

文章编号:1672-058X(2012)04-0045-05

基于改进的 2DPCA 人脸识别方法研究*

李 童

(重庆师范大学 数学学院,重庆 401331)

摘 要:传统的主成分分析(PCA)方法在图像识别时需将图像矩阵转化成向量,造成图像向量的维数偏高,使得整个特征提取过程的计算量较大;在 PCA 的基础上,有人提出了二维主成分分析(2DPCA)的方法,但其本质是对图像矩阵按行进行特征提取,虽然消除了图像列的相关性,但是仍然忽视了行的相关性;因此,在此考虑一种改进的方法能同时消除图像行、列的相关性,并通过实验得到了比 2DPCA 更高效的识别率。

关键词:人脸识别;特征提取;主成分分析;二维主成分分析

中图分类号:TP391.4

文献标志码:A

1 引 言

在人脸识别技术中,高效的特征提取是最为核心的工作,而主成分分析(PCA)方法就是最重要的特征提取方法之一,并最早在文献[1]中被应用于人脸识别研究。由于 PCA 方法是基于图像向量的,在人脸识别过程中,要将 2D 的人脸图像矩阵转化为 1D 的图像向量,这样就造成图像向量的维数一般较高,最终导致特征提取的计算量增大,识别率不是特别理想。人们总结了传统 PCA 方法的不足,在文献[2]提出了相对高效的二维主成分分析(2DPCA)方法。

2DPCA 方法不需要将图像矩阵预先转化为 1D 矢量,它是一种直接计算图像协方差矩阵的特征向量的方法^[3]。较传统 PCA 方法而言,2DPCA 具有几个明显的优势:首先,2DPCA 直接基于图像矩阵,在图像特征提取方面更加简单直观;其次,2DPCA 总体计算量远小于 PCA,特征提取更高效;最后,2DPCA 在实验中取得的平均识别率要高于 PCA^[4]。但是,2DPCA 方法本质上是对图像矩阵按行进行压缩提取特征,消除的是图像矩阵中列的相关性,依旧保留了行的相关性,不利于人脸识别。

2DPCA 方法虽然比 PCA 方法好,但是仍存在一定的缺陷,针对这一问题,采用一种改进的 2DPCA 方法,同时考虑到图像矩阵的行、列相关性,在 ORL 人脸库的实验背景下,该方法取得了比 2DPCA 更高效的识别率,其可行性和优化性得到了很好的验证。

收稿日期:2011-12-10;修回日期:2012-01-15.

* 基金项目:重庆市自然科学基金(CSTC,2011BB2116).

作者简介:李童(1987-),男,重庆人,硕士研究生,从事人工智能与模式识别研究.

2 基于行方向的 2DPCA 方法与基于列方向的 2DPCA 方法

2.1 基于行方向的 2DPCA 方法

在此所说的 2DPCA 方法也叫做广义主成分分析方法,其实质就是基于行方向的 2DPCA 方法^[5]。假设图像矩阵是大小为 $m \times n$ 的矩阵 A ,令 $X \in \mathcal{R}^{n \times d}$ ($n \geq d$) 是一个列向量相互正交的矩阵,把图像矩阵 A 投影到 X ,将产生一个 $m \times d$ 的矩阵 $Y = AX$ 。希望找到这样一个投影轴 X ,使得所有训练样本在其上投影后得到的特征向量的总体散布矩阵(即样本类间散布矩阵)达到最大化。在 2DPCA 方法中,可用投影样本的总离散度作为准则函数 $J(X)$ 来衡量投影矩阵 X 的优劣:

$$\begin{aligned} J(X) &= \text{trace}\{E[(Y - EY)(Y - EY)^T]\} = \\ &= \text{trace}\{E[(AX - E(AX))(AX - E(AX))^T]\} = \\ &= \text{trace}\{X^T E[(A - EA)^T(A - EA)]X\} \end{aligned} \quad (1)$$

上面的推理步骤用到了定理 $\text{trace}(AB) = \text{trace}(BA)$,其中 A 和 B 是两个矩阵, $\text{trace}(A)$ 表示矩阵 A 的迹。

定义图像的协方差矩阵:

$$G = E[(A - EA)^T(A - EA)] \quad (2)$$

它是一个 $n \times n$ 的非负定矩阵。假设有 M 个训练人脸样本,用 $m \times n$ 的矩阵 A_k ($k = 1, 2, \dots, M$) 来表示,其均值图像为

$$\bar{A} = \frac{1}{M} \sum_k A_k \quad (3)$$

那么, G 可以表示成

$$G = \frac{1}{M} \sum_{k=1}^M (A_k - \bar{A})^T (A_k - \bar{A}) \quad (4)$$

于是, $J(X)$ 可以改写成

$$J(X) = \text{trace}(X^T G_M X) \quad (5)$$

容易得知,矩阵 G 的前 d 个最大特征值所对应的特征向量 X_1, X_2, \dots, X_d 构成的投影矩阵 X_{opt} 就是最优值,即 $X_{\text{opt}} = [X_1, \dots, X_d]$ 。事实上,可以借鉴 PCA 中前 d 个特征值的筛选方法,设置阈值:

$$\frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^n \lambda_i} \geq \theta \quad (6)$$

其中, $\lambda_1, \dots, \lambda_n$ 是 G 的前 n 个最大特征值, θ 为一个预设值,通常可取 $\theta = 99\%$ ^[6]。这说明样本集在前 d 个轴上的能量占总能量的 99% 以上。

在求得投影矩阵 $X_{\text{opt}} = [X_1, \dots, X_d]$ 后,便可以对面脸图像进行特征提取和分类了。对于一幅给定的人脸图像 A ,令:

$$Y_k = AX_k \quad (k = 1, 2, \dots, d) \quad (7)$$

就获得了一组投影后的特征向量 $C = [Y_1, Y_2, \dots, Y_d]$,它叫做图像 A 的主成分向量,是后面分类识别的主要依据。两幅不同图像矩阵在投影后得到的主成分向量分别为 $C_i = [Y_1^{(i)}, Y_2^{(i)}, \dots, Y_d^{(i)}]$ 和 $C_j = [Y_1^{(j)}, Y_2^{(j)}, \dots, Y_d^{(j)}]$,可将它们之间的欧式距离定义为

$$\text{Dist}(C_i, C_j) = \sum_{k=1}^d \|Y_k^{(i)} - Y_k^{(j)}\|^2 \quad (8)$$

最后,可选用最近邻特征线(NFL)或者最近邻距离原则(NN)方法来进行人脸的识别和分类,在此不再多述。

实际上,对于式(3)中的 A_k 和 \bar{A} ,在此不妨令:

$$A_k = [(A_k^{(1)})^T (A_k^{(2)})^T \cdots (A_k^{(m)})^T]^T \quad (9)$$

$$\bar{A} = [(\bar{A}^{(1)})^T (\bar{A}^{(2)})^T \cdots (\bar{A}^{(m)})^T]^T \quad (10)$$

注意, $A_k^{(i)}$ 、 $\bar{A}^{(i)}$ 分别是 A_k 和 \bar{A} 的第 i 行行向量,于是可以把式(4)重写为

$$G = \frac{1}{M} \sum_{k=1}^M \sum_{i=1}^m (A_k^{(i)} - \bar{A}^{(i)})^T (A_k^{(i)} - \bar{A}^{(i)}) \quad (11)$$

式(11)中,图像协方差矩阵也可以用图像矩阵行向量的形式来表示。如果训练样本的均值图像为零,即 $\bar{A} = (0)_{m \times n}$,于是可以认为原始的2DPCA是按行进行特征提取的。

2.2 基于列方向的2DPCA方法^[7]

有了基于行方向的2DPCA方法的理论基础后,现在,重新令:

$$A_k = [(A_k^{(1)}) (A_k^{(2)}) \cdots (A_k^{(m)})] \quad (12)$$

$$\bar{A} = [(\bar{A}^{(1)}) (\bar{A}^{(2)}) \cdots (\bar{A}^{(m)})] \quad (13)$$

那么,这里的 $A_k^{(j)}$ 、 $\bar{A}^{(j)}$ 分别是 A_k 和 \bar{A} 的第 j 列列向量,于是基于列方向的图像协方差矩阵 G 可以定义为

$$G = \frac{1}{M} \sum_{k=1}^M \sum_{j=1}^m (A_k^{(j)} - \bar{A}^{(j)}) (A_k^{(j)} - \bar{A}^{(j)})^T \quad (14)$$

事实上,式(14)的推导也是比较容易的。令 $Z \in \mathcal{R}^{m \times q}$ 是一个列向量互相正交的矩阵,将图像矩阵 A 投影到 Z 上,产生一个大小为 $q \times n$ 的矩阵 B ,即:

$$B = Z^T A \quad (15)$$

类似的,用如下准则函数 $J(Z)$ 可以找到最佳投影矩阵 Z :

$$\begin{aligned} J(Z) &= \text{trace} \{ E[(B - EB)(B - EB)^T] \} = \\ & \text{trace} \{ E[(Z^T A - E(Z^T A))(Z^T A - E(Z^T A))^T] \} = \\ & \text{trace} \{ Z^T E[(A - EA)(A - EA)^T] Z \} \end{aligned} \quad (16)$$

从式(16)中,可以得到图像协方差矩阵的另一种定义方式:

$$\begin{aligned} G &= E[(A - EA)(A - EA)^T] = \\ & \frac{1}{M} \sum_{k=1}^M (A_k - \bar{A})(A_k - \bar{A})^T = \\ & \frac{1}{M} \sum_{k=1}^M \sum_{j=1}^m (A_k^{(j)} - \bar{A}^{(j)}) (A_k^{(j)} - \bar{A}^{(j)})^T \end{aligned} \quad (17)$$

同样的,也可以求出对应于前 q 个最大特征值的特征向量 Z_1, \dots, Z_q , 得到最优投影矩阵 Z_{opt} , 即: $Z_{\text{opt}} = [Z_1, \dots, Z_q]$ 。当然, q 值也可以用类似式(6)的方法来确定。由于式(17)只强化了图像矩阵列间的关系,在此认为这种方法是基于列方向来处理。

3 改进2DPCA方法的核心思想

由于2DPCA方法是基于行方向来处理的,消除了列的相关性,但忽视了行的相关性。相反,基于列方向的2DPCA方法,消除的是行的相关性,遗留了列的相关性。在此构造一种方法,能尽可能弥补上述两种方法的缺陷,即同时消除图像行、列的相关性,必定会达到更加满意的识别效果。

将一个大小为 $m \times n$ 的图像矩阵 A 向大小为 $n \times d$ (d 为所取行主成分特征向量)的最优投影矩阵 X_{opt} 投影,得到一个大小为 $m \times d$ 的矩阵 $Y = AX$ 。类似的,将该图像矩阵 A 向大小为 $m \times q$ (q 为所取列主成分特征向量)的最优投影矩阵 Z_{opt} 投影,得到一个大小为 $q \times n$ 的矩阵 $B = Z^T A$ 。于是我们可以利用最优投影矩阵 X

和 Z 来描述改进的 2DPCA 方法的核心思想。

假设已经求得最优投影矩阵 $X_{n \times d}$ 和 $Z_{m \times d}$, 然后把大小为 $m \times n$ 的图像矩阵 A 同时向 X 和 Z 上投影, 产生一个大小为 $q \times d$ 的矩阵 C :

$$C = Z^T A X \quad (18)$$

矩阵 C 叫做特征矩阵, 也可称为图像重建协方差矩阵, 于是原图像 A 的重建图像 \hat{A} 为

$$\hat{A} = Z C X^T \quad (19)$$

将训练样本图像 $A_k (k = 1, 2, \dots, M)$ 同时投影到 X 和 Z 上, 得到训练样本的特征矩阵 $C_k (k = 1, 2, \dots, M)$ 。选定一幅测试图像 A 后, 先应用式(18)得到其特征矩阵 C , 然后可选用最近邻分类器来进行分类。这里, 可以把 C 与 C_k 的距离定义为

$$D(C, C_k) = |C - C_k| = \sum_{i=1}^q \sum_{j=1}^d \sqrt{(C^{(i,j)} - C_k^{(i,j)})^2} \quad (20)$$

4 实验结果

实验中所用到的人脸图像均来自 ORL 人脸库, 选取了其中 30 人, 每人 10 幅大小为 112×92 的灰度图像。把每人前 6 幅图像作为训练图像, 后 4 幅图像作为待测图像, 这样训练样本共有 180 个, 待测样本共有 120 个。为了叙述方便, 把基于列方向的 2DPCA 方法简记为 R2DPCA, 把改进的 2DPCA 方法简记为 N2DPCA。

表 1 中, 括号外数据表示的是识别率, 括号内数据表示的是该识别率下的特征维数。从表 1 中, 不难看出, 应用 N2DPCA 方法的识别率在同一特征个数情况下均高于 2DPCA 和 R2DPCA 方法, 且特征维数降到了较低的范围。

表 1 多特征值下识别率和相应维数的比较

方法	特征个数				
	6	7	8	9	10
2DPCA	94.7 (112 * 6)	95.3 (112 * 7)	95.8 (112 * 8)	95.2 (112 * 9)	94.9 (112 * 10)
R2DPCA	94.1 (92 * 6)	94.5 (92 * 7)	95.2 (92 * 8)	95.3 (92 * 9)	95.0 (92 * 10)
N2DPCA	95.8 (7 * 6)	96.1 (7 * 7)	96.7 (7 * 8)	97.3 (7 * 9)	97.2 (7 * 10)

在表 2 中可以看出 N2DPCA 方法虽然在训练时间上不占优势, 但在识别时间上有了较大进步。

表 2 最佳识别率下训练和识别时间的比较

方法	训练时间/s	识别时间/s	总时间/s
2DPCA	2.77	3.85	6.62
R2DPCA	2.89	4.02	6.91
N2DPCA	2.82	2.73	5.55

5 结 语

在分析了基于行方向的2DPCA方法和基于列方向的2DPCA方法的基础上,构造了一种改进的2DPCA方法,该方法尽可能地消除了图像矩阵行、列的相关性,其可行性与优化性在实验中得到了很好的验证。事实上,还可以考虑把改进的2DPCA方法与传统的PCA方法相结合,达到进一步降维的目的。

参考文献:

- [1] TURK M, PETLAND A. Eigenfaces of Recognition[J]. Cognitive Neuroscience J. 1991, 3(1):71-86
- [2] YANG J, 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
- [3] 孙涛, 谷士文, 费耀平. 基于PCA算法的人脸识别方法研究比较[J]. 现代电子技术, 2007(1):112-114
- [4] 朱超平. 基于人脸识别的门禁系统设计与实现[J]. 重庆工商大学学报:自然科学版, 2011, 28(4):390-393
- [5] 李娟, 何伟, 张玲, 周阳. 双向压缩的2DPCA与PCA相结合的人脸识别算法[J]. 计算机应用, 2009, 6(29):245-248
- [6] 边肇祺, 张学工. 模式识别(第二版)[M]. 北京:清华大学出版社, 2000:226-227
- [7] 徐勇, 杨建, 赵英男, 等. 一种缩减图像维数的方法及其在人脸图像上的应用[J]. 电子与信息学报, 2008, 30(1):180-184

Research on Human Face Recognition Based on Improved 2DPCA Method

LI Tong

(School of Mathematics, Chongqing Normal University, Chongqing 401331, China)

Abstract: Traditional principal component analysis (PCA) needs to transform image matrix into vector during image identification, resulting in higher dimension of image vector and making larger amount of computation in the process of the entire feature extraction. On the basis of PCA, two-dimensional principal component analysis (2DPCA) method was pointed out, but its essence is to make feature extraction of image matrix by row, although the relevance of its image column is eliminated, the relevance of a row is ignored. Thus, a kind of improved method for simultaneously eliminating the relevance of row and column of the image is considered, the higher efficient recognition rate than 2DPCA is obtained by experiments.

Key words: human face recognition; feature extraction; principal component analysis; two-dimensional principal component analysis

责任编辑:代小红