

改进 2DPCA 算法在人脸识别中的应用

冯 飞 姜宝华 刘培学 陈玉杰
(青岛黄海学院 青岛 266427)

摘 要 随着二维主成分分析法在人脸识别中的应用,许多基于 2D 的分析方法日益成熟。相比于 PCA 算法基于向量的特征提取,2DPCA 算法是基于矩阵的特征提取。与依赖于特征矩阵的列或特征矩阵的全部矩阵的方法不同,提出了基于特征矩阵行的距离测量方法,该算法与 KNN 算法进行了结合。通过使用该方法可以缓解 2DPCA 算法相比于基于主成分分析的算法(PCA)需较多系数的问题。在人脸数据库上的实验结果表明,所提方法的分辨精度比 2DPCA 方法高,在准确性和存储容量方面超过了 2DPCA 算法。

关键词 2DPCA,人脸识别,行-KNN

中图分类号 TN911.4 文献标识码 A

Application of Improved 2DPCA Algorithm in Face Recognition

FENG Fei JIANG Bao-hua LIU Pei-xue CHEN Yu-jie
(Qingdao Huanghai College, Qingdao 266427, China)

Abstract With the application of two-dimensional principal component analysis (PCA) in face recognition, a lot of analysis methods based on 2D are becoming more popular. Compared with PCA algorithm based on vector feature extraction, 2DPCA algorithm is based on the feature extraction of the matrix. Unlike the methods depending on the columns or all matrix of the eigenmatrix, we proposed an algorithm based on the distance measurement method of the characteristic matrix, and the algorithm is combined with KNN algorithm. By using this method, the shortcoming based on the 2DPCA algorithm compared with algorithm based on principal component analysis (PCA) can alleviate some problems needed to be more coefficient. Experimental results on face database show that the proposed method of distinguish accuracy will increase, is's performance is better than other methods in terms of accuracy and storage capacity.

Keywords 2DPCA, Face recognition, Row-KNN

人脸识别技术被认为是一个重要的基于评价因素的生物识别技术。由于在算法上较容易实现,PCA 算法是在人脸识别应用中比较成功的方法之一。因此,许多研究人员专注于进行 PCA 的算法完善^[1]。然而,在 PCA 算法中,需要将 2D 图像矩阵转换为 1D 图像向量,提取数据量较大,计算复杂,很多将二维图像矩阵转换为一维列向量的方法取得的效果都十分有限,从而导致图像识别率不高。随后有人提出了不需转换而直接处理二维向量的方法,称为 2DPCA 方法^[2]。使用 2DPCA 找到图像中协方差矩阵的特征向量比采用 PCA 方法的准确性更高,且效率更高。

除了 2DPCA 方法,还有很多利用二维矩阵代替一维向量的方法,如 DiaPCA,然而多数二维矩阵算法主要侧重于特征提取,分类方法较少。2DPCA 方法利用特征矩阵的列之间的欧氏距离的总和来衡量特征矩阵之间的距离;DiaPCA 算法采用了两个特征矩阵之间的欧氏距离;集成矩阵算法提出利用距离度量来衡量两个特性之间的距离。还有学者提出将矩阵体积作为一个分类测量方法,称为体积测距^[3]。体积测距法在测量精度上要优于其他方法。传统方法处理的特征矩阵只考虑到了与原始人脸矩阵的列之间的关系,子空间的概念被限制在一个范围内。为了解决这些问题,本文提出了一

种新的距离算法,即利用特征矩阵的行(代替列)测距,它对特征矩阵的行向量的欧氏距离求总和,称为行欧氏距离。该方法结合了 KNN 算法^[5],称为 Row-KNN 算法,与之前的距离算法相比,当训练图像每个类的数量增加时,Row-KNN 在精度上具有优势。此外,用 KNN 算法计算选定特征行的距离,准确性、存储空间和时间复杂度都得到了改善。本文的方法结合 Row-KNN 算法对 2DPCA 算法进行改进。本文第 1 节介绍 2DPCA 算法,并简述之前测距方面的工作;第 2 节描述行距离的思想及其与 KNN 的相关性;第 3 节提出实验结果并讨论;最后总结全文。

1 2DPCA 算法

设 X 表示 n 维列向量矩阵,将大小为 $m \times n$ 的图像矩阵 A 通过如下的线性变化直接投影到 X 上^[6]:

$$Y = AX \quad (1)$$

Y 称为图像 A 的特征向量,最佳投影轴 X 可以根据特征相量 Y 的离散度分布情况来决定,采用的准则如下:

$$J(X) = \text{tr}(S_x) \quad (2)$$

其中, S_x 表示训练样本投影特征向量 Y 的协方差矩阵, $\text{tr}(S_x)$ 表示 S_x 的离散度。矩阵 S_x 的定义如下:

$$\begin{aligned}
 S_x &= E(Y-E(Y))E(Y-E(Y))^T \\
 &= E(AX-E(AX))(AX-E(AX))^T \\
 &= E((A-E(A))X)((A-E(A))X)^T
 \end{aligned}
 \tag{3}$$

因此有:

$$\text{tr}(S_x) = \text{tr}(X^T E((A-E(A))^T(A-E(A)))X) \tag{4}$$

假设有 M 个训练样本图像, G_r 为图像的协方差矩阵, G_r 的定义如下:

$$G_r = \frac{1}{M} \sum_{i=1}^M (A_i - \bar{A})^T (A_i - \bar{A}) \tag{5}$$

其中, A_i 是第 i 个训练样本图像, M 是训练样本图像的个数, \bar{A} 是所有训练样本的平均图像。通过计算 G_r 的特征向量, 选择特征向量 X_1, \dots, X_d 是矩阵 G_r 对应的 d 个最大特征向量, 可以得到最优投影轴。因为 G_r 的大小为 $n \times n$, 维数较小, 所以计算其特征向量的效率要高于 PCA 算法。其协方差矩阵可以重新写为式(6):

$$G_r = \frac{1}{M} \sum_{i=1}^M \sum_{r=1}^m (A_i^{(r)} - \bar{A}^{(r)})^T (A_i^{(r)} - \bar{A}^{(r)}) \tag{6}$$

其中, $A_i^{(r)}$ 和 $\bar{A}^{(r)}$ 分别是 A_i 和 \bar{A} 的第 r 个行向量, m 是人脸图像的行数, 因此称之为行 2DPCA。从行 2DPCA 中可以看出, 协方差矩阵是人脸图像行数的外积总和。由 $Y = Z^T A$ 推出的列协方差矩阵如式(7)所示:

$$G_r = \frac{1}{M} \sum_{i=1}^M \sum_{c=1}^n (A_i^{(c)} - \bar{A}^{(c)}) (A_i^{(c)} - \bar{A}^{(c)})^T \tag{7}$$

其中, n 为矩阵的列数目, $A_i^{(c)}$ 和 $\bar{A}^{(c)}$ 分别为 A_i 和 \bar{A} 的第 c 个列向量, 因此称之为列 2DPCA。特征矩阵可以通过式(8)得到:

$$Y = AX \tag{8}$$

其中, X 为选定的特征向量矩阵, Y 是图像 A 的特征矩阵。该方程可用于测试图像的处理, 然后再定义最小距离进行分类。

2 几种测距方法

2.1 2D 欧氏距离

$$d_{2D}(Y_i; Y_j) = \| Y_i - Y_j \|_2 \tag{9}$$

其中, Y_i 是测试图像的特征矩阵, Y_j 是训练图像的特征矩阵^[7]。

2.2 列的欧氏距离

$$d_c(Y_i; Y_j) = \sum_{c=1}^d \| y_i^c - y_j^c \|_2 \tag{10}$$

其中, Y_i 是测试图像的特征矩阵, Y_j 是训练图像的特征矩阵, d 为列数, y_i^c 和 y_j^c 分别为测试图像和训练图像特征矩阵的某一列向量。

2.3 集成矩阵距离 (AMD)

$$d_{AMD}(Y_i; Y_j) = \left(\sum_{c=1}^d \| y_i^c - y_j^c \|_2^p \right)^{1/p} \tag{11}$$

其中, Y_i 是测试图像的特征矩阵, Y_j 是训练图像的特征矩阵, d 为列数, y_i^c 和 y_j^c 分别为测试图像和训练图像特征矩阵的某一列向量。 p 为幂因子, 为取得较好的值, 根据经验令 p 为 0.125。

2.4 体积距离

$$d_v(Y_i; Y_j) = \sqrt{\det(Y_i - Y_j)^T (Y_i - Y_j)} \tag{12}$$

其中, Y_i 是测试图像的特征矩阵, Y_j 是训练图像的特征矩阵。

2.5 本文提出的方法

根据式(8)和矩阵相乘的线性特性, 可以采用两种方法进

行特征提取。从图 1(a)中可看出, 特征矩阵 Y 的第 c 列是通过人脸图像 A 在选定第 c 列的特征向量的投影计算得到的。因此, 特征矩阵的列具有测试图像的特性。另外一种方法如图 1(b)所示, 特征矩阵 Y 的行可以通过图像矩阵的行和所选的特征向量的乘积计算得到。这表明特征矩阵的行的迹实际上是给定图像行的迹。此外, 这种方式保持了子空间的概念, 因为选择特征向量构造了新的子空间, 返回了两点之间的欧氏距离, 由于 X 向量取自协方差矩阵, 协方差矩阵是由人脸图像行的外积构建, 随着训练图像每个类的数量增加, 该方法的精度和效率会逐步提高, 这是因为协方差矩阵的特征向量的计算精度增加了。在此定义一种新的测距方法:

$$d_R(Y_i; Y_j) = \sum_{r=1}^m \| y_i^r - y_j^r \|_2 \tag{13}$$

其中, Y_i 是测试图像的特征矩阵, Y_j 是训练图像的特征矩阵, m 是行数, y_i^r, y_j^r 是测试图像和训练图像的行向量, 称之为行欧氏距离, 由于在特征矩阵的某些行可能含有其他行的冗余信息, 因此不需要把所有的行进行分类, 而只选择可以提高精度和降低计算时间的最优行, 这样弥补了与 PCA 算法相比 2DPCA 需存储较多系数的缺点。最简单的方法是选择从第 1 行跳到第 J 行, 它们之间的行和被选行都含有多数相同的信息, 将 K 近邻法用于每个待选行。确定好每行和各自类的 K 近邻值, 计算每一类的出现率, 如果某一类的出现率超过其他类, 则选择该类作为划分类, 如果有多个类具有相同的发生率, 则把具有最小行距离的类作为划分类。这种方法将有益于提高 2DPCA 的性能同时弱化其缺点。

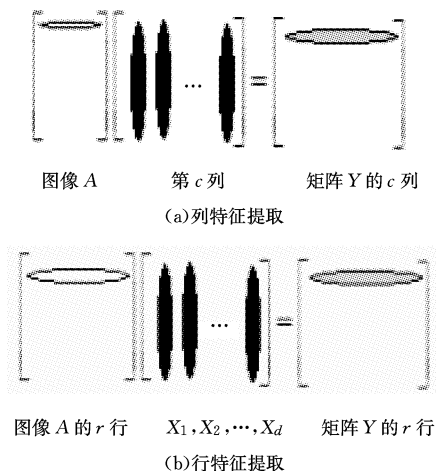


图 1 使用 2DPCA 的特征提取方法

3 实验结果

3.1 在 ORL 数据库的测试结果

ORL 人脸数据库包含 40 个人共 400 幅图像, 每人有不同角度的 10 幅图像, 图像尺寸为 112×92 , 背景为黑色, 图像含有不同的表情及面部细节, 如配镜/不配镜。

首先确定 K 和 J 的最优值, 可以通过两种方法来实现。第一种方法令 $K=5$, 确定 J 的最优值。随机选 5 幅图作为训练图, 其余图作为测试图, 表 1(a)列出了当特征向量值不同时的实验结果。可以看到, 当特征向量值为 4 且 J 为 3 时, 识别精度最高, 尽管精度的变化受 J 值的影响, 但是系数个数降低了, 从而弥补了 2DPCA 算法的不足。第二种方法是

(下转第 311 页)

[15] HUANG W T, CHEN W K, CHEN C H. Pancyclicity of Möbius cubes[C]// Proceedings of the Ninth International Conference on Parallel and Distributed Systems(ICPADS'02). 2002: 591-596.
 [16] FAN J X. Hamilton-connectivity and cycle-embedding of Möbius cubes[J]. Information Processing Letters, 2005, 93(3): 133-138.
 [17] SIM E, YEBRA J L A. The vulnerability of diameter of folded cubes[J]. Discrete Mathematics, 1997, 174(3): 317-302.
 [18] XU J M, L M. On restricted edge-connectivity of regular di-

graphs[J]. Taiwan Journal of Mathematics, 2005, 9(4): 661-670.
 [19] 师海忠. 互连网络的新模型: 多部群论模型[J]. 计算机科学, 2013, 40(9): 21-24.
 [20] 师海忠. 正则图连通圈: 多种互连网络的统一模型[C]// 中国运筹学会第十届学术交流会论文集. 2010: 202-208.
 [21] 张欣, 师海忠. 交叉立方体连通圈网络的 Hamilton 分解[J]. 软件, 2015, 36(8): 92-98.
 [22] 王海锋, 师海忠. Möbius 超立方体网络的 Hamilton 分解[J]. 软件, 2015, 36(10): 85-89.

(上接第 268 页)

令 J 值为 3, 确定 K 的最优值, 如表 1(b) 所列, 可知当 K 为 5 时识别精度最高。从表 2 可知, 2D 距离法在所有的实验中精度最低; 体积距离法在每类训练图较多时精度最高, 一般性能随每个类的训练图数量的增加而增加; Row-KNN 算法在每个类训练数量较少时精度最好, 成为了最有效的计算方法。

表 1 K, J 的最优值计算

(a) $K=5$ 时 Row-KNN 的分辨精度/%

特征向量值	J 值				
	1	2	3	4	5
1	79.5	74.5	69.5	65.0	63.0
2	94.5	93.5	93.0	92.0	93.5
3	96.0	96.0	95.5	95.0	94.5
4	96.5	97.0	98.0	95.5	95.5
5	96.0	97.5	96.5	95.0	95.0
6	97.0	96.5	97.0	94.5	94.0
7	97.5	96.5	97.0	95.0	96.5
8	96.5	96.5	96.5	95.0	96.0
9	96.5	96.5	97.0	95.5	97.0
10	96.0	96.0	95.5	95.0	96.0

(b) $J=3$ 时 Row-KNN 的分辨精度/%

特征向量值	K 值						
	1	2	3	4	5	6	7
1	44.0	55.0	58.5	67.0	69.5	72.0	72.5
2	84.5	89.5	92.0	93.0	93.0	94.5	95.5
3	90.0	92.5	95.0	96.0	95.5	97.0	97.5
4	90.0	92.5	95.0	96.0	95.5	97.0	97.5
5	94.0	96.0	97.5	97.0	98.0	97.5	96.5
6	94.5	96.5	97.0	96.0	97.0	96.0	96.0
7	94.5	96.5	97.0	96.5	97.0	96.0	96.0
8	95.5	96.0	96.0	96.0	96.5	96.5	96.0
9	97.0	96.0	96.0	95.0	97.0	97.5	96.5
10	96.5	96.5	96.0	95.0	95.5	96.0	96.5

表 2 ORL 数据库的实验结果

距离算法	精确度/%	特征数
2D 测距	95.5	366
列测距	96.0	366
AMD 测距	97.0	366
体积测距	98.0	366
本文算法	98.0	149

3.2 应用于 Yale 数据库实验结果

Yale 数据库包含 15 个人的 165 幅灰度图像, 尺寸为 243×320 , 图像有不同的表情和光照, 通常条件下, 中心光线、无配

镜、左侧光源、右侧光源、配镜作为训练图像, 困倦、眨眼、高兴、悲伤、惊讶等表情用于测试图像。从表 3 可以看出, 体积距离和 Row-KNN 方法的准确度最高, 但是 Row-KNN 需要较少的特征数。

表 3 Yale 数据库实验结果

距离算法	精确度	特征数
2D 测距	94.66	2000
列测距	97.33	1000
AMD 测距	98.66	1500
体积测距	100	500
本文算法	100	433

结束语 合理地使用特征矩阵的乘法特性可以在准确性、处理时间和存储能力方面取得较好的效果。实验表明, 在 2D 矩阵中, 本文提到的所有算法中, Row-KNN 算法更具有可行性, 当训练样本较多时, 体积距离法的精确度要优于其他算法, 但是当每类的训练样本较少时, 本文提出的 Row-KNN 算法在精确度和存储能力方面要比体积算法更好。该算法弥补了与 PCA 算法相比 2DPCA 需存储较多系数的缺点。该算法通过跳行的方法去除了行之间的冗余信息, 但是 J 值不能应用于所有的数据库, 其依赖于人脸图像的尺寸, 因此, 研究自动划分方法来确定特征行的最佳值将在后期工作中进行, 进而可以提高本算法的适用性。

参 考 文 献

[1] 齐兴敏, 刘冠梅. 基于 PCA 的人脸识别方法的比较研究[J]. 现代电子技术, 2008, 31(6): 77-79.
 [2] 陆微微, 刘晶. 一种提高 k-近邻算法效率的新算法[J]. 计算机工程与应用, 2008, 44(4): 163-165
 [3] 刘党辉, 沈兰荪. 人脸检测研究进展[J]. 计算机工程与应用, 2003, 39(28): 5-9.
 [4] 李娟, 何伟, 张玲. 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.
 [5] 边肇琪, 张学工. 模式识别[M]. 北京: 清华大学出版社, 2000: 226-227.
 [6] 徐勇. 一种缩减图像维度的方法及其在人脸图像上的应用[J]. 电子与信息学报, 2014, 30(18): 180-184.
 [7] 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.