

基于 FREAK 算符及双向最近汉明距的非理想虹膜识别算法

季毕胜 叶学义 廖奕艺 邹茹梦

(杭州电子科技大学通信工程学院 浙江 杭州 310018)

摘要 针对低约束条件的非理想虹膜识别性能的显著下降,以及尺度不变特征变换(SIFT)和加速稳健特征(SURF)方法实时性不高的问题,提出 FREAK 算符配合双向最近汉明距的识别算法。通过高斯核构建多尺度特征点检测算子提取稳健的特征点集合,并引入 FREAK 算符改进 SIFT 算符,以提高特征点的表征和匹配速度;利用双向最近汉明距的匹配策略增强特征匹配对的稳定性,以降低非同源虹膜的匹配点数。实验结果表明,识别等错误率和正确识别率均有改善且单次验证时间均在 0.3 s 左右。该方法能够有效应对非理想虹膜类内纹理质量的变化,与 SIFT 与 SURF 算法相比具有更好的实时性。

关键词 非理想虹膜识别 多尺度检测 FREAK 算符 双向汉明距 实时性

中图分类号 TP391.41

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.07.029

NON-IDEAL IRIS RECOGNITION ALGORITHM BASED ON FREAK OPERATOR AND BIDIRECTIONAL CLOSEST HAMMING DISTANCE

Ji Bisheng Ye Xueyi Liao Yiyi Zou Rumeng

(College of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, Zhejiang, China)

Abstract Aimed at the significant degradation of non-ideal iris recognition performance under low-constraint conditions, and the low real-time performance of scale invariant feature transform (SIFT) and speeded up robust feature (SURF) methods, a recognition algorithm based on FREAK operator and bidirectional nearest Hamming distance is proposed. A Gaussian kernel was used to construct a multi-scale feature point detection operator to extract a robust set of feature points, and the FREAK operator was introduced to improve the SIFT operator to enhance the characterization and matching speed of feature points. The bidirectional closest Hamming distance matching strategy was used to enhance the stability of feature matching pairs so as to reduce the number of mismatched points of non-homologous irises. The experimental results show that the recognition error rate and the correct recognition rate are improved and the recognition time for a single verification is about 0.3s. The proposed method can effectively cope with the texture quality changes in non-ideal iris classes and has better real-time ability compared with SIFT and SURF algorithms.

Keywords Non-ideal iris recognition Multi-scale detection FREAK operator Bidirectional nearest hamming distance Real-time ability

0 引言

虹膜纹理特征的高度复杂性,稳定性以及非侵入性使得虹膜识别技术成为当今生物特征识别的热门研究方向^[1]。传统的虹膜识别过程可分为虹膜图像获取、虹膜预处理、特征提取及匹配和虹膜识别四个步

骤^[2]。虹膜特征提取作为虹膜识别技术关键部分决定最终识别性能而得到深入研究^[3]。另外特征提取得到的特征向量类型也决定了后续选用的特征匹配方法,选取一个合适的特征匹配方法能够影响识别性能,因此本文对虹膜识别的提取和匹配阶段进行研究。

目前典型的虹膜识别算法可分为四类:(1)基于相位分析的方法,该方法以 Gabor 滤波器相位算法为

代表,采用不同尺度的 Gabor 滤波器对虹膜图像进行滤波,根据滤波后的相位编码二进制特征向量,之后采用汉明距离完成特征匹配^[4-5]。(2) 基于相关滤波器的方法,该类方法以 Wildes 等采用的拉普拉斯金字塔分解算法为代表,首先获取虹膜图像在 4 个不同分辨率的虹膜纹理图像,之后根据相关性判断注册虹膜与待测虹膜是否相关^[6]。(3) 基于过零检测的方法,例如田启川等^[7]提出的基于过零检测的虹膜特征提取算法;苑玮琦等^[8]提出基于小波过零点位置不等长编码匹配的虹膜识别。(4) 基于纹理分析的方法,例如李欢利等^[9]通过统计特征中心对称局部二值模式 (SCCS-LBP) 算子提取虹膜特征,最后用 Hamming 距离进行虹膜识别。

近些年来,随着深度学习在图像处理方向取得的巨大成功,许多学者将深度学习引入到虹膜识别中来,例如 Alaslani^[10]使用 Alex-Net 卷积神经网络提取虹膜特征后,最后利用多分类器 SVM 对虹膜进行识别,Nguyen 等^[11]则将目前几类流行的预训练卷积神经网络 (Pre-Trained Convolutional Neural Networks) 应用到虹膜的特征提取当中,在一些虹膜库中取得了不错的识别准确率。

以上算法通常从不同角度对虹膜特征进行编码,然而,在实际应用场景获得的非理想虹膜图像通常会受到尺度、光照不均、纹理模糊、旋转等多个因素的影响。例如基于 Gabor 滤波器相位算法和基于相关滤波器的方法依赖于高精度虹膜图像的采集,对于虹膜纹理的清晰度要求很高,基于过零检测方法和纹理分析方法对于噪声不具备鲁棒性,而卷积神经网络在非理想虹膜上的识别率高低依赖于训练虹膜数据的数量。但这些预训练神经网络在虹膜图像上的训练次数不足,识别率并不高,因此非理想虹膜识别作为虹膜识别中一个有待解决的挑战性问题^[12]并没有通过上述算法得以较好地解决。近些年,Lown^[13]首先提出尺度不变特征变换 (SIFT) 算法以获得图像中具有明显区分度的特征,该算法不仅可以提取到具有图像尺度和旋转不变性且对光照变化不变性的稳定特征,而且可以在一定程度上避免由噪声所引起的特征点误匹配情况。Zhu 等^[14]首先将 SIFT 算法应用在虹膜特征提取上,但因为虹膜纹理和非纹理之间灰度值差异不明显,并没有提取到足够多有效的特征点。Yang 等^[12]采用了直方图均衡化算法对虹膜图像纹理进行增强,虽提取足够的多的特征点,但是对过多的特征点进行浮点型描述复杂度高,并且在匹配时根据传统的欧氏距离进行特征点匹配涉及到过多的开方运算,计算量大,实

时性并不高。中科院的 Sun 等^[15]研究团队通过构建一种新的词袋模型 (HVC) 对虹膜中提取到的 SIFT 描述子进行了二次特征提取,在实验中取得了很好的识别效果,Ali 等^[16]将加速稳健特征 (SURF) 算法应用于虹膜特征提取虽然加快了识别速度,但算法本身是以减少一半的特征维度为代价,所以识别性能有所下降。

实际场景下的采集到的虹膜图像通常受到各种因素的干扰,其中虹膜纹理模糊,虹膜纹理和非纹理之间界限不明显是非理想虹膜主要特征之一,而以 Gabor 滤波为代表的上述四类典型算法对纹理质量要求较高而导致算法在实际应用场景下适应性较差,非理想虹膜识别性能显著下降,这些传统算法走出实验室,推向实际应用的依然需要进行改进。基于 SIFT 和 SURF 算法在光照不变性、虹膜纹理模糊、对比度不明显方面具有较好的性能,但算法在特征描述阶段较为复杂,匹配过程计算量大,最终的识别实时性不高,由此本文在特征点描述阶段引入了一种新的局部特征描述方法——快速视网膜关键点 (FREAK) 算符^[17],提出基于 FREAK 算符结合双向最近汉明距匹配的非理想虹膜识别算法。该算法首先利用高斯差分金字塔模型从不同尺度下提取虹膜中稳健的特征点集合。然后用 FREAK 算法对提取到的特征点进行编码,相对于 SIFT 算符和 SURF 算符而言,FREAK 算符编码后的结果是紧凑的二进制描述子,因此在特征向量生成和匹配上具有更快的速度优势。之后在特征向量的匹配阶段,提出双向最近汉明距特征匹配算法,相较于传统的单次汉明距离匹配算法,该方法能大大减少非同源虹膜的误匹配点数。最后通过计算虹膜匹配率完成待测虹膜的分类。通过实验分析,与基于 Gabor 滤波器相关算法比较,本文方法的通用性更强,在同源虹膜纹理质量变化不均的各类虹膜库中均具有较好的表现。另外,与典型的 SIFT 和 SURF 算法相比,本文方法保持了识别性能稳健性的同时,单次的虹膜分类时间要快很多,有着较高的实用价值。

1 本文算法

本文提出的虹膜识别算法框架如图 1 所示。主要思想为:首先收集虹膜图像,采用虹膜分割和限制对比度自适应直方图均衡化算法对虹膜图像进行预处理;然后在构建的虹膜差分尺度中检测特征点,得到稳定的局部特征编码区域并采用 FREAK 描述符对特征点及其局部区域进行特征的提取;最后利用双向最近汉明距离对两幅虹膜的特征点进行匹配,根据匹配分数实现虹膜识别。

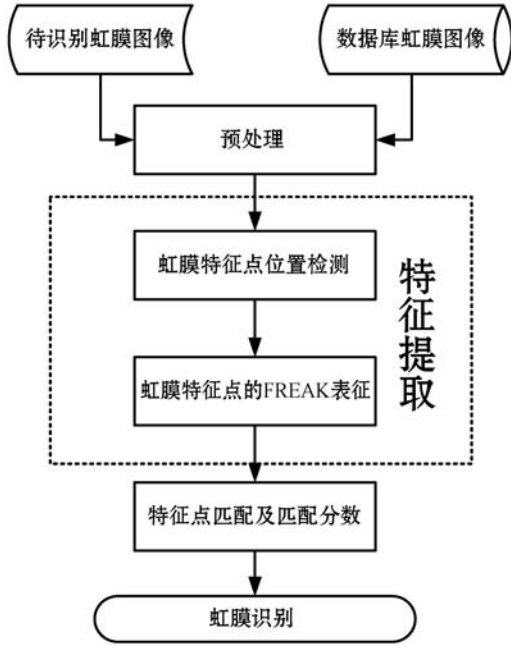


图1 虹膜识别算法框架

1.1 虹膜图像预处理

采集到的虹膜图像通常会包含除了虹膜以外的其他无关信息,在虹膜特征提取前需要将虹膜正确分割出来^[18]。分割后的虹膜通常还需要进行归一化处理以消除虹膜图像中旋转,平移对特征提取带来的影响。由于 FREAK 特征算符本身对于虹膜图像平移、旋转等具有较好的鲁棒性,因此可以在分割后的环形虹膜中直接提取特征,不再对虹膜进行归一化处理。另外,考虑到有些虹膜部分的灰度差异不明显而无法提取到足够的特征点集合,影响到后续的特征点匹配,所以采用限制对比度自适应直方图均衡化算法^[19] (CLAHE)对分割后的虹膜纹理部分进行增强以提高检测到的特征点数量^[20]。虹膜图像预处理流程如图2所示。




图2 虹膜预处理

1.2 虹膜特征点位置检测

为了得到虹膜纹理在不同模糊以及不同尺度下都存在的稳定特征,需要对虹膜图像进行多尺度处理,考虑到高斯核是唯一的线性核,使用高斯核对虹膜图像进行图像模糊的过程中不会引入其他噪声,因此构建虹膜图像的多尺度公式如下:

$$L(x, y, \sigma) = I(x, y) * G(x, y, \sigma) \quad (1)$$

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2)$$

式中: $L(x, y, \sigma)$ 为虹膜图像的尺度空间表征, $G(x, y, \sigma)$ 为高斯核,*为卷积操作, σ 是尺度空间因子,值的大小决定着虹膜图像被模糊平滑的程度,当 σ 连续变化时, $L(x, y, \sigma)$ 构成虹膜图像的尺度空间表征。

利用高斯核做差之后与虹膜图像做卷积得到差分尺度空间:

$$D(x, y, \sigma) = (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) = L(x, y, k\sigma) - L(x, y, \sigma) \quad (3)$$

式中: $D(x, y, \sigma)$ 为差分尺度空间, k 为常数因子。

利用差分尺度空间函数 $D(x, y, \sigma)$ 在虹膜特征点候选点处的泰勒展开式对特征点候选点进行三维二次函数拟合以精确定位特征点候选点位置和尺度同时去除不稳定的特征点,公式如式(4)所示。

$$D(\vec{X}) = D(x_0, y_0, \sigma_0) + \frac{\partial D}{\partial \vec{X}} \vec{X} + \frac{1}{2} \vec{X}^T \frac{\partial^2 D}{\partial \vec{X}^2} \vec{X} \quad (4)$$

式中: $\vec{X} = (x, y, \sigma)^T$,对式(4)求导令其等于零,得到特征点精确位为 $\hat{X} = \frac{\partial^2 D^{-1}}{\partial \vec{X}^2} \frac{\partial D}{\partial \vec{X}}$,代入式(4),根据 $D(\hat{x})$

的响应的绝对值剔除不稳定的低对比度的特征点,之后根据在虹膜特征点处的 Hessian 矩阵,如式(5)所示。

$$H = \begin{bmatrix} D_{xx} & D_{xy} \\ D_{xy} & D_{yy} \end{bmatrix} \quad (5)$$

求出特征点处的主曲率,其中 α 和 β 为矩阵的特征值分别代表在特征点在 x 和 y 方向的梯度大小, $\text{Tr}(H) = D_{xx} + D_{yy} = \alpha + \beta$ 为矩阵的迹,表示矩阵 H 的行列式。令 $\alpha = r\beta$,则有:

$$\frac{\text{Tr}(H)^2}{\text{Det}(H)} = \frac{(\alpha + \beta)^2}{\alpha\beta} = \frac{(r\beta + \beta)^2}{r\beta^2} = \frac{(r+1)^2}{r} \quad (6)$$

若 $\frac{\text{Tr}(H)^2}{\text{Det}(H)} \leq \frac{(r+1)^2}{r}$ 则保留该特征点。

1.3 虹膜特征点的 FREAK 表征

通过构建尺度空间,从虹膜纹理的多个尺度检测到特征点后,FREAK 算法通过对上述特征点邻域生成的采样点灰度值大小关系进行比较得到虹膜纹理中每一个特征点的区分性表征。与其他二值算符不同的是,该算法原理是受到人类视网膜机理的启发,其点采样模型与视网膜感受域结构相似^[21],如图3所示,Fovea 区域获得高分辨率图像,用于识别虹膜图像的细节信息,其他区域获得低分辨率图像,用于识别虹膜图像的轮廓信息^[21]。特征点位于中心,采样点均匀地分布在以特征点为圆心的7层同心圆上。越靠近特征点,采样点分布越密集,越远离特征点,采样点分布越稀疏。为了降低噪声对采样点的影响,需要对每个采

样点进行高斯平滑。

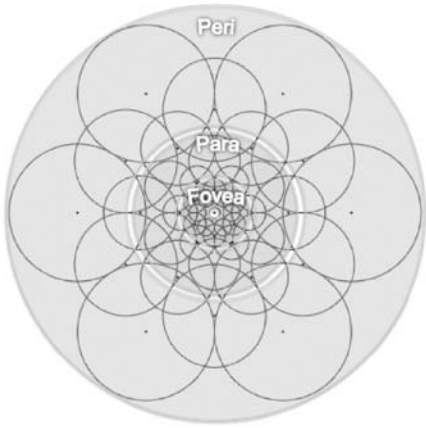


图3 采样模式

FREAK 算符将虹膜特征点周围的采样点两两组成一对,比较每对采样点的灰度值大小得到一个二进制的值,将这些二进制值级联起来得到每个虹膜特征点的描述子 F (特征点的特征向量):

$$F = \sum_{0 \leq a \leq N} 2^a T(P_a) \quad (7)$$

式中: P_a 表示一对采样点感受野; N 为描述子序列长度; $T(P_a)$ 为采样点对的输出结果,通过比较采样点的灰度值大小得到,如式(8)所示。

$$T(P_a) = \begin{cases} 1 & I(P_a^{r1}) - I(P_a^{r2}) > 0 \\ 0 & \text{其他} \end{cases} \quad (8)$$

式中: $I(P_a^i)$ 为经过高斯平滑后的采样点的灰度值强度, $r1$ 和 $r2$ 为不同采样点所在的同心圆半径。

FREAK 采样模式中(如图3)共有43个采样点,两两比较形成 $C_{43}^2 = 903$ 维的描述子,但由于上述采样点之间部分区域的重叠,采样点对之间具有较高的相关性,所以原描述子的区分性并不高,因此对原描述子进行重构,步骤如下:

(1) 对虹膜图像中每一个检测到的特征点进行上述的特征点描述,形成 $N \times 903$ (N 为检测到的特征点个数)的矩阵。

(2) 计算矩阵每一列0、1求和后的均值,该值越接近0.5,表示该列对应的采样点之间的相关性越低。

(3) 将每一列均值与0.5做差后的绝对值按照从小到大顺序排列后取前512列得到每个虹膜特征点最终的描述子。

与文献[12]中采用的SIFT特征点算符和文献[16]中提到的SURF特征点算符相比,FREAK算符是直接根据虹膜特征点周围采样点对的灰度值大小关系进行编码,而与采样点本身的灰度值大小无关,因此抗干扰性能更强,并且这种编码方式也更为简单,得到的二进制描述子在匹配过程中可以采用简单的汉明距离

进行匹配,提高了匹配速度。

1.4 特征点匹配及匹配分数

虹膜特征点描述子采用汉明距离作为两幅虹膜图像中特征点的相似性判定度量。假设匹配两幅虹膜图像 A 和 B ,对于 FREAK 描述子一般采用的匹配策略是选取图 A 中的某个特征点,再从图 B 中找到两个汉明距离最小的特征点,即最近邻 NN (Nearest neighbor) 点和次近邻 SN (Second neighbor) 点,若 $NN/SN \leq \text{Ratio}$ (Ratio 为匹配阈值),则表示图 A 中该特征点与图 B 中与该点汉明距离最小的特征点为一对匹配点。这里我们称图 A 到图 B 的匹配过程为虹膜图像的单向匹配。但这种匹配方式在非同源虹膜之间容易存在较多误匹配点对,为了提高匹配精度,提出双向最近汉明距特征点匹配策略对传统匹配策略进行相应改进,算法实现伪代码如算法1所示。


算法1 基于双向最近汉名距的虹膜特征点匹配算法

输入:待识别虹膜特征点集合 $X = \{x_1, x_2, \dots, x_p\}$, $p \geq 3$, 参考虹膜特征点集合 $Y = \{y_1, y_2, \dots, y_q\}$, $q \geq 3$ 。


输出:待识别虹膜特征点集合和参考虹膜中特征点的匹配关系。

1. for $i = 1$ to p
2. for $j = 1$ to q
3. 计算 x_i 和 y_j 的汉明距离 $hd(x_i, y_j) = \sum x_i \oplus y_j$
4. 找出参考虹膜特征点集中与特征点 x_i 汉明距离最小的特征点 $y_r, r \in [1, q]$:
 $\min(hd(x_i, y_r)) = hd(x_i, y_r)$
5. 计算 y_r 和 x_c 的汉明距离
for $c = 1$ to p
 $hd(y_r, x_c) = \sum y_r \oplus x_c$
end
6. 找出待识别虹膜特征点集中与特征点 y_r 汉明距离最小的特征点 $x_d, d \in [1, p]$:
 $\min(hd(y_r, x_d)) = hd(y_r, x_d)$
7. if $(x_i == x_d)$; 则判定待识别虹膜中特征点 x_i 与参考虹膜中特征点 y_r 为一对匹配点对 $\langle x_i, y_r \rangle$
8. end
9. end


图4给出了一组虹膜图像的特征点匹配结果。




(a) 非同源虹膜单向匹配



(b) 非同源虹膜双向匹配



(c) 同源虹膜单向匹配



(d) 同源虹膜双向匹配

图4 虹膜特征点匹配示意图

图4(a)、4(c)分别为非同源和同源采用单向汉明距离匹配后的结果,非同源虹膜中存在较多的误匹配点,而同源虹膜基本匹配正确,非同源虹膜之间较多的误匹配点会提高误识率(FAR)。图4(b)、4(d)分别为非同源虹膜和同源虹膜经过双向最近汉明距特征匹配算法之后得到的结果,非同源虹膜之间的匹配点数由图(a)的21对降到图(b)的9对,在原匹配策略的基础上匹配点数下降了一半以上,同源虹膜匹配点数由图(c)的57对变成图(d)的55对,基本无变化。因此采用双向最近汉明距离匹配方法能够大大降低非同源虹膜的匹配点对,提高识别性能。最后根据特征点的匹配分数完成虹膜分类,如式(9)所示。

$$\rho = \frac{in}{\min(n_1, n_2)} \quad (9)$$

式中: ρ 为匹配分数, in 为最终匹配成功的特征点对个数, $\min(n_1, n_2)$ 为两幅虹膜图像中提取到的特征点较小值。将计算好的匹配率与一个分类比例阈值 ρ_0 进行比较,若大于该分类阈值,则将两幅虹膜图像归为一类,否则归于不同类。

2 实验与分析

2.1 仿真环境和数据来源

为了测试基于FREAK算符及双向最近汉明距的非理想虹膜识别算法的性能,所有实验均在Inter酷睿

i5-4210U CPU,8 GB 内存,64 位 Windows 10 操作系统, MATLAB R2018b 工具箱的环境下进行仿真测试实验。为了使本文算法更有说服力,采用当前经典虹膜特征提取算法中的Gabor、SIFT、SURF和典型的神经网络 Alex-Net、Inception、ResNet 进行对比实验。虹膜图像来自 CASIA. V3-Interval、CASIA. V4-Syn、UBIRIS. V1 虹膜数据集。

CASIA. V3-Interval 虹膜数据库包含了 249 个人的左右虹膜,总计 395 类 2 639 幅,图像大小为 320×280 ,类型为灰度图像。这些图像中,部分虹膜区域受到光照、眼睑睫毛遮挡、角度旋转的影响,但是影响较小且虹膜纹理清晰。CASIA. V3-Interval 中的虹膜图像示例如图5所示。




图5 CASIA. V3-Interval 中 10 幅虹膜图像示例

CASIA. V4-Syn 虹膜数据库共有 1 000 类样本,每类样本包含 10 幅人工合成的虹膜图像,图像大小为 640×480 ,类型为灰度图像。这些合成的虹膜图像引入人类内变化,包括变形,模糊和旋转等。CASIA. V4-Syn 中的虹膜图像示例如图6所示。




图6 CASIA. V4-Syn 中 10 幅虹膜图像示例

UBIRIS. V1 虹膜数据库包含 241 类虹膜图像,共收集 1 877 幅,图像大小为 200×150 ,类型为灰度图像。最大特点是结合多种噪声因素的干扰,光照不均,虹膜纹理模糊,对比度弱,模拟较少约束的图像采集环境。UBIRIS. V1 中的虹膜图像示例如图7所示。




图7 UBIRIS. V1 中 10 幅虹膜图像示例

2.2 尺度空间的选择

为了得到稳定的特征点,需要构建尺度空间以及差分尺度空间,检测到的特征点数量和稳定性会对识别算法产生不同程度的影响。尺度空间层数越多,检测到的特征点越多,越有利于识别性能的提高,但特征点过多检测时间和编码时间也会随之增加,所以需要

在效率和识别率上寻找一个平衡点,图 8 为本文采用的 3 组,每组 5 层的尺度空间,图 9 为对应的差分尺度空间。图 10 为不同尺度下的特征点检测结果。




图 8 3 组 5 层的尺度空间






图 9 3 组 4 层的差分尺度空间



(a) 2 组 5 层

(b) 3 组 5 层



(c) 4 组 5 层

(d) 5 组 5 层

图 10 不同尺度下的特征点检测结果

图 10 展示了部分尺度空间下检测到的特征点,特征点个数分别为 127、149、162、172。当尺度空间组数为 3,层数为 5 时依然能够提取到足够的特征点,检测到的特征点主要集中分布在纹理更为复杂稳定的靠近中心的内环区域内,同时也减少了虹膜环形区域外伪特征点的提取。

2.3 与其他尺度不变特征提取算法的对比实验

为了验证本文算法的有效性和实时性,与原有的基于 SIFT 算法^[12,20]和基于 SURF 算法^[16]的虹膜识别方法在三个虹膜库上比较等错误率 (EER)、正确识别率 (CRR),以及单次验证识别时间 T_s ,由于 UBIRIS.

V1 和 CASIA. V4-Syn 虹膜纹理质量变化较大,虹膜分割难度大,容易产生分割错误的虹膜图像,因此本实验去除了具有明显分割错误的虹膜图像,最终得到每个虹膜库图像的选取情况及匹配次数如表 1 所示,各虹膜库的 EER、CRR 和单次验证识别时间如表 2 - 表 4 所示,各算法在不同虹膜库中的 ROC 曲线如图 11 所示,其中加粗的数据为最佳实验结果。

表 1 虹膜库介绍和匹配次数

虹膜库名称	类数	同源匹配次数	非同源匹配次数
CASIA. V3-Interval	180	3 780	16 110
CASIA. V4-Syn	195	4 095	18 915
UBIRS. V1	200	2 000	19 900

表 2 各算法在 CASIA. V3-Interval 虹膜库中实验结果


算法	EER/%	CRR/%	TS/s
文献[12]	4.98	98.23	1.10
文献[16]	11.91	94.06	0.60
文献[20]	2.80	99.04	2.11
本文算法	4.14	98.67	0.30

表 3 各算法在 CASIA. V4-Syn 虹膜库中实验结果


算法	EER/%	CRR/%	TS/s
文献[12]	21.30	85.60	1.00
文献[16]	20.70	86.98	0.55
文献[20]	18.10	89.28	1.90
本文算法	13.45	93.54	0.27

表 4 各算法在 UBIRIS. V1 虹膜库中实验结果


算法	EER/%	CRR/%	TS/s
文献[12]	9.22	89.28	1.18
文献[16]	10.96	94.57	0.64
文献[20]	9.89	95.49	2.00
本文算法	8.08	96.61	0.32



(a) CASIA. V3-Interval 虹膜库



(b) CASIA. V4-Syn 虹膜库



(c) UBIRIS. V1 虹膜库

图 11 各算法在不同虹膜库上的 ROC 曲线

由表 2 和图 11(a) 可见: 文献[20]通过对提取到的 Harris-Laplacian、Hessian-Laplacian 特征点进行 SIFT 编码后再进行加权融合的方法在 CASIA. V3-Interval 库上取得了最低的 EER 和最高的 CRR, 表明这三种特征点均能够在虹膜纹理中表达各自独特的信息, 识别性能较好, 但对过多的特征点进行 SIFT 编码显然大大降低了其识别效率, 所以实时性不高, 另外由于 CASIA. V4-Syn 和 UBIRIS. V1 虹膜库情况更为复杂, 纹理更为模糊, Harris-Laplacian、Hessian-Laplacian 特征点与多尺度特征点相比, 在低对比度特征点和具有较强边缘响应的特征点方面处理不够, 造成特征点稳定性不足, 反而降低了识别性能, 由表 3 和表 4 以及图 11(b) 和图 11(c) 所示, 本文算法在 CASIA. V4-Syn 和 UBIRIS. V1 虹膜库上的识别性能和单次识别时间均优于其他算法, EER 分别最少降低了 4.65 个百分点和 1.81 个百分点, CRR 分别最少提高了 4.26 个百分点和 1.12 个百分点, 单次验证时间最少提高了 0.3 s, 分析主要原因是: 通过多尺度特征点检测算法得到的特征点更加稳定, 使得同源虹膜之间在匹配阶段得到的匹配结果基本是稳定的, 在经过双向最近汉明距离完成特

征点匹配过后, 这些匹配对并不会明显减少, 但非同源虹膜之间的误匹配对会在这个阶段明显减少, 从而提高了识别性能。从单次验证时间分析, 本文在特征点描述阶段引入二进制算符 (FREAK) 对特征点描述阶段进行了改进, 生成更为紧凑的二进制描述子, 因此在特征匹配时只需要采用简单异或操作便能完成虹膜验证, 而基于 SIFT 和 SUFR 算法的特征在匹配时采用欧氏距离计算特征点描述子的相似性, 涉及较多的开方运算, 所需要的时间也需要更多, 因此本文在单次虹膜验证时间方面, 实时性更高。

2.4 与基于 Gabor 滤波和深度学习算法的对比实验

为验证本文算法的通用性, 与传统基于 Gabor 滤波和预训练卷积神经网络的虹膜识别算法进行了相关的对比实验, 其中基于 Gabor 滤波识别算法采用的是 Masek 虹膜识别算法^[20]的开源代码, 用 Gabor 滤波器对虹膜滤波的输出结果编码二进制特征向量, 根据特征向量之间的汉明距离判定待分类虹膜图像所属的虹膜类别, 在 CASIA. V3 和 CASIA. V4-Syn 中每类虹膜随机 6 幅虹膜图像作为注册虹膜, 剩余 1 幅虹膜图像作为待识别虹膜, 在 UBIRIS. V1 中随机 4 幅虹膜图像作为注册虹膜, 剩余 1 幅虹膜作为待识别虹膜, 和本文算法都采用的是最近邻分类方法进行虹膜识别。基于预训练卷积神经网络的虹膜特征提取算法采用的是 Maram. G 文中的 Alex-Net 网络和 KIEN 文中的 Inception 网络与 ResNet 网络, 根据 SVM 的分类结果进行虹膜识别, 比较本文算法与以上算法在 CASIA. V3-Interval、CASIA. V4-Syn、UBIRIS. V1 虹膜库上的正确识别率 (CRR)。

表 5 为各算法在三个虹膜库上的实验结果, 在 CASIA. V3-Interval 库中, 所提算法和 Masek 算法的正确识别率分别为 98.67% 和 98.81%, 两者在该库上的虹膜识别性能相似。分析原因主要是因为该虹膜库纹理非常清晰且变化较小, 本文算法和 Masek 算法都能在虹膜区域提取到其中稳健的特征信息, 进而较好地完成对虹膜的分类。在 CASIA. V4-Syn 和 UBIRIS. V1 虹膜库中, 相比 Masek 和三个卷积神经网络算法, 本文算法的正确识别率 (CRR) 更高。这是因为 UBIRIS. V1 中的虹膜在采集过程中条件较为宽松, CASIA. V4-Syn 人为地在虹膜纹理中添加了各类噪声, 因此类内虹膜纹理自身变化较大, 纹理和非纹理之间的界限变得模糊, Gabor 对于纹理变化敏感, 而卷积神经网络的训练样本不足、支持向量机 (SVM) 很难建立使得虹膜图像类别分开的超平面, 造成识别率不是很高, 本文的虹膜特征提取算法从多个尺度提取到虹膜纹理内部足够稳定的

特征点,根据特征点周围采样点大小关系进行编码,在每类虹膜图像数量有限情况下,能有效抵抗纹理变化虹膜纹理变化对识别性能带来的影响,通用性较好。

表5 各算法在虹膜库上的实验结果

算法	CRR/%		
	CASIA. V3-Interval	CASIA. V4-Syn	UBIRS. V1
Masek	98.81	61.99	66.66
Alex-Net	72.58(fc7)	77.27(fc6)	79.69(fc6)
Inception	72.98	67.53	71.16
ResNet	84.68	76.62	87.50
本文算法	98.67	93.54	96.61

3 结 语

本文针对虹膜识别这个场景,首先通过构建尺度空间以及差分尺度空间在虹膜区域检测稳定可靠的特征点集合,对特征点为中心的局部区域采用 FREAK 算法提取特征后,将得到的二进制特征向量进行重构降维能够有效地提高特征的特异性表达,计算速度以及节约所需的存储空间,最后采用双向最近汉明距离进行特征点匹配,提高特征点匹配的稳定性。本文在 CASIA. V3-Interval、CASIA. V4-Syn 和 UBIRS. v1 三个受不同程度噪声干扰的非理想虹膜数据集上进行仿真实验,通过分析虹膜的正确识别率、等错误率和单次验证时间等指标,说明基于 FREAK 算符及双向最近汉明距的非理想虹膜识别算法具有较好的通用性。算法针对实际应用中计算能力和储存空间有限的嵌入式和移动虹膜识别产品具有重大意义。

参 考 文 献

[1] 李星光,孙哲南,谭铁牛. 虹膜图像质量评价综述[J]. 中国图象图形学报,2014,19(6):813-824.

[2] 刘元宁,刘帅,朱晓冬,等. 基于高斯拉普拉斯算子与自适应优化伽柏滤波的虹膜识别[J]. 吉林大学学报(工学版),2018,48(5):1606-1613.

[3] 朱晓冬,张齐贤,刘元宁,等. 基于多方向局部二值模式与稳定特征的虹膜识别[J]. 吉林大学学报(工学版),2021,51(2):650-658.

[4] Daugman J G. High confidence visual recognition of persons by a test of statistical independence[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,1993,15(11):1148-1161.

[5] Yao P, Li J, Ye X Y, et al. Iris recognition algorithm using modified Log-Gabor filters[C]//18th International Conference on Pattern Recognition,2006:461-464.

[6] Wildes R P, Asmuth J C, Green G L, et al. A machine-vision system for iris recognition[J]. Machine Vision and Applications,1996,9(1):1-8.

[7] 田启川,潘泉,程咏梅,等. 基于过零检测的虹膜特征提取算法[J]. 电子与信息学报,2006(8):1452-1457.

[8] 苑玮琦,李平,柯丽. 基于小波过零点位置不等长编码匹配的虹膜识别[J]. 光学精密工程,2009,17(8):2040-2046.

[9] 李欢利,郭立红,李小明,等. 基于统计特征中心对称局部二值模式的虹膜识别[J]. 光学精密工程,2013,21(8):2129-2136.

[10] Alaslani M G, Elrefaei L A. Convolutional neural network based feature extraction for iris recognition[J]. International Journal of Computer Science & Information Technology,2018,10(2):65-78.

[11] Nguyen K, Fookes C, Ross A, et al. Iris recognition with off-the-shelf CNN features: A deep learning perspective[J]. IEEE Access,2017,6:18848-18855.

[12] Yang G P, Pang S H, Yin Y L, et al. SIFT based iris recognition with normalization and enhancement[J]. International Journal of Machine Learning and Cybernetics,2013,4(4):401-407.

[13] Lown D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision,2004,60(2):91-110.

[14] Zhu R H, Yang J F, Wu R B. Iris recognition based on local feature point matching[C]//International Symposium on Communications and Information Technologies,2006:451-454.

[15] Sun Z N, Zhang H, Tan T, et al. Iris image classification based on hierarchical visual codebook[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2013,36(6):1120-1133.

[16] Ali H S, Ismail A I, Farag F A, et al. Speeded up robust features for efficient iris recognition[J]. Signal, Image and Video Processing,2016,10(8):1385-1391.

[17] Alahi A, Ortiz R, Vanderghyest P. FREAK: Fast retina keypoint[C]//IEEE Conference on Computer Vision and Pattern Recognition,2012:510-517.

[18] 王红叶. 基于尺度不变特征变换的虹膜识别方法[D]. 长春:吉林大学,2014.

[19] Zuiderveld K. Contrast limited adaptive histogram equalization[J]. Graphics Gems,1994,5:474-485.

[20] Alvarez-Betancourt Y, Garcia-Silvente M. A keypoints-based feature extraction method for iris recognition under variable image quality conditions[J]. Knowledge-Based Systems,2016,92:169-182.

[21] 王灿进,孙涛,陈娟. 基于 FREAK 特征的快速景象匹配[J]. 电子测量与仪器学报,2015,29(2):204-212.

[22] Masek L. Recognition of human iris patterns for biometric identification[D]. Perth: University of Western Australia,2003.