



基于广义高斯分布 FDCT_Wrap 和 FSVM 的虹膜识别

何振红

(甘肃民族师范学院计算机科学系, 甘肃 合作 747000)

摘要: 为了提高虹膜识别的准确率, 提出了一种改进曲波变换的虹膜识别算法。首先对预处理后的虹膜图像进行 Wrapping 算法的快速离散曲波变换, 提取不同尺度和不同方向的曲波子带系数矩阵的均值、方差和能量, 然后利用广义高斯分布估算各子带的权值, 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。最后采用模糊支持向量机和二叉决策树相结合的分类器进行匹配识别。采用 UBIRIS 和 CASIA 虹膜数据库对算法性能进行测试。实验结果表明, 该算法能更好地提高虹膜识别准确率和效率, 具有可行性。

关键词: 广义高斯分布; 虹膜识别; 曲波变换; 模糊支持向量机; 二叉决策树

中图分类号: TP391

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2016200

Iris recognition based on generalized Gaussian distribution FDCT_Wrap and FSVM

HE Zhenhong

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

Abstract: In order to improve the accuracy rate of iris recognition, an improved curvelet transform algorithm for iris recognition was proposed. Firstly, the iris image was decomposed with fast discrete curvelet transform by wrapping algorithm. Mean variance and energy of curvelet sub-band coefficients in different scales and different orientations were extracted. The weights of sub-bands were estimated by generalized Gaussian distribution. The feature vectors with stronger classification ability had large weight, which were calculated to constitute feature vectors of iris image. Finally, feature vectors were matched and recognized by classifier combined with fuzzy support vector machine and binary decision tree. The algorithm performances were tested with UBIRIS and CASIA iris database. Simulation results show that the proposed algorithm has higher recognition accuracy rate and efficiency. It is feasibility.

Key words: generalized Gaussian distribution, iris recognition, curvelet transform, fuzzy support vector machine, binary decision tree

1 引言

近年来, 随着小波技术的发展, 采用小波变换进行虹膜特征提取取得了良好的效果^[1-7]。但是小波变换具有各向

同性, 在表示线奇异的二维图像时, 不满足空间各向异性的要求, 从而影响虹膜识别的准确性。curvelet(曲波)变换能有效弥补小波变换的不足, 以边缘曲线为基本元素, 体现出多方向性和各向异性, 能更好地表示虹膜图像的边

收稿日期: 2015-12-24; 修回日期: 2016-07-12

基金项目: 甘肃省高等学校科研项目(No.2015B-119)

Foundation Item: Scientific Research Project in Gansu Provincial Colleges and Universities(No.2015B-119)

信息。因此利用 curvelet 变换提取虹膜特征比小波变换更实际有效。Rahulkar 等人^[5]提出了一种基于快速离散 curvelet 变换的虹膜特征提取算法。该算法将归一化的虹膜图像划分为 6 个子图像,对每个子图像进行 curvelet 变换,提取 curvelet 系数的定向能量作为子图像的特征向量。在 UBIRIS V1 和 CASIA-Iris V2.0 数据库中进行实验,分别获得 97.73% 和 97.81% 的识别准确率,比 Gabor 小波算法和 Haar 小波算法的识别效果好。但该方法在眼睑和睫毛遮挡较严重的情况下表现一般。

为了更好地消除采集到的虹膜图像中不感兴趣信息因素对虹膜特征提取的影响,本文提出一种基于广义高斯分布 Wrapping 算法的快速离散 curvelet 变换虹膜识别算法。首先对预处理后的虹膜图像进行 Wrapping 算法的快速离散 curvelet 变换,提取不同尺度和不同方向的 curvelet 子带系数矩阵的均值、方差和能量,然后利用广义高斯分布 (generalized Gaussian distribution, GGD) 估算各子带的权值,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。最后采用模糊支持向量机 (fuzzy support vector machine, FSVM) 和二叉决策树相结合的分类器进行分类识别。采用 UBIRIS 和 CASIA 虹膜数据库对算法进行性能测试,实验结果表明,该方法提取的特征向量维数较少,相比小波变换具有较高的识别率和良好的顽健性。

2 基于广义高斯分布 FDCT_Wrap 和 FSVM 的虹膜识别

一个典型的虹膜识别系统由虹膜图像采集、虹膜预处理、虹膜特征提取、匹配识别 4 个主要部分组成,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。因此,本文重点阐述虹膜识别中的特征提取和匹配识别。

2.1 虹膜预处理

虹膜图像在采集的过程中,由于受光照、眼睑、睫毛等因素的影响,采集到的图像会含有不同程度的噪声,为了准确地将虹膜纹理区域从采集到的虹膜图像中分割,消除不利因素对虹膜特征提取及匹配识别的影响,要先进行虹膜预处理。虹膜预处理包括图像灰度化、虹膜定位、归一化和图像增强。整个虹膜的预处理过程如图 1 所示。

2.2 虹膜特征提取

2.2.1 Wrapping 算法的快速离散 curvelet 变换

Candès 和 Donoho 在脊波 (ridgelet) 变换基础上提出了曲波变换,之后又提出快速离散曲波变换 (fast discrete curvelet transform, FDCT)。FDCT 采用新框架结构,减少了参数,实现起来更加快速、简单。根据实现方法的不同,可分为基于 Wrapping 算法的快速离散曲波变换 (FDCT_Wrap) 和基于非均匀空间抽样二维 FFT 算法的快速离散曲波变换 (FDCT_USFFT)。本文采用 FDCT_Wrap 方法^[8],实现过程如下:

- 在给定笛卡尔坐标下对图像 $F[t_1, t_2] \in L^2(R)$ ($0 \leq t_1, t_2 < \omega$, ω 为频域参量) 进行二维 Fourier (傅里叶) 变换,得到二维频率函数 $F[n_1, n_2]$, $-n/2 \leq n_1, n_2 < n/2$ (n 为矩阵行数);
- 在频域中对每一对尺度方向 (j, l) 组合重采样,得到新的采样函数 $F[n_1, n_2 - n_1 \tan \theta_l]$, $-\pi/4 \leq \theta_l \leq \pi/4$;
- 计算 $f_{j,l}[n_1, n_2] = F[n_1, n_2 - n_1 \tan \theta_l] \times U_j[n_1, n_2]$, 其中, $U_j(n_1, n_2)$ 为窗函数;
- 围绕原点使用 Wrapping 算法做局部化处理;
- 对每一个 $f_{j,l}$ 进行二维逆 Fourier 变换,得到离散 curvelet 系数 $c^D(j, l, k)$, D 代表 discrete。

其中, j, l, k 分别为尺度参量、方向参量、位移参量。

2.2.2 特征提取

对预处理的虹膜图像进行 Wrapping 算法的快速离散




图 1 虹膜图像预处理过程



curvelet 变换, 得到不同尺度和不同方向的 curvelet 子带, 图 2 为 curvelet 变换各层系数重构结果。虹膜图像经 curvelet 变换后, 被划分为 5 个尺度层。第 1 层为 coarse 尺度层, 由低频系数组成, 包含虹膜图像的基本信息, 反映虹膜图像概貌; 第 2、3、4 层为 detail 尺度层, 每层系数被分解为 4 个方向, 由中、高频系数组成, 体现虹膜图像的细节信息和边缘特征; 第 5 层为 fine 尺度层, 由高频系数组成, 反映虹膜的斑点、收缩褶、细丝等纹理特征的分布情况及边缘特征。分别计算每层系数矩阵的均值、方差和能量, 计算式分别为式(1)~式(3)。

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

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

$$E_i = \frac{1}{mn} \sum_{i=-(m-1)/2}^{(m-1)/2} \sum_{j=-(n-1)/2}^{(n-1)/2} |c(k_1+i, k_2+j)| \times \frac{\sigma_i}{\sum_{i=1}^m \sum_{j=1}^n \sigma_i} \quad (3)$$

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, $m \times n$ 为子带系数矩阵的大小。

curvelet 变换各层系数重构结果如图 2 所示。

对虹膜图像进行 FDCT_Wrap 获取虹膜图像局部特征后, 针对图像不同子带系数矩阵分类能力的不同, 利用广




图 2 curvelet 变换各层系数重构结果

义高斯分布估算各子带的权值, 为分类能力较强的特征向量赋予较大权值, 为分类能力较弱的特征向量赋予较小权值。通过特征加权, 将利用 FDCT_Wrap 提取的不同子带信息的重要性反映到虹膜图像最终特征向量中。

GGD 概率分布函数为:

$$g(x, \xi, \delta) = \frac{\delta}{2\xi\Gamma(1/\delta)} e^{-(|x|/\xi)^\delta} \quad (4)$$

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

构造 δ 函数:

$$f(\delta) = \frac{\chi_1^2}{\chi_2} = \frac{\Gamma^2(2/\delta)}{\Gamma(1/\delta)\Gamma(3/\delta)} \quad (5)$$

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:

$$\delta = f^{-1}(\chi_1^2 / \chi_2) \quad (6)$$

ξ 估计值为:

$$\xi = \chi_1 \frac{\Gamma(1/\delta)}{\Gamma(2/\delta)} \quad (7)$$

利用尺度参数 ξ , 求得特征加权数值为:

$$w_i = K \frac{\xi_i}{\sum_{i=1}^k \xi_i} \quad (8)$$

经特征加权后的不同尺度和方向的 curvelet 子带系数矩阵的均值、方差和能量分别为 $\hat{\mu}_i = \mu_i w_i$, $\hat{\sigma}_i = \sigma_i w_i$, $\hat{E}_i = E_i w_i$ 。由此获得每层特征向量 $v_i = \{\hat{\mu}_i, \hat{\sigma}_i, \hat{E}_i\}$, 融合每层特征向量 v_i 为用于匹配识别的特征向量 $V = \bigcup_{i=1}^k \{v_i\}$ (k 为通道数量)。

2.3 匹配识别

2.3.1 模糊支持向量机原理

Vapnik 等人^[9]提出的统计学习理论的支持向量机 (support vector machine, SVM), 通过引入结构风险, 在寻找最优分类超平面作为决策函数的前提下, 将分类问题转化为线性约束的凸二次规划。针对小样本问题, 支持向量机已成为当前模式识别领域中的优选分类器, 实现对假设函数集的控制, 使学习机在经验风险和过拟合之间取折中, 获得较好的推广能力。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, 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, Lin 等人^[10]提出了模糊支持向量机, 引入模糊集理论, 依据不同的训练样本在分类中对

SVM 的贡献不同,赋予不同的模糊隶属度 $\tau_i^{[10]}$,来削弱噪声点对分类的不利影响,以区分噪声等异常信息与有效样本。

$$\tau_i = \begin{cases} \sigma, \tau_i \text{ 极小时} \\ 1 - \frac{\|x_i - x_c\|}{\max \|x_j - x_c\|} + \varepsilon, \text{ 其他} \end{cases} \quad (9)$$

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 $[\varepsilon, 1]$ 区间上。

设 n 个独立同分布训练样本集 $X = \{(x_i, y_i, \tau_i) | x_i \in R^n, y_i = \pm 1, \tau_i \in [\varepsilon, 1], i = 1, \dots, n\}$ 和核函数 $K(x_i, x_j)$, 根据统计学习理论,求解 FSVM 最优分类面可归结为如下二次规划:

$$\min J_F(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \tau_i \xi_i \quad (10)$$

$$\text{s.t. } y_i(w x_i + b) \geq 1 - \xi_i \quad (11)$$

其中, C 为惩罚因子且 $C > 0$, b 取类中心点的值, ξ_i 为松弛因子且 $\xi_i \geq 0$ 。

利用 Lagrange (拉格朗日) 函数,上述规划的 Wolfe 对偶规划为:

$$\min \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j y_i y_j K(x_i, x_j) - \sum_{i=1}^n a_i \quad (12)$$

$$\text{s.t. } \sum_{i=1}^n a_i y_i = 0, 0 \leq a_i \leq \tau_i C \quad (13)$$

这样模糊支持向量机的决策函数为:

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^n a_i^* y_i K(x_i, x_j) + b^* \right\} \quad (14)$$

$$\text{其中, } a^* = [a_1^*, a_2^*, \dots, a_n^*]^T, b^* = y_j - \sum_{i=1}^n y_i a_i^* K(x_i, x_j).$$

2.3.2 FSVM 与二叉决策树相结合的分类算法

当训练样本数和类别数较多时,FSVM 算法的时间复杂度较大,因而采用与二叉决策树相结合的方法来降低算法时间复杂度。

设训练样本集为 X ,总类别集为 M 。

步骤 1 定义一个二叉决策树 $Bdt = \{node(i)\}$ 。变量 $node(i)$ 包含 4 个域: $node(i).C$ 存放当前节点所包含的类别号; $node(i).P^+$ 和 $node(i).P^-$ 分别存放当前节点指向的正子节点和负子节点的指针; $node(i).S$ 表示训练的序列。令 $node(i).C = \{1, 2, \dots, M\}$ (M 为类别数), $node(i).P^+ = node(i).P^- = 0$, $node(i).S = 0$, 终节点数 $Endnode = 0$ 。当前节点指针 $i = 1$, 新生成节点指针 $j = 1$, 训练次数 $s = 1$ 。

步骤 2 在节点 i 上,判断 $node(i).C$ 中的元素个数是否为 1。如果是,节点 i 是终节点,转向步骤 4;否则继续。

步骤 3 用聚类算法将 $node(i).C$ 中的类别号分成两组,同时生成两个子结点 $node(j+1)$ 和 $node(j-1)$ 。令 $node(i).P^+ = j+1, node(i).P^- = j-1, node(i).S = s, node(j+1).P^+ = node(j-1).P^+ = 0, node(j+1).S = node(j-1).S = 0$ 。

在 $node(j+1).C$ 中存放正样本组类别号,在 $node(j-1).C$ 中存放负样本组类别号。此时训练样本集 X 等于 $node(i).C$ 所含类别的所有样本,对应的输出为 $Y = \{y_i | y_i = \begin{cases} 1, class(x_i) \in node(j+1).C \\ -1, class(x_i) \in node(j-1).C \end{cases} (i=1, 2, \dots, n)\}$ 。其中, $class(x_i)$ 表示样本 x_i 的所属类别。用 FSVM 训练,得到 Lagrange 乘子和阈值 $\{a^*, b^*\}$ 。令 $i = i+1, j = j+1, s = s+1$, 转向步骤 2。

步骤 4 令 $Endnode = Endnode + 1$, 判断终节点个数 $Endnode$ 是否等于类别数 M 。如果是 Bdt , 保存 Bdt , 算法结束;否则 $i = i+1$, 转向步骤 2。

3 实验结果及分析

为了对本文提出的虹膜识别算法性能进行分析评价,采用 UBIRIS V1^[11]和 CASIA-Iris V2.0^[12]虹膜数据库进行仿真实验。其数据库中的部分虹膜图像如图 3 和图 4 所示。



图 3 UBIRIS 虹膜数据库中的部分虹膜图像



图 4 CASIA 虹膜数据库中的部分虹膜图像

为了验证本文提出的基于广义高斯分布 Wrapping 算法的快速离散 curvelet 变换分解后,低频均值、方差和高频能量组成的特征向量是虹膜图像的最优特征表示,利用 FDCT_Wrap 分别对两个数据库中的虹膜图像进行分解,提取出低频分量和高频分量,并将低频分量、高频分量以及它们的组合分别输入同一分类器中进行分类识别,通过正确识别率 (correct recognition rate, CRR) 和错误识别率 (error recognition rate, ERR) 进行比较,实验结果见表 1、表 2。

由表 1 和表 2 可看出,特征加权能进一步提高虹膜图像识别率。在 UBIRIS 虹膜数据库中进行仿真实验,选用广义高斯分布 FDCT_Wrap 提取的低频子带系数矩阵的均值、方差作为特征向量,识别准确率为 93.23%;选用高频



表 1 UBIRIS 库测试结果

方法	特征向量	正确识别率	错误识别率
未特征加权	低频均值方差	91.15%	8.85%
	高频能量	80.94%	19.06%
	组合向量	93.97%	6.03%
特征加权	低频均值方差	93.23%	6.77%
	高频能量	83.48%	16.52%
	本文提出组合向量	98.16%	1.84%

表 2 CASIA 库测试结果

方法	特征向量	正确识别率	错误识别率
未特征加权	低频均值方差	91.79%	8.21%
	高频能量	82.87%	17.13%
	组合向量	95.22%	4.78%
特征加权	低频均值方差	93.86%	6.14%
	高频能量	84.57%	15.43%
	本文提出组合向量	98.83%	1.17%

子带能量作为特征向量,识别准确率仅为 83.48%;将低频均值、方差和高频能量组合作为特征向量,识别准确率达到 98.16%。在 CASIA 虹膜数据库中进行仿真实验,选用广义高斯分布 FDCT_Wrap 提取的低频子带系数矩阵的均值、方差作为特征向量,识别准确率为 93.86%;选用高频

子带能量作为特征向量,识别准确率仅为 84.57%;将低频均值、方差和高频能量组合作为特征向量,识别准确率达到 98.83%。由此可见使用广义高斯分布 FDCT_Wrap 分解后的低频子带系数矩阵的均值、方差能较好地表征虹膜纹理的基本特征,将其与高频子带能量组成特征向量组进行识别,提高了识别准确率,是用于虹膜识别的较佳特征组合。

为了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化速度较快的 Gabor 小波和 Haar 小波,对虹膜图像进行分解,提取虹膜纹理特征,分别采用汉明距离(hamming distance, HD)、SVM、二叉决策树 FSVM 进行匹配识别。对错误接受率(false acceptance rate, FAR)、错误拒绝率(false rejection rate, FRR)和正确识别率(correct recognition rate, CRR)3 个指标进行比较,实验结果见表 3、表 4。

通过对表 3 和表 4 的分析可知,对于不同的特征提取方法和不同的匹配识别方法,本文提出的改进 curvelet 变换的虹膜识别准确率比其他方法高,识别错误率相应降

表 3 不同方法的 UBIRIS 库性能比较

组别	特征提取方法	匹配方法	错误识别率	错误拒绝率	正确识别率
1	Gabor 小波	HD	4.32%	3.49%	92.94%
	Haar 小波		4.71%	2.83%	92.14%
	curvelet 变换		2.82%	2.55%	94.28%
	改进 curvelet 变换		2.47%	2.38%	95.16%
2	Gabor 小波	SVM	3.13%	1.91%	94.85%
	Haar 小波		4.47%	2.86%	92.72%
	curvelet 变换		2.38%	2.04%	95.18%
	改进 curvelet 变换		1.92%	1.76%	96.37%
3	Gabor 小波	二叉决策树 FSVM	1.86%	1.17%	96.09%
	Haar 小波		2.89%	1.56%	94.53%
	curvelet 变换		1.26%	0.78%	97.95%
	改进 curvelet 变换		1.01%	0.62%	98.16%

表 4 不同方法的 CASIA 库性能比较

组别	特征提取方法	匹配方法	错误识别率	错误拒绝率	正确识别率
1	Gabor 小波	HD	4.28%	3.25%	93.13%
	Haar 小波		4.66%	2.71%	92.63%
	curvelet 变换		2.56%	2.38%	94.74%
	改进 curvelet 变换		2.13%	2.06%	95.81%
2	Gabor 小波	SVM	2.95%	1.74%	95.28%
	Haar 小波		4.28%	2.65%	93.07%
	curvelet 变换		2.26%	1.92%	95.61%
	改进 curvelet 变换		1.81%	1.63%	96.56%
3	Gabor 小波	二叉决策树 FSVM	1.78%	1.09%	96.25%
	Haar 小波		2.71%	1.37%	94.68%
	curvelet 变换		1.17%	0.61%	98.22%
	改进 curvelet 变换		0.91%	0.47%	98.83%

低,说明采用广义高斯分布 FDCT_Wrap 和二叉决策树 FSVM 的虹膜特征提取与识别算法的性能更优,能有效提高虹膜识别效果,具有较好的稳定性和较强的顽健性。

为了更好地评价算法的优劣,采用 ROC 曲线表示。ROC 曲线越接近坐标轴,说明匹配识别性能越好。对 UBIRIS 和 CASIA 虹膜数据库,分别采用 Farouk^[2]算法、Rajbhoj^[3]算法、Rahulkar^[5]算法以及本文提出算法的 ROC 曲线对比如图 5、图 6 所示。从图 5 可知,本文提出的算法在相同 FAR 下 FRR 更小,这表示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。




图 5 UBIRIS 虹膜数据库不同算法的 ROC 曲线




图 6 CASIA 虹膜数据库不同算法的 ROC 曲线

4 结束语

本文提出的基于广义高斯分布 Wrapping 算法的快速离散 curvelet 变换和二叉决策树模糊支持向量机的虹膜特征提取与识别算法的识别性能有较明显的改进。该方法适合应用在对安全性要求较高的实时性身份认证系统中。利用广义高斯分布 Wrapping 算法的快速离散 curvelet 变换提取虹膜特征向量,有效地避免了小波变换不具有空间各

向异性的缺陷,结合二叉决策树 FSVM 算法,获得了较理想的识别效果。

参考文献:

- [1] 孙冬,周俊,魏勇.基于 Haar 小波的虹膜特征提取算法[J].科学技术与工程,2014,1(14):81-85.
SUN D, ZHOU J, WEI Y. Iris feature extraction based on Haar wavelet[J]. Science Technology and Engineering, 2014, 1(14): 81-85.
- [2] FAROUK R M. Iris recognition based on elastic graph matching and Gabor wavelets [J]. Computer Vision and Image Understanding, 2011, 115(8): 1239-1244.
- [3] RAJBHOJ S M, MANE P B. Haar wavelet approach of iris texture extraction for personal recognition [J]. International Journal of Innovative Technology and Exploring Engineering, 2013, 3(2): 22-25.
- [4] KARTHIKEYAN V. Novel algorithm for iris biometrics using fast wavelet transforms [J]. International Journal of Engineering Sciences and Research Technology, 2014, 3(3): 1481-1484.
- [5] RAHULKAR A D, JADHAV D V, HOLAMBE R S. Fast discrete curvelet transform based anisotropic iris coding and recognition using k-out-of-n: a fused post-classifier[J]. Machine Vision and Applications, 2012, 23(6): 1115-1127.
- [6] DHAGEA S S, HEGDEA S S, MANIKANTANA K, et al. DWT-based feature extraction and radon transform based contrast enhancement for improved iris recognition[J]. Procedia Computer Science, 2015, 1(45): 256-265.
- [7] ABDULLAH H N, ABDULLAH A A. Iris recognition using wavelet transform and artificial neural networks [J]. Engineering & Technology Journal, 2015, 33(6): 877-888.
- [8] CANDES E J, DEMANET L, DONOHO D L, et al. Fast discrete curvelet transforms[J]. Multiscale Modeling & Simulation, 2006, 5(3): 861-899.
- [9] VAPNIK V N. An overview of statistical learning theory[J]. IEEE Transactions on Neural Networks, 1999, 10(5): 988-999.
- [10] LIN C F, WANG S D. Fuzzy support vector machines [J]. IEEE Transactions on Neural Networks, 2002, 13(2): 464-471.
- [11] PROENCA H, ALEXANDRE L A. UBIRIS: a noisy iris image database[J]. Lecture Notes in Computer Science, 2005(3617): 970-977.
- [12] CASIA-Iris V2[EB/OL]. (2007-12-20)[2015-12-14]. [http://www.cbsr.ia.ac.cn/Iris Database.htm](http://www.cbsr.ia.ac.cn/Iris%20Database.htm).

[作者简介]



何振红(1979-),女,甘肃民族师范学院讲师,主要研究方向为图像处理、模式识别。