

基于 CNN 和改进的图搜索分割 OCT 图像中的视网膜层

唐艳红, 陈允照, 刘明迪, 曾亚光, 周月霞*

佛山科学技术学院物理与光电工程学院, 广东 佛山 528200

摘要 提出一种结合卷积神经网络(CNN)和改进的图搜索来分割光学相干断层扫描成像(OCT)图像中的 7 个视网膜层边界的方法。首先利用 CNN 自动提取每个边界的特征并训练相应的分类器,由此将获得的每个边界的概率图作为分割的感兴趣区域;其次,提出一种改进的图搜索方法,该方法在垂直梯度的基础上添加了横向约束,当遇到血管阴影时,分割线可以横向穿过阴影。使用所提方法对正常图像进行分割,并对得到的结果和图搜索方法、基于 CNN 的方法得到的结果进行比较。实验结果表明,所提方法能精确分割 7 个视网膜层边界,平均层边界误差为 $(4.31 \pm 5.87) \mu\text{m}$ 。

关键词 医用光学; 光学相干断层扫描; 视网膜分割; 卷积神经网络; 改进的图搜索

中图分类号 O438

文献标志码 A

doi: 10.3788/LOP57.241702

Segmentation of Retinal Layers in OCT Images Based on CNN and Improved Graph Search

Tang Yanhong, Chen Yunzhao, Liu Mingdi, Zeng Yaguang, Zhou Yuexia*

School of Physics and Optoelectronic Engineering, Foshan University, Foshan, Guangdong 528200, China

Abstract Herein, a method that combines convolutional neural networks (CNNs) and improved graph search is proposed to segment seven retinal-layer boundaries in optical coherence tomography (OCT) images. First, CNN is used to extract the features of each boundary automatically and to train the corresponding classifier to obtain the probability map of each boundary as the region of interest for boundary segmentation. Second, an improved graph search method is proposed to add lateral constraints based on the vertical gradient. When encountering a vascular shadow, the segmentation line can laterally cross the shadow. The normal image is segmented using the proposed method, and the results are compared with those obtained using the graph search method and the method based on CNN. Experimental results show that the proposed method can accurately segment seven retinal-layer boundaries with an average layer boundary error of $(4.31 \pm 5.87) \mu\text{m}$.

Key words medical optics; optical coherence tomography; retinal segmentation; convolutional neural network; improved graph search

OCIS codes 170.0110; 110.4500; 100.6950; 100.4996

1 引言

光学相干层析成像(OCT)是一种利用低相干干涉光对生物组织进行断层扫描的成像技术^[1]。由于其具有高检测灵敏度、高分辨率及体内无创性等

优点,因此在临床医疗领域具有重要的应用价值^[2-4]。近年来,视网膜 OCT 已经被广泛用来表征正常视网膜及其各个层,检测和监测年龄相关性黄斑变性(AMD)、青光眼和糖尿病性视网膜病变等眼部疾病^[5]。为了更好地了解相关疾病对视网膜中特

收稿日期: 2020-06-01; 修回日期: 2020-06-29; 录用日期: 2020-07-03

基金项目: 国家自然科学基金(61605026, 61771139, 81601534, 61705036, 61805038)、广东省自然科学基金(2017A030313386)、佛山科学技术学院高层次建设与科研项目(CGG07141)、佛山科学技术学院高层次人才科研启动项目(gg040988)、国家级大学生创新创业训练计划(202011847014)、广东大学生科技创新培育专项资金(pdjh2019b0508)

*E-mail: 19714213@qq.com

定类型细胞的影响,准确分割视网膜 OCT 图像中的不同组织层至关重要。

由于人工分割视网膜层边界时费时、易出错,所以开发可靠的 OCT 图像自动分割方法一直是众多人员研究的重点。现有的视网膜层边界分割方法可大致分为两类。1) 图搜索的方法。如 Chiu 等^[6]提出一种基于图论和动态规划的方法,该方法利用最短路径算法 Dijkstra 对 7 个视网膜层进行分割;Chen 等^[7]提出一种基于曲线平滑约束的改进二维图搜索方法,该方法实现脉络膜-巩膜界面(CSI)分割。这些图搜索算法大多基于图像强度和梯度来提取边界,能够实现简单、快捷的视网膜图像分层,也是其他视网膜图像技术研究中提取边界的首选算法^[8]。但视网膜图像中的噪声和血管阴影区域容易对视网膜分割带来挑战。为了提高精确度,牛四杰等^[9]提出一种多尺度三维图搜索方法,Guo 等^[10]在提出的双向图搜索中对梯度进行增强,结果证明,研究改进的垂直梯度法(如梯度增强、添加约束条件)是有必要的。此外,图搜索方法受到图像本身视网膜层厚度的先验知识约束,但是由于每个人的视网膜层厚度或特征不同,因此利用同一组规则分割其他人的数据时可能会分割错误。2) 机器学习的方法。机器学习方法包括传统的机器学习方法(如支持向量机^[11]、随机森林^[12-13])和近几年快速发展的深度学习方法^[5,14-16]。该类方法的模式是将视网膜层分割描述为一个分类问题,从每一层或其边界中提取特征,并将其用于训练分类器以确定层边界。通过对多组眼底视网膜数据进行训练,能增强模型对临床图像中各类视网膜图像预测的泛化能力,因此,机器学习方法已成为一系列视网膜 OCT 图像分析应用的有用工具。传统的机器学习方法需要人工提取特征,近几年来,深度学习方法

通过网络模型自主学习图像特征和分类器,给视网膜边界提取提供了新思路,但在分割边缘这种精度较高的情况下,往往因为训练集的不足而无法精确分割。

本文提出一种结合卷积神经网络(CNN)和改进的图搜索的分割方法。首先利用 CNN 提取每个边界的特征并训练相应的分类器,经过训练的 CNN 分类器为层边界生成类标签和概率图,获取每个边界的大概位置。所提方法不受视网膜层厚度的约束限制,而是通过图像和标签自主学习边界处的有效特征。由此将获得每个边界的概率图作为分割的感兴趣区域,其次利用图像的横向和纵向特征创建用于分割的权重矩阵,以降低视网膜分割对血管阴影的敏感性,最后结合感兴趣区域和权重矩阵,采用最短路径快速算法(SPPA)获得视网膜层边界。实验结果表明,所提方法可以正确分割视网膜层边界。

2 相关理论

2.1 卷积神经网络

CNN^[17]使用一系列转换层从输入图像中提取和分类特征。常用的 CNN 结构包括卷积层、池化层、全连接层、Softmax 分类层,如图 1 所示。当一张图像进入 CNN 时,先通过多组卷积层和池化层自动提取图像特征,并依靠最后的全连接层进行降维和类别匹配,最后根据提取的特征进行分类。在模型训练过程中,每一训练批次后通常对分类结果与人工标签结果进行比较,并计算两者之间的差异作为反馈,最后使用梯度下降算法进行反向传播,逐层更新各个层中的所有权值。除了上述 4 种基本层之外,其他常用的层还包括修正线性单元(ReLU)层和归一化层。




图 1 CNN 基本结构

Fig.1 Basic structure of CNN

2.2 图搜索分割

图搜索分割方法^[6]将 B 扫描中每个像素视为一个节点,将每个 B 扫描视为一个节点图,然后根据垂直梯度设定节点之间的权重。节点 a 和 b 之间的权重函数为

$$w_{ab} = 2 - (g_a + g_b) + w_{\min}, \quad (1)$$

式中: g_a 和 g_b 分别为节点 a 和节点 b 处的垂直梯度; w_{\min} 是为算法稳定添加的一个最小正数,设定为 10^{-5} 。

然后,初始化开始节点和结束节点(图像的左上角和右下角),选取每个节点的 8 邻域节点作为候选节点,并采用 Dijkstra 算法找到所有可访问路径中的最短路径,通过先确定内界膜(ILM)和光感受器内节/外节(IS-OS)来逐步限制搜索区域,分割各个视网膜层边界。

2.3 SPFA

SPFA 是一种应用于有向图的算法,目的是求出从源点 s 到其他点的单源最短路径。相对于 Dijkstra 算法来说,SPFA 的复杂度更低、速度更快。

SPFA 具体的算法步骤为

- 1) 设置“先进先出”队列,保存需要优化的节点;
- 2) 从队列中取出第一个节点,然后释放下一个节点;
- 3) 新点放在“先进先出”队列的尾部;
- 4) 重复步骤 2) 和 3),直到队列为空。

3 方 法

所提方法旨在识别 7 个层边界:ILM、神经纤维层/神经节细胞层(NFL-GCL)、内丛状层/内核层(IPL-INL)、内核层/外丛状层(INL-OPL)、外丛状层/外核层(OPL-ONL)、IS-OS、玻璃膜(BM)。图 2 为视网膜分割方法的流程图。首先对 OCT 图像进行预处理;其次利用 CNN 提取每个边界的特征块并训练相应的分类器,由此获得 7 个边界的概率图并将其作为分割的感兴趣区域;最后,利用图像梯度创建用于分割的权重矩阵,并结合感兴趣区域和权重矩阵,采用 SPFA 分割得到视网膜层边界。

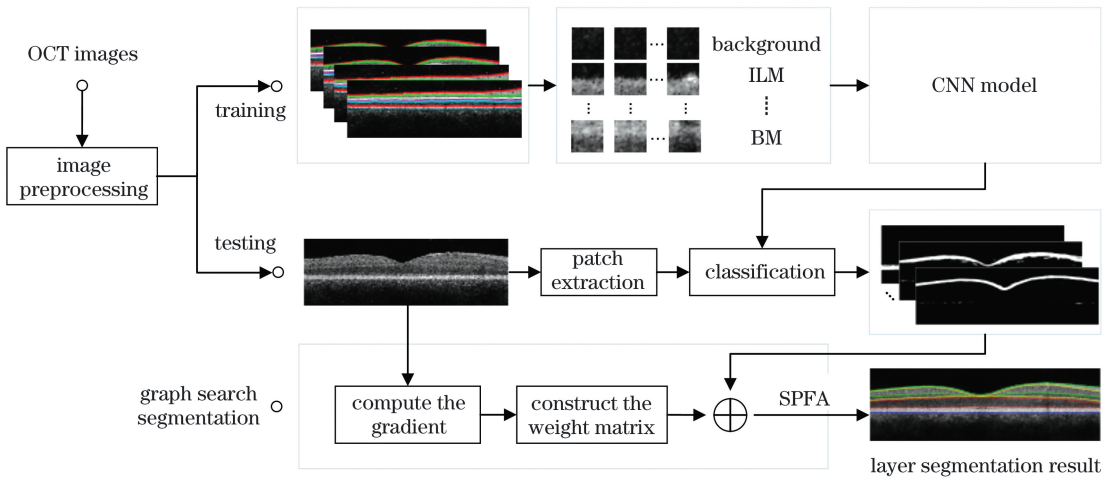


图 2 所提方法流程

Fig. 2 Flow chart of proposed method

3.1 图像预处理

由于 OCT 中测量的干扰信号的有限空间频率带宽引起的斑点噪声会极大地干扰图像的对比度,因此对图像进行自适应加权双边滤波处理^[18]。该滤波器已被证明可以有效地对视网膜图像进行去噪,并保持视网膜层的纹理信息。然后,以 BM 边界为基准将视网膜压平^[12]。最后,对图像进行强度归一化处理,将图像强度值范围调整至 $[0, 1]$,表达式为

$$I = (I_x - I_{\min}) / (I_{\max} - I_{\min}), \quad (2)$$

式中: I 为归一化后的图像; I_x 为图像中每个像素点强度值; I_{\min} 为图像中最小的强度值; I_{\max} 为图像

中最大的强度值。

3.2 CNN 层边界分类

3.2.1 CNN 结构设计

将由 Hamwood 等^[16]在 2018 年提出的一个网络架构(Complex-CNN)用于训练和测试 CNN 模型。Complex-CNN 的结构和参数(卷积核的大小和个数)如图 3 所示,其他设定为卷积过程 stride 为 1, padding 为 0,池化过程 stride 为 2, padding 为 1。该网络以 Fang 等^[5]使用的 CFAR-CNN 为基准,通过增加图像块大小和删除一些池化层来得到一个更复杂的 CNN。采用 Complex-CNN 模型的默认

参数,并使用大小为 65×65 的图像块进行训练和测试。在构建模型时,Hamwood 等^[16]已经调整了这

些参数,为了完整性,这里测试了其他参数,但是没有得到比使用默认参数更好的结果。




图3 Complex-CNN 结构

Fig.3 Complex-CNN structure

采用大小为 65×65 的图像块,使边界居于图像块的中心,可以精确视网膜层定位,采用大的块虽然会增加训练成本,但能有效提高特定层的性能。以前的研究表明,CNN 在使用较大的图像块时可以提高分类精度,这是因为在卷积学习过程中,CNN 可以更好地捕获标签之间特定的位置关系,以提高对视网膜层边界定位的精度。

3.2.2 视网膜层边界分类

训练设计的 CNN 来提取特定视网膜层边界的特征,并对视网膜图像上的 7 个层边界进行分类,主要包括训练和测试两个部分。

在训练部分中,将标签“1”~“7”人为地分配到

ILM 到 BM 层边界上。任何不在视网膜层边界位置的像素,都会被指定标签为“0”。首先在视网膜标签图上提取以 7 个人工分割的视网膜层边界上的每个像素并将其作为中心的小块(大小为 65×65 个像素),这些小块用来构建正训练样本;接着,随机提取不在层边界位置(例如背景区域、层结构区域)的部分像素点,并将其作为中心点的小块(大小为 65×65 个像素),这些小块用来构建负训练样本。将正、负训练样本小块输入到 CNN 中进行训练,得到对视网膜层边界位置进行定位的 CNN 分类模型。图 4 为训练和验证过程中的准确率和损失曲线图,可看出,网络模型完全收敛。

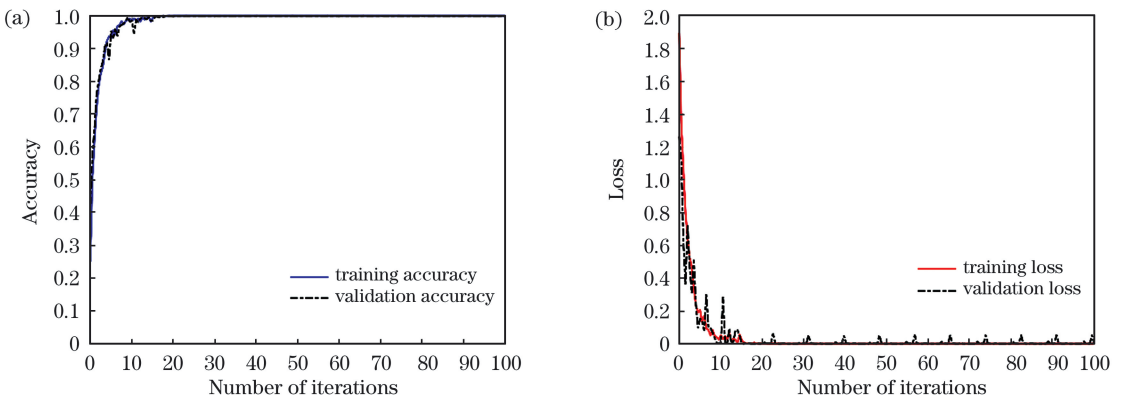


图4 训练和验证过程中的准确率和损失。(a)准确率;(b)损失

Fig. 4 Accuracy and loss during training process and validation process. (a) Accuracy; (b) loss

在测试部分,提取以测试 OCT 图像的每个像素为中心的 patch(块大小为 65×65 个像素);之后,将所有 patch 输入到训练好的 CNN 模型中,每个 patch 输出一个类标签和 8 个概率(分别对应背景区域和 7 个层边界),输出标签和概率对应于从全尺寸图像中获取的 patch 的中心像素;最后,将 patch 拼回原测试图大小,得到每个边界的概率图。

3.3 图搜索分割 7 个视网膜层边界

图搜索分割中,提出一种改进的图搜索方法,

该方法在图像垂直梯度的基础上添加了横向约束,当遇到血管阴影时,分割线可以横向穿过阴影,提高分割准确度。

将测试图像看作一个节点图,将每个像素与其单向 5 个邻域像素构成邻域矩阵,每个点与邻域点之间设置对应的权值,以构建一个权重矩阵。首先,由于视网膜层边界信息属于边缘信息,是层暗到亮、亮到暗的分界线。因此,将 y 方向像素强度值的梯度变化信息作为权重指标之一,再对图像求

取垂直梯度,表达式^[10]为

$$\begin{cases} G(x,y) = I(x,y) - I(x,y-1) \\ x = 1, 2, 3, \dots, m, \quad y = 1, 2, 3, \dots, n \\ G_A(x,y) = \begin{cases} 1 - G(x,y), & G(x,y) > 0 \\ 1, & G(x,y) \leq 0 \end{cases} \\ G_B(x,y) = \begin{cases} 1 + G(x,y), & G(x,y) < 0 \\ 1, & G(x,y) \geq 0 \end{cases} \end{cases} \quad (3)$$

式中: $I(x,y)$ 为位置 (x,y) 处的像素强度值; m 为图像沿 x 方向的像素个数; n 为图像沿 y 方向的像素个数。这将得到暗到亮、亮到暗边界两个不同的梯度图,再对其进行伽马变换以强化边界像素,最终的梯度图如图 5 所示。




图 5 梯度图。(a)暗到亮梯度图,用于构建分割 ILM, INL-OPL, IS-OS 的权重矩阵;(b)亮到暗梯度图,用于构建分割 NFL-GCL, IPL-INL, OPL-ONL, BM 的权重矩阵

Fig. 5 Gradient map. (a) Dark to light gradient map, used to construct the weight matrix for segmenting ILM, INL-OPL, IS-OS; (b) light to dark gradient map, used to construct the weight matrix for segmenting NFL-GCL, IPL-INL, OPL-ONL, BM




图 6 中央凹区域 OCT 视网膜图像分割结果对比。(a)手工绘制结果;(b)图搜索方法;(c)基于 CNN 的方法;(d)所提方法
Fig. 6 Comparison of OCT retinal image segmentation results in fovea area. (a) Manually drawn result; (b) graph search method; (c) method based on CNN; (d) proposed method

从图 6 可以看出:图搜索方法在 part 1、part 2 位置出现了明显的分割错误,这是由这些位置边界与边界之间相隔的像素太少,感兴趣区域的限制范围不精准造成的;而所提方法能够正确地分割视网

血管阴影会对视网膜的分割带来挑战,当仅将垂直特征用于分割时,可能无法正确找到边界,因此增加横向约束。根据压平后的图像,节点与节点之间沿 y 方向的坐标变化值不会相差太大,因此结合梯度变化值与沿 y 方向的坐标变化值,定义每个像素与其 5 个邻域点之间的权值,获得用于分割的暗到亮和亮到暗的权重矩阵,权重函数表达式为

$$w_{ab} = 0.8 \times (g_a + g_b) + 0.2 \times s_{ab} + w_{\min}, \quad (4)$$

式中: s_{ab} 为节点 a 和节点 b 沿 y 方向的坐标变化绝对值。

最后,将获得的每个层边界概率图作为图搜索感兴趣区域。在对应搜索区域中,结合权重矩阵,采用 SPFA 找到一条最短路径,该路径即对应视网膜层边界。

4 实验结果及分析

4.1 数据集和实验环境

本研究中采集了 10 个 3D-OCT 视网膜数据,使用的所有实验数据都是通过 Topcon 眼底断层扫描系统 3D OCT-1 获得的。以黄斑为中心的 $6 \text{ mm} \times 6 \text{ mm}$ 区域为扫描区域,扫描深度为 2.3 mm 。每个体积包含 128 个 B 扫描,每个 B 扫描得到的图片是一个视网膜切片,分辨率为 784×1024 。算法采用 MATLAB 编程实现,电脑配备环境为 Inter(R) Core (TM) i7-7700 CPU @3.60GHZ, 16GB RAM。

4.2 定性分析

为了更加直观地呈现算法的有效性,图 6、7 为所提方法和其他方法对正常成人眼睛进行分割得到的具有代表性的分割结果,方框代表分割错误的位置。

膜层边界。

从图 7 可以看出:图搜索方法在 part 4 位置处有明显的分割错误,这是因为在含血管阴影的图像中,图搜索方法中限定的感兴趣区域较宽,且阴影

区域缺少梯度,导致在使用最短路径算法时,图搜索方法会绕开血管阴影;而所提方法能够很好地限

制被血管阴影影响的边界的感兴趣区域,能够正确地分割视网膜层边界,在分割结果上更优。




图7 含血管阴影的OCT视网膜图像分割结果对比。(a)手工绘制结果;(b)图搜索方法;(c)基于CNN的方法;(d)所提方法

Fig. 7 Comparison of OCT retinal image segmentation results with vascular shadow. (a) Manually drawn result; (b) graph search method; (c) method based on CNN; (d) proposed method

4.3 定量分析

为了定量评估7个视网膜层边界的分割效果,对算法的分割结果与由专家手工绘制的视网膜分割结果进行比较。使用平均绝对误差(MAE)和方均根误差(RMSE)来验证算法的准确性。它们的表达式分别为

$$E_{MA}(X, h) = \frac{1}{L} \sum_{i=1}^L |h_i - X_i|, \quad (5)$$

$$E_{RMS}(X, h) = \sqrt{\frac{1}{L} \sum_{i=1}^L (h_i - X_i)^2}, \quad (6)$$

式中: X 为算法分割结果的轴向值数组; h 为人工分割结果的轴向值数组; L 为数组长度。MAE值

与RMSE值越小,代表算法结果与标准值(人工分割结果)差异越小。

从体积扫描中随机选择4个B扫描,对于每个B扫描,分别用三种方法(图搜索方法、基于CNN的方法、所提方法)分割视网膜边界。对不同方法的分割结果与人工分割结果进行比较,分割性能如表1所示。可以看到,在BM边界中,所提方法的RMSE比图搜索方法稍大一点,但均属于较小的误差,可以认为在正常的误差范围内。总体来说,所提方法对视网膜分割平均层边界的误差为 (1.47 ± 2) pixel,实际误差为 $(4.31 \pm 5.87) \mu\text{m}$,优于其他方法。

表1 不同方法的MAE和RMSE

Table 1 MAE and RMSE of different methods

Boundary	Graph search method		Method based on CNN		Proposed method	
	MAE/pixel	RMSE/pixel	MAE/pixel	RMSE/pixel	MAE/pixel	RMSE/pixel
ILM	0.9	1.4	1.4	1.8	0.8	0.7
NFL-GCL	4.3	6.7	3.9	3.3	1.4	1.8
IPL-INL	4.7	6.4	3.7	3.7	1.5	2.4
INL-OPL	4.4	7.3	3.5	6.8	1.3	2.1
OPL-ONL	5.5	11.4	3.8	10.6	2.1	3.6
IS-OS	1.3	3.4	1.0	1.3	0.8	0.9
BM	2.5	2.1	2.6	2.7	2.4	2.5

5 讨论

从结果分析中可以看出,所提方法能有效提高分割精度,更贴切人工分割的结果。所提方法的优势在于:使用CNN方法时可以有效定位OCT图像中的层边界位置,相比于图搜索方法,所提方法不

受视网膜层厚度的约束限制,可以根据提供的训练数据学习边界处的有效特征来制定自己的规则,且获得的每个边界的概率图是相互独立的,有效提高了感兴趣区域定位的准确度;提出了一种改进的图搜索方法,在图像垂直梯度的基础上添加了横向约束,当遇到血管阴影时,分割线可以横向穿过阴影,

有效提高了对血管阴影区域的分割准确性。

所提方法也存在一定的局限性:首先,CNN 尽管很容易适用于更广泛的群组,但受到模型数据集的约束,在不同的视网膜图像中很难直接进行精细分割,因而更适用于对边界进行定位;其次,本文数据集中未加入病状视网膜数据集,所以所提方法只适用于正常的视网膜分割。未来的工作是将进一步完善分层方法并将其应用于病状视网膜数据的分析中。

6 结 论

提出了一种对 OCT 视网膜图像进行精准分层的方法,该方法利用 CNN 进行层边界定位,使用改进的图搜索方法完成分层。对所提方法、图搜索方法、基于 CNN 的方法的分割结果进行对比,结果表明,所提方法的分割效果更优。综上,所提方法为 OCT 视网膜图像的视网膜层边界分割提供了一种新的方法,并为后期的临床诊断提供了一个高精度的定量参考。

参 考 文 献

- [1] Huang D, Swanson E A, Lin C P, et al. Optical coherence tomography [J]. *Science*, 1991, 254 (5035): 1178-1181.
- [2] Yazdanpanah A, Hamarneh G, Smith B, et al. Intra-retinal layer segmentation in optical coherence tomography using an active contour approach [J]. *Medical Image Computing and Computer-Assisted Intervention*, 2009, 12: 649-656.
- [3] Luo S T, Fan Y W, Chang W, et al. Boundary region of stomach mucinous carcinoma with swept source optical coherence tomography[J]. *Acta Optica Sinica*, 2018, 38(5): 0517001.
罗斯特, 范应威, 常玮, 等. 扫频光学相干层析成像应用于判断黏液型胃癌边界区域[J]. *光学学报*, 2018, 38(5): 0517001.
- [4] Li P, Yang S S, Ding Z H, et al. Research progress in Fourier domain optical coherence tomography[J]. *Chinese Journal of Lasers*, 2018, 45(2): 0207011.
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*, 2018, 45(2): 0207011.
- [5] Fang L, Cunefare D, Wang C, et al. Automatic segmentation of nine retinal layer boundaries in OCT images of non-exudative AMD patients using deep learning and graph search [J]. *Biomedical Optics Express*, 2017, 8(5): 2732-2744.
- [6] Chiu S J, Li X T, Nicholas P, et al. Automatic segmentation of seven retinal layers in SDOCT images congruent with expert manual segmentation [J]. *Optics Express*, 2010, 18(18): 19413-19428.
- [7] Chen Q, Fan W, Niu S J, et al. Automated choroid segmentation based on gradual intensity distance in HD-OCT images[J]. *Optics Express*, 2015, 23(7): 8974-8994.
- [8] Wang Q, Peng H L, Wang P H, et al. Dither removing of three-dimensional optical coherence tomography retinal image [J]. *Acta Optica Sinica*, 2019, 39(3): 0317001.
汪权, 朋汉林, 汪平河, 等. 光学相干层析成像眼底视网膜三维图像去抖动方法[J]. *光学学报*, 2019, 39(3): 0317001.
- [9] Niu S J, Chen Q, Lu S T, et al. SD-OCT image layer segmentation using multi-scale 3-D graph search method [J]. *Computer Science*, 2015, 42 (9): 272-277.
牛四杰, 陈强, 陆圣陶, 等. 应用多尺度三维图搜索的 SD-OCT 图像层分割方法[J]. *计算机科学*, 2015, 42(9): 272-277.
- [10] Guo Y K, Camino A, Zhang M, et al. Automated segmentation of retinal layer boundaries and capillary plexuses in wide-field optical coherence tomographic angiography[J]. *Biomedical Optics Express*, 2018, 9 (9): 4429-4442.
- [11] Zawadzki R J, Fuller A R, Wiley D F, et al. Adaptation of a support vector machine algorithm for segmentation and visualization of retinal structures in volumetric optical coherence tomography data sets [J]. *Journal of Biomedical Optics*, 2007, 12 (4): 041206.
- [12] Lang A, Carass A, Hauser M, et al. Retinal layer segmentation of macular OCT images using boundary classification[J]. *Biomedical Optics Express*, 2013, 4(7): 1133-1152.
- [13] Chen Q, Xu J, Niu S J. Retinal nerve fiber layer segmentation of spectral domain optical coherence tomography images based on random forest [J]. *Journal of Electronics & Information Technology*, 2017, 39(5): 1101-1108.
陈强, 徐军, 牛四杰. 基于随机森林的频谱域光学相干层析技术的图像视网膜神经纤维层分割[J]. *电子与信息学报*, 2017, 39(5): 1101-1108.
- [14] Kugelman J, Alonso-Caneiro D, Read S A, et al. Automatic segmentation of OCT retinal boundaries

- using recurrent neural networks and graph search[J]. *Biomedical Optics Express*, 2018, 9(11): 5759-5777.
- [15] Liu X M, Cao J, Fu T, et al. Semi-supervised automatic segmentation of layer and fluid region in retinal optical coherence tomography images using adversarial learning [J]. *IEEE Access*, 2019, 7: 3046-3061.
- [16] Hamwood J, Alonso-Caneiro D, Read S A, et al. Effect of patch size and network architecture on a convolutional neural network approach for automatic segmentation of OCT retinal layers [J]. *Biomedical Optics Express*, 2018, 9(7): 3049-3066.
- [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] Anantrasirichai N, Nicholson L, Morgan J E, et al. Adaptive-weighted bilateral filtering and other pre-processing techniques for optical coherence tomography [J]. *Computerized Medical Imaging and Graphics*, 2014, 38(6): 526-539.