

局部和全局加权的二维统计不相关鉴别分析

黄明晓,荆晓远,李 力,姚永芳

(南京邮电大学 自动化学院,江苏 南京 210003)

摘 要:传统的统计不相关鉴别分析方法使用样本的均值来估计期望,计算出总体散度矩阵。这些方法在数据不满足高斯分布的情况下会出现大的偏差,影响最优鉴别特征的提取。为了解决该问题,文中结合二维鉴别分析的思想,分别提出了基于局部的二维统计不相关鉴别变换(L2DUDT)方法和基于全局加权的二维统计不相关鉴别变换(WG2DUDT)方法。L2DUDT 通过用样本的近邻中心来定义每个样本的期望,而 WG2DUDT 用样本间的欧几里得距离加权来定义期望。基于 AR 和 FERET 人脸数据库的实验表明,文中提出的方法与一些相关方法相比,有效地提高了识别性能。

关键词:统计不相关鉴别分析;鉴别特征;二维鉴别分析;二维统计不相关鉴别变换

中图分类号:TP301

文献标识码:A

文章编号:1673-629X(2014)06-0114-04

doi:10.3969/j.issn.1673-629X.2014.06.029

Local and Global Weighted Uncorrelated Two-dimensional Discriminant Analysis

HUANG Ming-xiao, JING Xiao-yuan, LI Li, YAO Yong-fang

(College of Automation, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: The traditional uncorrelated discriminant analysis methods employ the mean of sample-set to estimate the expectation for all samples, thus computing the total scatter matrix. However, when the data are not Gaussian distributions, these methods may not extract optimal discriminant features. In order to address this problem, propose two approaches named Local Two-Dimensional Uncorrelated Discriminant Transform (L2DUDT) and Weighted Global Two-Dimensional Uncorrelated Discriminant Transform (WG2DUDT) on the basis of two-dimensional discriminant analysis respectively. L2DUDT redefines the expectation for each sample using the sample's neighbor center, while WG2DUDT uses Euclidean distance between samples as weighted value to construct the expectation. The experimental results on AR and FERET databases demonstrate that the proposed approaches can effectively improve the recognition performance, as compared with some related methods.

Key words: uncorrelated discriminant analysis; discriminant features; two-dimensional discriminant analysis; two-dimensional uncorrelated discriminant transform

0 引 言

特征提取^[1]是图像处理和模式识别的重要研究课题之一。在众多的特征提取方法中,子空间学习方法由于其计算简单、有效性高等优点受到了广泛的关注。主成分分析(PCA)^[2]和线性鉴别分析(LDA)^[3]是两种经典的子空间学习方法。PCA 没有考虑到样本的类别信息,得到的投影向量是正交的。LDA 利用了样本的类别信息,但是得到的投影向量一般不正交,存在冗余信息。Foley-Sammon 鉴别分析(FSODV)方法^[4]

是一种改进的 LDA 方法,它通过添加正交约束,使得投影向量彼此正交,去除特征之间的冗余信息,取得了比 LDA 更好的识别效果。FSODV 虽然使得鉴别向量正交,但由此得到的最佳鉴别特征却是统计相关的,尚存在一定的冗余信息。统计不相关的最佳判别矢量集(UDOV)方法^[5]通过加入统计不相关约束来提取统计不相关的特征,比 FSODV 得到的特征具有更强的鉴别能量^[6]。Jing 等推广了 UODV 的理论,提出了一种改进的 UODV 方法^[7]。

收稿日期:2013-08-24

修回日期:2013-11-26

网络出版时间:2014-02-24

基金项目:国家自然科学基金资助项目(61073113);教育部博士点博导类基金(20093223110001);教育部新世纪人才项目(NCET-09-0162);江苏省普通高校研究生科研创新计划(CXLX13_465)

作者简介:黄明晓(1988-),女,研究生,研究方向为模式识别;荆晓远,教授,博士生导师,研究方向为模式识别、图像与信号处理、信息安全、机器学习与数据挖掘。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20140224.0916.040.html>

但是 UODV 等统计不相关鉴别分析方法存在如下缺陷:

(1) 它们都使用样本的均值来估计期望,从而计算出样本的总体散度矩阵。这样的估计方法在样本不满足高斯分布的情况下会出现大的偏差,有可能会对识别结果造成负面影响。

(2) 这些方法一般先对图像进行向量化,然后再进行特征提取。这种做法有可能会破坏图像原有的结构信息,并且还会遇到一个很大的挑战,即图像向量化后都是高维的向量^[8],这给计算总体散度矩阵带来了很大的难度。

为了解决以上问题,文中从样本的近邻中心和全局中心两个角度考虑,对期望重新估计,构建新的总体散度矩阵意义下的统计不相关约束,提出了局部和全局加权的统计不相关鉴别分析思想。为了不破坏二维图像像素的结构信息,提取更有效的鉴别特征,文中分别提出了基于局部的二维统计不相关鉴别变换(L2DUDT)方法和基于全局加权的二维统计不相关鉴别变换(WG2DUDT)方法。基于 AR^[9]和 FERET^[10]人脸数据库上的实验结果表明了文中所提方法的有效性。

1 基于局部的二维统计不相关鉴别变换(L2DUDT)

设样本集 X 中包含 N 个训练样本,分为 c 个类别, X_{ij} 表示样本集 X 中第 i 类的第 j 个样本的一个 $m \times n$ 的矩阵样本,第 i 类的样本个数是 n_i 。

L2DUDT 通过下面的准则构建类间散度矩阵 S_{tb} , 类内散度矩阵 S_{tw} 和总体散度矩阵 S_{tL} 。

$$S_{tb} = \frac{1}{N} \sum_{i=1}^N (m_i - m)(m_i - m)^T \quad (1)$$

$$S_{tw} = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^{n_i} (X_{ij} - m_i)(X_{ij} - m_i)^T \quad (2)$$

$$S_{tL} = \frac{1}{N} \sum_{i=1}^N (X_{ij} - \tilde{m}_i)(X_{ij} - \tilde{m}_i)^T \quad (3)$$

$$\text{其中, } m_i = \frac{1}{N} \sum_{j=1}^N X_j, \tilde{m}_i = \frac{1}{N} \sum_{j=1}^N \alpha_{ij} X_j, \alpha = [\alpha_{ij}]_{N \times N}$$

是一个近邻关系矩阵:

$$\alpha_{ij} = \begin{cases} 1 & \text{如果样本 } X_i \text{ 在样本 } X_j \text{ 的 } k \text{ 近邻邻域内,} \\ & \text{或者样本 } X_j \text{ 在样本 } X_i \text{ 的 } k \text{ 近邻邻域内} \\ 0 & \text{其他情况} \end{cases} \quad (4)$$

L2DUDT 的目标方程为:

$$W = \arg \max_W \frac{W^T S_{tb} W}{W^T S_{tw} W} \quad (5)$$

$$\text{s. t. } \varphi_i^T S_{tL} \varphi_j = 0, \quad j = 1, 2, \dots, i-1$$

定理 1: L2DUDT 的第 i 个特征向量 φ_i 是下面特征方程的最大特征值对应的特征向量。

$$PS_{tb} \varphi_i = \lambda S_{tw} \varphi_i \quad (6)$$

其中:

$$P = I - S_{tL} D^T (DS_{tL} S_{tw}^{-1} S_{tL} D^T)^{-1} DS_{tL} S_{tw}^{-1} \quad (7)$$

$$D = [\varphi_1, \varphi_2, \dots, \varphi_j]^T \quad (8)$$

$$I = \text{diag}(1, 1, \dots, 1) \quad (9)$$

证明:

$$\max_{\varphi} J(\varphi) = \frac{|\varphi^T S_{tb} \varphi|}{|\varphi^T S_{tw} \varphi|} \quad (10)$$

$$\text{s. t. } \varphi_i^T S_{tL} \varphi_j = 0, \quad j = 1, 2, \dots, i-1$$

根据公式(10)构造一个拉格朗日函数:

$$L(\varphi_i) = \varphi_i^T S_{tb} \varphi_i - \lambda (\varphi_i^T S_{tw} \varphi_i - c) - \sum_{k=1}^{i-1} \mu_k \varphi_i^T S_{tL} \varphi_k \quad (11)$$

其中 λ 和 μ_k 是拉格朗日乘子, c 是常数。令公式(11)中的 $L(\varphi_i)$ 对 φ_i 的偏导数为 0, 即:

$$\frac{\partial (L(\varphi_i))}{\partial (\varphi_i)} = 2S_{tb} \varphi_i - 2\lambda S_{tw} \varphi_i - \sum_{k=1}^{i-1} \mu_k S_{tL} \varphi_k = 0 \quad (12)$$

公式(12)乘以 $\varphi_k S_{tL} S_{tw}^{-1} (k = 1, 2, \dots, i-1)$, 可以得到:

$$2\varphi_k S_{tL} S_{tw}^{-1} S_{tb} \varphi_i - \sum_{k=1}^{i-1} \mu_k \varphi_k S_{tL} S_{tw}^{-1} S_{tL} \varphi_k = 0 \quad (13)$$

令 $U = [\mu_1, \mu_2, \dots, \mu_k]^T, D = [\varphi_1, \varphi_2, \dots, \varphi_k]^T$, 公式(13)可表示为:

$$DS_{tL} S_{tw}^{-1} S_{tL} D U = 2DS_{tL} S_{tw}^{-1} S_{tb} \varphi_i \quad (14)$$

因此得到:

$$U = 2(DS_{tL} S_{tw}^{-1} S_{tL} D)^{-1} DS_{tL} S_{tw}^{-1} S_{tb} \varphi_i \quad (15)$$

然后公式(12)可以写成

$$2S_{tb} \varphi_i - 2\lambda S_{tw} \varphi_i - S_{tL} D^T U = 0 \quad (16)$$

把公式(15)代到(16)中,最终得到:

$$S_{tb} \varphi_i - \lambda S_{tw} \varphi_i - S_{tL} D^T (DS_{tL} S_{tw}^{-1} S_{tL} D)^{-1} DS_{tL} S_{tw}^{-1} S_{tb} \varphi_i = 0 \quad (17)$$

也就是:

$$(I - S_{tL} D^T (DS_{tL} S_{tw}^{-1} S_{tL} D)^{-1} DS_{tL} S_{tw}^{-1}) S_{tb} \varphi_i = \lambda S_{tw} \varphi_i \quad (18)$$

其中, I 是一个单位矩阵。公式(18)等价于公式(6)。

证明结束。

关于 L2DUDT 算法的实现描述如下:

1) 根据 Fisher 准则求出最大特征值对应的特征向量 φ_1 。

2) 根据公式(6)来迭代求解其余的特征向量。

3) 用 $W = [\varphi_1, \varphi_2, \dots, \varphi_j]$ 作为投影向量, 将数据集训练样本和测试样本投影到 W 所在的投影空间, 然

后用最近邻分类器来分类。

L2DUDT 算法分析:

(1) L2DUDT 用近邻样本均值来替代所有样本的均值,在样本不满足正态分布的情况下,可以更好地刻画样本的局部信息。

(2) L2DUDT 不用对二维矩阵先作向量化,直接计算散度矩阵,简化了计算,还能克服小样本问题,能够更好地提取鉴别特征。

2 基于全局加权的二维统计不相关鉴别变换(WG2DUDT)

WG2DUDT 通过下面的准则构建散度矩阵 S_{tG} 。

$$S_{tG} = \frac{1}{N} \sum_{i=1}^N (X_i - \tilde{m}_i) (X_i - \tilde{m}_i)^T \quad (19)$$

其中, $\tilde{m}_i = \frac{1}{N} \sum_{j=1}^N \alpha_{ij} X_j$, $\alpha = [\alpha_{ij}]_{N \times N}$ 是一个近邻关系矩阵:

$$\alpha_{ij} = \exp\left(-\frac{\|x_j - x_i\|^2}{2\sigma^2}\right) \quad (20)$$

其中,参数 σ 等于总体样本方差。

WG2DUDT 的目标方程为:

$$W = \arg \max_W \frac{W^T S_{tb} W}{W^T S_{tw} W} \quad (21)$$

$$\text{s. t. } \varphi_i^T S_{tG} \varphi_j = 0, \quad j = 1, 2, \dots, i-1$$

定理 2: WG2DUDT 的第 i 个特征向量 φ_i 是下面特征方程的最大特征值对应的特征向量。

$$P S_{tb} \varphi_i = \lambda S_{tw} \varphi_i \quad (22)$$

其中:

$$P = I - S_{tG} D^T (D S_{tG} S_{tw}^{-1} S_{tG} D^T)^{-1} D S_{tG} S_{tw}^{-1} \quad (23)$$

$$D = [\varphi_1, \varphi_2, \dots, \varphi_j]^T \quad (24)$$

$$I = \text{diag}(1, 1, \dots, 1) \quad (25)$$

定理 2 的证明和定理 1 类似,此处不再赘述。

关于 WG2DUDT 算法的实现描述如下:

1) 根据 Fisher 准则求出最大特征值对应的特征向量 φ_1 。

2) 根据公式(22)来迭代求解其余的特征向量。

3) 用 $W = [\varphi_1, \varphi_2, \dots, \varphi_j]$ 作为投影向量,将数据集训练样本和测试样本投影到 W 所在的投影空间,然后用最近邻分类器来分类。

WG2DUDT 算法分析:

(1) WG2DUDT 用每个二维图像与其他二维图像的距离计算出权值,兼顾样本的局部和全局信息,能更准确地表示反映样本的分布情况。

(2) 与 L2DUDT 类似, WG2DUDT 利用二维鉴别的思想,简化了计算,同时克服了小样本问题,能够更好地提取鉴别信息。

3 实验

本节介绍基于局部的二维统计不相关鉴别变换(L2DUDT)方法和基于全局加权的二维统计不相关鉴别变换(WG2DUDT)方法在 AR 和 FERET 人脸数据库的实验结果,并与 Foley-Sammon 鉴别分析(FSODV)、统计不相关的最佳判别矢量集(UODV)、2DPCA^[11]和 2DLDA^[12]相关方法进行对比分析。

3.1 数据库介绍

AR 人脸数据库包含 70 名男性和 56 名女性,一共 126 个人近 4 000 张的人脸图像,每个人都有 26 张图片,每个人的图片都是分为两个时期拍摄的,每部分都包含 13 张图片。所有的人脸图像都是用同一个摄像机拍摄的,通过改变光照和视角来改变拍摄时候的环境。数据库中每个原始人脸图像的分辨率大小为 768×576。采集到的原始人脸图像分辨率一般比较高,直接使用高分辨率的图像会耗费计算机的大量资源,所以实验中对原始人脸图像数据集进行处理,最后得到一个包含 119 个人,每人 26 张 60×48 分辨率的人脸数据库,来更有效地进行特征提取方法的实验。

FERET 人脸数据库包含 200 个人,每个人有 11 幅人脸图像样本,共计 2 200 幅人脸灰度图像。每幅原始人脸灰度图像的分辨率大小为 384×256,这些人脸图像是在改变的光照条件和拍摄较低下采集的,由于原始图像的分辨率比较高,实验中对每幅人脸图像都做了剪裁处理得到大小为 60×48 的人脸图像。

图 1 和图 2 分别显示了 AR、FERET 数据库中一个人的图像。



图 1 AR 数据库中一个人的图像



图 2 FERET 数据库中一个人的图像

3.2 实验结果及分析

在 AR 数据库上,随机选取每类中的 6 幅图像用做训练样本,剩下的 20 张人脸图像作为测试样本。在 FERET 数据库上,随机选取每类中的 4 幅图像用做训练样本,剩下的 7 张人脸图像作为测试样本。L2DUDT 算法在 AR、FERET 人脸数据库中的近邻数 k 分别设为 30、20。

图3和图4分别给出了所有方法在AR和FERET两个数据库上随机20次的识别率波动图。表1给出了相应的平均识别率。从表1可以看出,基于局部的二维统计不相关鉴别变换(L2DUDT)方法和基于全局加权的二维统计不相关鉴别变换(WG2DUDT)方法具有更好的识别效果。在AR数据库上,L2DUDT的平均识别率至少提高了4.23%(=88.97%-84.74%),WG2DUDT的平均识别率至少提高了4.58%(=89.32%-84.74%)。在FERET数据库上,L2DUDT的平均识别率至少提高了5.44%(=81.63%-76.19%),WG2DUDT的平均识别率至少提高了5.62%(=81.81%-76.19%)。

表1 所有方法的平均识别率

方法名称	平均识别率/%	
	AR库	FERET库
FSODV	84.74	76.19
UODV	86.19	77.84
2DPCA	86.80	77.10
2DLDA	87.95	78.29
L2DUDT	88.97	81.63
WG2DUDT	89.32	81.81




图3 所有方法在AR数据库随机20次的识别率




图4 所有方法在FERET数据库随机20次的识别率

4 结束语

为了更好地刻画样本的分布情况,去除鉴别特征的冗余,文中重新设计总体散布矩阵,分别从样本的近邻中心和全局中心两个角度考虑,对期望重新估计,构建新的总体散度矩阵意义下的统计不相关约束,提出了基于局部的二维统计不相关鉴别变换(L2DUDT)方法和基于全局加权的二维统计不相关鉴别变换(WG2DUDT)方法。基于AR和FERET人脸数据库上的实验表明,文中提出的方法与FSODV、UODV、2DPCA和2DLDA相关方法相比,有效地提高了识别性能。

参考文献:

[1] 尹飞,冯大政. 基于PCA算法的人脸识别[J]. 计算机技术与发展,2008,18(10):31-33.

[2] Turk M, Pentland A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1):71-86.

[3] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. fisherfaces: recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7):711-720.

[4] Foley D H, Sammon J W. An optimal set for discriminant vectors[J]. IEEE Transactions on Computers, 1975, C-24(3):281-289.

[5] Jin Zhong, Yang Jingyu, Tang Zhenmin, et al. A theorem on the uncorrelated optimal discriminant vectors[J]. Pattern Recognition, 2001, 34(10):2041-2047.

[6] Yang Jian, Yang Jingyu, Zhang D. What's wrong with Fisher criterion[J]. Pattern Recognition, 2002, 35(11):2665-2668.

[7] Jing Xiaoyuan, Zhang D, Jin Zhong. UODV: improved algorithm and generalized theory[J]. Pattern Recognition, 2003, 36(11):2593-2602.

[8] 韩璐. 一种基于2DLPP和2DLDA的人脸识别方法研究[J]. 计算机技术与发展, 2012, 22(9):87-90.

[9] Martinez A M, Benavente R. The AR face database[R]. [s. l.]:CVC, 1998.

[10] Phillips P J, Moon H, Rizvi S A, et al. The FERET evaluation methodology for face-recognition algorithms[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(10):1090-1104.

[11] Yang Jian, 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.

[12] Li Ming, Yuan Baozong. 2D-LDA: a statistical linear discriminant analysis for image matrix[J]. Pattern Recognition Letters, 2005, 26(5):527-532.

局部和全局加权的二维统计不相关鉴别分析

作者：[黄明晓](#)，[荆晓远](#)，[李力](#)，[姚永芳](#)，[HUANG Ming-xiao](#)，[JING Xiao-yuan](#)，[LI Li](#)，[YAO Yong-fang](#)

作者单位：[南京邮电大学 自动化学院, 江苏 南京, 210003](#)

刊名：[计算机技术与发展](#) 

英文刊名：[Computer Technology and Development](#)

年，卷(期)：2014(6)

本文链接：http://d.wanfangdata.com.cn/Periodical_wjfz201406029.aspx