

一种基于重采样双向 2DLDA 融合的人脸识别算法

李文辉, 姜园媛, 王 莹, 傅 博

(吉林大学计算机科学与技术学院, 吉林长春 130012)

摘 要: 针对人脸识别中普遍存在的光照、表情等变化带来的识别问题和小样本问题, 本文提出了一种利用重采样技术融合双向 2DLDA 特征的人脸识别算法 Resampling Bidirection 2DLDA(RB2DLDA). 二维线性判别分析中, 2DLDA 利用垂直方向上的类内和类间协方差信息进行识别, E2DLDA 利用水平方向上的类内和类间协方差信息进行识别, 本文中从理论上证明了这两个方向上的判别信息具有一定的互补性, 为融合两个方向的判别信息进行分类器的设计, 改善分类器的识别性能提供了理论基础. 同时为 RB2DLDA 算法提出一种自适应的降维参数设定方法, 经过在 AR 和 CAS-PEAL-R1 人脸库上的实验表明, RB2DLDA 算法具有较高的识别率和鲁棒性.

关键词: 人脸识别; 重采样; 双向二维线性判别分析

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2011) 11-2526-08

A Face Recognition Algorithm Using a Fusion Method Based on Resampling Bidirectional 2DLDA

LI Wen-hui, JIANG Yuan-yuan, WANG Ying, FU Bo

(College of Computer Science and Technology, Jilin University, Changchun, Jilin 130012, China)

Abstract: Aiming at recognition problem caused by variations in lighting, facial expression etc and small sample size problem which generally exist in face recognition, this paper proposes a novel recognition method, called RB2DLDA, which fuses bidirectional 2DLDA feature by resampling technique. In matrix-based LDA, 2DLDA uses inner-class and intra-class covariance information in the vertical direction, and E2DLDA uses inner-class and intra-class covariance information in the horizontal direction, this paper proves in theory that class information in the two directions is complementary to each other to some extent, provides theoretical foundation for fusing class information in the two directions to design classifier and improves recognition performance of the classifier. Moreover, proposes an adaptive algorithm of setting feature reduction parameter. Our method is tested on AR and CAS-PEAL-R1 face databases, and the experimental results show that the proposed approach possesses higher recognition accuracy and robustness than other state-of-the art methods.

Key words: face recognition; resampling; bidirectional two-dimensional linear discriminant analysis (2DLDA)

1 引言

线性判别分析 (Linear Discriminant Analysis) LDA^[1,2] 是模式识别中较常用的一种算法, 主要思想是最小化类内距离的同时最大化类间距离, 得到最优的投影方向以产生最好的分类结果. LDA 在人脸识别^[3]中得到了很广泛地应用, 但是不能很好解决目前普遍存在的两个问题: 光照、表情等变化引起的面部大变化带来的识别问题和小样本问题^[4].

光照、表情等变化问题^[1]会使人脸图像中的像素值发生较大的变化, 从而使得基于外观的识别算法的性能

下降. 且由于变化的多样性和样本采集的难度, 在仅有有限个训练样本的条件下, 很难得到准确的类内类间离散度矩阵, 直接影响到分类器的识别性能. 因此如何充分利用有限的样本显得十分重要, 目前关于这方面的研究有: 变换已有样本构建虚拟图像^[5]得到更多情况下的样本, 缺点是计算量和存储量较大; 在人脸分类器的设计中引入重采样算法^[6,7]构建多分类器, 以提高分类器的识别性能.

小样本问题是指, 由于样本库中的样本数量远小于样本的特征维数, 样本与样本之间的距离变大使得距离度量失效, 使 LDA 算法中的类内、类间离散度矩阵奇

异,不能得到最优的投影方向.目前解决小样本问题的主要方法有:(1)正则化判别分析 RDA 方法^[8],通过扰动使得类内离散度矩阵非奇异;(2)低维子空间法,在降维后的样本空间中进行 LDA,如 FisherFaces^[1],基于 QR 分解的 LDA^[9],零空间 LDA^[10,11],随机子空间 LDA^[12,13]等;(3)直接在二维图像矩阵上进行 LDA,从而避免小样本问题,如 2DLDA^[14]或 E2DLDA (Extended 2DLDA)、B2DLDA^[15]、(2D) 2DLDA^[16]、S2DLDA^[17]等二维 LDA 方法^[18].

二维 LDA 不仅可以避免小样本问题,与一维的方法相比,能够利用图像矩阵空间上的结构信息,估计出更准确的类内类间离散度矩阵,且计算复杂度较低.本文中通过理论分析以及实验证明了 2DLDA 和 E2DLDA 判别信息的互补性,并提出利用重采样技术进行 2DLDA 和 E2DLDA 特征的融合,从而获得更好的识别效果.本文算法 RB2DLDA 的优点为:始终在二维空间中进行,计算复杂度较低,并且保留图像空间上的结构关系;同时保持水平和垂直方向的判别信息,并利用两个方向判别信息的互补性,避免只使用单方向判别信息的片面性,从而保证了算法的鲁棒性;使用重采样技术充分利用了现有样本,并提高了分类器的识别性能.

2 2DLDA 和 E2DLDA

设 $\mathbf{X} = \{X_1, X_2, \dots, X_i, \dots, X_L\}$, $\mathbf{X}_i = \{X_{i,1}, X_{i,2}, \dots, X_{i,j}, \dots, X_{i,L_i}\}$, $i = 1, 2, \dots, L, j = 1, 2, \dots, L_i$. \mathbf{X} 为总样本集, L 为样本总类别数; \mathbf{X}_i 是第 i 类样本的样本集, L_i 是第 i 类样本的个数. $\bar{\mathbf{X}}$ 是所有样本的平均值, $\bar{\mathbf{X}}_i$ 是第 i 类的平均值. $\mathbf{X}_{i,j}$ 代表 \mathbf{X}_i 的第 j 个样本,维数 $m \times n$. 总样本数为 $\sum_{i=1}^L L_i = N$.

2DLDA 的目的是同时保证类内距离最小化和类间距离最大化,最终得到最优投影方向 \mathbf{P}_{2DLDA} :

$$\mathbf{P}_{2DLDA} = \arg \max_{\mathbf{W}} \frac{\mathbf{W}^T \mathbf{S}_B^L \mathbf{W}}{\mathbf{W}^T \mathbf{S}_W^L \mathbf{W}} \quad (1)$$

$\mathbf{S}_W^L = \sum_{i=1}^L \sum_{j=1}^{L_i} \frac{1}{N} (\mathbf{X}_{i,j} - \bar{\mathbf{X}}_i) (\mathbf{X}_{i,j} - \bar{\mathbf{X}}_i)^T$ 为类内离散度矩阵, $\mathbf{S}_B^L = \sum_{i=1}^L \frac{L_i}{N} (\bar{\mathbf{X}}_i - \bar{\mathbf{X}}) (\bar{\mathbf{X}}_i - \bar{\mathbf{X}})^T$ 为类间离散度矩阵.

求解上述式(1)的最优投影方向 \mathbf{P}_{2DLDA} 可以转化为计算 $\mathbf{S}_W^L^{-1} \mathbf{S}_B^L$ 的特征值矩阵 \mathbf{V} 和特征向量矩阵 \mathbf{U} . 表示为 $\mathbf{V} = \{\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_i, \dots, \mathbf{V}_m\}$, $i = 1, 2, \dots, m$; $\mathbf{U} = \{\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_i, \dots, \mathbf{U}_m\}$, $i = 1, 2, \dots, m$, $\mathbf{U}_i = \{U_{1,i}, U_{2,i}, \dots, U_{j,i}, \dots, U_{m,i}\}^T$, $j = 1, 2, \dots, m$. 降序排列 \mathbf{V} , 由降维参数 d 决定前 d 个较大的特征值 $\{\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_d\}$ 对应的特征向量 $\{U_1, U_2, \dots, U_d\}$ 为最优投影方向. d 一般利用贡献率设定,经验阈值设为 90% 以上.

E2DLDA 可进行类似定义 \mathbf{P}_{E2DLDA} :

$$\mathbf{P}_{E2DLDA} = \arg \max_{\mathbf{W}} \frac{\mathbf{W}^T \mathbf{S}_B^R \mathbf{W}}{\mathbf{W}^T \mathbf{S}_W^R \mathbf{W}} \quad (2)$$

$\mathbf{S}_W^R = \sum_{i=1}^L \sum_{j=1}^{L_i} \frac{1}{N} (\mathbf{X}_{i,j} - \bar{\mathbf{X}}_i) (\mathbf{X}_{i,j} - \bar{\mathbf{X}}_i)^T$ 为类内离散度矩阵, $\mathbf{S}_B^R = \sum_{i=1}^L \frac{L_i}{N} (\bar{\mathbf{X}}_i - \bar{\mathbf{X}}) (\bar{\mathbf{X}}_i - \bar{\mathbf{X}})^T$ 为类间离散度矩阵.

3 重采样和集成

3.1 重采样

人脸识别过程不可避免地存在光照、表情等变化,直接影响到分类器的识别性能和稳定性.因此,设计分类器时不直接使用有限的训练样本,而是引入重采样算法,在训练样本集中进行随机采样,利用采样出的若干个子训练样本集进行分类器的训练和集成.重采样虽然使得单个分类器的识别性能下降,但是集成后会获得更好的识别效果,同时可以平均化识别过程中出现的不稳定的现象,表现为在光照、表情变化影响下的分类器识别性能和稳定性的提高.

基于 LDA 的识别算法中使用了类内和类间离散度矩阵,所以本文中的重采样算法并不是在整个训练样本集上进行,而是在每一类别中进行随机采样,并保证每一个类别中采集到的样本数一致,从而得到若干个样本数一致的子训练样本集.

3.2 集成

通过重采样训练样本集得到若干个子样本集后,在这些子样本集上进行 2DLDA 和 E2DLDA 的训练,可以得到若干个基于余弦距离的最近邻分类器,将这若干个分类器进行集成从而得到最终的人脸分类器.目前的集成方法主要有两种:总和规则和最大规则^[6].一般子样本集的个数足够多时,才能得到较为准确的分类结果.

4 本文算法 RB2DLDA

4.1 2DLDA 和 E2DLDA 的互补性

定义 1 $\mathbf{X}_{i,j} = \{X_{i,j}|_1, X_{i,j}|_2, \dots, X_{i,j}|_n\} \in R^{m \times n}$, 其中 $X_{i,j}|_t \in R^{m \times 1}$ 是矩阵 $\mathbf{X}_{i,j}$ 中的第 t 列, $t = 1, 2, \dots, n$, $X_{i,j}|^t \in R^{1 \times n}$ 是矩阵 $\mathbf{X}_{i,j}$ 中的第 t 行, $t = 1, 2, \dots, m$, 则有下式成立:

$$\begin{aligned} \bar{\mathbf{X}}_i &= \{\bar{\mathbf{X}}_i|_1, \bar{\mathbf{X}}_i|_2, \dots, \bar{\mathbf{X}}_i|_n\} \\ &= \left\{ \frac{1}{L_i} \sum_{j=1}^{L_i} X_{i,j}|_1, \frac{1}{L_i} \sum_{j=1}^{L_i} X_{i,j}|_2, \dots, \frac{1}{L_i} \sum_{j=1}^{L_i} X_{i,j}|_n \right\} \\ \bar{\mathbf{X}}_i &= \{\bar{\mathbf{X}}_i|^1, \bar{\mathbf{X}}_i|^2, \dots, \bar{\mathbf{X}}_i|^m\} \\ &= \left\{ \frac{1}{L_i} \sum_{j=1}^{L_i} X_{i,j}|^1, \frac{1}{L_i} \sum_{j=1}^{L_i} X_{i,j}|^2, \dots, \frac{1}{L_i} \sum_{j=1}^{L_i} X_{i,j}|^m \right\} \\ \bar{\mathbf{X}} &= \{\bar{\mathbf{X}}|_1, \bar{\mathbf{X}}|_2, \dots, \bar{\mathbf{X}}|_n\} \end{aligned}$$

$$= \left\{ \sum_{i=1}^l \frac{L_i}{N} \bar{X}_i |1, \sum_{i=1}^l \frac{L_i}{N} \bar{X}_i |2, \dots, \sum_{i=1}^l \frac{L_i}{N} \bar{X}_i |n \right\}$$

$$\bar{X} = \{ \bar{X} |1, \bar{X} |2, \dots, \bar{X} |m \}$$

$$= \left\{ \sum_{i=1}^l \frac{L_i}{N} \bar{X}_i |1, \sum_{i=1}^l \frac{L_i}{N} \bar{X}_i |2, \dots, \sum_{i=1}^l \frac{L_i}{N} \bar{X}_i |m \right\}$$

引理 1^[17] 2DLDA 等价于基于列的 LDA;

$$S_W^L = \sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} (\mathbf{X}_{i,j} - \bar{X})(\mathbf{X}_{i,j} - \bar{X})^T$$

$$= \sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{t=1}^n (\mathbf{X}_{i,j}|_t - \bar{X}_i|_t) (\mathbf{X}_{i,j}|_t - \bar{X}_i|_t)^T$$

$$S_B^L = \sum_{i=1}^l \frac{L_i}{N} (\bar{X}_i - \bar{X})(\bar{X}_i - \bar{X})^T$$

$$= \sum_{i=1}^l \frac{L_i}{N} \sum_{t=1}^n (\bar{X}_i|_t - \bar{X}|_t) (\bar{X}_i|_t - \bar{X}|_t)^T$$

扩展引理 1 E2DLDA 等价于基于行的 LDA.

$$S_W^R = \sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} (\mathbf{X}_{i,j} - \bar{X})^T (\mathbf{X}_{i,j} - \bar{X})$$

$$= \sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{t=1}^m (\mathbf{X}_{i,j}|^t - \bar{X}_i|^t)^T (\mathbf{X}_{i,j}|^t - \bar{X}_i|^t)$$

$$S_B^R = \sum_{i=1}^l \frac{L_i}{N} (\bar{X}_i - \bar{X})^T (\bar{X}_i - \bar{X})$$

$$= \sum_{i=1}^l \frac{L_i}{N} \sum_{t=1}^m (\bar{X}_i|^t - \bar{X}|^t)^T (\bar{X}_i|^t - \bar{X}|^t)$$

引理 2^[19] 令 $\tilde{\mathbf{w}} = [\tilde{w}|_1^T, \tilde{w}|_2^T, \dots, \tilde{w}|_n^T]^T$ 为 $(m \times n) \times 1$ 维向量, 其中 $\tilde{w}|_t \in R^{m \times 1}$ 是矩阵 $\tilde{\mathbf{w}}$ 中的第 t 列, $t = 1, 2, \dots, n$, 若满足 $w^L = \tilde{w}|_1 = \tilde{w}|_2 = \dots = \tilde{w}|_n \in R^{m \times 1}$:

$$\tilde{\mathbf{w}}^T S_B^L \tilde{\mathbf{w}} = \mathbf{w}^{L^T} S_B^L \mathbf{w}^L$$

$$+ \mathbf{w}^{L^T} \left\{ \sum_{i=1}^l \frac{L_i}{N} \sum_{p=1, q=1, p \neq q}^n A_i|_p A_i|_q^T \right\} \mathbf{w}^L \quad (3)$$

$$\tilde{\mathbf{w}}^T S_W^L \tilde{\mathbf{w}} = \mathbf{w}^{L^T} S_W^L \mathbf{w}^L$$

$$+ \mathbf{w}^{L^T} \left\{ \sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, p \neq q}^n A_{i,j}|_p A_{i,j}|_q^T \right\} \mathbf{w}^L \quad (4)$$

其中 $A_i|_p = \bar{X}_i|_p - \bar{X}|_p$; $A_{i,j}|_p = X_{i,j}|_p - \bar{X}_i|_p$.

同理, 可得到扩展引理 2.

扩展引理 2 令 $\tilde{\mathbf{w}} = [\tilde{w}|^1, \tilde{w}|^2, \dots, \tilde{w}|^m]^T$ 为 $(m \times n) \times 1$ 维向量, 其中 $\tilde{w}|^t \in R^{1 \times n}$ 是矩阵 $\tilde{\mathbf{w}}$ 中第 t 行, $t = 1, 2, \dots, m$, 若满足 $\mathbf{w}^R = \tilde{w}|^1 = \tilde{w}|^2 = \dots = \tilde{w}|^m \in R^{1 \times n}$:

$$\tilde{\mathbf{w}}^T S_B^R \tilde{\mathbf{w}} = \mathbf{w}^{R^T} S_B^R \mathbf{w}^R$$

$$+ \mathbf{w}^{R^T} \left\{ \sum_{i=1}^l \frac{L_i}{N} \sum_{p=1, q=1, p \neq q}^n A_i|_p^T A_i|_q \right\} \mathbf{w}^R \quad (5)$$

$$\tilde{\mathbf{w}}^T S_W^R \tilde{\mathbf{w}} = \mathbf{w}^{R^T} S_W^R \mathbf{w}^R$$

$$+ \mathbf{w}^{R^T} \left\{ \sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, p \neq q}^n A_{i,j}|_p^T A_{i,j}|_q \right\} \mathbf{w}^R \quad (6)$$

其中 $A_i|_p = \bar{X}_i|_p - \bar{X}|_p$; $A_{i,j}|_p = X_{i,j}|_p - \bar{X}_i|_p$.

由引理 1、引理 2 说明, 经过 2DLDA 算法后的方差信息为图像相同列之间的方差信息, 即不包括图像不同列之间的信息; 由扩展引理 1、扩展引理 2 说明, 经过 E2DLDA 算法后的方差信息为图像行与行之间的方差信息, 即不包括不同行之间的信息.

借助上述引理可以得到如下定理:

定理 1 令 $\tilde{\mathbf{w}} = [\tilde{w}|_1^T, \tilde{w}|_2^T, \dots, \tilde{w}|_n^T]^T = [\tilde{w}|^1, \tilde{w}|^2, \dots, \tilde{w}|^m]^T$ 为 $(m \times n) \times 1$ 维向量, 若满足 $\mathbf{w}^L = \tilde{w}|_1 = \tilde{w}|_2 = \dots = \tilde{w}|_n \in R^{m \times 1}$ 且 $\mathbf{w}^R = \tilde{w}|^1 = \tilde{w}|^2 = \dots = \tilde{w}|^m \in R^{1 \times n}$, 即 $\tilde{\mathbf{w}}$ 中所有元素相等:

$$\mathbf{w}^{L^T} S_W^L \mathbf{w}^L = \tilde{w}|_1^T \left[\sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, r=1, q=r}^m A_{i,j}|_p^q A_{i,j}|_p^r \right] \tilde{w}|_1$$

$$+ \tilde{w}|_1^T \left[\sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, r=1, q \neq r}^m A_{i,j}|_p^q A_{i,j}|_p^r \right] \tilde{w}|_1 \quad (7)$$

$$\mathbf{w}^{L^T} S_B^L \mathbf{w}^L = \tilde{w}|_1^T \left[\sum_{i=1}^l \frac{L_i}{N} \sum_{p=1, q=1, r=1, q=r}^m A_i|_p^q A_i|_p^r \right] \tilde{w}|_1$$

$$+ \tilde{w}|_1^T \left[\sum_{i=1}^l \frac{L_i}{N} \sum_{p=1, q=1, r=1, q \neq r}^m A_i|_p^q A_i|_p^r \right] \tilde{w}|_1 \quad (8)$$

$$\mathbf{w}^{R^T} S_W^R \mathbf{w}^R = \tilde{w}|^1 T \left[\sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, r=1, q=r}^m A_{i,j}|_p^q A_{i,j}|_p^r \right] \tilde{w}|^1$$

$$+ \tilde{w}|^1 T \left[\sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, r=1, p \neq r}^m A_{i,j}|_p^q A_{i,j}|_p^r \right] \tilde{w}|^1 \quad (9)$$

$$\mathbf{w}^{R^T} S_B^R \mathbf{w}^R = \tilde{w}|^1 T \left[\sum_{i=1}^l \frac{L_i}{N} \sum_{p=1, q=1, r=1, q=r}^m A_i|_p^q A_i|_p^r \right] \tilde{w}|^1$$

$$+ \tilde{w}|^1 T \left[\sum_{i=1}^l \frac{L_i}{N} \sum_{p=1, q=1, r=1, p \neq r}^m A_i|_p^q A_i|_p^r \right] \tilde{w}|^1 \quad (10)$$

其中 $A_i|_p = \bar{X}_i|_p - \bar{X}|_p$; $A_{i,j}|_p = X_{i,j}|_p - \bar{X}_i|_p$.

证明

$$\mathbf{w}^{L^T} S_W^L \mathbf{w}^L$$

$$= \mathbf{w}^{L^T} \left\{ \sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, p=q}^n A_{i,j}|_p A_{i,j}|_q^T \right\} \mathbf{w}^L$$

$$= \mathbf{w}^{L^T} \left\{ \sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, p=q}^n \begin{bmatrix} A_{i,j}|_p^1 \\ A_{i,j}|_p^2 \\ \vdots \\ A_{i,j}|_p^m \end{bmatrix} \begin{bmatrix} A_{i,j}|_p^1 \\ A_{i,j}|_p^2 \\ \vdots \\ A_{i,j}|_p^m \end{bmatrix}^T \right\} \mathbf{w}^L$$

$$= \tilde{w}|_1^T \left[\sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, r=1}^m A_{i,j}|_p^q A_{i,j}|_p^r \right] \tilde{w}|_1$$

$$= \tilde{w}|_1^T \left[\sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, r=1, q=r}^m A_{i,j}|_p^q A_{i,j}|_p^r \right] \tilde{w}|_1$$

$$+ \tilde{w}|_1^T \left[\sum_{i=1}^l \sum_{j=1}^{l_i} \frac{1}{N} \sum_{p=1, q=1, r=1, q \neq r}^m A_{i,j}|_p^q A_{i,j}|_p^r \right] \tilde{w}|_1$$

$$\begin{aligned}
 & \mathbf{w}^{L^T} \mathbf{S}_B^L \mathbf{w}^L \\
 &= \mathbf{w}^{L^T} \left\{ \sum_{i=1}^L \frac{L_i}{N} \sum_{p=1, q=1, p=q}^n A_i \left|_p A_i \right|_q^T \right\} \mathbf{w}^L \\
 &= \mathbf{w}^{L^T} \left\{ \sum_{i=1}^L \frac{L_i}{N} \sum_{p=1, q=1, p=q}^n \begin{bmatrix} A_i \left|_p^1 \right. \\ A_i \left|_p^2 \right. \\ \vdots \\ A_i \left|_p^m \right. \end{bmatrix} \begin{bmatrix} A_i \left|_p^1 \right. \\ A_i \left|_p^2 \right. \\ \vdots \\ A_i \left|_p^m \right. \end{bmatrix}^T \right\} \mathbf{w}^L \\
 &= \tilde{\mathbf{w}} \left|_1^T \left[\sum_{i=1}^L \frac{L_i}{N} \sum_{p=1}^n \sum_{q=1, r=1}^m A_i \left|_p^q A_i \right|_p^r \right] \tilde{\mathbf{w}} \left|_1 \right. \\
 &= \tilde{\mathbf{w}} \left|_1^T \left[\sum_{i=1}^L \frac{L_i}{N} \sum_{p=1}^n \sum_{q=1, r=1, q=r}^m A_i \left|_p^q A_i \right|_p^r \right] \tilde{\mathbf{w}} \left|_1 \right. \\
 &+ \tilde{\mathbf{w}} \left|_1^T \left[\sum_{i=1}^L \frac{L_i}{N} \sum_{p=1}^n \sum_{q=1, r=1, q \neq r}^m A_i \left|_p^q A_i \right|_p^r \right] \tilde{\mathbf{w}} \left|_1 \right.
 \end{aligned}$$

同理, E2DLDA 也可进行相同证明。

虽然 $\tilde{\mathbf{w}}$ 是一个较特殊的向量,但是可以从定理 1 中看出,经过 2DLDA 和 E2DLDA 后,两者共同的方差信息为图像对应像素之间方差信息.除此之外,2DLDA 其余的方差信息为相同列上不同像素之间的方差信息, E2DLDA 其余的方差信息为相同行上的不同像素之间的方差信息,即其他的方差信息完全不同.从图像矩阵的角度上来讲,2DLDA 利用的是垂直方向上的判别信息, E2DLDA 则是利用水平方向上的判别信息.即证明了 2DLDA 和 E2DLDA 中所使用的判别信息具有一定的一致性和信息互补性,为融合两个方向的判别信息,提高分类器的识别率提供了理论基础。

4.2 算法中降维参数 d 的设定

d 的设定直接影响识别结果,降维维数足够多时才能保证识别率,而维数过多时则会对分类性能带来负面影响.利用贡献率设定 d 的优点是简单直观,缺点有:通过 \mathbf{V} 来确定 d ,没有利用到 \mathbf{U} ,即二维图像矩阵所具有的判别信息;需要利用经验值设定贡献率阈值,实验结果与阈值的设定有着密切关系。

本文中提出一种同时利用特征值矩阵 \mathbf{V} 和特征向量矩阵 \mathbf{U} 的自适应设定降维参数 d 的方法:

(1)按照对应的特征值降序的顺序排列每个特征向量 U_i .

(2)FOR $i = 1: m$

选出 U_i 中绝对值最大的值对应的行号,即选出对

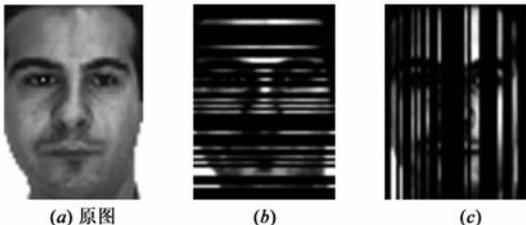


图1 特征向量矩阵选出具有最大权值绝对值的行(b)和列(c)

于判别具有最大影响的行;

END

(3)去除重复选择的行,得到由特征矩阵 \mathbf{U} 选择出的行的个数,记为 d .

主要思想是,可将每一个 U_i 看做对于原样本的行向量的权重,若 U_i 中第 j 行的权重绝对值较大,说明原样本中的第 j 行对于识别有着重要的作用.实验中根据本算法挑选出特征向量中权值绝对值最大的行和列,如图 1 所示的未画黑的部分,可以看出基本集中于含有较多识别信息的细节的面部中心区域.实验证明选择出的行和列对于识别有着重要的作用。

本文中这种同时利用 \mathbf{V} 和 \mathbf{U} 设定 d 的算法充分利用了 \mathbf{U} 所包含的权值信息;且不需要进行阈值的设定,实现了算法的自适应。

4.3 RB2DLDA 流程

算法主要流程如图 2:

(1)利用重采样从样本集 R 中分别独立选出 K 个子样本集 $\{R_1, R_2, \dots, R_k\}$. R_k 中的每个类别都随机采样 S 个样本, R_k 的样本数 $N' < N$.

(2)FOR $k = 1: K$

在 R_k 上进行 2DLDA 训练,得到分类器 2DLDAC_k;

在 R_k 上进行 E2DLDA 训练,得到分类器 E2DLDAC_k;

END

(3)采用最大规则集成 $K \times 2$ 个分类器,得到分类器 C .

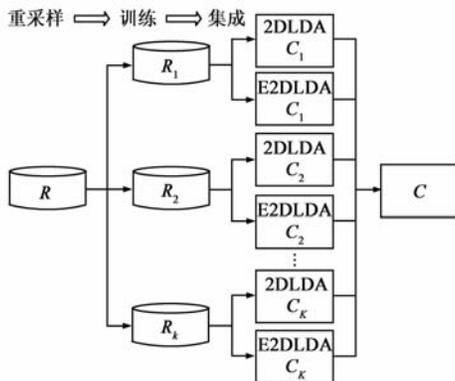


图2 RB2DLDA流程图

5 实验结果

5.1 人脸库的介绍

本文选取 AR 和 CAS-PEAL-R1 人脸库进行实验:

AR 人脸库^[20]:选取包含 121 人、每人表情变化和光照变化下的 12 个样本,共 1452 幅人脸图像的训练子集.表情变化库 AR_E 按照时间分为两个子库: $a \sim c$ 为 AR_E1; $d \sim f$ 为 AR_E2.光照变化库 AR_L 按照时间分为两个子库: $g \sim i$ 为 AR_L1; $j \sim l$ 为 AR_L2.

CAS-PEAL-R1:选取包含 100 人、每人表情变化和光照变化下的 12 个样本,共 1200 幅人脸图像的人脸库子

集.表情变化库 CAL_E 按照程度分为两个子库:皱眉,微笑,自然($b \sim d$)为 CAL_E1;闭眼,张嘴,吃惊($a, e \sim f$)为 CAL_E2.光照变化库 CAL_L 按照光源高度分为两个子库: $g \sim i$ 为 CAL_L1; $j \sim l$ 为 CAL_L2.



图3 AR((a),(d)自然;(b),(e):微笑;(c),(f):生气;(g),(j):左侧光照;(h),(k):右侧光照;(i),(l):两侧光照)

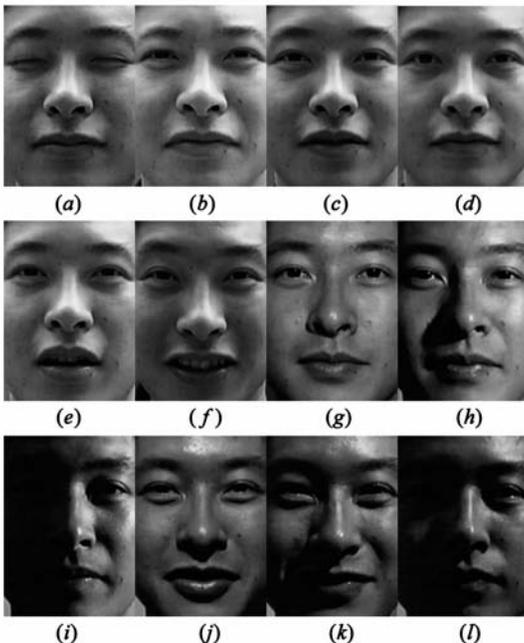


图4 CAS-PEAL-R1((a):闭眼;(b):皱眉;(c):微笑;(d):自然;(e):张嘴;(f):吃惊;(g):FM0°;(h):FM-45°;(i):FM-90°;(j):FU0°;(k):FU-45°;(l):FU-90°)F表示日光光照;光源高度M:0°,U:+45°,XX°代表光源位置

实验前首先对人脸库中样本进行灰度均衡化且为了便于处理缩放到 48×66 大小.实验中,考虑到实际应用中有可能出现训练库中未采集到的情况,采用交叉验证法中的留一法能更准确地测试出算法的识别性

能、稳定性和鲁棒性.实验包含 5 个部分:(1)从识别情况入手,表情变化、光照变化以及同时存在表情变化和光照变化这三种情况下的识别实验;(2)综合分析算法的识别性能;(3)实验证明 2DLDA 和 E2DLDA 的信息互补性,且利用两个方向的互补信息能够提高算法的识别性能,即 RB2DLDA 算法的正确性.

5.2 表情变化

在 CAL_E 和 AR_E 上实验得到的平均识别效果如表 1 所示,其中 RB2DLDA 是调整 K 参数获得的最好的平均识别率;图 5 是 RB2DLDA 算法在不同的 K、S 参数下获得的平均识别率.

表 1 不同算法在表情变化下的识别率比较

识别率(%)	算法	E1	E2	平均
CAL	FisherFaces ^[1]	72.33	76	74.17
	2DLDA ^[14]	95	97	96
	E2DLDA	96.67	97	96.83
	B2DLDA ^[15]	94	95.67	94.83
	(2D)2LDA ^[16]	94.67	95.67	95.17
	RB2DLDA	S = 3	97.33	96.67
	S = 4	97	97	97
AR	FisherFaces	58.40	64.46	61.43
	2DLDA	95.59	94.50	95.04
	E2DLDA	95.60	96.42	96.01
	B2DLDA	95.04	94.77	94.90
	(2D)2LDA	96.14	95.04	95.59
	RB2DLDA	S = 3	97.25	96.69
	S = 4	96.97	96.69	96.83

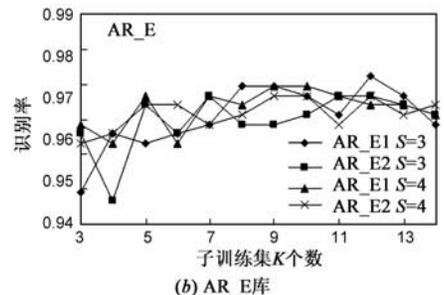
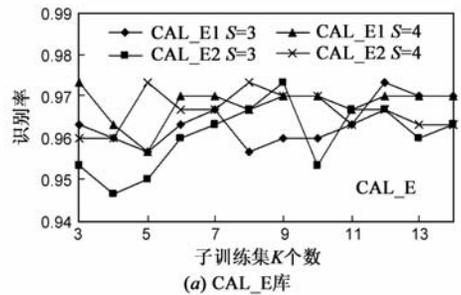


图5 RB2DLDA在表情变化下的识别率. K为子训练集个数, S是每类样本的采样个数

表情变化特别是皱眉、微笑等表情对垂直方向的影响较大,但是水平方向能够保证足够的判别信息,所以E2DLDA取得了比2DLDA更优的识别结果.这也同

时说明 RB2DLDA 在其中一个方向能够保证足够的判别信息的情况下,能比 B2DLDA、(2D)2LDA 更好地利用互补信息获得更优的性能.由图 5 可看出,RB2DLDA 算法的总体趋势是 K 取值较大时能够获得较好的识别结果.

5.3 光照变化

表 2 中为 CAL_L、AR_L 上的平均识别效果:

表 2 不同算法在光照变化下的识别率比较

识别率 (%)	算法	L1	L2	平均	
CAL	FisherFaces	59.33	72.33	65.83	
	2DLDA	72.33	73.67	73	
	E2DLDA	60.33	73.67	67	
	B2DLDA	74	76.67	75.33	
	(2D) ² LDA	68.33	69.33	68.83	
	RB2DLDA	S = 3	74	85.67	79.83
		S = 4	73.33	85	79.17
AR	FisherFaces	68.6	68.6	68.6	
	2DLDA	81.54	83.75	82.64	
	E2DLDA	86.78	86.23	86.5	
	B2DLDA	79.89	79.89	79.89	
	(2D) ² LDA	76.31	77.41	76.86	
	RB2DLDA	S = 3	91.18	91.46	91.32
		S = 4	88.71	92.29	90.5

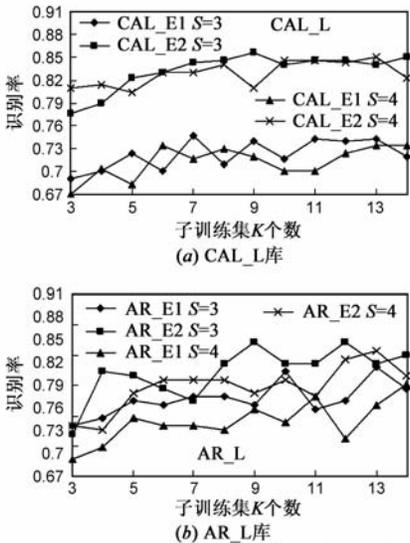


图 6 RB2DLDA 在光照变化下的识别率

光照变化下,2DLDA 和 E2DLDA 的互补性表现得更加明显.如 CAL_L1 子库上 2DLDA 的识别结果优于 E2DLDA,这是因为水平位置的单侧光照使得面部阴影产生较大变化,此时几乎所有的行信息都受到影响,但仍能保留半数的列信息,即利用垂直方向的判别信息的 2DLDA 算法能够保证足够的判别信息进行分类.在 2DLDA 和 E2DLDA 的互补性较为充分的情况下,RB2DLDA 算法能更好利用判别信息的互补性提高算法性能;相较而言, B2DLDA 的实验结果优于 (2D)2LDA,但是稳定性不强.

5.4 表情和光照变化

表 3 中为 CAL_E1、CAL_L2 和 AR_E1、AR_L1 上的平均识别结果:

表 3 不同算法在表情和光照变化下的识别率比较

识别率 (%)	算法	E	L	平均
CAL	FisherFaces	65	57	61
	2DLDA	87.33	70.33	78.33
	E2DLDA	90.67	67.67	79.17
	B2DLDA	90.67	76	83.33
	(2D) ² LDA	88.33	71.33	79.83
	RB2DLDA	S = 3	88.67	82
S = 4		91.33	79.67	85.5
AR	FisherFaces	59.78	75.21	67.49
	2DLDA	86.5	93.66	90.08
	E2DLDA	91.18	84.02	87.6
	B2DLDA	85.95	93.66	89.81
	(2D) ² LDA	84.57	93.11	88.84
	RB2DLDA	S = 3	93.94	96.69
S = 4		93.94	94.77	94.35

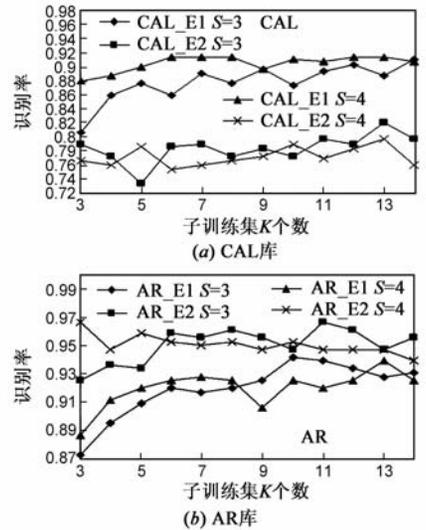


图 7 RB2DLDA 在表情和光照变化下的识别率

本部分的实验结果基本与前两次的实验结果相一致.可以从表 3 中的实验结果看出 RB2DLDA 算法在光照变化情况下能够比表情变化情况下大幅提高 2DLDA 和 E2DLDA 的识别效果,但是由于光照变化情况的识别难度较大,图 7 中的实验结果仍是表情变化情况下的识别率稍微高于光照变化情况下的识别率.总体而言,RB2DLDA 算法都表现出优于其他算法的识别性能和稳定性.

5.5 算法的总体识别情况比较

表 4 中可以看出,RB2DLDA 算法的识别率相较于 2DLDA 和 E2DLDA 算法均有不同程度的提高,与 B2DLDA、(2D)2LDA 相比能更充分利用信息互补性提高识别性能.

表 4 不同算法的识别率比较

识别率 (%)	算法	E	L	平均
CAL	FisherFaces	71.11	62.89	67
	2DLDA	93.11	72.11	82.61
	E2DLDA	94.78	67.22	81
	B2DLDA	93.44	75.55	84.5
	$(2D)^2LDA$	92.89	69.67	81.28
	RB2DLDA	$S = 3$	93.89	80.11
$S = 4$		94.89	79.33	87.11
AR	FisherFaces	60.88	70.80	65.84
	2DLDA	92.2	86.32	89.26
	E2DLDA	94.4	85.68	90.04
	B2DLDA	91.92	84.48	88.2
	$(2D)^2LDA$	91.92	82.28	87.1
	RB2DLDA	$S = 3$	95.78	92.65
$S = 4$		95.5	91.92	93.71

5.6 2DLDA 和 E2DLDA 的互补性

由表 5 中 AR 的平均实验结果可以看出, 2DLDA 和 E2DLDA 确实存在判别信息的互补性, 且使用 RB2DLDA 算法能够充分利用这种信息互补性明显提高了分类器的识别性能. 表 5 中还可以看出 RB2DLDA 算法的局限性, 即当两种算法均识别错误时, 无法利用这种互补信息提高识别结果.

表 5 2DLDA 和 E2DLDA 的互补性实验

错误率 (%)	2DLDA	E2DLDA	RB2DLDA
	10.06	20.96	5.92
2DLDA 错误 E2DLDA 正确	5.1		2.61
2DLDA 正确 E2DLDA 错误	16		
两者均识别错误	4.96		3.31

6 结论

2DLDA 主要利用图像垂直方向上的判别信息; E2DLDA 主要利用图像水平方向上的判别信息. 本文中通过理论证明这两个方向上的信息具有一定的一致性和互补性, 因此可通过融合两个方向上的判别信息提高识别性能. 本文中的 RB2DLDA 算法通过重采样融合这两个方向的判别信息, 实验证明具有更好的识别性能. 缺点是集成并不能提高 2DLDA 和 E2DLDA 算法本身的性能, 可以通过对 2DLDA 和 E2DLDA 算法进行改进达到改善局限性的目的.

参考文献

- [1] P N Belhumeur, J Hespánha, D J Kriegman. Eigenfaces vs. fisherfaces: recognition using class specific linear projection [J]. IEEE Pattern Analysis and Machine Intelligence, 1997, 19 (7): 711 – 720.
- [2] 尹洪涛, 付平, 沙学军. 基于 DCT 和线性判别分析的人脸

识别[J]. 电子学报, 2009, 37(10): 2211 – 2214.

- Yin Hongtao, Fu Ping, Sha Xuejun. Face recognition based on DCT and LDA[J]. Acta Electronica Sinica, 2009, 37(10): 2211 – 2214. (in Chinese)
- [3] 周杰, 卢春雨, 张长水, 李衍达. 人脸自动识别方法综述 [J]. 电子学报, 2000, 28(4): 102 – 106.
- Zhou Jie, Lu Chunyu, Zhang Changshui, Li Yanda. A survey of automatic human face recognition[J]. Acta Electronica Sinica, 2000, 28(4): 102 – 106. (in Chinese)
- [4] Rui Huang, Qingshan Liu, Hanqing Lu. Solving the small sample size problem of LDA[A]. International Conference on Pattern Recognition [C]. Quebec, Canada: IEEE Computer Society, 2002. 29 – 32.
- [5] Liu Jun, Chen Songcan, Zhihua Zhou. Single image subspace for face Recognition[A]. Analysis and Modeling of Faces and Gestures (AMFG'07) [C]. Rio de Janeiro, Brazil: Springer-Verlag Berlin, Heidelberg, 2007. 205 – 219.
- [6] Lu Xiaoguang, Anil K Jain. Resampling for face recognition [A]. Audio – and Video-based Biometric Person Authentication (AVBPA'03) [C]. Guilford, UK: Springer-Verlag Berlin, Heidelberg, 2003. 869 – 877.
- [7] Liu Jun, Chen Songcan. Resampling LDA/QR and PCA + LDA for face recognition [A]. Artificial Intelligence [C]. Sydney, Australia: Springer-Verlag New York Inc, 2005. 1221 – 1224.
- [8] Dao-qing Dai, Pong C. Yuen. Face recognition by regularized discriminant analysis [J]. Systems, Man, and Cybernetics part B-cybernetics, 2007, 37(4): 1080 – 1085.
- [9] Ye Jieping, Li Qi. A two-stage linear discriminant analysis via QR-decomposition [J]. Pattern Analysis and Machine Intelligence, 2005, 27(6): 929 – 941.
- [10] Li-fen Chen, Hong-yuan Mark Liao, Ming-Tat Ko. A new LDA-based face recognition system which can solve the small sample size problem[J]. Pattern Recognition, 2000, 33(10): 1713 – 1726.
- [11] Liu Jun, Chen Songcan. Discriminant common vecotors versus neighbourhood components analysis and laplacianfaces: A comparative study in small sample size problem [J]. Image and Vision Computing, 2006, 24(3): 249 – 262.
- [12] Wang Xiaogang, Tang Xiaou. Random sampling for subspace face recognition[J]. International Journal of Computer Vision, 2006, 70(1): 94 – 104.
- [13] Nitesh V Chawla, Kevin W Bowyer. Random subspaces and subsampling for 2-D face recognition [A]. Computer Vision and Pattern Recognition (CVPR'05) [C]. San Diego, USA: IEEE Computer Society, 2005. 582 – 589.
- [14] Wang Xiao-ming, Huang Chang, Fang Xiao-ying. 2DPCA vs. 2DLDA: face recognition using two-dimensional method [A]. Artificial Intelligence and Computational Intelligence [C]. Shanghai, China: Springer, 2009. 357 – 360.

- [15] Kong Hui, Wang Lei, Eam Khwang Teoh. A Framework of 2D Fisher Discriminant Analysis: Application to Face Recognition with Small Number of Training Samples[A]. Computer Vision and Pattern Recognition [C]. San Diego, CA, USA: IEEE Computer Society, 2005. 1083 – 1088.
- [16] S Nousath, G Hemantha Kumar, P Shivakumara. (2D) 2LDA: An efficient approach for face recognition[J]. Pattern Recognition, 2006, 39(7): 1369 – 1400.
- [17] Luo Dijun, Ding Chris, Huang Heng. Symmetric two dimensional linear discriminant analysis (2DLDA) [A]. Computer Vision and Pattern Recognition [C]. Miami, FL, USA: IEEE Computer Society, 2009. 2812 – 2819.
- [18] Wang Xiao-ming, Huang Chang, Liu Jin-gao. Gabor-2DLDA: face recognition using Gabor features and 2D linear discriminant analysis [A]. Computation Technology and Automation [C]. Changsha, China: IEEE Computer Society, 2009. 608 – 610.
- [19] Wei-shi Zheng, J H Lai, Stan Z Li. 1D-LDA vs. 2D-LDA: When is vector-based linear discriminant analysis better than matrix-based? [J]. Pattern Recognition, 2008, 41(7): 2156 – 2172.

- [20] A M Martinez, R Benavente. The AR Face Database[R]. New York, USA: CVC Technical Report, 1998.

作者简介



李文辉 男, 1961 出生, 吉林大学计算机科学与技术学院教授, 博士生导师. 研究方向: 计算机图形学, 数字图像处理, 计算机视觉, 虚拟现实.

E-mail: liwh@jlu.edu.cn



姜园媛 女, 1987 出生, 吉林大学计算机科学与技术学院硕士研究生. 研究方向: 数字图像处理, 计算机视觉.

E-mail: jiangyy0521@mails.jlu.edu.cn