

基于类矩阵和特征融合的加权自适应人脸识别

杨欣^{1,2)} 费树岷²⁾ 陈丽娟²⁾

¹⁾(南京航空航天大学自动化学院,南京 210016) ²⁾(东南大学自动化学院,南京 210096)

摘要 为了准确快速地进行人脸识别,提出了一种基于类矩阵和特征融合的加权自适应人脸识别算法,该算法首先,提取人脸的全局特征和6个关键部分的局部特征,同时给出了局部特征权值的动态选择方法,由于该法可以根据不同的训练集得出不同的权值,因而增强了算法的自适应能力;然后将全局和局部特征加权融合来得出样本的特征矩阵;接着设计出了一种加权PCA方法用于对样本矩阵进行降维;再进一步提出类矩阵的概念,同时给出并证明了类矩阵的推导公式,并据此得出一种新的投影准则;最后,将类矩阵和试验样本分别进行投影,并根据其欧氏距离的大小得出试验人脸的最终类别。试验表明,该算法不仅计算速度快、识别率高,而且能有效解决LDA小样本空间问题,应用前景良好。

关键词 人脸识别 特征提取 Gabor小波 主元分析 线性判别分析 类矩阵

中图分类号:TP391 文献标识码:A 文章编号:1006-8961(2008)05-0930-07

Weighted Adaptive Face Recognition Based on Class Matrix and Feature Fusion

YANG Xin^{1),2)}, FEI Shu-min²⁾, CHEN Li-juan²⁾

¹⁾(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016)

²⁾(School of Automation, Southeast University, Nanjing 210096)

Abstract A new weighted adaptive algorithm of face recognition based on class matrix and feature fusion was proposed. Firstly, global features and local features of six key parts of faces were extracted respectively. Dynamic method of how to choose the weights of local features was given. Different weights could be gained for different training sets according to this method. So, the adaptive ability of algorithm was enhanced. Then, global and local features were fused with weights to get the eigen-matrix of samples. Secondly, a new weighted principal component analysis (PCA) method was designed to lower dimension for sample matrixes. Thirdly, the concept of class matrix was proposed, and formula of how to obtain the class matrix was given and proved. According to class matrix, a new projected rule was given. Finally, class matrix and tested samples were projected respectively through the proposed rules. Then, the final class that tested faces belonged to was declared according to the Euclidean distance. Experiments show that the proposed algorithm can deal with small sample problems in LDA effectively, and the results also indicate that it has good performance on speed and recognition rate.

Keywords face recognition, feature extraction, Gabor wavelet, principal component analysis (PCA), linear discriminant analysis (LDA), class matrix

1 引言

人脸识别是当前模式识别和人工智能领域的研究热点,研究者们已经提出了很多用于人脸识别的方

法^[1],其中Turk和Pentland利用重构权向量作为识别用的特征,提出了“特征脸”识别技术^[2],从而人脸识别领域迎来了“基于表征”(appearance based)的子空间分析方法的研究热潮。其中比较有代表性的有主成分分析(PCA)^[2]、线性判别分析(LDA)^[3]、独立

成分分析(ICA)^[4]、Bayesian 方法^[5]、基于核技术的 Kernel PCA^[6]、Kernel LDA^[7] 等等。以上算法都有一个共同特点,即在进行特征提取时,只重视人脸的总体特征,而忽略了眼睛等作为人脸局部的存在。事实上,人脸关键部位的局部特征也是重要的鉴别特征。当然,由于人脸的各部位作为鉴别特征的重要性程度是不同的,因此,它们在人脸识别中能起到的作用也不同。在此之前,Kalocsai 等人用统计的方法比较了正面人脸不同的 48 个特征点在描述整个人脸模式中所起的作用,并据此赋予它们不同的权值^[8]。Pentland 等人则将“特征脸”技术用于人脸各局部器官,首先产生“特征眼”、“特征鼻”、“特征嘴”的概念^[9],并通过融合各“特征器官”以达到人脸识别的目的。由于这些方法在赋予各局部特征权值的时候,并没有针对特定的训练集进行优化,而是采用一种笼统的加权策略,其权值是不会因为训练集的不同而改变的,因此,没有自适应能力无疑会对识别结果产生消极的影响。

本文正是在以上背景下提出了一种基于类矩阵的融合全局和局部特征的人脸识别算法。该法首先将全局和局部特征进行加权融合,给出了局部特征权值的动态选择方法,由于该法可以根据不同的训

练集得出不同的权值,从而增强了算法的自适应能力;同时,本文还提出了样本特征矩阵的概念,并定义了所谓的类矩阵且给出证明,据此提出了一种新的投影准则,并给出了详细的识别算法,该算法不仅解决了 LDA 的小样本问题,而且训练时间短、速度较快。

2 样本特征矩阵

2.1 全局与局部特征提取

本文算法不仅提取了全局特征,还首先提取了 6 个关键局部特征,然后将它们组合成样本特征矩阵。这里所谓的全局特征,是指把人脸作为一个整体来提取特征,而局部特征则指的是正面人脸中左眉、右眉、左眼、右眼、鼻、嘴共 6 个子区域,它们包含了一个人面部的主要信息^[10]。局部区域的切割需依赖于人脸特征点的准确定位,这是一项极其重要也比较困难的任务。由于本文重点在于研究识别算法,因此假定一些关键的特征点(如眉角、眼角等)已通过前端的检测模块准确定位。这样,通过适当的归一化处理就可以得到 6 个训练样本集(如图 1 所示)。

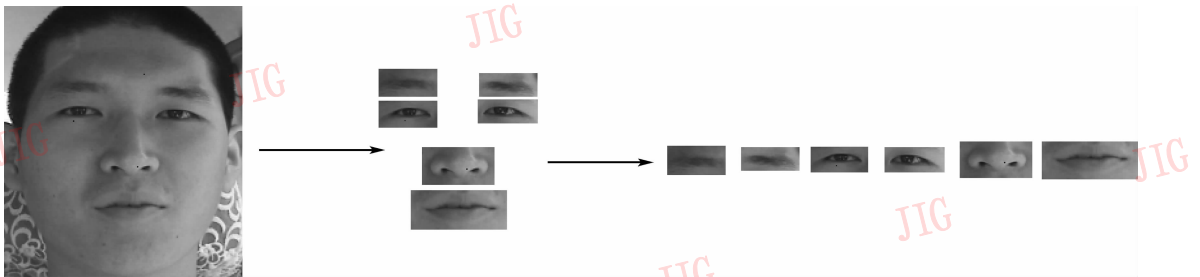


图 1 人脸 6 个关键局部特征的分割
Fig. 1 Partitions of six key local features

对训练集人脸进行 2 维小波变换时,首先分解成低频平滑、水平细节、垂直细节和对角线细节 4 部分,这样就可以组成 4 个样本空间,再用 PCA 分别提取出与这 4 个部分的 k_1, k_2, k_3, k_4 个最大的特征值对应的“特征脸”,以组成 4 个规范正交的变换阵 \mathbf{P} ;然后将每一个样本用 \mathbf{P} 进行变换,就得到每一个样本在对应小波子空间上的特征向量,分别为 $\mathbf{x}_1 = (x_{1,1}, \dots, x_{1,t_1})^T, \mathbf{x}_2 = (x_{2,1}, \dots, x_{2,t_2})^T, \mathbf{x}_3 = (x_{3,1}, \dots, x_{3,t_3})^T, \mathbf{x}_4 = (x_{4,1}, \dots, x_{4,t_4})^T$;最后将这 4 个向量合并为向量 \mathbf{X} ,即 $\mathbf{x} = (\mathbf{x}_1^T, \mathbf{x}_2^T, \mathbf{x}_3^T, \mathbf{x}_4^T)^T = (x_1, \dots, x_t)^T$,这里, $t = t_1 + t_2 + t_3 + t_4$ 。由上面分析可知, \mathbf{X} 即为样本的全局特征向量,它包含了人脸

在 4 个小波子空间的主要特征,其特点是维数较高。对于局部特征,可用一种基于 Gabor 小波变换的方法来提取,但和通常 Gabor 小波提取特征的方法不同,该方法对每一个局部提取特征的维数较少,这是因为对于每一个局部特征,它在识别过程中的相对重要性比起全局特征来说要低很多,所以维数不必过大。同时,低维空间能有效减少计算量。

如果对图像 $I(x, y)$ 进行 Gabor 小波变换,则可得: $k(x, y) = k_c(x, y) + ik_s(x, y)$,令 ω 为中心频率, θ 为相位角,那么图像 $I(x, y)$ 的 Gabor 滤波器响应的实部和虚部的平均值分别为

$$M_C(\omega, \theta) = \sum_x \sum_y k_c(x, y, \omega, \theta) / (H \cdot W) \quad (1)$$

$$M_S(\omega, \theta) = \sum_x \sum_y k_s(x, y, \omega, \theta) / (H \cdot W) \quad (2)$$

其中, H, W 分别为 2 维图像序列的高度和宽度

同样, 滤波器响应的实部和虚部的标准差分别为

$$SD_C(\omega, \theta) = \sqrt{\sum_x \sum_y [k_c(x, y, \omega, \theta) - M_C(\omega, \theta)]^2 / (H \cdot W - 1)} \quad (3)$$

$$SD_S(\omega, \theta) = \sqrt{\sum_x \sum_y [k_s(x, y, \omega, \theta) - M_S(\omega, \theta)]^2 / (H \cdot W - 1)} \quad (4)$$

如果选取 3 个不同的 ω 和 6 个不同的 θ , 则可得到如下向量 V , 可令其为人脸局部特征向量。

$$V = [M_C(\omega_1, \theta_1), \dots, M_C(\omega_3, \theta_6), M_S(\omega_1, \theta_1), \dots, M_S(\omega_3, \theta_6), SD_C(\omega_1, \theta_1), \dots, SD_C(\omega_3, \theta_6), SD_S(\omega_1, \theta_1), \dots, SD_S(\omega_3, \theta_6)] \quad (5)$$

用 Gabor 小波分解分别提取分割后人脸的 6 个关键局部特征, 就可得 6 个特征向量 V_1, V_2, \dots, V_6 , 每一个特征向量为 $3 \times 6 \times 4 = 72$ 维。

2.2 样本特征矩阵

与通常人脸识别中的样本特征向量不同, 本文算法根据得到的 7 个全局和局部特征向量, 用以下方法得出每个样本的特征矩阵为

$$F_{m,i} = \begin{bmatrix} X_{m,i} & 0 & \dots & 0 \\ 0 & q(1) * V_{m,i}(1) & 0 & 0 \\ \vdots & 0 & \ddots & \vdots \\ 0 & 0 & \dots & q(6) * V_{m,i}(6) \end{bmatrix} \quad (6)$$

其中, $F_{m,i}$ 指第 i 类中的第 m 个样本的特征矩阵, $X_{m,i}$ 指第 i 类中的第 m 个样本的全局特征向量, $V_{m,i}(n)$ 指在第 n 个关键局部中第 i 类的第 m 个样本的局部特征向量, $q(n)$ 是指局部特征向量 $V_{m,i}(n)$ 在人脸识别中的重要性权值。

本文引入了人脸识别中的全局和局部特征权值, 对于识别率较高的特征, 其特征向量的权值较大。全局是由局部组成, 所以权值最高, 本文设为 1。而局部特征的权值相对较低。本文用 Fisherface 算法得出每类样本结合在一起的紧密程度, 并以此

来得到权值的大小, 该方法可根据不同的训练集得出权值, 并具有一定的自适应能力, 举例如下:

(1) 设人脸训练集中类的个数为 C , 每一类中人脸的个数为 N , d 维列向量 $X_{m,i}$ 表示第 i 类中的第 m 个样本, 则训练集中共有 $M = N \times C$ 个样本。用这些样本向量减去平均脸, 则得到每一幅人脸与平均脸的差值;

(2) 这些差值构成协方差矩阵, 先求出此矩阵的前 K 个最大特征值的特征向量, 然后把这此向量再组合起来构成一个 PCA 投影矩阵, 设为 W_{PCA} ;

(3) 用这个 PCA 投影矩阵把所有的训练样本投影到一个 K 维的子空间;

(4) 把上面得出的最佳描述特征, 分别构成类内散布矩阵 S_W 和类间散布矩阵 S_B , 并计算矩阵 $S_W^{-1} S_B$ 的前 t 个最大特征值的特征向量, 再由这些向量构成一个 LDA 投影矩阵, 设为 W_{LDA} ;

(5) 设训练样本中的 6 个关键的局部特征向量 $V_{m,i}(1), \dots, V_{m,i}(6)$ 的维数分别为 m_1, \dots, m_6 , 其中 $i = 1, \dots, C$ 表示人脸类别, $m = 1, \dots, N$ 表示每类中的样本数。将局部特征向量分别减去其平均向量, 分别为 $S_{m,i}(1), \dots, S_{m,i}(6)$, 并把它们分别作两次投影变换, 则分别可得出分类特征 $\eta_{i,m}(n) = W_{LDA}^T W_{PCA}^T S_{i,m}(n)$, 其中 $i = 1, \dots, C, m = 1, \dots, N, n = 1, \dots, 6$ 。

(6) 求出 6 个关键局部的所有样本类内距离的平均值 $L_W(1), \dots, L_W(6)$ 分别为

$$L_W(n) = \frac{\sum_{i,j,k} \|\eta_{j,i}(n) - \eta_{k,i}(n)\|}{C \times C_N^2} \quad (7)$$

$1 \leq k < j \leq N; n = 1, \dots, 6$

(7) 求出 6 个关键局部中所有样本的类间距离的平均值 $L_B(1), \dots, L_B(6)$, 即

$$L_B(n) = \frac{\sum_{u,v,j,k} \|\eta_{u,j}(n) - \eta_{v,k}(n)\|}{N^2 \cdot C_C^2} \quad (8)$$

这里, $1 \leq k < j \leq C, u, v \in [1, N], n = 1, \dots, 6$

(8) 求出 $L(n) = L_B(n) / L_W(n), n = 1, \dots, 6$, 易知, $L(n)$ 越大, 权值越高。

(9) 设局部特征的权值为 $q(n)$, 这里 $n = 1, \dots, 6$ 。根据上面论述, 可得权值公式如下:

$$q(n) = L(n) / G(n), G(n) = \sum_n L(n) \quad (9)$$

以上方法首先得出了全局样本的最佳投影方向, 并首先分别将关键局部样本投影到此方向, 然后

计算出样本的类间距离平均值与类内距离平均值的比值,再以此来决定不同局部的权值大小,正如式(9)所示,比值 $L(n)$ 越大,说明其可识别性越大,所以重要性权值就越大。

3 基于加权 PCA 的特征矩阵降维

本节将对样本特征矩阵进行降维,由于经典的 PCA 针对的是样本的特征向量,因此,本文针对样本特征矩阵,提出了一种新的加权 PCA 算法,从而拓展了 PCA 算法的使用范围。

令 $\mathbf{K}_{m,i}(n) = q(n) \cdot \mathbf{V}_{m,i}(n)$ 为第 n 个局部的特征向量,这里 $n = 1, \dots, 6$ 。降维时,首先求出全局样本向量 $\mathbf{X}_{m,i}$ 、6 个关键局部样本向量 $\mathbf{K}_{m,i}(n)$ ($n = 1, \dots, 6$) 和其相对应的样本向量平均值的差值,然后分别求出它们的协方差矩阵,设为 $\Sigma, \Sigma(1), \dots, \Sigma(6)$,由它们组成的矩阵 \mathbf{A} 如下:

$$\mathbf{A} = \begin{bmatrix} \Sigma & 0 & 0 & 0 \\ 0 & \Sigma(1) & \cdots & 0 \\ 0 & \vdots & \ddots & 0 \\ 0 & 0 & 0 & \Sigma(6) \end{bmatrix} \quad (10)$$

PCA 特征矩阵降维时可根据经典的 PCA 算法,先求出矩阵 \mathbf{A} 的前 k 个最大特征值的特征向量,然后把这些向量再组合起来构成一个投影矩阵,不妨称之为加权 PCA 投影矩阵,设为 \mathbf{W}_{WPCA} 。这样,样本就可以根据 \mathbf{W}_{WPCA} 进行投影,以实现降维。

定理 1 一个形如式(10)的矩阵,其特征值分别为其对角线上子矩阵的特征值的集合。

由定理 1 可知,矩阵 \mathbf{A} 的特征值,即为全局样本和局部样本的协方差矩阵 $\Sigma, \Sigma(1), \dots, \Sigma(6)$ 的特征值的集合。

定理 2 一个形如式(10)所示的矩阵,其中 $\Sigma, \Sigma(1), \dots, \Sigma(6)$ 为 \mathbf{A} 的子矩阵, Σ 为 n 维方阵, $\Sigma(1), \dots, \Sigma(6)$ 分别为 m_1, \dots, m_6 维方阵,如果 ξ 是 \mathbf{X}

的特征向量,那么 $(\xi^T, \underbrace{0, \dots, 0}_{m_1 + \dots + m_6 \uparrow 0})^T$ 就为 \mathbf{A} 的特征向量,如果 ξ 是 $\Sigma(1)$ 的特征向量,那么 $(0, \dots, 0, \underbrace{\xi^T}_{n \uparrow 0}, \underbrace{0, \dots, 0}_{m_2 + \dots + m_6 \uparrow 0})^T$ 就为 \mathbf{A} 的特征向量,依次类推。

根据矩阵特征分析原理,定理 1、2 很容易得到证明。由定理 1 和 2 可得,若知道式(10)的子矩阵的特征值和特征向量,就很容易得到矩阵 \mathbf{A} 的特征值和特征向量,特征值不变,而特征向量则在子矩阵

的特征向量上前后补零,增加到与矩阵 \mathbf{A} 相同的维数即可。而且矩阵 \mathbf{A} 前 k 个最大特征值即是它的全局和局部特征的前 k 个最大特征值。这既符合经典 PCA 原理,又可保证全局和局部原有特征信息不变。这样就能更好地提取全局和局部最有用的信息,用来进行识别。

加权 PCA 算法步骤总结如下:

(1) 分别求出全局样本向量 $\mathbf{X}_{m,i}$ 、6 个关键局部样本向量 $\mathbf{K}_{m,j}(n)$ ($n = 1, \dots, 6$) 和相对应的样本向量平均值的差值,然后求出它们的协方差矩阵,设为 $\Sigma, \Sigma(n)$ ($n = 1, \dots, 6$)。再根据式(10)得出矩阵 \mathbf{A} ;

(2) 先求出矩阵 \mathbf{A} 的前 d 个最大特征值的特征向量,然后把这些向量再组合起来构成一个 PCA 投影矩阵,设为 \mathbf{W}_{WPCA} ,这里 \mathbf{W}_{WPCA} 是一个 $(n + m_1 + m_2 + \dots + m_6) \times d$ 大小的矩阵;

(3) 根据式(6)即可得出所有训练样本和试验样本的特征矩阵 $\mathbf{F}_{m,i}$;

(4) 用 PCA 投影矩阵把所有的训练样本投影到一个 d 维的子空间,即

$$\mathbf{b}_{m,i} = \mathbf{W}_{\text{WPCA}}^T \cdot \mathbf{F}_{m,i}$$

这里, $\mathbf{b}_{m,i}$ 是一个 $d \times 7$ 大小的矩阵;

4 基于类矩阵的人脸识别

设人脸训练集中共有 C 类不同的人脸,即训练集中类的个数为 C ,每一类中人脸的个数为 N , $\mathbf{b}_{m,i}$ 表示第 i 类中的第 m 个样本的特征矩阵,由上节可以看出,由于 $\mathbf{b}_{m,i}$ 是一个 $d \times 7$ 大小的矩阵,因此,训练集中共有 $M = N \cdot C$ 个样本。假设 $d > M - C$,则类内散布矩阵 \mathbf{S}_W 和类间散布矩阵 \mathbf{S}_B 分别定义为

$$\mathbf{S}_W = \sum_{i=1}^C \sum_{m=1}^N (\mathbf{b}_{m,i} - \boldsymbol{\mu}_i)(\mathbf{b}_{m,i} - \boldsymbol{\mu}_i)^T,$$

$$\mathbf{S}_B = \sum_{i=1}^C N(\boldsymbol{\mu}_i - \boldsymbol{\mu})(\boldsymbol{\mu}_i - \boldsymbol{\mu})^T,$$

这里, $\boldsymbol{\mu}$ 是所有样本的均值, $\boldsymbol{\mu}_i$ 是第 i 类样本的均值。为了在 \mathbf{S}_W 的零空间上找到最优投影向量 \mathbf{w}^{best} ,可以把人脸样本投影到 \mathbf{S}_W 的零空间上。然而,由于 \mathbf{S}_W 零空间的维数非常大,因此这种方法的计算量非常大。一个有效的方法是利用 \mathbf{S}_W 零空间的正交补空间,这个空间是一个相对低维的空间。

令 \mathbf{R}^d 是样本空间, \mathbf{V} 是 \mathbf{S}_W 的列空间, \mathbf{V}^\perp 是 \mathbf{S}_W 的零空间,即 $\mathbf{V} = \text{span} \{ \boldsymbol{\alpha}_k \mid \mathbf{S}_W \boldsymbol{\alpha}_k \neq 0, k = 1, \dots, r \}$,

$V^\perp = \text{span}\{\alpha_k | S_w \alpha_k = 0, k = r+1, \dots, d\}$ 。这里 $r < d$ 是 S_w 的秩, $(\alpha_1, \dots, \alpha_d)$ 是一个标准正交向量集, $(\alpha_1, \dots, \alpha_r)$ 是相对于 S_w 的非零特征值的特征向量。考虑矩阵 $Q = [\alpha_1, \dots, \alpha_r], \hat{Q} = [\alpha_{r+1}, \dots, \alpha_d]$, 因为 $\mathbf{R}^d = V \oplus V^\perp$, 每一个人脸向量 $x_{m,i} \in \mathbf{R}^d$ 有唯一的如下分解: $b_{m,i} = y_{m,i} + z_{m,i}$, 这里由于 $y_{m,i} = P b_{m,i} = Q Q^T b_{m,i} \in V, z_{m,i} = \hat{P} b_{m,i} = \hat{Q} \hat{Q}^T b_{m,i} \in V^\perp, P$ 和 \hat{P} 是 V 和 V^\perp 上的正交投影算子, 因此,

$$z_{m,i} = b_{m,i} - y_{m,i} = b_{m,i} - P b_{m,i} \quad (11)$$

令:

$$B_i^{\text{class}} = z_{m,i} = b_{m,i} - Q Q^T b_{m,i} = Q Q^T b_{m,i} \quad (12)$$

这里, $m = 1, \dots, N, i = 1, \dots, C$

定义上述 B_i^{class} 为类矩阵 (class matrix), 它只和类有关, 而和每一类中的样本无关, 即每一类的类矩阵 B_i^{class} 只有一个, 而和每类中的样本序号无关。

定理 3 设 \hat{Q} 为 Q 的投影后矩阵, 其列向量为组成 S_w 零空间 V^\perp 的标准正交向量, 那么在第 i 类中的样本 $b_{m,i}$ 在 V^\perp 上的投影产生唯一的一个投影 B_i^{class} , 即 $B_i^{\text{class}} = \hat{Q} \hat{Q}^T b_{m,i}, m = 1, \dots, N, i = 1, \dots, C$ 。

证明: 根据定义, 如果向量 $\alpha_k (k = r+1, \dots, d)$ 满足 $S_w \alpha_k = 0$, 那么 α_k 就在 V^\perp 中。令 μ_i 为 i 类中的平均矩阵, 令 $B_i = (b_{i,1}, \dots, b_{i,N})$, 因为 $b_{m,i}$ 为 $d \times 7$ 大小的矩阵, 易知, B_i 为 $d \times 7N$ 大小的矩阵, 令

$$G = \frac{1}{N} \begin{bmatrix} A_{1,1} & A_{1,2} & \dots & A_{1,N} \\ A_{2,1} & A_{2,2} & \dots & A_{2,N} \\ \vdots & \vdots & \ddots & \vdots \\ A_{N,1} & A_{N,2} & \dots & A_{N,N} \end{bmatrix}$$

其为 $7N \times 7N$ 大小的矩阵, 其元素 $A_{i,j}$ 均为 7×7 大小的单位矩阵, 这样, 根据 S_w 的定义, 令

$$S_w = \sum_{i=1}^C S_i \quad (13)$$

根据矩阵代数可得

$$\begin{aligned} S_i &= \sum_{m=1}^N (b_{m,i} - \mu_i)(b_{m,i} - \mu_i)^T \\ &= (B_i - B_i G)(B_i - B_i G)^T \end{aligned} \quad (14)$$

将式(13)两边同时左乘 α_k^T , 右乘 α_k 得

$$\begin{aligned} &\sum_{i=1}^C \alpha_k^T B_i (I - G)(I - G)^T B_i^T \alpha_k \\ &= \sum_{i=1}^C \|(I - G)^T B_i^T \alpha_k\|^2 = 0 \end{aligned} \quad (15)$$

这里 $\|\cdot\|$ 表示欧几里德范式, 由于由式(15)可得 $B_i^T \alpha_k = G B_i^T \alpha_k$, 因此, 根据定义

$$b_{m,i}^T \alpha_k = \mu_i^T \alpha_k, i = 1, \dots, C; k = r+1, \dots, d \quad (16)$$

可得

$$\begin{aligned} B_i^{\text{class}} &= \overline{Q} \overline{Q}^T b_{m,i} = \left(\sum_{k=r+1}^d \alpha_k \alpha_k^T \right) B_{m,i} \\ &= \sum_{k=r+1}^d \alpha_k \alpha_k^T b_{m,i} = \sum_{k=r+1}^d \alpha_k \alpha_k^T \mu_i \end{aligned} \quad (17)$$

上式说明, B_i^{class} 和各类中的样本数无关, 只和类有关, 原命题得证。

上述定理表明, 每一类样本可以得出一个类特征矩阵, 这样, 在进行人脸识别过程中, 就可以大大减少计算复杂度。根据每一类的类矩阵, 可以通过准则(式(18))来计算最优投影方向, 即

$$\begin{aligned} J(W_{\text{opt}}) &= \arg \max_{|W^T S_w W| = 0} |W^T S_B W| \\ &= \arg \max_{|W^T S_w W| = 0} |W^T S^T W| \\ &= \arg \max_W |W^T S_{\text{class}} W| \end{aligned} \quad (18)$$

这里,

$$\begin{aligned} S_{\text{class}} &= \sum_{i=1}^C (B_i^{\text{class}} - \mu_{\text{class}})(B_i^{\text{class}} - \mu_{\text{class}})^T \\ \mu_{\text{class}} &= \frac{1}{C} \sum_{i=1}^C B_i^{\text{class}} \quad i = 1, \dots, C \end{aligned}$$

S_{class} 是类矩阵 B_i^{class} 的类间离散度矩阵, μ_{class} 为类矩阵的平均值, 可通过对矩阵 S_{class} 进行特征分析来得到最优投影矩阵 W , 与 S_{class} 的所有非零特征值对应的特征向量就是最优投影向量。 S_{class} 为 $d \times d$ 大小的矩阵, 其特征向量计算复杂, 可采用如下方法简化: 因为 $S_{\text{class}} = A_{\text{class}} A_{\text{class}}^T$, 这里

$$A_{\text{class}} = [B_1^{\text{class}} - \mu_{\text{class}}, \dots, B_C^{\text{class}} - \mu_{\text{class}}],$$

通过计算 $A_{\text{class}}^T A_{\text{class}}$ 的非零特征值就可得到 S_{class} 的非零特征值。因为 S_{class} 的秩为 $C-1$, 因此可得 $C-1$ 个正交的特征向量, 组成最优投影矩阵 $W = [w_1, w_2, \dots, w_{C-1}]$ 。

根据上面得到的最优投影方向, 即可先按公式 $\varphi_i^{\text{class}} = W^T B_i^{\text{class}}$ 计算出每一类的判别向量 φ_i^{class} , 这里 $i = 1, \dots, C$, 然后把测试样本也投影到最优投影方向, 即 $\varphi_{\text{test}} = W^T B_i^{\text{test}}$, 这样, 通过计算 φ_i^{class} 和 φ_{test} 的欧氏距离, 就可以得到测试样本归属的类别了, 公式如下:

$$\eta_i = \|\varphi_i^{\text{class}} - \varphi_{\text{test}}\| \quad (19)$$

$i = 1, 2, \dots, C, \|\cdot\|$ 为欧氏距离。

再令 $\eta_k = \min(\eta_1, \eta_2, \dots, \eta_C)$, 即令 η_k 为所有得出的 $\eta_i (i = 1, 2, \dots, C)$ 中的最小者, 那么就可以判定测试人脸属于 k 类。

以上基于类矩阵的人脸识别方法因为采用了综合人脸全局和局部特征的特征矩阵,所以识别率较高,下面的试验也证明了这一点。而且该方法的以下 2 个独特的优点也保证了其有良好的应用前景:

(1) 由于该方法的投影准则解决了普通 LDA 算法的小样本空间问题,因此,该算法适用于样本数较少的人脸识别,如罪犯识别等。

(2) 因为每一类都有同样的类矩阵,其在人脸识别前只需计算出类矩阵和投影矩阵,就可以对测试人脸进行实时识别,所以该方法的识别速度较快,特别适用于一些实时系统,例如机场保安、考试认证等。

5 试 验

试验采用了普渡大学的 AR 标准人脸数据库中存储的人脸图像,该库由 126 个人的 4 000 多幅彩色人脸图像组成,人脸表情、面部装饰及光照条件都有变化。本文选取了每个人的 10 幅不同的图像进行试验,并先将这些人脸在计算机中转化为灰度图像,再用本文算法进行试验。

试验时,首先根据第 2 节的权值选择方法对人脸数据库进行了权值计算,共计算 3 次,再计算平均值,结果见表 1。

表 1 全局特征和关键局部特征权值大小

Tab. 1 Weight of global and keg local features

	全局	左眉	右眉	左眼	右眼	鼻子	嘴
1	0.183 0	0.182 5	0.152 3	0.153 4	0.193 7	0.135 1	
2	0.182 2	0.182 9	0.151 0	0.151 4	0.194 9	0.137 6	
3	0.183 5	0.181 1	0.149 9	0.151 2	0.196 5	0.137 8	
平均	0.182 9	0.182 2	0.151 1	0.152 0	0.195 0	0.136 8	

然后根据上面试验得到的平均权值对本文算法进行了试验,试验比较了 Eigenface、Fisherface^[1,3]和本文算法 3 种不同的人脸识别算法,每种算法进行了 3 组试验,每一组又分别进行 10 次试验,每次进行 100 个试验样本的识别;最后给出每组试验的识别率。第 1 组选取的样本为光照条件、面部装饰等都有变化的人脸;第 2 组选取光照条件相对变化小,没有面部装饰的人脸;第 3 组为随机抽取的样本,本试验,Eigenface 算法的样本数量取为 100,表 2 给出了试验结果。

由表 2 可以看出,Eigenface 算法的平均识别率是 83.9%,Fisherface 算法的平均识别率为 91.5%,本文算法的平均识别率则高达 97.1%。第 1 组由于条件较为复杂,因此识别率稍低。试验充分证明了本文算法的有效性。

表 2 3 种算法的识别效果比较

Tab. 2 Recognition effect compare of three algorithmal

算法	识别率(%)											
	1	2	3	4	5	6	7	8	9	10	平均	
第 1 组	A	82	85	81	82	82	82	81	83	83	83	82.4
	B	92	91	93	89	91	91	90	90	91	90	90.8
	C	94	96	95	96	93	97	97	96	95	96	95.5
第 2 组	A	82	87	86	87	84	85	87	85	83	85	85.1
	B	92	93	92	95	92	92	92	91	93	93	92.5
	C	100	98	97	98	99	100	100	96	99	96	98.3
第 3 组	A	86	84	86	84	85	83	84	85	83	83	84.2
	B	90	91	91	91	93	91	92	91	90	94	91.2
	C	97	98	98	95	98	97	98	100	99	96	97.6

注:A 为 Eigenface 算法,B 为 Fisherface 算法,C 为本文算法。

6 结 论

本文给出了一种基于类矩阵的融合全局和局部特征的人脸识别算法。该法首先提取人脸的全局特

征和 6 个关键部分的局部特征,同时给出了权值的概念,并通过将其全局和局部特征进行加权融合,得出了样本的特征矩阵;其次,在经典 PCA 基础上,设计出了一种加权 PCA 方法,用于对样本矩阵进行降维;然后,定义了每类样本的类矩阵,同时给出了证

明,并据此得出了一种新的投影准则;最后,将类矩阵和试验样本分别进行投影,并根据其欧氏距离的大小得出试验人脸的最终类。试验表明,本文算法不仅计算速度快、识别率高,而且能有效解决 LDA 小样本空间问题,应用前景良好。

参考文献 (References)

- 1 Zabrodsky H, Peleg S, Avnir D. Symmetry as a continuous feature [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1995, **17**(12): 1154 ~ 1166.
- 2 Turk M, Pentland A. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1991, **3**(1): 71 ~ 86
- 3 Belhumeur V, Hespanha J, Kriegeman D. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, **19**(7): 711 ~ 720
- 4 Bartlett M S, Movellan J R, Sejnowski T J. Face recognition by independent component analysis [J]. IEEE Transactions on Neural Networks, 2002, **13**(6): 1450 ~ 1464
- 5 Moghaddam B. Principal manifolds and probabilistic subspaces for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, **24**(6): 780 ~ 788
- 6 Kim K I, Jung K, Kim H J. Face recognition using kernel principal component analysis [J]. IEEE Signal Processing Letters, 2002, **9**(2): 40 ~ 42
- 7 Mika S, Ratsch G, Weston J, *et al.* Fisher discriminant analysis with kernels [A]. In: Proceedings of IEEE Workshop on Neural Network for Signal Processing [C], Madison, Wisconsin, USA, 1999, **9**: 41 ~ 48
- 8 Martinez A, Kak A. PCA versus LDA [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, **23**(2): 228 ~ 233.
- 9 Pentland A, Moghaddam B, Starner View-based and modular eigenspaces for face recognition [A]. In: Proceedings of IEEE Conference on Computer Vision and Pattern Recognition [C], Seattle, WA, USA 1994: 84 ~ 91
- 10 Wang Y H, Fan W, Tan T N. Face recognition based on information fusion [J]. Chinese Journal of Computers, 2005, **28**(10): 1657 ~ 1663. [王蕴红, 范伟, 谭铁牛. 融合全局与局部特征的子空间人脸识别算法 [J]. 计算机学报. 2005, **28**(10): 1657 ~ 1663]