

一种基于联合 CSVD-2DNMF 的人脸识别算法

李孔震 王炳和

(武警工程大学通信工程系, 西安 710086)

摘要 类估计基空间奇异值分解算法(CSVD)克服了奇异值分解(SVD)造成的重构图像基空间不一致的本质缺陷,但在一定程度上削弱了图像的类别特征。二维非负矩阵分解算法(2DNMF)能在一定程度上避免 NMF 识别算法中因图像向量化而造成的结构信息丢失、内存消耗大等不足,但是随着训练样本数量的增多,迭代速度慢、训练时间长等缺陷也将凸显。根据 CSVD 与 2DNMF 的优缺点,提出了人脸识别的联合 CSVD-2DNMF 算法,进而运用提出的算法在 Matlab 平台上对 ORL 人脸数据库中的人脸图像进行了识别实验。实验结果表明该算法能有效的缩短训练时间和提高识别率。

关键词 人脸识别 奇异值分解 类估计基空间奇异值分解 非负矩阵分解 二维非负矩阵分解 联合 CSVD-2DNMF

中图法分类号 TP391.41;

文献标志码 A

人脸识别隶属于模式识别的范畴,是近几年来模式识别领域的研究热点。人脸识别的一般步骤如图 1 所示。

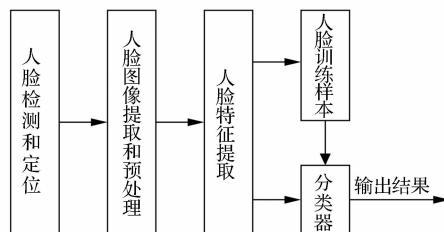


图 1 人脸识别的步骤

子空间分析法是人脸特征提取阶段的主流方法之一,其基本思想就是根据一定的性能目标来获取一个线性或非线性的空间变换,把原始数据压缩到一个低维子空间中,使数据在子空间的分布更为紧凑,为分类提供更好的特征描述。同时,也大大降低了计算的复杂度^[1]。非负矩阵分解(Non Negative Matrix Factorization, NMF)^[2]是目前国际上新的

矩阵分解方法,较系统的 NMF 理论由 D. D. Lee 和 H. S. Seung 在 1999 年《Nature》上提出并同时用于人脸识别^[2]。近十年来,有关 NMF 方面的算法和应用等理论研究也在激烈的展开。奇异值分解算法(SVD)它通过对矩阵的分解和近似,有效地对任意矩阵进行降维,从而达到简化分析的目的。

中国的洪子泉和杨静宇^[3,4]首次将奇异值分解(SVD)用到人脸识别中。高全学等人^[5]通过深入分析奇异值的特性指出,图像奇异值是图像在特定基空间分解得到的,这个基空间是由图像本身决定的。进而研究发现不同人脸图像对应的奇异值向量所在的基空间不一致、奇异值向量与人脸图像之间并不存在一一对应的关系以及奇异值向量的不可分割性,此三者导致了基于 SVD 人脸识别算法识别率低;最后他们提出了类估计基空间识别算法(CSVD)。姚同庆^[6]等在此基础上提出了 CSVD 算法与 NMF 特征数据相融合的人脸识别算法。但是随着训练样本类别的增加,图像向量化产生的高维数据将促使 CSVD-NMF 算法的训练时间增加,以及识别精度下降。

为了有效降低训练时间,本文在上述算法基础上提出了一种 CSVD 和 2DNMF 相结合的改进算法。

1 类估计基空间奇异值分解(CSVD)

1.1 奇异值分解(SVD)

设 $A \in C_r^{m \times n}$ ($r > 0$), 则 $\lambda_1 \geq \lambda_2 \geq \lambda_3 \cdots \lambda_r > \lambda_{r+1} = \cdots = \lambda_n = 0$ 为 $A^H A$ 的特征值, 称 $\sigma_i = \sqrt{\lambda_i}$ ($i = 1, 2, \dots, n$) 为 A 的奇异值, 则存在 m 阶酉矩阵 U 和 n 阶酉矩阵 V , 使得

$$U^H A V = \begin{bmatrix} \Sigma & 0 \\ 0 & 0 \end{bmatrix} \quad (1)$$

$\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$, σ_i ($i = 1, 2, \dots, r$) 为 A 的非零奇异值, 所以(1)式改写为:

$$A = U \begin{bmatrix} \Sigma & 0 \\ 0 & 0 \end{bmatrix} V^H \quad (2)$$

称式(1)为 A 的奇异值分解。

1.2 CSVD 算法

类估计空间奇异值分解算法的基本原理是通过构造误差识别人脸和对测试人脸相似度的比较来分类人脸图像, 重构后的图像不存在基空间不一致的问题, 因此避免了 SVD 算法的本质缺陷^[5,7]。因为同类图像的基空间相似度比较大, 所以用类估计基空间作为重构误差识别人脸的基空间时误差会比较小。假设训练样本类别数为 C , CSVD 用于人脸识别的计算步骤如下:

(1) 读取人脸图像并计算第 i 类人脸图像的平均脸 P_i ($i = 1, 2, \dots, C$);

(2) 对 P_i 进行 SVD 分解;

(3) 利用 SVD 定理求 P_i 的前 n 个较大奇异值矩阵 $\Sigma_n = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n)$ 及其对应的特征向量矩阵 U_n 和 V_n , 利用公式(1)构造第 i 个模板人脸 $P'_i = U_n \Sigma_n V_n^H$;

(4) 对测试图像 P_T 进行 SVD 分解, 根据步骤(3)的规则重构图像 P'_T ;

(5) 利用欧式距离比较 P'_T 与 P'_i 的误差, 根据最邻近准则进行分类。

2 二维非负矩阵分解(2DNMF)

2.1 NMF 的基本原理^[2]

非负矩阵分解(NMF)算法, 可以简略描述如下: 给定非负矩阵 $V \in R_+^{n \times m}$, 利用迭代的方法来寻

找 $W \in R_+^{n \times r}$, 以及 $H \in R_+^{r \times m}$, 使得 $V \approx WH$, NMF 的求解问题实际上是一个最优化问题, 利用迭代的方法求解 W 和 H 。

迭代规则 1:

$$W_{ik} = W_{ik} \frac{(VH^T)_{ik}}{(WHH^T)_{ik}} \quad (3)$$

$$H_{kj} = H_{kj} \frac{(W^T V)_{kj}}{(W^T WH)_{kj}} \quad (4)$$

评价函数:

$$F = \|V - WH\| = \sum_i \sum_j (V_{ij} - (WH)_{ij})^2 \quad (5)$$

该评价函数用以计算 V 和 WH 间的欧氏距离, 并用来评价两者的近似度。

迭代规则 2:

$$W_{ik} \leftarrow W_{ik} \frac{\sum_j H_{kj} V_{ij} / (WH)_{ij}}{\sum_j H_{kj}} \quad (6)$$

$$H_{kj} \leftarrow H_{kj} \frac{\sum_i W_{ik} V_{ij} / (WH)_{ij}}{\sum_i W_{ik}} \quad (7)$$

其评价函数是矩阵 V 与矩阵 WH 推广的 $K-L$ 离散度:

$$D(V \parallel WH) = \sum_i \sum_j \left(V_{ij} \lg \frac{V_{ij}}{(WH)_{ij}} - V_{ij} + (WH)_{ij} \right) \quad (8)$$

NMF 方法相对于传统的一些算法而言, 具有实现上的简便性、分解形式和分解结果的可解释性以及占用存储空间少等众多优点, 同时 NMF 具有对数据良好的夹逼性, 与其他矩阵分解方法相比, 能使特征子空间对数据的表示更为紧凑而有效, 但是其特征子空间类别信息模糊。

传统子空间算法提取图像特征时, 大都将二维图像按像素扫描顺序排列为列向量, 然后用一组基向量表示它们。这样使得二维图像变成高维向量, 将会丢失图像结构信息, 并且图像尺寸越大, 该向量的维数越高, 越容易造成维数灾难^[8]。图像向量化将会造成其结构信息丢失, 可能对分类识别造成负面影响; 图像向量化的高维数据会导致训练矩阵的奇异性, 使得 NMF 的分解速度慢、内存占用花销

大;由于图像信息冗余,所以 NMF 提取的特征可能对于分类的目的良莠不齐。

2.2 2DNMF 算法^[9]

和 NMF 的不同的是,2DNMF 不进行图像向量化,而是将图像看作二维矩阵并且用二维基组表示,所以它更能考虑图像的结构信息。2DNMF 算法包括列非负矩阵分解和行非负矩阵分解两部分。

2DNMF 分解步骤:

(1) 将大小为 $p \times q$ 的 m 幅人脸图像用矩阵 $X_{p \times qm} = [A_1, A_2, \dots, A_m]$ 表示, A_k 代表 m 幅人脸图像中的一幅图像矩阵;

(2) 找出一个大小为 $p \times d$ 的非负矩阵 L 和一个大小为 $d \times qm$ 的非负矩阵 H ,对 $X_{p \times qm}$ 进行 NMF,使得:

$$X_{p \times qm} \approx L_{p \times d} H_{d \times qm} \quad (9)$$

式(9)中 $L_{p \times d} = [L_1, L_2, \dots, L_d]$, $H_{d \times qm} = [H_1, H_2, \dots, H_m]$;

(3) 构造一个新的 $q \times dm$ 大小的非负矩阵 $H'_{q \times dm} = [H_1^T, H_2^T, \dots, H_m^T]$;

(4) 找出一个大小为 $q \times g$ 的非负矩阵 R 和一个大小为 $g \times dm$ 的非负矩阵 C , 使得:

$$H'_{q \times dm} \approx R_{q \times g} C_{g \times dm} \quad (10)$$

$R_{q \times g}, C_{g \times dm}$ 分别为基矩阵和系数矩阵;

(5) 令 $R_{q \times g} = [R_1, R_2, \dots, R_g]$ 、 $C_{g \times dm} = [C_1, C_2, \dots, C_m]$, 则对任意 A_k 有:

$$A_k \approx L_{p \times d} C_k^T R^T, k = 1, 2, \dots, m \quad (11)$$

(6) 则 2DNMF 的二维基定义为:

$$E_{ij} = L_i R_j^T (1 \leq i \leq d, 1 \leq j \leq g) \quad (12)$$

其中步骤(2)称为 2DNMF 的列分解,步骤(4)称为 2DNMF 的行分解。从理论和实验可以得知,当 m 值较小的时候,2DNMF 较 NMF 算法分解速度明显加快;但当 m 值和图像的大小相当时,2DNMF 的分解速度和 NMF 的分解速度相差无几,甚至比 NMF 更慢。

3 联合 CSVD-2DNMF 算法

CSVD 虽然克服了 SVD 重构图像基空间不一致的缺陷,实际中确实存在具有相同奇异值向量的不同人脸图像,这些图像有可能属于同一类别,也可

能属于不同类别,所以仅仅利用 CSVD 对图像进行分类时可能在一定程度上造成识别率的下降。在训练图像数量较少时,2DNMF 算法能有效克服 NMF 分解速度慢、内存花销大等一系列缺点。如果增大图像数量仍存在训练数据量大、迭代速度慢、训练时间长等问题。通过分析发现 CSVD 与 2DNMF 能互相弥补缺点,结合在一起可以进一步提高人脸识别率,并大大提高训练速度。

设训练样本的类别数为 C ,联合 CSVD-2DNMF 算法步骤:

(1) 从人脸数据库中读取并计算第 i 类人脸图像的平均脸 $P_i (i = 1, 2, \dots, C)$;

(2) 对 P_i 进行 SVD 分解;

(3) 利用 SVD 定理求 P_i 的前 n 个较大奇异值矩阵 $\Sigma_n = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n)$ 及其对应的特征向量矩阵 U_n, V_n ,利用公式(1)构造第 i 个模板人脸 P'_i ,

$$P'_i = U_n \sum_n V_n^H \quad (13)$$

(4) 读入模板人脸 P'_i 数据并存储,形成图像矩阵 $X = [P'_1, P'_2, \dots, P'_C]$;

(5) 对 V 进行 2DNMF 列分解得: $X \approx LH$, 将 H 分为 C 个子矩阵, $H = [H_1, H_2, \dots, H_C]$;

(6) 对 H 进行 2DNMF 行分解,确定阶数大小为 g ,可得 $H \approx RC$, 其中 $R = [R_1, R_2, \dots, R_g]$, $C = [C_1, C_2, \dots, C_c]$;

(7) 读入测试图像 T ,利用步骤(3)构造模板人脸 T' 。可以得到测试图像的系数矩阵:

$$(C_T)^T = L^+ T'(R^T)^+ \quad (14)$$

L^+ 和 $(R^T)^+$ 分别是 L 和 R^T 的 Moore-Penrose 逆矩阵^[10]

$$L^+ = L^H (L L^H)^{-1}, (R^T)^+ = R^H (R^H R)^{-1}.$$

(8) 利用距离度量 C_T 和 C_1, C_2, \dots, C_c 之间的误差,根据最邻近准则进行分类。

4 实验结果及分析

4.1 实验环境

实验条件为 PC 机,CPU 为 2.67 G,内存为 2 G,软件平台为 Matlab2008a。采用的是 10×40 的标准 ORL 人脸数据库,每幅图像大小为 112×92 ,如图 2(a)所示。为提高图像的处理速度和识别率,首先

对图像进行预处理,目的是为了保证所有的人脸在图像中的大小、位置和偏斜的不变性。实际操作中需要去除头发、脖子、肩膀及图像背景等与人脸无关的部分。在特征提取前必须对人脸图像进行几何归一化处理,其大小变为 80×80 ,进而进行直方图均衡。预处理后的图像如图 2(b)所示。

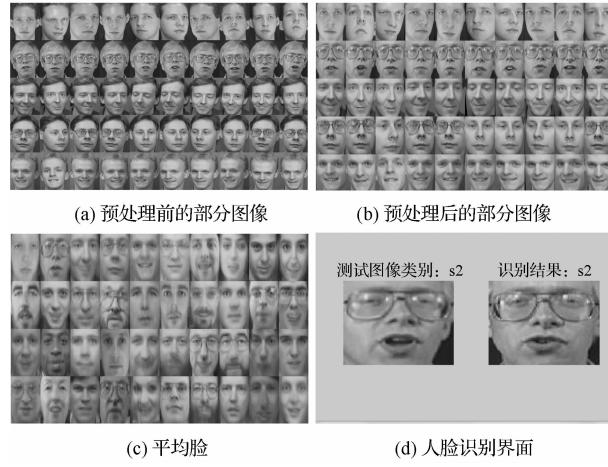


图 2 Matlab 实验中的部分图像

4.2 实验结果和分析

实验说明:训练样本为每个人的前 5 幅图像,其余图像作为测试图像;进行 CSVD 时取前 20 个较大的奇异值;NMF 分解的最大迭代次数为 100 次,误差容忍度为 0.001;进行 2DNMF 和联合 CSVD-2DNMF 列分解时,阶数 $g = 15$ 。

图 3 显示的是 SVD 和 CSVD 在不同特征维数下的训练时间和识别率的比较。从图 3(a)可以看出类估计基空间奇异值分解算法在相同特征维数下的训练时间明显小于奇异值分解算法,从图 4(b)可看出奇异值分解最好识别精度为 53%,类估计基空间奇异值分解算法在特征维数为 10 的时候识别精已达到 61%,其最佳识别率为 89%。可见,类估计基空间奇异值分解算法有效克服了奇异值分解算法的缺陷,比奇异值分解算法更具有优势。

从图 4 可以看出,二维非负矩阵分解算法虽然和非负矩阵分解算法在识别精度上大致相同,但是二维非负矩阵分解算法训练时间明显小于非负矩阵分解算法训练时间。

从图 5 可以看出,本文所提出的联合 CSVD-

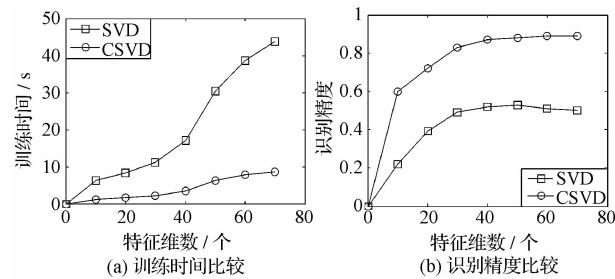


图 3 SVD 和 CSVD 训练时间和识别率的对比

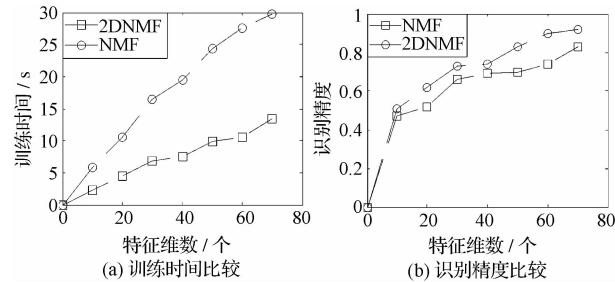


图 4 NMF 和 2DNMF 的比较

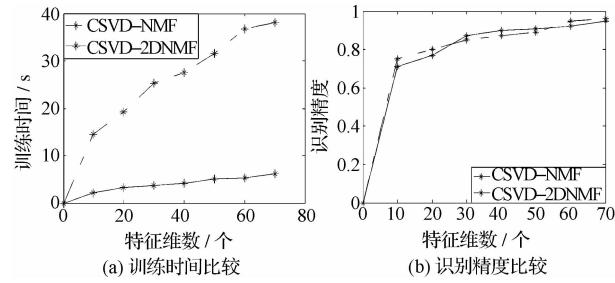


图 5 CSVD-NMF 和联合 CSVD-2DNMF 训练时间和识别率对比

2DNMF 算法和文献[6]所提出的 CSVD-NMF 相比,识别精度相当,但在训练时间上具有明显优势。由图 5(a)可以看出,当特征维数 $r = 40$ 时,CSVD-NMF 算法所用训练时间为 31.5 s,而联合 CSVD-2DNMF 算法所用时间为 4.99 s,可知联合 CSVD-2DNMF 算法的训练时间明显少于 CSVD-NMF 算法。

表 1 几种不同算法的训练时间比较

识别算法	SVD	CSVD	NMF	2DNMF	CSVD-NMF	CSVD-2DNMF
训练时间/s ($r=20$)	8.35	1.64	10.57	4.49	19.21	3.25
训练时间/s ($r=40$)	17.08	3.39	19.53	7.43	27.49	4.19
训练时间/s ($r=60$)	38.6	7.77	27.61	10.59	36.77	5.37

表 2 几种不同算法的最佳识别率比较

识别算法	SVD	CSVD	NMF	2DNMF	CSVD-NMF	CSVD-2DNMF
最佳识别精度	0.53	0.89	0.83	0.92	0.96	0.95

从表 1 可以看出:SVD 和 NMF 的训练时间较长,联合 CSVD-2DNMF 和 CSVD 所用的训练时间明显少于其它算法。说明联合 CSVD-2DNMF 算法较其它算法在训练速度上明显占优。从表 2 可以看出,CSVD-NMF 和联合 CSVD-2DNMF 算法的识别精度较其它算法高。

结合图 3、图 4、图 5 以及表 1、表 2 可以得出结论:联合 CSVD-2DNMF 算法是一种训练速度快,识别精度高的融合算法,比 CSVD-NMF 算法更具有优势。

5 结束语

本文通过研究 SVD 和 NMF 的优缺点,以及 CSVD 和 2DNMF 算法的特点,去劣存优,将 CSVD 和 2DNMF 算法融合在一起,形成了联合 CSVD-2DNMF 算法,并在 ORL 人脸数据库上进行了实验验证,结果表明此算法在样本训练速度和识别精度方面具有明显优势。进一步要做的工作:

- (1)需要增大样本的类别数,并进行不同光照和遮挡实验,以及用户不配合的情况下的人脸识别;
- (2)解决非负矩阵初始化问题,非负矩阵分解

A Face Recognition Algorithm Based on Joint CSVD and 2DNMF

LI Kong-zhen, WANG Bing-he

(Depf. of Communication Engineering, China Armed Police Force's Engineering University, Xi'an 710086, P. R. China)

[Abstract] Although CSVD can eliminate the SVD-caused intrinsic defect that the basic spaces of reconstructed image are disagreed, the features of image classification are not impaired. Because of the image vectorization, the face recognition algorithm based on NMF will cause the lost of structure information and takes more memory. Although 2DNMF avoid these shortcomings caused by NMF, its own defect that the slow iterative convergence speed and the long training time will appear along with the increase of training samples. By combining the advantages and disadvantages of CSVD and 2DNMF, the joint CSVD-2DNMF face recognition algorithm is advanced. Experimental results from ORL face image database by using Matlab show that the efficiency of this advanced fusion method can shorten training time and improve recognition rates effectively.

[Key words] face recognition SVD CSVD NMF 2DNMF joint CSVD-2DNMF

的初始化是影响分解速度的关键环节,但是至今还没有一种非常有效地方法对其进行初始化。

参 考 文 献

- 1 郭丹. 基于子空间分析的图像检索和人脸识别研究. 沈阳:辽宁师范大学, 2011
- 2 Lee D D, Seung H S. Learning the parts of objects with non-negative matrix factorization. *Nature*, 1999; 401: 788—791
- 3 洪子泉, 杨静宇. 用于图象识别的图象代数特征抽取. 自动化学报, 1992; 18(2): 233—238
- 4 洪子泉, 杨静宇. 基于奇异值特征和统计模型的人像识别算法. 计算机研究与发展, 1994; 31(3): 60—65
- 5 高全学, 梁彦, 潘泉, 等. SVD 用于人脸识别存在的问题及解决方法. 中国图象图形学报, 2006; 11(12): 1784—1791
- 6 姚同庆, 房斌, 尚赵伟. 基于 CSVD-NMF 的人脸识别算法. 计算机工程, 2009; 35(3): 214—216
- 7 何婧, 冯国灿. 奇异值分解在人脸识别中的应用. 广东教育学院学报, 2006; 26(3): 92—96
- 8 高宏娟. 基于 NMF 改进算法的人脸识别仿真研究. 计算机仿真, 2011; 28(12): 232—235
- 9 Zhang Daoqiang, Chen Songcan, Zhou Zhihua. Two-dimensional non-negative matrix factorization for face representation and recognition. LNCS 3723: Proceedings of the ICCV'05 Workshop on Analysis and Modeling of Faces and Gestures (AMFG'05), Beijing, China, 2005: 350—363
- 10 徐仲, 张凯院, 陆全, 等. 矩阵论简明教程. 北京: 科学出版社, 2005: 148—150