

结合深度神经网络和随机森林的手掌静脉分类

袁丽莎, 娄梦莹, 刘娅琴**, 杨丰, 黄靖*

南方医科大学生物医学工程学院, 广东 广州 510515

摘要 提出了一种结合深度神经网络和随机森林的手掌静脉分类新方法。利用预训练深度神经网络模型 AlexNet 提取掌脉特征, 采用主成分分析法对提取的高维掌静脉特征进行降维处理, 以减少存储空间、降低分类误差, 结合对噪声具有很好容忍能力的随机森林进行分类。基于香港理工(PolyU)数据库、中国科学院(CASIA)数据库和自建库的测试精度分别为 100%、97.00% 和 99.50%。相较传统方法, 所提方法避免了人工选择特征提取算法的局限性, 有效降低了手掌静脉的分类误差, 具有更好的稳健性。

关键词 图像处理; 掌脉分类; 迁移学习; 深度神经网络; 主成分分析; 随机森林

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP56.101010

Palm Vein Classification Based on Deep Neural Network and Random Forest

Yuan Lisha, Lou Mengying, Liu Yaqin**, Yang Feng, Huang Jing*

School of Biomedical Engineering, Southern Medical University, Guangzhou, Guangdong 510515, China

Abstract A new palm vein classification method that combines a deep neural network and a random forest is proposed. First, the proposed method extracts the palm vein features using AlexNet, a pre-trained deep neural network model. Then, the principal component analysis is used to reduce the dimensionality of the extracted high-dimensional palm vein features in order to conserve storage space and reduce classification errors. Finally, the random forest is used for classification owing to its high tolerance to noise. Based on the PolyU, CASIA, and self-built databases, the test accuracies obtained are 100%, 97.00%, and 99.50%, respectively. Compared with the traditional methods, the proposed method overcomes the limitations of the manual feature extraction algorithms, effectively reduces the palm vein classification errors, and demonstrates better robustness.

Key words image processing; palm vein classification; transfer learning; deep neural network; principal component analysis; random forest

OCIS codes 100.4996; 100.5010; 110.3080

1 引言

电子商务尤其是在线支付的迅猛发展对身份认证提出了更高的要求。以密码、U 盾、IC 卡为主要的传统身份认证方式难以满足高安全性、高可靠性, 以及便利性的要求, 这极大地推动了生物特征识别的研究和发展。在掌纹识别^[1]、指纹识别^[2]、静脉识别^[3]、虹膜识别^[4]、人脸识别^[5]等生物特征识别领域, 静脉(本文以手掌静脉为研究对象)以其独有的

活体性、唯一性、根植皮内、无法伪造等特点, 逐渐成为生物特征识别领域的研究焦点^[6]。其基本原理为: 手掌在波长为 720~1100 nm 的近红外光照射下, 皮下静脉中的血红蛋白对近红外光吸收性强, 其反射光在传感器上形成较暗的纹路, 而周围组织吸光性弱, 近红外光反射回传感器上形成较亮的区域, 从而形成亮度不同的灰度图像, 即为手掌静脉(以下简称“掌脉”)图像^[7], 在掌脉图像达到一定分辨率后即可用于身份认证。

收稿日期: 2018-10-30; 修回日期: 2018-12-06; 录用日期: 2018-12-12

基金项目: 国家自然科学基金(61771233)、广东省重点科技项目(2013A022100009)

* E-mail: jhuangyg@smu.edu.cn; ** E-mail: liuyq@smu.edu.cn

掌脉识别方法的研究,大多借鉴掌纹识别、人脸识别等方法,且在静脉识别时也参考了掌纹信息。传统掌脉识别主要分为基于单一特征的掌脉识别和基于多特征融合的掌脉识别。基于单一特征的掌脉识别又可归纳为以下3种:1) 基于结构特征的方法,包括局部 Radon 变换与 Hessian-Phase^[8]、方向梯度直方图(HOG)^[9]等,这类方法通过提取掌脉的线特征或点特征来表示掌脉;2) 基于子空间的方法,如双方向的二维线性判别分析 $[(2D)^2LDA]$ ^[10]、主成分分析(PCA)法^[6]等,这类方法将掌静脉图像看作是高维向量或矩阵,通过投影或变换将其转化为低维向量或矩阵,并在此空间下对掌脉进行表示和匹配;3) 基于纹理的方法,如 Gaussian-Randon^[11]、Gabor 滤波器^[12]、局部二值模式(LBP)^[13]等,其原理是先提取掌脉纹理图像局部特征的方向、频率、相位等信息作为掌脉特征,再编码特征并进行匹配识别。基于多特征融合的掌脉识别方法主要是融合掌纹和掌脉特征,如文献[14-15]中,先获取掌纹和掌脉结构特征,再分别采用基于决策层的加权融合识别和基于特征层的典型相关分析法进行融合识别。

以上传统掌脉识别方法虽然可以获得一个相对较好的结果,但存在以下局限性:1) 图像质量要求高,特征提取前需进行增强或去噪等不同程度的复杂预处理。如文献[6,8-15]所述,提取前需使用去背景、插值、直方图均衡化、灰度映射、中值滤波、限制对比度自适应直方图均衡、引导滤波、反锐化掩模增强、增强局部方向模式等预处理方法去除图像噪声,以增强图像对比度和分辨率。2) 需要根据图像本身特点和研究人员的经验人工设计算法提取特征。如文献[8]中,是根据掌脉图像的血管结构特征提取类似指纹的线结构特征;文献[9]中先分块提取了9个梯度方向的特征,最后合并为 HOG 特征向量;文献[10]根据掌脉图像的行列方向分别进行降维得到一个特征矩阵;文献[11]根据掌脉图像纹理特定的方向性采用 Gaussian-Randon 变换提取6个方向特征,但这些特征通常只是掌脉图像的浅层特征,特征单一,其中还掺杂有许多噪声,表达能力不足,且当手掌位置发生变化时,会导致提取的掌脉特征不稳定,使算法的精度受到影响。

目前,掌脉识别已逐渐应用于安防、门禁、新零售等领域。在实际应用中,随着使用人群的增多,偶尔会出现误识现象。本文从实用场景中搜集了14类容易误识的掌脉图像(简称“误识图像”),观察发

现,这些静脉图像质量不高,静脉信息少,掌纹等噪声信息多,且几幅图像误判度高,静脉大致方向走势相同,用传统掌脉分类方法难以准确分类。因此,需要找到能正确区分这14类图像的方法。

近年来,深度学习^[16]方法在计算机视觉领域的图像分类^[17-18]、图像识别^[19]、图像检测^[20]、图像分割^[21]等方面取得了突破性进展,但深度神经网络包含庞大的参数,从零开始训练一个深度神经网络通常需要大量的数据,需以高昂的计算成本以及时间成本为代价,因此,科研工作者们为解决此类问题,引入了迁移学习。所谓迁移学习,就是将来源领域学习到的东西(参数)应用到目标领域。迁移学习^[22-23]主要有两种策略:一种是基于新的数据集在预训练网络中更新权重,微调神经网络,如 Ghazi 等^[24]使用预训练网络模型和迁移学习的思想,将从“源领域(ImageNet)”学习的知识应用到“目标领域(植物图片)”,通过微调神经网络模型参数完成植物的识别任务;另一种是使用预训练网络提取特征,再训练一个分类器进行分类或识别,如 Sargano 等^[25]采用预训练网络模型 AlexNet 进行特征提取,接着使用支持向量机-K 最近邻(SVM-KNN)模型进行人类行为识别任务。

受文献[24-25]启发,本文提出了一种结合深度神经网络和随机森林的手掌静脉分类方法。由于掌脉数据相对 ImageNet 数据少,故采用第二种策略进行掌脉分类,所采用的预训练网络模型为 AlexNet^[17]。实验结果表明,所提方法可以完全准确地对14类误识图像进行分类,而且,在图像质量不均衡的情况下,在香港理工(PolyU)库、中国科学院(CASIA)库、自建库中均可获得非常好的识别结果。

2 方法流程

本文方法流程如图1所示,其主要过程包括:1) 掌脉图像处理,采用关键点定位法^[26]提取掌脉图像感兴趣区域(ROI),然后对训练 ROI 图像进行旋转扩充,增加数据样本量,以解决过拟合问题;2) 掌脉特征提取,首先使用迁移学习的思想,将预训练网络 AlexNet 前11层作为特征提取器,提取掌脉特征,然后采用 PCA 对深度学习提取的高维掌脉特征进行降维,以减少存储空间,降低分类误差;3) 掌脉图像分类,首先利用掌脉训练数据训练出一个随机森林分类模型,然后采用掌脉测试数据评估此模型的泛化能力。




图1 所提方法流程图

Fig. 1 Flow chart of proposed method

2.1 掌脉图像处理

由于神经网络对光照、背景等噪声具有一定的稳健性,因此这里直接采用原始 ROI 图像进行实验。为降低过拟合的风险,提高模型的泛化能力,对掌脉 ROI 图像进行数据扩充。借鉴文献[27]所提的数据扩充方法,分别对训练掌脉 ROI 进行 -10° , -5° , 5° , 10° 旋转扩充,获得 4 倍的训练掌脉 ROI 图像数据。

2.2 掌脉图像特征提取

2.2.1 AlexNet 模型介绍

AlexNet 是由 Alex 提出的网络结构模型,在

2012 年 ImageNet 大规模视觉识别赛上获得了冠军,这使得卷积神经网络成为图像分类上的核心算法模型。本文采用此模型作为掌脉特征提取器,将输入的掌脉 ROI 图像转化为高维特征表示,提取过程示意图如图 2 所示。该模型主要包括 8 个学习层:5 个卷积层(conv)和 3 个全连接层(fc)。训练时采用 dropout 正则化技术降低过拟合,修正线性单元(relu)提高训练速度,利用池化(pool)和归一化(norm)技术提高识别精度。

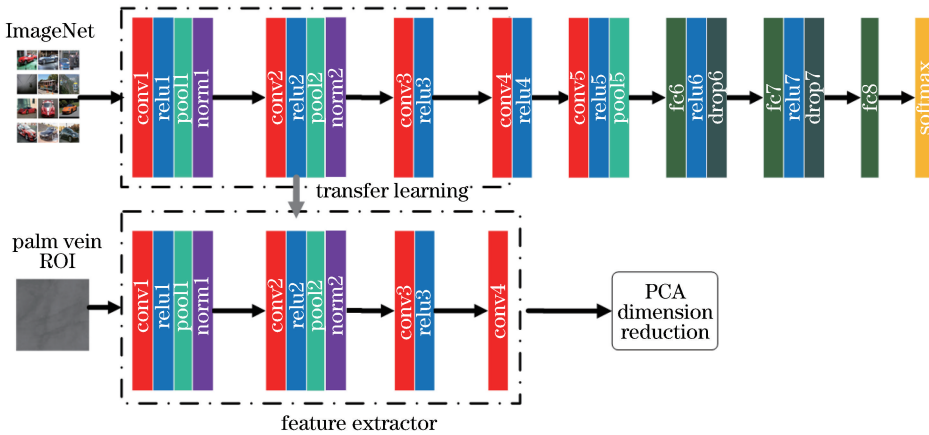


图2 掌脉特征提取示意图

Fig. 2 Schematic of palm vein feature extraction

2.2.2 掌脉特征提取

有相关研究表明,深度卷积神经网络的前面几层提取到的特征较为泛化,而后面层提取的特征与原始数据更相关^[28]。结合实验发现,在掌脉分类中,将预训练 AlexNet 网络的前 11 层作为特征提取器,从大量训练样本中自动学习复杂、高维的深层特征,用于后续掌脉分类可以得到最好的效果,相较使用特征提取器提取单一的掌脉特征的传统掌脉识别方法具有更强的表达能力。

将掌脉 ROI 图像输入到 AlexNet 网络中,经过一系列的卷积、激活、池化、归一化等操作后,从第 4 层卷积层输出的特征图 F_{conv4} 为

$$F_{conv4} = \sum \omega * I + b, \quad (1)$$

式中: ω 为卷积核; I 为前一层输出的掌脉特征图; b 为偏置; $*$ 为卷积操作符。

经过第 4 个卷积后输出特征图的特征维数为 64896。一般情况下,特征越丰富,分类精度越高,但数据维数过多又需要更多的内存空间和计算成本;因此,采用 PCA 对 F_{conv4} 进行降维,选取最具代表性的掌脉特征数据,以减少存储空间,降低分类误差。对每一个 64896 维的掌脉特征数据进行 PCA 降维,得到一个 k ($k \ll 64896$) 维的掌脉特征,即

$$F_{pca} = PCA\{F_{conv4}\}, \quad (2)$$

式中:PCA $\{\cdot\}$ 表示进行 PCA 降维操作。 k 的取值

根据主成分的累计贡献率决定,结合实验和文献[29],这里选取累计贡献率为0.97的前 k 个特征向量组成降维后的掌脉特征图,这样既可以达到降维的目的,又不影响分类精度。

2.3 分类器训练与分类

AlexNet 网络通常使用 softmax 分类器解决图

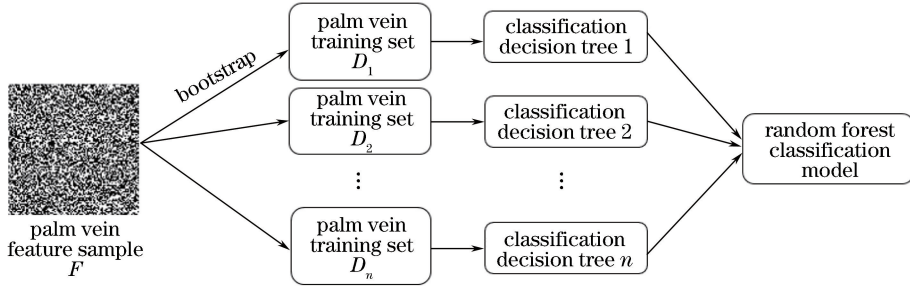


图3 随机森林训练流程

Fig. 3 Flow chart of random forest training

随机森林是以决策树为基分类器的一种集成算法,其主要思想是利用多个弱分类器通过投票表决组合成一个强分类器。决策树通常包括 ID3 (Iterative Dichotomiser 3, 基于信息增益的分类算法)、C4.5 (Classification 4.5, 基于信息增益比的分类算法)、CART (Classification and Regression Tree, 基于基尼指数的分类算法) 3 种学习算法。采用 CART 算法生成决策树。CART 算法假设决策树为二叉树,内部结点特征根据阈值划分为左分支和右分支,则决策树就等价于递归地将每一个特征划分为两部分。结点处最优特征的选择以及该特征的最优二值切分点以基尼指数为指标进行选择^[31]。采用随机森林对掌脉分类的步骤如下:

1) 从总的掌脉特征样本 F 中,采用自助法随机有放回地抽取 N 个样本组成掌脉训练集 D_j (序号 $j=1, 2, \dots, n$), 独立抽取 n 次, 则生成 n 个相互独立的掌脉训练集 D_j 。将 D_j 作为分类决策树的根结点样本, 从根结点开始训练。

2) 在分类决策树的结点处, 从 k 个特征中随机无放回地抽取 m ($m \leq k$) 个特征, 其取值记为 T_i (序号 $i=1, 2, \dots, m$), 然后通过判断 T_i 与预定阈值 T_{thi} 的大小划分数据集 D_j , 若 $T_i \geq T_{thi}$, 则该特征所对应的样本划分到左叶子结点 D_{j_L} , 若 $T_i < T_{thi}$, 则划分到右叶子结点 D_{j_R} 。而结点处最优划分标准为

$$R_{Gini}(D_j, m) = \frac{|D_{j_L}|}{|D_j|} R_{Gini}(D_{j_L}) + \frac{|D_{j_R}|}{|D_j|} R_{Gini}(D_{j_R}), \quad (3)$$

像分类识别问题,但在易混淆的图像中表现不佳,而随机森林(RF)^[30]方法对异常值和噪声图像具有很好的容忍能力,且不易过拟合,识别精度高。因此,采用随机森林分类模型对掌脉图像进行分类。使用2.2节提取的掌脉特征样本 F (F 包含多个 F_{pca}) 训练随机森林分类模型的流程如图3所示。

式中: $R_{Gini}(D_j) = 1 - \sum_{y=1}^Y (p_y)^2$, 表征数据集 D_j 的基尼指数, 其中, Y 为掌脉的类数, p_y 为掌脉训练集 D_j 中属于第 y 类掌脉的概率。在所有可能的特征 m 中以及所有可能的阈值中, 选择基尼指数最小的特征及其对应的阈值作为最优特征和最优切分点, 以此将数据集分配到左分支结点和右分支结点中去。

3) 对左分支结点和右分支结点递归调用步骤2), 直至训练集的基尼指数小于预定阈值, 则分类决策树停止生长, 此时, 掌脉训练集基本被正确分类。

4) 对 n 个相互独立的掌脉训练集 D_j , 重复调用步骤2)、3), 生成 n 个分类决策树, 将这些分类决策树组合就构成了用于掌脉分类的随机森林分类模型 $H(h_1, h_2, \dots, h_n)$ 。

5) 根据生成的掌脉分类模型 $H(h_1, h_2, \dots, h_n)$ 对掌脉测试数据进行分类, 采用简单投票表决机制, 选出得票数最多 ($R_{majorityvote}$) 的分类决策树 h_p 作为最终的分类结果。分类公式为

$$h_p = R_{majorityvote} [H(h_1, h_2, \dots, h_n)], \quad p = 1, 2, \dots, n, \quad (4)$$

式中: p 代表分类决策树的个数。

3 实验结果与分析

3.1 实验数据

为客观全面地评价所提算法的效果, 分别在公开的 PolyU 接触式掌脉数据库、CASIA 非接触式掌脉数据库和自建半接触式掌脉数据库上进行实验。

1) PolyU 接触式掌脉数据库: 使用电荷耦合器

件(CCD)摄像机,以一个简易装置固定采集人员的手和手指,在间隔约为9 d的两个时间段,采集了250个志愿者的500个手掌,每一阶段每只手采集6幅图像,本实验选取第一阶段的6幅图像作为实验数据库,共500类3000幅图像。图4(a)给出了PolyU采集装置和不同人手掌静脉图示例。实验中每一类按训练集与测试集的数量比4:2划分,再对训练集扩充4倍,则训练集共10000幅图像,测试集共1000幅图像。

2) CASIA非接触式掌脉数据库:使用CCD相机拍摄获取,相关研究表明,850 nm近红外光照射下可得到比较清晰的掌脉图像^[26]。因此,选取850 nm波段下的掌脉图像作为实验数据库。该数据库采集了100位志愿者,左右手各6幅图像,共

200类1200幅图像。图4(b)给出了CASIA采集装置和不同人手掌静脉图示例。实验中每一类按训练集与测试集的数量比4:2划分,接着对训练集扩充4倍,则训练集共4000幅图像,测试集共400幅图像。

3) 自建半接触式掌脉数据库:在不同时间段(早、中、晚)的不同地点环境下,使用CMOS采集装置^[32],在本校学生中采集了100人在手掌自然张开状态下的掌脉图像,左右手各采集6幅图像,共200类1200幅图像。图4(c)给出了自建库采集装置和不同人手掌静脉图示例。实验中每一类按训练集与测试集的数量比4:2划分,再对训练集扩充4倍,则训练集共4000幅图像,测试集共400幅图像。




图4 采集装置及该装置下采集的5幅不同人手掌静脉图示例。(a) PolyU库;(b) CASIA库;(c)自建库
Fig. 4 Acquisition device and five examples of different human palm vein images collected using this device.

(a) PolyU database; (b) CASIA database; (c) self-built database

3.2 实验环境

实验环境为MATLAB R2018a,硬件平台为Windows 10系统,CPU为Intel(R) Core(TM) i5-4590,主频为3.30 GHz,内存为16 GB,NVIDIA GeForce GTX 1050Ti,显存为4 GB。

3.3 评价指标

采用袋外(oob)误差^[30]和测试集分类误差评估随机森林模型的泛化能力。采用自助法每次从总的掌脉训练特征样本中抽取一定数量的样本作为掌脉训练集,则剩余样本称为袋外样本,用这一部分数据预测这棵分类决策树的分类误差,总的袋外误差为所有分类决策树的袋外误差的平均值。袋外误差与测试集分类误差越小,模型的泛化能力越好。

3.4 实验结果与分析

3.4.1 AlexNet网络不同层输出特征的表达能力

表1为不同数据库上AlexNet网络不同层提取的掌脉特征的分类误差,分别比较了PolyU库、

CASIA库、自建库在决策树 $n=600$ 时,使用AlexNet网络不同层提取掌脉特征的分类效果。从表中可以看出,3个数据库均是采用第4层卷积层输出的特征分类效果最好,其中PolyU库袋外误差和测试误差均为0(识别精度为100%),CASIA库的袋外误差为0.025%,测试误差为3.00%(识别精度为97%),自建库的袋外误差为0,测试分类误差为0.50%(识别精度为99.50%)。因此,以下实验均基于第4层卷积层提取特征。全连接层提取的掌脉特征效果逊于深层卷积层提取的特征,说明在迁移学习中,深度卷积神经网络的卷积层提取到的特征更泛化,全连接层提取的特征与原始数据更相关。

3.4.2 PCA对分类误差的影响

表2为PCA对各数据库分类误差的影响,分别比较了决策树为600时,PolyU库500类、CASIA库200类、自建库200类在AlexNet+RF、

表 1 不同数据库上 AlexNet 网络不同层提取的掌脉特征的分类误差

Database	Error	Conv1	Conv2	Conv3	Conv4	Conv5	Fc6	Fc7	Fc8
PolyU	Oob error	0	0	0.01	0	0.02	0.69	5.53	31.44
	Test error	1.10	0.10	0	0	0	1.90	5.50	33.40
CASIA	Oob error	2.78	0	0.025	0.025	0.05	3.85	17.28	63.33
	Test error	27.00	7.75	4.50	3.00	5.25	15.25	32.50	78.50
Self-built	Oob error	7.55	0.38	0	0	0	0.075	0.38	5.65
	Test error	9.25	4.75	1.25	0.50	0.75	1.50	4.25	16.50

AlexNet+PCA+RF 两种方法下的分类误差。从表中可以看出,PCA 可以在一定程度上有效降低分类误差,通过使用 PCA 降维,PolyU 库测试误差下降了 0.30%,CASIA 库测试误差下降了 3.75%,自建库测试误差下降了 1%。由此说明,由 AlexNet 网络提取的高维特征中包含较多的冗余信息,可通过 PCA 降维去噪,从而提取出最具代表性的掌脉特征,降低掌脉分类误差。

3.4.3 14 类误识数据比较

将所提方法和文献[11]方法的 14 类误识数据进行比较。搜集的误识图像 14 类及伪彩色图如图 5 所示。图 5(o)~(r)分别为误识图像图 5(a)、

表 2 PCA 对各数据库分类误差的影响

Table 2 Effect of PCA on classification error of each database %

Method	PolyU	CASIA	Self-built
AlexNet+RF	0.30	6.75	1.50
AlexNet+PCA+RF	0	3.00	0.50

(e)、(b)与(c)对应的特征图的伪彩色图,特征图采用文献[11]所述方法提取得到。由图可见,误识图像质量差,有不同程度的模糊,辨识度低,伪彩色图相似度高。观察图 5(a)、(e)、(b)与(c),肉眼认为是不同人的掌脉图像,但实际应用中,采用文献[11]中的方法计算匹配分时发现,当阈值^[6]为0.32(将错




图 5 误识图像及伪彩色图。(a)误识图像第 1 类示例;(b)误识图像第 2 类示例;(c)误识图像第 3 类示例;(d)误识图像第 4 类示例;(e)误识图像第 5 类示例;(f)误识图像第 6 类示例;(g)误识图像第 7 类示例;(h)误识图像第 8 类示例;(i)误识图像第 9 类示例;(j)误识图像第 10 类示例;(k)误识图像第 11 类示例;(l)误识图像第 12 类示例;(m)误识图像第 13 类示例;(n)误识图像第 14 类示例;(o)误识图(a)的伪彩色图;(p)误识图(e)的伪彩色图;(q)误识图(b)的伪彩色图;(r)误识图(c)的伪彩色图

Fig. 5 Misclassified images and pseudo color images. (a) Class-1 example of misclassified image; (b) class-2 example of misclassified image; (c) class-3 example of misclassified images; (d) class-4 example of misclassified images; (e) class-5 example of misclassified images; (f) class-6 example of misclassified images; (g) class-7 example of misclassified images; (h) class-8 example of misclassified images; (i) class-9 example of misclassified images; (j) class-10 example of misclassified images; (k) class-11 example of misclassified images; (l) class-12 example of misclassified images; (m) class-13 example of misclassified images; (n) class-14 example of misclassified images; (o) pseudo color image of misclassified Fig. (a); (p) pseudo color image of misclassified Fig. (e); (q) pseudo color image of misclassified Fig. (b); (r) pseudo color image of misclassified Fig. (c)

误拒绝率与错误接受率相等时的值作为阈值)时,图 5(a)与(e)之间的匹配分为 0.3359,图 5(b)与(c)之间的匹配分为 0.3786,不同类之间的匹配分均大于阈值,表明肉眼观看不同的两类被误判为同一类,这增加了掌脉分类的难度。

使用图 5 所示的误识图像 14 类(每类 10 幅)比较分析所提方法与传统纹理方法^[11]提取的特征。图 6 为掌脉 ROI 图、特征图及伪彩色图,分别给出了原始 ROI 图像、文献[11]中方法提取的掌脉特征

图和所提方法中 AlexNet 网络第 4 层卷积层提取的掌脉特征图及其对应的伪彩色图。从图中可看出,传统方法提取的特征虽提取了一定的方向纹理信息,但噪声信息太多,主要特征不明显,表达能力不足;第 4 层卷积层提取的掌脉特征图,虽分辨率低,难以看出掌脉的特征,但是从伪彩色图像可以发现,有些特征图边缘区域激活显著,有些特征图的静脉纹理区域激活显著,从而可猜测这些激活区域即为判断掌脉类别的显著特征。




图 6 掌脉 ROI 图、特征图及伪彩色图。(a) ROI 图;(b)图(a)的伪彩色图;(c)文献[11]所提方法提取的特征图;(d)图(c)的伪彩色图;(e)第 4 层卷积层提取的特征图;(f)图(e)的伪彩色图

Fig. 6 Palm vein ROI map, feature map and pseudo color image. (a) ROI map; (b) pseudo color image of Fig. (a); (c) feature map extracted by method in Ref. [11]; (d) pseudo color image of Fig. (c); (e) feature map extracted from 4th convolutional layer; (f) pseudo color image of Fig. (e)

表 3 为误识数据在不同方法上的分类误差,给出了文献[11]中方法与所提方法对 14 类误识数据和自建库 200 类的实验结果。从表中可以看出,单独以 14 类误识数据作为实验样本,所提方法误差为 0,明显优于文献[11]中方法;以 14 类误识数据和自建库 200 类混合作为实验样本,所提方法的分类误差为 0.23%(识别精度为 99.77%),且可完全正确地分类 14 类误识数据,文献[11]方法的分类误差为 17.15%,且不能正确地区分 14 类。这是由于传统特征提取算法属于无监督的方式,直接从原始掌脉图像像素中提取更高层次的特征,并没有用到图像的标签信息,提取的特征缺乏代表性,特征提取之后再结合相应的类标签训练分类模型;而神经网络提取特征属于有监督的方式,特征提取可通过特征与标签进行调整,提取具有高区分度的掌脉特征,因此所提方法具有更好的泛化能力。

自建库 200 类来评估所提算法。图 7 为不同分类决策树下各数据库的分类误差,比较了 PolyU 库、CASIA 库、自建库在分类决策树数量从 0~600 下的分类误差,其中插图为 3 个数据库分类误差的局部放大图。

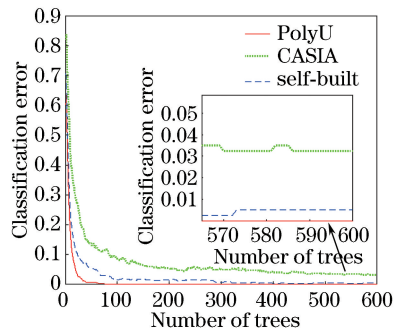


图 7 不同分类决策树下各数据库的分类误差
Fig. 7 Classification error of each database versus number of classification decision trees

由图 7 可见,在分类树的数量为 600 时,PolyU 库 500 类的分类误差为 0(识别精度为 100%),CASIA 库的分类误差为 3.00%(识别精度为 97.00%),自建库 200 类的分类误差为 0.50%(识别精度为 99.50%)。一定范围内,随分类决策树的增加,3 个数据库的分类误差均逐渐减小,说明分类决策树越多,模型训练得越好,泛化能力越强。CASIA 库的分类误差大于 PolyU 库和自建库,是由于 CASIA 库采用非接触式采集,图像质量相对

表 3 误识数据在不同方法上的分类误差

Table 3 Misclassification data classification errors from different methods

Class	Method	Classification error / %
14 classes	Method in Ref. [11]	3.10
	Proposed method	0
214 classes	Method in Ref. [11]	17.15
	Proposed method	0.23

3.4.4 分类决策树数量对分类误差的影响

分别使用 PolyU 库 500 类、CASIA 库 200 类、

较差;当决策树的数量在 500~600 之间时,3 个数据库的分类误差下降的趋势逐渐趋于平稳,考虑到时间和内存消耗成本,以 600 作为 3 个数据库的最优分类决策树的数量。

3.4.5 不同方法在各个数据库上的比较

表 4 为不同方法的识别精度,比较了所提方法与其他方法在 PolyU 库、CASIA 库以及自建库上的识别精度。其中文献[9-10]均采用传统人工特征提取算法提取掌脉特征,再分别使用支持向量机和最小距离分类器进行分类识别;AlexNet 是利用 AlexNet 网络自动学习掌脉特征,并使用 softmax 分类器分类识别,该方法需要足够的掌脉样本来训练分类器,但这里数据不充足,因而分类精度较低。AlexNet+PCA+SVM 方法和 VGG16+PCA+RF 方法比较了采用不同分类方法、不同网络提取特征的分类识别精度。从实验结果可见,特征提取较分类器设计更为重要,会在很大程度上影响掌脉分类精度。文献[9]采用 HOG 提取掌脉特征,过程中对图像分块,可能会造成同一梯度方向上的特征被划分为两块,从而影响分类精度。文献[10]采用最小距离分类器计算分类识别精度时,只考虑样本的均值,而没有考虑整体类别方差或样本分布,容易影响分类精度。从表 4 可看出,神经网络自动学习的特征表达能力优于人工特征的表达;在噪声、异常值的容忍度方面,随机森林使用的是无偏估计,模型泛化能力更强,尤其是在 CASIA 非接触式数据库和自建库上,在图像质量参差不齐的情况下也获得了一个好的结果,说明所提方法可以很好地平衡较差掌脉图像之间的误差。在时间性能方面,所提方法对 PolyU 库、CASIA 库、自建库的识别时间分别为 0.107,0.087,0.102 s,可以满足实时性要求。综合可得,所提方法具有较好的稳健性和实用性。

表 4 不同方法的识别精度

Method	PolyU	CASIA	Self-built
Method in Ref. [10]	92.90	79.00	87.25
Method in Ref. [9]	99.50	91.50	97.75
AlexNet	99.30	87.75	98.00
AlexNet+PCA+SVM	99.90	91.00	99.50
VGG16+PCA+RF	99.80	90.50	98.50
Proposed method	100	97.00	99.50

4 结 论

为有效提取更具表达能力的掌脉特征,提出了一种结合深度神经网络和随机森林的掌脉分类方

法,该方法以预训练网络 AlexNet 作为特征提取器,提取掌脉特征,并使用 PCA 进行降维处理,以减少存储空间,降低分类误差,最后使用随机森林分类模型对掌脉进行分类。实验结果表明,在特征提取、降维、分类器训练与分类几个阶段中,特征提取尤为重要,在很大程度上决定了后续分类器的分类精度。实验结果验证了所提算法的稳健性和实时性,正确区分了 14 类误识数据,且在 PolyU 库、CASIA 库、自建库中的识别精度分别为 100%,97.00%,99.50%,识别时间分别为 0.107,0.087,0.102 s,具有较好的应用前景。

参 考 文 献

- [1] Jia W, Zhang B, Lu J T, *et al.* Palmprint recognition based on complete direction representation [J]. *IEEE Transactions on Image Processing*, 2017, 26(9): 4483-4498.
- [2] Hrechak A K, McHugh J A. Automated fingerprint recognition using structural matching [J]. *Pattern Recognition*, 1990, 23(8): 893-904.
- [3] Lee J C. A novel biometric system based on palm vein image [J]. *Pattern Recognition Letters*, 2012, 33(12): 1520-1528.
- [4] Wei Z S, Qiu X C, Sun Z N, *et al.* Counterfeit iris detection based on texture analysis [C] // 2008 19th International Conference on Pattern Recognition, December 8-11, 2008, Tampa, FL, USA. New York: IEEE, 2008: 1-4.
- [5] Zhou B, He Y Q, Wang J. Face recognition based on adaptive neighborhood locality preserving projection algorithm [J]. *Laser & Optoelectronics Progress*, 2018, 55(3): 031010.
周博,何宇清,王建.基于自适应近邻局部保持投影算法的人脸识别[J].*激光与光电子学进展*, 2018, 55(3): 031010.
- [6] Li Q. The theoretical and experimental study on palm vein recognition technology [D]. Wuhan: Huazhong University of Science and Technology, 2010.
李强.掌静脉身份识别技术的理论与实验研究[D].武汉:华中科技大学,2010.
- [7] Watanabe M. Palm vein authentication[M]. London: Springer, 2008: 75-88.
- [8] Zhou Y B, Kumar A. Human identification using palm-vein images [J]. *IEEE Transactions on Information Forensics and Security*, 2011, 6(4): 1259-1274.
- [9] Xu X Y, Yao P. Palm vein recognition algorithm

- based on HOG and improved SVM[J]. Computer Engineering and Applications, 2016, 52(11): 175-180, 214.
- 徐笑宇, 姚鹏. 基于 HOG 与改进的 SVM 的手掌静脉识别算法[J]. 计算机工程与应用, 2016, 52(11): 175-180, 214.
- [10] Lee Y P. Palm vein recognition based on a modified (2D)²LDA[J]. Signal, Image and Video Processing, 2015, 9(1): 229-242.
- [11] Zhou Y J, Liu Y Q, Yang F, *et al.* Palm-vein recognition based on oriented features[J]. Journal of Image and Graphics, 2014, 19(2): 243-252.
- 周宇佳, 刘娅琴, 杨丰, 等. 基于方向特征的手掌静脉识别[J]. 中国图象图形学报, 2014, 19(2): 243-252.
- [12] Wang R, Wang G Y, Chen Z, *et al.* A palm vein identification system based on Gabor wavelet features[J]. Neural Computing and Applications, 2014, 24(1): 161-168.
- [13] Mirmohamadsadeghi L, Drygajlo A. Palm vein recognition with local texture patterns [J]. IET Biometrics, 2014, 3(4): 198-206.
- [14] Li J L, Wang H B, Tao L. Palm vein and palmprint fusion recognition with those two features existing in same near-infrared palm image [J]. Computer Engineering and Applications, 2018, 54(9): 156-164, 236.
- 李俊林, 王华彬, 陶亮. 单幅近红外手掌图像掌静脉和掌纹多特征识别[J]. 计算机工程与应用, 2018, 54(9): 156-164, 236.
- [15] Li X C, Zhang C H, Lin S. Palmprint and palm vein feature fusion recognition based on BSLDP and canonical correlation analysis [J]. Laser & Optoelectronics Progress, 2018, 55(5): 051012.
- 李新春, 张春华, 林森. 基于 BSLDP 和典型相关分析的掌纹掌脉融合识别[J]. 激光与光电子学进展, 2018, 55(5): 051012.
- [16] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [17] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [18] He K M, Zhang X Y, Ren S Q, *et al.* Delving deep into rectifiers: surpassing human-level performance on ImageNet classification [C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 1026-1034.
- [19] Li J N, Zhang B H. Face recognition by feature matching fusion combined with improved convolutional neural network [J]. Laser & Optoelectronics Progress, 2018, 55(10): 101504.
- 李佳妮, 张宝华. 特征匹配融合结合改进卷积神经网络的人脸识别[J]. 激光与光电子学进展, 2018, 55(10): 101504.
- [20] Ren S Q, He K M, Girshick R, *et al.* Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [21] Noh H, Hong S, Han B. Learning deconvolution network for semantic segmentation[C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 1520-1528.
- [22] Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [23] Shao L, Zhu F, Li X L. Transfer learning for visual categorization: a survey [J]. IEEE Transactions on Neural Networks and Learning Systems, 2015, 26(5): 1019-1034.
- [24] Ghazi M M, Yanikoglu B, Aptoula E. Plant identification using deep neural networks via optimization of transfer learning parameters [J]. Neurocomputing, 2017, 235: 228-235.
- [25] Sargano A B, Wang X F, Angelov P, *et al.* Human action recognition using transfer learning with deep representations [C] // 2017 International Joint Conference on Neural Networks (IJCNN), May 14-19, 2017, Anchorage, AK, USA. New York: IEEE, 2017: 463-469.
- [26] Wu W, Yuan W Q. A survey of palm-vein image recognition[J]. Journal of Image and Graphics, 2013, 18(10): 1215-1224.
- 吴微, 苑玮琦. 手掌静脉图像识别技术综述[J]. 中国图象图形学报, 2013, 18(10): 1215-1224.
- [27] Kumar A, Wang K. Identifying humans by matching their left palmprint with right palmprint images using convolutional neural network [C] // The First International Workshop on Deep Learning and Pattern Recognition (DLPR 2016), December 4-8, 2016, Cancun, Mexico. [S.l.:s.n.]. 2016: 1-6.
- [28] Yosinski J, Clune J, Bengio Y, *et al.* How transferable are features in deep neural

- networks?[C]// Advances in Neural Information Processing Systems 27 (NIPS 2014), December 8-13, 2014, Palais des Congrès de Montréal, Montréal, Canada. [S.l.:s.n.]. 2014: 3320-3328.
- [29] Chen P. Principal component analysis and its application in feature extraction[D]. Xi'an: Shaanxi Normal University, 2014.
陈佩. 主成分分析法研究及其在特征提取中的应用[D]. 西安: 陕西师范大学, 2014.
- [30] Breiman L. Radom forests [J]. Machine Learning, 2001, 45(1): 5-32.
- [31] Li H. Statistical learning method [M]. Beijing: Tsinghua University Press, 2012.
李航. 统计学习方法[M]. 北京: 清华大学出版社, 2012.
- [32] Liu Y Q, Zhou Y J, Qiu S R, *et al.* Real-time locating method for palmvein image acquisition[M]. Lecture Notes in Computer Science. Cham: Springer International Publishing, 2015: 94-110.