



基于深度残差网络与离散哈希的指静脉识别方法

张娜¹, 陈春宇¹, 徐璐¹, 涂小妹¹, 包晓安¹, 吴彪²

(1. 浙江理工大学信息学院, 杭州 310018; 2. 山口大学东亚研究科, 日本山口 753-8514)

摘要: 针对传统卷积神经网络提取的特征不够充分、自学习特征稀疏导致指静脉识别精度和识别速度不高的问题, 提出了一种基于深度残差网络和离散哈希的二元特征指静脉识别方法。首先, 在深度残差网络模型训练过程中提出将加性角边缘损失函数作为监督信号, 扩大类间差, 缩小类内差; 其次, 将归一化后的指静脉图像输入改进的深度残差模型进行特征提取; 然后, 提出采用监督式离散哈希模型对实值特征进行离散化, 获得二值化特征替代原有的实值特征; 最后, 采用哈明距离计算二值化特征与指静脉库中的模板间的匹配分数确定识别结果。实验结果表明: 在 MMCBNU_6000 数据集上, 指静脉识别准确率达 96.59%, 同时模板尺寸缩减为 1024 bit, 是常用的实值特征模板尺寸的 1/16; 在 FV-USM 数据集上, 模板尺寸缩减为 1024 bit 时, 指静脉识别准确率达到 95.37%。

关键词: 指静脉识别; 深度残差网络; 监督式离散哈希; 二值化特征; 哈明距离

中图分类号: TP391.4

文献标志码: A

文章编号: 1673-3851(2020)07-0549-08

Finger vein recognition method based on deep residual network and discrete hashing

ZHANG Na¹, CHEN Chunyu¹, XU Lu¹, TU Xiaomei¹, BAO Xiaolan¹, WU Biao²

(1. School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China;

2. Department of East Asian Studies, Yamaguchi University, Yamaguchi 753-8514, Japan)

Abstract: Concerning low accuracy and low speed of finger vein recognition due to insufficiency in feature extraction by traditional convolutional neural network and sparse self-learning features, a binary feature finger vein recognition method based on deep residual network and discrete hashing is proposed. Firstly, it is proposed to take the additive angular margin loss function as the supervised signal in the process of deep residual network model training to expand the inter-class difference and reduce the intra-class difference. Secondly, the normalized finger vein image is input into the improved deep residual model for feature extraction. Then, it is proposed to discretize the real-valued features using the supervised discrete hashing model to obtain the binary features as a replacement. Last, the Hamming distance is used to calculate the matching score between the binary feature and the template in the finger vein library to determine the result of recognition. Experimental results show that on the MMCBNU_6000 dataset, the accuracy of finger vein recognition is up to 96.59%, and the template size is reduced to 1024 bits, 1/16 of the size of commonly used real-valued feature template; on the FV-USM dataset, when the template size is reduced to 1024 bits, the accuracy of finger vein recognition reaches 95.37%.

Key words: finger vein recognition; deep residual network; supervised discrete hashing; binary feature; Hamming distance

收稿日期: 2019-12-23 网络出版日期: 2020-03-05

基金项目: 浙江省自然科学基金青年基金项目(LQ20F050010); 浙江省重点研发计划项目(2020C03094)

作者简介: 张娜(1977—), 女, 浙江东阳人, 副教授, 硕士, 主要从事智能信息处理方面的研究。

通信作者: 包晓安, baoxiaolan@zstu.edu.cn

0 引言

随着信息技术的快速发展,利用生物特征进行个人身份验证的技术受到人们越来越多的关注。生物特征识别技术是利用人体的生理特征或者行为特征进行的身份认证,与传统的身份认证方法^[1]相比具有极高的安全性^[2]。人体的生物特征主要有人脸、虹膜、指纹、掌纹、指静脉、掌静脉、行为特征步态、笔迹等。在这些生物特征中,指静脉因具有活体采集、使用方便、防盗取性强^[3]等特点被研究者逐步重视。指静脉认证主要是利用手指内静脉的分布图像进行身份认证,每个手指静脉之间的交叉点、角度以及空间位置被认为是排它信息,而排它信息是可以被用来生成一个唯一的密钥^[4]。

指静脉识别作为生物识别的重要技术之一,研究学者提出了多种手指静脉的识别认证方法,主要分为两大类。第一类是基于传统的模式识别方法,运用基于结构特征或者纹理特征进行识别的思想,提取手指静脉中的几何线和特征点的结构特征或者提取手指静脉中的局部或者全局纹理特征等^[5]。如 Lee 等^[6]研究中采用加权的局部二值模式特征进行手指静脉的识别, Song 等^[7]研究中采用平均曲率进行指静脉识别。但这类的识别方法受限于手指静脉图像的质量,在实际应用中的效果还有待提高。第二类是基于学习的指静脉识别方法,通过算法模型学习如何提取指静脉之间具有区分性的区别,从而避免人工提取特征导致的有效特征提取困难的问题。早期基于学习的指静脉识别算法研究,一般采用手工提取的指静脉特征用来做识别,如 SIFT^[8]、LBP^[9]等,而采用手工提取的特征进行学习的算法识别性能提高有限,识别性能提高的关键应该是自动学习具有区分性的指静脉特征。随着深度学习和卷积神经网络的快速发展,越来越多的学者开始研究基于深度学习以及卷积神经网络的指静脉识别方法,如何鑫等^[10]提出的基于改进卷积神经网络的指静脉识别,戴庆华等^[11]提出的基于孪生卷积神经网络的指静脉识别等,都取得了较好的效果。从以上研究可以发现,基于深度学习的方法能够有效地提取出静脉的纹理以及结构特征,因此基于深度学习的指静脉识别方法越来越受到研究者的重视。

本文提出了一种基于深度残差网络与离散哈希的指静脉识别方法,在有效缩小模板尺寸、大幅提高匹配速度的情况下提高识别准确率。首先,针对指

静脉图像具有区分性的特征提取困难的问题,采用改进的深度残差网络进行指静脉特征的提取:网络使用参数修正线性单元(Parametric rectified linear unit, PRelu)函数作为激活函数,避免修正线性单元(Rectified linear unit, Relu)函数作为激活函数导致的部分处于非敏感区特征消失的问题,从而进一步提高网络提取特征的能力;采用 Additive angular margin loss^[12]作为损失函数,扩大不同指静脉特征的距离,缩小同一指静脉特征间的差距,从而提高算法的泛化能力。其次,指静脉模板匹配的精度和速度作为在指静脉识别应用中最重要指标,针对模板尺寸大造成储存和检索压力过大的情况,本文通过有监督的离散哈希^[13-14](Supervised discrete hashing, SDH)算法对高维实值特征进行离散哈希,显著减小指静脉模板尺寸,同时利用哈密距离计算二值哈希特征实现模板匹配速度的大幅提高。

1 算法理论

1.1 残差网络模型

使用深层卷积神经网络通常是希望深层网络相较浅层网络可以更好地表征图像的特征,因为网络越深意味着参数量越多,非线性表达能力越强。但在实际应用发现,如果只是简单的堆积神经网络层,然后采用标准的优化算法进行训练,如随机梯度下降法等,会出现深层网络的训练结果较浅层网络结果更差的情况,这是由于深层神经网络出现了网络退化问题(Degradation problem)。而残差网络^[15]是在增加神经网络层数的同时,添加不同层之间的恒等映射(Identity mapping),从而解决深层网络的网络退化问题。

本文的残差网络模型如图1所示,采用 Resnet50 结构,将归一化的指静脉图像送入第一个卷积核为 7×7 的卷积层中,并对卷积层输出进行批标准化(Batch-Norm)和 PRelu 激活。其后是4个网络层集合共24个残差块、一个 dropout^[16]层、一个全连接输出层(Fully connected layer)以及相应的批标准化层和激活函数层。为了可以使网络更好地得到训练,添加了 Batch-Norm^[17]层、dropout 层,采用 PRelu^[18]函数替代原有的 Relu 函数作为激活函数,从而提高了网络对指静脉特征的提取能力。PRelu 函数作为激活函数在只增加极少量参数的情况下,不仅可以有效减少特征在网络传递过程中的损耗,还可以针对每个通道选择更为合适的激活函

数,极大地提高了网络表征的能力。针对传统的交叉熵损失函数对于细粒度图像分类的泛化性能不佳,类间距离较小、类内距离较大,本文将加性角边缘损失函数(Additive angular margin loss)作为目标函数,进一步扩大类间的距离,缩减类内距离,提高网络模型的泛化能力。

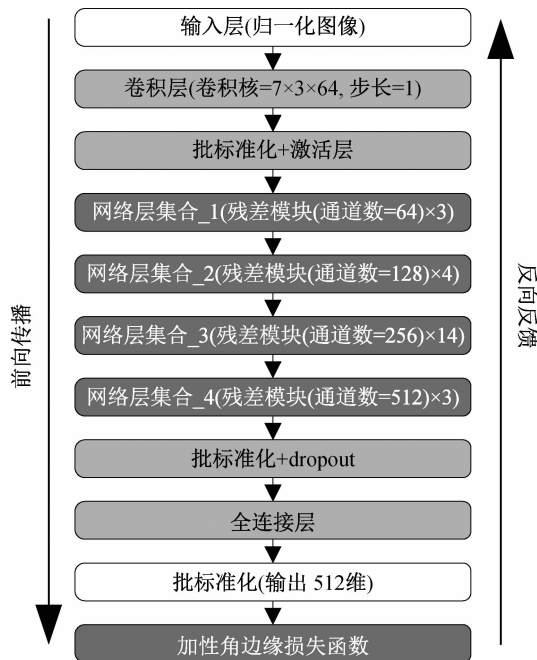


图1 深度残差网络模型

1.1.1 残差模块

传统的卷积神经网络或者全连接网络在进行信息的传递时,或多或少的会出现信息的丢失、损耗等问题,同时会引发梯度爆炸或者梯度消失问题,进而导致深度网络的性能差,效果还不如浅层网络。残差模块在一定程度上解决了这个问题,在进行网络层信息传递的同时,直接将输入信息传递到网络模块输出位置,避免了信息的丢失。这种将输入信息直接传递到输出端的层,被称为恒等映射层。本文采用了预激活的残差模块^[19],将残差分支中的激活层放在卷积之前,可以保证尽量不影响恒等分支的数据,使图像的信息得到更好的保存。

本文所采用的残差模块结构如图2所示。网络输入为 X ,通过残差网络模块学习得到输出特征 H_X ;残差模块有两个分支,一个是恒等映射(Identity mapping)分支 X ,另一个是残差学习(Residual learning)分支 F_X 。为了避免在学习的过程原有特征的遗失,在保留原有特征的基础上继续进行学习,即进行残差学习 $F_X = H_X - X$,使得在残差网络学习不到新特征($F_X = 0$)的情况下,网络

的原有特征也不会丢失,很好地解决了网络的退化问题。在 F_X 不为0的情况下,即网络在原有特征的基础上又学习到了新的特征,很好地提高了网络性能。

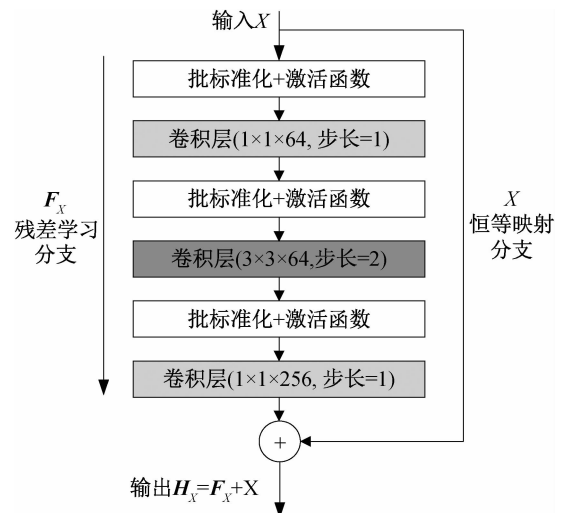


图2 残差模块结构框图

深度残差网络中第 m 个残差模块到第 $m+k$ 个残差模块所学习的网络特征为:

$$X_{m+k} = X_m + \sum_{i=m}^{m+k-1} F_{X_i} \quad (1)$$

其中: X_i 表示第 i 个残差模块的输入和第 $i-1$ 个残差模块的输出, F_{X_i} 表示第 i 个残差模块经过残差学习后的输出。从式(1)中可以看出,无论网络模型叠加多少个残差模块,最后一个残差模块的输出中总是包含着第一个残差模块的输入,即输入数据的原始信息不会丢失。

1.1.2 加性角边缘损失函数

加性角边缘损失函数是根据加性余弦边缘损失^[20](Additive cosine margin loss)函数改进而来的,因为角度距离比余弦距离对角度的影响更加直接。与余弦边相比,实现角度空间内最大化分类界限相对于余弦空间有更清晰的几何解释,而且角度空间中的角边缘距离对应着超球面上的弧距。如式(2)所示, $e^{s(\cos(\theta_{y_i} + m))}$ 表示分类正确时label的值,添加角边参数 m 在 $\cos(\theta)$,因为当 θ 在0和 $\pi-m$ 之间时, $\cos(\theta + m)$ 比 $\cos(\theta)$ 更小,损失值会更大,所以这种约束对于分类更加严格。损失函数公式可以表示为:

$$Loss = -\frac{1}{k} \sum_{i=1}^k \log \frac{e^{s(\cos(\theta_{y_i} + m))}}{e^{s(\cos(\theta_{y_i} + m))} + \sum_{j=1, j \neq y_i}^n e^{s(\cos(\theta_j))}} \quad (2)$$

此时,需要满足以下条件:

$$\begin{cases} W_j = \frac{W_j}{\|W_j\|} \\ x_i = \frac{x_i}{\|x_i\|} \\ \cos(\theta_j) = W_j^T x_i \end{cases} \quad (3)$$

其中: k, n 分别表示批数量(Batch size)和类别数, W_j 表示网络最后的全连接层中参数矩阵 W 的第 j 列, x_i 表示第 i 个样本的特征序列, s 表示超球面的半径, 有关 s 值限制的讨论见文献^[21]。在本文的实验中, s 设置为 64, 角边参数 m 设置为 0.5。

加性角边缘损失函数相对于交叉熵损失函数可以有效扩大不同指静脉特征之间的类间距离, 缩小同一指静脉特征之间类内距离。以二分类为例, 加性角边缘损失函数的决策边界是 $s(\cos(\theta_1 + m) - \cos(\theta_2)) = 0$, 类别 1 和类别 2 之间的距离由两个类别的自有参数 θ_1, θ_2 和角边参数 m 决定, 而如果不添加角边参数 m , 则损失函数为交叉熵损失函数, 其决策边界是 $s(\cos(\theta_1) - \cos(\theta_2)) = 0$ 。二分类决策边界对比情况如图 3 所示, 其中图 3(a) 为不添加角边参数的交叉熵损失函数的决策边界示意图, 图 3(b) 为添加角边参数的角边缘损失函数的决策边界示意图。由图 3 可知, 增加角边参数 m 可以使同一类别指静脉图像差别更小, 不同类别指静脉图像特征差别更大。




图 3 二分类决策边界示意图

1.2 监督式离散哈希算法

Shen 等^[13]提出了一种可以把高维的实值特征转换成低维二元特征的监督式离散哈希算法。这种哈希算法的主要优点在于极大的减少指静脉模板的存储空间, 同时二值化模板对匹配速度的性能提升也是巨大的, 因为其计算匹配分数所需的哈密顿距离要比计算实值特征向量间的欧氏距离快的多。

监督式哈希算法生成的二进制特征向量间的匹配分数和上节中神经网络输出的实值特征向量间的匹配分数保持一致。SDH 算法的训练阶段主要是

从 n 张图像对应的特征向量集 $X = \{x_i\}_{i=1}^n$ 和对应的标签矩阵 $Y = \{y_i\}_{i=1}^n$ 中学习获得 L bit 的二进制特征向量集 $E = \{b_i\}_{i=1}^n$ 。

SDH 算法求得的二元编码是用于多分类的, 多分类的公式可以表示为:

$$y = W^T b = [w_1^T b, \dots, w_C^T b] \quad (4)$$

其中: w_k 表示类别 k 的表示向量, k 为类别序列号, 1 到 C , 一共有 C 个类别; y 表示标签向量, 其最大值表示预测的类别。

$$W = (EE^T + \lambda I)^{-1} EY^T \quad (5)$$

其中: W 表示多分类的参数矩阵; λ 表示正则化参数, $Y = \{y_i\}_{i=1}^n \in \mathbb{R}^{C \times n}$ 表示真实的标签矩阵, 当 x_i 属于 k 类时 $y_{ki} = 1$ 而 $y_{ji, j \neq k} = 0$; I 表示单位矩阵; E 表示二元编码。

$$S = (U_X U_X^T)^{-1} U_X E \quad (6)$$

其中: U_X 表示特征集 X 通过 RBF 核映射出的列向量。

$$H(X) = S^T U_x \quad (7)$$

其中: $H()$ 表示自学习的哈希函数。

$$z = \text{sgn}(q - E'^T W'^T v) \quad (8)$$

其中: z^T 表示 E 的第 l 行; $l = 1, \dots, L$; E' 示矩阵 E 中除了 z 之外的矩阵。类似的, q^T 表示 Q 的第 l 行, Q' 表示矩阵 Q 去除 q , v^T 表示 W 的第 l 行, W' 表示矩阵 W 去除 v , 其中 $Q = WY + vH(X)$ 。推导的详细内容见文献^[13]相关内容。

监督式离散哈希算法的输入数据有训练数据集训练集数据 $\{x_i, y_i\}_{i=1}^n$ 、编码长度 L 、锚点数 m 、最大迭代数 t 、正则化参数 λ 和 v ; 输出数据有二元编码 $\{b_i\}_{i=1}^n \in \{-1, 1\}^{L \times n}$ 、哈希函数 $H(x) = \text{sgn}(H(x))$, $\text{sgn}()$ 表示符号函数, 输入整数则为 1, 否则为 0。训练步骤如下:

步骤 1: 从训练集数据中随机选择 m 个样本 $\{a_j\}_{j=1}^m$, 通过 RBF 核计算映射出的一个 m 维列向量 $U_x = [e^{\frac{\|x-a_1\|^2}{\sigma}}, \dots, e^{\frac{\|x-a_m\|^2}{\sigma}}]$, σ 表示核的宽度;

步骤 2: 随机初始化 b_i , b_i 是一个长度为 L 的二元 $\{-1, 1\}$ 向量;

步骤 3: 循环直到收敛或者达到最大迭代次数: a) 使用最小二乘法如式(5)参数矩阵 W ; b) 使用式(6)计算映射矩阵 $S \in \mathbb{R}^{m \times L}$, S 矩阵将向量 U_x 从高维映射到低维, 通过非线性式(7)计算哈希函数 $H(x)$; c) 选用 L2 损失函数, 采用式(8)的 DCC 算法按位迭代学习 $\{b_i\}_{i=1}^n$ 。

1.3 基于深度残差网络和 SDH 的指静脉识别

本文提出的指静脉识别算法流程如图 4 所示,

主要分为训练部分和测试部分。训练部分采用离线训练的方式进行参数的自动学习。首先,对训练集中的指静脉图像进行图像预处理以及归一化等操作;其次,将归一化后的指静脉图像送入1.1所述的

深度残差网络进行特征学习,提取出具有区分性的实值特征;然后,使用1.2所述的监督式离散哈希算法对深度残差网络提取出的实值特征进行学习,获得二值的指静脉特征。

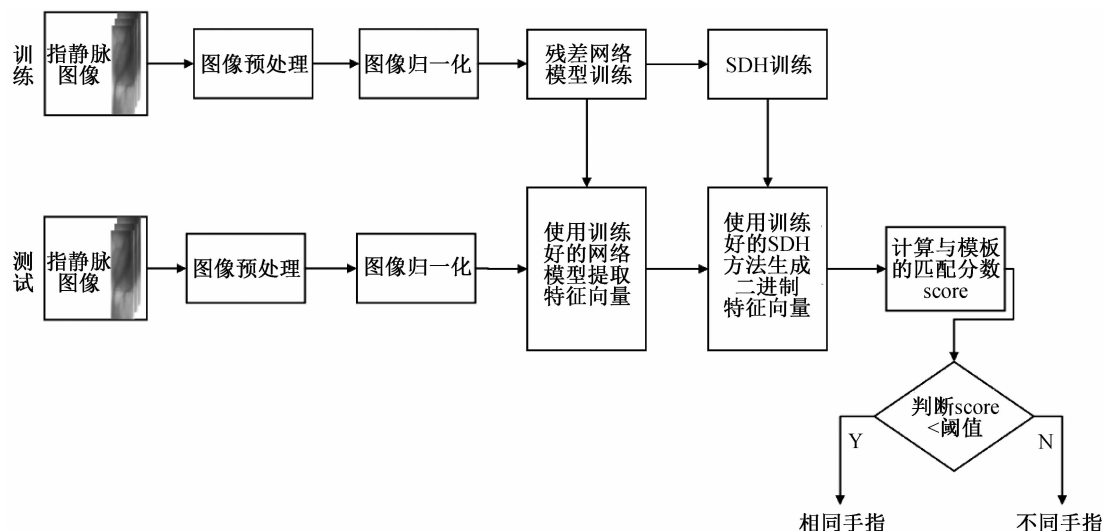


图4 算法流程

测试部分的数据集采用和训练集完全不同的手指静脉图像集。首先,预处理和归一化部分采用和训练部分相同的操作;其次,通过预训练的深度残差网络模型对归一化后的指静脉图像进行特征提取;然后,将提取的指静脉实值特征序列送入预训练的监督式离散哈希算法模型中离散化,生成基于哈明距离匹配的二值化特征。最后,计算指静脉图像二值特征序列与指静脉模板间的哈明距离作为匹配分数 score,进而根据设置的阈值确定识别结果。

2 实验设计与结果分析

本文实验所用的计算机配置如下:CPU 为 Intel(R) Core(TM) i7-4790K CPU;主频为 4.00 GHz;系统为 64 位系统。采用 python3.6 作为编程语言,深度学习框架选用 Tensorflow 1.10。

2.1 数据集及实验设置

本文使用了两个公开的指静脉数据集,分别是韩国全北国立大学多媒体实验室的指静脉图像数据集^[22](MMCBNU_6000)以及马来西亚理工大学指静脉数据集(FV-USM)。MMCBNU_6000 指静脉数据集包含 100 个人的指静脉数据,每人采集 6 根手指,共计 600 根手指,每根手指 10 张静脉图像,共包含 6000 张图像;FV-USM 数据集包含 123 个人,每人采集 4 根手指,共采集 2 期,每期每根手指采集 6 张静脉图像,共包含 5904 张图像。MMCBNU_6000 数据集和 FV-USM 数据集提取 ROI 区域后的

示例图像图 5 所示。MMCBNU_6000 指静脉数据集提取 ROI 区域后归一化尺寸为 60×128 (宽度 \times 高度),FV-USM 数据集提取 ROI 区域后归一化尺寸为 100×300 (宽度 \times 高度)。网络结构参数如卷积核尺寸、卷积步长等根据图像大小做相应调整。




图5 MMCBNU_6000 数据集和 FV-USM 数据集示例图像

MMCBNU_6000 数据集取 500 根手指作为训练集,每根手指 10 张样本,共 5000 张图片;其余 100 根手指作为测试集,每根手指 10 张样本,共 1000 张图片。训练时学习率设置为动态学习率,按照训练批次进行衰减,初始值为 0.0010,在训练批次达到 10、50、100 时分别衰减为 0.0005、0.0003、0.0001。Batch size 设置为 32。使用训练好的网络模型对测试数据集进行验证,在测试集中任取两张同源图片对,可以得到 4500 对同源图像对作为正样本对,因为异源图像对的总个数远远大于同源样本对的数量,为了保持正负样本对数量基本保持一致,在异源图像对中随机抽取 4500 对异源图像对作为负样本对。同样的,对 FV-USM 数据集选取 420 根手指共计 5040 张图像作为训练数据集,其余 72 个手指共 864 张作为测试集进行实验。将所有测试样

本对进行 K 折交叉验证, K 选择 10。

2.2 不同网络结构的对比实验

为了验证本文中使用预激活残差模块、PReLU 激活函数构成以及加性角边缘损失函数的深度残差网络对指静脉的识别性能优于传统的卷积神经网络, 本文设计了不同网络结构以及损失函数进行指静脉识别的对比实验。方法一选用传统的 Alexnet 网络进行指静脉识别, 损失函数为多分类交叉熵损失函数, 即 softmax 损失函数; 方法二选用激活函数为 PReLU、预激活残差模块的深度残差网络, 损失函数采用 softmax 损失函数; 方法三选用激活函数为 PReLU、预激活残差模块的深度残差网络, 损失函数采用加性角边缘损失函数。

不同网络结构下指静脉识别性能见表 1。由表 1 可知, 深度残差网络中采用 PReLU 激活函数以及预激活残差模块相比于传统的残差网络, 网络泛化能力更强, 提取的特征更利于指静脉之间的区分。同时, 采用加性角边缘损失函数相比于一般的 softmax 损失函数可以使指静脉图像的类间距离更大, 类内距离更小, 使网络具有更好的泛化性能。

表 1 不同网络结构下指静脉识别性能

实验方法	MMCBNU_6000 库		FV-USM 库	
	准确率/%	AUC	准确率/%	AUC
方法一	90.14	0.9667	89.52	0.9642
方法二	97.42	0.9923	95.71	0.9884
方法三	98.07	0.9937	97.10	0.9942

本实验的受试工作特征曲线(Receiver operator characteristic curve, ROC 曲线)如图 6 所示, 其中横轴坐标表示将负例判断为正例的概率(False positive rate, FPR), 纵轴坐标表示将正例判断为正例的概率(True positive rate, TPR)。通过实验结果, 本文的方法取得了较高的 AUC 值。




图 6 受试工作特征曲线

本实验采用 1:1 匹配方式, 在测试集中选择两张指静脉图像, 对图像的特征进行归一化, 然后计算两张图像归一化特征之间的距离。MMCBNU_

6000 数据集中选择了测试集中的 4500 组正样本对和 4500 组负样本对。FV-USM 数据集中选择了测试集内的 4752 组正样本对和 4752 组负样本对用来统计。MMCBNU_6000 数据集和 FV-USM 数据集在方法三中的距离验证结果见图 7。图 7 中横坐标表示指静脉图像归一化特征之间的欧氏距离, 纵坐标表示距离的分布比例。从图 7 中可以看出, 正样本对和负样本对的距离分布区别明显, 左边的实线表示正样本对的距离分布图, 主要分布在 0 到 1.0 之间, 右边的虚线表示负样本对的距离分布图, 主要集中在 1.2 到 2.8 之间。




图 7 MMCBNU_6000 数据集和 FV-USM 数据集
在方法三中的匹配距离

2.3 不同二值特征长度的对比实验

为了验证采用监督式离散哈希算法将指静脉实值特征压缩为二元离散特征的有效性, 本文设计了不同长度指静脉特征对指静脉识别性能影响的对比实验。如表 2 所示, 在 MMCBNU_6000 数据集上比较 512 维实值特征和 SDH 算法生成的 128 位、512 位、1024 位和 2048 位二元特征对于指静脉识别性能的影响可知, 采用 SDH 算法对实值特征进行离散化, 可以在准确率略微下降的情况下, 大幅度地减少指静脉模板的存储空间, 同时可以极大地提高检索效率。本实验设置锚点数 m 为 1000 个, 最大迭代数为 5。

表2 MMCBNU_6000 数据集中不同长度指静脉特征对比

实验方法	模板长度/bit	空间压缩比例	1:1000 耗时/s	时间压缩比例	准确率/%	AUC
无 SDH	512×32	1.000	0.4513	1.0000	98.07	0.9937
SDH-128-bit	128	7.813×10^{-3}	0.0374	0.0828	94.93	0.9842
SDH-512-bit	512	3.125×10^{-2}	0.1395	0.3091	96.17	0.9893
SDH-1024-bit	1024	6.250×10^{-2}	0.2811	0.6228	96.59	0.9952
SDH-2048-bit	2048	1.250×10^{-1}	0.5673	1.2570	96.84	0.9917

基于 MMCBNU_6000 数据集的实验结果如表 2 所示,随着二元离散特征长度的增加,准确率也在增加,当大于 1024 位后准确率增长相对缓慢而 AUC 值开始下降,综合考虑,当二元离散特征长度设置为 1024 位时准确率下降相对较少,而且时间以及空间的压缩比例也达到了较高的水平。结果中的计算耗时实验采用最简单的数学计算,未采用相关加速操作,仅可作为参考。受试工作特征曲线如图 8 所示。




图8 MMCBNU_6000 数据集 SDH 算法受试工作特征曲线

本实验在 FV-USM 数据集上的结果与在 MMCBNU_6000 数据集上的结果基本一致,实验结果见如表 3。

表3 FV-USM 数据集中不同长度指静脉特征对比

实验方法	准确率/%	AUC
无 SDH	97.10	0.9942
SDH-128-bit	91.32	0.9658
SDH-512-bit	94.46	0.9832
SDH-1024-bit	95.37	0.9880
SDH-2048-bit	95.61	0.9871

2.4 与现有方法的对比实验

上述实验已经证明了改进的深度残差网络和监督式离散哈希算法的有效性,本部分将本方法与现有方法进行比较。相对于基于深度学习的指静脉识别方法,基于传统方法的指静脉识别更加成熟,本实验将张严严等^[23]研究中提出的基于指静脉方向场图的识别方法、刘广东等^[24]研究中提出的基于多模式 LBP 与深度森林的指静脉识别方法与本文的方法进行对比。以上两种方法的相关实验中采用了不同的评价标准,为了让实验结果更加直观,本实验的评价标准仍然使用上述实验的评价标准,由于深度森林方法输出为分类概率,设定训练类别数为 512,即模板长度为 512 位浮点型。对比结果如表 4 所示,本文的方法在指静脉识别的准确率和识别速度达到了较好的水平。

表4 与现有算法的性能对比表

实验方法	MMCBNU_6000 库			FV-USM 库		
	准确率/%	模板长度/bit	1:1000 耗时/s	准确率/%	模板长度/bit	1:1000 耗时/s
方向场图方法	93.86	60×128×8	1.7853	93.03	100×300×8	13.2830
深度森林方法	97.53	512×32	0.4632	97.32	512×32	0.4632
方法三	98.07	512×32	0.4513	97.10	512×32	0.4513
SDH-1024-bit	96.59	1024	0.2811	95.37	1024	0.2811

3 结束语

本文提出了一种基于深度残差网络和监督式离散哈希算法的二元特征指静脉图像识别算法,通过使用结构更优的深度残差网络解决了传统卷积神经网络提取特征不充分的问题,并提出了将加性角边缘损失函数用于提升指静脉图像的区分度,使指静

脉图像的类内间距更小、类间间距更大,提高了网络的泛化能力。同时,在指静脉识别中,本文提出了将监督式离散哈希算法用于二元特征离散,在准确率略微降低的情况下极大的减少了模板尺寸、提高了指静脉检索的效率。算法在公开库上的软件仿真结果表明,本文提出的指静脉识别方法具有较好的综合性能,满足指静脉识别要求。

参考文献:

- [1] 黄静,岳梦婕.基于 AES 和 RSA 双向认证登录方案的研究[J].浙江理工大学学报(自然科学版), 2017, 37(2): 242-245.
- [2] Jain A K, Ross A, Prabhakar S. An introduction to biometric recognition[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2004, 14(1): 4-20.
- [3] Yang L, Yang G P, Yin Y L, et al. Finger vein recognition with anatomy structure analysis[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2018, 28(8): 1892-1905.
- [4] Mohsin A H, Zaidan A A, Zaidan B B, et al. Based medical systems for patient's authentication: Towards a new verification secure framework using CIA standard [J]. Journal of Medical Systems, 2019, 43(7): 192.
- [5] Lee E C, Jung H, Kim D. New finger biometric method using near infrared imaging[J]. Sensors, 2011, 11(3): 2319-2333.
- [6] Lee H C, Kang B J, Lee E C, et al. Finger vein recognition using weighted local binary pattern code based on a support vector machine [J]. Journal of Zhejiang University: Science C, 2010, 11(7): 514-524.
- [7] Song W, Kim T, Kim H C, et al. A finger-vein verification system using mean curvature[J]. Pattern Recognition Letters, 2011, 32(11): 1541-1547.
- [8] Peng J L, Wang N, El-Hatf A A, et al. Finger-vein verification using Gabor filter and SIFT feature matching [C]//2012 Eighth International Conference on Intelligent Information Hiding and Multimedia Signal Processing(IIH-MSP). Piraeus: IEEE, 2012: 45-48.
- [9] 杨文文,毛建旭.基于分块 LBP 和分块 PCA 的指静脉识别方法[J].电子测量与仪器学报, 2016, 30(7): 1000-1007.
- [10] 何鑫,陈讯.基于改进卷积神经网络的指静脉识别[J].计算机工程与设计, 2019, 40(2): 562-566.
- [11] 戴庆华,陈光化,唐逍,等.基于 Siamese 卷积神经网络的指静脉识别[J].电子测量技术, 2018, 41(24): 51-55.
- [12] Deng J K, Guo J, Xue N N, et al. Arcface: Additive angular margin loss for deep face recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 4690-4699.
- [13] Shen F M, Shen C H, Liu W, et al. Supervised discrete hashing [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015: 37-45.
- [14] Wang K, Kumar A. Cross-spectral iris recognition using CNN and supervised discrete hashing[J]. Pattern Recognition, 2019, 86: 85-98.
- [15] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.
- [16] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [17] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [EB/OL]. (2015-03-02)[2020-01-30]. <https://arxiv.org/abs/1502.03167>.
- [18] He K M, Zhang X Y, Ren S Q, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification[C]//Proceedings of the IEEE International Conference on Computer Vision. Santiago: IEEE, 2015: 1026-1034.
- [19] He K M, Zhang X, Ren S, et al. Identity mappings in deep residual networks[C]//European Conference on Computer Vision. Amsterdam: Springer, Cham, 2016: 630-645.
- [20] Wang H, Wang Y, Zhou Z, et al. Cosface: Large margin cosine loss for deep face recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 5265-5274.
- [21] Ranjan R, Castillo C D, Chellappa R. L2-constrained softmax loss for discriminative face verification[EB/OL]. (2017-06-07)[2020-01-30]. <https://arxiv.org/abs/1703.09507>.
- [22] Lu Y, Xie S, Yoon S, et al. Robust finger vein ROI localization based on flexible segmentation [J]. Sensors, 2013, 13(11): 14339-14366.
- [23] 张严严,沈雷,李小刚,等.基于指静脉方向场图的快速识别算法研究[J].杭州电子科技大学学报, 2017, 37(5): 21-25.
- [24] 刘广东,邱晓晖.基于多模式 LBP 与深度森林的指静脉识别[J].计算机技术与发展, 2018, 28(7): 83-87.

(责任编辑:康 锋)