

中图法分类号: TP391.7 文献标志码: A 文章编号: 1006-8961(2011)01-0059-07

论文索引信息: 王相海, 董钦科. 一种基于2D-PLDA和小波子带的虹膜识别算法[J]. 中国图象图形学报, 2011, 16(1):59-65

一种基于2D-PLDA和小波子带的虹膜识别算法

王相海^{1),2)}, 董钦科¹⁾

¹⁾(辽宁师范大学计算机与信息技术学院,大连 116029) ²⁾(南京大学计算机软件新技术国家重点实验室,南京 210093)

摘要:近年来,基于线性判别分析(LDA)的图像模式识别方法研究越来越受到人们的关注。然而LDA方法自身存在的小样本难题,极大的影响了样本集特征矩阵的获取。研究者随后提出的2维线性分析(2D-LDA)在一定程度上解决了这个问题。在传统2D-LDA基础上,提出一种改进的2维线性分析方法——2D-PLDA,该方法通过对样本集进行预分类,使得散布矩阵更加合理;在此基础上将2D-PLDA和离散小波相结合,应用于虹膜识别中。实验结果证明,该算法在识别精度和计算复杂度等方面均较传统LDA和2D-LDA方法有很大的改进,同时采用小波的不同子带作为输入空间也在一定程度上增加了算法的鲁棒性。

关键词:虹膜识别; 2D-LDA; 2D-PLDA; 小波子带; 特征矩阵

An kind of iris recognition algorithm based on 2D-PLDA and wavelet subband

Wang Xianghai^{1),2)}, Dong Qinke¹⁾

¹⁾(College of Computer and Information Technology, Liaoning Normal University, Dalian 116029 China)

²⁾(State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210093 China)

Abstract: In the last few years linear Discriminant Analysis (LDA) become more popular. But small sample size problem (SSSP) is always the biggest problem to perform it. In order to overcome this shortcoming, 2D-LDA is proposed. We improve 2D-PLDA by Pre-Clustering, which can make the distribution matrix precisely; then a new iris recognition arithmetic is proposed which is combined with 2D-PLDA and wavelet transform. In the experiment, preprocessing was performed at first, then we extract the feature vector from the known class sample by 2D-PLDA and wavelet. In the validation step, we use Euclidean distance and Hamming distance to find the K-nearest neighbor to decide which class the unknown sample belongs to. From the experiment result, we can conclude that, the proposed arithmetic can achieve higher recognition rate than traditional LDA and 2D-LDA, also the new arithmetic is simple in calculation. We use the different subbands as the input space of 2D-PLDA, so the robustness is enhanced.

Keywords: iris recognition; 2D-LDA; 2D-PLDA; wavelet subband; feature matrix

0 引言

与其他模式识别问题一样,特征提取也是虹膜识别中最为关键的一个环节。目前有关特征提取的

算法总体上可分为两类,即基于几何特征匹配的方法和基于统计学的方法。近年来,基于离散小波变换的特征提取方法作为几何特征匹配方法中比较有代表性的一种在虹膜识别方面取得了很好的效果^[1-2],根据图像特点选取适当的小波子带,直接或

收稿日期:2009-03-13;修回日期:2009-08-24

基金项目:辽宁省自然科学基金项目(20102123);辽宁百千万人才工程项目(2008921036);南京邮电学院图像处理与图像通信江苏省重点实验室开放基金项目(ZK207008)。

第一作者简介:王相海(1964—),男,辽宁师范大学计算机应用技术专业教授,苏州大学计算机应用技术专业博士生导师,CCF高级会员。主要研究领域为CG、CAGD、多媒体信息处理。E-mail: xhwang@lnnu.edu.cn。

进一步变换作为样本的特征向量,通常能够对样本进行有效的降维并获得有效的特征向量。在基于统计方法中,LDA (liner discriminant analysis)被应用于多种模式识别问题中^[3-4]。然而 LDA 在求解小样本问题(样本数量或样本集中的类别个数远小于样本维数)时,通常不能直接应用 Fisher 准则^[5]直接求解^[6-7],由此人们提出了 DLDA^[8]、PCA + LDA^[9-10]和 2D-LDA^[11-12]方法,都在一定程度上缓解了小样本问题对 LDA 相关算法的影响,并且一般情况下可以通过直接计算而获取较为精确的特征矩阵。不论是传统 LDA 还是各种改进的方法,都要求样本集每一类别内的样本分布应尽量集中,否则会給类内散布矩阵的求解带来较大的误差,从而影响特征矩阵的精度。

本文对 2D-LDA 进行基于样本集预分类的改进(2D-PLDA),在和离散小波结合后应用于虹膜图像识别中。实验中首先对原始虹膜图像进行预处理,得到归一化且纹理增强后的虹膜矩阵;然后对该矩阵进行 3 级离散小波变换,选取低频子带以及第 3 级小波系数的两个中频子带作为 2D-PLDA 的输入空间,并计算每个子带对应的特征矩阵;接下来把每个样本的 3 个子带分别向各自的特征矩阵投影得到特征向量,用所有已知类别样本特征向量形成样本集特征库。在未知样本的识别阶段,根据低频子带和中频子带特征向量的系数特点,分别采用欧氏距离和海明距离对未知类别样本的特征向量在特征库中进行多模板匹配,并根据 3 个子带的识别结果通过 K 近邻法则决定未知样本的模式类别。

1 LDA 和 2D-LDA

LDA 作为一个有效的降维和特征提取工具可以从高维空间中提取具有分类能力的低维特征,即经过 LDA 对样本降维后,同类别特征的分布更加密集,而不同类特征的分布则更加分散。

假设对于 C 个模式类别 $\{\omega_1, \omega_2, \dots, \omega_c\}$, ω_j 类的先验概率和均值分别为 P_j 和 μ_j ,以及 m 维列向量样本集 $X = \{x_1, x_2, \dots, x_m\}$,其中 $x_i \in \omega_j$,记 μ_0 为全体样本的均值,此时样本集类间散布矩阵 S_b 和类内散布矩阵 S_w 分别为

$$S_b = \sum_{j=1}^c P_j (\mu_j - \mu_0) (\mu_j - \mu_0)^T \quad (1)$$

$$S_w = \sum_{j=1}^c P_j S_j \quad (2)$$

式中 $S_j = E\{(x - \mu_j)(x - \mu_j)^T\}$ ($x \in \omega_j$) 是 ω_j 类的协方差矩阵, E 为数学期望。

为了使原始数据经过 LDA 投影降维后,在低维空间更加容易分类,当 S_w 非奇异时,我们希望确定投影方向 η ,使得在 η 方向上 S_b 和 S_w 行列式的比值最大,即确定

$$\arg_{\eta} \max \frac{|\eta^T S_b \eta|}{|\eta^T S_w \eta|} \quad (3)$$

由线性代数理论可知,上式 η 将满足

$$S_b \eta_i = \lambda_i S_w \eta_i \quad (4)$$

式中 λ_i 是 $S_w^{-1} S_b$ 的特征值,而 η_i 则是与之相对应的特征向量。

将 $S_w^{-1} S_b$ 的特征值由大到小排列 $\{\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m\}$,且 $\{\eta_1, \eta_2, \dots, \eta_m\}$ 为相对应的特征向量,此时 η_1 既为最佳的投影方向。考虑到算法的鲁棒性,我们选取所有正特征值 $\{\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d > 0\}$ 对应的特征向量组成样本集特征矩阵: $\eta = \{\eta_1, \eta_2, \dots, \eta_d\}$, X 中的样本可通过 $y = \eta^T x$ 向该特征矩阵投影从而得到样本的特征向量。

对于模式识别问题中的 $m \times n$ 维图像矩阵, LDA 特征提取算法需要预先把图像矩阵按列展成列向量,由定义可以看出,此时 S_w 和 S_b 的维数都会达到 $m \times n \times m \times n$,如此大的维数通常会造成计算上的困难;而且该方法在处理小样本问题^[6]时,通常无法通过 Fisher 准则直接得到样本集的投影向量。Li^[11]和 Yang^[12]分别提出的 2D-LDA 算法在一定程度上克服了 LDA 的这个弱点。

与 LDA 方法不同,2D-LDA 不需要预先将图像转换为 1 维向量,它采用了直接针对图像 2 维矩阵计算样本分布矩阵的方法,具体定义如下:

设模式类别为 $\{\omega_1, \omega_2, \dots, \omega_c\}$,样本集 $X = \{x_1, x_2, \dots, x_N\}$,其中 x_i 为 $m \times n$ 维矩阵并且 $x_i \in \omega_j, j \in [1, C]$ 。同样设 ω_j 类的先验概率和均值分别为 P_j 和 μ_j, μ_0 为全体样本的均值,则可定义样本集的 2D-LDA 类间分布矩阵和类内分布矩阵分别为

$$S_b = \sum_{j=1}^c P_j [(\mu_j - \mu_0)]^T [(\mu_j - \mu_0)] \quad (5)$$

$$S_w = \sum_{j=1}^c P_j \sum_{x_i \in \omega_j} [(x_i - \mu_j)]^T [(x_i - \mu_j)] \quad (6)$$

选取 $S_w^{-1} S_b$ 大于零的特征值 $\{\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d > 0\}$ 对应的特征向量组成样本集的特征矩阵 $\eta = \{\eta_1, \eta_2, \dots, \eta_d\}$,然后把 X 中的样本通过 $y = x\eta$ 向特征矩阵投影得到特征向量。

由于 2D-LDA 拥有更小的分布矩阵 ($n \times n$), 不仅运算复杂度进一步降低, 而且小样本问题对算法的影响在一度程度上被减小, 甚至在某些具体应用中可以被去除。

2 基于样本集预分类的 2 维线性分析 2D-PLDA

由式(2)(6)可以看出, 不论是 LDA 还是 2D-LDA, 如果某个样本集内存在个别样本分布与类别中其他样本距离较远, 容易造成样本集类内散布矩阵中关于该类别的信息不准确, 从而影响该类别未知样本的识别精度。由此本文在传统 2D-LDA 基础上提出一种新的基于样本集预分类的线性分析方法——2D-PLDA, 其基本思想如下:

在对 2 维图像样本集进行传统 2D-LDA 训练之前, 首先进行样本预分类处理, 挑选出某些聚合不够理想的类别进行拆分, 由此增加每个类别内样本分布的紧密性, 从而提高算法得到样本集特征矩阵的有效性。

为了确定被拆分的类别, 引入如下的类别“类内距离”函数^[13]:

$$D^2(\omega_i) = \frac{1}{n_i(n_i - 1)} \sum_{x_j \in \omega_i} d^2(x_j, \{\omega_i - x_j\}) \quad (7)$$

式中, $d^2(\cdot, \cdot)$ 表示两个列向量的欧氏距离, ω_i 表示样本中的一类, n_i 为 ω_i 类中样本的个数。

上述公式表示了某一类别中所有样本间欧氏距离的均值, 可以用来衡量每个类别中样本的聚合度; 其中某一类别的类内距离越大, 表明此类别的聚合度越低, 反之聚合度则越高。

假定样本集中类别数为 C , 分类后样本类别由 C 变为 C' , i 为拆分次数, θ_1 和 θ_2 分别为拆分过程中前后两次测试得到的识别率, 下面给出预分类的具体实现过程:

1) 首先设置 $C' = C, \theta_1 = 0, i = 1$; 计算所有类别的类内距离, 并根据其数值的大小对样本各类重新排序, 使各类符合 $D^2(\omega_1) \geq D^2(\omega_2) \geq \dots \geq D^2(\omega_c)$, 并选取 ω_1 为当前拆分类别;

2) 设当前类别下标为 j , 利用 K 均值聚类法^[5]把当前类别分成两个新的类别 ω_j 和 ω_{j+c} ;

3) 对拆分后获得的样本集进行 2D-LDA 特征提取, 并利用未知样本进行测试, 获得识别率, 记为 θ_2 ;

4) 比较 θ_1 和 θ_2 :

(1) 如果 $\theta_2 = \theta_1$, 则结束预分类;

(2) 如果 $\theta_2 < \theta_1$, 则取消此次分类并结束预分类;

(3) 如果 $\theta_2 > \theta_1$, 则置 $i = i + 1, \theta_1 = \theta_2, C' = C' + 1$; 继续选取第 ω_{j+1} 类别为当前拆分类别, 并转步骤 2)。

2D-PLDA 通过对样本集进行预分类可以把样本中原本聚合不够理想的类别进行有效的拆分, 使分类后类别中的每个样本更加紧密的聚合在类均值周围, 并且使得算法的两个分布矩阵更加精确, 从而获得更为精确的特征矩阵和特征向量。图 1 列举了被拆分的类别拆分前后类内距离的变化情况, 图中横坐标每组 3 个柱形代表一个类别拆分前后的样本集组, 第一个柱形为拆分前的类内距离, 后两个为拆分后新类别的类内距离。




图 1 被拆分样本预分类前后类内距离变化示意图

Fig. 1 Change of Inner-Class-Dis after Pre-Clustering

3 基于 2D-PLDA 和小波子带的虹膜识别算法

将 2D-PLDA 和小波变换进行融合, 利用小波变换的不同子带作为 2D-PLDA 的输入空间, 获取相应的特征向量, 然后根据不同子带的系数特点, 采用相应匹配方法进行未知类别样本的分类。

3.1 虹膜图像的预处理

通常采集到的眼部图像都会包含虹膜、瞳孔、睫毛在内的很多信息, 并且受到瞳孔收缩、光照不均等因素的影响, 图像特征不是很明显, 所以在进行特征

提取之前,要对虹膜图像进行预处理操作,以便得到显示清晰,范围准确的虹膜矩阵。通常情况下,虹膜图像的预处理可分为虹膜区域定位、归一化和纹理增强 3 个步骤^[14]。预处理首先要在图像进行虹膜区域定位,以便准确的找到眼部图像中的虹膜区域,采用 Canny 变换和改进的 Hough 变换^[14]相结合的算法得到虹膜圆心以及内外边缘的精确定位;对虹膜区域实现定位后,为了获得尺度不变的虹膜矩阵,还需要把环形的虹膜区域归一化到大小一定的矩阵中,从而更容易被程序处理,并且还能减小瞳孔弹性形变对虹膜产生的影响,把虹膜图像归一化为 60×360 矩阵;实际情况中,虹膜环形区域的外边缘通常容易受到眼睑和睫毛影响,内边缘也经常由于内边缘定位不够精确而受到瞳孔影响,故在归一化过程中去除靠近内外边缘的部分,只选取虹膜的中间部分进行归一化作为输出矩阵(大小为 48×360);最后对上述矩阵进行直方图均衡,以减少光照不均对图像质量产生的影响,图 2 给出了预处理过程的示意图。

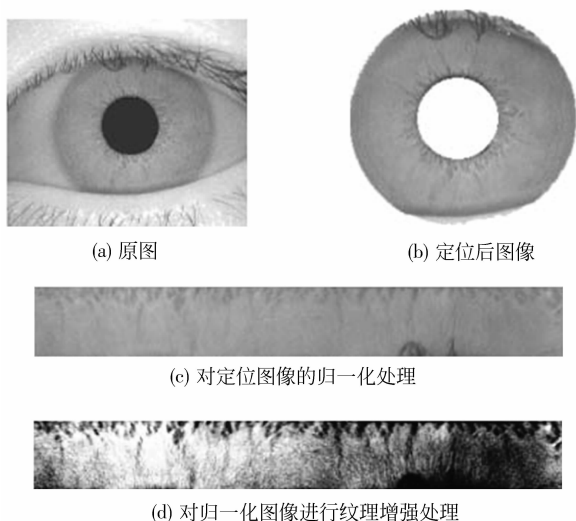


图 2 虹膜预处理示意图

Fig. 2 Iris preprocessing

3.2 基于小波和 2D-PLDA 的特征提取

对预处理后的虹膜图像首先进行 3 级小波变换(图 3),小波系数的低频子带是图像的近似表示,受噪声影响较小;而每个尺度上的两个中频子带分别代表了图像水平和垂直方向上的高频信息,故选取小波变换后的低频子带以及两个维数最低的中频子带-3 级中频子带作为 2D-PLDA 的输入空间进行特征提取以及特征匹配。




图 3 小波子带输入空间示意图(阴影区域)

Fig. 3 Input subbands of wavelet

具体特征提取算法如下:

- 1) 首先对图像矩阵进行 3 级小波变换;
- 2) 选取样本小波系数的低频子带(LL₃)以及两个 3 级中频子带(HL₃, LH₃)作为 2D-PLDA 的 3 个独立输入空间(X-LL₃, X-HL₃, X-LH₃);

- 3) 针对 X-LL₃、X-HL₃、X-LH₃ 分别进行 2D-PLDA 训练,得到 3 个输入空间的特征矩阵(η -LL₃, η -HL₃, η -LH₃);

- 4) 再把(X-LL₃, X-HL₃, X-LH₃)中的元素向对应的特征矩阵(η -LL₃, η -HL₃, η -LH₃)进行投影,这样通过每个原始样本便可以得到 3 个单独的特征向量。针对 3 个小波子带特征向量系数的特点(参见图 4)进行如下处理:

- (1) 由 X-LL₃ 获得的特征向量数值较大且比较分散(参见图 4(a)),该部分特征向量可直接作为最终的特征向量使用,记为 \mathbf{v}_L ,在识别阶段对 \mathbf{v}_L 采用欧氏距离计算不同样本间的距离;

- (2) 由 X-HL₃ 和 X-LH₃ 获得的特征向量数值较小,且分布较集中(参见图 4(b)),本文算法将这两组特征向量连接成一个向量,记为 \mathbf{v}_H ,再进行符号量化(参见式(8))作为特征使用,在识别阶段采用海明距离计算不同样本间的距离。

$$\begin{cases} \mathbf{v}_H[i] = 0 & \mathbf{v}_H[i] \leq 0 \\ \mathbf{v}_H[i] = 1 & \mathbf{v}_H[i] > 0 \end{cases} \quad (8)$$

3.3 输入空间小波子带特征匹配

在识别阶段,对于由低频子带 LL₃ 得到的特征向量,采用下式所示的欧氏距离进行匹配

$$ED_{AB} = \sqrt{(\mathbf{v}_L_A - \mathbf{v}_L_B)^T (\mathbf{v}_L_A - \mathbf{v}_L_B)} \quad (9)$$

式中 \mathbf{v}_L_A 和 \mathbf{v}_L_B 分别为 A, B 两个样本 LL₃ 空间的特征向量, ED_{AB} 为这两个特征向量的欧氏距离;

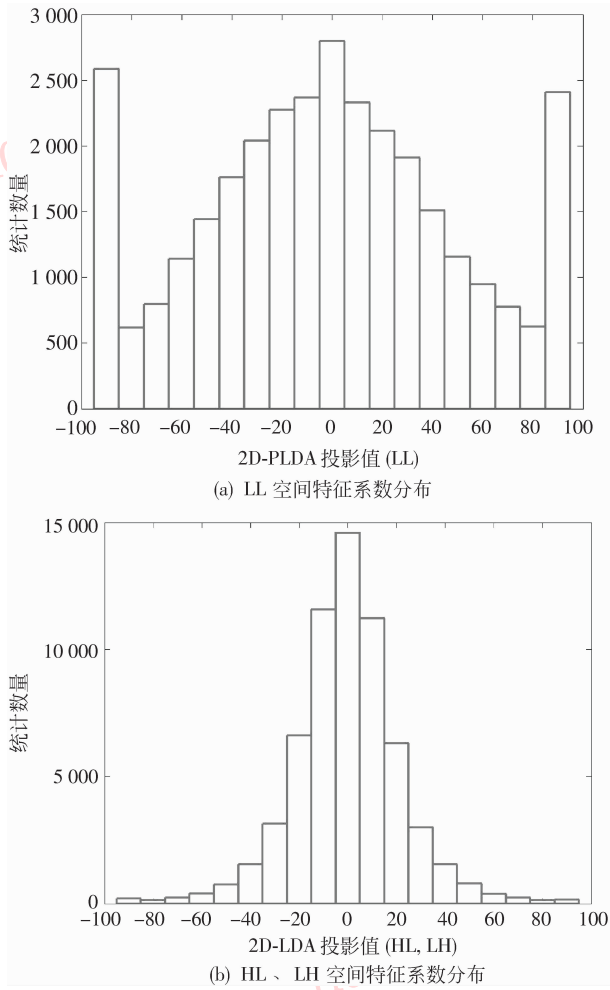


图 4 小波子带空间特征系数分布情况

Fig. 4 Distribution of value in every subband

而对于中频子带 HL_3 , LH_3 得到的特征向量采用下式所示的海明距离进行匹配

$$HD_{AB} = \frac{1}{2 \times n \times d} \sum_{i=1}^{2nd} \mathbf{v}_H[i]_A \oplus \mathbf{v}_H[i]_B \quad (10)$$

式中 $\mathbf{v}_H[i]_A$ 和 $\mathbf{v}_H[i]_B$ 分别为 A, B 两个样本 HL_3 和 LH_3 空间的特征向量; HD_{AB} 为二者的海明距离, n 为 2D-PLDA 输入矩阵的列数, d 为特征矩阵的列数, \oplus 为异或操作。

3.4 特征识别算法

提出的虹膜特征识别的总体过程如下:

1) 对于未知类别样本, 首先进行 3.1 节的预处理, 获得相应纹理增强的虹膜矩阵;

2) 对获得的纹理增强虹膜矩阵进行小波变换获得相应的小波子带, 进而利用 3.2 节提出的小波子带作为输入空间的 2D-PLDA 特征提取方法获得 \mathbf{v}_L 和 \mathbf{v}_H 特征向量;

3) 分别对 \mathbf{v}_L 和 \mathbf{v}_H 在样本特征库中进行相应的欧氏距离和海明距离匹配, 并采用如下 K ($K = 5$) 近邻法则获得识别结果:

(1) 在特征库中找出未知类别样本特征向量的 K 个欧氏距离 (\mathbf{v}_L) 近邻和海明距离 (\mathbf{v}_H) 近邻;

(2) 确定 K 个近邻中最多的特征向量类别, 将此类别作为由这个特征向量获得的识别结果。

4) 由实验中数据可知 (图 5), LL_3 空间得到的识别率最高, 识别能力较为稳定, HL_3 空间次之, 而 LH_3 空间最差, 所以对 3) 中由 \mathbf{v}_L 和 \mathbf{v}_H 所获得的识别结果进行如下判断处理:

(1) 如果二者的识别结果一致, 则将该识别结果作为最后的识别结果, 算法结束;


(2) 如果二者的识别结果不一致, 则继续把 \mathbf{v}_H 拆分为合并前的 \mathbf{v}_{HL} 和 \mathbf{v}_{LH} , 并分别计算这两个特征向量在样本特征库中的海明距离以及海明距离 K 近邻。接下来对 3 个识别结果继续进行如下判断: 如果 3 个识别结果中有两个是一致的, 则将此结果作为最后的识别结果; 否则选取由 LL_3 空间所获得的识别结果作为未知类别样本的模式类别。

4 实验结果及数据分析


实验中采用中国科学院自动化研究所提供的 CASIA^[15] 虹膜图像库进行测试。CASIA 包括 80 人, 108 只不同眼睛的虹膜图像样本, 每只眼睛有 7 幅 8 字节的灰度图像。我们选取图像数据库中的 40 个类别作为实验用样本。实验中每次选取各类中相同编号的一个样本作为考试样本, 其他作为训练样本。采用 Daubechies-4 小波对虹膜图像进行小波分解。

图 5 列举了每个输入空间的识别率以及 FR (错误拒绝) 曲线和 FA (错误接受) 曲线。


从图 5 可以看出, 3 个子带获得的最佳识别率存在着一定的差异, 其中由 LL_3 和 HL_3 可以得到较高的识别率, 这个结果也基本符合虹膜图像的特点, LL_3 作为虹膜图像的近似值, 保持了原始图像的大部分信息和特征, 因此可以得到比较理想的识别结果; HL_3 和 LH_3 子带则分别代表了虹膜矩阵水平和垂直方向上的高频信息, 本文算法对 3 个子带的实验结果要应用 K 邻法则, 这样 HL_3 和 LH_3 子带可以看做是 LL_3 空间的一对校验空间, 可以对 LL_3 空间的识别结果进行校正。另外从图 5 可以看出, 随着特征矩阵列数, 即 d 值的不断增加, 3 个子带识别率



(a) 识别率曲线



(b) FR曲线



(c) FA曲线

图 5 各小波子带作为输入空间的识别效果曲线

Fig. 5 Experiment result of every subband

的增长速度也不尽相同,并且达到最好识别效果所需最小的 d 值也不相同。实际应用中可根据 3 个子带不同的性能表现,选取不同的 d 值以获得更快的识别速度。

实验中本文同时用 LDA 对虹膜图像进行特征提取,并采用欧氏距离和 K 近邻法则进行未知类别样本的匹配和分类;用 2D-LDA + wavelet 对虹膜图像进行特征提取,并采用上文中 3.4 中办法进行未知样本的匹配和分类。把两个实验结果与本文所提出的算法在算法识别率和算法复杂度两方面进行比较,结果参见表 1。

表 1 本文算法和 LDA、2D-LDA + wavelet 算法性能比较

Tab. 1 Comparison between LDA, 2D-LDA + wavelet and proposed method

	LDA	2D-LDA	本文算法
正确率/%	91.2	95.1	99.1
FA/%	3.2	1.6	0
FR/%	5.6	3.3	0.9
散布矩阵维数	$m^2 \times n^2$	$n \times n/8$	$n \times n/8$

从表 1 可以看出,与传统的 LDA 和 2D-LDA 相比,经过改进的 2D-PLDA,在 2D-LDA 之前对样本集进行预分类,使同类样本的分布更加密集,从而提高了样本特征矩阵的准确性,在很大程度上提高了识别正确率;并且在和小波结合后,进一步降低了输入空间的维数,从而提高了识别速度,此外,提出算法的输入空间由一个变成了 3 个,通过高频子带空间来对低频子带空间的识别结果进行校正,从而大大提高了算法的鲁棒性。

5 结论

提出了一种基于样本集预分类的 2 维线性判别分析特征提取算法——2D-PLDA,并把 2D-PLDA 和小波结合,将虹膜图像小波分解的 LL_3 、 HL_3 和 LH_3 3 个子带作为 2D-PLDA 的输入空间,分别进行训练、特征提取和获得 3 个识别结果,最后利用由 HL_3 和 LH_3 所获得的识别结果对基于 LL_3 的识别进行校正,从而得到未知类别样本的模式类别。实验结果验证了提出算法的有效性,其识别准确率、运算时间和算法的鲁棒性均较传统 LDA 和 2D-LDA 有了一定的改善。

参考文献 (References)

- [1] Shinyoung L, Kwanyong L, Okhwan B, et al. Efficient iris recognition through improvement of feature vector and classifier [J]. ETRI Journal, 2001, 23(2):61-70.

- [2] Ming Xing, Liu Yuanning, Zhu Xiaodong, et al. Iris recognition based on wavelet transform with shift invariance preprocessing [J]. Journal of Computer Research and Development, 2006, 43(7):1186-1193. [明星,刘元宁,朱晓冬,等.基于平移不变预处理的小波变换的识别算法[J].计算机研究与发展,2006,43(7):1186-1193.]
- [3] Turk M, Pentland A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1):71-86.
- [4] Belhumeur P N, Jhespanha J P, Kriegman D J. Eigenfaces vs fisherfaces: recognition using class specific linear projection[J]. IEEE Trans. Pattern Anal. Machine Intell., 1997, 19(7): 711-720.
- [5] Bian Zhaoqi, Zhang Xuegong. Pattern Recognition[M]. Beijing: Tsinghua University Press, 2000. [边肇祺,张学工.模式识别[M].北京:清华大学出版社,2000.]
- [6] Swets D L, Weng J. Using discriminant eigenfeatures for image retrieval[J]. IEEE Trans. Pattern Anal. Machine Intell., 1996, 18(8):831-836.
- [7] Huang Rui, Shan qing, Lu Hanqing, et al. Solving the small sample size problem of LDA [C]// Proceedings of the 16th International Conference on Pattern Recognition (ICPR'02). Washington, DC, USA; IEEE Computer Society, 2002:29-32.
- [8] Yu H, Yang J. A direct LDA algorithm for high-dimensional data with application to face recognition [J]. Pattern Recognition, 2001, 34(10):2067-2070.
- [9] Yang Jian, Wang Jingyu. Why can LDA be performed in PCA transformed space? [J]. Pattern Recognition, 2003, 36(2): 563-566.
- [10] Zheng Yujie, Yang Jingyu, Xu Yong, et al. A new feature extraction method based on fisher discriminant minimal criterion [J]. Journal of Computer Research and Development, 2006, 43(7):1201-1206. [郑宇杰,杨静宇,徐勇,等.一种基于Fisher鉴别极小准则的特征提取方法[J].计算机研究与发展,2006,43(7):1201-1206.]
- [11] Li Ming, Yuan Baozhong. 2D-LDA: A statistical linear discriminant analysis for image matrix [J]. Pattern Recognition Letters, 2005, 26: 527-532.
- [12] Yang J, Zhang D, Xu Y, et al. Two dimensional discriminant transform for face recognition [J]. Pattern Recognition, 2005, 38(1): 1125-1129.
- [13] Maulik U, Bandyopadhyay S. Performance evaluation of some clustering algorithms and validity indices [J]. IEEE Trans. Pattern Anal. Machine Intell. Machine Intell, 2002, 24(12):1650-1654.
- [14] Daugman J G. High confidence visual recognition of persons by a test of statistical independence [J]. IEEE Trans. on Pattern Analysis and Machine Intelligence. 1993, 15(11): 1148-1161.
- [15] Institute of Automation, Chinese Academy of Sciences. CASIA Iris Image Database [OL], 2004. <http://www.cbsr.ia.ac.cn/Database.htm>.