

基于小波和非负稀疏矩阵分解的人脸识别方法^{*}

欧阳怡彪, 蒲晓蓉, 章毅

(电子科技大学 计算机科学与工程学院 计算智能实验室, 四川 成都 610054)

摘要: 提出了利用小波变换(WT)、非负稀疏矩阵分解(NMFs)和 Fisher 线性判别(FLD)来进行人脸识别。用小波变换分解人脸图像, 选择最低分辨率的子段, 既能捕获到人脸的实质特征, 又有效地降低了计算复杂性; 非负稀疏矩阵分解能显式地控制分解稀疏度和发现人脸图像的局部化表征; Fisher 线性判别能在低维子空间中形成良好的分类。实验结果表明, 这种方法对光照变化、人脸表情和部分遮挡不敏感, 具有良好的健壮性和较高的识别效率。

关键词: 人脸识别; 小波变换; 非负矩阵分解; Fisher 线性判别

中图分类号: TP317.4 文献标识码: A 文章编号: 1001-3695(2006)10-0159-04

Wavelet-based Non-negative Matrix Factorization with Sparseness Constraints for Face Recognition

OUYANG Yi-biao, PU Xiao-rong, ZHANG Yi

(Computational Intelligence Laboratory, College of Computer Science & Engineering, University of Electronic Science & Technology of China, Chengdu Sichuan 610054, China)

Abstract: This paper combines Wavelet Transformation(WT), Non-negative Matrix Factorization with sparseness constraints(NMFs), and Fisher's Linear Discriminant(FLD) to extract features for face recognition. Wavelet transformation is used to decompose face images and for choosing the lowest resolution sub-band coefficients so that the substantial facial features can be captured and the computational complexity can be reduced. NMFs can control sparseness explicitly and find parts-based representations for face images. FLD plays the role of forming well-separated classes in a low-dimensional subspace. Extensive experiments are carried out to illustrate the proposed combine face recognition method by using the ORL face database. The experimental results show that the method has robust high-performance against varying illumination, facial expression and part occlusion.

Key words: Face Recognition; Wavelet Transformation(WT); Non-negative Matrix Factorization(NMF); Fisher Linear Discriminant(FLD)

1 引言

由于人脸识别在身份认证、视觉监控以及人机接口等方面有着广泛的应用前景, 从而成为近年来计算机视觉与模式识别领域极富挑战性的研究热点。近 20 年来, 许多研究者在人脸识别领域进行了深入研究并提出了很多有效的方法。按照识别特征的不同, 基本上可以分为基于几何特征的方法^[1,2]、基于统计的特征脸方法^[3]、基于神经网络的方法^[4,5]、基于小波的模板匹配方法^[6]和它们的混合方法。其中 Fisher 线性判别(FLD)^[7]方法能在低维子空间中形成很好的分类, 对于遮掩物和光照具有好的容错性, 从而也较好地解决了特征脸方法^[3]中对遮掩物和光照较敏感的缺点。

Lee 和 Seung 提出了不同于传统 PCA 的非负矩阵分解(NMF)方法^[8], 通过 NMF 可以提取人脸的各种局部特征。非负稀疏矩阵分解(NMFs)^[9]是在 NMF 基础上的一种改进。通

过将一个非负的矩阵分解为左右两个非负矩阵的乘积, 控制分解后矩阵的稀疏度, 即使在无监督的情况下也能很好地表征原始数据的局部特征。该方法具有收敛速度快、左右非负矩阵存储空间小的特点; 同时, 能将高维的数据矩阵降维处理, 适合处理大规模数据。事实上, 心理学和生理学有依据表明, 人的大脑具有能发现基于局部表征的能力^[10,11]。因此, 很有必要研究基于局部表征的人脸识别方法。

采用小波变换(WT)特征来描述人脸的信息, 与视网膜对图像的响应相类似, 在一定程度上容忍光线和角度的干扰。应用小波变换抽取特征, 对人脸进行低维表达, 在很大程度上克服了人脸姿态变化、表情变化和头饰变化对人脸识别的影响, 对于细微表情变化具有一定的不变性, 同时也保留了空间位置信息。这样, 既能捕获到人脸的实质特征, 同时也有效地降低了计算复杂性。早期的研究认为人脸的空间低频段信息在人脸识别中起主要作用。Nastar 等人^[12,13]研究了人脸外观变化与频谱变化之间的关系, 指出人脸的光照、少许遮挡、旋转扭曲和面部表情只影响图像中高频部分的变化, 而人脸图像的低频部分在这样的变化下仍然保持稳定, 因此, 基于小波的方法成了人脸识别中的一种新的趋势; Lai^[14]提出了运用光谱脸和小

收稿日期: 2005-08-12; 修返日期: 2005-09-27

基金项目: 国家自然科学基金资助项目(60471055); 电子科技大学青年基金资助项目(L08010601JX04030)

波变换、傅里叶变换结合的整体表征的方法; Li^[15] 提出用小波技术和特征脸相结合的方法来提取特征进行人脸识别; Chien^[16] 提出用可分辨的小波脸和最近邻特征分类方法进行人脸识别。

2 人脸图像小波预处理

小波变换具有多分辨率、多尺度分析的特点, 而且在时频两域都具有表征信号局部特征的能力, 被誉为“数学显微镜”。给定平方可积的信号 $f(t)$, 即 $f(t) \in L^2(R)$, 则 $f(t)$ 的连续小波变换定义为

$$W_f(a, b) = \int_{-\infty}^{\infty} f(t) \overline{\psi_{a,b}(t)} dt \quad (1)$$

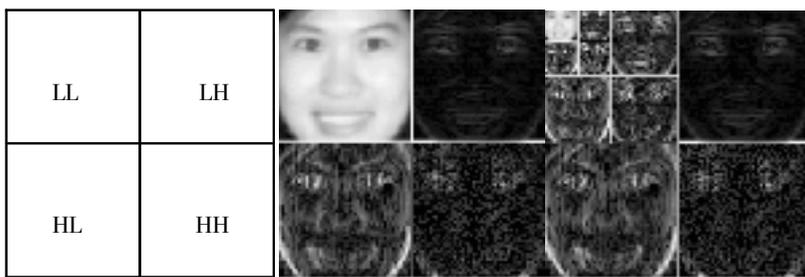
这里, 小波基函数

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad a, b \text{ 均为常数, 且 } a > 0 \quad (2)$$

如果取尺度 $a = 2^n$, $b \in Z$ 可实现对式(1)的离散化, 这样就可以利用金字塔算法^[19] 在计算机中实现小波变换。对信号进行小波变换时, 如果选择了正交小波基(如 Daubechies 基、Symmlets 基), 得到的小波系数是相互独立的, 也就得到了原始信号的一系列不同的特征。

通过二维离散小波分解图像后, 不同方向的子图分辨率减少, 计算复杂度就相应减少。适当层次小波变换后的低频子图像刻画了人脸的表情和姿势的不变特征, 有较好的稳定性。对人脸图像先进行小波分析的目的是降维和图像滤波, 从而降低计算复杂度, 并滤掉人脸的情感变化因素及眼镜、发型等不必要的细节对识别产生的影响。

本文使用 DB6 小波作为小波基函数先对人脸样本进行小波分解, 如图 1(a) 的四个部分(LL, LH, HL, HH)。其中, LL 是水平方向和垂直方向的低通滤波后的小波系数, 它基本上包含了原有图像的信息, 同时在这个区域中, 随机噪声和冗余信息已被大大压制; LH 是水平方向的低通滤波和垂直方向的高通滤波后的小波系数, 主要包括了水平方向的特征; HL 是垂直方向的特征, 眼睛、鼻子、嘴巴等器官的边缘和纹理对应其中的强响应, 而前额和脸颊等平滑区域则对应其中的弱响应; HH 是水平方向和垂直方向的高通滤波后的小波系数, 所包含的信息最少。所以, 对原始图像进行三层小波分解, 选用第三层的低频 LL 分量作为小波特征, 这样既保留了人脸的全局形状信息, 同时又淡化了局部细节。



(a) 一层小波分解 (b) 人脸图像一层分解 (c) 人脸图像三层分解
图 1 小波变换图像分解

3 非负稀疏矩阵分解和 Fisher 线性判别

3.1 非负稀疏矩阵分解(NMFs)

非负矩阵分解是一种新的线性矩阵分解算法, 其基本思想^[8] 就是寻找一个线性子空间 W , 使原样本 X 在 W 上的投影

H 和 X 之间的关系满足: $X = WH$, 且 W, H 中的所有元素都是非负的。由于分解前后的矩阵中仅包含非负的元素, 因此, 原矩阵 V 中的一列向量可以解释为对左矩阵 W 中所有列向量(基向量)的加权和, 而权重系数为右矩阵 H 中对应列向量中的元素。这种基于基向量组合的表示形式具有很直观的语义解释, 它反映了人类思维中局部构成整体的概念。

人脸图像集可以看成是一个非负矩阵 $X_{n \times m}$, 每一列包含了 m 张图像中的某一张的 n 个非负的像素值, 矩阵 $W_{n \times r} = [W_1, W_2, \dots, W_r]$ 表示基向量。一张训练图像可看成是基向量 $X_j = Wh_j$ 的线性组合, $h_j = [h_{1j}, h_{2j}, \dots, h_{rj}]$ 是一个 r 维的列向量, 由 r 维特征空间中的投影坐标组成。因此, 整个人脸的训练图像的矩阵可以看成

$$X = WH \quad (3)$$

其中, $W_{n \times r}$ 称为基图像, $H_{r \times m} = [h_1, h_2, \dots, h_m]$, $W, H \geq 0$ 。

Patrik^[9] 在 NMF 的基础上, 提出了非负矩阵稀疏分解方法用于人脸识别中, 能够更好地发现稳定、直观的局部特征, 并且能自由地控制分解后矩阵的稀疏度。这个算法具有收敛速度快、左右非负矩阵存储空间小的特点。它可将高维的数据矩阵降维处理, 适合处理大规模数据。

$$\begin{cases} \min_{W, H} D(X|WH) = \sum_{i,j} (X_{ij} - (WH)_{ij})^2 \\ \text{s. t. } W, H \geq 0, \text{sparseness}(w_i) = S_w, \text{sparseness}(h_j) = S_h, \forall i \end{cases} \quad (4)$$

其中, 稀疏度 $\text{sparseness}(x) = \frac{\sqrt{n} - \sum_{i=1}^n x_i / x_2}{\sqrt{n} - 1}$, n 是 x 的维数。

3.2 Fisher 线性判别 (FLD)

Fisher 线性判别方法 (FLD)^[7] 能在人脸图像的投影空间中找到最优的特征子空间, 使样本的类间散布最大、类内散布最小, 从而改善分类特征, 使得类间散布和类内散布之比最大^[7,17]。这个比值为

$$P_{\text{fld}} = \arg \max_P \frac{|P^T S_B P|}{|P^T S_W P|} = [P_1, P_2, \dots, P_k] \quad (5)$$

P_{fld} 是 $k \times r$ ($k = r$) 维矩阵, $\{P_i | i = 1, 2, \dots, k\}$ 是矩阵 $S_W^{-1} S_B$ 中 k 个最大特征值对应的特征向量。 S_B 是类间散布矩阵, 定义为

$$S_B = \sum_{i=1}^c N_i (\mu_i - \mu) (\mu_i - \mu)^T \quad (6)$$

其中, N_i 是第 i 类 C_i 的样本数, c 是类别的总数, $\mu = \frac{1}{m} \sum_{j=1}^m \mu_j$ 是全体图像的平均值, μ_i 是第 i 类 C_i 的平均值。 S_W 是类内散布矩阵, 定义为

$$S_W = \sum_{i=1}^c \sum_{u_k \in C_i} (u_k - \mu_i) (u_k - \mu_i)^T = \sum_{i=1}^c S_{W_i} \quad (7)$$

这里 S_{W_i} 是 C_i 的协方差矩阵。

4 结合 WT, NMFs 和 FLD 的人脸识别方法

人脸识别过程分为训练过程和识别过程。为了降低人脸图像的维数和减少训练时间, 同时又能保证较好的识别效率, 我们提出了这种方案: 运用三层的二维小波变换将原始的人脸图分解成子图; 在降维后的最低层子图上进行非负稀疏矩阵分解; 用 Fisher 线性判别方法对前面得到的特征向量进行处理, 得到新的 FLD 特征向量。在识别过程中, 每当一个新的

人脸样本加入, 先用小波变换对其进行分解, 然后通过比较 FLD 的特征向量之间的欧氏距离就能识别出这张人脸。

训练样本集的子空间 $S_{\text{train}} = [S_1, S_2, \dots, S_k]$ ($k = m$) 通过 FLD 变换计算^[19] 得到

$$S_{\text{train}} = P_{\text{fld}}^T H_{\text{train}} \quad (8)$$

识别过程中, 对于一张新的人脸样本 X_i , 其对应的系数 H_{test}^i 通过

$$H_{\text{test}}^i = W^+ X_i \quad (9)$$

计算得到, 其中, W 是训练过程中得到的基向量组成的矩阵, W^+ 是 W 的伪逆。用 k 最邻近分类来计算欧氏距离 d_j 。

$$d_j = \|S_j - P_{\text{fld}}^T H_{\text{test}}^i\|, (j=1, 2, \dots, k) \quad (10)$$

当最小的欧氏距离 d_q 小于某个阈值, 就认为这个测试样本属于第 q 类, 否则就是未定的。

整个识别过程如图 2 所示。对于给定的已知身份的训练图像集和未知身份的测试图像集, 通过特征的选择、分类以及模式匹配识别出测试图像集中每张人脸所对应的训练图像集中人脸的身份。

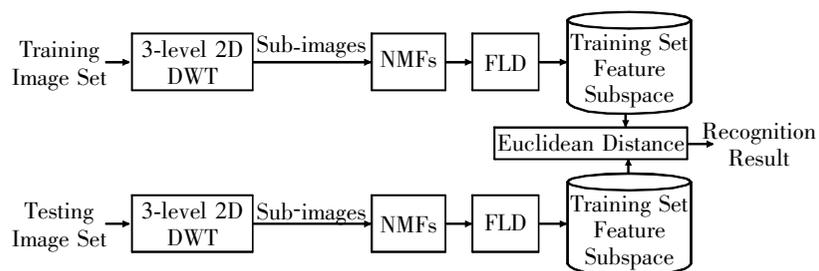


图 2 人脸识别的框架

算法描述如下:

(1) 训练过程

给定一个人脸图像的训练集 $X_i (i=1, 2, \dots, N)$, 对其进行适当层次的小波分解, 从而获得每幅训练图像的低频子图像, 对应的小波系数为 $X_i (i=1, 2, \dots, N)$ 。

利用 NMFs 方法, 由 $X_{\text{train}} = [X_1, X_2, \dots, X_N] = WH_{\text{train}}$ 得到 W 和 H_{train} , 计算由 h_1, h_2, \dots, h_N 构成的类内散布矩阵和类间散布矩阵 S_w 和 S_b , 然后计算对应矩阵的 $S_w^{-1} S_b$ 的 r 个最大特征值对应的特征向量 $p_1^{\text{fld}}, p_2^{\text{fld}}, \dots, p_r^{\text{fld}}$ 。由这 r 个最大特征值对应的特征向量构成 FLD 投影矩阵 $P_{\text{fld}} = [p_1^{\text{fld}}, p_2^{\text{fld}}, \dots, p_r^{\text{fld}}]$ 。

利用 FLD 投影矩阵 P_{fld} 可得到分类特征, 即 $S_i = [s_1, s_2, \dots, s_r]^T = P_{\text{fld}}^T h_i (i=1, 2, \dots, N)$ 。

根据这些对应人脸图像训练集的分类特征向量 $s_1, s_2, \dots, s_i, \dots, s_N$ 组成 c 类人脸识别数据库, 存储所有训练样本的特征向量。为表达方便起见, 在此我们不妨假设由这 N 个最佳分类特征向量 $s_1, s_2, \dots, s_i, \dots, s_N$ 组成的 c 类人脸识别数据库中的标准样本向量为 $s^{(1)}, s^{(2)}, \dots, s^{(c)}$ 。

(2) 识别过程

给定一个待识别的人脸图像, 对其进行适当层次的小波分解, 从而获得它的低频子图像, 对应的小波系数为 x 。

计算 $h = W^+ x$, W^+ 是训练过程中 NMFs 分解中 W 的伪逆。对 h 利用 FLD 投影矩阵 P_{fld} 可得到分类特征, 即 $s = P_{\text{fld}}^T h$ 。

找到与待识别图像最接近的训练集(数据库)中的人脸类。计算欧几里德距离 $d_q = \min_j \|s - s^{(j)}\|$, 当 d_q 小于某一个阈值时, 就把这张脸划分到第 q 类。

5 实验结果

采用 ORL 标准人脸图像数据库进行人脸识别的仿真实验。该数据库中有 40 个受试者, 每个受试者有 10 幅图像, 因此共有 400 幅图像。图像的表情、姿态、光照变化都非常大, 所有的图像为实验者的正脸, 带有一定程度的朝上、下、左、右的偏转或倾斜; 对表情不作任何限制, 面部表情(张开/合拢)、眼睛(微笑/不微笑)和面部细节(戴眼镜/不戴眼镜); 大多数人的照片是在不同的时间和不同的光照但背景总为黑色的条件下得到的。图 3 为该数据库的部分人脸图像。我们的实验数据是数据库中图像转成大小为 92×112 具有 8bits 灰度级的图片。实验随机选取每个受试者的五幅人脸图像作为训练集, 剩余五幅归为测试集, 运用 Daubechies D6 对图像进行三层二维小波分解, 得到 23×21 的 LL 子图。取基向量矩阵 W 的稀疏度为 0.7。



图 3 部分人脸图像

(1) 实验 1。对平均识别效率和平均计算时间的比较。用 MATLAB 7.0 编程, 在 P4 2.66GHz, 512MB 内存的 PC 机上运行 600 次。结果如表 1 所示。表 1 是运用小波变换、WNMFs 方法在第三层的四个子图的平均识别率和平均时间, 识别率按 LL, LH, HL, HH 的顺序排列, 因此我们选取 LL 子图进行识别。表 2 是对三种方法的比较, 结合表 1 可以看出, 运用了小波变换后, 基于小波分解的非负稀疏矩阵分解方法比不用小波处理的非负稀疏矩阵分解方法具有很大的计算速度优势, 很大程度上降低了计算的复杂性, 而且 LL 子图的识别率保持在原来的水平或者提高了一点。

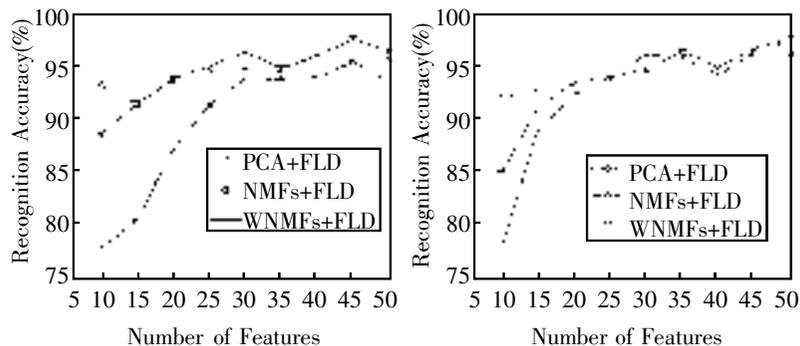
表 1 运用小波后, 在 23×21 分辨率的子图上的平均识别率和平均时间

Data	平均识别率 (%)	平均计算时间 (s)
	WT + NMFs + FLD	WT + NMFs + FLD
LL	96.833	49.844
LH	55.083	49.802
HL	46.667	49.105
HH	21.583	51.268

表 2 平均识别率和平均计算时间的比较

方法	平均识别率 (%)	平均计算时间 (s)
PCA + FLD	95.75	13.825
NMFs + FLD	94.417	218.287
WT + NMFs + FLD	96.833	49.844

(2) 实验 2。对每幅图像先进行三层小波分解, 取低频子图像 LL。识别结果如图 4 (a) 所示, 最高识别率可达 96.917%, 同时我们还将它与 PCA + LDA 方法和 NMFs + FLD 的方法进行了比较。当特征数很少时, PCA + FLD 的方法效果略好, 这是由于非负稀疏矩阵分解是基于局部特征的, 在特征很少的情况下并不能很好地表征实质人脸。总体上来说, 实验表明本文提出的 WNMFs 方法识别率略优于 PCA + FLD 方法, 明显比 NMF + FLD 方法高。



(a) 在 ORL 库上平均识别率的比较结果

(b) 针对有遮挡图像的平均识别率比较结果

图 4 识别结果

(3) 实验 3。对测试样本集中的人脸进行部分遮挡, 然后进行识别。遮挡的部分图像用大小分别为 36×65 , 40×65 , 40×65 灰度片表示, 如图 3(b) 所示。分别模拟遮住眼睛、眼睛和鼻子、鼻子和嘴巴, 识别效果如图 4(b) 所示, 实验说明了我们的方法 WNMFs 对于局部的遮挡相对于其他两种方法 (PCA + FLD, NMFs + FLD) 更不敏感; 同时也能达到很好的识别效率。与没有遮挡的识别效率相差不超过 0.8%, 其最好结果可以达到 96.582%, 比 PCA + FLD 和 NMFs + FLD 的方法要好。

6 总结

本文提出了基于小波和非负稀疏矩阵分解的人脸识别方法, 其主要优点在于能够识别基于局部特征和有遮挡的人脸。运用 WNMFs 识别 ORL 库的人脸图像, 最高识别率可达到 96.917%, 同时对有遮挡的图像识别率也能达到 96.582%。实验表明, 该方法对人脸的局部表情、光照以及遮挡不敏感, 识别性能优于 PCA + LDA 方法以及 NMFs + FLD 方法, 而且在很大程度上降低了计算的复杂性。此外, 该方法比上述两种方法对于部分遮挡的人脸更不敏感。

参考文献:

- [1] Sawayama Y, Kobayashi K. A Basic Study on Human Face Recognition [A]. *Frontiers of Pattern Recognition* [M]. New York: Academic Press, 1972. 265-289.
- [2] Kanade T. *Computer Recognition of Human Faces* [M]. Basel and Stuttgart: Birkhauser, 1977.
- [3] Turk M, Pentland A. Eigenfaces for Recognition [J]. *Journal of Cognitive Neuroscience*, 1991, 3(1): 71-86.
- [4] M S Bartlett, J R Movellan, T J Sejnowski. Face Recognition by Independent Component Analysis [J]. *IEEE Trans. Neural Networks*, 2002, 13: 1450-1464.
- [5] M J Er, S Wu, H L Toh. Face Recognition with Radial Basis Function (RBF) Neural Networks [J]. *IEEE Trans. Neural Networks*, 2002, 13: 697-710.

- [6] Lades M, Vorbruggen J, Buhmann J, et al. Distortion Invariant Object Recognition in the Dynamic Link Architecture [J]. *IEEE Trans. Comput*, 1993, 42(3): 300-311.
- [7] P N Belhumeur, J P Hespanha, D J Kriegman. Eigenfaces Versus Fisherfaces: Recognition Using Class Specific Linear Projection [J]. *IEEE Trans. Pattern Anal. Machine Intell.*, 1997, 19: 711-720.
- [8] D D Lee, H S Seung. Learning the Parts of Objects by Non-negative Matrix Factorization [J]. *Nature*, 1999, 401(6755): 788-791.
- [9] O H Patrik. Non-negative Matrix Factorization with Sparseness Constraints [J]. *Journal of Machine Learning Research*, 2004, (5): 1457-1469.
- [10] E Wachsmuth, M W Oram, D I Perrett. Recognition of Objects and Their Component Parts: Responses of Single Units in the Temporal Cortex of the Macaque [J]. *Cereb. Cortex*, 1994, 4: 509-522.
- [11] S Z Li, X Hou, H Zhang, et al. Learning Spatially Localized Part-based Representations [C]. Hawaii: Proc. of IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), 2001. 207-212.
- [12] C Nastar, B Moghaddam, A Pentland. Flexible Images: Matching and Recognition Using Learned Deformations [J]. *Comput. Vision Image Understanding*, 1997, 65(2): 179-191.
- [13] C Nastar, N Ayache. Frequency-based Non-rigid Motion Analysis [J]. *IEEE Trans. Pattern Anal. Mach. Intell.*, 1996, 18(11): 1067-1079.
- [14] J H Lai, P C Yuen, G C Feng. Face Recognition Using Holistic Fourier Invariant Features [J]. *Pattern Recognition*, 2001, 34: 95-109.
- [15] B Li, Y Liu. When Eigenfaces are Combined with Wavelets [J]. *Knowl. Based Syst.*, 2002, 15: 343-347.
- [16] J T Chien, C C Wu. Discriminant Waveletfaces and Nearest Feature Classifiers for Face Recognition [J]. *IEEE Trans. Pattern Anal. Machine Intell.*, 2002, 24: 1644-1649.
- [17] A M Martinez, A C Kak. PCA versus LDA [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(2): 228-233.
- [18] X R Pu, Zhang Yi, et al. Face Recognition Using Fisher Non-negative Matrix Factorization with Sparseness Constraints [C]. Chongqing: The 2nd International Symposium on Neural Networks (ISNN), 2005. 112-117.
- [19] S Mallat. A Theory of Multiresolution Signal Decomposition: The Wavelet Representation [J]. *IEEE Trans. Pattern Anal. Mach. Intell.*, 1989, 11: 674-693.

作者简介:

欧阳怡彪(1978-), 男, 湖南隆回人, 硕士研究生, 主要研究方向为数据挖掘、生物特征识别; 蒲晓蓉(1969-), 女, 四川射洪人, 博士研究生, 主要研究方向为计算智能、生物特征识别; 章毅(1963-), 男, 四川邛崃人, 教授, 博导, 主要研究方向为神经网络、数据挖掘、计算智能等。

(上接第 158 页)

- [4] 赵雪春, 戚飞虎. 基于彩色分割的汽车自动识别技术 [J]. *上海交通大学学报*, 1998, 32(10): 4-9.
- [5] 燕鹏, 刘长松, 丁晓青. 复杂背景下的汽车牌照自动识别系统 [J]. *电视技术*, 2005, (6): 90-93.
- [6] 叶茂亮, 刘长松, 丁晓青, 等. 基于笔画分析和形态学的汽车牌照定位算法 [J]. *电视技术*, 2005, (5): 85-87.
- [7] 崔屹. 图像处理与分析——数学形态学方法及应用 [M]. 北京: 科学出版社, 2000. 1-50.
- [8] Jun-Wei Hsieh, Shih-Hao Yu, et al. Morphology-based License Plate Detection from Complex Scenes [C]. *IEEE*, 2002. 176-179.
- [9] 周妮娜, 王敏, 黄心汉, 等. 车牌字符识别的预处理算法 [J]. *计算机工程与应用*, 2003, 39(15): 220-221, 232.

- [10] 张引, 潘云鹤. 面向车辆牌照字符识别的预处理算法 [J]. *计算机应用研究*, 1999, 16(7): 85-87.

- [11] 张玉姣, 史忠科. 一种新的车牌识别预处理算法 [J]. *西北工业大学学报*, 2002, 20(1): 83-86.

作者简介:

李波(1975-), 男, 湖北宜都人, 硕士研究生, 主要研究方向为图像处理、模式识别; 曾致远(1957-), 男, 湖北武汉人, 教授, 主要研究方向为视频技术、图像处理; 周建中(1959-), 男, 湖北武汉人, 教授, 博导, 主要研究方向为工业控制及自动化系统、模糊控制与人工智能理论; 罗勤(1978-), 男(土家族), 硕士研究生, 主要研究方向为视频监控、图像处理。