

优化的小波变换和改进的 LDA 相融合的人脸识别算法

楚建浦 何光辉 刘玉馨
(重庆大学数学与统计学院 重庆 401331)

摘要 提出了一种优化的小波变换与改进的 LDA 相融合的人脸识别算法。首先对经过预处理的人脸图像进行 2 层小波变换并提取特征,然后对小波分解后的高频子带进行融合,并在改进的 LDA 下利用交替方向法求出投影矩阵和最优融合系数,再结合低频子带在改进的 LDA 下的特征表示,利用最近邻分类器进行分类。实验结果表明,该算法在 ORL 及 YALE 人脸库上的识别效果较传统的人脸识别算法更优。

关键词 小波变换,融合系数,人脸识别

中图分类号 TP391.4 文献标识码 A

Face Recognition Algorithm Based on Fusion of Optimized Wavelet Transform and Improved LDA

CHU Jian-pu HE Guang-hui LIU Yu-xin

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

Abstract A face recognition algorithm based on fusion of optimized wavelet transform and improved LDA (OWT+ILDA) was proposed. First, we extracted features of the preprocess face images through the 2-level wavelet transform, and an alternating direction method is used to solve the projection matrix and the corresponding optimal fusion coefficients of the high frequency wavelet sub-bands which are fused by the improved LDA. Then we combined representations of the low frequency and high frequency. Finally, the nearest neighbor classifier was used to perform face classification. Experiments were carried out on the ORL and YALE face databases, which indicate that the method is more effective than other traditional methods.

Keywords Wavelet transform, Coefficient of fusion, Face recognition

1 引言

人脸识别是通过比较分析人脸特征信息来进行身份鉴别的一种计算机技术。近几年,随着计算机科学技术的迅猛发展,人脸识别技术已成为生物识别和信息科学的研究热点并广泛应用于安检系统及人机交互等领域。

小波变换可以同时提取时域和频域特征,具有多分辨率分析、良好压缩比及自适应性,并且在人脸图像的特征数据降维方面有很大优势,因此小波变换技术被广泛地应用于人脸识别领域^[1-5]。文献[1-4]利用二维离散小波变换仅对低频成分提取特征进行人脸识别并舍弃高频成分,操作虽然简单,但影响识别效果;文献[5]验证了尽管高频子带不像低频子带那样包含较多的信息,但也包含反映脸部细节的边缘及轮廓的重要信息。本文对人脸图像进行多级小波分解,发现 2 级小波分解的识别效果较好。为了充分利用小波变换后的高频成分,先对图像进行 2 级小波分解,然后将高频成分融合,并利用交替方向法求出最优融合系数和投影矩阵。小波变换后维数仍较高且计算过于复杂,需进一步降维。较为经典的方法有主成分分析(PCA)^[6]和最佳鉴别分析(LDA)^[7,8]。前者可

用较少数量的特征对人脸图像进行描述使数据易于处理,但对不同类的样本区分度低,而后者使类间区分度加大,类内区分度减小,但会产生小样本和边缘化问题。为了克服传统 LDA 算法的缺点,大批学者对 LDA 算法进行了深入研究。文献[2]提出的改进的 LDA 算法解决了边缘类重叠的问题,推广了 LDA 算法的应用空间;文献[9]提出了改进的 LDA 的人脸识别算法,保留了最有利的判别信息,提高了算法的识别率,优于传统的 PCA+LDA 算法。由于计算的复杂性和小样本问题不能直接用于高维模式,文献[10]提出近似加权 LDA 算法。本文通过引入加权函数重建类间散度矩阵,并重新定义 Fisher 准则,得到了改进的 LDA 算法,有效地避免了上文提出的传统 LDA 算法的两个缺点,并将小波变换与改进的 LDA 融合应用于人脸识别(OWT+ILDA 算法),实验结果证明是可行的。

2 小波原理

令 $L^2(R)$ 表示平方可积空间,一维连续小波变换函数 $f \in L^2(R)$ 定义为:

$$W_f(a, b) = \int_R f(t) \overline{\varphi_{a,b}(t)} dt$$

本文受国家自然科学基金项目:图像运动模糊不变量特征学习(61572087)资助。

楚建浦(1990—),男,硕士生,主要研究方向为模式识别;何光辉(1976—),男,博士,副教授,主要研究方向为模式识别、小波分析;刘玉馨(1991—),女,硕士生,主要研究方向为模式识别。

其中, $\varphi_{a,b}(t) = |a|^{-\frac{1}{2}} \varphi(\frac{t-b}{a})$ 是小波基函数, $\varphi(t)$ 为小波母函数, 参数 a 和 b 分别表示小波的尺度和位置。上式可由参数 a 和 b 限制, 令 $a=2^n$ 且 $b \in Z$ 。

图像的 2D-DWT 小波分解过程是图像在水平方向进行一维离散小波变换, 再在垂直方向进行相同的处理。因此一个图像可分解成 4 个子带, 分别为低频成分(LL)和对应的水平(HL)、垂直(LH)、对角线方向(HH)的高频成分。图 1 示出小波分解示意图及 2 层小波分解下的人脸图像。

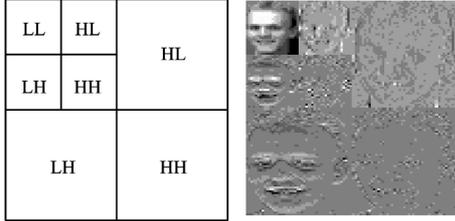


图 1 小波分解示意图及 2 层小波分解后的人脸图像

3 LDA 算法原理

3.1 传统的 LDA 算法

LDA 算法又称 Fisher 最佳鉴别分析, 其基本思想是将高维空间的样本投影到最佳鉴别向量空间, 即选择使类间距离与类内距离的比值最大的特征, 进而实现数据降维的目的。

假设 $n \times m$ 的灰度人脸图像按先后行、从左到右进行向量化后变为 $M(M=nm)$ 维的列向量, 传统的 LDA 方法定义类内散度矩阵 S_w 和类间散度矩阵 S_b 如下:

$$S_w = \sum_{i=1}^c \sum_{j=1}^{N_i} p_i (x_{ij} - m_i)(x_{ij} - m_i)^T$$

$$S_b = \sum_{i=1}^c p_i (m_i - m)(m_i - m)^T$$

其中, x_{ij} 为第 i 类第 j 个样本, N, m 分别为包含 c 个类的样本集的样本总数和均值, N_i, m_i 分别为第 i ($i=1, 2, \dots, c$) 类样本的数目和均值, $p_i = \frac{N_i}{N}$ 为第 i 类的先验概率。

定义变换矩阵 W 的 Fisher 准则函数:

$$J(W) = \max_W \frac{\text{tr}(W^T S_b W)}{\text{tr}(W^T S_w W)} \quad (1)$$

LDA 算法就是求使 $J(W)$ 取得最大值的最佳的变换矩阵 W , S_w 非奇异且 W 为 $S_w^{-1} S_b$ 的特征矩阵时, 式(1)最大化。

3.2 改进的 LDA 算法(ILDA)

由式(1)知, W 满足 $W^T S_w W = 0$, 且 $W^T S_b W \neq 0$ 时, $J(W)$ 无穷大。由此可见, 最有鉴别力的特征位于 S_w 的零空间和 S_b 的非零空间的交集子空间中。由于传统的 LDA 降维必须保证 S_w 是非奇异的, 否则会失去“最有鉴别力”的信息, 但在人脸识别中总会出现小样本问题, 即样本数小于图像的维数导致 S_w 奇异, 传统的 LDA 失效。为此, 本文对类间散度矩阵和 Fisher 准则进行改进。为了抑制边缘类的作用, 本文采用加权的类间散度矩阵, 将向量化的第 i 类和第 j 类均值样本的欧氏距离的平方分之一作为两类间的加权函数来衡量类间的差异。具体如下:

$$S_b = \sum_{i=1}^{c-1} \sum_{j=i+1}^c p_i p_j \omega_{\sigma_{ij}} (m_i - m_j)(m_i - m_j)^T$$

$$\sigma_{ij} = \sqrt{(m_i - m_j)^T (m_i - m_j)}, \omega_{\sigma_{ij}} = \frac{1}{\sigma_{ij}^2}$$

其中, σ_{ij} 为两个类别间的欧氏距离, $\omega_{\sigma_{ij}}$ 是加权函数。

加权的类间散度矩阵只考虑类间距离的方向, 忽略其距离大小, 有效解决了边缘类的问题。

为了避免小样本问题, 即 S_w 奇异, 无法求最大化 Fisher 准则的 W , 本文对 Fisher 准则进行改进。

$$J(W) = \max_W \text{tr}(W^T (S_b - c S_w) W) \quad (2)$$

其中, $\|w\| = 1$, c 为非负数, 这里 c 取 10。由文献[11]知, 最优投影矩阵 W 为 $(S_b - c S_w)$ 所对应的最大特征值对应的单位化特征向量, 这样就避免了 S_w 奇异的问题。

4 OWT+ILDA

4.1 算法原理

本文算法将经过 2 层小波变换得到的低频图像向量化, 然后采用改进的 LDA 算法得到其特征表示。同时, 将得到的 3 个高频图像进行向量化, 设定一个初始的融合系数, 然后在改进 LDA 的基础上采用更新迭代的方法, 当达到一定的精度时输出融合系数, 作为最终的最优融合系数。

为了增加对比度, 削弱光照影响, 对有 N 幅人脸图像的训练集进行归一化和伽马变换^[12]预处理, 然后对第 i 类第 j 幅人脸图像进行 2 层小波变换, 得到第二层小波变换的低频和高频成分, 然后分别将其向量化为: $L_{ij}, H_{ij}, V_{ij}, D_{ij}$ ($i=1, 2, \dots, c; j=1, 2, \dots, N_i$)。

首先对用 ILDA 向量化的低频成分 $L = (L_{11}, L_{12}, \dots, L_{1N_1}, L_{21}, \dots, L_{cN_c})$ 降维, 得到投影为:

$$Y_L = (y_{L_{11}}, y_{L_{12}}, \dots, y_{L_{1N_1}}, y_{L_{21}}, \dots, y_{L_{cN_c}}) \in R^{d_1 \times N}$$

其次, 将高频成分 $H_{ij}, V_{ij}, D_{ij} \in R^l$ 组成矩阵 $A_{ij} = [H_{ij}, V_{ij}, D_{ij}] \in R^{l \times 3}$, 并设 S_{ij} 为高频成分的融合, 即

$$S_{ij} = u_1 H_{ij} + u_2 V_{ij} + u_3 D_{ij} = A_{ij} u \in R^l$$

其中, $u = (u_1, u_2, u_3)^T$ 为融合系数, 第 i 类的均值为 $\overline{S_i} = \overline{A_i} u$, 其中 $\overline{A_i}$ 分别为 A_{ij} 的第 i 类均值, 则类间、类内散度矩阵分别为:

$$S_b(u) = \sum_{i=1}^{c-1} \sum_{j=i+1}^c p_i p_j \omega_{\sigma_{ij}} (\overline{S_i} - \overline{S_j})(\overline{S_i} - \overline{S_j})^T$$

$$= \sum_{i=1}^{c-1} \sum_{j=i+1}^c p_i p_j \omega_{\sigma_{ij}} (\overline{A_i} - \overline{A_j}) u u^T (\overline{A_i} - \overline{A_j})^T$$

$$\sigma_{ij} = \sqrt{(\overline{S_i} - \overline{S_j})^T (\overline{S_i} - \overline{S_j})}, \omega_{\sigma_{ij}} = \frac{1}{\sigma_{ij}^2}$$

$$S_w(u) = \sum_{i=1}^c \sum_{j=1}^{N_i} p_i (S_{ij} - \overline{S_i})(S_{ij} - \overline{S_i})^T$$

$$= \sum_{i=1}^c \sum_{j=1}^{N_i} p_i (A_{ij} - \overline{A_i}) u u^T (A_{ij} - \overline{A_i})^T$$

改进的 Fisher 准则为:

$$J(W, u) = \max_{W, u} \text{tr}(W^T (S_b(u) - c S_w(u)) W)$$

其中, W 是 $l \times \gamma$ 变换矩阵。

定义矩阵:

$$L_b(W) = \sum_{i=1}^{c-1} \sum_{j=i+1}^c p_i p_j \omega_{\sigma_{ij}} (\overline{A_i} - \overline{A_j})^T W W^T (\overline{A_i} - \overline{A_j}) \in R^{3 \times 3}$$

$$L_w(W) = \sum_{i=1}^c \sum_{j=1}^{N_i} p_i (A_{ij} - \overline{A_i})^T W W^T (A_{ij} - \overline{A_i}) \in R^{3 \times 3}$$

由线性代数关于矩阵迹的相关性质知:

$$\text{tr}(W^T S_b(u) W) = u^T L_b(W) u$$

$$\text{tr}(W^T S_w(u) W) = u^T L_w(W) u$$

$$\text{tr}(W^T (S_b(u) - c S_w(u)) W) = u^T (L_b(W) - c L_w(W)) u$$

则:1)假定 u 是已知的,则 $(S_b(u) - c S_w(u))$ 也为已知,即可计算其前 γ 个最大特征值对应的特征向量 $W = [\omega_1, \omega_2, \dots, \omega_\gamma]$;2)假定 W 已知,则可计算 $(L_b(W) - c L_w(W))$ 最大特征值对应的特征向量 u 。

因此由 1)、2)可知,可以采用更新迭代的方法求出高频成分的投影矩阵和最优的融合系数。

设定一个精度 ϵ 和一组初始的融合系数 $u^{[0]}$ 进行步骤 1),得到前 γ 个最大特征值对应的特征向量 $W^{[1]} = [\omega_1, \omega_2, \dots, \omega_\gamma]$;再用得到的 $W^{[1]}$ 进行步骤 2)得到 $u^{[1]}$,依次进行下去,不断更新迭代,直至满足:

$$|J(W^{[k+1]}, u^{[k+1]}) - J(W^{[k]}, u^{[k]})| < \epsilon$$

输出 $u^{[k]}, W^{[k]}$ 作为最终高频成分的最优融合系数和投影矩阵。

4.2 算法步骤

算法 1 优化的小波变换和改进的 LDA 融合的人脸识别算法

1. 对人脸图像进行归一化和伽马变换预处理;
2. 对伽马变换的图像经过 2 层 2D-DWT 后得到向量化的低频和高频子带分别为 $L_{ij}, H_{ij}, V_{ij}, D_{ij} (i=1, 2, \dots, c; j=1, 2, \dots, N_i)$;

3. 对 L_{ij} 进行 ILDA, 得到其特征表示 $y_{L_{ij}}$;

4. 令 $A_{ij} = [H_{ij}, V_{ij}, D_{ij}]$, 并对 u 进行初始化, $u = u^{[0]}$ 且设 $k=0$;

5. 计算 $(S_b(u^{[k]}) - c S_w(u^{[k]}))$ 的前 γ 个最大特征值对应的特征向量 $w_i (i=1, 2, \dots, \gamma)$, 并令

$$W^{[k+1]} = (w_1, w_2, \dots, w_\gamma)$$

6. 计算 $(L_b(W^{[k+1]}) - c L_w(W^{[k+1]}))$ 的最大特征值对应的特征向量 $u^{[k+1]}$;

7. 设置精度 ϵ , 且 $k > 0$, 当

$$|J(W^{[k+1]}, u^{[k+1]}) - J(W^{[k]}, u^{[k]})| < \epsilon \quad (3)$$

时, 则输出 $W^{[k+1]}, u^{[k+1]}$, 并令

$$W = W^{[k+1]}, u = u^{[k+1]}$$

否则, 转 4, 直至满足式(3);

8. 由 W, u 计算高频特征 $y_{H_{ij}}$, 并将其与特征 $y_{L_{ij}}$ 进行融合得到特征

$$F_{ij} = \begin{bmatrix} y_{L_{ij}} \\ y_{H_{ij}} \end{bmatrix};$$

9. 用最近邻分类器进行分类。

5 实验结果与分析

本文用 MATLAB 分别在 YALE 和 ORL 人脸库中以 db4 和 haar 为小波基函数, 以余弦距离为相似度度量进行实验, 验证所提算法的可行性。

YALE 人脸库包含 15 人, 每人 11 幅, 共 165 幅人脸图像, 其尺寸为 100×100 像素, 这些人脸图像主要差异表现为表情、姿态和光照上, 同时此人脸数据库中图像光照变化相对较大, 为此本文对图像进行归一化和伽马变换预处理。

ORL 人脸库包含 40 个人, 每人 10 幅, 共 400 幅人脸图像, 其尺寸为 112×92 像素, 每人的图像都是在不同的光照、姿态和表情下采集的。本文对该人脸库进行相同的预处理。图 2 显示了人脸库中的部分图像。



(a) YALE 数据库

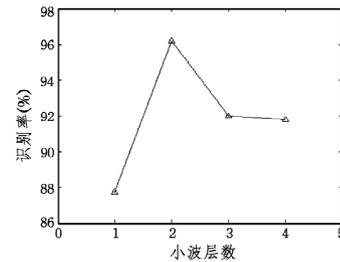


(b) ORL 数据库

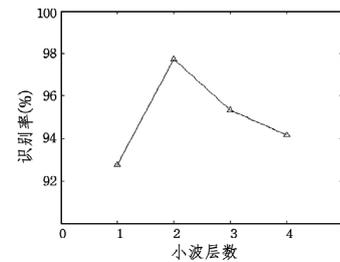
图 2 人脸数据库中部分人脸图像

5.1 db4 为小波基函数的实验

首先用本文算法以 db4 为小波基函数分别在 YALE 和 ORL 数据库上对人脸图像进行 $i (i=1, 2, 3, 4)$ 级小波分解, 每人选取 5 张图像作为训练样本, 其余作为测试样本, 实验效果如图 3 所示。



(a) YALE 数据库运行结果



(b) ORL 数据库运行结果

图 3 不同级数小波分解对应的识别率

由以上两个实验可以看出当 $i=2$ 时, 识别效果最好, 这是因为当小波分解的级数过小时, 图像存在大量的冗余信息, 没有最大限度地降低图像数据的复杂度; 当小波层数过多时, 则会丢掉图像的主要信息, 进而造成识别率的下降。所以后面涉及小波分解的算法均采用 2 级分解。

下面以 db4 为小波基函数, 将算法 OWT+ILDA 与经典的人脸识别算法 PCA、LDA、WT+PCA、WT+LDA 及 TWSBF+LDA^[5] 分别在 YALE 和 ORL 数据库上, 以及在不同样本数量下进行实验比较, 结果如表 1 和表 2 所列。

表 1 不同算法在 YALE 上的识别效果比较

样本数	PCA	LDA	WT+PCA	WT+LDA	TWSBF+LDA	OWT+ILDA
3	73.33	76.18	78.13	83.33	84.17	87.25
4	74.40	79.79	82.86	90.38	92.50	93.42
5	79.62	83.37	84.44	91.11	94.46	96.18
6	80.17	80.79	82.67	94.25	96.17	97.50
7	82.87	85.07	95.00	96.27	97.25	97.45
8	82.66	85.59	88.89	97.50	97.56	98.50

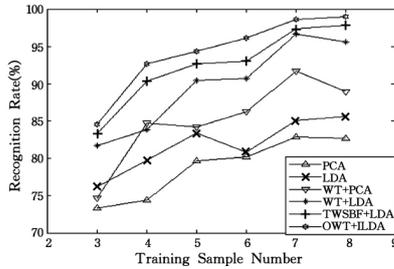
表 2 不同算法在 ORL 上的识别效果比较

样本数	PCA	LDA	WT+PCA	WT+LDA	TWSBF+LDA	OWT+ILDA
3	75.78	80.79	83.21	89.29	90.43	90.15
4	76.53	83.62	88.33	92.75	93.00	94.60
5	82.97	85.39	91.50	94.50	97.50	97.73
6	82.55	89.36	93.75	95.87	98.75	98.95
7	85.27	92.13	94.17	96.25	99.17	99.45
8	86.69	93.79	93.75	97.50	99.30	99.70

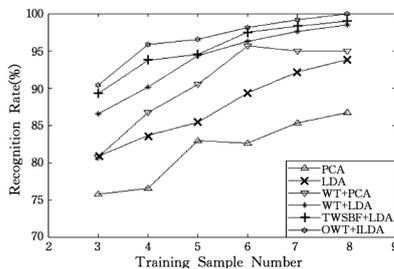
由表 1 和表 2 可以看出 OWT+ILDA 在 YALE 和 ORL 数据库上的识别效果较好。

5.2 haar 为小波基函数的实验

下面采用 haar 为小波基函数,在 YALE 和 ORL 上与另外 5 种算法进行实验比较,如图 4 所示。



(a) YALE 数据库运行结果



(a) ORL 数据库运行结果

图 4 不同数量的训练样本的识别效果

由图 4 知,在 YALE 和 ORL 数据库上相同数量的训练样本下,OWT+ILDA 的识别率较另外 5 种算法要高。且在相同识别率的情况下,OWT+ILDA 所需的训练样本个数较少。因此,OWT+ILDA 识别效果较好。

综合 5.1 节和 5.2 节知,PCALDA,WT+PCA,WT+LDA 的识别效果没有 TWSBF+LDA 好,这是因为经典的人脸算法 PCA 和 LDA 直接用人脸图像提取特征,其中包含大量的冗余信息,且容易造成维数灾难和小样本问题。WT+PCA 和 WT+LDA 仅提取低频特征,丢弃高频特征,而 TWSBF+LDA 不但提取了低频特征而且将高频进行了融合,提取了高频特征。另外,算法 TWSBF+LDA 的识别效果没有 OWT+ILDA 算法的识别效果好,这是因为前者采用的 LDA 由于类内散度矩阵奇异问题,先采用了 PCA 降维,但 PCA 和 LDA 的准则不能同时达到最优,在 PCA 降维的同时会丢掉一些重要的 LDA 判别信息,而 OWT+ILDA 正是在 TWSBF+LDA 的基础上采用改进的 LDA,克服了上述问题,因此相比而言,OWT+ILDA 的识别效果更好。

5.3 不同相似度量分类器的比较实验

分类是人脸识别系统的关键步骤之一,在研究过程中使用最多也最简单快捷的相似性度量是基于欧氏距离的分类器。其中,余弦距离,KL 散度也是较为普遍的相似性度量。

图 5 展示了本文算法分别以 4 种距离为相似度量,在 YALE 人脸数据库上以 db4 为小波基函数不同数量的训练样本的识别结果。

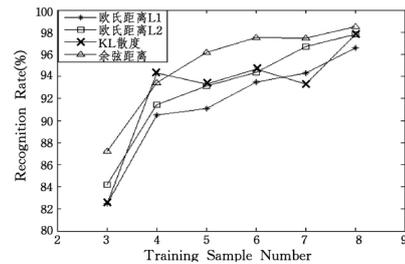


图 5 OWT+ILDA 算法在不同距离下的识别率

由图 5 知,OWT+ILDA 以余弦距离作为相似度量时识别效果最好。这是因为 KL 散度是计算两个随机变量的概率分布距离,而 L2 范数欧氏距离单纯地把两个向量作为空间中的两个点,求取在空间上两个点间的最短距离,L1 范数仅是求取两个向量的差的绝对值,当在球形分布或规律分布的数据集上以欧氏距离作为相似性度量时有良好的效果,但在非凸形状,或者分布未知的、更复杂的数据集上不能发挥很好的作用,而人脸图像受光照、姿态、遮挡等影响显然属于后者,余弦距离是更具有弹性的相似性度量方法,更加注重两个向量在方向上的差异,所以余弦距离作为相似性度量的效果较好。

结束语 本文对人脸图像进行归一化和伽马变换预处理,增强对比度,削弱光照影响;然后进行二级小波分解并将分解后的高频信息进行融合,充分利用了各个子带的信息;而后利用 ILDA 算法分别对高频和低频成分进行降维,ILDA 有效地克服了传统 LDA 出现的边缘类和小样本问题。本文算法在一定程度上提高了识别率,且表现出对表情、姿态及光照等变化具有一定鲁棒性,对以后人脸识别算法研究有一定的意义。然而,由于时间限制,该方法的研究内容还有许多不足和改进之处。例如,本文采用了线性的 ILDA 提取特征,而人脸图像存在大量的非线性特征,可以尝试非线性的方法提取人脸图像的非线性特征;该算法的时间复杂度在实验条件复杂化时有待提高,如何降低时间复杂度也是我们需要进一步研究的工作。

参考文献

- [1] Sharma M K, Sharma S. Wavelet Decomposition Based Principal Component Analysis for Face Recognition Using MATLAB[C]// International Conference on Communication Systems, 2015:42-50
- [2] 方杰,谭晓衡.基于小波变换的优化 LDA 人脸特征提取[J].传感器与微系统,2012,31(5):65-67
- [3] Zhang Bai-ling, Zheng Hai-hong. Face recognition by applying wavelet sub-band representation and kernel associative memory [J]. IEEE Trans on Neural Networks, 2004, 15(1):166-177
- [4] Puyati W, Walairacht S, Walairacht A. PCA in wavelet domain for face recognition [C]// Proc of the 8th International Conference on Advanced Communication Technolog. IEEE Press, 2006:450-456
- [5] Huang Zheng-hai, Li Wen-juan, Wang Jun, et al. Face recognition based on pixel-level and feature-level fusion of the top-levels wavelet sub-bands[J]. Inf. Fusion, 2015, 22:99-104

(下转第 166 页)

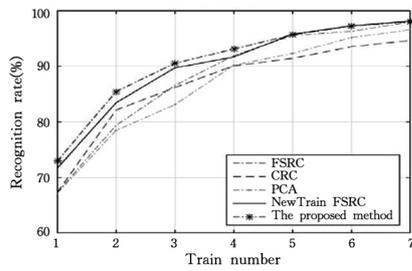


图 11 ORL 人脸数据库不同训练样本数的人脸识别率

表 8 ORL 人脸数据库不同训练样本数的人脸识别率 (%)

训练样本数	算法				
	FSRC	CRC	PCA	NewTrain FSRC	The proposed method
1	67.33	67.36	67.19	71.69	72.97
2	79.38	82.13	78.47	83.44	85.44
3	86.54	86.18	83.11	89.74	90.57
4	91.96	90.08	90.21	91.71	93.13

在 YALE 与 ORL 人脸数据库上,由图 10、表 7、图 11、表 8 可以看出:与其他方法相比,本文所提方法的识别率不因人脸数据库改变而降低,这进一步说明了本文所提方法具有广泛的适用性。

6 关于决策环节的讨论

以上的实验只考虑测试样本在样本库中,此时可判断其与样本中每个训练样本图像的距离,进而找到最小距离,判断其所属的类;但是如果测试样本不在样本库中,如在 Feret 人脸数据库中,我们从 100 个人中选择 90 个人,每个人的 4 幅图像作为训练,剩余 2 幅图像作为测试,此时剩余 10 人的 60 幅图像不作为训练,若将其作为非法访问者,同样可以求最小残差矩阵,但此时选择该对象作为识别结果就不合理了。上述的问题属于模式识别的拒识问题,或者说在实际应用中执行算法前需要首先判断测试样本所属的类别是否在训练集中,而一般的算法研究可以不用考虑这类问题,只要假设测试样本所属的类别都在训练集中即可。本文所用的测试对象都在样本库中,所以没有考虑测试样本不在样本库中的情况。如果需要考虑上述问题,可以在运行本文算法前设置拒识参数,根据阈值判断测试样本访问者是否合法,对其进行取舍后再运用本文所提的方法。

结束语 本文提出了一种融合快速描述与协同描述的人脸识别方法,其特点是:镜像人脸的引入减弱了训练样本不足对识别造成的影响,基于数据级的加权权重融合既利用了 FSRC 整体分析特性,又兼顾了 CRC 局部样本间的协调性优势。在 Feret, AR, YALE, ORL 人脸数据库上的实验表明,本文方法对提高人脸识别率具有明显的效果。

在实验中我们发现权重值的选择与识别率息息相关,本

文所提方法是以手动的方式进行选择。如何自动选择权重 λ 以提高识别率是我们继续研究的重点。

参考文献

- [1] Liu Z, Zhang Z Y. Face geometry and appearance modeling: concepts and application[M]. Cambridge University Press, 2011: 13-67
- [2] Gross R, Matthews I, Baker S. Appearance-based face recognition and light-fields[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(4): 449-463
- [3] Dass S C, Jain A K. Markov face models[C]// Eighth IEEE International Conference on Computer Vision. 2001: 680-687
- [4] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227
- [5] Yang M, Zhang L, Zhang D. Gabor feature based robust representation and classification for face recognition with gabor occlusion dictionary[J]. Pattern Recognition, 2013, 46: 1865-1878
- [6] Naseem I, Togneri R, Bennamoun M. Linear regression for face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(11): 2106-2110
- [7] Xu Y, Li X, Yang J, et al. Integrating conventional and inverse representation for face recognition[J]. IEEE Transactions on Cybernetics, 2014, 44(10): 1738-1746
- [8] Xu Y, Zhang D, Yang J, et al. A two-phase test sample sparse representation method for use with face recognition[J]. IEEE Transactions and Systems for Video Tehnology, 2011, 21(9): 1255-1260
- [9] Zhang L, Yang M, Feng X C. Sparse representation or collaborative representation: which helps face recognition? [C]// IEEE International Conference on Computer Vision. 2011: 471-478
- [10] Thian N P H, Marcel S, Bengio S. Improving face authentication using virtual samples[C]// 2003 IEEE International Conference on Acoustics, Speech, and Signal(ICASSP'03). 2003: 233-236
- [11] Jung H C, Hwang B W, Lee S W. Authenticating corrupted face image based on noise model[C]// Proceedings of sixth IEEE International Conference on Automatic Face and Gesture Recognition. 2004: 1-6
- [12] Xu Y, Zhang Z, Lu G, et al. Approximately symmetrical face images for image preprocessing in face recognition and sparse representation based classification [J]. Pattern Recognition, 2016 (54): 68-82
- [13] Donoho D L, Tsaing Y. Fast solution of l_1 -norm minimization problems when the solution may be sparse[J]. IEEE Transactions on Information Theory, 2008, 54(11): 4789-4812

(上接第 150 页)

- [6] Turk M, Pentland A. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86
- [7] Belhumeur P N, Hespanha J P, Eigenfaces K D. Fisherfaces: recognition using class specific linear projection[M]// Computer Vision-ECCV'96. Springer Berlin Heidelberg, 1996: 43-58
- [8] Bansal A, Mehta K, Arora S. Face recognition using PCA and LDA algorithm[C]// 2012 Second International Conference on Advanced Computing & Communication Technologies (ACCT). 2012: 251-254

- [9] 齐兴敏, 尹朝庆, 李智博. 基于改进 LDA 算法的人脸识别[J]. 计算机与数字工程, 2007, 35(8): 31-37
- [10] Loog M, Duin R P W, Haeb-Umbach R. Multiclass linear dimension reduction by weighted pairwise Fisher criteria[J]. IEEE Patt Anal Mach Intel, 2001, 23(7): 762-766
- [11] 张勇胜. 一种新的线性判别准则在人脸识别中的应用[J]. 兰州理工大学学报, 2008, 34(2): 101-103
- [12] 董兰芳, 任乐乐, 董玉德. 复杂光照下的人脸姿态估计[J]. 小型微型计算机系统, 2016(3): 598-602