/2)rc}|\boldsymbol{U}|^{(1/2)c}|\boldsymbol{V}|^{(1/2)r}$。

本文使用最大似然估计法来估计参数，$\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_n$ 是服从正态分布的独立随机矩阵组成的样本集合。根据 $\boldsymbol{X}$ 的概率密度函数可以得到对数似然函数为：

$$L=-\frac{rcn}{2}\ln(2\pi)-\frac{cn}{2}\ln|\boldsymbol{U}|-\frac{rn}{2}\ln|\boldsymbol{V}|-\frac{1}{2}\sum_{i=1}^{n}\left\{\boldsymbol{U}^{-1}(\boldsymbol{X}_i-\boldsymbol{M})\boldsymbol{V}^{-1}(\boldsymbol{X}_i-\boldsymbol{M})^{\mathrm{T}}\right\} \tag{2}$$

使用最大似然估计法来估计参数，$\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_n$ 是服从正态分布的独立随机矩阵组成的样本集合。根据 $\boldsymbol{X}$ 的概率密度函数可以得到对数似然函数为：

$$\hat{\boldsymbol{M}}=\frac{1}{n}\sum_{i=1}^{n}\boldsymbol{X}_i \tag{3}$$

$$\begin{cases}\hat{\boldsymbol{U}}=\dfrac{1}{cn}\displaystyle\sum_{i=1}^{n}(\boldsymbol{X}_i-\bar{\boldsymbol{X}})\hat{\boldsymbol{V}}^{-1}(\boldsymbol{X}_i-\bar{\boldsymbol{X}})^{\mathrm{T}}\\ \hat{\boldsymbol{V}}=\dfrac{1}{rn}\displaystyle\sum_{i=1}^{n}(\boldsymbol{X}_i-\bar{\boldsymbol{X}})^{\mathrm{T}}\hat{\boldsymbol{U}}^{-1}(\boldsymbol{X}_i-\bar{\boldsymbol{X}})\end{cases} \tag{4}$$

对式(4)的求解没有可以使用的解析解法，但是可以使用文献[6]中提出的二级迭代算法求解。其方法描述如下：

第 1 步

$$\boldsymbol{V}_-=\boldsymbol{V}_0$$

$$\boldsymbol{U}_-=\frac{1}{cn}\sum_{i=1}^{n}(\boldsymbol{X}_i-\bar{\boldsymbol{X}})\boldsymbol{V}_-^{-1}(\boldsymbol{X}_i-\bar{\boldsymbol{X}})^{\mathrm{T}}$$

第 2 步

$$\boldsymbol{V}_+=\frac{1}{rn}\sum_{i=1}^{n}(\boldsymbol{X}_i-\bar{\boldsymbol{X}})^{\mathrm{T}}\boldsymbol{U}_-^{-1}(\boldsymbol{X}_i-\bar{\boldsymbol{X}})$$

$$\boldsymbol{U}_+=\frac{1}{cn}\sum_{i=1}^{n}(\boldsymbol{X}_i-\bar{\boldsymbol{X}})\boldsymbol{V}_+^{-1}(\boldsymbol{X}_i-\bar{\boldsymbol{X}})^{\mathrm{T}}$$

第 3 步

若 $\|\boldsymbol{U}_+-\boldsymbol{U}_-\|_2>\varepsilon_1$ 或 $\|\boldsymbol{V}_+-\boldsymbol{V}_-\|_2>\varepsilon_2$，则 $\boldsymbol{U}_-=\boldsymbol{U}_+$；$\boldsymbol{V}_-=\boldsymbol{V}_+$ 重复第 2 步。

第 4 步

迭代结束，求解结果为：$\hat{\boldsymbol{U}}=\boldsymbol{U}_+;\hat{\boldsymbol{V}}=\boldsymbol{V}_+$。

上述算法表示经过若干次迭代计算之后，$\boldsymbol{U}_+$ 和 $\boldsymbol{U}_-$、$\boldsymbol{V}_+$ 和 $\boldsymbol{V}_-$ 会逐渐逼近。在某一次迭代后，当 $\boldsymbol{U}_+$ 和 $\boldsymbol{U}_-$ 的欧氏距离小于临界值 ε_1 时，并且同时 $\boldsymbol{V}_+$ 和 $\boldsymbol{V}_-$ 的欧氏距离小于临界值 ε_2 时，停止迭代。把当前的 $\boldsymbol{U}_+$ 和 $\boldsymbol{V}_+$ 看作是方程组的解。$\boldsymbol{V}_-$ 的初值，这里可以用单位矩阵 $\boldsymbol{I}_c$。

2.2 人脸图像特征提取

对于包含足够多人脸图像的样本集，可以认为其中的各样本图像是独立且符合正态分布的矩阵，所以可以运用上述最大似然法估计正态分布矩阵的参数，求出估计参数 $\hat{\boldsymbol{U}}$ 和 $\hat{\boldsymbol{V}}$。

然后对 $\hat{\boldsymbol{U}}$ 和 $\hat{\boldsymbol{V}}$ 作频谱分解，得：

$$\hat{\boldsymbol{U}}=\boldsymbol{\Gamma}_r\boldsymbol{\Lambda}_r\boldsymbol{\Gamma}_r^{\mathrm{T}} \tag{5}$$

$$\hat{\boldsymbol{V}}=\boldsymbol{\Gamma}_c\boldsymbol{\Lambda}_c\boldsymbol{\Gamma}_c^{\mathrm{T}} \tag{6}$$

为了能得到 $\hat{\boldsymbol{U}}$ 的 q 行主成分，和 $\hat{\boldsymbol{V}}$ 的 s 列主成分，取：

$$\boldsymbol{A}_q=\left[(\boldsymbol{\Gamma}_r)_1,(\boldsymbol{\Gamma}_r)_2,\cdots,(\boldsymbol{\Gamma}_r)_q\right],r\times q \tag{7}$$

$$\boldsymbol{B}_s=\left[(\boldsymbol{\Gamma}_c)_1,(\boldsymbol{\Gamma}_r)_2,\cdots,(\boldsymbol{\Gamma}_c)_s\right],c\times s \tag{8}$$

这样，对每个图像样本可以得到其降维后的特征矩阵为：

$$\boldsymbol{S}_i=\boldsymbol{A}_q^{\mathrm{T}}\left(\boldsymbol{X}_i-\hat{\boldsymbol{M}}\right)\boldsymbol{B}_s,i=1,2,\cdots,n \tag{9}$$

其中，$\hat{\boldsymbol{M}}$ 表示人脸图像的总体均值估计；$\boldsymbol{S}_i$ 是大小为 $q\times s$ 的特征矩阵，其包含了图像样本矩阵 $\boldsymbol{X}_i$ 的主要信息。对不同类别的人脸分类也就是对不同 $\boldsymbol{S}_i$ 的分类，在后续实验中使用最临近法来分类。

以上这种线性特征提取方法被称为 FPCA 算法。由文献[7]的理论推导可知 2DPCA 是其一种特例，相当于当人脸图像矩阵在行方向上压缩时，列方向上的向量看作相互独立；当人脸图像矩阵在列方向上压缩时，行方向上的向量看作相互独立。这时，FPCA 就退化成了 2DPCA。但在实际应用中，人脸图像不会满足上述特殊情况，所以在理论上，FPCA 是一种更具有泛化能力的特征提取算法。

3 模块化 FPCA

模块化FPCA的思想是先将一个 $m\times n$ 的图像矩阵 $\boldsymbol{X}$ 分成 $p\times q$ 的分块图像矩阵(相当于矩阵分块)，即：

$$\boldsymbol{X}=\begin{pmatrix}\boldsymbol{X}_{11} & \boldsymbol{X}_{11} & \cdots & \boldsymbol{X}_{1q}\\ \boldsymbol{X}_{21} & \boldsymbol{X}_{12} & \cdots & \boldsymbol{X}_{2q}\\ \vdots & \vdots & & \vdots\\ \boldsymbol{X}_{p1} & \boldsymbol{X}_{p2} & \cdots & \boldsymbol{X}_{pq}\end{pmatrix}$$

其中，每个子图像矩阵 $\boldsymbol{X}_{ij}$ 是 $m_1\times n_1$ 矩阵，$pm_1=m$，$qn_1=n$。假如原始图像样本集合为 $\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_N$，模块化之后，子图像矩阵分别为 $(\boldsymbol{X}_1)_{ij},(\boldsymbol{X}_2)_{ij},\cdots,(\boldsymbol{X}_N)_{ij}$，$i=1,2,\cdots,p$，$j=1,2,\cdots,q$。然后用 FPCA 方法分别对每个子图像矩阵训练投影矩阵 $\boldsymbol{A}_{ij},m_1\times m_2$ 和 $\boldsymbol{B}_{ij},n_1\times n_2$。最后特征矩阵为：

$$\boldsymbol{S}=\begin{pmatrix}\boldsymbol{A}_{11}^{\mathrm{T}}\left(\boldsymbol{X}_{11}-\overline{\boldsymbol{X}_{11}}\right)\boldsymbol{B}_{11} & \cdots & \boldsymbol{A}_{1q}^{\mathrm{T}}\left(\boldsymbol{X}_{1q}-\overline{\boldsymbol{X}_{1q}}\right)\boldsymbol{B}_{1q}\\ \vdots & & \vdots\\ \boldsymbol{A}_{p1}^{\mathrm{T}}\left(\boldsymbol{X}_{p1}-\overline{\boldsymbol{X}_{p1}}\right)\boldsymbol{B}_{p1} & \cdots & \boldsymbol{A}_{pq}^{\mathrm{T}}\left(\boldsymbol{X}_{pq}-\overline{\boldsymbol{X}_{pq}}\right)\boldsymbol{B}_{pq}\end{pmatrix} \tag{10}$$

其中，$\overline{\boldsymbol{X}_{ij}}$ 表示 $\boldsymbol{X}_{ij}$ 的训练样本均值；$\boldsymbol{S}$ 大小为 $pm_2\times n_2q$。图 1 是以模块数为 4 的灰度图像特征提取流程。

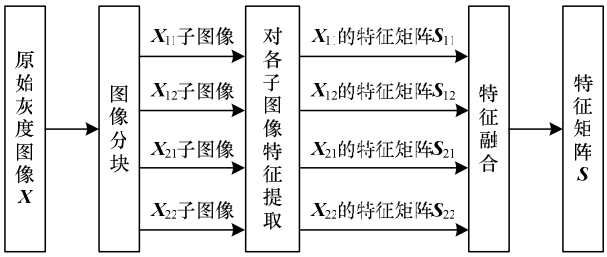


图 1　灰度图像特征提取流程

4　彩色图像的特征提取

上述特征提取方法都是基于灰度图像矩阵的。要将模块化 FPCA 应用于彩色图像，需要将基于 RGB 颜色空间的彩色图像融合为对应的二维矩阵。目前主要方法有：(1)利用彩色图像 *R*、*G*、*B*3 个颜色分量不同的比重，通过对 3 个颜色分量二维矩阵的加权得到二维的灰度矩阵，此类方法将彩色图像退化为灰度图像，可以直接使用灰度图像特征提取和识别算法，但是它忽略了彩色图像中的色彩信息，所以识别率不高；(2)先对彩色图像 *R*、*G*、*B* 3 个颜色分量的二维矩阵提取特征，再将这 3 组特征整合成最终的特征矩阵进行识别，此类方法对彩色图像 *R*、*G*、*B* 3 个颜色分量分别提取特征值，破坏了色彩信息的结构，忽略了彩色图像 3 个颜色分量之间的相关性，因此，识别性能也不佳。

本文改进了文献[11]中的色彩信息融合方法，克服了现有彩色图像融合到二维矩阵方式的缺点，又结合了模块化思想提出了一种应用于彩色图像特征提取的彩色 M-FPCA 方法。

一幅分辨率为 $m\times n$ 的彩色图像，在计算机里以一个 $m\times n\times 3$ 的三维数组表示，令其为 $\boldsymbol{Y}$、$\boldsymbol{R}$、$\boldsymbol{C}$ 3 个颜色分量矩阵分别用 $\boldsymbol{R}$、$\boldsymbol{G}$、$\boldsymbol{B}$ 3 个矩阵表示。将 $\boldsymbol{Y}$ 分成 $p\times q$ 的分块图像矩阵(相当于三维数组分块)，即：

$$\boldsymbol{Y}=\begin{pmatrix}\boldsymbol{Y}_{11} & \boldsymbol{Y}_{11} & \cdots & \boldsymbol{Y}_{1q}\\ \boldsymbol{Y}_{21} & \boldsymbol{Y}_{12} & \cdots & \boldsymbol{Y}_{2q}\\ \vdots & \vdots & & \vdots\\ \boldsymbol{Y}_{p1} & \boldsymbol{Y}_{p2} & \cdots & \boldsymbol{Y}_{pq}\end{pmatrix}$$

其中，每个彩色子图像矩阵 $\boldsymbol{Y}_{ij}$ 是一个 $m_1\times n_1\times 3$ 数组，$pm_1=m$，$qn_1=n$。将彩色子图像矩阵 $\boldsymbol{Y}_{ij}$ 融合为二维矩阵后可表示为大小为 $m_1\times 3n_1$ 的矩阵 $\boldsymbol{Z}_{ij}=\left(\boldsymbol{R}_{ij}\quad\boldsymbol{G}_{ij}\quad\boldsymbol{B}_{ij}\right)$。假如原始图像样本集合为 $\boldsymbol{Y}_1,\boldsymbol{Y}_2,\cdots,\boldsymbol{Y}_n$，进行模块化之后，子图像矩阵分别为 $(\boldsymbol{Y}_1)_{ij},(\boldsymbol{Y}_2)_{ij},\cdots,(\boldsymbol{Y}_N)_{ij}$，$i=1,2,\cdots,p$，$j=1,2,\cdots,q$。再将彩色子图像矩阵分别融合成二维矩阵后为 $(\boldsymbol{Z}_1)_{ij},(\boldsymbol{Z}_2)_{ij},\cdots,(\boldsymbol{Z}_N)_{ij}$，然后用 FPCA 方法分别对 $(\boldsymbol{Z}_1)_{ij},(\boldsymbol{Z}_2)_{ij},\cdots,(\boldsymbol{Z}_N)_{ij}$ 训练投影矩阵 $\boldsymbol{C}_{ij},m_1\times m_2$ 和 $\boldsymbol{D}_{ij},n_1\times n_2$。最后特征矩阵为：

$$\boldsymbol{S}=\begin{pmatrix}\boldsymbol{C}_{11}^{\mathrm{T}}\left(\boldsymbol{Z}_{11}-\overline{\boldsymbol{Z}_{11}}\right)\boldsymbol{D}_{11} & \cdots & \boldsymbol{C}_{1q}^{\mathrm{T}}\left(\boldsymbol{Z}_{1q}-\overline{\boldsymbol{Z}_{1q}}\right)\boldsymbol{D}_{1q}\\ \vdots & & \vdots\\ \boldsymbol{C}_{p1}^{\mathrm{T}}\left(\boldsymbol{Z}_{p1}-\overline{\boldsymbol{Z}_{p1}}\right)\boldsymbol{D}_{p1} & \cdots & \boldsymbol{C}_{pq}^{\mathrm{T}}\left(\boldsymbol{Z}_{pq}-\overline{\boldsymbol{Z}_{pq}}\right)\boldsymbol{D}_{pq}\end{pmatrix} \tag{11}$$

其中，$\overline{\boldsymbol{Z}_{ij}}$ 表示 $\boldsymbol{Z}_{ij}$ 的训练样本均值；$\boldsymbol{S}$ 大小为 $pm_2\times n_2q$。图 2 为模块数以 4 为例的彩色图像特征提取流程。

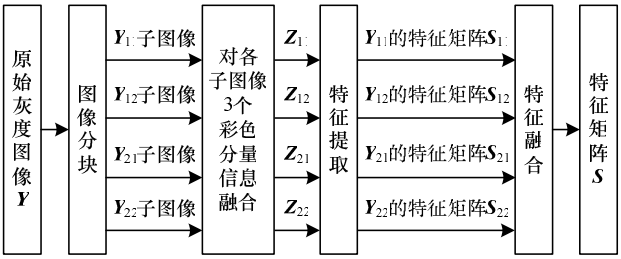


图 2　彩色图像特征提取流程

5　实验及结果分析

5.1　实验环境

实验所用的计算机为 Intel(R)Core(TM)2 Duo CPU E4400，2.00 GHz, 1 GB 内存，软件环境为 Microsoft Windows XP Professional 版本 2002，SP2 操作系统，MatlabR2009b 仿真平台。

5.2　人脸数据库

CVL 人脸库是由 114 人、每人 7 幅图像组成的彩色人脸库。其中包括不同年龄、不同性别的人。在这些图像中，人的脸部表情和脸部细节有着不同程度的变化；人脸姿态也有相当程度变化。图像的分辨率是 640×480 像素。选取每人的 3 幅前视图作为实验图像，如图 3(a)所示，将 3 幅前视图截取人脸有效部分，作为标准人脸图像，分辨率为 81×81 像素，如图 3(b)所示。实验从 3 幅图像样本中随机抽取一张作为测试样本，其余 2 张作为训练样本。



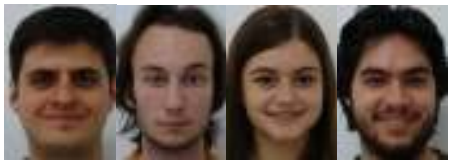
(a)CVL 人脸库中某人的 3 幅前视原始图像



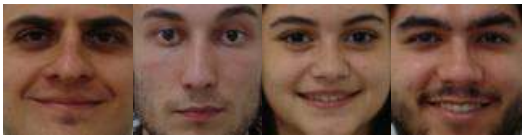
(b)某人的标准图像

图 3 CVL 人脸数据库例图

FEI 人脸数据库是由 200 人、每人 14 幅图像组成的彩色人脸数据库。图像的分辨率是 640×480 像素。本文实验中采用 FEI 人脸数据库的子集，此数据库由 200 人，每人 2 幅前视图(一幅表情中立，另一幅微笑)，同样对其截取标准图像，分辨率为 81×81 像素，如图 4 所示。在实验中从每个人的 2 幅图片中随机抽取一张作为训练样本，另一张作为测试样本，这样训练样本和测试样本均为 200 个。



(a)FEI 人脸库中部分正面图



(b)部分标准图像

图 4 FEI 人脸数据库例图

5.3 实验结果

以下实验基于上述 CVL、FEI2 个人脸库。实验中使用的 CVL、FEI 数据库的灰度图是运用公式 Gray=R×0.299+G×0.587+B×0.114 由彩色图像转换得到的。以下有关模块化特征提取算法的实验数据均是在将原图像尽可能均等分为 4 个子图像块的基础上得到的。本文使用的 CVL、FEI 数据库中的标准图像分辨率都是 81×81 像素，模块化后的 4 个子图像块的大小分别为：40×41，40×40，41×41，41×40。最后，经过特征提取的特征矩阵利用最临近分类器实现分类，即实现人脸识别。

表 1 中的 d 表示 2DPCA 及其扩展算法的投影轴数。q、s 分别表示 FPCA 及其扩展算法提取出的特征矩阵的行数和列数。表 2~表 4 中 d、q、s 意义同表 1。

表 1 不同算法在 CVL 人脸库上的识别率

d	2DPCA 及其扩展算法/(%)			(q, s)	FPCA 及其扩展算法/(%)		
	2DPCA	M-2DPCA	彩色 M-2DPCA		FPCA	M-FPCA	彩色 M-FPCA
2	77.27	76.36	76.36	(4,4)	57.27	70.00	71.82
4	83.64	79.09	77.27	(6,4)	63.64	74.55	80.91
6	80.91	80.00	79.09	(6,6)	70.91	80.91	83.64
8	82.73	83.64	80.91	(6,8)	73.64	80.00	84.55
10	80.91	81.82	80.00	(8,6)	77.27	84.55	87.27
12	80.91	81.82	80.91	(10,6)	76.36	84.55	86.36
14	81.82	81.82	80.91	(8,8)	78.18	82.73	85.45
16	81.82	80.91	80.91	(10,8)	77.27	84.55	88.18
18	81.82	81.82	81.82	(10,10)	78.18	83.64	89.09

表 2 不同算法在 FEI 人脸库上的识别率

d	2DPCA 及其扩展算法/(%)			(q, s)	FPCA 及其扩展算法/(%)		
	2DPCA	M-2DPCA	彩色 M-2DPCA		FPCA	M-FPCA	彩色 M-FPCA
2	71.50	73.00	77.50	(4,4)	57.50	54.00	53.00
4	82.00	79.00	83.50	(6,4)	64.50	61.00	62.00
6	84.50	81.50	85.50	(4,6)	67.00	77.50	78.50
8	85.50	83.50	86.00	(6,6)	71.00	82.00	84.00
10	85.50	83.50	87.00	(6,8)	74.00	84.00	87.00
12	85.00	85.50	88.00	(8,6)	71.50	83.50	87.50
14	85.00	85.50	89.00	(8,8)	75.00	85.00	89.00
16	85.00	85.50	89.00	(10,8)	81.00	85.50	90.00

表 3 特征提取算法与对应模块化算法性能的比较

参数	CVL				FEI			
	2DPCA	M-2DPCA	FPCA	M-FPCA	2DPCA	M-2DPCA	FPCA	M-FPCA
最佳投影	d=4	d=8	q=8,s=8	q=8,s=6	d=8	d=12	q=10,s=8	q=10,s=8
最高识别率/(%)	83.64	83.64	78.18	84.55	85.50	85.50	81.00	85.50
训练时间/s	0.066 0	0.070 4	3.558 9	2.190 8	0.102 0	0.068 3	3.249 0	2.771 8
识别时间/s	0.009 6	0.011 0	0.004 3	0.004 5	0.010 0	0.011 5	0.004 0	0.004 1
总时间/s	0.075 6	0.081 4	3.563 2	2.195 3	0.112 0	0.079 8	3.253 0	2.775 9
训练样本个数	2	2	2	2	1	1	1	1

注：最佳投影表示当识别率最高时对应的特征提取算法的投影方式，即 2DPCA 及其扩展算法的最小投影轴数 d，FPCA 及其扩展算法提取出的特征矩阵的最小行数 q 和最小列数 s。

表 4 特征提取算法压缩率比较

特征提取算法	CVL			FEI		
	最佳投影	最高识别率/(%)	压缩率	最佳投影	最高识别率/(%)	压缩率
2DPCA	d=4	83.64	1/20.25	d=8	85.50	1/10.13
M-2DPCA	d=8	83.64	1/10.13	d=12	85.50	1/6.75
彩色 M-2DPCA	d=18	81.82	1/13.50	d=14	89.00	1/17.36
FPCA	q=8,s=8	78.18	1/102.52	q=10,s=8	81.00	1/82.01
M-FPCA	q=8, s=6	84.55	1/136.69	q=10,s=8	85.50	1/82.01
彩色 M-FPCA	q=10,s=10	89.09	1/196.83	q=10,s=8	90.00	1/246.04

注：一副图像大小为 $M\times N$，特征提取之后得到的特征矩阵大小为 $m\times n$，表 4 中的灰度图的压缩率为$(m\times n)/(M\times N)$；彩色图的压缩率为$(m\times n)/(3M\times N)$。

5.4 结果分析

实验结果分析如下：

(1)从表 1、表 2 可以看出，在 CVL 和 FEI 2 个灰度图像数据库上，M-2DPCA 特征提取算法得到的识别率相比 2DPCA 没有明显提升；然而 M-FPCA 特征提取算法得到的识别率相比 FPCA 提升明显。经仔细分析发现，在 CVL 库上识别率平均提升超过 8 个百分点；在 FEI 库上识别率平均提升超过6个百分点。由此可以看出，模块化思想与FPCA算法结合更能体现出各自的优势。模块化特征提取算法有利于保留图像局部信息，FPCA 在特征抽取方面有更好的泛化能力。两者结合得到 M-FPCA 算法，并最终大大提高了图像识别率。

在 CVL 数据库上，经彩色 M-2DPCA 得到的识别率比灰度 M-2DPCA 没有明显提升。但是，在 CVL 和 FEI 库上的其余实验中，彩色模块化算法得到的识别率相比于灰度模块化算法平均提高超过 4 个百分点。在 FEI 库上的实验中可以看到，彩色 M-FPCA 和灰度 M-FPCA 这 2 个方法都将原图像压缩至10×8的特征矩阵，且同样使用最临近分类法，由彩色 M-FPCA 得到的识别率比灰度 M-FPCA 高出了 4.5 个百分点，这是由于引入了图像的色彩信息。以上分析说明，本文使用的彩色信息融合方法能够有效地保留图像色彩信息，并且这些色彩信息在特征矩阵分类时被有效利用，最终提高了识别率。

(2)从表 3 中可以看到，在 CVL 和 FEI 2 个灰度人脸数据库上，当各算法实现最佳投影时，模块化特征提取算法总体上都比原始的非模块化特征提取算法实时性强。只有在 CVL 库上 M-2DPCA 的实时性略逊于 2DPCA。分析其原因为：M-2DPCA 的最佳投影轴数为 8，是 2DPCA 的 2 倍，所以计算量本来就会更大。上述实验结果表明，M-2DPCA 算法训练时间比 2DPCA 多用 0.004 4 s，也是符合实际情况的。从表 3 实验数据中可以发现，特征提取算法与对应模块化算法识别时间几乎相等，这是因为 2 种算法提取出的特征矩阵是一样大的，并且使用了同样的最临近分类法。由以上实验数据分析可以得到结论，特征提取算法结合模块化思想能缩短特征提取的训练时间。

(3)对图像的压缩率能表明图像特征提取方法的优劣。从表 4 中可以看到，基于彩色图片的模块化特征提取算法的压缩率普遍较小。而且经过这么小压缩率的特征提取之后，其识别率依然比其他方法高。这说明彩色 M-FPCA 是低压缩率的优秀特征提取算法。

6 结束语

本文提出一种新的应用于彩色图像 M-FPCA 的特征提取算法。理论分析和实验结果都证明了其优越性，主要表现在：(1)模块化思想有助于特征提取算法提取图像的局部信息，有利于提高图像识别率。(2)将模块化思想引入到 FPCA 中，A 算法运行于小矩阵样本上能避免 FPCA 算法可能导致的维数灾难，提高 FPCA 算法的实时性。尤其是基于彩色图像的 M-FPCA 算法实时性能提升更为明显。(3)改进的色彩信息融合方法结合 M-FPCA 算法，能在特征矩阵中保留图像的色彩信息。同样大小的特征矩阵，同样经过最临近法分类。包含色彩信息的特征矩阵的识别率明显提高。值得注意的是：M-FPCA 及彩色 M-FPCA 方法只是图像特征提取方法，如果该方法能与支持向量机、神经网络等方法相结合，则可以取得更高的图像识别率。文中默认将原始图像近似均等地分为 4 个子图像，如何模块化使识别率更高是下一步需要研究的内容。

参考文献

[1] 边肇其, 张学工. 模式识别[M]. 2 版. 北京: 清华大学出版社, 2000.

[2] Turk M, Pentland A. Face Recognition Using Eigenfaces[J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86.

[3] Yang Jian, Zhang D, Frangi A F, et al. Two-dimensional PCA: A New Approach to Appearance-based Face Representation and Recognition[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-137.

[4] Zhang Haiyang. A Comparison of PCA and 2DPCA in Face Recognition[J]. Electrical Power Systems and Computers, 2011, 99(1): 445-449.

[5] Kong H. Generalized 2D Principal Component Analysis for Face Image Representation and Recognition[J]. Neural Networks, 2005, 18(5/6): 585-594.

[6] Dutilleul P. The MLE Algorithm for the Matrix Normal Distribution[J]. Journal of Statistical Computation and Simulation, 1999, 64(2): 105-123.

[7] Ian L, Dryden C L, Li Bai, et al. Factored Principal Components Analysis, with Applications to Face Recognition[J]. Statistics and Computing, 2009, 19(3): 229-238.

(下转第 199 页)