

用于人脸识别的两类主成分分析融合

杨军^{1,2},张秀琼²,高志升²,袁红照²

YANG Jun^{1,2},ZHANG Xiu-qiong²,GAO Zhi-sheng²,YUAN Hong-zhao²

1.四川师范大学 计算机科学学院,成都 610066

2.四川大学 图形图像研究所,成都 610064

1.College of Computer Science,Sichuan Normal University,Chengdu 610066,China

2.Institute of Image & Graphic,Sichuan University,Chengdu 610064,China

E-mail:yangjun204@yahoo.com.cn

YANG Jun,ZHANG Xiu-qiong,GAO Zhi-sheng,et al.Fusion of two different PCAs for face recognition.Computer Engineering and Applications,2010,46(1):194–195.

Abstract: The principle of two different PCAs,PCA based on global scatter matrix and PCA based on global between-class scatter matrix is analyzed firstly.Two different fusion methods,feature level fusion and decision level fusion are proposed using the feature got from two different PCAs.The experiment result is displayed and data fusion method is proved to be efficient for getting better recognition rate.

Key words: face recognition;Principal Component Analysis(PCA);global scatter matrix;between-class scatter matrix;data fusion

摘要:分析了基于总体离散度矩阵和总类间离散度矩阵的主成分分析的原理。利用两种方法分别提取人脸特征并进行识别。对两种方法获得的结果进行了特征层融合和决策层融合,基于ORL人脸数据库的实验表明该方法的识别性能优于单一的主成分分析方法。

关键词:人脸识别;主成分分析;总体离散度矩阵;类间离散度矩阵;数据融合

DOI:10.3778/j.issn.1002-8331.2010.01.057 文章编号:1002-8331(2010)01-0194-02 文献标识码:A 中图分类号:TP391

1 引言

人脸识别在安全、监控、人机智能接口等方面的应用前景,是统计模式识别领域中的一个研究热点。针对人脸识别,人们已经提出了许多算法^[1],其中子空间分析方法是众多方法中的一个重要分支。子空间分析方法就是利用某个准则寻找一组基向量,将人脸图像向这组基向量张成的子空间投影提取特征,同时降低特征的维数^[2]。主成分分析(PCA)可以用来寻找在均方重构误差最小意思下的一组标准正交基向量,特征脸(Eigenfaces)^[3]方法成功地将PCA运用到人脸识别中并取得了不错的效果,自从特征脸被提出以来得到了人们的广泛研究并提出了一些基于特征脸的改进方法^[4~5]。然而,利用传统的PCA方法并不一定获得分类意思上的最佳特征,因为它是以最小均方重构误差为准则的。信息融合技术是协同利用多源信息,以获得对同一事物或目标的更客观,更本质认识的信息综合处理技术^[6],文献[7]利用基于总体离散度矩阵的PCA和基于总类内离散度矩阵的PCA相结合的人脸识别方法并取得了一定的效果。在分析传统的PCA和基于总类间离散度矩阵的PCA的物理含义的基础上,对两种方法的结果进行基于特征层和决策层的融合,在ORL人脸数据库的实验结果显示了该算

法的有效性。

2 基于总体离散度矩阵的PCA

给定总数为M的样本集 $X=\{x_1, x_2, \dots, x_M\}$, x_i 为一个训练样本,假设其有n维特征,通常用一个n维列向量表示。利用一个 $n \times p$ 维($p < n$)的变换矩阵U对其进行线性变换,即 $y=U^T x$,得到该样本集在低维子空间的表示 $Y=\{y_1, y_2, \dots, y_M\}$, y_i 为p维列向量,是第*i*个样本在子空间的表示。

样本集在子空间的总体离散度矩阵定义为式(1),其中 \bar{y} 表示样本集在子空间的均值, $\bar{y}=\sum_{i=1}^M y_i$

$$S_{yt}=\frac{1}{M} \sum_{i=1}^M (y_i - \bar{y})(y_i - \bar{y})^T \quad (1)$$

定义函数 $J(U)=\text{trace}(S_{yt})$,trace表示求矩阵的迹,即为 S_{yt} 对角线元素之和。基于总体离散度矩阵的PCA以最大化J为目标准则来求取变换矩阵,最大化J意味着样本在子空间中的总体散度最大,即各样本分离程度最大。将 $y=U^T x$ 代入式(1),即

$$J(U)=\text{trace}\left(U^T \left[\frac{1}{M} \sum_{i=1}^M (x_i - \bar{x})(x_i - \bar{x})^T\right] U\right) \quad (2)$$

基金项目:国家自然科学基金(the National Natural Science Foundation of China under Grant No.60736046);四川师范大学校级科研基金(No.06lk021)。

作者简介:杨军(1977-),男,博士研究生,讲师,主研领域为图像处理,模式识别;张秀琼(1972-),女,博士研究生,主研领域为图像处理,图像融合;

高志升(1976-),男,博士研究生,主研领域为图像处理,人脸识别;袁红照(1970-),男,博士研究生,主研领域为图像处理,增强现实。

收稿日期:2008-07-21 修回日期:2008-08-25

定义样本离散度矩阵 S_x 为:

$$S_{x^T} = \frac{1}{M} \sum_{i=1}^M (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \quad (3)$$

将式(3)代入式(2),则将 J 表示为:

$$J(\mathbf{U}) = \text{trace}(\mathbf{U}^T S_x \mathbf{U}) \quad (4)$$

变换矩阵 \mathbf{U} 中的列向量 \mathbf{u}_i 组成一组标准正交基,满足约束:

$\mathbf{u}_i^T \mathbf{u}_i = 1$, 当 $i \neq j$ 时, $\mathbf{u}_i^T \mathbf{u}_j = 0$, 利用拉格朗日乘子法,求解式(4)的最大值问题可以转换成解式(5)的特征向量问题,选取式(5)求得的最大的 p 个特征值所对应的特征向量组成变换矩阵 \mathbf{U} 。

$$S_x \mathbf{u}_i = \lambda_i \mathbf{u}_i \quad (5)$$

式(5)即为特征脸方法^[3]用来求取变换矩阵的公式,这里将用来求取特征向量的矩阵称为产生矩阵。通过以上分析,可以得出结论:传统的特征脸方法实际上是以样本总体离散度矩阵作为产生矩阵,以变换后的样本总体离散度最大为目标的一种线性变换方法,这里将该矩阵,即式(3)记为 \mathbf{G}_t ,记该方法为 PCAGt。实际在使用特征脸方法时通常将图像数据表示成列向量并对样本进行去均值处理,即使得样本均值为零,则变换后的总体离散度和相关矩阵相同并且都为对角阵,在最大化总体离散度的同时去除了特征的相关性,并具有最小化均方重建误差的意思。

3 基于总类间离散度矩阵的 PCA

基于总体离散度矩阵的 PCA 实际上是一种无监督的学习方法,最大化样本在子空间中的散度并不具有最优分类的意义,因为同类的样本的散度也同样被最大化了。如果已知训练样本的类别,则可以采用更为有效的有监督学习方法,基于总类间离散度矩阵的 PCA 就是其中之一。假定已知训练样本共有 C 类,每类样本的数量为 M_1, M_2, \dots, M_c , 定义样本在子空间的总类间离散度矩阵为:

$$S_{yb} = \frac{1}{C} \sum_{j=1}^C (\bar{\mathbf{y}}^j - \bar{\mathbf{y}})(\bar{\mathbf{y}}^j - \bar{\mathbf{y}})^T \quad (6)$$

其中 $\bar{\mathbf{y}}^j$ 为第 j 类样本在子空间的均值, $\bar{\mathbf{y}}^j = \sum_{i=1}^{M_j} \mathbf{y}_i$, 满足 $\mathbf{y}_i \in \text{class}(j)$ 。将 $\mathbf{y} = \mathbf{U}^T \mathbf{x}$ 代入式(6)得: $S_{yb} = \mathbf{U}^T \left[\frac{1}{C} \sum_{j=1}^C (\bar{\mathbf{x}}^j - \bar{\mathbf{x}})(\bar{\mathbf{x}}^j - \bar{\mathbf{x}})^T \right] \mathbf{U}$,

其中 $\bar{\mathbf{x}}^j$ 为第 j 类样本的均值。定义样本总类间离散度矩阵为:

$$S_{xb} = \frac{1}{C} \sum_{j=1}^C (\bar{\mathbf{x}}^j - \bar{\mathbf{x}})(\bar{\mathbf{x}}^j - \bar{\mathbf{x}})^T \quad (7)$$

则 S_{yb} 表示为:

$$S_{yb} = \mathbf{U}^T S_{xb} \mathbf{U} \quad (8)$$

最大化总类间离散度矩阵具有使各个类别之间总体散度最大,易于分类的意义。基于总类间离散度矩阵的 PCA 以最大化 S_{yb} 的迹为准则,同第 2 章的分析一样,该准则最终转换为对式(9)求解特征值的问题。

$$S_{xb} \mathbf{u}_i = \lambda_i \mathbf{u}_i \quad (9)$$

通过以上分析,可以看到:基于总类间离散度矩阵的 PCA 实际上是以样本总类间离散度矩阵作为产生矩阵,以变换后的样本总类间离散度最大为目标的一种线性变换方法,这里将其产生矩阵 S_{xb} 记为 \mathbf{G}_b ,记该方法为 PCAGb。

4 特征提取及融合识别

通过训练样本计算 \mathbf{G}_t 和 \mathbf{G}_b ,利用以上两类 PCA 方法向子

空间投影得到两组特征,记利用 PCAGt 得到的特征为 y_1 ,其维数为 p_1 ,利用 PCAGb 得到的特征为 y_2 ,其维数为 p_2 ,该文设计了两种融合策略对抽取的特征进行融合。

第一种融合方法将 y_1 和 y_2 连接起来形成一个特征向量 \mathbf{y} ,其维度为 $p=p_1+p_2$,称之为基于特征层的融合,记为 FFusion。两种方法提取的特征幅度相差可能很大,所以采用这种融合方法时首先对两类特征作标准化处理,即对 $y_1, y_1 = y_1 / \|y_1\|$,使其成为单位向量,对 y_2 也做相同的处理。分类采用基于欧式距离的最近邻分类器(NN),设测试样本 x^* 经过两类变换及特征融合得到特征向量 \mathbf{y}^* ,计算测试样本与每个训练样本的欧式距离:

$$D(\mathbf{y}^*, \mathbf{y}_k) = \sum_{i=1}^p \| \mathbf{y}_i^* - \mathbf{y}_{ki} \|_2, k=1, 2, \dots, N \quad (10)$$

选择与测试样本距离最小的训练样本所属的类作为识别结果。即:

$$\mathbf{y}^* \in \text{class}(p) \text{ if}$$

$$D(\mathbf{y}^*, \mathbf{y}_p) = \arg \min_k D(\mathbf{y}^*, \mathbf{y}_k) \text{ and } \mathbf{y}_p \in \text{class}(p) \quad (11)$$

另一种融合方法首先直接利用两类特征进行识别得到两组识别结果,再将两组识别结果进行模糊化之后进行融合。设特征 y_1 与训练样本的距离为 $D_1 = \{d_{11}, d_{12}, \dots, d_{1N}\}$, y_2 与训练样本的距离为 $D_2 = \{d_{21}, d_{22}, \dots, d_{2N}\}$,利用模糊化的思想^[8]对距离模糊化。令 $D_{\max} = \max(D_1), D_{\min} = \min(D_1)$,通过计算 $D_1' = (D_1 - D_{\min}) / (D_{\max} - D_{\min})$ 将距离归一化,同理对 D_2 进行归一化得到 D_2' ,最终的距离表示为 $D = D_1' + D_2' = \{d_1, d_2, \dots, d_N\}$ 。选择 D 中的最小值, $d_p = \min(D)$,若 $d_p \in \text{class}(p)$,则将测试样本归入第 p 类,将该方法称为基于决策层的融合,记为 DFusion。

5 实验结果

在 ORL 数据库上进行了人脸识别实验,该数据库含有 40 个人,每人 10 幅不同的图像,包含有微笑,闭眼等各种表情的变化和多达 20 度的平面外姿态变换以及部分遮挡所有图像被规范化为 112×92 大小的灰度图像,图 1 显示了 ORL 数据库中某人的部分样本图像,实验中采用每人的前 3~6 张人脸图像作为训练样本,剩余的图像作为测试图像。



图 1 ORL 人脸库中某人的部分图像

表 1 给出了各种方法的识别结果,其中括号内的数字表示选取特征的维数,FFusion 和 DFusion 的识别结果为 PCAGt 和 PCAGb 各选取 35 维融合的结果。

表 1 不同方法的识别率 (%)

训练样本数	PCAGt(35)	PCAGb(35)	PCAGt(70)	DFusion	FFusion(70)
3	82.86	83.57	84.29	83.93	85.71
4	85.83	87.92	87.92	87.50	88.75
5	88.50	89.50	88.50	89.50	91.50
6	95.63	95.63	95.63	96.25	95.63

从表 1 中数据可以看到在维数相同的条件下,PCAGb 的识别结果要略好于 PCAGt,经 FFusion 和 DFusion 融合后的识

(下转 199 页)