

文章编号:1000-582X(2012)08-134-05

分块 PCA 和奇异值分解相结合的人脸识别算法

印 勇,何文娟,郭之强,郭 攀,徐亦达

(重庆大学 通信工程学院,重庆 400044)

摘 要:针对分块 PCA 算法对位移、旋转等几何变化比较敏感的缺点,提出一种基于分块 PCA 和奇异值分解相结合的人脸识别算法。该算法分别提取分块子图像的 PCA 特征和奇异值特征,在此基础上得到同时包含分块 PCA 和奇异值信息的距离测度,利用最小距离分类器进行分类识别。在 ORL 人脸库上的实验结果表明,该方法能够得到较高的识别率。

关键词:人脸识别;分块 PCA;奇异值分解;分类器

中图分类号:TP391.41

文献标志码:A

A face recognition method based on modular PCA and SVD

YIN Yong, HE Wenjuan, GUO Zhiqiang, GUO Pan, XU Yida

(College of Communication Engineering, Chongqing University, Chongqing 400044, P. R. China)

Abstract: In order to solve the problem that modular PCA method is sensitive to translation, rotation and other geometric transform, a face recognition method based on modular PCA and singular value decomposition (SVD) is proposed. The PCA features of sub-image and SVD features are extracted respectively. The distance measure that fuses information of modular PCA and SVD is obtained. Minimum distance classifier is used to face recognition. Experimental results on ORL human face database show that the proposed method can obtain higher recognition rate.

Key words: face recognition; modular PCA; SVD; classifier

人脸识别是模式识别研究领域的重要课题,也是一个目前非常活跃的研究方向。人脸识别是一种非接触式的身份识别技术,它与指纹和虹膜等接触式方法相比具有很多优点。人脸识别技术应用背景广泛可用于公安系统的罪犯身份识别、驾驶执照及护照等与实际持证人的核对、银行及海关的监控系统及自动门卫系统等^[1-2]。

目前,已经有很多人脸识别算法^[3-6]。其中,主成分分析(principal component analysis, PCA)被认为是最成功的线性鉴别算法之一,它的目的是在最小均方意义下寻找最能代表原始数据的投影^[7-8]。不仅可以有效地降低人脸图像的维数,同时又能保留主要的识别信息。但是由于 PCA 方法受光照条

件和人脸姿势变化的等影响较大,识别效果并不理想。实际上,当人脸表情和光照条件变化时,只有部分人脸区域变化明显,而其他部分变化不大,甚至没有变化,基于这一特点,Rajkiran^[9]等提出了分块 PCA(modular PCA, MPCA)算法,较大程度地改善了对人脸表情和光照条件变化较大的人脸识别效果。但 MPCA 算法作为一个子空间方法,对位移、旋转和其他一些几何变化比较敏感,该方法在图像平移、旋转和其他一些几何变换后识别率严重下降。

奇异值分解^[10-11](singular value decomposition, SVD)是一种有效的代数特征提取方法,用奇异值描述的图像特征,具有位移、旋转不变性等优点^[12],SVD 的这一优点正好弥补 MPCA 在这一方面的不足。因

收稿日期:2011-08-18

基金项目:中央高校基本科研业务费资助项目(CDJXS10160007)

作者简介:印勇(1963-),男,重庆大学博士,主要从事图像处理与识别方向研究,(E-mail) yongyin@cqu.edu.cn。

此,提出分块 PCA 和奇异值分解相结合的人脸识别算法,以 SVD 特征的几何不变性来克服分块 PCA 的几何变化敏感性,有效地提高了识别率。

1 分块 PCA 算法

分块 PCA 算法^[13-14]首先将人脸图像分成若干块子图像,然后对每个子图像进行 PCA 算法分析。采用最小距离分类器分类。具体步骤如下

1) 设人脸样本库总共有 B 个不同的人,第 i 个人有 b 个训练样本图像矩阵: $\mathbf{I}_{i1}, \mathbf{I}_{i2}, \dots, \mathbf{I}_{ib}$, ($i=1, 2, \dots, B$)。大小为 $M \times N$ 的训练样本图像 \mathbf{I}_{ij} , ($i=1, 2, \dots, B, j=1, 2, \dots, b$) 的 $p \times q$ 分块矩阵可表示如下

$$\mathbf{I}_{ij} = \begin{Bmatrix} \mathbf{I}_{ij(11)} & \mathbf{I}_{ij(12)} & \cdots & \mathbf{I}_{ij(1q)} \\ \mathbf{I}_{ij(21)} & \mathbf{I}_{ij(22)} & \cdots & \mathbf{I}_{ij(2q)} \\ \cdots & \cdots & \cdots & \cdots \\ \mathbf{I}_{ij(p1)} & \mathbf{I}_{ij(p2)} & \cdots & \mathbf{I}_{ij(pq)} \end{Bmatrix}, \quad (1)$$

每个子图像大小是 $m \times n$ ($m=M/p, n=N/q$)。所有样本的平均脸矩阵为 $\bar{\mathbf{I}} = \frac{1}{L} \sum_{i=1}^B \sum_{j=1}^b \sum_{k=1}^p \sum_{l=1}^q \mathbf{I}_{ij(kl)}$, 样本子图像总数为 $L = (B \times b \times p \times q)$: 于是,所有样本的子图像矩阵的总体散布矩阵为

$$\mathbf{C} = \frac{1}{L} \sum_{i=1}^B \sum_{j=1}^b \sum_{k=1}^p \sum_{l=1}^q (\mathbf{I}_{ij(kl)} - \bar{\mathbf{I}})(\mathbf{I}_{ij(kl)} - \bar{\mathbf{I}})^T. \quad (2)$$

容易证明 \mathbf{C} 为非负定矩阵。

2) 特征提取。得到协方差矩阵后,计算出其特征值和与之对应的特征向量。将特征值从大到小排列,从中选出 P 个最大的特征值,并选出 P 个最大特征值对应的标准正交的特征向量 $\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_P$ 。记 $\mathbf{V} = [\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_P]$, $P \in R^{(m \times n) \times P}$, 称最优投影矩阵。

样本 \mathbf{I}_{ij} 的特征矩阵为 $\mathbf{W}_i = \mathbf{V}^T \times (\mathbf{I}_{ij} - \bar{\mathbf{I}})$ 。

3) 分类识别。经过上面的运算之后,每幅子图像对应着一个 MPCA 特征矩阵。先将待测图像进行分块,然后将每个子矩阵投影到投影矩阵上,得到待测图像的特征矩阵。待测图像 J 的 $p \times q$ 分块

$$\mathbf{J} = \begin{Bmatrix} J_{11} & J_{12} & \cdots & J_{1q} \\ J_{21} & J_{22} & \cdots & J_{2q} \\ \cdots & \cdots & \cdots & \cdots \\ J_{p1} & J_{p2} & \cdots & J_{pq} \end{Bmatrix},$$

其特征矩阵为 $\mathbf{W} = \mathbf{V}^T \times (\mathbf{J} - \bar{\mathbf{I}})$ 。

最后,可以运用最小距离分类器完成分类识别。比较待测图像的特征向量与样本图像的特征向量间的距离,将该待测人脸图像分为距离最小的样本图

像的那个类。

2 奇异值分解

奇异值分解(SVD)是一种有效的代数特征提取方法。近年来,图像的奇异值已经作为特征向量被成功地应用于人脸识别领域。奇异值分解定理如下^[15]

设 $A \in R^{s \times t}$ (不失一般性,设 $s \geq t$), $\text{rank}(A) = r$, 则存在 $\mathbf{U} = [u_1, u_2, \dots, u_s] \in R^{s \times s}$, $\mathbf{U}\mathbf{U}^T = \mathbf{I}$ 和 $\mathbf{V} = [v_1, v_2, \dots, v_t] \in R^{t \times t}$, $\mathbf{V}\mathbf{V}^T = \mathbf{I}$, 以及对角矩阵 $\mathbf{S} = \text{diag}[\lambda_1, \lambda_2, \dots, \lambda_r, 0, \dots, 0] \in R^{s \times t}$, $\lambda_1 > \lambda_2 > \dots > \lambda_r > 0$ 使得下式成立

$$\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^T = \sum_{i=1}^r \lambda_i \mathbf{u}_i \mathbf{v}_i^T, \quad (3)$$

其中, λ_i 同时是 $\mathbf{A}\mathbf{A}^T$ 和 $\mathbf{A}^T\mathbf{A}$ 的特征值, \mathbf{u}_i 和 \mathbf{v}_i 分别是 $\mathbf{A}\mathbf{A}^T$ 和 $\mathbf{A}^T\mathbf{A}$ 对应于 λ_i^2 的特征向量。称 λ_i 为奇异值。把奇异值 λ_i 构成的向量作为奇异值特征向量。将图像 \mathbf{I}_{ij} ($i=1, 2, \dots, B, j=1, 2, \dots, b$) 得到的奇异值特征向量记为 \mathbf{s}_i , 待测图像 \mathbf{J} 得到的奇异值特征向量记为 \mathbf{s} 。同样可以利用最小距离分类器分类。

3 分块 PCA 和奇异值分解相结合的算法

融合的目的是获得比单个分类器更高的分类精度,如果对现有的分类器(或不同方法提取的特征)融合并取得更好的效果,也是很经济,很有意义的。

分类器融合分为特征层上的融合和决策层上的融合。研究涉及的是特征层上的融合,对一幅灰度图像提取 MPCA 特征和 SV 特征,融合这两种特征来完成最后的分类。融合能提高分类性能的前提是,不同特征有一定的独立性和信息互补性。MPCA 方法把每一幅图像都看做了高维空间中的一个点,对位移、旋转和其他一些几何变化比较敏感。而奇异值特征具有位移、旋转不变性等优点。所以考虑到将 MPCA 与 SVD 方法相结合,即要将 MPCA 与 SVD 各自提取的特征向量进行融合识别。

算法的基本思想是,先对样本库的图像进行分块,然后对每个子图像分别采用主成分分析和奇异值分解,得到样本子图像的 MPCA 特征矩阵和 SVD 特征矩阵。同理得到待测子图像的 MPCA 特征向量和 SVD 特征向量。计算待测子图像与样本子图像的 MPCA 特征和 SVD 特征各自的欧几里距离。在设计分类器时,比较简单的融合方法是求平均和乘法^[16], 通过实验,最终选用乘法得到最终的距离,

即将 MPCA 和 SVD 各自得到的欧几里距离相乘作为最终距离。这样,在分类的时候同时包含了 MPCA 和 SVD 信息,包含了更多的有利于分类的信息,所以比单一的 MPCA 的识别率要高。最后,将最终距离输入到最小距离分类器中完成分类。经过实验证明,识别率得到了一定的提高。

运用最小距离分类器分类识别时,先计算 MPCA 的欧几里距离

$$d_1(W, W_i) = \sum_{i=1}^B \|W - W_i\|_2, i = 1, 2, \dots, B. \quad (4)$$

然后,计算 SVD 的欧几里距离

$$d_1(s, s_i) = \sum_{i=1}^B \|s - s_i\|_2, i = 1, 2, \dots, B. \quad (5)$$

将 2 个距离相乘,得到既包含 MPCA 信息,又包含 SVD 信息的距离

$$d_i = d_1(W, W_i) \cdot d_2(s, s_i), i = 1, 2, \dots, B. \quad (6)$$

如果 $d_h = \min_i d_i$,则待测图像 J 属于第 h 类。

4 实验结果及分析

实验采用的是 ORL 人脸数据库。该人脸库包含了 40 个人脸,每个人有 10 幅不同的图像。图像包含了一定的光照变化、表情变化(睁眼和闭眼,笑与不笑)、面部细节变化(戴眼镜与不戴眼镜)以及一定范围内的旋转,包含比较齐全。这些图像分辨率大小都是 112×92 像素的。图 1 是 ORL 人脸数据库中某人的 10 幅人脸图像。



图 1 ORL 人脸数据库中某人的 10 幅人脸图像

在实验中,对每个人选择前 5 幅作为训练样本,后 5 幅作为测试样本,这样总的训练样本数是 200 幅(分块前)。根据文献[9]和[13],对训练样本原始图像矩阵进行 $2 \times 2, 4 \times 2, 4 \times 4, 8 \times 4$ 分块(记分块数 $T=4, 8, 16, 32$)。3 种情况下子矩阵的大小分别为 $56 \times 46, 28 \times 46, 28 \times 23, 14 \times 23$,对应的特征矩阵大小为 $P \times 4, P \times 8, P \times 16, P \times 32$ (P 为选取的特

征向量个数)。为了便于比较,图 2 给出了结合前后识别率的实验结果。

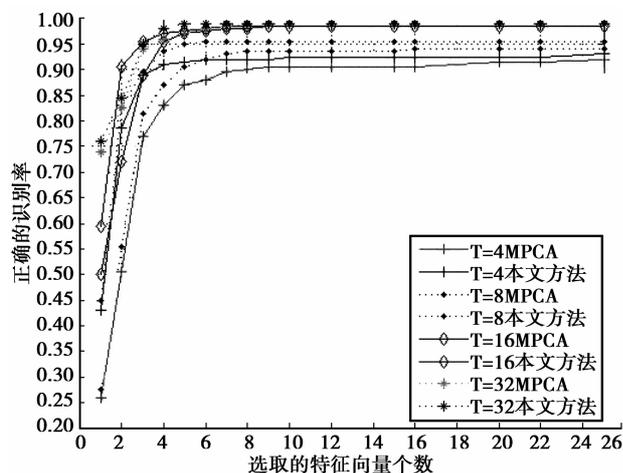


图 2 四种分块结合前后的比较

从图 2 可以看出,无论是单一的 MPCA 方法,还是结合后的方法, $T=32$ 时分块识别率总是最高, $T=16$ 和 $T=8$ 次之, $T=4$ 最低,这是因为,分块数越多,包含了更多有利于分类的局部信息,故识别率越高。而且,三种分块 MPCA 和 SVD 结合的方法比相对应的单一的 MPCA 方法识别率都更高,证明了算法的可行性。MPCA 对位移、旋转和其他一些几何变化比较敏感,SVD 的位移、旋转不变性等优点正好弥补了 MPCA 的这点不足。所以,将两者结合的算法同时包含了 MPCA 特征信息和 SVD 特征信息,故可以提高识别率。从图中还看出,对 $T=4$ 和 $T=8$ 的分块来说,算法识别率高于单一的 MPCA 识别率;但对于 $T=16$ 和 $T=32$ 分块来说,在特征向量个数选择较少时,识别率明显高于单一的 MPCA,当特征向量个数达到一定时,就与单一的 MPCA 识别率保持一致了,这是因为,分块数多了,把有利于分类的细节几乎都包含进来了,SVD 的信息就不是那么有用了。 $T=32$ 分块的识别率最高,达到 99%。实验中还发现,并不是特征向量选取越多越好,并且每种分块选取的最优特征向量个数是不一样的,这与分块密切相关。在选取特征向量时,是按照从大到小的特征值的次序来选择与此相对应的特征向量的,故排在前面的特征向量具有更好的区分性,包含有更多的信息,后面的特征向量包含的信息很少,对分类基本没有多大的作用,选取一些没用的特征向量,会增加不必要的运算量。

为了进一步说明算法的性能,结合图 1,再对算法和单一的 MPCA 算法在 ORL 人脸库上实验得到

的选取的特征个数,误识样本数,识别率,识别时间进行了比较。为了便于比较,对同一种分块方式,选取的特征数是一样的,依据方法所得到的最优特征个数作为标准(从图 1 可以得到)。实验使用

MATLAB 语言编程,在英特尔酷睿 2 双核 T5870@2.00GHz,XP,内存 1.00GB 计算机上进行的。相关实验结果如表 1 所示。

表 1 实验结果比较

| 方法 | MPCA | | | 研究方法 | | |
|----------|---------|--------|--------|---------|--------|--------|
| | T=4 | T=8 | T=16 | T=4 | T=8 | T=16 |
| 选取特征数 | 22 | 10 | 7 | 22 | 10 | 7 |
| 误识样本数 | 15 | 13 | 5 | 14 | 9 | 3 |
| 识别率 | 91.5% | 93.5% | 97.5% | 93% | 95.5% | 98.5% |
| 特征提取时间/s | 173.202 | 32.476 | 4.187 | 173.239 | 32.517 | 4.228 |
| 识别时间/s | 3.156 | 12.656 | 68.375 | 3.264 | 13.625 | 69.832 |

从表 1 的数据可以看出,研究算法识别率高于单一 MPCA 方法,且随着分块数的增加,可选择更少的特征数,就可以达到较高识别率,这给实验带来了很大的方便。在 $T=16$ 分块情况下,特征提取的时间明显减少。这是因为,这种情况下,子块矩阵更小,得到的散布矩阵维数相对另两种维数要小,故花费更少的时间提取特征。但是, $T=16$ 情况下识别时间明显增多,这是由最优特征向量个数和分块数

决定的。分块数越多,循环比较次数越多,花费的时间更多。结合 SVD 算法之后,提出的算法提高了识别率,而特征提取时间和识别时间只比单一 MPCA 略有增加。因此,提出的 MPCA 和 SVD 相结合的算法是有效的。

从识别率、最优特征向量个数以及运算时间等综合考虑,折中选择了 $T=8(4 \times 2)$ 的分块方式,并与相关算法进行比较,实验结果如表 2 所示。

表 2 研究算法与相关算法比较

| 方法 | PCA | SVD | PCA+SVD | MPCA | MPCA+SVD |
|----------|------|------|---------|------|----------|
| 识别特征向量个数 | 70 | 92 | 40 | 16 | 10 |
| 正确识别率/% | 93.8 | 74.9 | 94.5 | 94 | 95.5 |

从表 2 可以看出,提出的 MPCA+SVD 算法的识别率高于 PCA 算法、SVD 算法以及 PCA 和 SVD 融合的算法。PCA+SVD 方法^[17]最高识别率只有 94.5%,而研究方法识别率能达到 95.5%。并且研究所需要的识别特征向量个数远远少于文献[17]的识别特征向量。这是因为 PCA 算法对光照,表情,姿势变化都很敏感,而且 SVD 算法也受光照,表情,姿势变化的影响,故将 PCA 和 SVD 结合的算法对光照、表情变化较大的图像依然效果不好。ORL 人脸库的图像比较齐全,涵盖了姿势变化、光照变化、表情变化各方面的图像,故在 ORL 人脸库上实验效果不佳。而 MPCA 算法对光照、表情变化较大的图像能达到很好的识别效果,针对文献[17]的不足,提出将 MPCA 和 SVD 相结合的算法,有效提高了识别率。

5 结 论

结合分块 PCA 和奇异值分解(SVD)的优缺点与互补性,提出了将两者结合的人脸识别算法。使用 ORL 人脸库进行实验,通过与相关算法的结果比较,证明了该算法能够有效地提高识别率。

参考文献:

- [1] 张翠平,苏光大. 人脸识别技术综述[J]. 中国图象图形学报, 2000, 5(11): 885-894.
ZHANG Cuiping, SU Guangda. Human face recognition: a survey [J]. Journal of Image and Graphics, 2000, 5(11): 885-894.
- [2] 吴巾一,周德龙. 人脸识别方法综述[J]. 计算机应用研究, 2009, 26(9): 3205-3208.
WU Jinyi, ZHOU Delong. Survey of face recognition [J].

- Application Research of Computers, 2009, 26(9): 3205-3208.
- [3] Lu J W, Plataniotis K N, Venetsanopoulos A N. Face recognition using LDA-based algorithms [J]. IEEE Transactions on Neural Networks, 2003, 14(1): 195-200.
- [4] Keun-chang K, Pedrycz W. Face recognition using an enhanced independent component analysis approach [J]. IEEE Transactions on Neural Networks, 2007, 18(2): 530-541.
- [5] Othman H, Aboulnasr T. A separable low complexity 2D HMM with application to face recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(10): 1229-1238.
- [6] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. Neural Computation, 2001, 15(6): 1373-1396.
- [7] Turk M, Pentland A. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86.
- [8] 李盛文, 鲍苏苏. 基于 PCA+AdaBoost 算法的人脸识别技术 [J]. 计算机工程与应用, 2010, 46(4): 170-173.
- LI Shengwen, BAO Susu. Face recognition based on PCA+AdaBoost algorithm [J]. Computer Engineering and Application, 2010, 46(4): 170-173.
- [9] Gottumukkal R, Asari V K. An improved face recognition technique based on modular PCA approach [J]. Pattern Recognition Letters, 2004, 25(4): 429-436.
- [10] Hong Z Q. Algebraic feature extraction of image for recognition [J]. Pattern Recognition, 1991, 24(3): 211-219.
- [11] Tian Y, Tan T, Wang Y H, et al. Do singular values contain adequate information for face recognition [J]. Pattern Recognition, 2003, 36(6): 649-655.
- [12] 杜干, 朱雯君. 基于局部奇异值分解和模糊决策的人脸识别方法 [J]. 中国图象图形学报, 2006, 11(10): 1456-1459.
- DU Gan, ZHU Wenjun. Face recognition method based on singular value decomposition and fuzzy decision [J]. Journal of Image and Graphics, 2006, 11(10): 1456-1459.
- [13] 任小康, 李文静, 靳艳峰. 基于粗糙集和 mPCA 的人脸识别算法 [J]. 计算机工程, 2008, 34(14): 179-181.
- REN Xiaokang, LI Wenjing, JIN Yanfeng. Face recognition algorithm based on rough set and mPCA [J]. Computer Engineering, 2008, 34(14): 179-181.
- [14] 李晓东, 费树岷. 一种改进的模块 2DPCA 人脸识别新方法 [J]. 系统仿真学报, 2009, 21(15): 4672-4675.
- LI Xiaodong, FEI Shumin. New face recognition method based on improved modular 2DPCA [J]. Journal of System Simulation, 2009, 21(15): 4672-4675.
- [15] 梁毅雄, 龚卫国, 潘英俊, 等. 基于奇异值分解的人脸识别方法 [J]. 光学精密工程, 2004, 12(5): 543-549.
- LIANG Yixiong, GONG Weiguo, PAN Yingjun, et al. Singular value decomposition-based approach for face recognition [J]. Optics and Precision Engineering, 2004, 12(5): 543-549.
- [16] Tax D M J, Van Breukelen M, Duin R P W, et al. Combining multiple classifiers by averaging or by multiplying [J]. Pattern Recognition, 2000, 33(9): 1475-1485.
- [17] 庞彦伟, 刘政凯, 俞能海. 融合奇异值分解和主分量分析的人脸识别算法 [J]. 信号处理, 2005, 21(2): 202-205.
- PANG Yanwei, LIU Zhengkai, YU Nenghai. Fusion of SVD and PCA for face recognition [J]. Signal Processing, 2005, 21(2): 202-205.

(编辑 侯 湘)