

一种自适应加权变形的 2DPCA 人脸识别方法

曾 岳 冯大政

(西安电子科技大学雷达信号处理国家重点研究所 西安 710071)

摘 要 为了充分利用图像矩阵的局部信息和更多的鉴别信息,以提高 2DPCA 的识别率,提出了一种自适应加权变形的 2DPCA 人脸识别方法。该方法将人脸图像矩阵分块,然后利用变形的 2DPCA 方法提取特征,接着自适应地计算每个分块在分类中的权值,最后根据类别的权值大小进行分类。在 ORL 人脸库中进行的实验研究表明,该方法在正确识别率和识别时间上更优于传统的 2DPCA 和模块化 2DPCA。

关键词 自适应,人脸识别,识别率,分块

中图分类号 TP75 文献标识码 A

Adaptive Weighted Variational 2DPCA for Face Recognition

ZENG Yue FENG Da-zheng

(The State Key Lab of Radar Signal Processing, Xidian University, Xi'an 710071, China)

Abstract For full using of local information and more discriminative information of the image matrix to improve the recognition rate of 2DPCA, an adaptive weighted variational 2DPCA for face recognition was presented, which partitions its subpatterns from an original whole image, extracts features from them in the variational 2DPCA, adaptively computes the weight of each subpattern in classification, finally makes classification in terms of weight of each classification. The experiments on ORL face bases show this algorithm is also superior to the traditional 2DPCA and Modular 2DPCA in terms of the recognition accuracy and recognition time.

Keywords Adaptation, Face recognition, Recognition rate, Partitioning

1 引言

自动人脸识别已经有 40 多年的历史,成为了模式识别和计算机视觉最有效的研究领域之一,在理论、模型和算法上取得了很大的进步^[1-3],并且已经开发出了很多应用系统。在这些系统中,最流行的算法还是 PCA 或基于 PCA 的方法。尽管已经取得了很大的成功,但有些问题还有待进一步研究,第一,将一个矩阵图像转化为一个列向量;第二,基于 PCA 的方法识别率比较低,不能满足实际的要求;第三,它只利用图像的一些全局信息。为了解决这些问题,研究者提出了一些方法。其中最好的方法之一就是杨等人于 2004 年提出的 2DPCA 人脸识别方法^[4],它能减轻计算的复杂性,提高人脸识别的准确率,随后 Visaniet 等人也证明了 2DPCA 具有很好的健壮性^[5]。后来为了提高 2DPCA 方法的性能,又提出了许多算法^[6-8]。Nguyen 等人^[9]提出了一个随机子空间的 2DPCA 方法,它将 2DPCA 和随机子空间技术结合起来,利用这种方法不仅考虑到了最大的特征向量,也考虑到了非零特征值的特征向量,这种方法显示了比传统的方法更高的识别率。Pan 和 Ruan^[10]提出了利用基于 Gabor 小波特征的(2D) 2PCA 掌纹识别方法。Yu^[11]等人将 2DPCA 水平投影和垂直

投影的信息应用于 LDA(线性鉴别分析)进行人脸识别。Yu 和 Bennamoun^[12]提出了一种基于高阶奇异值分解的 nD-PCA 方法。Lu 等人^[13]提出了一种新的方法,即是降维和特征提取的多线性 PCA 方法应用于步态识别。Tao 等人对子空间选择的几何平均研究。

但 2DPCA 方法也有不足之处,第一,2DPCA 方法相对于 PCA 方法来说丢失了一些协方差信息,这些协方差对图像局部结构鉴别信息的反映,对人脸识别起着很重要的作用,充分利用这些协方差信息可以提高图像的识别率^[14],第二,2DPCA 方法需要用更多的系数来表示一张图像^[4]。文献^[15]提出一种改进的模块 2DPCA 人脸识别方法(IM2DPCA),该方法将图像样本分成若干个子图像,然后求训练样本图像的子图像矩阵的总体散度矩阵,计算最优投影矩阵,接着将训练样本投影到最优投影空间以求得训练样本的特征矩阵,最后用最近距离分类器与测试样本进行分类。该方法在一定程度上减少了图像表示的系数,提高了 2DPCA 方法的识别率,但其仅仅利用了从子图像里提取的局部信息,并不重视不同子图像在分类过程中所起的作用不同,也就是说,它认为所有子图像在分类过程中所起的作用一样,因此全局信息里很有可能包含一些没有用的局部信息,它降低了最

到稿日期:2010-12-16 返修日期:2011-03-22 本文受国家自然科学基金(60372049),江西省科技计划青年基金(GJJ09412)资助。

曾 岳(1972-),男,博士生,副教授,主要研究方向为模式识别、智能网络;冯大政(1959-),男,教授,博士生导师,主要研究方向为阵列图像处理。

后的分类性能。文献[16]提出了一种加权的模块化 2DPCA 方法,该方法根据每类子图像在分类中所起的作用赋不同的权值,但这个权值是通过实验估计的,不能准确地计算。

鉴于此,本文提出一种自适应加权变形的 2DPCA 方法(AWV2DPCA),它直接将人脸图像分割成若干个子图像集,相同位置的子图像形成一个集合,然后直接提取子图像集的特征,并根据特征自适应地计算每个子图像集在分类的权值,根据权值的大小计算测试样本的类别。该方法弥补了以上方法的不足,不仅考虑了人脸图像空间上相关的信息,也考虑了不同的子图像在分类过程所起的作用不同。

本文第 2 节提出变形的 2DPCA;第 3 节提出了自适应加权变形的 2DPCA 方法;第 4 节在 ORL 库上进行试验研究;最后是结论。

2 变形的 2DPCA

在此,我们首先求基于图像列方向的协方差矩阵,假设 X_j 是一个 $m \times n$ 随机矩阵的第 j 个样本, $\bar{X} = (\frac{1}{M}) \sum_{j=1}^M X_j$ 是总体均值矩阵。式(1)中 x_j^i 是 X_j 的第 i 列向量, \bar{x}^i 是 \bar{X} 的第 i 列向量。令

$$X_j = [x_j^1, x_j^2, \dots, x_j^n] \quad \bar{X} = [\bar{x}^1, \bar{x}^2, \dots, \bar{x}^n] \quad (1)$$

定理 1 C^{2D} 是随机 $m \times n$ 图像矩阵 X_j 的基于 2DPCA 方法的协方差矩阵,如式(2)所示。

$$C^{2D} = \frac{1}{M} \sum_{j=1}^M \sum_{i=1}^m (x_j^i - \bar{x}^i)^T (x_j^i - \bar{x}^i) = C_{1,1}^{2D} + C_{2,2}^{2D} + C_{3,3}^{2D} + \dots + C_{n,n}^{2D} \quad (2)$$

式中, $C_{i,i}^{2D}$ 定义如式(3), $C_{i,i}^{2D} \in R^{n \times n}$ 是训练样本第 i 列的协方差矩阵。

$$C_{i,i}^{2D} = \frac{1}{M} \sum_{k=1}^M (x_k^i - \bar{x}^i)^T (x_k^i - \bar{x}^i) \quad (3)$$

证明(略)。

定理 2 $C^{1D} \in R^{(m \times n) \times (m \times n)}$ 为随机 $m \times n$ 图像矩阵 X_j 的基于 PCA 方法的协方差矩阵,被分解为子矩阵如下:

$$C^{1D} = \begin{bmatrix} C_{1,1}^{1D} & C_{1,2}^{1D} & \dots & C_{1,n}^{1D} \\ C_{2,1}^{1D} & C_{2,2}^{1D} & \dots & C_{2,n}^{1D} \\ \vdots & \vdots & \ddots & \vdots \\ C_{n,1}^{1D} & C_{n,2}^{1D} & \dots & C_{n,n}^{1D} \end{bmatrix} \quad (4)$$

证明(略)。

从式(2)得知 C^{2D} 是式(4)中 C^{1D} 每行的主对角线元素的相加,因此可知 C^{2D} 损失了一些非对角线元素,这些非对角线元素反映的是图像局部结构信息,对人脸识别起很重要的作用。充分利用这些非对角线上的元素,可以提高人脸的识别率。为了利用非对角线上的元素,本文提出了一种变形的协方差矩阵。

定义 1 $\rho = \{j | j = \text{count}(\lambda_i), \lambda_i \text{ 为 } C^{1D} \text{ 对角线上的元素}\}$ 。

定义 2 变形后协方差矩阵 C^{V2D} 在 C^{1D} 协方差矩阵中,在主对角线上顺序选取 $\rho = k$ 个元素,以这 k 个元素为正方形对角线,向 C^{1D} 的主对角线上下延拓,构成正方形。依次构成全

体正方形所含的协方差信息的集合。

当 $\rho = 1$ 时,变形的协方差矩阵 C^{V2D} 只包含 C^{1D} 对角线上的元素,该协方差矩阵也就是 C^{2D} 。当 $\rho = n$ 时,变形的协方差矩阵 C^{V2D} 含有 C^{1D} 里的所有元素,该协方差矩阵也就是 C^{1D} 。当 $\rho = k$ 时,其变形的协方差矩阵 C^{V2D} 选取的元素是图 1 中矩阵框内的元素。图 1 中 n 是 k 的整数倍,不足的行补零。

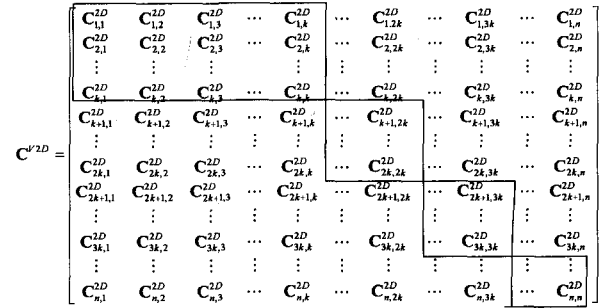


图 1 当 $\rho = k$ 时变形 2DPCA 的协方差矩阵 C^{V2D} 选取的元素

当 $\rho = k$ 时,根据式(2)可以求得其变形的协方差矩阵 C^{V2D} 等于式(5),本文称式(5)中的 C^{V2D} 为 $\rho = k$ 的变形 2DPCA 的协方差矩阵。

$$C^{V2D} = \sum_{i=1}^{\lfloor n/k \rfloor} \begin{bmatrix} C_{k(i-1)+1, k(i-1)+1}^{2D} & C_{k(i-1)+1, k(i-1)+2}^{2D} & \dots & C_{k(i-1)+1, k(i-1)+k}^{2D} \\ C_{k(i-1)+2, k(i-1)+1}^{2D} & C_{k(i-1)+2, k(i-1)+2}^{2D} & \dots & C_{k(i-1)+2, k(i-1)+k}^{2D} \\ \vdots & \vdots & \ddots & \vdots \\ C_{k(i-1)+k, k(i-1)+1}^{2D} & C_{k(i-1)+k, k(i-1)+2}^{2D} & \dots & C_{k(i-1)+k, k(i-1)+k}^{2D} \end{bmatrix} \quad (5)$$

前面所提到的参数 ρ 实质上是在图像进行 PCA 变换时需要合并的列数。当 $\rho = 1$ 时,不用进行列的合并,图像就被作为一个矩阵,当 $\rho = n$ 时,要将 n 列合并成一个列向量,当 $\rho = k$ 时,将图像矩阵的每 k 列依次合并成一个列向量。图 2 是当 $\rho = 2$ 时求 C^{V2D} 协方差矩阵的原图像的变换过程。

a_{11}	a_{12}	a_{13}	a_{14}	a_{15}	a_{16}	a_{17}	a_{18}
a_{21}	a_{22}	a_{23}	a_{24}	a_{25}	a_{26}	a_{27}	a_{28}

(a) 原始图像

a_{11}	a_{13}	a_{15}	a_{17}
a_{21}	a_{23}	a_{25}	a_{27}
a_{12}	a_{14}	a_{16}	a_{18}
a_{22}	a_{24}	a_{26}	a_{28}

(b) 变形后的图像

图 2 基于列的图像变换过程

2.1 变形的 2DPCA 方法计算特征脸

假设在人脸库中人脸的大小为 $W_1 \times W_2$, 这些图像就可以表示成 $W_1 \times W_2$ 二维空间的一个点,因此这些图像就对应了 $W_1 \times W_2$ 二维空间的一个点集。由于人脸在结构上是相似的,这些点集也不是随机分布的,因此它们可以被一个低维的子空间来表示。变形的 2DPCA 方法就能给出这个低维子空间的一些基本向量,它就是原图像所对应的协方差矩阵的特征向量。

令 I_1, I_2, I_M 是人脸图像的训练样本集,为了利用更多的鉴别信息,首先按照图 2 所示的方法对原始图像进行变形,变

形后的人脸图像的大小为 $(2w_1) \times (w_2/2)$, 其图像分别为 I_1', I_2', \dots, I_M' 。变形后人脸的平均脸定义如下:

$$A = \frac{1}{M} \sum_{i=1}^M I_i' \quad (6)$$

每张人脸像与均值脸不同, 表示为 $Y_i = I_i - A$ 。求得协方差矩阵 C 如下式:

$$C = \frac{1}{M} \sum_{i=1}^M Y_i \cdot Y_i^T \quad (7)$$

计算协方差矩阵的特征向量并选择 M' 个最大的特征值所对应的特征向量。在训练集中每个人脸图像的值计算如下:

$$W_{ik} = E_k^T \cdot (I_i - A) \quad \forall i, K \quad (8)$$

式中, E_k 是协方差矩阵 C 最大的 M' 个特征值所对应的特征向量, $K \in [1, M']$ 。

3 自适应加权变形的 2DPCA 方法(AWV-2DPCA)

本方法进行人脸识别步骤主要有 3 步: 第一步将人脸分割成若干子图像; 第二步计算每类子图像的权值; 第三步根据权值大小和最近邻原理对未知人脸样本进行分类。

3.1 人脸分割

假设在 M 个人的训练集中有 N 张 $W_1 \times W_2$ 的人脸图像, 这些人分别拥有 N_1, N_2, \dots, N_M 张人脸图像。将每张人脸图像分割成大小相等的 3 个不重叠的子图像, 接着将所有人脸图像相同位置的子图像集成一个特殊的图像集, 用这种方式就形成了 3 个单独的图像集, 其形成过程如图 3 所示。




图 3 形成人脸图像的子图像集

3.2 计算权值

人脸图像相同位置子图像的集合为图像集, 这样共有 3 个图像集, 将图像集作为训练样本。将每个图像集中的同一个人脸子图像的中值脸和均值脸作为测试样本, 选中值脸和均值脸为测试样本的原因是它们能更好地代表人脸不同的子部分。人脸空间不同部位在分类中所取的权值即为求人脸图像不同部分的中值脸和均值脸在训练样本集中的识别率。其过程可以通过如下步骤求得: 第一步, 计算每个图像集中每个人的脸子图像的中值图像(中值矩阵)和均值图像(均值矩阵); 第二步, 定义两个样本的相似度; 第三步, 计算每个图像集的权值大小。

第一步 在第 j 个图像集中, 第 i 个人所对应的子图像的中值矩阵为:

$$I_{ij\text{-median}} = \text{median}(I_{ij1}, I_{ij2}, \dots, I_{ijN_i}) \quad (9)$$

所对应的子图像的均值脸为:

$$I_{ij\text{-mena}} = \frac{1}{N_i} \sum_{k=1}^{N_i} I_{ijk} \quad (10)$$

式中, I_{ijk} 为在第 j 个原像集中的第 i 个人的第 k 张人脸图像所对应的子图像。

第二步 将第 j 个图像集里的样本作为训练样本, 利用 2.1 节所提出的变形 2DPCA 方法求其特征向量 U_j, U_j 由 M 个最大的特征值所对应的特征向量所构成, 两个样本 x, y 的相似度定义如下:

$$\text{similarity}(x, y) = -(x - y)^T U_j U_j^T (x - y) \quad (11)$$

第三步 计算每个图像集对分类所做的贡献(权值)。

对测试样本中的每个样本, 根据式(11)计算它和对应的图像集里每个样本的相似度, 然后将相似度按从大到小的顺序进行排列, 该测试样本的类别即为相似度最大的样本所属的类别。如果计算的结果与测试样本本身的类别一致, 则识别是正确的, 否则是错误的。完成第 j 个图像集所有测试样本的相似度计算后, 用 C_j 表示第 j 个图像集的测试样本分类正确的数目。最后, 第 j 个图像集对分类的权值用下式表示:

$$W_j = C_j / 2M \quad (12)$$

3.3 分类

把每类图像作为一个整体进行分析。定义 $\overline{A_{c(i)}} (1 \leq i \leq C)$ 如下:

$$\overline{A_{c(i)}} = \frac{1}{n_i} \sum_{j=1}^{n_i} A_j, A_j \in c(i) \quad (13)$$

式中, $\overline{A_{c(i)}} (1 \leq i \leq C)$ 表示类别为 c_i 的训练样本的均值矩阵, 则模块化图像矩阵可表示为:

$$\overline{A_{c(i)}} = [\overline{(A_{c(i)})_1} \quad \overline{(A_{c(i)})_2} \quad \overline{(A_{c(i)})_3}]^T \quad (14)$$

将每个子矩阵 $\overline{(A_{c(i)})_j} (j=1, 2, 3)$ 按图 2 做 $\rho=2$ 列变换后, 每个子矩阵变为 $\overline{(A_{c(i)})_j}' (j=1, 2, 3)$ 。

根据文献[5], 可以求出第 j 个子图像集矩阵 $\overline{(A_{c(i)})_j}'$ 的最优投影矩阵 $P_j (j=1, 2, 3)$, 假设 $\overline{(Q_{c(i)})_j}'$ 是 $\overline{(A_{c(i)})_j}'$ 的特征矩阵, 则 $\overline{(Q_{c(i)})_1}', \overline{(Q_{c(i)})_2}'$ 和 $\overline{(Q_{c(i)})_3}'$ 分别是矩阵 $\overline{(A_{c(i)})_j}'$ 的 3 个模块化矩阵变形后的子特征矩阵, 如式(15)所示。

$$\overline{(Q_{c(i)})}' = \begin{bmatrix} \overline{(Q_{c(i)})_1}' \\ \overline{(Q_{c(i)})_2}' \\ \overline{(Q_{c(i)})_3}' \end{bmatrix} = \begin{bmatrix} ((\overline{(A_{c(i)})_1}')^T P_1) \\ ((\overline{(A_{c(i)})_2}')^T P_2) \\ ((\overline{(A_{c(i)})_3}')^T P_3) \end{bmatrix} \quad (15)$$

给定 A 为测试样本, 它们的 3 个子矩阵分别为 A_1, A_2, A_3 , 根据图 2 的方法将 A 的 3 个子矩阵做 $\rho=2$ 列变换, 每个子矩阵变为 A_1', A_2', A_3' 。则它的特征矩阵如式(16)所示:

$$Q' = \begin{bmatrix} Q_1' \\ Q_2' \\ Q_3' \end{bmatrix} = \begin{bmatrix} (A_1')^T P_1 \\ (A_2')^T P_2 \\ (A_3')^T P_3 \end{bmatrix} \quad (16)$$

使用最邻分类器来计算特征矩阵之间的距离, 如式(17)所示:

$$d(\overline{(Q_{c(i)})}', Q') = \sum_{j=1}^3 W_j \times ||\overline{(Q_{c(i)})_j}' - Q_j'|| \quad (17)$$

式(18)中 W_j 表示人脸 3 个部分在识别中所取的权值, 该权值的大小为式(12)。如果式(18)成立, 则识别的结果为 $A \in c(i)$ 。

$$d(\overline{(Q_{c(i)})}', Q') = \min_j (d(\overline{(Q_{c(i)})_j}', Q_j')) \quad (1 \leq j \leq C) \quad (18)$$

4 实验

4.1 人脸数据库各实验环境

本实验采用剑桥大学 ORL (Olivetti Research Laboratory) 人脸数据库。在该数据库中有 40 个人的 400 幅不同的人脸图像, 每个人有 10 幅不同表情、不同时期和环境的人脸图像, 所有图像的大小为 112×92 。这个数据库反映了不同人的不同图像间区别, 也反映了相同人不同图像间细微的区别, 因此它符合实验要求。在实验过程中, 首先随机选取每个人 6 幅不同的图像作为训练样本, 每个剩余的 4 幅作为测试样本。图 4 和图 5 表明这些数据中某些人脸图像。




图 4 训练集中的人脸图像




图 5 测试集中的人脸图像

本实验硬件环境为 DUO T5850 CPU, 2G 内存, 软件环境为 MATLAB 7.0。识别率的定义为某类样本有多少落在该类模型的区域, 其人脸识别率定义为: 识别率 = $\frac{\text{正确判定人脸类别的实验次数}}{\text{本次实验的总次数}}$ 。

4.2 实验结果

实验 1 比较 AWV2DPCA、IM2DPCA 和 2DPCA 的鉴别矢量个数与正确识别率间的关系。在 ORL 数据库每次随机地选取每个人 5 幅人脸图像做训练样本, 剩余 5 幅人脸图像用作测试样本, 该实验单独地重复 40 次, 实验结果的平均值如表 1 所列, 实验中的子图像大小为 14×4 。在表 1 中的 $\alpha = (\text{所选的特征向量数} / \text{特征向量总数}) \times 100\%$, 在这里所有的特征向量均是按它相应的特征值大小的降序排列, 并选取最大的特征值对应的特征向量。

表 1 AWV2DPCA、IM2DPCA 和 2DPCA 3 种正确识别率的比较

$\alpha(\%)$	AWV2DPCA	IM2DPCA	2DPCA
100	0.9873	0.9378	0.9194
80	0.9849	0.9356	0.9178
70	0.9842	0.9345	0.9156
60	0.9834	0.9302	0.9143

从表 1 可以看出, AWV2DPCA 比 IM2DPCA 在正确识别率上提高了 4%, 同时比 2DPCA 提高了 5%, 是因为本算法考虑了不同分块在分类中所起的作用不同。

实验 2 对原始矩阵进行不同分块应用本方法进行比较。实验方案如实验 1, 分块数分别为: $4 \times 4, 4 \times 2, 2 \times 2$ 。其

子矩阵的大小分别为: $32 \times 23, 32 \times 46, 56 \times 46$ 。其特征矩阵的大小为: $12 \times k, 23 \times k, 23 \times k, k$ 为鉴别矢量数目, 实验结果如表 2 所列, 从表 2 可以看出, 4×4 的分块方式的识别率明显低于 $4 \times 2, 2 \times 2$, 是因为 $4 \times 2, 2 \times 2$ 的分块方式充分体现了人脸结构的对称性, 每个对称体含有大量的鉴别信息; 4×2 的分块方式的识别率高于 2×2 的分块方式, 是因为人脸的区别主要集中在眼、鼻、嘴和下巴等部位, 而 4×2 的方式更能体现人脸的不同特征, 2×2 的分块方式则忽视了一些局部的鉴别信息。

表 2 对 AWV2DPCA 算法进行不同分块方式比较

块数	$\alpha(\%)$						
	10	20	30	40	50	60	70
4×2	0.78	0.90	0.91	0.923	0.918	0.928	0.935
2×2	0.72	0.82	0.912	0.925	0.932	0.927	0.924
4×4	0.70	0.79	0.85	0.89	0.90	0.901	0.912

实验 3 在相同的正确识别率的前提下对 AWV2DPCA、IM2DPCA 和 2DPCA 3 种方法比较误识数目、样本识别时间和特征提取时间。实验结果如表 3 所列, 其中 α 表示正确识别率, β 表示误识数目, σ 表示特征提取时间, λ 表示样本识别时间。从表 3 可以看出, IM2DPCA 方法在特征提取时间上比 AWV2DPCA 优, 是因为对于相同的 $2 \times 2, 4 \times 2, 4 \times 4$ 分块, IM2DPCA 分块的总体散布矩阵的大小分别为: $56 \times 56, 23 \times 23, 23 \times 23$, 而 AWV2DPCA 分块的散布矩阵大小分别为: $112 \times 112, 46 \times 46, 46 \times 46$; 本算法在样本识别时间上比 IM2DPCA 优, 是因为对于相同的 $2 \times 2, 4 \times 2, 4 \times 4$ 分块, IM2DPCA 分块的特征矩阵为: $46 \times k, 46 \times k, 23 \times k$, 而本算法的特征矩阵为: $23 \times k, 23 \times k, 12 \times k$ 。

表 3 AWV2DPCA、IM2DPCA 和 2DPCA 3 种方法实验结果比较

项目	IM2DPCA			AWV2DPCA		
	2×2	4×2	4×4	2×2	4×2	4×4
α	91.5	91.5	91.5	91.5	91.5	91.5
β	17	17	17	17	17	17
σ	5.34	5.56	5.84	4.18	4.37	4.45
λ	4.08	5.92	6.97	3.23	3.34	3.75

本算法与传统的 2DPCA 方法相比, 充分考虑了图像的局部鉴别信息, 与传统的模块化 2DPCA 方法相比, 利用了不同分块在分类中所起的作用不同。正是由于这两点, 通过实验证明本算法比传统的 2DPCA 和模块化的 2DPCA 方法的正确人脸识别率高, 并且识别时间短。

结束语 本文提出了一种自适应加权变形的 2DPCA 人脸识别方法, 并将它和 2DPCA、IM2DPCA 算法进行了比较。经过实验表明: 本文提出的算法不仅有效, 而且在识别率和识别时间方面优于传统的 2DPCA 方法。这一点说明了人脸图像矩阵的每个分块在分类中所起的作用是不一样的, 如何充分利用有用全局和局部的信息, 去掉一些对分类作用不大的信息是以后研究的重点和难点。

参考文献

- [1] Eftekhari A. Mohamad Forouzanfar and Hamid Abrishami Moghaddam. Block-wised 2D kernel PCA/LDA for recognition [J]. Information Processing Letters, 2010, 110(2010): 761-766

- [2] Qi Yong-feng, Zhang Jia-shu. (2D)2PCALDA: An efficient approach for face recognition[J]. Applied Mathematics and Computation, 2009, 213(1): 1-7
- [3] Wang Jin, Barret A, Wang Lu, et al. Multilinear principal component analysis for face recognition with fewer features[J]. Neurocomputing, 2010, 73(10-12): 1550-1555
- [4] Yang J, Zhang D, 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
- [5] Visanni M, Garcia C, Laurent C. Comparing robustness of two-dimensional PCA and eigenfaces for face recognition[J]. Lecture notes in computer science, 2004, 3212: 717-724
- [6] Lu C, Liu W, Liu X, et al. Double sides 2DPCA for face recognition[J]. Lectures notes in computer science, 2008, 5226: 446-459
- [7] Kim Y, Song Y, et al. Face recognition using a fusing method based on bidirectional 2DPCA [J]. Applied mathematics and computation, 2008, 205(2): 601-607
- [8] Kim C, Choi C. Image covariance-based subspace method for face recognition[J]. Pattern recognition, 2007, 40(5): 1592-1604
- [9] Nguyen N, Liu W, Venkates S. Random subspace two-dimensional PCA for face recognition[J]. Lecture notes in computer science, 2007, 4810: 655-664
- [10] Pan X, Ruan Q. Palmprint recognition using Gabor feature-based (2D)²PCA[J]. Neurocomputing, 2008, 71(13-15): 3032-3036
- [11] Yu W, Wang Z, Chen W. A new framework to combine vertical and horizontal information for face recognition[J]. Neurocomputing, 2009, 72(4-6): 1084-1091
- [12] Yu H, Bennamoun M. 1D-PCA, 2D-PCA to nD-PCA[C]// The 18th international conference in pattern recognition. 2006
- [13] Lu H, Plataniotis K N, Venetsanopoulos A N. MPCA: multilinear principal component analysis of tensor objects [J]. IEEE transactions in neural networks, 2008, 19(1)
- [14] Zheng Wei-shi, Lai J H, Li S Z. 1D-LDA vs. 2DLDA: when is vector-based linear discriminant analysis better than matrix-based[J]. Pattern Recognition, 2008, 41(7): 2156-2172
- [15] 李晓东, 费树岷. 一种改进的模块化 2DPCA 人脸识别方法[J]. 系统仿真学报, 2009, 21(15): 4672-4675
- [16] Zhang Li-jing, Zhang Ying. Facial feature extraction with weighted modular Two-Dimensional PCA[C]// The 2nd International Conference on Bioinformatics and Biomedical Engineering, 2008. ICBBE, 2008: 1992-1995

(上接第 215 页)

所以相应地被 1 取代。因此可得二分网络计算环数目公式:

$$T_s^2 = N_s^2 = N * \psi_s * \sum_{d=s/2}^{d_{\max}} p(d) * \frac{(s/2)!}{2} * \binom{d}{s/2} C_d$$

$$(d)^{s/2-1} | \psi_s = 1/s \quad (10)$$

任一多分网络都是由三角形或四边形组成的,所以可知式(9)不仅可以在一分网络和二分网络中应用,还可以在多分网络中应用。

结束语 本文引申一阶聚类系数的概念,提出计算二阶聚类系数方法,即存在的四边形数目占最多可能四边形数目的分数。证明二阶聚类系数和一阶聚类系数对研究各种不同拓扑结构复杂网络起同等重要作用。二阶聚类系数使得在没有三角形的二分网络中计算二分网络社团变成可能。任一环都是由三角形和四边形基构成,因此一分网络可用一阶聚类系数计算一分网络中的聚类系数,类似可用扩展聚类系数计算二分网络图中的社团性质,进而可以用一阶和二阶聚类系数计算多分网络结构中的社团性质。

在一分网络中估计某尺度环数目时,环尺度存在上限 $s < d_{\max} + 1$, d_{\max} 表示网络中最大结点数。本文提出一更通用的表达式,此表达式不仅增加了估计某尺度环数目时漏掉的类型数目,并且也适合于二分网络,同时可使估计环尺度最大值增加到 $2d_{\max}$ 。为验证这些结论,应该把该计算应用于大型网络,这将在以后文章中详细研究的问题。

参 考 文 献

- [1] Watts D J, Strogatz S H. Collective dynamics of small-world networks[J]. Nature, 1998, 393: 440-442
- [2] McGraw P N, Menzinger M. Clustering and the Synchronization of Oscillator Networks[Z]. cond-mat/0501663, 2005
- [3] Holme P, Edling C R, Liljeros F. Structure and Time-evolution of an Internet Dating Community[J]. Social Networks, 2004, 26 (155)
- [4] Caldarelli G, Pastor-Satorras R, Vespignani A. Structure of cycles and local ordering in complex networks[Z]. Eur. Phys. J. 2004, B 38: 183-186
- [5] Marinari E, Monasson R J. Circuits in random graphs: from local trees to global loops[J]. Stat. Mech. , 2004
- [6] Bianconi G, Capocci A. Number of loops of size h in growing scale-free networks[J]. Phys. Rev. Lett. , 2003, 90: 078701
- [7] Bianconi G, Caldarelli G, Capocci A. Loop structure of the Internet at the Autonomous System Level[Z]. cond-mat/0408349, 2004
- [8] Herrero C P. Self-avoiding walks on scale-free networks [J]. Phys. Rev. , 2005, E 71: 016103
- [9] Yang S J. Exploring complex networks by walking on them[J]. Phys. Rev. , 2005, E 71: 016107
- [10] Bianconi G, Marsili M. Loops of any size and Hamilton cycles in random scale-free networks[Z]. cond-mat/0502552, 2005
- [11] V'azquez A, Oliveira J G, Barab'asi A-L. Modeling bursts and heavy tails in human dynamics [J]. Phys. Rev. , 2005, E 71: 025103(R)
- [12] Newman M E J, Watts D J. Scaling and percolation in the small-world network model[J]. Phys. Rev. , 1999, E 60: 7332-7342
- [13] Petermann T, de los Rios P. The role of clustering and gridlike ordering in epidemic spreading[Z]. cond-mat/0401434, 2004
- [14] Petermann T, de los Rios P. The role of clustering and gridlike ordering in epidemic spreading[Z] cond-mat/0401434, 2004