

一种基于模糊 2DPLA 的人脸识别方法

宋家东¹ 李晓娟¹ 徐鹏飞² 周明全²

(首都师范大学信息工程学院 北京 100048)¹ (北京师范大学信息科学与技术学院 北京 100875)²

摘 要 将模糊集的隶属度函数矩阵嵌入到二维主成分分析以及二维线性判别分析中,形成了一种基于模糊 2DPLA 的新方法。该方法首先通过基于模糊的 KNN 方法求出隶属度函数矩阵;然后将隶属度函数矩阵从图像矩阵的水平方向和垂直方向分别嵌入到二维主成分分析和二维线性判别分析中,从而更好地实现降维;最后采用基于矩阵的 F-范数代替传统的基于向量的 2-范数进行分类度量。实验阶段,采用 Yale Face Database B, ORL 和 FERET 人脸数据库进行了测试和验证。结果证明,该方法具有较好的鲁棒性,并能获得较高的识别率。

关键词 二维化,主成分分析,线性判别分析,模糊集,隶属度

中图法分类号 TP391.41 **文献标识码** A

Novel Face Recognition Method Based on Fuzzy 2DPLA

SONG Jia-dong¹ LI Xiao-juan¹ XU Peng-fei² ZHOU Ming-quan²

(Information Engineering College, Capital Normal University, Beijing 100048, China)¹

(College of Information Science and Technology, Beijing Normal University, Beijing 100875, China)²

Abstract In this paper, a novel method based on fuzzy 2DPLA was proposed which embeds the degree matrix of membership based on the fuzzy set into 2DPCA and 2DLDA methods. This method first calculated the degree matrix of membership using the fuzzy KNN method. In the sequel, the degree matrix of member was embedded into 2DPCA and 2DLDA for reducing the dimension from horizontal and vertical two directions of image matrix, respectively. Last but more importantly, we used the F-norm classification measure based on the matrix instead of the traditional 2-norm measure based on the vector. In experimental phase, Yale Face Database B, ORL and FERET Face Database were used to test the new method. Experimental results demonstrate that our method has better robustness and higher recognition rate than the state-of-art methods.

Keywords Two-dimensional, Principal component analysis, Linear discriminant analysis, Fuzzy set, Degree of membership

1 引言

人脸识别主要是通过计算机分析人脸的图像,并从人脸图像中提取特征信息进行身份识别的过程。人脸识别在信息安全、医学、人机交互等方面有着广泛的应用。其中,主成分分析方法(PCA)^[1]以及线性判别分析(LDA)^[2]已经成为人脸识别领域的经典算法,且取得了巨大成功。但这两种传统的方法都有一些致命的缺陷,如 LDA 容易受到小样本事件(small sample size)的影响,PCA 受光照以及姿态的影响较为严重,同时又由于这两种方法都是针对拉伸的列向量进行操作的,因此很可能破坏原有空间结构以及向量维数无限增长,致使运算时间的开销和存储开销随着维度增大而迅速增加等,即所谓的维度灾难(curse of dimensionality)。针对这些问

题, Yang^[3]首先提出了 2DPCA 方法,即直接对图像矩阵操作,避免了将图像张成向量,从而大大减缓了维数灾难的形成,但是特征矩阵内部仍存在很大的相关性。Kong 等^[4]将其进行了改进,提出了 B2DPCA,不仅从理论上证明了 2DPCA 的可行性,而且将图像矩阵双方向同时进行降维,从而尽可能地剔除图像内部的相关性,但 B2DPCA 仍然只适合数据降维而非分类,而且没有充分解释双向降维结果会不同的具体原因。Kong 等^[5]针对传统 LDA 方法易发生小样本事件这个事实提出了 2DLDA 方法,并且从理论上证明了 2DLDA 方法不再受小样本事件的干扰,然而在图像不受光照等因素影响时,其识别率反而不如 2DPCA。Zhao^[6]提出了判别成分分析方法(DCA),该方法主要分两个阶段,首先使用传统的 PCA 将高维数据映射到低维空间中,然后使用 LDA 方法对 PCA 空

到稿日期:2010-05-05 返修日期:2010-09-27 本文受国家自然科学基金重点项目颅骨面貌的形态学研究(60736008),国家“863”高技术研究发展计划项目基金(2008AA01Z301),北京市自然科学基金重点项目(4081002),北京市“优秀人才培养”项目(20081D0501600187),北京市属市管高校人才强教计划资助项目 PHR(IHLB)资助。

宋家东(1985—),男,硕士生,CCF 学生会会员,主要研究方向为模式分类、机器学习, E-mail: rhadamanthys0407@126.com; 李晓娟(1968—),女,博士,教授,CCF 高级会员,主要研究方向为无线传感器网络、数字图像处理; 徐鹏飞(1982—),男,博士,讲师,CCF 会员,主要研究方向为机器视觉、图形学; 周明全(1954—),男,硕士,教授,CCF 常务理事,主要研究方向为计算机图形学、数字图像处理、科学计算可视化。

间进行分类。虽然该方法能尽可能避免小样本事件(并非完全避免小样本发生),但是被移除的子空间也可能存在重要的鉴别信息,同时在第一阶段是针对长长的列向量进行的,因此也可能出现维度灾难。最近, Yang^[1], M^[7] 等对现有一些文献中关于 ICA, PCA 等组合框架得到了截然相反的实验结论这一现象进行了解释,同时从光照因素、度量距离准则等角度解释了产生自相矛盾结果的原因,而这些关于一维向量处理的观点却对本文二维矩阵框架的选择提供了有利的帮助。Song 等^[8] 提出了基于全局框架的对称 B2DPLS+LDA 框架,该方法主要是对图像进行预处理,将一幅图像分裂成奇偶两幅图像,然后使用 B2DPLS 进行降维,同时利用 LDA 方法进行分类。该方法虽然识别率有明显的提高,而且在样本匮乏的情况下表现突出,但存在增加存储空间的开销、耗时,同时武断地舍弃信息特征等缺点。

本文提出的基于模糊的 2DPLA(即 F2DLPA)算法是同时针对图像矩阵的两个方向采用不同方法进行降维。由于图像矩阵(并非向量)的行投影相关信息较多,而列投影因受光照因素影响较严重,导致相关信息紊乱,但可以提取类别信息,因此本文在图像矩阵行方向中利用 2DPCA 提取不相关信息,而在列方向使用 2DLDA 清晰化类别信息,从而实现更合理的降维。即既能使特征矩阵提取类别信息,又尽可能地减少噪声(简称为 2DPLA 方法);其次,本算法将模糊集的隶属度函数矩阵嵌入到 2DPLA 中,使数据类别之间的分布更有规律,且可扩展应用于半监督人脸识别中,因此其自适应性加强,实用性提高;最后,本文采用了基于矩阵的 F-范数进行分类度量,并从理论上证明了基于矩阵的 F-范数与基于向量的 2-范数相容。

本文第 2 节介绍 F2DPLA 算法的整体框架;第 3 节详细介绍 F2DPLA 算法的核心思想以及算法形成;第 4 节对本方法相关的小结论通过实验的方式进行验证及分析;最后总结全文。

2 F2DPLA 框架

F2DPLA 算法框架由两个部分组成:部分 1 主要通过 FKNN 算法求出模糊集的隶属度矩阵 U ;部分 2 主要将模糊集中的隶属度矩阵嵌入到双方向的 2DPCA 和 2DLDA 方法中。由于处理的对象是图像矩阵而不是向量,因此可以同时利用行、列两个方向进行压缩降维。实验证明,矩阵的行投影含有大量的相关信息,因此适合采用 2DPCA 方法进行降维,并剔除了无用的相关信息;而矩阵的列投影由于受到光照因素的影响较严重,从而导致空间的不相关信息紊乱,但可以利用类别的判别信息,剔除噪声,因此适合使用 2DLDA 方法将空间有用的类别信息提取出来再进行分类。本文简称部分 1 和部分 2 的串联组合框架算法为基于模糊的 2DLPA(即 F2DPLA)算法。




图 1 F2DPLA 算法框架图

具体流程图如图 1 所示。其中, F2DPCA, F2DLDA 分别表示基于模糊的 2DPCA 和基于模糊的 2DLDA 方法。

3 F2DPLA 算法的实现

首先在第 3.1 小节引进模糊集隶属度的概念,并通过 FKNN^[10] 算法,求出模糊集的隶属度矩阵;其次,在第 3.2 小节介绍 F2DPLA 算法的核心思想以及形成;然后,在第 3.3 小节中证明基于最近邻分类器采用 F-范式与传统的 2-范式(即 Euclidean 距离)是相容的;最后,在第 3.4 小节中,总结 F2DPLA 算法设计流程。

3.1 FKNN 算法的设计流程

定义 1 隶属度函数是表示一个对象 x 隶属于集合 A 的程度的函数^[12]。

接着设计基于模糊的 KNN(即 FKNN)算法,并通过此算法求出隶属度函数矩阵。具体流程如下所述。

Step1 宏观上把库中每一幅图像看成高维空间里的每一个点,同时计算出训练集中特征向量对的 Euclidean 距离,如式(1)所示,并以矩阵的形式记录下来:

$$d = \|y - x\|_2 = \sqrt{(y-x)^T(y-x)} \quad (1)$$

Step2 将距离矩阵的对角元素设置为无穷大。

Step3 将距离矩阵的每一列按照升序排列,然后搜集位于样本的最近邻情况下对应的样本的类标签。即如果有 K 个最近邻,则返回一个由 K 个整数组成的列表。

Step4 根据文献[12]的方法,求出第 i 类第 j 个样本的隶属度 u_{ij} :

$$u_{ij} = \begin{cases} 0.51 + 0.49(\frac{n_{ij}}{K}), & i=j \text{ 的类标签} \\ 0.49(\frac{n_{ij}}{K}), & i \neq j \text{ 的类标签} \end{cases} \quad (2)$$

式中, n_{ij} 代表第 j 个属于第 i 类的样本的邻居数, K 代表最近邻的个数。

Step5 将所有的 u_{ij} 隶属度合并成模糊集的隶属度矩阵,即 U :

$$U = [u_{ij}], i=1, 2, \dots, C, j=1, 2, \dots, N_i \quad (3)$$

式中, U 满足如下两个重要属性:

$$\begin{aligned} 0 < \sum_{i=1}^C \sum_{j=1}^{N_i} u_{ij} < C \times N_i \\ \sum_{i=1}^C u_{ij} &= 1 \end{aligned} \quad (4)$$

3.2 F2DPLA 算法的主要理论

通过式(3),可以求出隶属度矩阵并将其嵌入到 2DPLA 中,从而得到 F2DPLA 算法。

具体算法推导如下。

假定 I_{ij} 为图像库中第 i 类第 j 个样本图像矩阵; u_{ij} 为第 i 类第 j 个样本的隶属度; q 为控制隶属度的影响因子且设置一个常数,为了方便起见可以设置为 1。则类内均值矩阵 $Mean_i$ 、总均值矩阵 $TMean$ 、协方差矩阵 Cor 为:

$$Mean_i = \frac{\sum_{j=1}^{N_i} u_{ij}^q I_{ij}}{\sum_{j=1}^{N_i} u_{ij}^q} \quad (5)$$

$$TMean = \frac{\sum_{i=1}^C \sum_{j=1}^{N_i} u_{ij}^q I_{ij}}{\sum_{i=1}^C \sum_{j=1}^{N_i} u_{ij}^q} \quad (6)$$

$$Cor = \frac{1}{C} \sum_{i=1}^C (Mean_i - TMean)(Mean_i - TMean)^T \quad (7)$$

通过计算式(7)Cor的特征值矩阵 Λ_1 和所对应的特征向量矩阵 V_1 ,可以提取出图像空间的行降维矩阵 $V_1^T I_{ij}$ 。同理,根据式(8)、式(9)以及式(10)的Fisher准则函数,求 FS_b/FS_w 的特征值矩阵 Λ_2 和所对应的特征向量矩阵 V_2 ,可以提取出列降维矩阵 $I_{ij} V_2$,并且不受小样本事件影响,如定理1所示。其中 $\det(\cdot)$ 运算代表该式的行列式。

$$FS_b = \sum_{i=1}^C \sum_{j=1}^{N_i} u_{ij}^q (Mean_i - TMean)^T (Mean_i - TMean) \quad (8)$$

$$FS_w = \sum_{i=1}^C \sum_{j=1}^{N_i} \sum_{l=1}^{N_l} u_{ij}^q (I_{ij} - Mean_i)^T (I_{ij} - Mean_i) \quad (9)$$

$$J_{opt} = \frac{\det(V_2^T FS_b V_2)}{\det(V_2^T FS_w V_2)} \quad (10)$$

最终,基于双向的特征矩阵为:

$$Y = V_1^T I V_2 \quad (11)$$

定理1 F2DPLA不受小样本事件影响。

证明:根据式(9),可以将其表达为

$$FS_w = \phi_{FS_w}^T \phi_{FS_w} \quad (12)$$

式中,

$$\begin{aligned} \phi_{FS_w} &= [\phi_{FS_w}^1, \phi_{FS_w}^2, \dots, \phi_{FS_w}^C] \\ \phi_{FS_w}^i &= [(I_{i1} - Mean_i), (I_{i2} - Mean_i), \dots, (I_{iN_i} - Mean_i)] \end{aligned} \quad (13)$$

因此

$$\dim(\phi_{FS_w}) = m \times (n \sum_{i=1}^C N_i) \quad (14)$$

式中, m 为图像的宽, n 为图像的高。由于

$$\text{rank}(\phi_{FS_w} \phi_{FS_w}^T) = \text{rank}(\phi_{FS_w}^T \phi_{FS_w}) = \text{rank}(\phi_{FS_w}) = m \quad (15)$$

此外 FS_w 的维数是 $m \times m$,因此 FS_w 是满秩的,即F2DPLA算法不受小样本事件影响。

证毕。

3.3 最近邻分类器度量的设计

为了简单方便,本文依旧采用最近邻分类器来进行分类。即如果样本 X 到各个类别均值的Euclidean距离最小,则样本 X 属于距离最小的类别。但是,由于F-范数与2-范数相容,因此本文使用基于矩阵的F-范数度量方式代替传统的基于向量的2-范数度量方式(即Euclidean距离)是合理的。式(16)、式(17)分别代表传统的2-范数和F-范数:

$$d = \|y - ymean_i\|_2 = \sqrt{(y - ymean_i)^T (y - ymean_i)} \quad (16)$$

$$\begin{aligned} d &= \min\{\|Y - YMean_i\|_F\} \\ &= \min\{\sqrt{\text{tr}((Y - YMean_i)^H (Y - YMean_i))}\} \end{aligned} \quad (17)$$

式中, Y 为测试特征矩阵, y 代表测试特征矩阵各列顺次链接的长长的列向量; $YMean_i$ 为各类的特征均值矩阵; $ymean_i$ 为 $YMean_i$ 各列顺次链接的长长的列向量; $\text{tr}(\cdot)$ 代表矩阵的迹。

定理2 基于矩阵的 $\|A\|_F$ 与基于向量的 $\|\cdot\|_2$ 相容。

证明: $\|A\|_F$ 显然具有非负性与齐次性。设 A 的第 j 列为 a_j ($j=1, 2, \dots, n$), $B \in C^{m \times n}$ 的第 j 列为 b_j ($j=1, 2, \dots, n$), 则有:

$$\begin{aligned} \|A+B\|_F^2 &= \|a_1 + b_1\|_2^2 + \dots + \|a_n + b_n\|_2^2 \\ &\leq (\|a_1\|_2 + \|b_1\|_2)^2 + \dots + (\|a_n\|_2 + \|b_n\|_2)^2 \end{aligned}$$

$$\begin{aligned} &= (\|a_1\|_2^2 + \dots + \|a_n\|_2^2) + (\|b_1\|_2^2 + \dots + \|b_n\|_2^2) + 2(\|a_1\|_2 \|b_1\|_2 + \dots + \|a_n\|_2 \|b_n\|_2) \\ &= \|A\|_F^2 + \|B\|_F^2 + 2\|A\|_F \|B\|_F \\ &= (\|A\|_F + \|B\|_F)^2 \end{aligned}$$

再设 $B = (b_{ij})_{n \times l} \in C^{n \times l}$, 则有:

$$AB = (\sum_{k=1}^n a_k b_{kj})_{m \times n} \in C^{m \times l} \quad (18)$$

于是

$$\begin{aligned} \|AB\|_F^2 &= \sum_{i=1}^m \sum_{j=1}^l |\sum_{k=1}^n a_k b_{kj}|^2 \\ &\leq \sum_{i=1}^m \sum_{j=1}^l (\sum_{k=1}^n |a_k| |b_{kj}|)^2 \\ &\leq \sum_{i=1}^m \sum_{j=1}^l (\sum_{k=1}^n |a_k|^2) (\sum_{k=1}^n |b_{kj}|^2) = (\sum_{i=1}^m \sum_{k=1}^n |a_k|^2) (\sum_{j=1}^l \sum_{k=1}^n |b_{kj}|^2) \\ &= \|A\|_F^2 \|B\|_F^2 \end{aligned}$$

即 $\|A\|_F$ 为 A 的矩阵范数。由式(19)可知结论成立。

$$\|Ax\|_2 = \|AB\|_F \leq \|A\|_F \|B\|_F = \|A\|_F \|x\|_2 \quad (19)$$

证毕。

通过观察定理2,可以总结出基于矩阵的 $\|A\|_F$ 相对于基于向量的 $\|A\|_2$ 进行度量具有以下优点。

(1)基于矩阵的 $\|A\|_F$ 相对于基于向量的 $\|A\|_2$ 运算时间减少;

(2) $\|A\|_2$ 是将矩阵转化成长长的向量,因此可能加大了产生维度灾难的可能性;而基于矩阵的 $\|A\|_F$ 则直接针对矩阵操作,避免了转化操作,同时也明显地减少了维度灾难发生的可能。

(3) $\|A\|_2$ 是将矩阵每列依次首尾相接形成的向量,因此破坏了高维空间的原始结构,影响识别效果,而 $\|A\|_F$ 则不会。

3.4 F2DPLA算法的设计流程

基于模糊的2DPLA(即F2DPLA)算法的具体流程如下所述。

Step1(FKNN) 通过FKNN可以求出基于模糊集的隶属度函数 U 。

Step2(原数据矩阵行方向进行Fuzzy 2DPCA降维) 将隶属度函数嵌入到2DPCA算法的类均值矩阵 $Mean_i$ 、总均值矩阵 $TMean$ 以及协方差矩阵 Cor 中,分解协方差矩阵,获得原数据矩阵行方向分解的特征值矩阵 Λ_1 和相应的特征向量矩阵 V_1 。

Step3(原数据矩阵列方向进行Fuzzy 2DLDA降维) 将隶属度函数嵌入到2DLDA算法的类内判别矩阵 FS_w 和类间判别矩阵 FS_b 中,通过Fisher准则函数获得最大方向的投影,从而分解 FS_b/FS_w 商的特征值矩阵 Λ_2 和相应的特征向量矩阵 V_2 。

Step4(特征脸表达) 通过式(11)求出每类每张测试样本的特征脸矩阵表达式。

Step5(识别与统计) 采用简单的最近邻分类器进行分类,但与以往最近邻分类器有所不同,本文采用F-范数进行分类度量,同时在实验数据较少的情况下,为了获得较准确的

识别率,可以采用 Leave-Out- One^[14]方法进行测试。

4 实验

首先介绍实验所采用数据库的数据集以及实验前的预处理工作;其次验证本文提出的 F2DPLA 的降维能力的表现高于其他同类方法;然后验证随着样本集的增加,在不同的环境中, F2DPLA 相对于其他相关方法稳定性更高;再次,验证几种度量方式中相对于 F2DPLA 算法基于矩阵的 F-范数是最优的;接着,验证其在 FERET 数据库中大类别分类是可行的;最后,展示在维数很低的情况下 F2DPLA 略微次于 FPCA 的现象。

4.1 实验设备

本文采用 3 个数据库的部分数据集进行验证,分别是 Yale Database B, FERET 以及 ORL 数据库。其中 Yale Database B 中包含 10 个人的数据集,每个人在不同光照下有 64 张正面图像; FERET 中包含 1564 个图像集,总计 14126 张图像,本文采用 130 个图像集,每个集合包含“fa”和“fb”两幅图像; ORL 数据库包含 40 个数据集,其中每个数据集包含 10 张来自不同角度旋转以及不同表情的图像,且不受光照影响。通过上述可以总结出,本文选择 Yale Database B 是验证 F2DPLA 方法在受光照影响严重情况下的表现;选择 FERET 是因为数据库类别庞大;而选择 ORL 是验证在样本匮乏、类别丰富且人脸的旋转角度不同情况下的表现。图 2 展示了这 3 个数据库部分图像的缩率图。




图 2 上为 Yale Face Database B 在不同光照影响下的缩率图;中为 FERET 部分类别的缩率图;下为 ORL 不同角度旋转的缩率图

4.2 实验预处理

文献[13]指出,相对于全局特征,局部特征更有利于分类。因此,本文对图像的光照补偿选择的是基于局部的补偿光照,而不是选择传统的基于全局的直方图光照补偿。同时为了实验简便以及实验数据准确, Yale Database B, FERET, ORL 数据库中的原始图像通过定位双目然后通过旋转、缩放以及剪裁等方式最终处理为 100×100 像素大小。具体样例如图 3 所示。




图 3 原始数据库图像处理前后的对比

4.3 实验分析

首先验证 F2DPLA 降维能力高于其他同类方法。图 4 展示了在 Yale Database B 数据库上各方法降维能力的表现。其中假设随机提取训练样本数为 5,共 10 类样本。如图 4 所示,其中 x 轴表示维数, y 轴代表识别率。




图 4 各种方法降维能力对比

从图 4 中可以发现 F2DPLA 算法降维能力明显优于 F2DLPA, F2DPCA 和 F2DLDA 算法;当 F2DLDA 维度降至 30×30 达到饱和,在 20×20 出现欠拟合现象; F2DPCA 识别率上升缓慢至 10×10 仍未饱和。综上所述, F2DPLA 降维能力最强。

其次验证当 F2DPCA 容易受到光照的影响时,识别率明显低于其他算法;而 F2DLDA 在样本数很少且样本不受光照影响时其识别率明显低于其他算法,且在这两种环境中本文提出的 F2DPLA 稳定性最好。

此次实验将对 F2DPCA, F2DLDA, 对称 2DPLS+LDA, F2DLPA 以及 F2DPLA 方法进行比较。图 5 展示了在 Yale Database B 数据库中各个方法的表现。其中,类别数是 10,随机从每个数据集中提取 i 张人脸图用做训练,其余 $64-i$ 张用做测试。首先,可以看出 F2DLDA, 对称 2DPLS+LDA, F2DPLA 和 F2DLPA 算法都较好地都将异类数据彼此分开,得到较好的识别率,其中 F2DPLA 算法非常稳定; F2DLPA 则由于光照处理不当,导致算法不稳定,但该算法在图像矩阵行方向提取了较多的分类信息以及嵌入了模糊集,最终识别率会有明显的提高;对称 2DPLS+LDA 的时空耗费是巨大的。其次, F2DPCA 由于受到光照等因素的影响,识别率明显低于其它算法,随着样本数的增加,识别率也在缓慢提高,但波动很大。




图 5 Yale Database B 测试结果

当数据库样本数较少而类别较多,并且样本不受光照影响时,传统 PCA 优于传统 LDA^[1]。图 6 展示了基于二维化的各种降维方法的结果与文献[1]的观点十分相似。由于 ORL 数据库样本数量较少,类别数量适中,且库中图像不受光照影响,从图 6 中可以发现 F2DPCA 的识别率明显优于 F2DLDA,且识别率依次为 F2DPCA 优于 F2DPLA 优于

F2DLPA 优于 F2DLDA (即 F2DPLA 识别率仅次于 F2DPCA)。

综上所述,可以发现本文提出的 F2DPLA 方法虽然没有 F2DPCA, F2DLDA 在实验中的效果好,但是最稳定,即对光照、图像样本的旋转角度、样本数量以及类别数量的影响都远远小于 F2DPCA 和 F2DLDA,而且识别率在两次实验中只是略逊于 F2DPCA 和 F2DLDA 这两种方法。因此可以证明本文提出的 F2DPLA 具有较好的稳定性。




图6 ORL测试结果

其次,文献[9]指出在标准 PCA, ICA 降维空间中, Cosine 度量优于 2-范数以及 1-范数,图 7 展示了图像矩阵降维至 5×5 大小后几种度量方式的分类效果。从图 7 可见,在 F2DPLA 空间中,该命题依然成立,但同时也应注意首先当训练样本数据欠拟合时, Cosine 度量方法波动性较大,因此不宜做基于身份验证的人脸识别应用;其次, F-范数优于 2-范数、1-范数、Cosine 度量以及 ∞ -范数;最后,在 F2DPLA 空间中, 2-范数优于 1-范数,但这与文献[1]的基于向量空间的结论是不同的。综上所述,本文选择用 F-范数进行分类度量。




图7 几种度量方式的对比

再次,验证在大类别 FERET 数据库上也能取得较好的效果。本实验样本类别数为 130, 每个数据集包含 2 个样本。首先计算“fa”和“fb”的均值图像作为第 3 个样本, 随机提取两个样本训练, 剩下一个用来测试。通过图 8 曲线可以发现本文提出的算法的识别率都在 96% 之上, 也就是说本文提出的算法同样也可以应用于大类别数据库。之所以它可以应用到大类别样本匮乏的数据库中, 主要是因为 F2DPLA 方法的类内矩阵是满秩的, 不再受小样本事件的影响。




图8 FERET数据库上的测试结果

最后,在 ORL 数据库上展示传统 FPCA 算法在样本维数较低的情况下略胜于 F2DPLA 算法的现象,该现象与文献[3]提到的现象相似。图 9 给出了将原始图像缩放至 20×20 大小后传统的 FPLA 算法和 F2DPLA 算法的比较。训练样

本数以及测试样本数均随机抽取。从图 9 中可以发现,随着训练样本本数的增加,识别率都有着明显的提高,而 F2DPLA 明显低于 FPCA;同时也应注意到 F2DPLA 随着训练样本本数的增加,识别率上升的斜率明显大于 FPCA。




图9 ORL数据库上 FPCA 与 F2DPLA 的对比

结束语 本文提出了一种新颖的基于模糊 2DPLA 的人脸识别方法(即 F2DPLA)。通过理论证明和实验验证,本文可以归纳出此方法具有如下几方面的优点。

首先,此方法继承了传统 PCA 和 LDA 方法自身的优点,也就是新方法不仅着眼于降维数据对原有高维数据保真度的优化,而且同样关心降维数据对异类数据判别性的优化^[14],并通过实验证实了采用 2DPCA 进行行变换、采用 2DLDA 进行列变换能更好地避免光照对样本的影响。

次之,此方法嵌入了 F2DLDA 提取列分类信息,导致类内矩阵都是满秩的,因此不受小样本事件的影响。

其次,此方法继承了二维化思想的优点,没有破坏图像数据原有的结构,同时从图像矩阵两个方向运用不同的方法进行压缩,从而大量地压缩了矩阵内部的相关性,并且避免了由于向量过长造成无法制造出判别矩阵,即维度灾难。

再次,此方法采用基于矩阵的 F-范数度量方式进行分类,实验验证了该度量方式优越于其他基于矩阵的度量方式。

最后,此方法由于使用 FKNN 方法嵌入了模糊集的隶属度矩阵的概念,使得类与类之间的分布更有规律,识别率更稳定,同时具有较好的鲁棒性和自适应性;又由于 FKNN 方法具有监督学习算法以及非监督学习聚类算法的很多特性,因此可以很容易地将其应用到半监督学习方法的人脸识别中。

虽然本文提出的 F2DPLA 具有以上的优点,但仍有 3 方面需要在未来深入研究:

首先,虽然大多数情况下基于 F2DPLA 的识别率胜于传统 FPLA 算法,但不能解释当样本维数很小时,为什么有时基于向量 FPLA 的方法略优于基于矩阵的 F2DPLA。

其次,采用 FKNN 获得模糊集的隶属度矩阵需要开辟大量的存储空间,而且耗时。

最后,将算法在基于半监督学习的环境下进行人脸识别。

参考文献

- [1] Yang Jian, Zhang D, Yang Jing-yu. Constructing PCA Baseline Algorithms to Reevaluate ICA-based Face Recognition Performance[J]. IEEE Trans. on Systems, Man, and Cybernetics, 2007, 37(4): 1015-1021
- [2] Liu Xiao-zhang, Chen Wen-sheng, Yuen P C, et al. Learning Kernel-based LDA for face recognition under illumination variations[J]. IEEE Trans. on Signal Processing Letters, 2009, 16(12): 1019-1022
- [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 Trans. Pattern Anal. Machine Intell, 2004, 26(6): 131-137

- [4] Kong H, Wang L, Teoh E K, et al. Generalized 2D principal component analysis for face image representation and recognition[J]. *Neural Networks*, 2005, 18(5/6): 585-594
- [5] Kong Hui, Wang Lei, Teoh E K, et al. A Framework of 2 D Fisher Discriminant Analysis: Application to Face[C]// *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition(CVPR 2005)*. Washington D. C, USA, June 2005, 2: 1083-1088
- [6] Zhao W. Discriminant Component Analysis for Face recognition. [C]// *Proceedings of the 15th International Conference on Pattern Recognition*. Barcelona, Spain; Sept. 2000, 2: 818-821
- [7] Vicente M A, Hoyer P O, Hyvarinen A. Equivalence of Some Common Linear Feature Extraction Techniques for Appearance-based Object Recognition Tasks [J]. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2007, 29(5): 896-900
- [8] Song Jia-dong, Li Xiao-juan, Xu Peng-fei, et al. Global face recognition framework based on symmetrical 2DPLS by two sides plus LDA[C]// *Proceedings of the 2nd International Workshop on Education Technology and Computer Science*. Wuhan, China: Mar. 2010, 2: 60-64
- [9] Draper B A, Baek K, Bartlett M S, et al. Recognizing faces with PCA and ICA[J]. *Computer Vision and Image Understanding*, 2003, 99: 115-137
- [10] Yang Wan-kou, Wang Jian-guo, Ren Ming-wu, et al. Fuzzy 2-Dimensional FLD for Face Recognition[J]. *Journal of Information and Computing Science*, 2009, 4(3): 233-239
- [11] 边肇祺, 张学工. 模式识别(第二版)[M]. 北京: 清华大学出版社, 2000: 1-338
- [12] Kw K C, Pedry W. Face recognition using a fuzzyfisher classifier [J]. *Pattern Recognition*, 2005, 38(10): 1717-1732
- [13] He X, Cai D, Liu H, et al. Locality preserving indexing for document representation[C]// *Proceedings of the 27th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval(SIGIR'04)*. Sheffield, UK, July 2004: 96-103
- [14] Ray Kumar S, Ghoshal J. Approximate Reasoning Approach to Pattern Recognition[J]. *Fuzzy Sets and Systems*, 1996, 77(2): 125-150
- [15] 张道强, 陈松灿. 高维数据降维方法[J]. *中国计算机学会通讯*, 2009, 5(8): 15-22

(上接第 262 页)

行了测试。结果表明, ACG-MOPSO 算法在处理这类优化问题时, 在非劣解的多样性以及收敛性方面取得了满意的效果。下一步的研究方向是把该算法应用于解决多目标离散优化问题以及解决实际问题。

参 考 文 献

- [1] Kennedy, Eberhart R C. Particle swarm optimization [C]// *IEEE International Conference on Neural Networks*. Piscataway. 1995: 1942-1948
- [2] Coello C A C, Lechuag M S. MOPSO: A proposal for multiple objective particle swarm optimization[C]// *IEEE Congress on Evolutionary Computation*. Piscataway. New Jersey, 2002: 1051-1056
- [3] Mostaghim S, Teich J. Strategies for finding good local guides in multi-objective particle swarm optimization (MOPSO) [C] // *IEEE Swarm Intelligence Symposium*. Indianapolis, 2003: 26-33
- [4] Sierra M R. Improving PSO-based multi-objective optimization using crowding, mutation and ϵ -dominance[C]// *Third International Conference on Evolutionary Multi-Criterion Optimization*. Guanajuato, Mexico, 2005: 505-519
- [5] Li X. A non-dominated sorting particle swarm optimizer for multi-objective optimization [C] // *Genetic and Evolutionary Computation Conference*. 2003: 37-48
- [6] Coello C A C, Pulido G T, Lechuga M S. Handling multiple objectives with particle swarm optimization [J]. *IEEE Transactions on Evolutionary Computation*, 2004, 8: 256-279
- [7] Sierra M R, Coello C A C. Multi-Objective Particle Swarm Optimizers: A Survey of the State-of-the-Art [J]. *International Journal of Computational Intelligence Research*, 2006, 2(3): 287-308
- [8] Zitzler E. Evolutionary algorithms for multiobjective optimization: Methods and applications [D]. Zurich, Switzerland: Swiss Federal Inst. Technol, 1999
- [9] 杨俊杰, 周建中, 方仍存. 基于自适应网格的多目标粒子群优化算法[J]. *系统仿真学报*, 2008, 21(20): 5843-5847

(上接第 277 页)

- [5] Qi Heng, Li Ke-qiu, Shen Yan-ming, et al. An effective solution for trademark image retrieval by combining shape description and feature matching [J]. *Pattern Recognition*, 2010, 43(6): 2017-2027
- [6] Kennedy G J, Orbach H S, Loffler G. Global shape versus local feature: An angle illusion [J]. *Vision Research*, 2008, 48(11): 1281-1289
- [7] Gheorghiu E, Kingdom F A A. The spatial feature underlying the shape-frequency and shape-amplitude after-effects [J]. *Vision Research*, 2007, 47(6): 834-844
- [8] Prescott J W, Zhang Dong-qing, Wang J Z, et al. Temporal analysis of tumor heterogeneity and volume for cervical cancer treatment outcome prediction: preliminary evaluation[J]. *J Digit Imaging*, 2010, 23(3): 342-57
- [9] Kezele I, Descoteaux M, Poupon C, et al. Spherical wavelet transform for ODF sharpening[J]. *Med Image Anal*, 2010, 14(3): 332-342
- [10] Yang X Y, Shi Y, Chen L H, et al. The Lifting Scheme for Wavelet Bi-Frames: Theory, Structure, and Algorithm[J]. *IEEE Trans on image processing*, 2010, 19(3): 612-624
- [11] Unser M, van de Ville D. Wavelet Steerability and the Higher-Order Riesz Transform[J]. *IEEE Trans on image processing*, 2010, 19(3): 636-652
- [12] Feng G C, Yuen P C. Multi cues eye detection on gray intensity images[J]. *Pattern Recognition*, 2001, 34(5): 1033-1046
- [13] 刘向东, 陈兆乾. 人脸识别技术的研究[J]. *计算机研究与发展*, 2004, 41(7): 1075-1080
- [14] Bruneli R, Poggio T. Face recognition: Features versus templates [J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1993, 15(10): 1042-1052
- [15] Hafed Z M, Levine M D. Face recognition using the discrete cosine transform[J]. *International Journal of Computer Vision*, 2001, 43(3): 167-188
- [16] Zhang Yan-kun, Liu Chong-qing. A Novel Face Recognition Method Based on Linear Discriminant Analysis[J]. *Journal Infrared Millimeter and Waves*, 2003, 22(5): 327-330