

# 实时虹膜识别系统中的图像预评估检测

叶学义 龙飞 庄连生 庄镇泉

(中国科学技术大学电子科学与技术系, 合肥 230026)

**摘要** 在采集虹膜图像样本时,会由于各种原因而出现不同类型的坏样本。由于现有的图像质量评估方法需要在虹膜定位或者粗定位之后,根据虹膜的清晰度或分辨率来进行判定,因此只能检测出特定类型的坏样本。为了能对各种类型坏样本进行检测,在分析坏样本产生原因和类型的基础上,提出了一种实时预评估网络的检测方法,即在定位或者粗定位处理之前,预先对缓存中的图像进行评估,再根据预评估检测的结果来决定是重新采集,还是进入后续的处理。其目的是,①节省现有的图像评估在定位处理上花费的时间和降低采集失败率,以提高识别系统的友好性;②减少因为坏样本的输入而导致的定位出错,以避免引起误识别的可能;③提高识别率的同时降低识别系统的注册失败率。实验结果表明,这种方法不仅可以检测出多种类型的坏样本,且检测错误率低,同时具有较高的评估速度,可以满足实时虹膜识别系统的要求。

**关键词** 坏样本 图像的预评估 实时虹膜识别系统 预评估网络

中图分类号: TP391 文献标识码: A 文章编号: 1006-8961(2007)11-2037-06

## Pre-estimation of Images for Real-time Iris Identification Systems

YE Xue-yi, LONG Fei, ZHUANG Lian-sheng, ZHUANG Zhen-quan

(Department of Electronic Science and Technology, University of Science and Technology of China, Hefei 230026)

**Abstract** There are different types of bad images when an iris identification application system captures iris images. Because previous image quality evaluation methods judge an image whether bad or else by the resolution and the definition of the iris part after the iris localization, they barely can sift a few types of bad images. For improving the performance of image's real-time estimation, debasing the rate of failure to acquire and decreasing the localization errors possibility resulted from bad images, this paper proposes a new idea of the real-time pre-estimation network which pre-estimates images saved in memory before the localization or rough localization in an recognition process and decides whether it captures an iris image again or turns into the next step by the network output. The experimental result shows that the method can detects most types of bad images with fairly low false rate and little calculation and satisfies the requirement of a real-time iris recognition system.

**Keywords** bad images, image's pre-estimation, real-time iris identification system, pre-estimation network

## 1 引言

利用人类自身的生理或者行为特征来识别别人的身份的生物特征识别技术,到目前为止,是替代传统的身份识别手段(基于密码或钥匙等等)的最有希望的候选者。各种生物特征识别方法,包括指纹、虹膜、人脸、手形和签名等等,在不同的条件下都获得了优良的表现。其中,虹膜识别因为其丰富的纹理

特征及良好的不变性,在身份识别中表现了更加出色的性能,例如,极低的误识率(FAR)和误拒率(FRR)。虹膜识别的前提就是要通过传感器来采集到合格的虹膜图像,这种采集方式虽然因为非接触而具有交互友好的特点,但也因为其要求比较严格的采集条件,使得这种身份识别方法具有较高的注册失败率<sup>[1]</sup>,特别是在实时系统中,会给使用者带来一定的困扰,是虹膜识别技术推向大规模实用化的障碍之一<sup>[2]</sup>。

收稿日期:2005-06-20; 改回日期:2006-06-26

第一作者简介:叶学义(1973~),男,2006年获中国科学技术大学信号与信息处理专业博士学位。研究方向为模式识别、计算机视觉、生物特征识别和信息安全。E-mail: xuexi\_ye@ustc.edu

如图 1 所示,在采集虹膜的过程中有相当多的因素会导致采集到的图像样本不符合识别系统的处理条件(通常称之为坏样本),例如,虹膜不在样本图像中;图像中虹膜不完整;眼睛的斜视造成了样本中虹膜过度变形;采集的瞬间,眼睛发生了位移等

等。上述的这些情况都会对识别造成严重的影响,甚至会直接导致识别错误。如果不对包含这些因素的图片样本进行处理,则会大大降低识别系统或方法的识别率。



(第 1 行:图像中不包含虹膜;第 2 行:不正确的采集位置;第 3 行:采集设备本身的错误)

图 1 坏样本示意

Fig. 1 Different bad images

在现有的虹膜识别系统或者方法中,大多数是利用反馈的手段来对这种问题进行处理。它们通常可以分为以下 3 类方法:(1)在图像预处理阶段(一般是指从图像采集完成到虹膜定位结束之后或者特征提取开始之前),先对采集的图像进行评估,然后根据输出结果来提示是否需要使用者重新输入虹膜图像<sup>[3]</sup>;(2)是从硬件的角度来考虑,例如在虹膜采集设备中使用单向镜,即利用单向镜的特殊性质,直接将大致的采集结果反馈给使用者<sup>[4]</sup>;(3)人工干预(最可靠的反馈方法),它是由识别系统操作员或者样本采集控制者直接判断采集的虹膜样本是否满足识别的要求,然后决定是否要求使用者进行再次采集<sup>[4]</sup>。但是第 3 类方法和自动身份识别的发展要求是相背离的。

抛开第 3 类方法,现有的前两类方法对上述问题的处理存在着不足之处,例如,在第 1 类方法中,无论采集的样本属于前文提到的哪一种类型的坏样本,都需要完成虹膜定位或者粗定位之后,才能进行具体的评估,然后再将结果反馈,并且它们仅仅对样本是否清晰和分辨率是否足够进行评估,由此带来了以下两种不利的影 响:(1)消耗了过多的系统时间,在现有的识别方法中,虹膜定位的时间通常占到一次完整的识别过程所需要时间的 1/3 ~ 1/2,甚至更多;(2)将定位处理中可能产生的错误带入了反馈输出(例如,因为定位处理的原因,将合格样本判定为坏样本,或者对于满足清晰度和分辨率要求的坏样本,因为定位的错误而导致了相反的结果)。在第 2 类方法中,尽管利用单向镜是一种新颖的思路,但它是一种中间过程的反馈,不一定反映最后的

采集结果。因为采集者自身瞬间的移动和采集硬件的同步等问题(见图 1 的第 2 行和第 3 行各图)依然会造成坏样本。

如果在定位处理之前,对采集的样本先进行预评估处理,然后再根据输出的结果来决定是重新采集样本,还是进行之后的处理,这样就可以将大部分类型的坏样本阻挡在定位处理之前。这既可以节省计算成本,又降低了虹膜定位的错误率,还可以避免因定位的错误而将坏样本引入识别处理的可能。本文基于此提出了一种预评估网络的方法,以检测输入图像中是否包含完整的虹膜部分,即在定位处理之前,首先对采集的样本进行实时的检测,以节省计算成本和提高识别系统的实时性;同时降低识别系统的采集失败率,以提高系统的友好性。实验结果表明,该方法可以检测出大部分类型的坏样本,不仅计算效率高,而且具有较好的推广性能。

## 2 实时虹膜样本的预评估

图像样本的预评估属于虹膜图像预处理的前端部分。在实时虹膜识别系统中,这种预评估就是对存储于系统缓存中的单幅原始虹膜图像或者图像序列进行处理,然后系统根据它的输出结果来决定是继续采集图像还是结束采集进入后续的处理。此时,样本的预评估本质上是一个两类划分的问题,它将所有待评估的图像分别归类到坏样本和合格样本(预评估)两个集合中(如图 1 和图 3 所示)。从图 3 可以看出,虹膜图像具有相对特殊的几何轮廓结构;同时,由于典型的 BP 神经网络可以实现输入和输出间的任意非

线性映射<sup>[5]</sup>,而且利用经过训练的网络来完成样本图像的预评估时,只需进行比较简单的计算,就可以输出结果,因此可以满足实时性的要求。

根据以上的分析,本文建立了一种复合 BP 神经网络用来完成实时虹膜样本的预评估。它采用带动量因子的 BP 算法,试图利用新颖的复合网络结构来降低 BP 神经网络的典型缺陷对评估性能的影响<sup>[6]</sup>。整个复合网络由以下 3 部分组成(如图 2 所示):原始图像数据重构部分(形成网络的输入数据)、网络 I、网络 II。其中网络 I 由 3 个子 BP 网

络组成,它们输入独立,各自训练;网络 II 是一个独立的 BP 网络,其是以网络 I 的输出作为输入,训练也是独立的。当网络 I 和网络 II 训练好之后,再将它们连接起来,以完成预评估的功能。期望这种单独训练、复合测试的方法以及独特的网络结构,会缓解 BP 神经网络存在的这样一种矛盾(那就是当网络的规模增大时,虽然会降低出现局部极小的可能,但是却降低了网络的推广(泛化)能力;而较小的规模虽可以提高网络的推广能力,但同时又增加了出现局部极小的可能<sup>[6]</sup>),以提高复合网络的评估性能。




图 2 实时图像预评估网络的示意图

Fig. 2 Real-time images pre-estimation network

2.1 样本图像的数据重构

如果直接将虹膜识别系统采集的原始图像样本(通常大小为  $480 \times 640$ )作为网络 I 的输入向量,则显然输入向量的维数太高。而且因为利用复合 BP 神经网络来进行预评估的方法是基于样本特定的几何轮廓,所以在可以保持这种轮廓特性的前提下,要对图像样本进行数据重构,以降低输入向量的维数。

数据重构时,首先将样本图像  $I$  缩小为  $I_{n \times m}$ (式(1)),并保持  $n \times m$  的比例关系和原图像相同( $n$  为行数,  $m$  为列数),使得缩小后的图像不会发生扭曲;然后对  $I_{n \times m}$  进行二值化处理得到矩阵  $P_{n \times m}$ (式(1)),即抓住图像整体的轮廓特征;最后分别计算  $P_{n \times m}$  中各行和各列的均值及方差,生成新的输入矩阵,记为  $H_{n \times 2}$  及  $V_{2 \times m}$ ,并以此提取图像局部的典型特征(如式(1)~式(6)所示)。

$$I_{n \times m} = \text{Resize}(I), (n, m \in \mathbf{N}), P_{n \times m} = \text{Binary}(I_{n \times m}) \quad (1)$$

$$H_{n \times 2}(i, 1) = \mu_{i,1} = \frac{1}{m} \sum_{j=1}^m P_{n \times m}(i, j) \quad (2)$$

$$i \in (1, \dots, n), j \in (1, \dots, m)$$

$$H_{n \times 2}(i, 2) = \sigma_{i,2} = \frac{1}{m} \sum_{k=1}^m [P_{n \times m}(i, j) - \mu_{i,1}]^2 \quad (3)$$

$$V_{2 \times m}(1, j) = \mu_{1,j} = \frac{1}{n} \sum_{i=1}^n P_{n \times m}(i, j) \quad (4)$$

$$V_{2 \times m}(2, j) = \sigma_{2,j} = \frac{1}{n} \sum_{i=1}^n [P_{n \times m}(i, j) - \mu_{1,j}]^2 \quad (5)$$

$$H_{n \times 2} = \begin{pmatrix} \mu_{1,1} & \sigma_{1,2} \\ \vdots & \vdots \\ \mu_{n,1} & \sigma_{n,2} \end{pmatrix}, V_{2 \times m} = \begin{pmatrix} \mu_{1,1} & \dots & \mu_{1,m} \\ \sigma_{2,1} & \dots & \sigma_{2,m} \end{pmatrix},$$

$$P_{n \times m} = \begin{pmatrix} a_{1,1} & \dots & a_{1,m} \\ \vdots & \ddots & \vdots \\ a_{n,1} & \dots & a_{n,m} \end{pmatrix} \quad (6)$$

2.2 网络 I

网络 I 由 3 个独立的子 BP 神经网络  $N_1^{BP}$ 、 $N_2^{BP}$

和  $N_3^{BP}$  组成(如图 2 所示)。它们都包含一个输入层,两个隐层和一个输出层;除了输出层都只包含一个节点之外,隐层的节点数各不相同,分别根据经验和实验效果来确定<sup>[6-8]</sup>;  $N_1^{BP}$ 、 $N_2^{BP}$  和  $N_3^{BP}$  的权值矩阵分别为  $(W_1^{BP1}, W_2^{BP1}, W_3^{BP1})$ ,  $(W_1^{BP2}, W_2^{BP2}, W_3^{BP2})$  和  $(W_1^{BP3}, W_2^{BP3}, W_3^{BP3})$ ; 偏差矩阵分别为  $(b_1^{BP1}, b_2^{BP1}, b_3^{BP1})$ ,  $(b_1^{BP2}, b_2^{BP2}, b_3^{BP2})$  和  $(b_1^{BP3}, b_2^{BP3}, b_3^{BP3})$ ; 传递函数都选择连续可微的 Sigmoid 函数 ( $f_1^{Sigmoid}$ ,  $f_2^{Sigmoid}$ ,  $f_3^{Sigmoid}$ ) 分别对应于子神经网络的隐层 1、隐层 2 和输出层); 构成输入向量的矩阵  $H_{n \times 2}$ 、 $P_{n \times m}$  和  $V_{2 \times m}$  如式(6)所示,它们分别作为网络的输入;然后将由  $N_1^{BP}$ 、 $N_2^{BP}$  和  $N_3^{BP}$  各自的输出  $O_1^{BP}$ 、 $O_2^{BP}$ 、 $O_3^{BP}$  生成的矩阵  $O_{3 \times 1}$  (如式(7)~式(10)所示),作为网络 II ( $N_4^{BP}$ ) 的输入;  $T$  为训练目标矩阵,  $T$  中的每一元素对应于一个输入样本(当输入为合格样本时,  $T$  中对应的元素为 1; 当输入为坏样本时,  $T$  中对应的元素为 -1), 各子神经网络的训练目标矩阵都为  $T$ 。

$$O_1^{BP} = f_3^{Sigmoid} (W_3^{BP1} \cdot f_2^{Sigmoid} (W_2^{BP1} \cdot f_1^{Sigmoid} (W_1^{BP1} \cdot H_{n \times 2} + b_1^{BP1}) + b_2^{BP1}) + b_3^{BP1}) \quad (7)$$

$$O_2^{BP} = f_3^{Sigmoid} (W_3^{BP2} \cdot f_2^{Sigmoid} (W_2^{BP2} \cdot f_1^{Sigmoid} (W_1^{BP2} \cdot P_{n \times m} + b_1^{BP2}) + b_2^{BP2}) + b_3^{BP2}) \quad (8)$$

$$O_3^{BP} = f_3^{Sigmoid} (W_3^{BP3} \cdot f_2^{Sigmoid} (W_2^{BP3} \cdot f_1^{Sigmoid} (W_1^{BP3} \cdot V_{2 \times m} + b_1^{BP3}) + b_2^{BP3}) + b_3^{BP3}) \quad (9)$$

$$O_{3 \times 1} = \begin{pmatrix} O_1^{BP} \\ O_2^{BP} \\ O_3^{BP} \end{pmatrix}, (O_1^{BP}, O_2^{BP}, O_3^{BP} \in [-1, 1]) \quad (10)$$

### 2.3 网络 II

网络 II 是一个单独的 BP 网络  $N_4^{BP}$ , 在训练时它和网络 I 断开, 当网络 I 训练好之后, 再将它输出  $O_{3 \times 1}$  作为网络 II 的训练数据, 对应于同样的训练目标矩阵  $T$ , 用以训练  $N_4^{BP}$ 。训练完成之后, 再将复合 BP 神经网络的 3 部分连接起来, 对输入的样本图像进行预评估, 并将网络的最后输出  $O_4^{BP}$  作为预评估的结果(如式(11)所示)。在  $N_4^{BP}$  中, 除了输入层  $O_{3 \times 1}$  之外, 单隐层包含两个节点, 输出层依然由一个节点组成<sup>[7]</sup>,  $f_4^{Sigmoid}$  和  $f_5^{Sigmoid}$  分别对应  $N_4^{BP}$  的隐层和输出层的传递函数。在训练过程中, 误差的反向传递仅仅在网络 II 的范围内来更新权值矩阵  $(W_1^{BP4}, W_2^{BP4})$  和偏差矩阵  $(b_1^{BP4}, b_2^{BP4})$ , 并不对网络 I 的权值矩阵  $(W_1^{BP1}, W_2^{BP1}, W_3^{BP1})$ 、 $(W_1^{BP2}, W_2^{BP2}, W_3^{BP2})$ 、 $(W_1^{BP3}, W_2^{BP3}, W_3^{BP3})$  和偏差矩阵  $(b_1^{BP1}, b_2^{BP1}, b_3^{BP1})$ 、

$(b_1^{BP2}, b_2^{BP2}, b_3^{BP2})$ 、 $(b_1^{BP3}, b_2^{BP3}, b_3^{BP3})$  产生影响。

$$O_4^{BP} = f_5^{Sigmoid} (W_2^{BP4} \cdot f_4^{Sigmoid} (W_1^{BP4} \cdot O_{3 \times 1} + b_1^{BP4}) + b_2^{BP4}) \quad (O_4^{BP} \in [-1, 1]) \quad (11)$$

## 3 实验结果

因为对识别系统采集的图像进行预评估是在现有的图像质量评估处理之前, 所以对于定位完成之后的图像清晰度和分辨率的评估也就不属于预评估的处理内容。预评估的研究目的就是迅速判断出采集的原始图像或者图像序列中是否包含完整的虹膜。整个实验数据由本实验室采集的虹膜数据库 (self-databases) 以及坏样本、CASIA 的公开虹膜数据库<sup>[9]</sup> (CASIA-open) 以及首届生物特征识别竞赛提供的训练数据库<sup>[10]</sup> 组成 (contest-DB1 & DB2), 图 1 和图 3 是从其中选取的部分样本组成的。




图 3 不同条件下采集到的预评估合格的图像样本

Fig. 3 Normal images of the pre-estimation in different capturing conditions

图 3 所示的 64 个原始虹膜样本, 分别包含了不同采集设备、不同光照、不同姿态、不同距离、不同个体等采集条件下得到的各种图像样本。其中的第 1、3 和 8、2 和 4 列分别是本实验室设计的 3 种虹膜图像采集设备采集得到的图像样本, 其中第 8 列中的示例图像并不能满足识别系统对图像的要求, 但是在图像预评估阶段, 它们都是合格的图像; 第 7 列是从 CASIA 的公开数据库得到的<sup>[9]</sup>; 第 6 列来自于 CASIA-contest-DB1<sup>[10]</sup>, 第 5 列来自于 CASIA-contest-DB2<sup>[10]</sup>。因为目前公开的数据库中的图像都不包含在采集时因为各种原因产生的坏样本, 所以实验中

全部的坏样本都来自于本实验室的数据库。

从图 3 中可以看出,不同的虹膜采集设备得到的虹膜样本图像的差异是相当大的,因此对 4 个数据库分别进行了实验。实验结果如表 1 所示,其中总的坏样本数为 1 348 个,分别和以上的 4 个数据库搭配进行训练和测试,而且比例相同,都是 244 个用于训练预评估网络,剩余的 1 104 个进行测试;self-

databases 总共包含 1 850 个样本,其中 540 个用于训练,剩余的 1 310 个进行测试;CASIA-open 总共包含 756 个样本,其中 256 个用于训练,剩余的 500 个进行测试;contest-DB1 总共包含 1 200 个样本,其中 400 个用于训练,剩余的 800 个进行测试;contest-DB2 总共包含 1 200 个样本,其中 400 个用于训练,剩余的 800 个进行测试。


表 1 不同数据库上的实验结果

Tab. 1 Experimental results of different databases


样本数据库	训练样本		测试样本		总测试时间 (s)	测试错误率 (%)
	合格样本数	坏样本数	合格样本数	坏样本数		
self-databases	540	244	1 310	1 104	0.125	0.083
CASIA-open	256	244	500	1 104	0.094	0.44
contest-DB1	400	244	800	1 104	0.109	0.58
contest-DB2	400	244	800	1 104	0.110	0.84

从表 1 中可以看出,4 个数据库的分类实验得到了比较好的测试结果,测试的错误率都低于 1%,而且从总测试时间来看,网络的预评估速率大约为

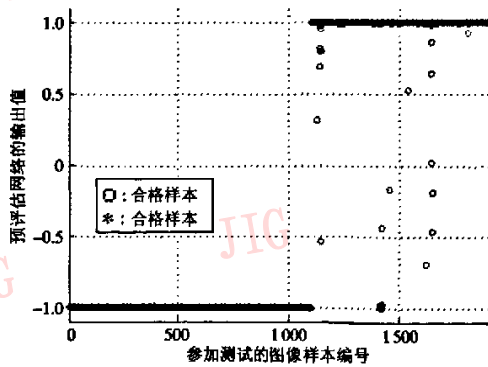
18 000 个/s,应当可以满足实时虹膜识别系统的要求。图 4(a)、图 4(b)、图 4(c)和图 4(d)分别详细描述了预评估网络对 4 个数据库的测试样本的输出



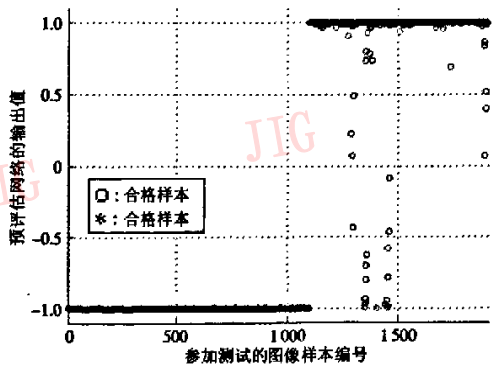
(a)



(b)



(c)



(d)

图 4 预评估网络测试样本的输出值的分布示意

Fig. 4 The pre-estimation network output distribution of different databases

值,图中水平坐标表示参加测试的样本编号,垂直坐标表示网络的输出值。

研究中还要对这些问题加以探讨。

#### 4 分析和讨论

针对虹膜图像预评估的目的,上一节的实验结果表明,由复合BP神经网络构成的预评估网络,在评估速度和评估错误率两方面都得到了比较满意的结果,可以较好地满足识别系统实时评估的需要。预评估网络这种新颖的结构以及数据重构、独立训练、联合评测的方法,使得各个子BP网络以较低的迭代次数完成了训练,并降低了发生过训练的可能;同时还使得整个预评估网络保持了较好的推广性(泛化能力),符合预期的目标。从图4中还可以看到,虽然针对各个数据库的测试都还有一定的错误率,但是预评估网络对于坏样本的输出完全集中在-1的小邻域(即整个网络预评估的误识率为0)。

当然在实验中也发现了一些问题。例如,对于图像预评估,这种复合BP网络的结构只能在一定程度上缓解BP神经网络的固有缺陷造成的影响,而且各个子BP网络隐层的节点数依然是依靠经验和实验效果来确定;虽然取得了较理想的训练和测试的结果,但是依然不能确定该网络是否实现了全局最优的预评估。还有图4(c)和图4(d)分别是contest-DB1和contest-DB2的测试结果,从图中可以看出,预评估的错误率较高,而且预评估网络的输出值的分布较为分散,这些现象说明,这种预评估网络还不能完全忽略采集时的光照变化,因此在以后的

#### 参考文献(References)

- 1 Jain A K, Pankanti Sharath, Prabhakar Salil, et al. Biometrics: A grand challenge [A]. In: Proceedings of IEEE International Conference on Pattern Recognition [C], Cambridge, UK, 2004: 0-7695-2128-2.
- 2 Summary of NIST Standards for Biometric Accuracy[R]. In: Tamper Resistance and Interoperability of NIST Report to the United States Congress[EB/OL]. Available at ftp://sequoyah.nist.gov/pub/nist internal reports/NISTAPP Nov02. pdf, November 2002.
- 3 HE Jia-feng, YE Hu-nian, YE Miao-yuan. A study on iris image quality evaluation [J]. *Journal of Image and Graphics*, 2003, 8A(4): 387 ~ 391. [何家峰,叶虎年,叶妙元. 虹膜图像质量评价的研究[J]. *中国图象图形学报*, 2003, 8A(4): 387 ~ 391.]
- 4 Daugman J. Iris recognition: Current state of the art[A]. In: The Advance Study Institute of Biometric Authentication in Hongkong Baptist University[C], Hongkong, China, 2004.
- 5 Rumelhart D E, McClelland J L. Learning internal representations by error propagation[A]. In: Rumelhart D E, McClelland J L. (Eds). *Parallel Distributed Processing* [C], Cambridge, MA, USA: MIT Press, 1986, 1: 318 ~ 362.
- 6 Eberhart R C, Dbbins R W. *Neural Network PC Tools: A Practical Guide*[M]. New York: Academic Press, 1990.
- 7 Lippmann R P. An Introduction to Computing with Neural Nets[J]. *IEEE Transactions on ASSP (Acoustics, Speech, and Signal Processing) Magazine*, 1987, 4(2): 4 ~ 22.
- 8 Lippmann R P. Pattern classification using neural networks [J]. *IEEE Communications Magazine*, 1989, 27(11): 47 ~ 64.
- 9 Iris database 1.0 of CASIA[DB/OL]. www.sinobiometrics.com
- 10 Iris training database of the first contest of biometrics recognition and testing of China[DB/OL]. 2004, www.sinobiometrics.com