



基于特征加权 FDCT 和模糊最小二乘支持向量机的虹膜识别算法

何振红

(甘肃民族师范学院计算机科学系,甘肃 合作 747000)

摘要:为了克服小波变换在二维空间分析的缺陷,提出了基于快速离散曲波(Curvelet)变换的虹膜识别改进算法。利用能有效捕捉图像边缘信息的 Curvelet 变换对虹膜图像进行分解,提取低频子带系数矩阵的均值方差和高频子带能量,然后根据不同子带特征的分类能力不同,对各子带特征的离散度进行加权,为分类能力较强的特征向量赋予较大权值,构成虹膜图像的特征向量。利用最优二叉树多类模糊最小二乘支持向量机分类器进行分类与识别。仿真实验结果表明,该算法具有较高的识别性能,具有可行性。

关键词:虹膜识别;特征加权;快速离散曲波变换;模糊最小二乘支持向量机;最优二叉树

中图分类号:TP391

文献标识码:A

doi: 10.11959/j.issn.1000-0801.2016058

Iris recognition algorithm based on feature weighting fast discrete Curvelet transform and fuzzy LS-SVM

HE Zhenhong

Department of Computer Science, Gansu Normal University for Nationalities, Hezuo 747000, China

Abstract: In order to overcome the weakness of wavelet transform in two dimensional spatial analysis, an improved algorithm based on fast discrete Curvelet transform for iris recognition was proposed. Curvelet transform which can effectively capture the image edge information was introduced to decompose iris image. Mean and variance of low frequency sub-band coefficients and the energy of high frequency sub-band were extracted. Then the feature vectors were weighted according to the difference of classification ability of sub-band feature. Fuzzy least square support vector machine with optimal binary tree was developed to implement classification and recognition. The simulation results show that the proposed algorithm has higher recognition performance than the present method.

Key words: iris recognition, feature weighting, fast discrete Curvelet transform, fuzzy least square support vector machine, optimal binary tree

1 引言

虹膜纹理以其唯一性、高稳定性、高可靠性和低错误率的特点,已成为生物特征识别中极具发展潜力的身份识别技术,具有重要的研究价值和应用意义,被广泛应用于金融、企事业、公共安全等领域,成为生物识别领域中研究的热点之一。

虹膜识别包括图像采集、定位、特征提取和分类识别4个

部分。其中特征提取是虹膜识别的关键环节,决定了识别系统的性能。目前常用的虹膜特征提取方法有:Daugman^[1]利用 2D-Gabor 滤波器的局部方向性提取虹膜纹理图像的相位信息作为虹膜特征编码;Wildes^[2]利用 Laplacian 金字塔滤波器分解提取虹膜特征;Boles^[3]采用小波过零检测选取特定小波子带过零点间的小波变换积分均值构建虹膜特征;Lim^[4]等人使用 2D-Haar 小波的多尺度分解建立特征模板;Huang^[5]等人利用二维不可分小波变换,结合 Gauss-MRF 提取具有旋转不变性虹膜纹理特征;Babu^[6]等人将离散 Wavelet 变换与 ICA 相结合提取虹膜特征;Tsai^[7]等人利用 Log-Gabor 小波局部频率性编码虹膜纹理作为虹膜特征等。以上方法对虹膜识别技术的发展产生了积极推动作用。

虽然采用小波变换进行虹膜特征提取,取得了良好的效果。但是小波变换也存在缺陷性,小波变换反映点奇异性,在表示线奇异的二维图像时,不具有空间各向异性的要求,不能有效捕捉虹膜图像的边缘信息,从而影响虹膜识别的准确性。Curvelet(曲波)变换克服了小波这一局限性,除了具有小波变换多尺度特性之外,还具有多方向性和各向异性,对图像边缘特征的表达更优于小波变换。罗忠亮等^[8]利用 Curvelet 变换提取虹膜特征取得了较好的识别效果。

本文提出了一种基于快速离散曲波变换(fast discrete Curvelet transform, FDCT)的虹膜识别改进算法。利用能有效捕捉图像边缘信息的 Curvelet 变换对虹膜图像进行分解,提取低频子带系数矩阵均值方差和高频子带能量,根据不同子带特征的分类能力不同,对各子带特征的离散度进行加权,为分类能力较强的特征量赋予较大权值,构成虹膜图像的特征向量。利用最优二叉树多类模糊 LS-SVM(最小二乘支持向量机)分类器实现对特征向量的有效分类。仿真实验结果表明,该算法识别准确率较高,能有效应用于身份认证系统中。

2 快速离散 Curvelet 变换与模糊最小二乘支持向量机

2.1 快速离散 Curvelet 变换

Curvelet 变换作为一种多尺度几何分析的新方法,兼顾尺度、角度和位移信息,能构建最优逼近意义下的高维特征函数表示,从而成为图像处理领域新的研究热点。为了更好地体现 Curvelet 变换的优良特性,提升其在信号处理、统计估计等多领域的应用潜力,Candès 和 Donoho 于 2005 年提出了快速离散 Curvelet 变换理论的实现方法。

设 x 为空间域参量, r 和 θ 分别为频域极坐标的半径和角度。在空间 $L^2(R)$ 中存在平滑非负实数的径向窗函数 $W(r)$ 和角窗函数 $V(t)$, 满足可容许条件^[9]:

$$\begin{cases} \sum_{j=-\infty}^{\infty} W^2(2^j r) = 1, r \in \left(\frac{3}{4}, \frac{3}{2}\right) \\ \sum_{l=-\infty}^{\infty} V^2(t-l) = 1, t \in \left(-\frac{1}{2}, \frac{1}{2}\right) \end{cases} \quad (1)$$

对任意一个 $j \geq j_0$, 傅里叶频域的频率窗 U_j 定义如下:

$$U_j(r, \theta) = 2^{-\frac{3}{4}j} W(2^{-j} r) V\left(\frac{2^{\lfloor j/2 \rfloor} \theta}{2\pi}\right) \quad (2)$$

于是, 频域中尺度为 2^j 、旋转角度为 θ_l 、位移为 $x_k^{(j,l)}$ 的连续 Curvelet 变换定义为:

$$\varphi_{j,l,k}(x) = \varphi_j(R_{\theta_l}(x - x_k^{(j,l)})) \quad (3)$$

其中, $\theta_l = 2\pi l \times 2^{-\lfloor \frac{j}{2} \rfloor}$ ($0 \leq \theta_l < 2\pi$), $k = (k_1, k_2) \in L^2(R)$, $x_k^{(j,l)} = R_{\theta_l}^{-1}(2^{-j} k_1, 2^{-j/2} k_2)$, R_{θ_l} 表示以 θ_l 为弧度的旋转矩阵。

在图像处理中连续 Curvelet 变换不能直接使用,需将其离散化。实现过程如下^[10]。

(1) 在给定笛卡尔坐标下对图像进行二维 Fourier 变换, 得到二维频率函数 $\hat{F}[n_1, n_2]$, $-n/2 \leq n_1, n_2 \leq n/2$, n 为矩阵行数。

(2) 频域中对每一对尺度角度 (j, l) 组合重采样, 得到新的采样函数 $\hat{F}[n_1, n_2 - n_1 \tan \theta_l]$, $-\pi/4 \leq \theta_l \leq \pi/4$, 计算 $f_{j,l}[n_1, n_2] = \hat{F}[n_1, n_2 - n_1 \tan \theta_l] \times U_j[n_1, n_2]$ 。

(3) 对每一个 $f_{j,l}$ 进行二维的逆 Fourier 变换, 得到离散 Curvelet 系数 $c^D(j, l, k)$:

$$c^D(j, l, k) = \frac{1}{L_{1,j} L_{2,j}} \sum_{n_1, n_2 \in P_j} f_{j,l}[n_1, n_2] \exp\left(2\pi i l \left(\frac{k_1 n_1}{L_{1,j}} + \frac{k_2 n_2}{L_{2,j}}\right)\right) \quad (4)$$

其中, $P_j = \{(n_1, n_2) | n_{1,0} \leq n_1 < n_{1,0} + L_{1,j}, n_{2,0} \leq n_2 < n_{2,0} + L_{2,j}\}$, $L_{1,j}$ 与 $L_{2,j}$ 分别表示 $U_j(n_1, n_2)$ 的支撑区间长宽分量, 且 $L_{1,j} \approx 2^j$, $L_{2,j} \approx 2^{j/2}$ 。

2.2 模糊最小二乘支持向量机

对于二分类问题, Suykens 和 Vandewalle 提出的 LS-SVM, 采用最小二乘线性系统作为损失函数, 利用核函数将数据由输入空间映射到线性高维的特征空间, 使原样本空间中的线性不可分问题转化为高维特征空间的线性可分问题。把 SVM 中不等式约束条件转换成等式约束, 使支持向量机的求解由二次规划问题转化为低阶的对称正定线性方程组问题, 降低了求解复杂性, 提高了求解效率^[11]。但在



虹膜图像的分类识别过程中,如果训练样本中含有噪声点等“异常”信息,LS-SVM 分类过程就容易出现过学习或者欠学习现象,因而不能获取真正最优分类面。针对此情况,许亮^[12]在最小二乘支持向量机的基础上,通过引入模糊集理论,依据不同的训练样本在分类中对 LS-SVM 的贡献不同,赋予不同的模糊隶属度 τ_i ,削弱噪声点对分类产生的不利影响,以实现噪声等异常信息与有效样本区分开。

$$\tau_i = \begin{cases} \sigma \\ 1 - \frac{\|x_i - x_c\|}{\max\|x_j - x_c\|} + \varepsilon \end{cases} \quad (5)$$

其中, $\|x_i - x_c\|$ 表示训练样本点间的欧式距离, x_c 表示类中心, ε 表示极小正数, 且 $0 < \sigma < \varepsilon$ 。当训练样本点为异常数据时, 赋予其隶属度, 这样确保所有正常样本全部映射到 $[\varepsilon, 1]$ 。

假设训练样本集 T 由 n 个独立同分布样本点组成: $T = \{(x_i, y_i) | x_i \in R^n, y_i \in \{-1, 1\}\}$ 。根据结构风险最小化原理, 求解模糊 LS-SVM 最优分类面可归结为如下二次规划:

$$\begin{aligned} \min J_{\text{LS}}(w, \zeta) &= \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=1}^n \zeta_i^2 \\ \text{s.t. } y_i &= [w^T \varphi(x_i) + \delta] = 1 - \zeta_i, \quad i=1, 2, \dots, n \end{aligned} \quad (6)$$

其中, w 为权向量, γ 为正则化因子且 $\gamma > 0$, ζ_i 为松弛变量且 $\zeta_i > 0$, $\varphi(x_i)$ 表示由输入空间到高维特征空间的非线性映射, δ 为偏差量。

引入拉格朗日函数:

$$L(w, \delta, \zeta, a) = J_{\text{LS}}(w, \zeta) - \sum_{i=1}^n a_i [y_i [w^T \varphi(x_i) + \delta] - 1 + \zeta_i] - \sum_{i=1}^n \tau_i \zeta_i \quad (7)$$

根据 KKT 条件同解变换消去变量 w 和 ζ_i , 结合 Mercer 理论, 得到矩阵形式:

$$\begin{bmatrix} 0 & Y^T \\ Y & \Psi_y + \gamma^{-1} I \end{bmatrix} \begin{bmatrix} \delta \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ \bar{l} \end{bmatrix} \quad (8)$$

其中, $Y = [y_1, \dots, y_n]^T$, $\zeta = [\zeta_1, \dots, \zeta_n]^T$, $a = [a_1, \dots, a_n]^T$, $\bar{l} = [1, \dots, 1]^T$, $\Psi_y = y y^T K(x_i, x_j)$ 。

于是, 模糊 LS-SVM 分类决策函数为:

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^n \alpha_i y_i K(x_i, x) + \delta \right\} \quad (9)$$

3 基于特征加权 FDCT 与模糊 LS-SVM 的虹膜识别算法

3.1 虹膜图像预处理

虹膜图像预处理包括图像灰度化、虹膜定位、归一化

和图像增强。图像灰度化的目的是降低图像维数, 剔除图像的冗余信息, 虹膜定位在虹膜图像中确定虹膜内外边缘所在圆周的圆心和半径, 以准确分割虹膜区域。归一化是采用极坐标形式将环型虹膜图像展开成固定尺度的矩形图像, 以实现虹膜图像平移不变性及瞳孔缩放不变性。为了提高识别的效果, 采用局部动态的直方图均衡化来获得虹膜图像的增强效果。整个虹膜的预处理过程如图1所示。

3.2 特征提取

在图像识别中, 特征提取的目的是从图像中获取有助于分类识别的特征向量。Curvelet 作为多尺度几何分析新方法, 兼顾尺度、角度和位移信息, 能构建最优逼近意义下的高维特征函数表示, 从而成为图像处理领域新的研究热点。根据 FDCT 结果, 提取低频子带系数矩阵的均值方差和高频子带能量, 然后根据不同子带特征的分类能力不同, 对各子带特征的离散度进行加权, 为分类能力较强的特征向量赋予较大权值, 构成虹膜图像的特征向量。

(1) 低频子带系数矩阵的均值方差

Curvelet 分解的低频子带含有虹膜图像的基本信息, 是对虹膜图像的平滑逼近。其均值和方差表征了虹膜图像整体特征, 决定了分类准确性。

$$\mu = \frac{1}{mn} \sum_{i=-\frac{m-1}{2}}^{\frac{m-1}{2}} \sum_{j=-\frac{n-1}{2}}^{\frac{n-1}{2}} c(k_1 + i, k_2 + j) \quad (10)$$

$$\sigma = \sqrt{\frac{1}{mn} \sum_{i=-\frac{m-1}{2}}^{\frac{m-1}{2}} \sum_{j=-\frac{n-1}{2}}^{\frac{n-1}{2}} [c(k_1 + i, k_2 + j) - \mu]^2} \quad (11)$$

(2) 高频子带能量

Curvelet 分解的高频子带的能量反映虹膜的斑点、收缩褶、细丝等纹理特征在不同方向、不同尺度的分布情况, 刻画了虹膜图像的边缘特征, 是最具识别性的特征之一。

$$E_{ij} = \frac{1}{m_{ij} n_{ij}} \sum_{i=-\frac{m_{ij}-1}{2}}^{\frac{m_{ij}-1}{2}} \sum_{j=-\frac{n_{ij}-1}{2}}^{\frac{n_{ij}-1}{2}} |c(k_1 + i, k_2 + j)| \frac{\sigma_{ij}}{\sum_{i=1}^{m'} \sum_{j=1}^{n'} \sigma_{ij}} \quad (12)$$

其中, $c(k_1 + i, k_2 + j)$ 为对应图像在第 i 层 j 方向子带的系数矩阵, $m \times n$ 为低频子带系数矩阵的大小, $m_{ij} \times n_{ij}$ 为第 i 层 j 方向的高频子带系数矩阵的大小, σ_{ij} 为对应层子带的方差。




图1 虹膜图像预处理

(3) 特征加权

对虹膜图像进行 FDCT 获取的是虹膜图像局部特征, 针对图像不同子带系数矩阵分类能力不同, 对各子带系数矩阵离散度进行加权, 为分类能力较强的特征向量赋予较大权值, 分类能力较弱的特征向量赋予较小权值。通过特征加权, 使利用 FDCT 提取的不同子带信息重要性反映到虹膜图像最终特征向量中。

由于经 FDCT 分解后, 各子带系数的概率分布服从广义高斯分布 (generalized Gaussian distribution, GGD) 模型, 因而可以利用零均值 GGD 描述 FDCT 系数概率分布, 用极大似然准则估计法估算 GGD 的尺度参数和形状参数。

令 GGD 概率分布函数为 $g(x, \xi, \delta) = \frac{\delta}{2\xi\Gamma\left(\frac{1}{\delta}\right)} e^{-\left(\frac{|x|}{\xi}\right)^\delta}$ 。其

中, $\Gamma(x) = \int_0^\infty t^{x-1} e^{-t} dt$ 为 Gamma 函数, ξ 为尺度参数, δ 为形状参数。

构造 δ 函数:

$$f(\delta) = \frac{\chi_1^2}{\chi_2} \frac{\Gamma^2\left(\frac{2}{\delta}\right)}{\Gamma\left(\frac{1}{\delta}\right)\Gamma\left(\frac{3}{\delta}\right)} \quad (13)$$

其中, $\chi_1 = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n |x_{ij}|$, $\chi_2 = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n |x_{ij}|^2$ 。则 $\delta = f^{-1}\left(\frac{\chi_1^2}{\chi_2}\right)$, ξ 估计值为 $\xi = \chi_1 \frac{\Gamma\left(\frac{1}{\delta}\right)}{\Gamma\left(\frac{2}{\delta}\right)}$ 。利用尺度参数 ξ , 求得特征加权数

$$w_{ij} = K \frac{\xi_{ij}}{\sum_{i=1}^m \sum_{j=1}^n \xi_{ij}}。$$

利用特征加权后的低频子带系数矩阵的均值 $\hat{\mu} = \mu w_{ij}$ 、方差 $\hat{\sigma} = \sigma w_{ij}$ 和高频子带能量 $\hat{E}_{ij} = E_{ij} w_{ij}$, 构造用于分类识别的特征向量 $\hat{F} = [\hat{\mu}, \hat{\sigma}, \hat{E}_{ij}]$ 。

3.3 分类识别

利用特征加权 FDCT 提取虹膜的特征向量后, 选择合适的分类算法进行分类识别至关重要。目前采用支持



向量机对特征向量进行分类识别较为普遍。SVM 通过使用核函数将输入数据信息映射到高维的特征空间,使非线性模式转化为线性可分模式,较好地解决了高维非线性小样本模式识别和函数估计等实际问题。当 SVM 的训练复杂度高、样本数据量大时,求解二次规划问题就越复杂。针对上述不足,采用模糊 LS-SVM 把 SVM 的训练转化为线性方程组的求解,在一定程度上加速了 SVM 的训练。

目前应用较多的多类分类算法有一对一模糊 LS-SVM 和一对多模糊 LS-SVM 算法,但这些算法在测试样本数和类别数较多时,算法时间复杂度较大。为此,本文利用聚类类距离为二叉树生成依据,提出了最优二叉树多类模糊 LS-SVM 分类算法。

设虹膜图像训练样本集 $T=\{(x_i, y_i) | x_i \in R^n, y_i = \pm 1, i=1, 2, \dots, n\}$, M 为类别数。则第 m 类样本子集的均值表示为

$$T_m = \frac{1}{n_m} \sum_{i=1}^{n_m} x_i^{(m)}.$$

步骤 1 依据给定 M 类训练样本构造 M 棵二叉树集合 $BT=\{T_1, T_2, \dots, T_M\}$, 每棵二叉树 $T_i (i=1, 2, \dots, M)$ 带有一个权值为 Δ_i 的根节点, 它的左、右子树均为空。其中, $\Delta_i = \min\{\|T_i - T_j\|^2\}$, $i, j=1, 2, \dots, M$ 且 $i \neq j$ 。

步骤 2 在 BT 中选取两棵最小权值根节点的二叉树 (T_i 和 T_j) 为左、右子树构造一棵新的二叉树 $T_{New, i}$, 其左子树根节点对应样本为正类, 右子树根节点对应样本为负类, 训练模糊 LS-SVM, 同时新生成的二叉树根节点的权值为其左、右节点的权值之和。

步骤 3 在 BT 中删除 T_i 和 T_j , 同时将 $T_{New, i}$ 加入 BT 中。

步骤 4 重复步骤 2 和步骤 3, 直到 BT 中只有一棵树, 此时所生成的二叉树即所求。

对测试样本从根节点出发, 依次经若干个两类模糊 LS-SVM 分类器到达某一叶节点, 则该节点对应的类即该测试样本的类别。

4 实验结果与分析

为了验证本文算法的性能, 实验在 Intel Core2 Duo CPU E7600, 3.06 GHz, 3.0 GB 内存, MATLAB 7.1 编程环境的 PC 上进行, 采用中国科学院自动化研究所模式识别国家重点实验室虹膜图像数据库 CASIA(V2) 中的虹膜样本进行测试。CASIA 包括了 40 个人的虹膜图像, 每人 10 幅, 共 400 幅虹膜图像标本, 分辨率为 640 dpix 480 dpi。实验选取

各类虹膜前 7 幅图像为训练样本, 后 3 幅虹膜图像为测试样本。在特征提取阶段, 将训练样本和测试样本采用特征加权 FDCT 进行分解, 获得 Curvelet 变换系数。每幅虹膜图像分别选取 16、64、256、1 024、4 096 个数, 做 5 组实验。通过错误接受率 (FAR)、错误拒绝率 (FRR) 和正确识别率 (CRR) 3 个指标进行比较, 实验结果见表 1。

表 1 性能比较

实验	Curvelet 变换 系数个数	错误 接受率	错误 拒绝率	正确 识别率
第 1 组实验	16	2.95%	2.36%	94.69%
第 2 组实验	64	1.86%	1.41%	96.73%
第 3 组实验	256	0.91%	0.58%	98.51%
第 4 组实验	1 024	0.86%	0.42%	98.72%
第 5 组实验	4 096	1.69%	1.23%	97.08%

特征加权 FDCT 算法训练虹膜样本图像, 其编码长度由 Curvelet 变换系数个数决定。系数数目将直接影响识别算法性能, 系数数目过少或过多都会增大等错率 (EER)。系数数目过少, 提取预处理后的虹膜图像序列会丢失太多虹膜图像纹理信息; 系数数目过多, 提取预处理后的虹膜图像序列会包含大量噪音信号。实验结果表明, Curvelet 变换系数数目为 1 024 个时, 可获得最佳识别效果。

选取径向基核函数 $K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / 2\alpha^2)$ 作为模糊 LS-SVM 的核函数, 采用双线性法对 280 幅训练样本图像进行实验。正则化参数 γ 和径向基宽度 α 对识别准确率有较大影响, 如图 2 所示。 γ 过大或 α^2 过小都会导致过拟合现象。当 $\gamma=10, \alpha^2=0.9$ 时, 取得了较低等错率 (0.81%)。




图 2 EER 与 γ, α^2 的分布曲线

为了进一步验证本文算法的效果和性能,将该算法与基于小波变换的虹膜识别算法进行对比实验。实验采用识别准确率较高且变换速度较快的 Gabor 小波和 Haar 小波,对虹膜图像进行 3 层分解,提取虹膜纹理特征,分别采用海明距离 (Hamming distance, HD)、SVM、最优二叉树多类模糊 LS-SVM 进行分类识别,实验结果见表 2。

通过对表 2 实验结果的分析可知,基于特征加权 FDCT 和模糊最小二乘支持向量机的虹膜识别算法的性能优于采用小波变换的虹膜识别算法,识别结果相对于小波算法的识别准确率略有提高,最佳识别率可达 98.72%,而 Gabor 小波和 Haar 小波算法最佳识别率分别为 96.22%、94.63%。实验验证,基于特征加权 FDCT 的虹膜识别算法具有较好稳定性和较强顽健性。

为了更好地评价算法的优劣,采用 ROC 曲线进行比较。ROC 曲线越接近坐标轴,说明匹配性能越好。对 CASIA (V2) 虹膜数据库图像采用 Gabor 小波、Haar 小波、特征加权 FDCT 的 ROC 曲线如图 3 所示。从图 3 可知,与 Gabor 小波和 Haar 小波的虹膜图像纹理特征提取算法相比,在同一相似度量度的情况下,本文提出的基于特征加权 FDCT 的特征提取算法,在相同错误接受率下,错误拒绝率更小,这表示虹膜识别性能得到提高。这是因为特征加权 FDCT 在提取虹膜纹理特征尺度信息的同时,也提取其角度和位移信息,细化了虹膜纹理信息的表达。因此,本文提出的算法,提取虹膜纹理特征性能更好,识别准确率更高。

5 结束语

快速离散 Curvelet 变换具有紧支撑框架结构,可实现对二维图像线奇异的“最优”稀疏表示,其非线性逼近误差可达到 $o(\sqrt{1bM}/M^2)$ 。在提取虹膜图像纹理特征的算法




图 3 ROC 曲线

中,基于特征加权 FDCT 能有效捕捉虹膜图像的边缘信息,从而提高了虹膜识别的准确性。本文研究工作还有可改进的地方,下一步将继续完善相关算法,将小波变换和曲波变换的优点相结合,提取虹膜图像的纹理特征,采用多类分类器融合算法进行分类识别,以期获得更高的识别效果。

参考文献:

[1] DAUGMAN J. The importance of being random: statistical principles of iris recognition[J]. Pattern Recognition, 2003, 36(2): 279-291.

[2] WILDES R P. Iris recognition: an emerging biometric technology[J]. Proceedings of the IEEE, 1997, 85(9): 1348-1363.

[3] BOLES W W. Security system based on human iris identification using wavelet transform [J]. Engineering Applications of Artificial Intelligence, 1998, 11(1): 77-85.

[4] LIM S Y, LEE K, BYEON O, et al. Efficient iris recognition

表 2 算法性能对比

组别	特征提取方法	匹配方法	错误接受率	错误拒绝率	正确识别率	时间/s
1	Gabor 小波	HD	4.28%	3.25%	93.13%	2.571
	Haar 小波		4.66%	2.71%	92.63%	2.395
	特征加权 FDCT		2.13%	2.06%	95.81%	3.056
2	Gabor 小波	SVM	2.95%	1.74%	95.28%	3.196
	Haar 小波		4.28%	2.65%	93.07%	2.985
	特征加权 FDCT		1.81%	1.63%	96.56%	3.967
3	Gabor 小波	最优二叉树多类模糊 LS-SVM	1.72%	1.06%	96.22%	4.192
	Haar 小波		2.67%	1.33%	94.63%	3.938
	特征加权 FDCT		0.86%	0.42%	98.72%	4.717



- through improvement of feature vector and classifier [J]. Journal of Electronics and Telecommunication Research Institute, 2001, 23(2): 61-70.
- [5] HUANG J, YOU X G, YUAN Y, et al. Rotation invariant iris feature extraction using Gaussian Markov random fields with non-separable wavelet [J]. Neuro Computing, 2010, 73 (4-6): 883-894.
- [6] BABU N T N, VAIDEHI V. Fuzzy based iris recognition system (FIRS) for person identification[C]//International Conference on Recent Trends in Information Technology, June 3-5, 2011, Chennai, India. New Jersey: IEEE Press, 2011: 1005-1011.
- [7] TSAI C C, LIN H Y, TAUR J, et al. Iris recognition using possibilistic fuzzy matching on local features [J]. IEEE Transactions on Systems, Man and Cybernetics, 2012, 42 (1): 150-162.
- [8] 罗忠亮, 段琢华. 基于 Curvelet 变换的虹膜识别[J]. 武汉理工大学学报, 2012, 34(8): 160-164.
- LUO Z L, DUAN Z H. Iris recognition based on the second generation Curvelet transform[J]. Journal of Wuhan University of Technology, 2012, 34(8): 160-164.
- [9] STARCK J L, MURTAGH F, CANDÈS E J, et al. Gray and color image contrast enhancement by the Curvelet transform[J]. IEEE Transactions on Image Processing, 2003, 12(6): 706-717.
- [10] CANDÈS E J, DEMANET L, DONOHO D L, et al. Fast discrete Curvelet transforms[J]. Multiscale Modeling & Simulation, 2006, 5(3): 861-899.
- [11] SUYKENS J A K, VANDEWALLE J. Least squares support vector machine classifiers[J]. Neural Processing Letter, 1999, 9(3): 293-300.
- [12] 许亮. 改进的模糊最小二乘支持向量机模型[J]. 计算机工程, 2009, 35(14): 236-240.
- XU L. Improved fuzzy least squares support vector machines model[J]. Computer Engineering, 2009, 35(14): 236-240.

[作者简介]



何振红(1979-),女,甘肃民族师范学院计算机科学系讲师,主要研究方向为图像处理、模式识别。