基于深度学习的亚表面指纹重构

刘 凤 张文天 刘浩哲 刘国杰 沈琳琳

(深圳大学计算机与软件学院 深圳 518060)(深圳市人工智能与机器人研究院深圳大学分院 深圳 518060)(广东省智能信息处理重点实验室深圳大学学部 深圳 518060)

摘 要 光学相干层析成像(optical coherence tomography, OCT)是一种高分辨率成像技术,可以采集到手指表面 皮肤下的多层深度信息,即指纹层析结构.将指纹层析结构高质量地重构为亚表面指纹图像,不仅可以解决因表面 成像导致的低质量指纹图像问题,而且可以实现与现有传统指纹识别技术的无缝连接.本文首次提出一种基于深度 学习的亚表面指纹重构方法.首先以HDCRes-34为基础网络,根据皮肤结构的不同,将每个OCT 横截面图像分割 成三层.然后,利用滑动窗口函数根据一个手指所有横截面图像的分割结果,纠正模型可能存在的分割失效情况.同 时比较三个层次亚表面指纹信息,针对不同指纹特征,使用不同权重进行融合,得到高质量的亚表面指纹图像.实验 结果表明,我们提出的分割模型达到平均像素准确率(meanPA)为0.956,以及平均交并比(mIoU)为0.873,从而显 示我们的分割方法能很好地分割与皮肤结构相对应的三个层次的信息.同时,我们也比较了本文提出的重构方法与 目前得到最好重构结果的方法,结果表明,我们的方法在单位像素指纹特征数量、脊线密度和等错误率(EER)方面 均表现最佳.

关键词 光学相干层析成像;亚表面指纹;内指纹;深度学习;指纹重构 中图法分类号 TP18 **DOI**号 10.11897/SP.J.1016.2021.02033

Deep Learning Based Fingerprint Subsurface Reconstruction

LIU Feng ZHANG Wen-Tian LIU Hao-Zhe LIU Guo-Jie SHEN Lin-Lin (College of Computer Science and Software Engineering, Shenzhen University, Shenzhen 518060) (SZU Branch, Shenzhen Institute of Artificial Intelligence and Robotics for Society, Shenzhen 518060) (the Guangdong Key Laboratory of Intelligent Information Processing, Shenzhen University, Shenzhen 518060)

Abstract Optical Coherence Tomography (OCT) is a high resolution imaging technology, which provides depth information of multilayer tissues of finger skin. An OCT-based fingerprint image is presented in the form of multiple cross sectional images (i. e. B-scan), which is quite different from the surface image of fingerprint. Reconstructing subsurface fingerprint image from multiple B-scans with high quality will not only solve the image degradation problem caused by surface imaging (e. g., altered or worn-out fingerprints, wet/dry fingers), but also provide compatible image data for minutiae based fingerprint recognition techniques. However, existing reconstruction methods are designed only for internal fingerprint (i. e. some layers of skin tissues) and simple edge detection approaches are used. Other features such as sweat gland, which exists in epidermal layers of skin tissues, cannot be extracted effectively. Meanwhile, those traditional

收稿日期;2020-03-27;在线发布日期;2021-01-18.本课题得到国家自然科学基金项目(62076163,91959108),深圳市基础研究项目基金(No. JCYJ20190808163401646, JCYJ20180305125822769)和腾讯"犀牛鸟"深圳大学青年教师科研基金会资助.刘凤,博士,副教授,主要研究领域为生物特征识别、图像处理和模式识别. E-mail; feng.liu@szu.edu.cn. 张文天,硕士研究生,主要研究领域为图像处理,模式识别和生物特征识别.刘浩哲,硕士研究生,主要研究领域为人工智能、计算机视觉和生物特征识别.刘国杰,硕士研究生,主要研究领域为人工智能、计算机视觉和生物特征识别.刘国杰,硕士研究生,主要研究领域为模式识别、生物特征识别和图像处理. 沈琳琳(通信作者),博士,教授,中国计算机学会(CCF)会员,主要研究领域为深度学习、人脸识别分析和医疗图像处理. E-mail; llshen@szu.edu.cn.

hand-crafted feature based methods usually involve lots of parameters, which are sensitive to noises and are thus not robust. To solve those problem, this paper, for the first time, proposes to reconstruct subsurface fingerprint image using deep learning. The proposed method firstly uses HDCRes-34 as the backbone network to robustly segment each OCT-based B-scan into stratum corneum layer, ridge part and valley part, which correspond to stratum corneum layer, viable epidermis layer and papillary dermis layer. In HDCRes-34, an Atrous Spatial Pyramid Pooling (ASPP) structure is applied to increase the receptive fields of the network, so as to acquire more accurate feature representation. To further improve the segmentation accuracy, we applied a slide window to the adjacent B-scans to correct the false segmentations caused by the uneven distribution of the subsurface skin structure. The subsurface fingerprint is finally reconstructed by fusing the information of three layers by a weighted combination. In experiments, we randomly selected 4,800 B-scans from 116,000 B-scans collected from 73 volunteers to train the proposed segmentation network. To verify the effectiveness of the network, we compared our model with 21 classical segmentation models. Experimental results show that the proposed model can well segment the B-scans into three layers with different skin structures, with mean pixel accuracy of 0.956 and mean intersection over union of 0.873. To determine the most suitable weights for fusion, we analyzed the reconstruction results based on the number of sweat pores, the restoration potential of worn-out fingerprint surface and the definition of ridges and valleys of reconstructed images. Finally, we evaluated our method with the state-of-the-art internal fingerprint based methods using the number of features (sweat pores and minutiae) per pixel, the ridge-line density and Equal Error Rate (EER) on our own database, which were collected from 100 finger pairs of students (or officers) and 45 finger pairs (worn-out fingerprints) of labor workers. While $5.3 \times$ 10^{-4} ridge-line density is achieved, around 1.9×10^{-5} sweat pores per pixel can be extracted from the image reconstructed using our method. 5.2% EER is achieved for our approach in our dataset. The results show that our method outperforms other reconstruction approaches in terms of the number of features per pixel, ridge-line density and EER. When worn-out fingers are concerned, the accuracy of subsurface fingerprint reconstructed by our proposed method is about 40% higher than that of 2D surface fingerprints collected by two commercial optical sensors.

Keywords optical coherence tomography; subsurface fingerprint; internal fingerprint; deep learning; fingerprint reconstruction

1 引 言

指纹作为手指的主要生物特征,具有普遍性、显 著性、持久性、可采集性、可接受性和抗规避性等理 想特征,在个人识别系统中得到广泛应用^[1-2].常用 的 自 动 指 纹 识 别 系 统 (automatic fingerprint recognition systems, AFRSs)是基于指纹表面成像 进行识别匹配.指尖或指纹表面的油脂和汗液会降 低指纹成像质量,进而降低指纹识别的精度.另一方 面,指纹表面的纹理易被伪造,因此,AFRSs针对欺 骗攻击是缺乏鲁棒性的^[2-5].例如,常见物品(如橡皮 泥、口红等)制造的指纹模具就可以欺骗通用 AFRSs^[6].因此,传统的自动指纹识别系统识别精度和抗欺骗能力有待提高.为解决以上问题,基于光学相干层析成像(optical coherence tomography, OCT)^[7]的指纹成像技术应运而生.

OCT 是一种无创、高分辨率的生物医学成像技术.目前,该技术已广泛应用于医学影像诊断、生物学和工业检测等领域^[3.8-12].在指纹成像领域,OCT 不同于传统的传感器,能捕获指尖皮肤下亚表面信息和表皮生物组织的内部特征.如图1(c)所示,皮肤组织结构与图1(a)的OCT 指纹图像相对应.OCT 指纹以手指横截面图像(B-scan)和皮下深度信息(Aline)的形式成像.每条 Aline 达到的穿透深

度,对应深度方向的像素,反映了传感器对皮肤亚表面特征成像的能力.通过所有沿水平方向扫描的 Aline形成了B-scan,即横截面图像.

2006年OCT成像技术被引入指纹识别领域并 首次实现指纹防伪检测^[2,5]. 基于 OCT 指纹的研究 工作发展至今,主要集中在 OCT 指纹防伪 技术^[3,13-19], OCT 指纹特征研究^[20],内指纹提取 技术^[21-27],以及基于OCT指纹识别技术^[28-36]这几个 方面,具体地,在防伪技术方面,石博雅^[16]等人使用 全光纤OCT技术获取人造指纹数据,利用微结构信 息以及光学特性识别出人造指模.陈朋等人[17]使用 OCT技术利用光学微血管造影对指纹识别进行防 伪工作. Chugh和Jain^[18]基于深度卷积神经网络,从 OCT扫描仪采集的指纹横截面图像中提取真手指 与攻击材料的局部块图像,设计表征攻击检测器实 现指纹防伪, Liu等人^[19]基于自动编码网络设计显 著性检测结构,提出单类别的表征攻击检测器,在仅 输入真指纹的情况下,实现对指纹攻击材料的检测. 在 OCT 指纹特征提取研究中, Liu 等人^[20]使用 ResNet 卷积神经网络提取 OCT 指纹图像中的性别 特征,并实现性别分类.在OCT指纹识别方面, 鲍文^[35]等人使用OCT技术对物体表面存留的潜指 纹进行获取. Raja等人^[36]使用双路卷积神经网络对 全域OCT指纹图像进行识别.

而内指纹(对应图1(a)中的活性表皮层信息) 提取技术的提出,主要因为大部分的OCT指纹采集 设备采集到的图像是一个手指的多幅具有皮肤剖面 图信息的B-scan图像,如图2所示本文实验用OCT 设备(图2(a))采集到的一个手指指纹图像 (图2(b)),要想获取与表面指纹图像相同的纹理呈 现,必须将多幅*X-Z*平面上的B-scan图像还原重 构成图2(c)所示的X-Y平面图像,我们也称之为 亚表面指纹图像.观察图2(c)所示的不同深度的亚 表面指纹图像,我们可以看出,亚表面指纹图像尽管 与表面纹理特征具有一致性,但不同深度的亚表面 指纹的质量存在差异.因此,重构高质量亚表面指纹 对于OCT指纹识别研究与现有指纹识别技术的衔 接具有重要意义.

现有的亚表面指纹重构方法,大多数指的是内 指纹提取方法,由于传统的表面指纹是由活性表皮 层生长得到,从B-scan 中提取活性表皮层线轮廓, 再使用轮廓信息进行亚表面指纹的重构就称之为内 指纹提取,2010年,Bossen等人^[21]发现内部指纹的 OCT 成像可以用于准确可靠的指纹识别.在 2013年,Liu和Chen^[24]使用OCT设备得到亚表面指 纹,证明了亚表面指纹与表面指纹的直接关系,基于 不同的线轮廓提取技术,自动化亚表面重构算法包 含有边缘检测^[22, 23, 25]、峰值检测^[26]和投影方法^[27]. Darlow 等人^[25]利用滤波器降低了 B-scan 中散斑噪 声的影响,使用了Sobel算子提取活性表皮层线轮 廓,利用线轮廓在B-scan中的位置信息完成了亚表 面的提取工作.不同于Darlow等人的工作,在 2017年,Sekulska等人^[26]提出了一种基于峰值检测 法的亚表面提取方法,角质层与活性表皮层在Aline 维度上表现为双峰信号, Sekulska 等人通过提取 Aline 的峰值信号得到活性表皮层的线特征,进而提 取得到亚表面指纹信息.在2020年,Liu等人[27]提出 了一种基于手指皮肤结构的投影方法,对OCT指纹 横截面图像进行同方向投影,对不同深度角质层指 纹、内指纹和乳突指纹进行提取并融合,完成OCT 指纹重构,为目前领域最佳算法.

上述研究表明了高质量亚表面指纹的潜力和科



图1 *X*-*Z*平面指纹图像标注示例.(a). 纵向(*X*-*Z*)指纹图像生物结构示意图,(b). 纵向 指纹组成结构标注示意图,(c). 对应人体皮肤的物理结构^[8]



图 2 OCT 指纹采集设备获取三维(3D)指纹图像:X-Y平面对应传统二维(2D)指纹的观察平面;Z轴方向为3D指纹具备的附加深度方向.(a).实验用接触式OCT 指纹采集设备,(b). 沿Y轴方向获取到一个指尖的400张纵向(X-Z)指纹图像,(c). 沿z轴不同深度的3D指纹在X-Y平面指纹层析结构图

学意义.但是上述方法仍存在关键问题需要解决: (1)以上方法对噪声敏感,算法的表现依赖于横断面 图像的质量.(2)这些方法都是基于活性表皮层线 轮廓进行的亚表面指纹提取,这导致以下两个问题: (i)在基于接触式OCT设备采集的指纹图像中,活 性表皮层上边界和角质层的下边界接触重合 (如图1(a)白色实线),这些方法无法有效分割出活 性表皮层线轮廓,影响指纹重构结果准确性;(ii)Bscan中存在的其他生物信息(如图1(a)所示汗腺)没 有被有效利用,因此基于线轮廓提取的重构图像会 丢失指纹特征.(3)这些方法在提取亚表面指纹结构 时,存在大量超参数,进而降低了系统的鲁棒性.

针对这些问题,本文提出了一种基于层析结构 的深度学习重构方法.根据指尖皮肤的内部生物结构,采用带有空洞卷积金字塔结构(Atrous Spatial Pyramid Pooling, ASPP)的HDCRes-34 深度学习 网络,对每一横截面图像(B-scan)中的亚表面指纹 进行分割,得到如图1(b)所示的角质层、脊部和谷 部.针对可能存在分割模型预测失效的问题,本文利 用滑动窗口函数对网络进行微调,使分割模型具有 更强的鲁棒性和稳定性.最后,本文根据分割结果, 给不同区域的亚表面指纹信息赋予权值,在Aline 维度对B-scan进行加权累和,重构出具有更多特征 (如汗腺)的高质量亚表面指纹.实验结果表明本文 提出的方法在重构图像的特征数量(汗腺和细节特 征)、特征质量(脊线密度)、和等错误率(EER)等方 面超过了现有方法.

论文章节安排如下.第2节简要介绍本文使用的OCT指纹数据.第3节介绍了本文用于对B-scan的角质层、脊部和谷部进行分割的模型.第4节中描述了本文提出的基于层析结构的亚表面指纹重构方法.第5节对实验结果进行展示和分析.第6节为本文结论和未来工作的概述.

2 OCT 指纹简介

如图 2(b)所示,OCT 指纹由多张连续横截面图像(即 B-scan)组成.不同的 OCT 采集设备会产生不同规格的 B-scan 图像,但不改变数据的格式.目前尚无公开的 OCT 指纹数据库,本文实验用的数据采用与公司合作研发的 OCT 设备^[37,38]进行自主采集,采集设备如图 2(a).设备使用 18 khz 光源采集指尖皮肤深度方向(即 Aline)的光谱信息,在皮肤介质中的探测深度为1.8 mm,对应为图 2(b)所示的Z方向上的 500像素,设备沿 X 方向扫描 1500条 Aline 图像得到图 2(b)所示的(X-Z)空间中大小为 500×1500像素的 B-scan 图像.为获得指尖的三维(3D)成像,设备使用慢扫描振镜在 Y 方向进行矢量平移得到了 400 张 B-scan 图像组成,其大小为 15 mm×

15 mm×1.8 mm,对应图像尺寸为500×1500×400 像素,如图2(b)所示.从图2(b)中我们可以看出 OCT指纹图像的呈现与传统的二维(2D)表面指纹 图像完全不同,想要获得传统的指纹纹理图像呈现, 我们必须将图2(b)所示的OCT指纹图进行重构, 得到如图2(c)所示的不同深度的*X*-*Y*平面的亚表 面指纹图像.因此,本文的目标是从OCT指纹(即 400张B-scan图像)重构一个高质量的亚表面指纹 (即*X*-*Y*空间中的指纹纹理(en-face)指纹).

3 指尖皮肤层析结构分割模型

参考传统的亚表面指纹提取方法,准确分割 B-scan图像的活性表皮层是重构亚表面指纹的关 键步骤.观察图1(a)所示的B-scan截面图,指纹的 内脊线特征主要存在于活性表皮层中而内谷线特征 主要存在于乳突层中,因此本文将这两层分别称之 为脊部和谷部,从而与图1(b)所示的划分相对应. 因此本文提出了一种基于生物结构的分割模型,将 B-scan图像划分为角质层、脊部、谷部和背景 (如图1(b))用于后续亚表面指纹重构.从B-scan图 像中提取分割所需区域分为两个步骤:(1)使用基于 深度学习的模型实现层析结构的语义分割; (2)利用B-scan图像结构上的连续性,使用滑动窗 口函数对上一步预测结果进行信息补充,得到更鲁 棒的分割结果.

3.1 基于深度学习的层析分割模型

近年来,深度卷积神经网络在许多复杂视觉任务,如分割任务中,取得了巨大进展.考虑到B-scan的噪音和问题空间复杂度,本文提出了一种基于深度学习的分割模型用于分割指尖的生物结构.在深

度学习中,分割模型具有应用场景的特殊性,不同的 应用场景和数据集对应有不同的网络模型.但这些 模型在整体结构上具有一致性,即模型由两部分组 成,一部分是用于特征提取的基础网络,另一部分是 像素级的分割网络.

在选取基础网络时,考虑到B-scan图像含有的 细粒度噪声会限制卷积层在感受野很小情况下的网 络表现,本文选取了基于混合空洞卷积(Hybrid Dilated Convolution, HDC)的残差网络HDCRes-34^[39]作为基础网络.HDCRes-34网络使用了空洞卷 积操作增加网络的感受野,在保留数据结构的同时, 提取更多信息特征;利用残差块结构解决了深度学 习在深层网络下梯度消失的问题,降低了噪音对模 型的扰动,增加了网络对特征的表征能力.混合空洞 卷积在每一空洞卷积层中使用不同的空洞率,将卷 积核的接收视野全覆盖整个图像区域,可以有效消 除连续使用空洞卷积时出现的像素点丢失情况.

在像素级分割网络中,本文使用Atrous-FCN^[40]作为网络的基本结构(Baseline).考虑到 B-scan的图像分辨率高,图像特征分布不均匀,在 Baseline 基础上增加了基于空洞卷积空间金字塔 (Atrous Spatial Pyramid Pooling, ASPP)^[41]的反卷 积结构,通过使用不同空洞率的空洞卷积对图像特 征进行融合,在增加感受野的同时,进一步提高特征 映射质量.

本文提出的分割模型结构如图 3 所示. 分割模型的输入为单张 B-scan图像,经过基础网络HDCRes-34的提取得到高维特征. 以高维特征作为输入,分割网络中使用ASPP结构进行特征融合,利用反卷积网络,对融合后的特征进行上采样,进而完成像素级别的分类. 基础网络 HDCRes-34 由四个



图3 本文语义分割模型和重构算法结构图:基于HDCRes-34基础网络结构,使用ASPP结构进行特征融合,经过上采样完成分割;分割结果经过滑窗函数和权值函数重构算法,实现指纹重构

网络集成块组成.每个网络集成块由三个空洞卷积 层和一个卷积层构成,如图4所示.其中,三层空洞 卷积的空洞率为1、2、5,用于增强网络的感受野.卷 积层在空洞卷积1-3中的步距为2,用于压缩图像的 特征,减少网络的网格效应,提高网络的运算效率, 减少收敛所需时间.空洞卷积4的卷积层步距为1, 用于减少低尺度下特征图的细节特征损失.



战4 至何卷怀莱瓜沃布物图. 至何卷怀莱瓜沃田四即分至成, 空洞率分别为1、2、5的空洞卷积和一个普通卷积

分割网络由 Atrous-FCN (Baseline)和 ASPP 两部分构成. ASPP结构融合了图像池化,pixel wise 卷积以及空洞率为6、12、18的空洞卷积共五种不同 提取方法的高维特征,得到更加精细化的语义信息. 通过使用级联结构,网络将 ASPP输出的语义信息 和基础网络第一个集成块输出的结构信息进行融 合,提供给反卷积网络.Baseline 网络由四层组成, 前三层为卷积网络,对特征进行进一步的分析运算, 第四层为上采样层,将预测结果变化为与原图大小 一致,实现像素级别的分割,如图5(b)所示.本文将 所提出的分割模型定义为.

 $y_x = f_x(i, j, c), \forall I_x \in D \tag{1}$



图 5 指纹亚表面分割结果及 3D 指纹图像示例. (a). 原始 3D 指尖结构图, (b). 指纹 B-scan 图像以及对应指纹亚表 面不同层结构标签和预测结果图

在公式(1)中, y_x 为B-scan图像 I_x 在位置(i,j)处 的类别c的概率. $x \in [1,400]$ 为B-scan的索引下标, D为一个指尖的完整 3D数据(400张B-scan).在图 5(b)第二行中, $c \in [1,4]$ 对应四个不同的标签类别, 即角质层、脊部、谷部和背景.将图5(b)第一行的示例图像I₄作为输入,模型可以将指尖图像依据不同的生物结构分割,如图5(b)第三行.

3.2 基于滑窗函数优化分割

基于所提出的分割网络模型见公式(1),模型可 以得到 B-scan 图像逐像素的类别概率.由于 OCT 亚表面三部分层析结构随着 Y 轴变化分布不 均且存在噪音干扰情况,在极端情况下可能会导致 分割模型在分割部分非连续的 B-scan 时存在失效 或分割结果与标签差距过大情况.此时,失效的分割 结果无法用于指纹重构.因此,基于该预测结果,本 文提出了一个滑动窗口函数,用以防止分割模型失 效,得到更加稳定和鲁棒的分割结果.

在图 2(b)中,一个亚表面指纹(X-Y)是由 400张分割后的B-scan图像(X-Z)重构得到.本文 将这种 3D指纹数据定义为指纹方体.为在指纹重构 中,消除可能存在部分 B-scan分割失效结果的影 响,模型应沿 Y 轴方向连接 B-scan 图像,并沿 Z 轴 累加像素值.利用指纹方体沿 Y 轴具有的空间连续 性,在分割后的指纹方体上,增加滑动窗口函数.该 滑窗函数以原有 400张 B-scan 图像的分割结果作为 依据,使用每张 B-scan 图像前后两张图像对其进行 空间连续性的信息补充,可以帮助模型解决 B-scan 图像中存在的分割失效问题,并且模型可以获得更 精确的类别 y^{*}_x的概率分布.滑动窗口函数可表示为 公式(2)和公式(3).

$$y_{x_0}^* = \int_{x \in domain(x_0)} H(x) y_x dx$$
(2)

$$H(x) = \begin{cases} \alpha & x = x_0 - 1 \\ 1 - 2\alpha & x = x_0 \\ \alpha & x = x_0 + 1 \\ 0 & others \end{cases}$$
(3)

在公式(2)和公式(3)中, $x_0 \in [2,399]$ 为D中指 纹图像 I_{x_0} 对应的索引下标, $y_{x_0}^*$ 是滑动窗口函数处理 后的预测概率. domain(x_0)表示第 x_0 个B-scan图像 的前一张和后一张B-scan. H(x)为窗口函数,其中, α 为连续三张B-scan图像的权重参数. 通过联合前 后域的预测结果确定每个像素的概率分布,可以更 鲁棒和稳定地完成指纹亚表面的分割.

4 亚表面指纹重构

将B-scan图像的角质层、脊部和谷部与背景分离,得到B-scan图像中每个像素所属类别的细粒度

概率,如公式(2). 在此基础上,本文提出了一种基 于该细粒度分割的重构方法. 在D中,对亚表面指 纹重构的每个像素值应与Aline所提供的信息对 应,如图2(b)所示. 因此,为了在X-Y平面上重构 出更加鲁棒的亚表面指纹,应合理有效地利用Aline 并使用权值函数来确定不同生物结构层对亚表面指 纹重构的贡献度.

$$h = \{Aline(i), i \in len(I_x)\}$$
(4)

在公式(4)中,h是第*i*条Aline坐标的集合,len(I_x) 表示图像I_x的宽度.为了获得具有更多特征的亚表面 重构指纹,模型对目标区域不同层的权值进行量化.本 文提出了一种基于亚表面指纹层析结构的权值函数K (h)确定不同层(角质层、脊部、谷部)对亚表面重构图 像的贡献,表达为公式(5)和公式(6).

$$K(h) = \begin{cases} \beta_1 & y_x^{h} = \hat{\mu} \hat{\beta}_E \\ \beta_2 & y_x^{h} = \hat{\eta} \hat{\beta} \\ 1 - \beta_1 - \beta_2 & y_x^{h} = \hat{\eta} \hat{\beta} \\ 0 & y_x^{h} = \hat{\eta} \hat{\beta} E \nabla \psi \\ z_x = \int K(h) I_x^{h} dh \qquad (6) \end{cases}$$

其中, z_x 条亚表面重构指纹的水平线,y表示根 据概率分布y得到的类别预测结果, y_x ^{*}是B-scan图 像 I_x 中第i条 Aline的类别预测结果.在 y_x ^{*}对应位置 的像素值被定义为 I_x ^{*}.公式(5)确定重构过程中不 同层的权重. β_1 , $\beta_2 \in [0,1]$ 是重构算法中用于量化不 同层权重的超参数. β_1 值越小,角质层对重构图像中 的权重越小. β_2 值越小,脊部对重构图像中的权重越 小.由于OCT采集设备为接触式,在重构过程中,我 们假设重构区域的图像不受指纹表面弯曲程度的影 响.因此,我们在Z方向上直接聚合 $I_c \in D$ 的加权图 像,并在公式(6)中重构 I_z 指纹图像,沿Y方向得到 重构指纹图像z.

5 实验结果与分析

为证明所提出分割模型和重构算法的合理性和 有效性,本章从以下四个小节实验进行论述和分析. 小节5.1介绍分割模型所使用数据集和模型训练方 法以及参数设置.小节5.2将本文分割方法与其他 常见语义分割模型实验对比分析.小节5.3对所提 出的重构算法进行实验,讨论超参数β1和β2的选取 对重构算法的影响,并关注表面磨损指纹重构结果. 最后,小节5.4对比本文方法和现有重构算法在指 纹特征获取、特征质量和指纹匹配上的实验结果.

5.1 数据集和模型训练

本文的指纹数据采集来自于73名志愿者(37名 男性,36名女性)的右手拇指和食指,志愿者含50名 20-40岁学生和办公室工作人员以及23名38-60岁 从事家政的体力劳动工作者.我们采用图2(a)的设 备进行OCT指纹扫描,手指一次扫描包含400幅 B-scan图像,每根手指分两个阶段(时隔1周)进行 重复采集.由于一名志愿者右手拇指指纹无法获取, 最终,我们的OCT指纹数据集包含145×2×400 (手指数量×采集次数×每手指的B-scan数量)张 图像.同时,我们用2D商用指纹采集器(URU4000 B)和2D高精度指纹采集器^[42,43](香港理工大学提 供的公开指纹数据库所使用采集器)对45根来自于 从事家政的体力劳动工作者的手指同样分两阶段进 行传统2D表面指纹采集,得到45×2手指数量×采 集次数)张分辨率为512 dpi大小为328×356 像素 的2D表面指纹数据集,如图9(c)第一列图像所示; 以及包含45×2(手指数量×采集次数)张分辨率大 约为1200 dpi大小为640×480 像素的2D表面高精 度指纹数据集,如图9(c)第二列图像所示.通过观 察,学生和办公人员的手指一般是光滑无磨损的,采 集到的2D表面指纹图像质量较高;而从事家政的体 力劳动工作者因为长期劳作,手指存在或多或少的 破皮或者磨损情况,因而采集到的2D表面指纹图像 质量较低,我们称之为磨损指纹.

在模型训练数据的标注方面,我们从这145根手 指中随机选取12根手指,根据OCT指纹的皮肤组织 结构,对OCT横截面图像的角质层、脊部和谷部进行 如图1(b)所示的像素级别标注,共标注4800(12× 400)张OCT横截面图像.(注:本文数据集中的真实 标签均为手工标注,为避免标注中的人为误差,我们 邀请三位标注人员对同一张B-scan图像分别进行标 注,对三种标注结果取平均作为最终标注结果.)

在训练模型时利用80%的标注数据,即3840张 数据进行训练;20%的标注数据,即960张数据进行 验证.模型中损失函数使用交叉熵,优化器使用 Adam^[44],其学习率为0.0001.训练分割模型时,所 有数据的迭代次数为10次,批大小为10张数据.

5.2 指纹分割模型有效性分析

本节对所提出指纹亚表面层析分割模型进行 具体实验,对比主流语义分割模型,从基础网络和分 割网络两部分出发,列举21种分割模型对本文数据 集进行分割,实验结果见表1.基础网络模型对比使 用VGG-17^[45],Res-34^[46]和HDCRes-34^[41].

基础网络	评价指标	FCN ^[47]	Atrous-FCN ^[40]	U-Net ^[48]	PSP-Net ^[49]	DenseASPP ^[41]	BiseNet ^[50]	本文方法
VGG-17 ^[45]		0.868	0.858	0.801	0.853	0.870	0.858	0.862
Res-34 ^[46]	mIoU	0.870	0.862	0.837	0.832	0.863	0.861	0.870
HDCRes-34 ^[41]		0.875	0.861	0.854	0.840	0.865	0.858	0.873
VGG-17		0.962	0.952	0.939	0.918	0.960	0.917	0.949
Res-34	meanPA	0.967	0.946	0.926	0.906	0.970	0.943	0.956
HDCRes-34		0.951	0.926	0.877	0.946	0.962	0.914	0.956
VGG-17		0.917	0.922	0.823	0.913	0.957	0.944	0.938
Res-34	角质层PA	0.944	0.954	0.875	0.958	0.946	0.983	0.966
HDCRes-34		0.966	0.972	0.941	0.897	0.985	0.926	0.962
VGG-17		0.873	0.938	0.819	0.769	0.920	0.827	0.846
Res-34	脊部PA	0.908	0.868	0.951	0.883	0.919	0.877	0.889
HDCRes-34		0.877	0.847	0.859	0.944	0.876	0.942	0.938
VGG-17		0.982	0.906	0.899	0.846	0.945	0.845	0.955
Res-34	谷部PA	0.986	0.987	0.822	0.780	0.987	0.918	0.913
HDCRes-34		0.897	0.803	0.732	0.920	0.994	0.795	0.895
VGG-17		0.0513	0.0363	0.0596	0.0545	0.0373	0.0499	0.0518
Res-34	Std	0.0465	0.0555	0.0556	0.0684	0.0487	0.0494	0.0416
HDCRes-34		0.0426	0.0670	0.0758	0.0436	0.0614	0.0604	0.0390

表1 不同分割模型在本文数据集上的分割结果

分割网络对比模型包含FCN^[47]、Atrous-FCN^[40]、U-Net^[48]、PSP-Net^[49]、DenseASPP^[41]以及 BiseNet^[50].在评价指标中,IoU(Intersection-over-Union)为预测结果和真实标签的交并比,mIoU为一 张B-scan图像中角质层、脊部和谷部三层各自交并 比的平均值.PA(Pixel Accuracy)为逐像素准确率, 是像素级别评价指标.meanPA为除背景外的分割 结果(角质层、脊部和谷部)的逐像素准确率.Std为 考虑mIoU、meanPA、角质层PA、脊部PA和谷部 PA评价指标的标准差,用以衡量模型的稳定情况.

为验证本文分割网络选取HDCRes-34作为基础网络的有效性,对比VGG-17、Res-34和HDCRes-34的分割性能,我们对表1中最后一列评价指标为mIoU、meanPA、角质层PA、脊部PA和谷部PA下的结果计算均值(Mean)和标准差(Std),并在表2进行比较.结果表明HDCRes-34基础网络的平均值为0.925,优于其他两种网络,证明本文采用HDCRes-34为基础网络时分割性能最佳;同时,标准差为0.0390,达到最低值,证明分割性能最稳定.

为验证分割网络中选取 ASPP 结构的有效性,

表 2 相同基础网络的评价指标平均值与标准差

	VGG-17	Res-34	HDCRes-34
Mean	0.910	0.919	0.925
Std	0.0518	0.0416	0.0390

我们对表1中的分割网络在基础网络为HDCRes-34时的不同评价指标结果(不包含Std)计算均值 (Mean),标出最高值和第二高值;并提取表1最后 一行标准差(Std),标出最低值和第二低值,结果 如表3所示.本文分割方法均值(0.925)高于 Baseline(Atrous-FCN)网络,证明了ASPP结构的 有效性.在所有网络中,DenseASPP网络指标均值 (0.936)最高,本文方法排名第二.然而在标准差结 果中本文方法0.0390,排名第一,而DenseASPP网 络排名第五位.分析可知,本文方法虽然指标均值 排名与DenseASPP网络相差一名,但在指标标准 差中具有更强的稳定性,各项评价指标波动最小.

由于400张B-scan图像中层析结构随着Y轴变 化分布不均且存在噪音干扰,当在极端情况下,分割 模型无法良好分割部分非连续的B-scan.如图6失 效情况所示,在背景区域中存在大量噪音时,角质

表 3 相同分割网络的评价指标平均值与标准差

评价指标	FCN	Atrous-FCN	U-Net	PSP-Net	DenseASPP	BiseNet	本文方法
Mean	0.913	0.882	0.853	0.909	0.936	0.887	0.925
Std	0.0426	0.0670	0.0758	0.0436	0.0614	0.0604	0.0390

层、脊部和谷部三层分割中均存在缺陷区域,即无法 将 B-scan 中的前景亚表面指纹区域和背景区域进 行良好分离,且不能完美识别亚表面指纹层析结构 的边缘,与图6真实标签相差较大.在这种情况下, 本文提出使用滑窗函数利用前后张 B-scan 图像的 连续信息,对原来预测结果中的缺陷区域和边缘部 分进行信息补充.从公式(3)中,我们可以知道 $\alpha \in [0,0.5]$.本文将 α 分别取值0.1,0.3,0.5进行测 试,结果如图6所示.从优化结果我们看出,滑动窗 口函数在三种 α 取值情况下都可以将预测损失部位 进行填充,从而证明了本文提出的滑动窗口函数的 有效性.但是,随着 α 的变化,优化结果并未显著变 化,因此我们认为本文设计的滑动窗口函数对 α 的 选值并不敏感,但是考虑到数据分布不够平衡,此处 对 α 取均值,即 $\alpha = 1/3$,近似为0.3.





图7展示出在3D可视化下,本文分割模型的逐 层分割结果和OCT指纹每层的真实标签.从中发现 预测结果的可视化图像中每张B-scan图像连接平 滑,而在真实标签中则存在明显的断层.预测结果可 视化图像优于真实标签,进一步可以证明,本文所提 出的分割模型在指纹亚表面层析结构中由于考虑到 B-scan图像间的空间连续性,具有更好的适应性和 有效性.

5.3 指纹亚表面重构算法分析

由于本文最终的亚表面指纹图像是通过融合角 质层、活性表皮层和乳突层的亚表面指纹图像得来, 参数β₁(角质层的权重)和β₂(活性表皮层的权重)的 取值影响最终的重构指纹结果.本文通过实验选择 β₁和β₂的取值.图8给出了一个指尖表面有磨损(图 中虚线框区域)的OCT指纹图像在只改变其中某一 层权重而保持其他两层的权重相等的情况下的重构 结果.图8中的第一行图像对应只改变β₁的取值,保



图7 指纹亚表面不同层结构标签和预测结果图

持岛=1-岛-岛的亚表面重构结果;第二行图像对 应只改变 β_2 的取值,保持 $\beta_1=1-\beta_1-\beta_2$ 的亚表面重 构结果;第三行图像对应只改变 $(1-\beta_1-\beta_2)$ 的取值, 保持 $\beta_1 = \beta_2$ 的亚表面重构结果. 观察图8的第一行图 像,我们发现随着β,的增大,只存在于角质层对应的 亚表面图像上的汗孔特征在最终亚表面指纹图像上 越来越明显,但磨损区域的纹理越来越暗,脊骨线对 比度低. 当 β_1 =1.0, β_2 =0.0时, 汗腺特征最清晰. 图8第二行显示随着β2的增大,脊部所占权重增大, 重构图像中的脊线特征逐渐丰富.β1=0.0,β2=1.0 时,可以看到重构图像中脊线上的暗色小坑.相似 的,第三行显示随着(1-β1-β2)的增大,重构图像中 的谷线特征逐渐增多.实验表明,β.的取值最终决定 角质层对最终重构结果的贡献.想要得到较多的汗 孔特征, β_1 的取值应该尽量大,但是 β_1 过大又将导致 结果中对应的磨损区域脊骨线对比度低的问题,不 利于细节点等低精度指纹特征的提取.β。的取值影 响重构结果的脊谷线纹理特征.想要得到较好的纹 理特征,β₁的取值应该尽可能小.

因此,为了确定 $β_1$ 和 $β_2$ 取值,本文设置了 $β_1$ =0.0,也就是角质层不起作用时,改变 $β_2$ 的取值 来观察确定 $β_2$ 的最优取值.同样的,设置 $β_2$ =0.0,改 变 $β_1$ 的取值来观察确定 $β_1$ 的最优取值,实验结果如 图 9 所示.通过图 9(a)的实验对比可知,固定 $β_1$ = 0.0,随着 $β_2$ 的增大,图中褶皱线区域逐渐被修复,并 且谷部信息的适当填充(1 $-β_1-β_2$ 适当增加)可以 增加重构图像的质量.当 $β_1$ =0.0, $β_2$ =0.7时,重构 效果最佳.

本文所提出重构算法可以通过调节 β_1 和 β_2 的取 值以进行指纹不同特征的研究,从而证明了基于 OCT图像的亚表面指纹重构算法的有效性和灵活 性.在重构算法结果对比分析中,提取汗腺特时征选 取 $\beta_1=1.0,\beta_2=0.0$ 进行指纹重构;提取脊谷线和细



图 8 亚表面指纹层析结构权重选取分析:超参数β₁、β₂、 (1-β₁-β₂)分别对应角质层、脊部和谷部在指纹重构时所占 比重.每行只对一种超参数从0.0到1.0取值,固定另外两 个超参数值相等

节特征的指纹匹配实验中选取 β_1 =0.0, β_2 =0.7进 行指纹重构.

5.4 现有重构算法结果对比分析

本节比较现有最佳重构算法(基于峰值检测算法(Peak-Detection)^[26]、基于边缘检测算法(Edge-Detection)^[25])、基于投影重构算法均基于B-scan图像进行重构.如图10(a)和(d)所示,本文重构结果的图像质量与基于投影重构算法均可较为准确地提取出指纹的脊线.基于峰值检测算法的重构结果受B-scan图像质量影响,具有大量散斑噪声,如图10(b).而基于边缘检测算法的重构结果,由于受接触式OCT设备采集到的B-scan图像中角质层和活性表皮层边缘接触重合影响,无法有效提取活性表皮层线轮廓,导致存在大量条状噪声,如图10(c).本文方法得到的重构结果在以下两个方面的表现显著提升:(1)指纹特征质量和数量的提高;(2)指纹匹配性能的提高.具体地:

5.4.1 指纹特征质量和数量对比

由于目前自动指纹识别系统(AFRSs)主要依赖于指纹的细节特征和汗腺特征^[51],细节特征和汗腺特征数量影响AFRSs的识别精度.因此我们使用每像素细节特征和汗腺特征的数量作为衡量不同重构算法结果优劣的标准.特征数量越多,重构结果质量越高.同时,由于脊谷线是指纹最重要的特征之一,我们将脊线密度(单位像素上的脊线数量)作为重构算法的另一评价指标.



图 9 重构算法表现结果. (a). 使用不同 β₂时的重构结果对 比,(b). 使用不同 β₁时的重构结果对比,(c). 指尖表面磨损 2D 指纹图像及对应指纹重构结果. 其中,指纹图像中虚线 框为指纹磨损区域

在获取指纹特征之前,随机从30张重构指纹图 像中选取100个尺寸为100×100像素的正方形区 域,然后对这100个区域中的特征进行人工标注.计 算特征数量公式为<u>1</u>0<u>2</u>*Pixels*/(100×100),其中 *Pixels*表示特征标记区域的像素数量.记汗腺特征, 细节特征,脊线密度单位为每像素特征数量,值越大 表示特征数量越多,并作为实验结果进行比较.对每 种重构算法而言,重构所用指尖OCT数据均对应相 同,选取的正方形区域均为对应相同区域.

结果如表4所示,本文重构结果中包含汗腺特 征数量最多,且脊线密度最高;投影方法可以提取出 更多的细节特征.可以证明本文方法充分利用 B-scan图像中的信息,以获得较高数量的指纹细节



图 10 现有最佳重构算法的表现对比:第一行为同一指尖 图像重构结果对比,并对比其中所选正方形区域及对应细 化图像.(a).本文重构算法(β₁=0.0,β₂=0.7),(b).基于峰 值检测算法(Peak-Detection)^[26],(c).基于边缘检测算法 (Edge-Detection)^[25],(d).基于投影重构算法^[27]

表 4 重构图像每像素汗腺和细节特征数量及脊线密度对比

评价指标	本文方法	边缘检测	峰值检测	投影方法
汗腺特征	$1.9 imes 10^{-5}$	4.0×10^{-6}	$3.0 imes 10^{-6}$	1.1×10^{-5}
细节特征	1.9×10^{-3}	$3.0 imes 10^{-6}$	6.7×10^{-5}	2.3×10^{-3}
脊线密度	5. 3×10^{-4}	2.5×10^{-4}	3.7×10^{-4}	5.1 \times 10 ⁻⁴

特征;同时在指纹第三级特征(汗腺)的获取上取得 突破;并有效降低原始数据中存在的噪音,以提高脊 谷线的清晰度.

5.4.2 指纹识别结果对比

指纹图像质量评价也以指纹识别^[52]的结果作 为评价指标.由于等错误率(Equal Error Rate, EER)可以反映重构指纹图像的识别度,我们利用 EER测量指纹识别结果,用以评价重构指纹图像质 量.我们使用基于细节点特征的指纹识别软件^[53]进 行指纹识别,从横向对比其他重构方法,纵向验证亚 表面指纹信息,具体进行以下两个实验.

在第一个实验中,对使用OCT指纹采集设备获 取学生或办公室工作人员的100个手指数据和从事 家政的体力劳动工作者45个手指数据,分别形成145 对真手指匹配对和41905(145×2×(145×2-1)÷ 2)对假手指匹配对,用以指纹识别.通过比较不同重 构指纹的识别结果,本文重构方法EER达到5.2%, 优于基于峰值检测、边缘检测和投影方法的重构算法 结果.在本实验中,所对比边缘检测和峰值检测方法 中重构结果无法提供清晰的细节点特征供识别软件 识别,而本文方法重构结果具有的较高质量细节特 征,因此证明了本文方法的有效性,如表5所示.

表 5 不同重构算法指纹识别结果对比

评价指标	本文方法	边缘检测	峰值检测	投影方法
EER	5.2%	51.7%	26.7%	5.3%

在第二个实验中,为证明本文重构方法对于磨 损指纹的指纹特征修复的有效性,本文对使用 OCT指纹采集设备、2D商用指纹采集器和2D高 精度指纹采集器获取的从事家政的体力劳动工作 者45个手指数据进行单独识别,分别形成45对真 手指匹配对和4005(45×2×(45×2-1)÷2)对假手 指匹配对.对比本文重构方法、投影方法和2D指纹 采集器获取的指纹图像识别结果,如表6所示,本 文重构方法亚表面指纹识别EER为5.0%,优于 2D表面指纹图像识别结果和基于投影方法重构结 果,如表6所示.在本实验中,2D表面指纹存在的 磨损区域会导致该区域细节点特征丢失,而本文重 构算法根据亚表面指纹信息可以良好的对磨损区 域细节点特征进行还原补充,如图9(c)所示.因此 证明本文方法的鲁棒性.

表 6 表面磨损指纹识别结果对比

河体北右	本文方法	2D商用指纹	2D高精度	投影
评价指怀		采集器	指纹采集器	方法
EER	5.0%	6.9%	7.9%	6.3%

两个实验结果表明,本文所提出的重构算法在 指纹识别中达到最佳结果,且对于磨损指纹可以更 加有效的识别,进一步证明本文所提方法的有效性 和鲁棒性.

6 结 论

本文使用OCT 3D 指纹图像,首次提出一种基 于层析结构的深度学习重构方法,使用语义分割算 法提取亚表面层析结构,并基于分割结果设计出重 构算法,使得现有的指纹识别技术能直接应用OCT 指纹图像上.亚表面的分割提取解决了指纹亚表面 特征提取困难的问题,同时,重构算法充分利用 B-scan图像中的层析结构,根据指纹不同特征的分 布情况进行分离.实验表明,本文所提模型的性能指 标超过目前最佳算法,获得最高质量和数量的指纹 特征,并在指纹匹配实验中表现最佳.之后工作中, 我们将进一步提高分割模型和重构算法的鲁棒性. 由于重构算法超参数β无法自适应调整,将尝试使 用生成对抗网络实现自动化指纹重构.

致谢 感谢国家自然科学基金(62076163, 91959108)深圳市基础研究项目基金(No. JCYJ20190808163401646, JCYJ20180305125822769) 和腾讯"犀牛鸟"深圳大学青年教师科研基金会对本 研究的资助.感谢陕西科技大学齐勇、陈嘉树、曹海 铭对本文研究的支持和帮助.

参考文献

- [1] Jain A K, Dass S C, Nandakumar K. Can soft biometric traits assist user recognition? //Biometric Technology for Human Identification. Orlando, USA, 2004, 5404: 561-572
- [2] Cheng Y, Larin K V. Artificial fingerprint recognition by using optical coherence tomography with autocorrelation analysis. Applied optics, 2006, 45(36): 9238–9245
- [3] Nasiri-Avanaki M R, Meadway A, Bradu A, et al. Anti-spoof reliable biometry of fingerprints using en-face optical coherence tomography. Optics and Photonics Journal, 2011, 1(3): 91-96
- [4] Akbari N, Sadr A. Automation of fingerprint recognition using OCT fingerprint images. Journal of Signal and Information Processing, 2012, 3(1): 117
- [5] Cheng Y, Larin K V. Identification of artificial fingerprints using optical coherence tomography technique//Optics and Photonics for Counterterrorism and Crime Fighting II. Stockholm, Sweden, 2006, 6402; 640200
- [6] Matsumoto T, Matsumoto H, et al. Impact of artificial "gummy" fingers on fingerprint systems//Optical Security and Counterfeit Deterrence Techniques IV. San Jose, USA, 2002, 4677: 275-289
- [7] Huang D, Swanson E A, Lin C P, et al. Optical coherence tomography. science, 1991, 254(5035): 1178–1181
- [8] Madhero88, "Layers of the skin." https://en.wikipedia.org/ wiki/File: Skin_layers.png
- [9] Meng Z, Liang Y, Yao X, et al. In-line measurement and compensation for dispersion in OCT system. Journal of Optoelectronics•Laser, 2011, 22(2):256-260
- [10] Su R, Kirillin M, Ekberg P, et al. Optical coherence tomography for quality assessment of embedded microchannels in alumina ceramic. Optics express, 2012, 20(4): 4603–4618
- [11] Dubey S K, Anna T, Shakher C, et al. Fingerprint detection using full-field swept-source optical coherence tomography. Applied Physics Letters, 2007, 91(18): 181106
- [12] Darlow L N, Connan J. Study on internal to surface fingerprint correlation using optical coherence tomography and internal fingerprint extraction. Journal of Electronic Imaging, 2015, 24(6): 063014
- [13] Darlow L N, Webb L, Botha N. Automated spoof-detection for fingerprints using optical coherence tomography. Applied

optics, 2016, 55(13): 3387-3396

- [14] Meissner S, Breithaupt R, Koch E. Defense of fake fingerprint attacks using a swept source laser optical coherence tomography setup //Frontiers in Ultrafast Optics: Biomedical, Scientific, and Industrial Applications Ⅲ. International Society for Optics and Photonics. San Francisco, USA, 2013, 8611; 86110L
- [15] Larin K V, Cheng Y. Three-dimensional imaging of artificial fingerprint by optical coherence tomography//Biometric Technology for Human Identification V. International Society for Optics and Photonics. Orlando, USA, 2008, 6944: 69440M
- [16] Shi B, Meng Z, Liu T, et al. Identifying artificial fingerprint by using optical coherence tomography. Journal of Optoelectronics
 Laser, 2013, 24(12): 2404-2408
 (石博雅,孟卓,刘铁根,等.全光纤光学相干层析系统用于人造 指纹的识别.光电子·激光, 2013, 24(12): 2404-2408)
- [17] Chen P, Jiang L, Wang H, et al. Fingerprint Anticounterfeiting Method Based on Optical Coherence Tomography and Optical Micro-angiography. Acta Photonica Sinica, 2019, 048(006): 1-10
 (陈朋,江磊,王海霞,等.基于光学相干层析成像与光学微血管 造影的指纹防伪方法.光子学报, 2019, 048(006): 1-10)
- [18] Chugh T, Jain A K. OCT fingerprints: Resilience to presentation attacks. arXiv preprint arXiv:1908.00102, 2019
- [19] Liu F, Liu H, Zhang Wet al. One-class Fingerprint Presentation Attack Detection using Auto-encoder Network. IEEE Transactions on Image Processing, doi: 10.1109/ TIP.2021.3052341
- [20] Liu H, Zhang W, Liu F, et al. 3D fingerprint gender classification using deep learning//Chinese Conference on Biometric Recognition. Springer, Cham. Zhuzhou, China, 2019: 37-45
- [21] Bossen A, Lehmann R, Meier C. Internal fingerprint identification with optical coherence tomography. IEEE photonics technology letters, 2010, 22(7): 507–509
- [22] Darlow L N, Akhoury S S, Connan J. Internal fingerprint acquisition from optical coherence tomography fingertip scans// 2015 Third International Conference on Digital Information, Networking, and Wireless Communications (DINWC). Moscow, Russia, 2015; 188–191
- [23] Khutlang R, Nelwamondo F V. Novelty detection-based internal fingerprint segmentation in optical coherence tomography images //2014 Second International Symposium on Computing and Networking. Shizuoka, Japan, 2014; 556–559
- [24] Liu G, Chen Z. Capturing the vital vascular fingerprint with optical coherence tomography. Applied optics, 2013, 52(22): 5473-5477
- [25] Darlow L N, Connan J. Efficient internal and surface fingerprint extraction and blending using optical coherence tomography. Applied optics, 2015, 54(31): 9258–9268
- [26] Sekulska-Nalewajko J, Gocławski J, Sankowski D. The detection of internal fingerprint image using optical coherence tomography. Image Processing & Communications, 2017, 22(4): 59-72
- [27] Liu F, Liu G, Zhao Q, et al. Robust and high-security

fingerprint recognition system using optical coherence tomography. Neurocomputing, 2020, 402: 14-28

- [28] Yu X, Xiong Q, Luo Y, et al. Contrast enhanced subsurface fingerprint detection using high-speed optical coherence tomography. IEEE Photonics Technology Letters, 2016, 29(1): 70-73
- [29] da Costa H S G, Bellon O R P, Silva L. Biometric identification with 3D fingerprints acquired through optical coherence tomography [Ph. D Thesis]. Federal University of Paraná, Curitiba, Brazil, 2016
- [30] Auksorius E, Boccara A C. Fast subsurface fingerprint imaging with full-field optical coherence tomography system equipped with a silicon camera. Journal of biomedical optics, 2017, 22 (9): 096002
- Breithaupt R, Sousedik C, Meissner S. Full fingerprint scanner using optical coherence tomography//3rd International Workshop on Biometrics and Forensics (IWBF 2015). IEEE, Gjovik, Norway, 2015: 1-6
- [32] Khutlang R, Khanyile N P, Makinana S, et al. High resolution feature extraction from optical coherence tomography acquired internal fingerprint//2016 17th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD). Shanghai, China, 2016; 637–641
- [33] Raja K B, Auksorius E, Raghavendra R, et al. Robust verification with subsurface fingerprint recognition using full field optical coherence tomography//Proceedings of the IEEE conference on computer vision and pattern recognition workshops. Hawaii, USA, 2017: 144-152
- [34] Moolla Y, Singh A, Saith E, et al. Fingerprint matching with optical coherence tomography//International Symposium on Visual Computing. Springer, Cham. Las Vegas, USA, 2015: 237-247
- [35] Bao W, Ding Z, Wang C, et al. Phase sensitive spectral domain optical coherence tomography for latent fingerprint detection. Acta Physica Sinica, 2013(11): 257-262
 (鲍文,丁志华,王川,等.基于相位敏感谱域光学相干层析术的 潜指纹获取方法.物理学报,2013(11): 257-262)
- [36] Raja K B, Raghavendra R, et al. Two Stream Convolutional Neural Network for Full Field Optical Coherence Tomography Fingerprint Recognition//2019 22th International Conference on Information Fusion (FUSION). Ottawa, Canada, 2019; 1-4
- [37] Liu F, Liu G, Wang X. High-accurate and robust fingerprint anti-spoofing system using optical coherence tomography. Expert Systems with Applications, 2019, 130: 31-44
- [38] Liu F, Shen C, Liu H, et al. A flexible touch-based fingerprint acquisition device and a benchmark database using optical coherence tomography. IEEE Transactions on Instrumentation and Measurement, 2020, 69(9): 6518-6529

- [39] Wang P, Chen P, Yuan Y, et al. Understanding convolution for semantic segmentation//2018 IEEE winter conference on applications of computer vision (WACV). IEEE. Lake Tahoe, USA, 2018; 1451–1460
- [40] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions. arXiv preprint arXiv:1511.07122, 2015
- [41] Yang M, Yu K, Zhang C, et al. Denseaspp for semantic segmentation in street scenes//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City, USA, 2018; 3684–3692
- [42] Zhao Q, Zhang L, Zhang D, et al. Direct pore matching for fingerprint recognition//International conference on biometrics. Alghero, Italy:Springer. 2009: 597-606
- [43] Liu F, Zhao Q, Zhang L, et al. Fingerprint pore matching based on sparse representation//2010 20th International Conference on Pattern Recognition. Istanbul, The Republic of Turkey, 2010; 1630–1633
- [44] Kingma D P, Ba J. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014
- [45] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv: 1409.1556, 2014
- [46] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition//Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas, USA, 2016: 770-778
- [47] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation//Proceedings of the IEEE conference on computer vision and pattern recognition. Boston, USA, 2015: 3431–3440
- [48] Xie S, Tu Z. Holistically-nested edge detection//Proceedings of the IEEE international conference on computer vision. Santiago, Republic of Chile, 2015: 1395-1403
- [49] Zhao H, Shi J, Qi X, et al. Pyramid scene parsing network // Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu, USA, 2017:2881–2890
- [50] Yu C, Wang J, Peng C, et al. Bisenet: Bilateral segmentation network for real-time semantic segmentation//Proceedings of the European conference on computer vision (ECCV). Munich, Germany, 2018; 325-341
- [51] Maltoni D, Maio D, Jain A K, et al. Handbook of fingerprint recognition. Springer Science & Business Media, 2009
- [52] Ma L, Tan T, Wang Y, et al. Personal identification based on iris texture analysis. IEEE transactions on pattern analysis and machine intelligence, 2003, 25(12): 1519–1533
- [53] KennethK. and WayneJ. S.. NBIS: Nist Biometric Image Software. https://www.nist.gov/services-resources/software/ nist-biometric-image-software-nbis



LIU Feng, Ph. D., associate professor. Her research interest covers biometrics, image processing and pattern recognition. **ZHANG Wen-Tian**, M. S. candidate. His research interests include image processing, pattern recognition and biometrics.

LIU Hao-Zhe, M. S. candidate. His research interests are in artificial intelligence, computer vision and biometrics.

LIU Guo-Jie, M. S. candidate. His research interests include pattern recognition, biometrics and image processing.

SHEN Lin-Lin, Ph. D., professor. His research interest covers deep learning, face recognition analysis and medical image processing.

Background

Optical Coherence Tomography (OCT) technology opens up a new domain for fingerprint recognition, since the information beneath the skin of the fingertip and the internal features of multilayered tissues can be imaged using OCT. Reconstructing subsurface fingerprint image with high quality will not only solve the image degradation problem caused by surface imaging (e. g., altered or worn-out fingerprints, ultrawet/ dry fingers), but also provide compatible image data for minutiae based fingerprint recognition techniques.

Existing subsurface fingerprint reconstruction approaches focus on accurately detecting viable epidermis layer of skin tissues by using either edge detection-based, peak detectionbased or projection-based methods. However, such methods are very sensitive to noise and image quality. Meanwhile, other useful subsurface fingerprint features will be lost, such as sweat gland. The quality of the reconstructed subsurface fingerprints are far below our expectations for the following recognition.

To solve these problems, this paper, for the first time, proposes to reconstruct subsurface fingerprint image using deep learning. Firstly, we use HDCRes-34 as the basical network to robustly segment each OCT-based cross sectional image into three layers corresponding to skin structure. Then, we use a slide window in the segmentation results to correct the possible false segmentation by previous model. The subsurface fingerprint is finally reconstructed by fusing the information of three layers. Experimental results show that the segmentation model can effectively obtain the three subsurface layers and by comparing with the state-of-the-art reconstruction approaches, our method outperforms in the number of features per pixel, ridge-line density and EER.

This project proposes to investigate robust anti-spoofing and recognition approaches by making full use of the subsurface information captured by OCT. The project will finally realize a set of automatic fingerprint recognition scheme which integrates high anti-spoofing, high recognition accuracy and living detection capability. Thus, to further promote the application of fingerprint recognition, to make up for the shortcomings of current AFRSs, and to open up a new field for fingerprint recognition.

Fingerprint recognition and deep learning are main research topics of our research group. In the past few years, we have worked out methods on fingerprint segmentation, 3D fingerprint reconstruction, deep fingerprint feature extraction and so on. A few of representative papers are listed as bellow:

(1) High-accurate and robust fingerprint anti-spoofing system using Optical Coherence Tomography. Expert Systems with Applications. 2019

(2) 3D fingerprint reconstruction system using feature correspondences and finger shape model. Pattern Recognition. 2014

(3) Fingerprint pore matching using deep features. Pattern Recognition. 2020