

文章编号:1001-9081(2008)01-0122-03

基于对称的二维主成分分析及其在人脸识别中的应用

丁明勇

(重庆工商大学 计算机科学与信息工程学院,重庆 400067)

(dmytt@163.com)

摘要:在二维主成分分析算法中引入了对称性思想,提出了基于对称的二维主成分分析算法(STDPCA)。在该算法中,首先把人脸图像分解成奇对称图像和偶对称图像,然后分别在这两类图像中进行二维主成分分析,提取所需要的特征。该算法不仅有效利用了二维主成分分析算法的优点,而且也考虑了人脸对称性的特点,因此在人脸识别中有较高的识别率。在著名人脸库 ORL、YALE 中的实验证明了该算法的有效性。

关键词:人脸识别;对称性;主成分分析;二维主成分分析;基于对称的二维主成分分析

中图分类号: TP391 文献标志码:A

Symmetry based two-dimensional principal component analysis and its application to face recognition

DING Ming-yong

(School of Computer Science and Information Engineering, Chongqing Technology & Business University, Chongqing 400067, China)

Abstract: This paper presented a Symmetry based Two-Dimensional Principal Component Analysis (STDPCA) on the basis of this idea of symmetry, which was introduced into Two-Dimensional Principal Component Analysis (TDPCA). Firstly, facial image was divided into the even symmetrical image and the odd symmetrical image. Then TDPCA was performed in the even symmetrical image and the odd symmetrical image for feature extraction, respectively. Therefore, STDPCA used effectively not only the advantages of TDPCA, but also the symmetrical properties of facial images. The experimental results on ORL and YALE database show the efficiency of STDPCA.

Key words: face recognition; symmetry; Principal Component Analysis (PCA); Two-Dimensional Principal Component Analysis (TDPCA); Symmetry based Two-Dimensional Principal Component Analysis (STDPCA)

文献[1]应用主成分分析算法(Principal Component Analysis, PCA)提取人脸特征,并且提出了特征脸这一著名概念。从此,主成分分析算法得到了广泛的关注,同时成为了人脸识别中最关键的特征提取方法之一。然而,主成分分析算法也存在一些弱点,例如对出格点的敏感性等。文献[2]提出了对称主成分分析算法(SCPA)并且应用到人脸识别中。该方法主要引入了对称性的思想,所以能有效利用人脸对称的这个特征。最近,文献[3]提出了二维主成分分析算法(TDPCA),其优点主要就是不需要把图像矩阵展开成向量,而是直接在图像矩阵中进行特征分析,这大大减小了计算量,同时还提高了识别精度。此外,文献[4]提出了改进的二维主成分分析并应用到掌纹识别中;文献[5]考虑在水平和垂直方向顺序进行 2 次二维主成分分析并应用到人脸识别中,不仅降低了计算复杂度,还压缩了人脸的特征维数;文献[6]首先对人脸图像进行分块,然后再进行二维主成分分析。但是这些研究在应用和推广二维主成分分析的时候尚未有考虑人脸的对称性。因此,本文在考虑人脸对称特点的同时结合二维主成分分析方法的优点,提出了基于对称的二维主成分分析算法(STDPCA)。

1 TDPCA 算法原理

在二维主成分分析算法中^{[3]80},我们希望去找到一个投影向量 V ,这里 V 表示一个 n 维单位列向量,然后通过式(1)

计算一幅图像在 V 中的投影:

$$Y = X V \quad (1)$$

即 Y 就是图像 X 的投影向量,并且是 m 维的。怎样才能找到一个好的投影向量 V 呢?根据文献[3],可以考虑采用投影样本的总体散度去判定投影向量 V 的辨识能力。因为通过投影特征向量的协方差矩阵可以刻画投影样本的总体特征,因此,我们可以采用下列准则:

$$J(V) = \text{tr}(S_v) \quad (2)$$

其中: S_v 表示训练样本的投影特征向量的协方差矩阵且 $\text{tr}(S_v)$ 表示 S_v 的迹,即:

$$\text{tr}(S_v) = V^T \{E[(X - EX)^T(X - EX)]\} V$$

定义下列矩阵:

$$C = E[(X - EX)^T(X - EX)] \quad (3)$$

其中: C 称为图像的协方差矩阵,并且可以直接用训练图像样本来计算 C 。然后通过对协方差矩阵进行特征分解,可以获得我们所需要的投影向量 V 。这就是二维主成分分析算法的基本思想。

2 基于对称的 TDPCA 算法

首先,我们先阐述对称性的思想^{[2]98}。任意一个函数 $f(t)$ 都可以分解为一个偶函数 $f_e(t)$ 和一个奇函数 $f_o(t)$,即 $f(t) = f_e(t) + f_o(t)$, 其中 $f_e(t) = \frac{f(t) + f_m(t)}{2}$ 为偶函数,

$f_o(t) = \frac{f(t) - f_m(t)}{2}$ 是奇函数,且 $f_m(t) = f(-t)$ 是一个镜像

函数。我们可以把这个思想应用到人脸图像分解中。设 $\{x_k | k = 1, 2, \dots, M, x_k \in R^N\}$ 表示一组人脸图像集,其中 M 表示训练样本数, N 表示一幅输入图像的维数。根据奇偶分解理

论, x_k 可以分解为 $x_k = x_{e_k} + x_{o_k}$, 其中 $x_{e_k} = \frac{x_k + x_{m_k}}{2}$ 表示偶对

称图像, $x_{o_k} = \frac{x_k - x_{m_k}}{2}$ 表示奇对称图像, x_{m_k} 是 x_k 的镜像图像。

如果让 C, C_e, C_o 分别表示图像集 x_k, x_{e_k}, x_{o_k} 的协方差矩阵,那么根据文献[2],存在一个关系式为: $C = C_e + C_o$, 这说明对 C 的特征分解可以等价于对 C_e 和 C_o 的分解。因此, x_k 可以由 C_e 和 C_o 的特征向量得到完全的重构。

下面我们来阐述所提出的基于对称的二维对称主成分分析算法(STDPCA)。假设总共有 N 个训练样本, 第 j 幅训练图像可以用一个 $m \times n$ 矩阵 X_i ($i = 1, 2, \dots, N$), 并且所有训练样本的均值图像可以用 \bar{X} 来表示, 那么训练样本的协方差矩阵可以通过下式来计算:

$$C = \frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^T (X_i - \bar{X}) \quad (4)$$

根据奇偶分解原理, $X_i = X_{e_i} + X_{o_i}$, 其中 $X_{e_i} = \frac{X_i + X_{m_i}}{2}$

表示偶对称图像, $X_{o_i} = \frac{X_i - X_{m_i}}{2}$ 表示奇对称图像, 且 X_{m_i} 是 X_i 的镜像图像。在这里, 如果我们定义 \bar{X}_e 为所有偶对称样本的均值图像, \bar{X}_o 为所有奇对称样本的均值图像, 则训练样本的协方差矩阵可以通过下式得到计算:

$$C = C_e + C_o \quad (5)$$

其中:

$$C_e = \frac{1}{N} \sum_{i=1}^N (X_{e_i} - \bar{X}_e)^T (X_{e_i} - \bar{X}_e) \quad (6)$$

且

$$C_o = \frac{1}{N} \sum_{i=1}^N (X_{o_i} - \bar{X}_o)^T (X_{o_i} - \bar{X}_o) \quad (7)$$

于是, 训练样本的协方差 C 的特征分解就等价于 C_e 和 C_o 的分解。因此, 要找到最优投影向量的准则可表示为:

$$J(V) = V^T C V = V^T (C_e + C_o) V \quad (8)$$

这意味着最优投影向量 V_{opt} 就是最大化 $J(V)$ 的单位向量。

和 SPCA 相似, 在获得的特征中怎样选择呢? 一般来说, 我们首先要对特征值进行排序, 然后选择对应较大特征值的特征向量。由于偶对称特征 V_e 比奇对称特征 V_o 具有较大的能量, 所以很自然首先选择得到的是偶对称特征, 然后根据需要才选择奇对称特征。

现在我们可以总结出 STDPCA 算法的计算步骤如下:

- 1) 从训练图像 X_k 中产生镜像图像 X_{m_k} , 然后分解 X_k 成偶对称图像 X_{e_k} 和奇对称图像 X_{o_k} 。
- 2) 通过式(6)和式(7)分别计算出 C_e 和 C_o , 然后分别在 C_e 和 C_o 上进行特征分解得到特征向量 V_e 和 V_o 。
- 3) 通过特征值排序, 然后选择具有较大特征值所对应的特征向量 V_e 和 V_o 组成特征变换矩阵 $V = (V_e, V_o)$ 。
- 4) 使用公式 $Y = X V$ 就可以获得测试图像 X 的主成分。

3 实验结果及分析

为了比较 STDPCA 和 SPCA, TDPCA 的性能, 我们在两个著名的人脸数据库 ORL^[7] 和 YALE^[8] 上进行实验。这里的实验主要是比较这些算法的最好识别率和奇偶特征的选择。在所有的实验中, 首先, 这些图像都要经过预处理, 即直方图均衡、归一化到零均值; 然后分别应用 SPCA、TDPCA 和 STDPCA 提取人脸图像的特征; 最后采用线性支持向量机^[9] 进行分类。

3.1 ORL 人脸库

ORL 人脸库包含 40 人的脸图像, 其中每个人有 10 幅图像, 总共 400 幅图像。这些图像的采集是在不同时间进行的, 同时也包含了不同表情(开眼、闭眼、微笑等), 甚至装饰上也不同, 例如带眼睛和不带眼睛等。ORL 人脸库的特点: 每个人都具有同等数量的脸图像; 表情和视角和面部细节上都有丰富的变化; 光照条件的差异是不大的。

ORL 库中的原始的人脸图像都是 92×112 的 256 级灰度图像。为了比较这些算法的性能, 我们随机选择每个人的 10 幅图像的 1, 2, 3, 4, 5 幅作为训练样本, 余下的图像作为测试样本。

分别应用 SPCA、TDPCA 和 STDPCA 作为特征提取算法所得到最高识别率如图 1 所示。同时, 使用 SPCA、TDPCA 及 STDPCA 进行特征提取的平均时间比较如表 1。

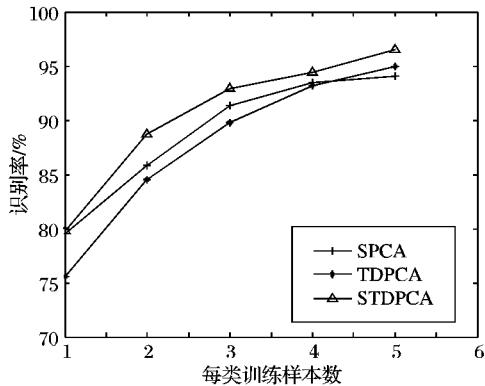


图 1 SPCA、TDPCA 及 STDPCA 在 ORL 库上的识别率比较

表 1 SPCA、TDPCA 及 STDPCA 特征提取的平均时间比较(每类 1 个训练样本时)

算法	特征提取时间/s
SPCA	14.42
TDPCA	10.76
STDPCA	12.36

在图 1 中, 横坐标为每类训练样本数, 纵坐标为识别率。当同样采用每个人的 5 幅图像进行训练时, SPCA 算法获得的最高识别率为 92.1%; TDPCA 算法获得的最高识别率为 94.5%; 而本文所提出的 STDPCA 算法获得的最高识别率为 96.4%。其实从整个图形曲线来看, 不管是对于每类或每个人, 不管是采用几幅图像作为训练样本, STDPCA 算法在识别率上都高于 SPCA 和 TDPCA。但是从表 1 也看到, 由于引入了对称性思想, 也增加了计算量, 所以 STDPCA 算法的训练时间要大于 TDPCA 算法, 这也是本算法的弱点。但是相对于 SPCA 算法来说, STDPCA 花费较少的时间, 这是因为进行特征分解时直接在图像矩阵中进行, 而不需要展开成一向量。

关于偶对称特征和奇对称特征数的选择问题, 可以参看表 2。从表 2 中可以看到, 在 STDPCA 算法中, 当提取的特征

总数为 40 时,偶对称特征数为 34,奇对称特征数为 6,这说明了偶对称特征具有较大的能量,证明了前面的理论分析。

表 2 总特征数、奇对称特征和偶对称特征数比较

算法	偶对称特征	奇对称特征	总特征数
SPCA	32	8	40
STDPCA	34	6	40

3.2 YALE 人脸库

YALE 人脸库包含了 15 个人共 165 幅人脸图像,其尺度大小为 96×116 。每人 11 幅图像,包括了光源、表情,以及装饰物等的变化图像,并且部分人脸图中还故意加入了严重扭曲变形的脸部图像。YALE 库的特点是:样本数较少,可用来考查识别方法在小样本情况下的识别能力;库中人脸图像变化丰富,可以充分考查特征提取算法对各影响因素的鲁棒性。

由于上一个实验已经对这些算法进行了全面的比较,因此,由于篇幅所限,下面只给出了这三种算法在识别性能方面的比较。为了比较这三种算法的综合性能,我们采用留一法(Leave-one-out),然后得到这三种算法的最好识别率如表 3 所示。

表 3 SPCA、TDPCA 和 STDPCA 在 YALE 库上的比较

算法	最高识别率/%
SPCA	94.5
TDPCA	96.6
STDPCA	97.5

从表 3 可以看出,STDPCA 算法的识别率要比 SPCA 和 TDPCA 要高,这主要是由于 STDPCA 不仅考虑到人脸的对称性特点,而且也有效利用了人脸的结构信息。这个实验再一次验证了 STDPCA 算法的有效性。

3.3 实验分析

我们所提出的基于对称的二维主成分分析算法之所以能在人脸识别中获得较高的识别率,从理论上分析有下面几个原因:1)从式(6)和式(7)可以看出,我们所获得的偶对称特征和奇对称特征是通过所有的训练样本获得的,所以所获得的特征是训练人脸样本中最本质的特征;2)人脸本来就具有近似的对称性,因为我们考虑人脸的这种对称特性,所以和仅仅利用二维主成分分析提取特征相比,肯定获得更高的识别

率;3)因为直接使用二维人脸图像进行计算,由于有效地利用了人脸图像的结构信息,相对于没有利用结构信息的对称主成分分析算法来说,那么肯定在识别率上有很大的提高;4)把图像分为偶对称图像和奇对称图像,这无形中增加了训练样本的个数,所以在样本数较少时也能获得较高的识别率。因此,把人脸二维主成分分析的优点和利用人脸对称的特性有机结合起来,那么获得较高的识别率就是理所当然的结果。

4 结语

本文所提出的 STDPCA 算法集成了 SPCA 算法和 TDPCA 算法的优点,即它不仅考虑了人脸的对称性特性,而且减少了计算代价,因为它不需要把图像矩阵展开成向量。同时,STDPCA 算法可以获得两类图像,即偶对称图像和奇对称图像,因此当训练样本很少时可以得到较高的精度。总之,STDPCA 在人脸识别精度上要优于 SPCA 和 TDPCA。

参考文献:

- [1] TURK M, PENTLAND A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71 - 86.
- [2] YANG Q, DING X. Symmetrical PCA in face recognition[C]// Proceedings of IEEE ICIP2002. New York: IEEE Press, 2002, II: 97 - 100.
- [3] YANG J, ZHANG D, FRANGI A F, 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.
- [4] 李强, 裴正定, 孙冬梅, 等. 基于改进二维主成分分析的在线掌纹识别[J]. 电子学报, 2005, 33(10): 1886 - 1889.
- [5] 祝磊, 朱善安. 基于二维广义主成分分析的人脸识别[J]. 浙江大学学报: 工学版, 2007, 41(2): 264 - 267.
- [6] 陈伏兵, 陈秀宏, 高秀梅, 等. 二维主成分分析方法的推广及其在人脸识别中的应用[J]. 计算机应用, 2005, 25(8): 1767 - 1770.
- [7] ORL database[EB/OL]. [2007-05-05]. <http://www.uk.research.att.com/pub/data/attfaces.tar>.
- [8] YALE database[EB/OL]. [2007-06-18]. <http://cvc.yale.edu/projects/yalefacesB/yalefacesB.html>.
- [9] VAPNIK V N, The nature of statistical learning theory[M]. New York: Springer-Verlag, 1995.

(上接第 121 页)

最好结果几乎超出 PCA 4%,这是因为 EPCA 利用了集成中成员分类器的差异性。

表 3 分类结果比较(训练集与测试集比例为 6:4)

维数	PCA	Average	EPCA
5	59.38	58.13	64.50
10	76.25	76.38	82.00
15	84.38	82.29	88.12
20	86.25	84.42	90.38
25	86.88	85.33	90.62
30	88.75	86.08	91.50
35	88.75	86.87	92.12
40	88.75	87.37	93.00

4 结语

本文提出了基于 PCA 集成的模式分类方法——EPCA。由随机子空间方法 RSM 获得多个 PCA 投影变换,从而获得

多个初始分类器,然后选择一组分类器进行集成。在人脸识别中的应用表明,EPCA 能够更好地对模式进行分类。

参考文献:

- [1] MAXIM A G. On internal representations in face recognition systems[J]. Pattern Recognition, 2000, 33(8): 1161 - 1177.
- [2] DIETTERICH T G. Ensemble methods in machine learning[C]// Proceeding of First International Workshop on Multiple Classifier Systems. New York: Springer-Verlag, 2000: 1 - 15.
- [3] HO T K. The random subspace method for constructing decision forests[J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 1998, 20(8): 832 - 844.
- [4] SHARKEY A J C, SHARKEY N E, GERECKE U, et al. The "test and select" approach to ensemble combination[C]// Lecture Notes in Computer Science 1857. New York: Springer-Verlag, 2000: 30 - 44.
- [5] 周志华, 陈世福. 神经网络集成[J]. 计算机学报, 2002, 25(1): 1 - 8.