

基于轻量级 U-Net 神经网络提取 OCT 内指纹和外指纹^①

王海霞^{②*} 杨熙丞^{**} 梁荣华^{*} 陈 朋^{③*}

(* 浙江工业大学计算机科学与技术学院 杭州 310000)

(** 浙江工业大学信息工程学院 杭州 310000)

摘 要 光学相干断层扫描(OCT)技术是一种非侵入式的成像技术,可以用来采集高分辨率的手指 3 维数据,提取角质层和乳头层轮廓并生成内指纹和外指纹。针对目前已有算法在提取角质层和乳头层轮廓时易受到汗腺和皮下组织的影响导致轮廓提取结果有偏差这一问题,本文利用自制 OCT 实验平台获取高分辨率手指 3 维数据,提出了一种基于深度可分离卷积的轻量级 U-Net 神经网络算法来准确提取角质层和乳头层轮廓,通过拼接轮廓的相对深度信息生成内指纹和外指纹。实验结果表明,本文提出的算法能够精确地提取内外指纹,同时在生成指纹效果和普通 U-Net 神经网络算法相似的前提下大幅减少了模型参数数量。

关键词 光学相干断层扫描(OCT); 内指纹; 外指纹; 深度可分离卷积; U-Net

0 引 言

生物识别技术是一种利用人体的生物特征或行为特征进行识别的技术。由于指纹的独特性和永久性,指纹识别成为了目前最成熟的生物识别技术,广泛应用于公安、金融等领域^[1]。传统的指纹扫描仪扫描手指表面皮肤,生成 2 维指纹图像,根据指纹图像的细节特征进行识别。如果在手指表面使用人造指纹,可以骗过大多数的指纹扫描仪,大大降低其识别的可靠性^[2]。因此,在一些高安全性需求的业务场景,需要更为可靠的指纹防伪与识别方法。

光学相干断层扫描技术(optical coherence tomography, OCT)是 20 世纪 90 年代初发展起来的无损、高分辨、非侵入式的成像技术,是利用生物组织散射光相干原理成像的介观(微米尺度)活体组织高分辨率成像和观测手段,目前在眼底检测领域有

着广泛应用^[3]。由于 OCT 仪器发出的光可以穿过手指皮肤的表皮,直到手指真皮层,得到 2 ~ 3 mm 深的 OCT 3 维原始数据,因此利用 OCT 技术可以同时检测到表皮层指纹和真皮层指纹^[4]。观察发现手指内部的真皮层指纹(内指纹)和表皮层指纹(外指纹)纹路相同。实际上,内指纹是外指纹的来源,它能代表外指纹的谷线与脊线结构^[5]。因此,高效利用内指纹和外指纹联合进行指纹识别,可以大大提高指纹识别的安全性。

利用 OCT 技术本文采集到了一系列手指断层扫描切片(B-scan 图像)。皮肤主要分为 3 层,即表皮层、真皮层和皮下组织。OCT 的 B-scan 图像主要呈现出皮肤的表皮层和真皮层。其中表皮层的顶端叫做角质层,为表皮指纹提供了脊线和谷线的纹理。表皮层的中下端包含着一些螺旋形状的汗腺。其次表皮层和真皮层之间的分界处轮廓称为乳头层,它的凹陷与突起是内指纹纹路的重要依据。精准提取

① 国家重大科研仪器研制项目(61527808),国家自然科学基金(61602414),浙江省自然科学基金(LY19F050011)和浙江省基础公益研究计划(LGG19F020011)资助项目。
② 女,1983 年生,博士,副教授;研究方向:图像处理与模式识别;E-mail: hxbwang@zjut.edu.cn
③ 通信作者,E-mail: chenpeng@zjut.edu.cn
(收稿日期:2018-12-04)

出角质层和乳头层的轮廓是生成高质量的外指纹和内指纹的前提。

OCT 外指纹和内指纹提取算法主要分为 2 类,即切片法和轮廓提取法。切片法主要提取一系列 B-scan 图像中固定深度的灰度值,组合呈现出内指纹和外指纹的灰度指纹图。Bossen 等人^[6]利用多张固定深度的指纹横截面切片的平均值来还原内指纹的纹路。Raja 等人^[7]讨论了不同深度提取的内指纹的质量差异,同时也讨论了将这些指纹进行融合对于指纹识别准确率的影响。轮廓提取法需要精确提取每张 B-scan 图像中的角质层和乳头层轮廓,利用每层的凹陷和突起的深度关系或者轮廓本身的灰度值来还原内指纹和外指纹。Khutlang 等人^[8,9]首先通过利用 3 次拟合函数去除手指表面的曲率,然后使用一种新颖性的检测方式提取乳头层的轮廓。Darlow 等人^[10]利用 B-scan 图像中每一列像素的峰值距离、梯度、标准差等属性构成特征变量,使用 k 均值聚类算法来侦测乳头层的位置。Wang 等人^[11]通过提取每一列像素的梯度值,使用层次聚类算法提取角质层上表面和乳头层的轮廓,重建外指纹和内指纹。

目前已知的方法都有一些不足,切片法主要的问题是無法选择合适的深度生成外指纹和内指纹,提取效果也不尽如人意。而目前的轮廓提取法一般通过构建梯度算子等特征并组合,利用机器学习算法进行分类。这类方法的缺点是容易出现许多异常点,同时无法避免乳头层轮廓周围的皮下组织和汗腺等结构的影响。随着深度学习技术不断发展,卷积神经网络已经证明了自己在图像分类、目标识别、图像分割^[12]等任务中的有效性。和传统的机器学习算法相比,卷积神经网络的最大优势是可以通过多层的卷积自动提取有效的特征。Long 等人^[13]提出了全卷积神经网络(fully convolutional neural network, FCN),建立了一个端到端的神经网络来解决图像分割问题。Ronneberger 等人^[14]提出了 U-Net 神经网络,特点是增加了跳跃结构来连接收缩网络和扩张网络,提高了图像分割的准确性。此算法广泛应用于医学图像分割领域。由于 OCT 采集到的手指 3 维数据的数据量较大,需要设计一种模型参

数量比较小的轻量级神经网络来处理 OCT 手指 3 维数据。

因此,本文提出一种结合深度可分离卷积和 U-Net 神经网络的新型轻量级神经网络来提取角质层和乳头层轮廓。相比于已有的角质层和乳头层轮廓提取算法,本方法的轮廓提取更为精准,能很好地排除汗腺和皮下组织的干扰。相比于标准 U-Net 神经网络算法,本方法的参数量明显下降,计算时间也有所减少,可以在未来更好地部署于嵌入式平台。

1 算法总体设计

图 1 给出了本文算法框架,本文算法分为 4 个部分:(1)图像预处理部分,包括 B-scan 图像去噪、手指曲率去除、图像分块及数据扩增;(2)利用轻量级 U-Net 神经网络预测 B-scan 图像的角质层和乳头层的分割结果部分;(3)分割结果后处理部分,包括假阳性区域去除、轮廓提取、缺失点补齐并提取深度差;(4)生成 OCT 内指纹和外指纹部分。

1.1 图像预处理

如图 2(a)所示,由于 B-scan 图像中含有大量 OCT 特有的散斑噪声,影响了角质层和乳头层的提取,需采用滤波方法去除散斑噪声。块匹配和 3 维滤波(block-matching and 3D filtering, BM3D)算法^[15]是一种非局部算法,通过块匹配算法和 3 维变换滤波算法进行 2 次去噪,第 1 次去噪的结果作为第 2 次去噪的权值。此算法广泛应用于医学图像去噪领域。本文采用 BM3D 滤波算法处理 B-scan 图像,图 2(b)显示了去噪后得到的高信噪比结果。非接触的 OCT 采集方式使采集到的手指数据保持了自然曲率,因此本文采用文献[8]的方法自动展平曲率。图 2(c)得到了 B-scan 图像展平曲率后的结果。本次实验采用的数据集的单张 B-scan 图像大小为 500×1 500 像素,超过了 GPU 的处理能力。同时样本过少容易造成神经网络的泛化能力不强。因此,本文通过前景和背景灰度的明显差异来提取感兴趣区域,并利用手指 B-scan 图像水平方向上纹理的相关性,在感兴趣区域中进行图像切块操作。其中在模型的训练阶段沿水平方向以 40 像素的间




图1 算法总体流程




图2 B-scan 图像预处理步骤

隔半重复地切块,测试阶段沿水平方向以 80 像素的间隔不重复地切块,得到一系列 200×80 像素大小的切块结果,如图 2(c)的方框区域所示。由于深度学习往往需要大量的训练样本,而标注数据需要花

费大量的时间,因此本文中采用数据增强技术,以随机角度旋转、随机平移、图像翻转来扩充数据集,减少因数据集过小产生的神经网络过拟合问题,以取得更好的分割精度。

1.2 轻量级 U-Net 神经网络

卷积神经网络 (convolutional neural network, CNN) 近几年引起了很大关注,因其使用了权值共享、局部连接、池化等思想,可以有效地降低神经网络的复杂性。卷积神经网络的核心是卷积层和池化层,卷积层可以用来提取图像的局部特征,同时融合激活函数所具有的非线性特征、抽象出更为复杂的特征,提升模型表达能力。池化层的作用是将得到的特征进行降维操作,降低模型的复杂性。传统的卷积神经网络主要适用于图像分类问题。对于本文需解决的图像分割问题,文献[13]提出了全卷积神经网络结构,该网络和卷积神经网络的区别在于全卷积神经网络将卷积神经网络的全连接层替换为卷积层,使该网络可以处理任意尺寸大小的图像,得到每个像素所属类别的语义信息。全卷积神经网络已经广泛地应用于端到端的语义分割任务中,其结果

精度大大优于传统的分割算法。文献[14]提出的 U-Net 神经网络对全卷积神经网络进行了改进:一是加入了跳跃连接结构,二是在扩张路径中加入了卷积层,使其成为一个对称的 U 型网络结构。由于标准 U-Net 神经网络所需的模型参数数量较大,为了减少参数数量,使其更好地移植到硬件平台,本文基于深度可分离卷积来改进 U-Net 神经网络结构,提出一种新的轻量级 U-Net 神经网络。使用训练好的轻量级 U-Net 神经网络预测 B-scan 图像中角质层和乳头层的具体区域。在保持预测精度的同时,能够有效地减少神经网络的模型参数,具有重要意义。

1.2.1 深度可分离卷积

深度可分离卷积是一种标准卷积的分解形式,可以在有效缩小模型参数的同时仍然保持较高的准确率,是 Xception^[16]、MobileNet^[17]等网络上的基础模块。深度可分离卷积将标准卷积核分解为一个逐通道处理的深度卷积核和一个跨通道处理的点卷积核。将标准卷积核进行分解可以有效地减少模型参数和计算量。

步长为 1 的标准卷积输出可以由式(1)表示:

$$G_{k,l,m} = \sum_{i,j,m} K_{i,j,m,n} F_{k+i-1,l+j-1,m} \tag{1}$$

其中 G 表示卷积层输出特征图, K 表示卷积核,尺寸为 $D_K \times D_K \times M \times N$, M 为输入通道数, N 为输出通道数, F 表示输入特征图, $D_F \times D_F$ 为输入特征图的维度大小。标准卷积的计算量为

$$P_1 = D_K \times D_K \times M \times D_F \times D_F \times N \tag{2}$$

深度可分离卷积可以分为 2 部分,它将标准卷积分解为一个逐通道深度卷积和一个 1×1 的跨通道点卷积,深度卷积将单个卷积核应用到了每一个输入通道,点卷积用来组合深度卷积的输出。其中深度卷积可以由式(3)表示:

$$G'_{k,l,m} = \sum_{i,j} K'_{i,j,m} F_{k+i-1,l+j-1,m} \tag{3}$$

式中 G' 代表深度卷积输出特征图, K' 代表深度卷积卷积核,大小为 $D_K \times D_K \times M$ 。深度可分离卷积的计算量分为 2 部分:一部分为逐通道深度卷积核的计算量;另一部分为跨通道的点卷积核计算量。深度可分离卷积的计算量为

$$P_2 = D_K \times D_K \times M \times D_F \times D_F + D_F \times D_F \times M \times N \tag{4}$$

其中,加号左边为逐通道 2 维卷积的计算量,加号右边为跨通道的卷积计算量。因此利用标准卷积和深度可分离卷积的计算量比例为

$$P = \frac{P_2}{P_1} = \frac{1}{N} + \frac{1}{D_K^2} \tag{5}$$

假设输出 $N = 128$ 通道的特征图,卷积层卷积核的尺寸为 3×3 ,则模型的参数数量仅为标准卷积参数数量的 11.89%,大大减小了模型的参数数量。

1.2.2 基于深度可分离卷积的轻量级 U-Net 神经网络结构

U-Net 神经网络通过收缩路径和扩张路径构成了一个对称的 U 型神经网络。标准 U-Net 神经网络由 19 个卷积层和相应的池化层及上采样层组成。U-Net 神经网络中首次采用跳跃连接的方式将收缩路径的特征和扩张路径的特征级联到一起来获取图像的多尺度信息,提高分割的准确率。本文的轻量级 U-Net 神经网络使用深度可分离卷积模块代替 U-Net 神经网络的标准卷积模块,同时缩减了每个特征图的通道数。其中图 3 比较了标准卷积模块和深度可分离卷积模块,如图 3(a)所示,标准卷积模块由一个标准的卷积层、批归一化层(batch normalization)^[18]和线性整流函数(ReLU)组成。其中卷积核的大小为 3×3 。如图 3(b)所示,深度可分离卷积模块由 3×3 的深度卷积和 1×1 的点卷积组成,在每个卷积层之后跟随批归一化层和线性整流函数。




图 3 标准卷积模块和深度可分离卷积模块的比较

图 4 和表 1 展示了网络结构和模型参数。本模型包含收缩路径和扩张路径。在收缩路径中,包含 3 个收缩单元,第 1 个收缩单元中包含 1 个标准卷积模块、1 个深度可分离卷积模块和 1 个池化层。第 2 个和第 3 个收缩单元中包含 2 个重复的深度可分离卷积模块和 1 个池化层。每经过一次池化层,下一层次的卷积特征通道数量加倍,同时特征图维度减半。相比于标准 U-Net 神经网络,本网络的最大通道数为 128。对网络结构的精炼有助于减小网络参数数量,同时保持较好的泛化能力。经过收缩路径和扩张路径之间的 2 个深度可分离模块后,使用扩张路径复原特征的分辨率。扩张路径和收缩路

径相反,同样有 3 个扩张单元,第 1 个和第 2 个扩张单元中包含 1 个上采样层和 2 个重复的深度可分离卷积模块。最后一个扩张单元中包含上采样层、深度可分离卷积模块和标准卷积模块。每次使用上采样层后特征图维度加倍、通道数减半。跳跃连接增加了收缩路径和扩张路径之间的通路。网络最后使用一个 1×1 大小的标准卷积模块缩减维度,并使用归一化指数函数 (softmax) 将数值转换为概率。模型输入为预处理得到的一系列切块图像,模型输出为对应的分割结果,每一个像素点的值表示该点属于角质层、乳头层和背景的概率。




图 4 基于深度可分离卷积的轻量级 U-Net 神经网络结构

表 1 轻量级 U-Net 神经网络模型参数

层类型	输入大小	滤波器	重复次数
标准卷积模块	$1 \times 200 \times 80$	3×3	1
深度可分离卷积模块	$16 \times 200 \times 80$	$3 \times 3, 1 \times 1$	1
池化层	$16 \times 200 \times 80$		1
深度可分离卷积模块	$16 \times 100 \times 40$	$3 \times 3, 1 \times 1$	2
池化层	$32 \times 100 \times 40$		1
深度可分离卷积模块	$32 \times 50 \times 20$	$3 \times 3, 1 \times 1$	2
池化层	$32 \times 50 \times 20$		1
深度可分离卷积模块	$64 \times 25 \times 10$	$3 \times 3, 1 \times 1$	2
上采样层	$128 \times 25 \times 10$		1
深度可分离卷积模块	$192 \times 50 \times 20$	$3 \times 3, 1 \times 1$	2
上采样层	$64 \times 50 \times 20$		1
深度可分离卷积模块	$96 \times 100 \times 40$	$3 \times 3, 1 \times 1$	2
上采样层	$32 \times 100 \times 40$		1
深度可分离卷积模块	$48 \times 200 \times 80$	$3 \times 3, 1 \times 1$	1
标准卷积模块	$16 \times 200 \times 80$	3×3	1
标准卷积模块	$16 \times 200 \times 80$	1×1	1


1.3 后处理、指纹拼接与增强

对于图 5(a) 所示的 OCT B-scan 图像,使用轻量级 U-Net 神经网络得到了角质层和乳头层的分割结果。如图 5(b) 和 (c) 所示,可以发现角质层和乳头层总体呈现出较准确的分割结果,但是也观察到角质层和乳头层的分割结果出现了一定的假阳性区域,这些区域在图 5(b) 和 (c) 中用灰色箭头标出。出现这些假阳性区域的原因是一些角质层或乳头层周围的皮下组织或汗腺的信号强度十分接近,容易和角质层与乳头层区域混淆,为此本文首先使用最大类间方差算法二值化角质层和乳头层区域,对得到的结果使用种子填充法计算每个连通区域的面积,并设置面积阈值 $T = 100$,去除面积小于 T 的孤立点,得到优化的角质层分割结果 F_s 和乳头层分割结果 F_p 。此操作可以有效去除大部分假阳性区域。接下来需要提取角质层上表面轮廓 L_{us} 、下表面轮廓 L_{ds} 和乳头层上表面轮廓 L_p 。本文针对分割结果 F_s 和 F_p , 对其深度方向(y 方向)进行一阶微分提取边缘特征点,考虑使用一阶差分来近似其一阶微

分值。根据结果的正负来判断轮廓上下表面,公式如下:

$$\begin{cases} L_{us}(x) = y & F_s(x, y + 1) - F_s(x, y) > 0 \\ L_{ds}(x) = y & F_s(x, y + 1) - F_s(x, y) < 0 \\ L_p(x) = y & F_p(x, y + 1) - F_p(x, y) > 0 \end{cases} \quad (6)$$

通过图 5(c) 的箭头发现,乳头层或角质层存在信号强度十分弱的区域,这是因为透镜与指尖谷线位置之间存在空气间隙,光在穿过该位置时,由于折射率变化使对应成像灰度值变低,其中一些区域尤为严重。这些区域经过轻量级 U-Net 神经网络处理,得到的结果可能会产生断裂现象。对于这些区域提取轮廓后存在的缺失点,本文使用 3 次样条插值来补齐这些缺失点。得到连续完整的角质层上表面轮廓 L'_{us} 、下表面轮廓 L'_{ds} 和乳头层上表面轮廓 L'_p , 最后以角质层上表面轮廓 L'_{us} 作为基准,通过 $L'_{ds} - L'_{us}$ 和 $L'_p - L'_{us}$ 得到单张 B-scan 图像角质层和乳头层的深度差 1 维矩阵,由于本文使用的手指



从上往下依次表示角质层上表面,角质层下表面和乳头层上表面

图 5 B-scan 图像及其处理后的结果

3 维数据包含 1 200 张连续 B-scan 图像,获取每张图像的角质层和乳头层的深度差 1 维矩阵并依次拼接,得到了外指纹初步结果 I_{outer} 和内指纹初步结果 I_{inner} 。最后对外指纹和内指纹进行图像归一化操作和高斯低通滤波器滤波操作,得到最终外指纹结果 I'_{outer} 和内指纹结果 I'_{inner} 。

1.4 OCT 生成外指纹和内指纹算法步骤

本节总结了 OCT 生成外指纹和内指纹的算法流程,步骤如下:

(1) 选取部分 OCT B-scan 数据划分为训练集和验证集,并进行角质层和乳头层标注。对其中的 B-scan 图像分别进行 BM3D 图像去噪、手指曲率去除和图像分块及数据扩增等图像预处理工作。

(2) 使用预处理后的训练集来训练本文提出的轻量级 U-Net 神经网络,使用验证集评价此网络的有效性。

(3) 使用训练好的轻量级 U-Net 神经网络模型对经过预处理的 OCT B-scan 图像进行角质层和乳头层分割。

(4) 对上述分割结果进行去除小面积假阳性区域、曲线轮廓提取和插值补充缺失点等图像后处理操作,得到角质层和乳头层轮廓。

(5) 以角质层上表面轮廓为基准,计算每张 B-scan 图像的角质层和乳头层的深度差信息。

(6) 对每一组 OCT 手指数据(由 1 200 张 B-scan 图像组成)中的每幅 B-scan 图像,重复进行步骤(3)~(5),得到所有 B-scan 图像的角质层和乳头层深度差信息。拼接这些图像的深度差信息得到 OCT 外指纹和内指纹。形成一套完整的外指纹和内指纹提取算法。

2 实验结果分析

本文完成了以下 3 组实验:B-scan 层面上不同算法对角质层和乳头层轮廓提取的精确度比较;指纹层面上不同算法生成 OCT 指纹的质量评价比较以及 2 种神经网络算法的模型参数和时间的讨论。通过上述的实验来验证卷积神经网络对于 OCT 内外指纹生成的有效性和本文提出的基于深度可分离

卷积的轻量级神经网络的综合优势。

2.1 实验平台和数据集

如图 6 所示,本实验搭建光谱频域 OCT 系统(spectral domain OCT, SD-OCT),由宽频带光源、光谱仪、参考臂、样品臂等组成,可以采集大面积的高清 OCT 指纹。利用了 2 块分别放置于样品臂和参考臂的玻璃 G1 和 G2,其中手指放在接近 G1 玻璃下表面处,G2 玻璃用来色散补偿。准直器 M 安装在样品臂上,增加系统的焦点深度,减少指尖的离焦现象。光谱仪频率的中心波长在 $\lambda = 848 \text{ nm}$,频谱带宽在 $\Delta\lambda = 46 \text{ nm}$,输出能量在 $P = 4.81 \text{ mW}$,线扫描相机的轴向扫描速率在 18 kHz/A-scan 。系统的成像深度在 2 mm 左右。OCT 通过多次线扫描获取 1 张 B-scan 图像,每张 B-scan 图像由 1 500 列 A-scan 组成,1 组 OCT 数据包括 1 200 张 B-scan 图像。采集单个手指数据的时间约需 120 s,最终生成 $1\,500 \times 1\,200$ 像素大小、 $15 \text{ mm} \times 12 \text{ mm}$ 的外指纹和内指纹。




图 6 OCT 系统

获取到的数据集总共包含 26 个手指,分为 2 部分 D_1 和 D_2 。其中 D_1 数据集包含了 3 个手指的部分 OCT 数据,每个手指数据选择其中 48 张 B-scan 图像进行角质层和乳头层的标注,其中乳头层的标注位置为乳头层上表面自上至下 25 像素。 D_1 数据集用来比较不同算法的轮廓提取的准确度。 D_2 数据集包含了 23 个手指的 OCT 数据,用来比较不同算法生成指纹质量的评价结果。

2.2 网络训练

实验基于 Keras 深度学习框架,训练的神经网络模型统一采用交叉熵损失函数,定义为

$$L = - \sum_{k=1}^n \sum_{i=1}^C t_{ki} \log(y_{ki}) \quad (7)$$

式中, n 为图像的像素数量, C 表示类别, t_{ki} 指像素

点 k 属于类别 i 的概率, y_{ki} 指模型对像素点 k 预测为类别 i 的概率。本文使用 Adam 优化方法作为参数优化器^[19]。设置学习率为 0.001, 训练批大小为 24, 训练数据集共迭代训练 200 轮。实验显卡为 NIVDIATesla K80。

2.3 轮廓准确性提取实验

本实验中分别使用与文献[11]的算法、深度可分离卷积构成的轻量级 U-Net 神经网络和标准卷积构成的相同层数的 U-Net 神经网络提取角质层上表面 L'_{us} 、下表面 L'_{ds} 和乳头层的上表面轮廓 L'_p 并

进行比较。其中文献[11]的算法未寻找表皮层下表面的轮廓, 因此本文利用梯度算子对该轮廓进行了补充。本文使用均方误差 (mean squared error, MSE) 和均方根误差 (residual mean-square error, RMSE) 定量评估角质层和乳头层提取的效果。指标的值越低, 说明算法提取到的轮廓和标注的轮廓越接近。本实验使用数据集, 采用 3 折交叉验证的方式, 即每次利用其中的 2 个 OCT 手指数据标注后的 B-scan 图像进行训练, 另一个手指标注后的 B-scan 图像进行验证。表 2 给出了结果。

表 2 轮廓准确性提取实验结果

方法	L'_{us}		L'_{ds}		L'_p	
	MSE	RMSE	MSE	RMSE	MSE	RMSE
文献 [11]	4.65	7.03	1.35	1.71	1.92	1.71
U-Net	2.47	3.70	1.14	1.51	1.56	1.51
深度可分离卷积 + U-Net	2.64	3.93	1.23	1.59	1.75	1.59

从表 2 可以看出, 相比于传统方法手工设计的特征, 神经网络的 2 种算法得到的结果更优。其中乳头层上表面轮廓指标平均提升了 1 倍, 这对内指纹的重建效果有着很大的帮助。角质层的上表面和下表面的指标也有了一定的提升, 这是因为提取角质层轮廓的任务比较简单, 容易提取准确。通过标准卷积组成的 U-Net 神经网络和深度可分离卷积组成的 U-Net 形成的神经网络得到的结果比较, 发现标准卷积组成的 U-Net 指标略好于深度可分离卷积组成的 U-Net 神经网络。说明相比于标准卷积, 深度可分离卷积会损失一定的准确率。图 7 显示了不同算法的提取效果。从图中可以看出, 文献[11]的算法容易误识汗腺组织, 同时对于乳头层轮廓的凹陷处不敏感。普通卷积组成的 U-Net 神经网络和深度可分离卷积组成的 U-Net 神经网络的效果基本一致。

2.4 内外指纹质量评估对比实验

由于 OCT 3 维数据最终得到的目标是手指的内指纹和外指纹, 因此本实验对不同提取轮廓算法得到的内外指纹进行质量评价。赵启军等人^[20]提出了利用方向确定性等级 (orientation certainly lev-

el, OCL) 可以有效地对高分辨率指纹进行评价。因此, 本实验采用 D_2 数据集, 分别用文献[11]的算法、标准卷积组成的 U-Net 神经网络和本文提出的深度可分离卷积组成的轻量级 U-Net 神经网络 3 种算法分别生成 OCT 的内指纹和外指纹。并利用平均方向确定性等级进行评价, 结果如表 3 所示。




图 7 不同方法轮廓提取结果比较

根据表 3 的结果发现, 利用深度可分离卷积的轻量级 U-Net 神经网络和标准卷积的 U-Net 神经网络

表 3 指纹质量评估实验结果

方法	OCL
文献[11]算法	0.2238
U-Net	0.1879
深度可分离卷积 + U-Net	0.1889

络效果均好于文献[11]提出的算法,表明了利用神经网络确实能提升生成内指纹和外指纹的质量,同时发现使用深度可分离卷积和普通卷积的 U-Net 神经网络的内外指纹质量评价结果基本相似。原因在于深度可分离卷积生成的 U-Net 神经网络虽然在提取角质层和乳头层的精度上劣于标准卷积生成的 U-Net 神经网络,但是也较准确学习到了轮廓的位置,尤其是轮廓凹陷和凸起的深度关系。这种凹陷和凸起的深度关系是生成外指纹和内指纹深度关系图的重要依据。本实验说明了深度可分离卷积生成的 U-Net 神经网络能够很好地生成 OCT 的内指纹和外指纹。图 8 显示了生成内指纹和外指纹的效果。




图 8 基于可分离卷积 U-Net 神经网络的指纹提取结果

2.5 运行参数量和速度比较实验

本实验对 2 种神经网络的计算量和计算时间进行讨论,实验采用 D_2 数据集比较标准卷积组成的 U-Net 神经网络和由深度可分离卷积组成的 U-Net 神经网络的网络参数量和计算时间。实验结果如表 4 所示。

表 4 神经网络计算时间实验结果

	参数量	单张 B-scan 时间(s)
卷积网络	4.9×10^6	0.254
深度可分离卷积网络	6.5×10^5	0.241

实验结果表明,由深度可分离卷积组成的 U-Net 神经网络与标准卷积组成的 U-Net 神经网络相比,在生成指纹质量相似的情况下,总体网络参数量缩小了 8 倍左右,计算时间也有所下降,证明了深度可分离卷积组成的 U-Net 神经网络的高效。

3 总 结

本文提出了一种基于深度可分离卷积的轻量级 U-Net 神经网络用于 OCT 指纹轮廓提取及内外指纹重建。相比现有算法,神经网络算法可以提高角质层和乳头层轮廓提取精度,尤其是乳头层轮廓的精度有了大幅提高。通过融合深度可分离卷积和 U-Net 神经网络,在生成指纹质量基本一致的情况下,模型参数量有了 8 倍左右的下降,有利于嵌入式平台的神经网络模型移植。

参考文献

[1] 尹义龙, 宁新宝, 张晓梅. 自动指纹识别技术的发展与应用[J]. 南京大学学报(自然科学), 2002, 38(1):29-35

[2] Larin K V, Cheng Y. Artificial fingerprint recognition by using optical coherence tomography with autocorrelation analysis[J]. *Applied Optics*, 2006, 45(36):9238-9245

[3] 李培, 杨姗姗, 丁志华, 等. 傅里叶域光学相干层析成像技术的研究进展[J]. 中国激光, 2017, 45(2):153-163

[4] 王金玉, 雷鸣, 尹韶云, 等. 宽光谱干涉显微术快速提取内指纹[J]. 光谱学与光谱分析, 2018, 38(1):26-30

[5] Sousedik C, Busch C. Quality of fingerprint scans captured using optical coherence tomography[C] // *Proceedings of the IEEE International Joint Conference on Biometrics*, Clear Water, USA, 2014: 1-8

[6] Bossen A, Lehmann R, Meier C. Internal fingerprint identification with optical coherence tomography [J]. *IEEE Photonics Technology Letters*, 2010, 22(7):507-509

[7] Raja K B, Auksoorius E, Raghavendra R, et al. Robust verification with subsurface fingerprint recognition using full field optical coherence tomography[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Honolulu, USA, 2017: 646-654

[8] Khutlang R, Khanyile N P, Makinana S, et al. High resolution feature extraction from optical coherence tomography acquired internal fingerprint[C] // *Proceedings of*

- the 17th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel Computing, Shanghai, China, 2016: 1-5
- [9] Khutlang R, Nelwamondo F V. Novelty detection-based internal fingerprint segmentation in optical coherence tomography images [C] // Proceedings of the IEEE 2nd International Symposium on Computing & Networking, Shizuoka, Japan, 2015: 556-559
- [10] Darlow L N, Connan J, Akhoury S S. Internal fingerprint zone detection in optical coherence tomography fingertip scans [J]. *Journal of Electronic Imaging*, 2015, 24(2): 1-14
- [11] Wang H X, Ma L T, Chen P. External and internal fingerprint extraction based on optical coherence tomography [C] // Proceedings of the International Society for Optical Engineering, Shanghai, China, 2018: 1-6
- [12] 张新明, 祝晓斌, 蔡强, 等. 图像语义分割深度学习模型综述 [J]. 高技术通讯, 2017, 27(9): 808-815
- [13] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2017, 39(4): 640-651
- [14] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation [C] // Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, Munich, Germany, 2015: 234-241
- [15] Buades A, Coll B, Morel J M. A non-local algorithm for image denoising [C] // Proceedings of the IEEE Computer Society Conference on Computer Vision & Pattern Recognition, San Diego, USA, 2005: 1-6
- [16] Chollet F. Xception: deep learning with depthwise separable convolutions [C] // Proceedings of the IEEE Conference on Computer Vision & Pattern Recognition, Honolulu, USA, 2016: 1800-1807
- [17] Howard A G, Zhu M, Chen B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications [J]. *arXiv:1704.04861*, 2017
- [18] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C] // Proceeding of International Conference on International Conference on Machine Learning, Lille, France, 2015: 448-456
- [19] Kingma D, Ba J. Adam: a method for stochastic optimization [J]. *arXiv:1412.6980*, 2014
- [20] Zhao Q, Liu F, Zhang L, et al. A comparative study on quality assessment of high resolution fingerprint images [C] // Proceedings of the IEEE International Conference on Image Processing, Hong Kong, China, 2010: 3089-3092

OCT internal and external fingerprints generation based on a lightweight U-Net neural network

Wang Haixia^{*}, Yang Xicheng^{**}, Liang Ronghua^{*}, Chen Peng^{*}

(^{*} College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310000)

(^{**} College of Information Engineering, Zhejiang University of Technology, Hangzhou 310000)

Abstract

Optical coherence tomography (OCT) is a non-destructive imaging technique which has been used to acquire high-resolution 3D data of fingertips from which contours of stratum corneum and papillary are extracted and subsequently internal and external fingerprints are generated. Since most current contour extraction methods are susceptible to sweat glands and subcutaneous tissues, the estimated stratum corneum and papillary contours may be deviated from its real location. In this paper, a self-built OCT system is used to obtain high-resolution 3D fingertip data and a lightweight U-Net neural network based on depth separable convolution is proposed to accurately extract the stratum corneum and papillary contours. The depth information of these contours are then used to generate internal and external fingerprints. The experimental results show that the proposed method can accurately extract internal and external fingerprints. Compared to the original U-Net neural network, the proposed lightweight U-Net greatly reduces the number of model parameters while obtaining similar fingerprint generation results.

Key words: optical coherence tomography (OCT), internal fingerprint, external fingerprint, depth-wise separable convolution, U-Net