

基于改进的自适应局部保持投影算法的人脸识别

梅玲玲 龚 劬

(重庆大学数学与统计学院 重庆 401331)

摘 要 局部保持投影(LPP)通过构造近邻图来保持样本的局部结构,在构造近邻图的过程中,LPP会遇到两个参数 K 和 σ 的选择问题。近邻图的构建对算法的识别效果起着重要的作用,因而这两个参数的选择会在很大程度上影响 LPP 的识别率。为了避免参数的选择对识别率造成影响,提出了一种基于改进的自适应局部保持投影的人脸识别算法。首先,构造无参数的近邻图,其能够自适应地选取样本的近邻点并确定其相应的边权。其次,由于在计算过程中出现了矩阵维数过高的问题,因此采用 QR 分解进行降维处理。最后,利用共轭正交化使得投影轴具有统计不相关性,以降低特征矢量间的统计相关性,提高识别率。在 ORL 人脸库和 YALE 人脸库上进行了实验,结果表明改进的算法在识别率方面整体上好于 LPP 算法、DLPP 算法、LMMC 算法。

关键词 近邻图,自适应局部保持投影,人脸识别,共轭正交,统计不相关,降维

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.8.058

Face Recognition Based on Improved Adaptive Locality Preserving Projection

MEI Ling-ling GONG Qu

(College of Mathematics and Statistics, Chongqing University, Chongqing 401331, China)

Abstract Locality preserving projections (LPP) aims to preserve local structure of the data by constructing a nearest-neighbor graph. In the construction process of nearest-neighbor graph, LPP will encounter the difficulty of the selection of two parameters K and σ . The construction of nearest-neighbor graph plays an important role in recognition effect, so selection of the two parameters can affect the discrimination ability of LPP. In order to avoid the effects of the selection of parameters on recognition rate, an face recognition algorithm based on improved adaptive locality preserving projection was proposed. Firstly, a parameter-free graph construction strategy is designed, which can adaptively choose neighbors of each sample point and determine corresponding edge weights. Then, because of the high dimensionality problem in the matrix calculation process, QR decomposition is used to reduce dimension. Finally, conjugate orthogonalization is used to reduce the statistical correlation between feature vectors and improve the recognition rate by ensuring that the projection axis has statistical uncorrelation. The experimental results on ORL database show that the new algorithm is better than the LPP algorithm, DLPP algorithm, and LMMC algorithm in terms of recognition rate.

Keywords Nearest-neighbor graph, Adaptive locality preserving projection, Face recognition, Conjugate orthogonalization, Statistical uncorrelation, Dimension reduction

在大多数计算机视觉和模式识别问题中,大量的感官输入如图像和视频,对计算分析来说是极具挑战性的。在这样的情况下,我们希望能够通过特征提取降低数据的维数的同时保持样本固有的局部几何结构不变。在过去的几十年中,大量的特征提取方法被提出。线性方法包括主成分分析(Principal Component Analysis, PCA)^[1-3]、线性判别分析(Linear Discriminant Analysis, LDA)^[4,5]等。PCA 是一种无监督的降维技术,与 PCA 不同,LDA 利用了数据的类别信息,具有更好的分类性能。但是 PCA 和 LDA 均为全局线性方法。

研究表明,人脸图像可能位于高维空间的低维非线性流形之上,因此,PCA 和 LDA 无法揭示数据内在的非线性结

构。基于这些流形的假设,近年来提出的非线性流形方法有局部线性嵌入(Locally Linear Mmbedding, LLE)^[6]、拉普拉斯特征映射(Laplacian Eigenmaps)^[7]、等距映射(Isomap)^[8]等,然而这些算法不能显式地处理未见新样本的机制,无法在人脸识别中展开应用。基于此,He^[9]提出了局部保持投影(Locality Preserving Projections, LPP)算法。虽然 LPP 能够有效地保持数据的流形结构,但是它由于忽略了数据的类别信息,因此对不同类间的判别性能较差。尽管 LPP 成功运用于人脸识别领域,但它仍有一些缺陷,研究人员也在不断地对其进行改进。

局部保持投影通过构造近邻图来保持样本的局部结构,在构造近邻图的过程中,LPP 会遇到两个参数 K 和 σ 的选择

到稿日期:2015-07-10 返修日期:2015-09-15 本文受有限角逆向螺旋锥束 CT 扫描与图像重建(61271313)资助。

梅玲玲(1991-),女,硕士生,主要研究方向为图像处理与模式识别;龚 劬(1963-),女,博士,教授,主要研究方向为图像处理、小波分析、图论与组合优化、数学建模。

问题。近邻图的构建对算法的识别效果起着重要的作用,因而这两个参数的选择会在很大程度上影响 LPP 的识别率。为了避免参数的选择对识别率造成影响,本文提出了一种基于改进的自适应局部保持投影算法。首先构造无参数的近邻图^[6],其能够自适应地选取样本的近邻点并确定其相应的边权。其次由于在计算过程中出现矩阵维数过高问题,采用 QR 分解进行降维处理。最后利用共轭正交化使得投影轴具有统计不相关性,以降低特征矢量间的统计相关性,提高识别率。

1 局部保持投影算法

LPP 算法就是将训练样本投影到一个低维空间,在这个低维子空间中,原始样本点的局部信息被保存下来,即邻近的点在低维子空间中仍然是邻近的。设 $x_1, x_2, x_3, \dots, x_{n-1}, x_n$ 是 N 维欧氏空间 R^N 的 n 个训练样本,共有 c 类,每一类的样本个数分别为 $n_1, n_2, \dots, n_{c-1}, n_c$, 记 $X = (x_1, x_2, \dots, x_{n-1}, x_n)$ 。设投影矩阵为 $A \in R^{N \times d}$ 。LPP 的目的就是寻找投影矩阵使得下式最小:

$$\frac{1}{2} \sum_{i,j} \|y_i - y_j\|^2 \omega_{ij} \quad (1)$$

其中, y_i, y_j 分别代表 x_i, x_j 的投影特征向量,即 $y_i = A^T x_i$, $y_j = A^T x_j$; ω_{ij} 代表 x_i 和 x_j 的邻近关系的权值,是对称矩阵 W 的元素。邻接矩阵 W 中的元素定义如下:

$$\omega_{ij} = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma}\right), & \text{若 } x_i \text{ 位于 } x_j \text{ 的 } k \text{ 邻域} \\ 0, & \text{其他情形} \end{cases}$$

为方便讨论,下面先考虑一维投影向量的情形,设投影向量为 α ,则 LPP 的目标函数可定义为:

$$\begin{aligned} & \frac{1}{2} \arg \min_{\alpha} \sum_{i,j} (y_i - y_j)^2 \omega_{ij} \\ & = \frac{1}{2} \arg \min_{\alpha} \sum_{i,j} (\alpha^T x_i - \alpha^T x_j)^2 \omega_{ij} \\ & = \arg \min_{\alpha} \alpha^T X(D-W)X^T \alpha \\ & = \arg \min_{\alpha} \alpha^T XLX^T \alpha \end{aligned}$$

其中, D 为对角矩阵,对角线上的元素为对称矩阵 W 对应的行和或列和,即 $D_{ii} = \sum_{j=1}^n \omega_{ij}$ 且 $L = D - W$ 。另外 LPP 还施加一个限制 $\alpha^T XDX^T \alpha = 1$,故目标函数为:

$$\arg \min_{\alpha^T XDX^T \alpha = 1} \alpha^T XLX^T \alpha$$

要求解满足上式目标函数的最优投影向量,只需求解下述特征方程中最小特征值对应的特征向量。

$$XLX^T \alpha = \lambda XDX^T \alpha$$

其中, λ 表示特征值, α 表示特征向量。

若要求解 LPP 目标函数的最优投影矩阵 A ,只需求解上式特征方程中 d 个最小特征值对应的特征向量,分别记为 $\alpha_1, \alpha_2, \dots, \alpha_{d-1}, \alpha_d$,则 $A = (\alpha_1, \alpha_2, \dots, \alpha_{d-1}, \alpha_d)$ 。

为解决 LPP 算法中的小样本问题,采用最大间距准则(Maximum Margin Criterion, MMC)^[10,11]方法。MMC 以最大化类间散度矩阵和类内散度矩阵的差值为目标函数,但 MMC 方法前提假设类内散度矩阵和类间散度矩阵具有相同比例的权重,本文使用一种改进的 MMC 方法,即加权大间距准则^[12,13]。其针对实际存在的问题,对类内、类间散度矩阵分别加权修正,最大化加权投影后的类内散度矩阵和类间散度矩阵的差值。

2 本文算法

2.1 构造无参数的邻接矩阵

由上述知识可知,LPP 构造近邻矩阵时需要两个参数:近邻参数 K 与核参数 σ 。文献[14,15]指出参数 σ 与 K 的选择会严重影响 LPP 的识别性能,为避免复杂的参数选择,本节提出构造无参数的近邻图。

邻接矩阵是基于皮尔逊关系(Pearson Correlation, or Normalized Correlation)^[16]构造的并且自适应地选取邻域值。令 p_{ij} 代表任意两个样本 x_i 和 x_j 的皮尔逊系数,那么皮尔逊系数通过下式转化为大小属于区间[0,1]的相似度。

$$\overline{p_{ij}} = \frac{p_{ij} - \min(p_{ij})}{1 - \min(p_{ij})}$$

用 $\overline{p_{ij}}$ 来代表任意两个样本 x_i 和 x_j 之间的相似度,那么对于训练集中的每一个训练样本 x_i ,都可以计算出它与其他所有样本的平均相似度 m_i 。

下面构造无参数的邻接矩阵,令

$$W_{ij} = \begin{cases} \overline{p_{ij}}, & \text{若 } \overline{p_{ij}} > m_i \text{ 或 } \overline{p_{ij}} > m_j, \text{ 且 } x_i, x_j \text{ 属于同一类} \\ 0, & \text{其他情况} \end{cases} \quad (1)$$

$$\overline{W}_{ij} = \begin{cases} \overline{p_{ij}}, & \text{若 } \overline{p_{ij}} > m_i \text{ 或 } \overline{p_{ij}} > m_j, \text{ 且 } x_i, x_j \text{ 属于不同类} \\ 0, & \text{其他情况} \end{cases} \quad (2)$$

式(1)所定义的邻接矩阵 W 与 LPP 中的邻接矩阵 W 的作用是相同的,区别在于式(1)是重新构造的且使用了类别信息。

由式(1)和式(2)来重新定义类内散度矩阵 G_w 和类间散度矩阵 G_b :

$$\begin{aligned} G_w & = \sum_{i=1}^n \sum_{j=n}^n (x_i - x_j)(x_i - x_j)^T W_{ij} \\ & = 2X(D-W)X^T \\ & = 2XLX^T \end{aligned} \quad (3)$$

其中, D 为对角矩阵,对角线上的元素为对称矩阵 W 对应的行和或列和,即

$$\begin{aligned} D_{ii} & = \sum_{j=1}^n W_{ij}, L = D - W \\ G_b & = \sum_{i=1}^n \sum_{j=n}^n (x_i - x_j)(x_i - x_j)^T \overline{W}_{ij} \\ & = 2X(\overline{D} - \overline{W})X^T \\ & = 2X\overline{L}X^T \end{aligned} \quad (4)$$

其中, \overline{D} 为对角矩阵,对角线上的元素为对称矩阵 \overline{W} 对应的行和或列和,即

$$\overline{D}_{ii} = \sum_{j=1}^n \overline{W}_{ij}, \overline{L} = \overline{D} - \overline{W}$$

这里,LPP 的目标函数为

$$\max \text{tr} \left(\alpha \sum_{i=1}^n \sum_{j=1}^n (y_i - y_j)(y_i - y_j)^T \overline{W}_{ij} - (1-\alpha) \sum_{i=1}^n \sum_{j=1}^n (y_i - y_j)(y_i - y_j)^T W_{ij} \right) \quad (5)$$

把 $y_i = A^T x_i$ 代入式(5)化简可得到目标函数

$$\begin{aligned} \max J(A) & = \text{tr}(A^T [\alpha G_b - (1-\alpha)G_w]A) \\ & = \text{tr}(A^T X[\alpha \overline{L} - (1-\alpha)L]X^T A) \\ & = \text{tr}(A^T XGX^T A) \end{aligned} \quad (6)$$

其中, $A(A \in R^{N \times d})$ 是投影矩阵, $X = (x_1, x_2, \dots, x_{n-1}, x_n)$, $G = \alpha \overline{L} - (1-\alpha)L$, $\alpha \in [0, 1]$ 是加权参数,通过调整 α 的

值,可以更好地反映出高维空间中的流形结构。

在式(6)的基础上增加一个正交的约束 $A^T A = I$, 求解方法与文献[17]中的类似,于是可以得到目标函数(6)在正交约束条件下的最大值为 $\sum_{i=1}^d \lambda_i$, 其中 $\lambda_1, \lambda_2, \dots, \lambda_{d-1}, \lambda_d$ 分别是 XGX^T 的前 d 个最大的特征值,它们所对应的特征向量分别为 $\eta_1, \eta_2, \dots, \eta_{d-1}, \eta_d$, 则最优投影矩阵 $A = (\eta_1, \eta_2, \dots, \eta_{d-1}, \eta_d)$ 。

2.2 降维处理

由于矩阵 $XGX^T \in R^{N \times N}$ 维数很高,直接求其特征值和特征向量计算量太大,因此先对它进行降维处理。对 X 进行 QR 分解^[18,19], 令 $X = QR$, 其中 $X \in R^{N \times n}$, $Q (Q \in R^{N \times r})$ 有正交的列, $R (R \in R^{r \times n})$ 为上三角矩阵, r 为 X 的秩且 Q 为 X 的标准正交基。则 $A = QB$, 其中 $A \in R^{N \times d}$, $Q \in R^{N \times r}$, $B \in R^{r \times d}$, 将求 A 的问题转化成了求 B 的问题,即目标函数转化为

$$\max_{\substack{B^T Q^T Q B = I \\ B^T B = I}} \text{tr}(B^T Q^T XGX^T Q B) \quad (7)$$

令 $G_1 = Q^T XGX^T Q$, $G_1 \in R^{r \times r}$, 则问题转化为求 G_1 的前 d 个最大特征值和其对应的特征向量问题, 设 G_1 的前 d 个最大特征值所对应的特征向量分别为 $\alpha_1, \alpha_2, \dots, \alpha_{d-1}, \alpha_d$, 则 $B = (\alpha_1, \alpha_2, \dots, \alpha_{d-1}, \alpha_d)$, $A = QB$ 。

2.3 统计不相关分析^[20,21]

投影变换为 $Y = A^T X$, 其中 A 称为投影矩阵, 矩阵 A 的列矢量 $A_1, A_2, \dots, A_{d-1}, A_d$ 称为投影轴。 $Y = (Y_1, Y_2, \dots, Y_{d-1}, Y_d)^T$, $Y_i = A_i^T X$, $i = 1, 2, \dots, d$, 特征矢量 Y 的第 i 个分量与第 j 个分量之间的协方差为

$$\begin{aligned} \text{cov}(Y_i, Y_j) &= E(Y_i - EY_i)(Y_j - EY_j) \\ &= A_i^T \{E(X - EX)(X - EX)^T\} A_j \\ &= A_i^T S_i A_j \end{aligned} \quad (8)$$

其中, $S_i = \frac{1}{m} \sum_{i=1}^m (x_i - \bar{x})(x_i - \bar{x})^T$, $\bar{x} = \frac{1}{m} \sum_{i=1}^m x_i$ 。

因此第 i 个分量与第 j 个分量之间的统计意义下的相关系数为

$$\rho(Y_i, Y_j) = \frac{A_i^T S_i A_j}{\sqrt{A_i^T S_i A_i} \sqrt{A_j^T S_j A_j}} \quad (9)$$

由式(9)可知, $\rho(Y_i, Y_j) = 0$ 的充要条件^[22]是 $A_i^T S_i A_j = 0, i \neq j, i, j = 1, 2, \dots, d$ 。

当 $i \neq j$ 且第 i 个分量与第 j 个分量之间的统计意义下的相关系数为 0 时, 说明特征分量之间是统计不相关的。

如果投影轴 $A_1, A_2, \dots, A_{d-1}, A_d$ 满足 $A_i^T S_i A_j = 0, i \neq j, i, j = 1, 2, \dots, d$ 条件, 则称投影轴 $A_1, A_2, \dots, A_{d-1}, A_d$ 是具有统计不相关性的投影轴。

由式(9)可以看出, 经过变换后特征空间样本分量间信息的统计相关性是由对应的投影轴之间的统计相关性来决定的。为了消减投影变换后特征分量之间的统计相关性, 减少特征矢量之间信息的冗余, 获得真正有效的鉴别信息, 选择一组具有统计不相关性的投影轴是消除投影变换后特征分量之间的统计相关性的比较有效的方法。

由 2.2 节可以求出投影矩阵 $A = (A_1, A_2, \dots, A_{d-1}, A_d)$, 接下来利用共轭正交化^[23]来消除投影轴之间的统计相关性^[24], 进而消除变换后特征空间样本分量间信息的统计相关性。令

$$C_1 = A_1$$

$$C_2 = A_2 - \frac{A_2^T S_1 C_1}{C_1^T S_1 C_1} C_1$$

$$C_3 = A_3 - \frac{A_3^T S_1 C_1}{C_1^T S_1 C_1} C_1 - \frac{A_3^T S_2 C_2}{C_2^T S_2 C_2} C_2$$

...

$$C_k = A_k - \sum_{i=1}^{k-1} \frac{A_k^T S_i C_i}{C_i^T S_i C_i} C_i \quad (10)$$

最后, $C = (C_1, C_2, \dots, C_{d-1}, C_d)$ 即为最优投影矩阵。

3 算法描述

本文算法的具体实现步骤如下。

1) 给定训练样本集 $X = (x_1, x_2, \dots, x_{n-1}, x_n)$, 通过式(1)和式(2)计算邻接矩阵, 再由式(3)和式(4)分别计算出 L 和 \bar{L} , 进而计算出矩阵 G ;

2) 对 X 进行 QR 分解, 得到 $Q \in R^{N \times r}$, 从而计算出矩阵 $G_1 = Q^T XGX^T Q$;

3) 求出 G_1 的前 d 个最大特征值对应的特征向量 $\alpha_1, \alpha_2, \dots, \alpha_{d-1}, \alpha_d$, 则;

$$B = (\alpha_1, \alpha_2, \dots, \alpha_{d-1}, \alpha_d), A = QB$$

4) 对 $A = (A_1, A_2, \dots, A_{d-1}, A_d)$ 利用式(10)进行共轭正交化得到 $C = (C_1, C_2, \dots, C_{d-1}, C_d)$, 即为最优投影矩阵;

5) 给定一个检测样本 x_0 , 得到其不相关判别特征 $y_0 = C^T x_0$, 最后采用基于欧氏距离的最近邻分类器得到 x_0 的类别。

4 实验结果与分析

4.1 尺度因子 α 值的选取实验

本实验在 ORL 人脸库上进行。ORL 人脸库有 40 个人, 每个人包含 10 幅分辨率为 112×92 的图像, 其中有些图像是在不同时期拍摄的, 人的脸部表情和脸部细节有不同程度的变化, 另外人脸姿态也有相当程度的变化, 深度旋转和平面旋转可达 20° 。为方便实验, 将 ORL 人脸库中的图像预处理为每幅图像分辨率是 32×32 , 但不不对图像的灰度做任何处理。

本文中参数 α (尺度因子) 需要设定, α 主要用于平衡矩阵 G_w 和 G_b , 已知 $\alpha \in [0, 1]$, 取 $\alpha = \{0.05, 0.10, 0.15, \dots, 0.95, 1.00\}$ 这 20 个值来进行比较实验。

ORL 人脸库中每个人包含 10 幅图像, 实验中随机选取每个人的 n 幅图像作为训练样本, 从而构成一个具有 $40 \times n$ 幅图像的训练集, 剩下的 $40 \times (10 - n)$ 幅图像构成检测样本集。对每一个 $n (n = 2, 3, 4, 5)$ 值, 作 10 次随机划分实验, 结果取这 10 次随机划分实验的均值。图 1—图 4 分别是本文算法在特征个数 $d = 40, 50, 60, 70$, 且随机选取每个人的 $n (n = 2, 3, 4, 5)$ 幅图像作为训练样本时, 尺度因子 α 与识别率的关系图。

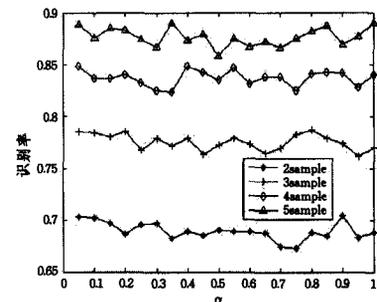


图 1 $d=40$ 时参数 α 与识别率的关系

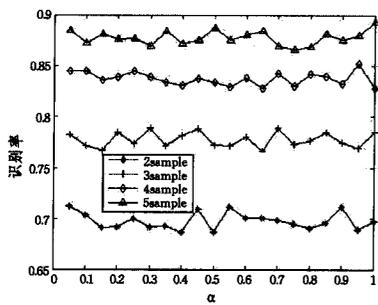


图2 $d=50$ 时参数 α 与识别率的关系

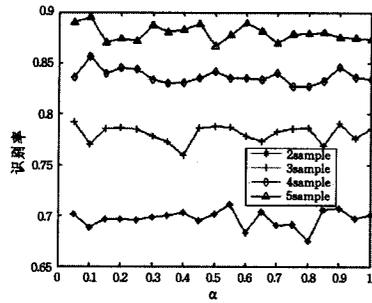


图3 $d=60$ 时参数 α 与识别率的关系

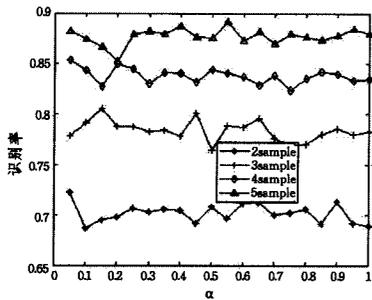


图4 $d=70$ 时参数 α 与识别率的关系

由图1—图4可以看出,在 $\alpha = \{0.05, 0.10, 0.15, \dots, 0.95, 1.00\}$ 这20个数值中,每幅图中选取不同样本数的识别率曲线均能在 $\alpha=0.05$ 时达到较高点。通过对图1—图4进行比较可以看出,特征个数选取不同值($d=40, 50, 60, 70$)时的识别率曲线也能在 $\alpha=0.05$ 时取得较高值。故实验中本文算法的尺度因子 α 取值为 0.05。

4.2 ORL 上不同算法的比较实验

用于对比实验的算法有 LPP, DLPP, LMMC 和本文所提的算法,统一采用基于欧氏距离的最近邻分类器来进行分类。图5—图9分别是对每个人选取 $n=2, 3, 4, 5, 6$ 幅图像作为训练样本时,各种算法特征值个数与识别率的关系图。其中对每一个 $n(n=2, 3, 4, 5, 6)$ 值,仍作 10 次随机划分实验,结果取这 10 次随机划分实验的均值。

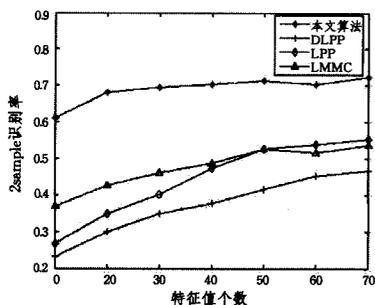


图5 取2个训练样本时特征值个数与识别率的关系

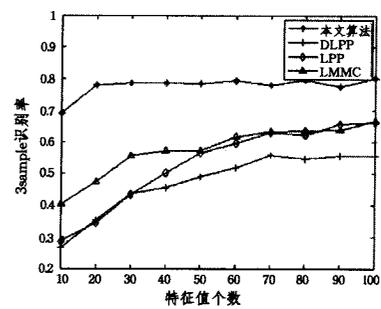


图6 取3个训练样本时特征值个数与识别率的关系

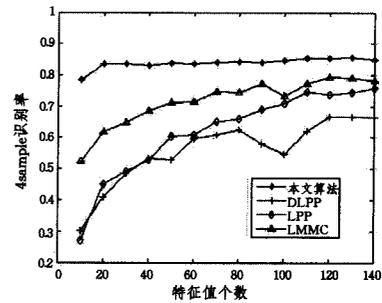


图7 取4个训练样本时特征值个数与识别率的关系

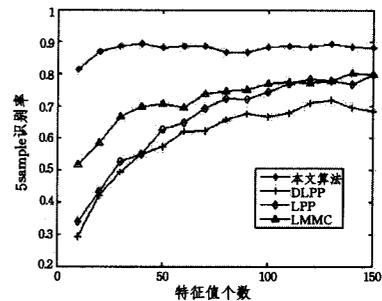


图8 取5个训练样本时特征值个数与识别率的关系

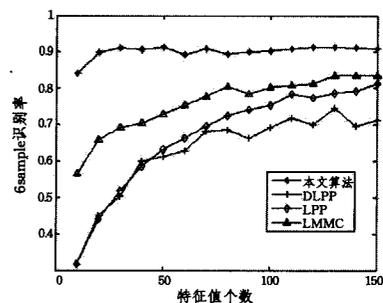


图9 取6个训练样本时特征值个数与识别率的关系

通过对图5—图9进行比较和分析可以看出:

- 1)在对每个人选取不同的训练样本时,与 LPP, DLPP, LMMC 算法相比,本文算法都能获得较高的识别率。
- 2)训练样本越多,识别效果越好。
- 3)选取的特征个数越大,识别效果越好。在特征个数较小时识别率变化非常明显,超过某一界限时虽然识别率也在提高,但是变化不再明显。

4)通过比较可以看出,当训练样本较少时,本文算法的识别效果更好,所以本文方法更适合用于人脸识别,因为人脸库的样本数较小,远小于其空间维数。

4.3 本文算法在不同人脸库上的实验

上述实验均在 ORL 人脸库上进行,为了验证本文算法的

有效性,增加在不同人脸库(YALE 人脸库)上的实验。YALE 人脸库共有 15 个人,每人有 11 幅图像,包含 3 种不同的光照情况和 6 种不同的表情,并且图像有戴眼镜和不戴眼镜的区别。同样在 YALE 人脸库上先做尺度因子 α 的选取实验,与 4.1 中的实验相同,选取 YALE 人脸库实验中参数 α 的值为 0.05。表 1 和表 2 分是在 ORL 人脸库和 YALE 人脸库上每个人选取不同训练样本时 4 种算法取得的最高识别率实验结果,括号里是取得最高识别率时特征值的个数。

表 1 ORL 人脸库上的实验结果比较

训练样本	LPP	DLPP	LMMC	本文方法
2	55.25%(70)	46.69%(70)	53.75%(70)	72.28%(70)
3	66.29%(100)	55.79%(90)	66.68%(100)	80.11%(100)
4	75.79%(140)	66.67%(120)	79.15%(130)	85.62%(130)
5	79.85%(150)	71.70%(130)	80.35%(140)	89.25%(130)
6	81.25%(150)	74.44%(130)	83.63%(140)	91.37%(120)

表 2 YALE 人脸库上的实验结果比较

训练样本	LPP	DLPP	LMMC	本文方法
2	38.37%(15)	30.07%(15)	45.01%(15)	67.30%(20)
3	55.07%(40)	48.22%(40)	54.02%(35)	73.73%(40)
4	62.67%(55)	51.34%(50)	60.67%(50)	79.73%(25)
5	64.09%(55)	49.78%(55)	69.07%(60)	83.69%(45)
6	73.36%(85)	55.81%(70)	73.17%(70)	89.23%(50)

实验结果表明,无论在 ORL 人脸库还是在 YALE 人脸库上,本文算法均取得了较好的识别率。

4.4 本文算法使用不同分类器的比较实验

上述实验均是使用基于欧氏距离的最近邻分类器进行分类,为了验证本文算法的有效性,增加使用不同分类器(余弦相似分类器)的实验。

由图 10 可以看出,在使用不同的分类器进行实验时,本文算法的识别率变化不大,就说明了本文算法是有效的。

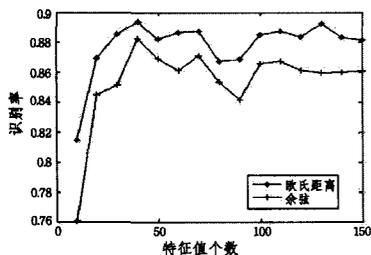


图 10 本文算法在使用不同分类器时的实验结果

4.5 无不相关条件和有不相关条件的对比实验

在本文的算法中为了消减投影变换后特征分量之间的统计相关性,减少特征矢量之间信息的冗余,获得真正有效的鉴别信息,选择了一组具有统计不相关性的投影轴。如图 11 示出本文算法在有、无不相关条件下的对比实验结果。

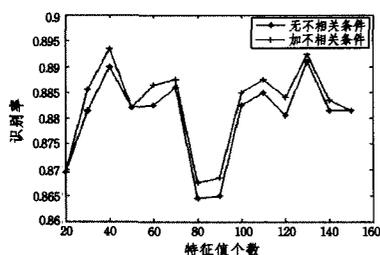


图 11 本文算法在有、无不相关条件下的对比实验结果

由图 11 可以看出,虽然添加不相关的条件后识别率提高

得不多,但还是在一定程度上提高了识别的效果,说明了选择一组具有统计不相关性的投影轴是有用的。

结束语 LPP 是使用非常广泛的一种线性流形的学习算法,其通过构造近邻图保持样本数据间的局部结构,然而在构图过程中,LPP 会遇到两个参数 K 和 σ 的选择问题。为了避免参数的选择对识别率造成影响,本文提出了一种基于改进的自适应^[25]局部保持投影的人脸识别算法。在计算的过程中为了在保持数据的几何结构的同时方便计算,进行了 QR 降维。为了避免信息冗余,本文利用共轭正交化使得投影轴具有统计不相关性,以降低特征矢量间的统计相关性,提高识别效果,降低分类时计算的复杂度。在 ORL 人脸数据库和 YALE 人脸数据库上进行实验,实验结果表明,本文算法相对其他几种算法更具优势,且训练样本较少时本文算法的识别效果更好。

参考文献

- [1] Li X W. The Method of Face Recognition Based on PCA[D]. Changsha: Hunan University, 2010(in Chinese)
李现伟. 基于 PCA 的人脸识别方法[D]. 长沙: 湖南大学, 2010
- [2] Li R J, Han Q L, Yang X H. New Optimization Method of PCA Face Recognition [J]. Journal of Dalian Jiaotong University, 2008, 29(4): 49-50(in Chinese)
李荣健, 韩其龙, 杨鑫华. 改进的 PCA 人脸识别新算法[J]. 大连交通大学学报, 2008, 29(4): 49-50
- [3] Yang H Y. The Improvement of Face Recognition Algorithm [D]. Tianjin: Tianjin Polytechnic University, 2010(in Chinese)
杨洪燕. 人脸识别算法的改进[D]. 天津: 天津工业大学, 2010
- [4] Hu Y. Face Recognition Algorithms Based on Principle Component Analysis and Independent Component Analysis[D]. Jilin: Jilin University, 2010(in Chinese)
胡月. 基于主成分分析和独立成分分析的人脸识别研究[D]. 吉林: 吉林大学, 2010
- [5] Liang W L. A Research on Algorithms for Face Recognition Technology Based on Independent Component Analysis[D]. Xi'an: Xi'an University of Science and Technology, 2012(in Chinese)
梁文莉. 基于独立成分分析的人脸识别算法研究[D]. 西安: 西安科技大学, 2012
- [6] She X Y, Zhao Y Y, Cai Y Q. Face recognition based on dynamically determining neighborhood parameter of locally linear embedding algorithm [J]. Application Research of Computers, 2014, 31(12): 3870-3872, 3884(in Chinese)
库向阳, 赵元元, 蔡院强. 基于邻域参数动态变化的局部线性嵌入人脸识别[J]. 计算机应用研究, 2014, 31(12): 3870-3872, 3884
- [7] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. Neural Comput, 2003, 15(6): 1373-1396
- [8] Tenenbaum J B, Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290: 2319-2323
- [9] He Xiao-fei, Yan Shui-cheng, Hu Yu-xiao, et al. Face Recognition Using Laplacianfaces [J]. IEEE Trans on Pattern Analysis

- and Machine Intelligence, 2005, 27(3):328-340
- [10] Guo Z J. The Application of Locality Preserving Maximum Margin Criterion In Face Recognition [J]. Science & Technology Information, 2010, 1:496-697(in Chinese)
郭子健. 局部保持最大间距准则在人脸识别中的应用[J]. 科技信息, 2010, 1:496-697
- [11] Zhan Y B, Yin J P, Liu X W. Face Feature Extraction Based on Maximum Margin Criterion and Image Matrix Bidirectional Projection[J]. Acta Automatica Sinica, 2010, 36(12):1645-1654(in Chinese)
詹宇斌, 殷建平, 刘新旺. 基于大间距准则和双向投影的人脸识别特征提取方法[J]. 自动化学报, 2010, 36(12):1645-1654
- [12] Qin C X, Ren W J, He C W, et al. Face Recognition Based on Weighted Maximum Margin Criterion [J]. Computer Engineering, 2008, 34(15):193-195(in Chinese)
秦春霞, 任文杰, 贺长伟, 等. 基于加权最大类间边缘准则的人脸识别[J]. 计算机工程, 2008, 34(15):193-195
- [13] Gong Q, Tang P F. Uncorrelated Locality Preserving Projections Analysis Based on Maximum Margin Criterion [J]. Acta Automatica Sinica, 2013, 39(9):1575-1580(in Chinese)
龚劬, 唐萍峰. 基于大间距准则的不相关保局投影分析[J]. 自动化学报, 2013, 39(9):1575-1580
- [14] Wang Su-jing, Chen Hui-ling, Peng Xu-jun, et al. Exponential Locality Preserving Projections for Small Sample Size Problem [J]. Neurocomputing, 2011, 74(17):3654-3662
- [15] Xu Yong, Zhong Ai-ni, Yang Jian, et al. LPP solution schemes for use with face recognition[J]. Pattern Recognition, 2010, 43:4165-4176
- [16] Fadi D, Ammar A. Enhanced and parameterless Locality Preserving Projections for face recognition[J]. Neurocomputing, 2013, 99:448-457
- [17] Li H F, Jiang T, Zhang K S. Efficient and robust feature extraction by maximum margin criterion [J]. IEEE Transactionson Neural Networks, 2006, 17(1):157-165
- [18] Yang L P, Gong W G, Gu X H, et al. Complete Discriminant Locality Preserving Projections for Face Recognition[J]. Journal of software, 2010, 21(6):1277-1286(in Chinese)
杨利平, 龚卫国, 辜小花, 等. 完备鉴别保局投影人脸识别算法[J]. 软件学报, 2010, 21(6):1277-1286
- [19] Gong Q, Hua T T. Face Recognition Based on Improved Locality Preserving Projection [J]. Journal of Computer Applications, 2012, 32(2):528-530, 534(in Chinese)
龚劬, 华桃桃. 基于改进的局部保持投影算法的人脸识别[J]. 计算机应用, 2012, 32(2):528-530, 534
- [20] Liang Yi-xiong, Gong Wei-guo, Pan Ying-jun, et al. Face Recognition Using Uncorrelated, Weighted Linear Discriminant Analysis[J]. Springer-Verlag Berlin Heidelberg, 2005, 3687:192-198
- [21] Gong Q, Ma J J. Face Recognition Based on Improved Two-dimensional Locality Preserving Projection Algorithm [J]. Computer Engineering, 2014, 40(9):252-256(in Chinese)
龚劬, 马家军. 基于改进二维保局投影算法的人脸识别[J]. 计算机工程, 2014, 40(9):252-256
- [22] Tang P F. Study on Face Recognition Based on Subspace Analysis and Frequency Domain Feature Extraction [D]. Chongqing: Chongqing University, 2013(in Chinese)
唐萍峰. 基于子空间分析和频域特征提取的人脸识别研究[D]. 重庆: 重庆大学, 2013
- [23] Li Y Z, Yang J Y. Novel Methods of Face Recognition Based on Non-negative Matrix Factorization[J]. Journal of System Simulation, 2008, 20(1):111-116(in Chinese)
李勇智, 杨静宇. 基于非负矩阵分解新的人脸识别方法[J]. 系统仿真学报, 2008, 20(1):111-116
- [24] Lu Gui-fu, Lin Zhong, Jin Zhong. Orthogonal Complete Discriminant Locality Preserving Projections for Face Recognition[J]. Springer Science Business Media, LLC, 2011, 33:235-250
- [25] Huang P, Tang Z M. Parameter-Free Locality Preserving Projections and Face Recognition[J]. Pattern Recognition and Artificial Intelligence, 2013, 26(9):865-871(in Chinese)
黄璞, 唐振民. 无参数局部保持投影及人脸识别[J]. 模式识别与人工智能, 2013, 26(9):865-871

(上接第 285 页)

- [9] Chu J, Jin L, Tong B, et al. A Monitoring Method of Driver Mouth Behavior Based on Machine Vision[C]//2004 IEEE Intelligent Vehicles Symposium. 2004:351-356
- [10] Li Shao-wen, Wang Jiang-bo. Research on driver fatigue detection system[J]. Computer Engineering and Applications, 2013, 49(15):253-258(in Chinese)
李绍文, 王江波. 驾驶员疲劳检测系统研究[J]. 计算机工程与应用, 2013, 49(15):253-258
- [11] Chen Yun-hua, Yu Yong-quan, Zhang Ling, et al. Mental Fatigue Recognition Extension Model Based on Facial Visual Cues [J]. Computer Science, 2013, 40(2):284-288(in Chinese)
陈云华, 余永权, 张灵, 等. 基于面部视觉特征的精疲劳可拓辨识模型[J]. 计算机科学, 2013, 40(2):284-288
- [12] Daugman J G. Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters[J]. Journal of the Optical Society of America, 1985, 2(7):1160-1169
- [13] Zhang W, Shan S, Gao W, et al. Local Gabor binary pattern histogram sequence (LGBPHS): A novel non-statistical model for face representation and recognition[J]. International Conference on Computer Vision, 2005, 1:786-791
- [14] Liu C, Wechsler H. Gabor feature based classification using the enhanced Fisher linear discriminant model for face recognition [J]. IEEE Transaction on Image Processing, 2002, 11(4):467-476
- [15] Yang J, Zhang D. Two-dimensional PCA: A New Approach to Appearance-based Face Representation and Recognition [J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2004, 26(1):131-137
- [16] Ramamoorthi R. Analytic PCA construction for theoretical analysis of lighting variability in images of a Lambertian object[J]. IEEE PAMI, 2002, 24(10):1322-1333
- [17] Plumbley M D, Abdallah S A, Blumensath T. Musical audio analysis using sparse representations[C]//Proceedings in Computational Statistics. 2005:104-117