

基于机器学习的可降解支架检测与分割算法

鲁逸峰^{1,2}, 金琴花³, 荆晶³, 陈韵岱³, 曹一挥¹, 李嘉男¹, 朱锐¹

¹中国科学院西安光学精密机械研究所瞬态光学与光子技术国家重点实验室, 陕西 西安 710000;

²中国科学院大学, 北京 100049;

³中国人民解放军总医院心血管内科, 北京 100853

摘要 针对血管内光学相干断层扫描(IVOCT)成像系统,提出一种改进的自适应增强(Adaboost)算法及一种基于动态规划的轮廓分割算法用于可降解支架的自动检测与分割,实现对支架贴壁情况的自动评估。在检测阶段,利用多层决策树构建 Adaboost 分类器,实现对支架位置和大小检测;基于检测结果,利用动态规划算法对支架轮廓进行分割;最后,结合分割结果,对支架贴壁情况进行计算。实验结果显示,所提算法的检测召回率达到 91.6%,精确率为 87.2%,轮廓分割的平均 Dice 系数为 0.80,表明所提算法能够实现 IVOCT 影像中可降解支架的准确检测与分割,且具有较好的稳健性。

关键词 机器视觉;自动检测与分割;自适应增强算法;可降解支架;血管内光学相干断层扫描图像

中图分类号 TP391.7

文献标识码 A

doi: 10.3788/AOS201838.0215005

Detection and Segmentation Algorithm for Bioresorbable Vascular Scaffolds Struts Based on Machine Learning

Lu Yifeng^{1,2}, Jin Qinhu³, Jing Jing³, Chen Yundai³, Cao Yihui¹, Li Jianan¹, Zhu Rui¹

¹State Key Laboratory of Transient Optics and Photonics, Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences, Xi'an, Shaanxi 710000, China;

²University of Chinese Academy of Sciences, Beijing 100049, China;

³Department of Cardiology, Chinese PLA General Hospital, Beijing 100853, China

Abstract An improved Adaboost algorithm, together with a profile segmentation method based on dynamic programming (DP), is proposed for automatic detection and segmentation of bioresorbable vascular scaffold (BVS) in intravascular optical coherence tomography (IVOCT) imaging system, to achieve auto estimation on the strut malapposition. During detection, the multi-layer decision tree is applied to the construction of Adaboost classifier, in order to detect the position and size of each strut. Then, the DP algorithm is adopted to segment the struts' boundaries based on detection results. Finally, combined with the segmentation results, struts malapposition is calculated. Experimental results show that our method reaches the detection recall rate of 91.6% with the precision of 87.3%, and the average Dice coefficient of segmentation is 0.80. It suggests that our method can accurately achieve the detection and the segmentation of BVS struts in IVOCT images, and has high robustness.

Key words machine vision; automatic detection and segmentation; Adaboost algorithm; bioresorbable vascular scaffold; intravascular optical coherence tomography image

OCIS codes 150.1135; 100.2960; 100.6950

1 引言

支架植入术是目前治疗心血管疾病最常用也是

最可靠的方法之一。相比传统的金属支架,可降解支架(BVS)可显著降低晚期支架血栓的风险^[1],因而成为目前支架植入术中使用较多的支架类型。然

收稿日期: 2017-08-29; 收到修改稿日期: 2017-10-09

基金项目: 中国科学院科技服务网络计划(KFJ-SW-STS-185)

作者简介: 鲁逸峰(1992—),男,硕士研究生,主要从事图像处理方面的研究。E-mail: fenglinwan@163.com

导师简介: 朱锐(1983—),男,博士,副研究员,硕士生导师,主要从事生物医学光子学与光学相干断层扫描技术方面的研究。E-mail: rzhu@vivo-light.com (通信联系人)

而,由于 BVS 支架在 X 光造影环境下是不可见的,如果医生在手术中操作不当,往往会引起支架贴壁不良,大大提高了急性血管再狭窄和晚期支架血栓的风险。因此,在 BVS 支架植入术中,需要实时检测支架的贴壁情况。

血管内光学相干断层扫描技术(IVOCT)是目前较为主流的血管内成像方式。在成像阶段,系统样品臂通过导管等元件制成的探头进入血管对血管壁进行成像^[2],利用低相干干涉和光外差探测原理,探测生物组织内部不同深度层面对入射光的后向散射光强度,获得组织内部微结构特征^[3]。IVOCT 利用近红外线及光学干涉,其分辨率比血管内超声等传统成像方式高出一个数量级,轴向分辨率达 5~15 μm ,纵向分辨率达 25 μm ,探测深度约为 2 mm。因此,可通过 IVOCT 对 BVS 支架精确成像,实现对支架贴壁情况的分析^[4]。

为了评估支架的贴壁情况,需要准确检测和分割出 IVOCT 图像中的 BVS 支架,并定量计算支架与血管壁之间的距离。调研结果显示,目前针对 BVS 支架的自动检测及分割研究极少。Xu 等^[5]提出了一种基于脊线的检测算法,通过将二阶算子作为脊线检测器,计算每个像素点黑塞矩阵的特征值,由于支架的脊线结构,其所在区域的黑塞矩阵特征值会呈现出特定的分布,通过设定阈值便可将支架区域检测出来。然而该方法主要应用于金属支架的检测,利用的是金属支架的局部特征,难以推广至复杂背景下的 BVS 支架自动检测。Wang 等^[6]提出了一种基于灰度特性曲线的自动检测算法,主要利

用 BVS 支架的灰度和梯度特性,通过设定阈值对灰度特性曲线中波峰波谷的顶点、坡度及宽度进行界定,从而检测 BVS 支架。然而,由于不同病人的 IVOCT 图像的亮度和对比度存在很大差异,并且血管中可能存在一些血液伪影,利用固定阈值进行自动检测的方法存在较大的局限性,难以推广至各类情况。

针对上述方法的局限性,提出了一种基于机器学习的 BVS 支架自动检测算法,基于多层决策树模型,利用 Adaboost 算法训练级联检测器,并将其用于 IVOCT 图像中 BVS 支架的自动检测,从而得到一系列局部感兴趣区域(ROI)。接着在各 ROI 内部,利用动态规划算法^[7]进行支架轮廓的自动分割。最后,基于分割结果,定量计算支架与血管壁之间的最短距离,从而实现支架贴壁情况的自动分析。为了客观评价所提方法的性能,将专家手动标记的结果与所提方法自动检测和分割的结果进行对比,实验结果表明,所提方法能够准确检测与分割复杂背景下的 BVS 支架,并且具有较快的检测速度、较好的稳健性和可推广性。

2 算 法

BVS 支架贴壁分析流程图如图 1 所示,算法主要包含 3 步:1) 支架检测,主要用于检测 BVS 支架的位置和尺寸,并形成局部 ROI;2) 支架分割,在每个局部 ROI 内部对支架边缘进行准确分割;3) 贴壁分析,结合分割结果,对支架贴壁情况进行自动分析。下面对各步骤进行详细介绍。




图 1 BVS 支架贴壁分析流程图(第一幅图中的局部放大图显示了其中一个 BVS 支架的结构)

Fig. 1 Workflow of BVS strut malapposition analysis (Local enlarged drawing in the first image shows structure of one of the BVS struts)

2.1 支架检测

采用并改造机器学习方法,并对支架的位置和尺寸进行检测。过程主要分两步:特征提取和分类器训练。其中分类器训练在第 2.1.2 节至第 2.1.4 节中进行详细介绍。

2.1.1 特征提取

提取训练样本的 Haar 特征用于分类器模型训

练。Haar 特征最初由 Viola 等^[8]引入目标检测领域,其计算方法主要基于区域像素和,基本思路是计算一个特征模板内各个指定区域的像素和之差,并在不同尺度对特征模板进行放大,同时逐步平移模板,重复上述计算,直至完成所有特征模板的计算。

然而,由于特征模板的尺度及位置变化范围很大,一幅图像内的 Haar 特征数量往往十分巨大,

因此要在原始图像中计算所有 Haar 特征是极其费时的。考虑到 Haar 特征是基于区域像素和进行计算的,因此采用预先计算图像积分图的方式减小 Haar 特征的计算量。积分图的大小与原图相同,积分图中某一点 (x, y) 的值 $I'(x, y)$ 可通过对该点在原图 $I(x, y)$ 中左上角区域所有像素点的灰度值求和得到,即

$$I'(x, y) = \sum_{x'=1}^x \sum_{y'=1}^y I(x', y')。 \quad (1)$$

在得到积分图后,任意一个矩形区域 $D(x_1, y_1, x_2, y_2)$ 内的像素和为

$$D(x_1, y_1, x_2, y_2) = I'(x_1, y_1) + I'(x_2, y_2) - I'(x_1, y_2) - I'(x_2, y_1), \quad (2)$$

式中点 (x_1, y_1) 、 (x_2, y_2) 、 (x_1, y_2) 、 (x_2, y_1) 分别为矩形区域 D 的4个顶点。基于图像积分图,只需查询4个点的值,便能计算一个矩形区域内的像素和。这样,只需遍历一次原始图像,便能得到整幅图的积分图,对于任意 Haar 特征,都能通过对积分图的几次查询得到其特征值,从而极大地减小了计算量。

2.1.2 分类器训练

采用 Adaboost 算法对训练样本进行学习,从而挑选出最具分辨能力的 Haar 特征构成分类器。Adaboost 算法最初由 Freund 等^[9]提出,并被 Viola 等^[8]成功运用于人脸检测领域。其基本思想是通过对不同弱分类器的组合构建一个强分类器,从而极大地提升分类器的分类能力。

最简单的弱分类器是一个决策树桩,定义为

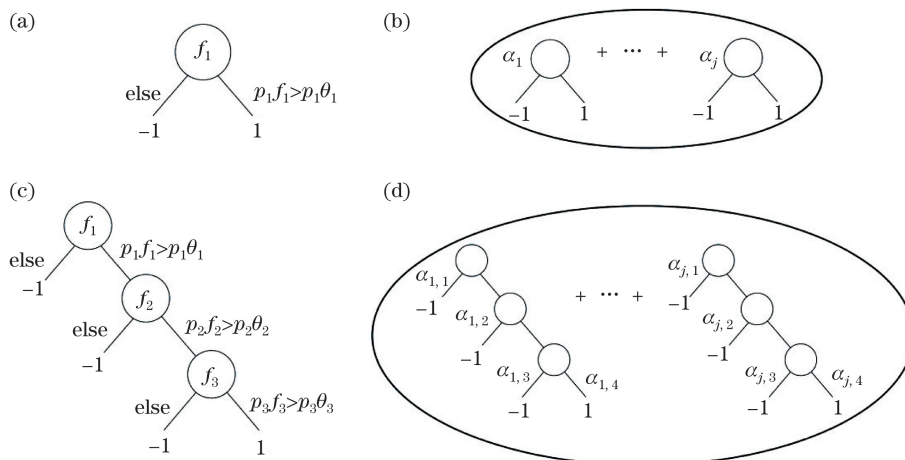


图 2 (a)单树桩弱分类器;(b)由图 2(a)构建的强分类器;(c)三层决策树弱分类器;
(d)由图 2(c)构建的强分类器

Fig. 2 (a) Single stump-based weak classifier; (b) strong classifier boosted by Fig. 2(a);
(c) three-layer decision tree-based weak classifier; (d) strong classifier boosted by Fig. 2(c)

$$h(f, x, p, \theta) = \begin{cases} 1, & pf > p\theta \\ -1, & \text{else} \end{cases}, \quad (3)$$

式中 f 为特征值, x 为训练样本, p 为极性, θ 为特征阈值。训练时, N 个样本被标记为 (x_1, y_1) , $(x_2, y_2), \dots, (x_N, y_N)$ 。其中,对于正样本, $y_i = 1$;对于负样本, $y_i = -1$ 。每个样本都会被分类器 h 分为1或-1。如果 $h = y_i$,则认为样本被正确分类,否则认为被错误分类。特征阈值 θ 由训练样本的特征矩阵唯一确定。具体来说,特征矩阵的行表示不同特征,列表示不同样本。对于某一特征,沿列遍历所有训练样本在该特征上的特征值,并依次将每个特征值设为阈值,计算该阈值下决策树桩的分类错误率 e , e 最小时对应的阈值即为所求的特征阈值。接着沿行遍历每个特征,将 e 最小的特征作为该决策树桩所挑选的特征。一个典型的单树桩弱分类器结构如图 2(a)所示。

单个弱分类器的分类性能是极其有限的,Adaboost 算法通过将多个弱分类器进行组合,得到一个性能远胜于单个弱分类器的强分类器,极大地提升了分类性能。为了得到强分类器,需要对一系列弱分类器进行训练。每一个弱分类器的训练过程基本一样,唯一的区别是训练样本的权重会在训练过程中不断改变。其规则是:加大被前一个弱分类器分错的样本权重,而减小被前一个弱分类器正确分类的样本权重,从而使后续的弱分类器更加集中于对困难样本的学习。在所有弱分类器训练完成后,需要对每个弱分类器分配权重以组合成强分类器。在 Adaboost 算法中,弱分类器的权重与其分类

性能有关。具体来说,在训练集上分类错误率越小的弱分类器,其分类效果越好,所分配的权重也就越大。最终的强分类器由各个弱分类器通过加权组合而成,由弱分类器构建的强分类器如图 2(b)所示。

尽管 Adaboost 算法在特征选择方面是很高效的,但是由于 Haar 特征数量巨大,不同 Haar 特征之间往往存在很大的冗余性。一旦组合成强分类器,其内部各弱分类器之间可能会因所选特征之间的冗余性而难以达到最佳的分类性能。为了解决这一问题,用多层决策树代替单层树桩构建弱分类器。主要思想是通过最大化决策树内部相邻节点的分类错误率之差减小特征冗余度,从而提高分类性能。图 2(c)为一个三层决策树弱分类器模型。具体训练过程为:利用单层决策树桩的训练方式,寻找分类错误率 e 最小的特征作为根节点;而后续节点的特征通过最大化相邻节点分类错误率之差 Δe 进行选择;重复这一过程直到达到树的最大分裂次数。在本方法中,最大分裂次数设定为 3 次。

强分类器的训练过程与图 2(b)所示的过程类似。在训练过程中不断改变训练样本的权重分布,使得后续的分类器更集中于对困难样本的学习上,并依据分类错误率为各弱分类器分配不同的权重,以构成强分类器。考虑到每个弱分类器内部不同节点分类能力的差异,在所提方法中,依据叶节点的分类错误率,对一个弱分类器内的每个叶节点分配一个权重。所构建的弱分类器有 4 个叶节点,因而会被分配 4 个不同的权重 $\alpha_{j,1}, \alpha_{j,2}, \alpha_{j,3}, \alpha_{j,4}$, 构建得到的强分类器如图 2(d)所示。

为了进一步说明,以伪代码的形式在基于多层决策树的 Adaboost 训练算法过程中输入训练样本集 $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$, 对于正样本 $y_i = 1$, 对于负样本 $y_i = -1$, 指定训练轮数 J 。输出为由 J 个弱分类器构成的强分类器。步骤为:

1) 初始化样本权重分布,其中正样本权重 $\omega_{1,i} = 1/2l$, 负样本权重 $\omega_{1,i} = 1/2m$, l 和 m 分别为正样本与负样本的数量。

2) For $j = 1:J$

① 归一化权重分布: $\omega_{j,i} = \omega_{j,i} / \sum_{i'=1}^N \omega_{j,i'}$;

② 对于每个弱分类器 c_j , 挑选 3 个特征作为树节点 $h_{j,u}$ ($u = 1, 2, 3$), 挑选原则为:最小化桩节点 $h_{j,1}$ 的错误率 e , 而最大化后续节点间的错误率之差 Δe 。其中错误率 $e = \sum_i \omega_{j,i} |h_{j,u}(x_i) - y_i| / 2$, 相

邻节点间错误率差 $\Delta e = e_{\text{parent_node}} - e_{\text{child_node}} + e_{\text{parent_node}}$ 为叶父节点错误率, $e_{\text{child_node}}$ 为叶子节点错误率;

③ 对每个输出的叶子节点 $h'_{j,k}$ ($k = 1, 2, 3, 4$), 计算其权重 $\alpha_{j,k} = 0.5 \lg[(1 - e_{j,k}) / e_{j,k}]$, 其中 $e_{j,k}$ 为第 j 个弱分类器的第 k 个叶子节点的错误率, $h'_{j,k}$ 为第 j 个弱分类器的第 k 个叶子节点, $h'_{j,k} = 1$ 表示判定为正, 否则为负;

④ 更新样本权重: $\omega_{j+1,i} = \omega_{j,i} \beta_j^{1-\epsilon_i}$, 其中 $\beta_j = e_j / (1 - e_j)$ 。对于分类错误的样本, $\epsilon_i = 1$; 对于分类正确的样本, $\epsilon_i = 0$ 。

3) 最终的强分类器可表示为

$$H(x) = \begin{cases} 1, & \sum_{j=1}^J c_j - t > 0 \\ 0, & \text{else} \end{cases}, \quad (4)$$

式中 $c_j = \alpha_{j,k} h'_{j,k}$ (k 值取决于从哪个叶节点输出), 表示第 j 个弱分类器的分数; t 为一个分数阈值, 根据强分类器在验证集上的表现确定其值。具体来说, 人为设定强分类器的预期检测率 D_{DR} , 当分类器在验证集上的实际检测率刚好大于预期检测率时, 对应的阈值即为所求阈值。阈值确定后, 强分类器训练完毕。

2.1.3 强分类器级联

一个强分类器对单幅图像的检测耗时与其复杂程度(包含的弱分类器个数)是成正比的。而一个性能较好的强分类器往往包含上百个弱分类器, 因此在实际检测中, 用单个强分类器对图像的每个子窗口进行检测是极其耗时的, 难以满足临床实时性的要求。为了加快检测速度, 使用一种级联结构将多个强分类器级联起来, 级联分类器结构如图 3 所示。级联的每一级都是一个强分类器, 输入的子窗口逐级经过各强分类器并接受判定。一旦被某一级强分类器判定为负, 则直接被排除, 并且不再接受后续强分类器的判定。唯有被所有强分类器均判定为正才能作为候选窗口。考虑到图像中大部分区域很容易被判定为负的子窗口, 可以被结构较简单的分类器排除, 只有极少数子窗口真正包含目标, 需要利用更加复杂的分类器进行判定。因此, 在该级联结构中, 靠前的分类器结构比较简单, 用于快速排除图像中的大多数负窗口, 而靠后的分类器结构较为复杂, 用于对少数难以判定的子窗口进行检测。这样, 通过逐级精细化的构造, 使结构复杂、性能优越的强分类器只需对少数窗口进行检测, 从而极大加快了检测速度, 缩短了检测时间。




图 3 级联分类器结构

Fig. 3 Structure of cascaded classifier

为了保证靠后的分类器具有更强的对困难窗口的分辨能力,在构建级联分类器的过程中,每级强分类器训练所用到的样本是不同的。具体来说,每级的正样本保持不变,而负样本通过以下方法选取:将当前的级联分类器在 IVOCT 图像中进行检测,并将误报的负窗口收集起来,作为下一级强分类器的负样本。

通常来说,一个子窗口在通过级联检测器的所有级后,便被认为是包含目标的子窗口。然而,BVS 支架结构简单,且容易受血液伪影的干扰,使得误报偏多。为了尽可能多地排除假阳性窗口,对每个强分类器计算一个分数 S_s ,即

$$S_s = \sum_{j=1}^J c_{s,j} - t_s, \quad (5)$$

式中 $c_{s,j}$ 为第 s 个强分类器的第 j 个弱分类器; t_s 为第 s 个强分类器的阈值,其值由预期检测率 D_{DR} 唯

一确定。 S_s 实际上反映的是输入窗口被第 s 个强分类器分类为正的得分。假设级联结构共有 N_a 级,即由 N_a 个强分类器构成,那么所有强分类器的分数之和 $\sum_{s=1}^{N_a} S_s$ 反映输入窗口被整个级联分类器分类为正的总得分,该分数越高,则输入窗口为正的可能性越大。设定一个阈值 T ,使得同时满足

$$\begin{cases} H_s(x) = 1, s = 1, 2, \dots, N_s \\ \sum_{s=1}^{N_a} S_s - T > 0 \end{cases} \quad (6)$$

时,输入窗口被判定为正。至此,级联分类器构建完成。利用该级联分类器,可以在 IVOCT 图像中进行 BVS 支架的检测。

2.1.4 检测过程

检测流程图如图 4 所示。检测过程主要包含三步:预处理、检测和后处理。

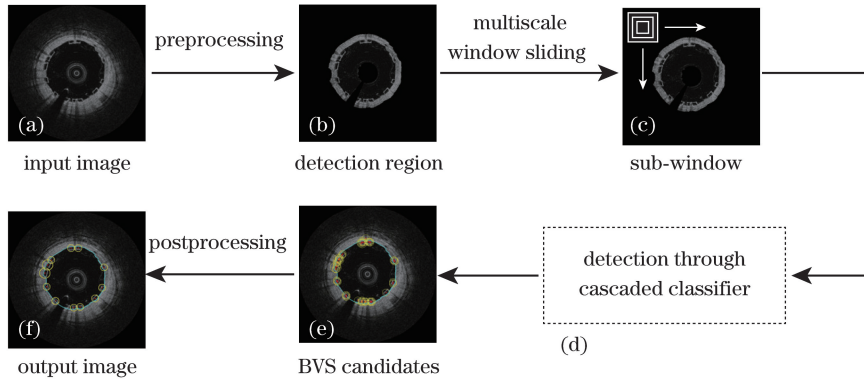


图 4 检测流程图。(a)输入图像;(b)检测区域;(c)滑窗示意图;
(d)用级联分类器检测;(e)BVS 候选点;(f)输出图像

Fig. 4 Workflow of detection. (a) Input image; (b) detection region; (c) diagram of sliding sub-window;
(d) detection through cascaded classifier; (e) BVS candidates; (f) output image

首先,如图 4(a)、(b)所示,输入的 IVOCT 图像经过预处理,将血管壁、导管和保护鞘进行分割,构成一个检测区域。这里,采用动态规划算法对上述目标进行分割,具体内容可以参考文献[10]。分割完成后,将血管壁向外扩展一个设定值,即血管壁扩展阈值,这里 $\epsilon = 30$ pixel,以使所有支架均能包含

在血管壁扩展后所限定的检测范围内。扩展后的血管壁外围、导丝内部和保护鞘内部均被排除,从而得到如图 4(b)所示的检测区域。

接下来通过滑窗的方式,基于训练好的级联分类器对 BVS 支架的位置和大小进行检测。如图 4(c)、(d)所示,一个初始尺寸为 $L \times L$ 的滑窗以

步长 K 对输入图像进行遍历,并且利用级联分类器判定每个滑窗内是否包含支架。由于支架大小不固定,滑窗会以尺度系数 $\sigma = [1, 1.5, 1.5^2, 1.5^3, 1.5^4]$ 逐级增大,形成多尺度滑窗。如果成功检测到支架,则支架的位置由相应滑窗的中心点表征,称之为候选种子点。此外,由于支架大小不一,需要为每个支架找到一个局部 ROI 以方便后续分割。这里,采用一个圆形区域表征局部 ROI,其半径 $R = \sigma L/2$,其中 σ 为滑窗尺度系数, L 为滑窗初始尺寸。尺寸较大的支架往往被尺度系数较大的滑窗检测出,根据上述定义,其半径更大,则 ROI 也更大。图 4(e) 显示了一幅图中检测出的所有 ROI 及候选种子点,其中黄色圆圈代表 ROI,红点代表候选种子点。

一个支架会在多个尺度 σ 被重复检测,并且考虑到滑窗步长 K 远小于支架尺寸,因此同一个支架

往往会被多个子窗口检测出来,故在检测完成后需采取后处理,将这些候选窗口聚类,并挑选出其中最具代表性的窗口表征相应支架。主要策略是在一定邻域内搜索分数 $\sum S_i$ 最大的窗口,并将其中心点和对应 ROI 作为最终种子点和 ROI。这里,用一个距离阈值 $\lambda = 20$ pixel 来确定邻域范围。对于每个被检测出的支架,都会挑选出一个得分最高的种子点及其 ROI,用以表征该支架。图 4(e)、(f) 显示了通过后处理进行窗口挑选的结果。至此,支架检测部分结束,每个被检测出的支架都由一个种子点和一个 ROI 表征,输出图像如图 4(f) 所示。

2.2 支架分割

为了定量计算支架到血管壁的距离以实现支架贴壁分析,需要对支架边界进行分割。在检测结果的基础上,提出一种基于动态规划的支架轮廓分割方法。图 5 为支架分割流程图。




图 5 支架分割流程图。(a)笛卡尔坐标系下的一个支架;(b)极坐标系下的一个支架;
(c)极坐标系下的轮廓分割结果;(d)转回至笛卡尔坐标系下的分割结果

Fig. 5 Procedure of strut segmentation. (a) Strut in Cartesian coordinate system; (b) strut in polar coordinate system; (c) segmented contour in polar coordinate system; (d) segmented contour transformed back into Cartesian coordinate system

首先,将图 5(a) 所示的每个局部 ROI 都转至极坐标空间,极坐标空间由角度 γ 和深度 d 表征。具体转换过程可参考文献[11]。假设转换后的 ROI 区域大小为 $M \times R$,则 $\gamma \in [1, M], d \in [1, R]$ 。支架边界分割问题可定义为从第 1 列至第 M 列搜索一条路径,使得代价函数 C 最小。考虑到支架边界上相邻两点的连续性约束,该问题可分解为一系列子问题并借助动态规划逐级解决。具体来说,代价函数 C 定义为

$$C(\gamma, d) = \begin{cases} E(\gamma, d), & \gamma = 1 \\ \min C(\gamma - 1, d^*) + E(\gamma, d), & 1 < \gamma \leq M \end{cases} \quad (7)$$

式中 $C(\gamma, d)$ 为第一列到点 (γ, d) 的累积代价;

$d^* \in [d - \delta, d + \delta]$, δ 为邻域系数,用以决定相邻列的连接关系,这里取 $\delta = 1$ pixel; $E(\gamma, d)$ 为点 (γ, d) 处的能量函数,定义为

$$E(\gamma, d) = I * \omega, \quad (8)$$

式中 I 为极坐标下的局部 ROI 图像, ω 为一个对水平边界敏感的滤波器。通过对累积代价函数 C 进行全局最小化,并反向搜索该路径,便可得到支架的边界,极坐标下的轮廓分割结果如图 5(c) 所示。将得到的图像及边界数据再转回至笛卡尔坐标系,得到转回至笛卡尔坐标系下的分割结果如图 5(d) 所示,其中绿色曲线即为分割出的支架边界。

2.3 贴壁情况计算

在获得支架分割数据后,便可基于支架和血管

壁分割结果自动计算支架的贴壁情况。设血管壁轮廓中心为 P_c , 每个支架边界上均可找到一个点 P_s , 使得其到 P_c 的距离最远。连接 P_c 与 P_s 并延长, 将其与血管壁的交点设为 P_1 , 则 P_s 到 P_1 之间的距离可视为支架到血管壁的距离。如果该距离小于 $10 \mu\text{m}$, 则该支架贴壁良好, 否则贴壁不良。具体内容参见图 6(d)~(f)。

3 实 验

3.1 实验材料

在实验中, 所有支架均采用 ABSORB 1.1 BVS 支架 (Abbott Vascular, Santa Clara, 美国), IVOCT 图像均通过 FD-OCT 系统 (C7-XR system, St. Jude, 美国) 获取。系统的成像分辨率为 $10 \mu\text{m} \cdot \text{pixel}^{-1}$, 每幅图像大小为 $704 \text{ pixel} \times 704 \text{ pixel}$ 。实验总共选取 16 组回拉序列, 每组序列包含 271 幅 IVOCT 图像。这 16 组回拉序列共包含 10561 个支架, 所有支架均由专家手工标记, 作为真实支架。这 16 组回拉序列中, 4 组作为训练集, 4 组作为验证集, 剩下的 8 组作为测试集。而 8 组测试集中, 第 1 组至第 4 组同时包含贴壁不良和贴壁良好支架, 第 5 组至第 8 组包含严重的血液伪影。

3.2 参数设置

实验中涉及到一些参数阈值, 根据参数特性, 将其分为 2 类: 不敏感参数和重要参数。

不敏感参数在一定范围内的取值对实验结果影响不大, 一般根据图像特点和工程经验进行设置。包括: 训练样本尺寸、正负样本数量、强分类器预期检测率 D_{DR} 、检测滑窗步长 K 、窗口合并距离阈值 λ 、血管壁扩展阈值 ϵ 以及滑窗尺度系数 σ 。具体来说, 由于常见的 BVS 支架宽度约为 $150 \mu\text{m}^{[12]}$, 长度变化范围为 $150 \sim 800 \mu\text{m}$, 为了保证训练样本能完全包含支架同时又不包含太多背景, 取训练样本的宽度为普通支架的 1.5 倍, 故样本尺寸为 $24 \text{ pixel} \times 24 \text{ pixel}$ ($240 \mu\text{m} \times 240 \mu\text{m}$)。对于大于或小于常见尺寸的支架, 采样窗口取其长宽中较大者的 1.5 倍, 并在提取完支架后放缩至 $24 \text{ pixel} \times 24 \text{ pixel}$; 尺度系数设为 $\sigma = [1, 1.5, 1.5^2, 1.5^3, 1.5^4]$, 从而保证最大的支架依然能被滑窗完全包含在内; 将每级强分类器训练所用的训练样本数量设定为正样本数量 $l = 1500$, 负样本数量 $m = 4500$; 每级强分类器的预期检测率 $D_{\text{DR}} = 99\%$; 血管壁扩展阈值设定为支架厚度的 2 倍, 即 $\epsilon = 30 \text{ pixel}$, 以保证所有支架均在检测区域内; 滑窗尺寸与样本尺寸相同, 取 $24 \text{ pixel} \times$

24 pixel ; 滑窗步长 $K = 3 \text{ pixel}$, 以保证图像的所有子窗口都得到遍历; 候选窗口合并时所用的距离阈值设为最大支架长度的 $1/4$, 即 $\lambda = 20 \text{ pixel}$ 。

重要参数主要包括级联分类器阈值 T , 该值对实验结果有显著影响。具体来说, T 值越高, 表明级联分类器判定标准越严格, 在测试集上的召回率和误报率越低; 相反, T 值越低, 表明级联分类器判定标准越宽松, 在测试集上的召回率和误报率也越高。需多次对 T 进行取值并绘制 ROC 曲线来进行分析。详细内容将在第 3.4.2 节中进行讨论。

另外, 对于级联分类器每级的分类器设置, 基于越往后越复杂的原则, 以每级增加 $2 \sim 20$ 个弱分类器为标准, 人为设定了每级强分类器的训练轮数。具体来说, 训练了一个 20 级的级联分类器, 第 1 级只包含 1 个弱分类器, 前 5 级以每级增加 2 个弱分类器的方式构建, $6 \sim 10$ 级每级增加 $5 \sim 6$ 个弱分类器, $11 \sim 15$ 级每级增加 $10 \sim 12$ 个弱分类器, $16 \sim 20$ 级每级增加 $15 \sim 20$ 个弱分类器, 最终得到一个 20 级的级联分类器, 共包含 1326 个弱分类器。

3.3 评价标准

为了定量评估所提方法的性能, 对每组数据的召回率 R_{re} 、精确率 R_{p} 和 F 值进行了计算, 计算公式为

$$\begin{cases} R_{\text{re}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \\ R_{\text{p}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \\ F = \frac{2 \times R_{\text{re}} \times R_{\text{p}}}{R_{\text{re}} + R_{\text{p}}} \end{cases}, \quad (9)$$

式中 N_{TP} 为检测结果为支架且实际也是支架的窗口数; N_{FP} 为检测结果为支架且实际不是支架的窗口数; N_{FN} 为检测结果不是支架且实际是支架的窗口数。

为了对支架检测进行定量评价, 计算了中心点误差 (E_{CP}), 其定义为种子点到真实支架中心的距离, 计算公式为

$$E_{\text{CP}} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}, \quad (10)$$

式中 (x_1, y_1) 和 (x_2, y_2) 分别为种子点和真实支架中心点的坐标。

为了对支架分割进行定量评价, 计算了分割区域与真实支架区域间的 Dice 系数 (C_{Dice}) 以衡量两者间的重合度。Dice 系数的定义为

$$C_{\text{Dice}} = \frac{2 \times (A_1 \cap A_2)}{A_1 + A_2}, \quad (11)$$

式中 A_1 和 A_2 分别为分割区域与真实支架区域。

3.4 结果分析

3.4.1 定性结果

图 6 为所提方法的部分支架贴壁分析结果图。白色半透明区域为专家标记的真实支架, 蓝点为种子点, 黄色圆圈为 ROI, 绿色和红色轮廓分别为分割出的贴壁良好和贴壁不良支架。图 6(a) 为一张普通的 IVOCT 图像, 由图可见, 几乎所有支架均被正确检测和分割, 并且没有误报。唯一未检测出的支架在这帧图像中非常不清晰, 其放大图显示在图 6(a) 右上角。图 6(b)、(c) 为存在血液伪影的图

像, 尽管如此, 该方法仍然成功检测和分割出了所有支架, 并且图 6(b) 中没有误报, 而图 6(c) 中出现了一个误报, 误报的主要原因是血液伪影形成了类似支架的结构, 其放大图如图 6(c) 左上角所示。图 6(d)~(f) 为同时包含贴壁良好和贴壁不良支架的图像, 其中蓝色轮廓表示分割出的血管壁边界, 对于贴壁不良支架, 所提方法自动计算并标记出其到血管壁的距离。实验结果表明, 无论是否有血液伪影, 所提方法均能准确检测和分割出几乎所有支架, 并且很少发生误报。此外, 贴壁良好和贴壁不良支架也被准确识别。

以上定性分析显示所提方法对于 BVS 支架的检测和分割是准确且稳健的, 可用于复杂背景下可降解支架的自动贴壁分析及评估。

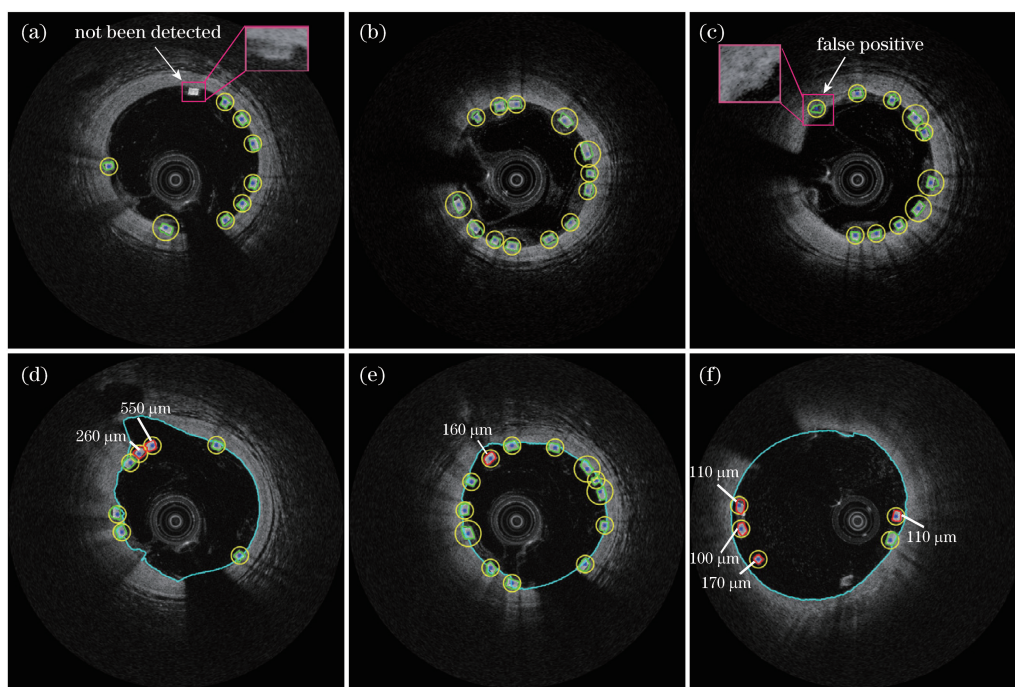


图 6 支架贴壁分析结果图。(a)普通 IVOCT 图像;(b)(c)有血液伪影的图像;

(d)~(f)同时包含贴壁良好和贴壁不良支架(对于贴壁不良支架,以白色线段表征其到血管壁的距离)

Fig. 6 Results of strut malapposition analysis. (a) Normal IVOCT images; (b)(c) images with blood artifacts; (d)-(f) images with both apposed and malapposed struts (For malapposed struts, distances between strut and lumen are represented by white lines)

3.4.2 定量结果

表 1 为支架检测与分割结果。评估检测性能时,若种子点落在真实支架区域内部,则认为检测正确,否则检测错误;评估分割性能时,以分割区域与真实支架区域的 Dice 系数衡量分割性能的好坏。如表 1 所示,所提方法达到了 91.6% 的平均召回率和 87.2% 的平均精确率。通过对比第 1 组至第 4 组(无血液伪影)和第 5 组至第 8 组(有严重血液伪影)的结果可以发现,图像中无伪影时的检测结果略优

于有伪影时的检测结果,但二者差距极小,即使只观察第 5 组至第 8 组,所提方法依然能达到 90.8% 的平均召回率和超过 85% 的平均精确率,因此,所提方法对于复杂背景下的 BVS 支架检测是具备较强稳健性的。此外,8 组测试集的平均中心点误差为 $27.4 \mu\text{m}$ 。考虑到支架的厚度往往达到 $150 \mu\text{m}$,而长度变化范围为 $150 \sim 800 \mu\text{m}$,该误差是可以接受的,表明所提方法具有较高的检测准确性。平均 F 值为 0.89,表明所提方法具有较好的综合检测性能。

表 1 支架检测与分割结果

Table 1 Results of strut detection and segmentation

Data set	Number of evaluated frames	Number of ground truth	Detection				Segmentation
			$R_{re} / \%$	$R_p / \%$	F	E_{CP} / cm	C_{Dice}
No.1	81	691	95.5	89.8	0.93	26.4	0.80
No.2	119	928	91.3	89.8	0.91	31.2	0.79
No.3	118	1172	92.0	89.4	0.91	32.4	0.80
No.4	78	604	90.7	88.4	0.90	21.3	0.82
No.5	147	1188	93.5	83.0	0.88	24.8	0.82
No.6	86	635	90.7	84.6	0.86	30.0	0.80
No.7	76	603	86.9	89.2	0.88	24.1	0.79
No.8	150	1240	92.1	83.2	0.87	29.1	0.80
Average	-	-	91.6	87.2	0.89	27.4	0.80

为了验证所提方法训练误差的有界性,记录并绘制了训练误差 e_t 随训练轮数 N_t 的变化曲线,训练误差曲线如图 7(a)所示。由图可以看到,在训练的前 200 轮,训练误差随训练轮数的增加迅速减小,表明分类器的分类能力在迅速提升;而 200 轮以后,曲线逐渐平缓,表明分类器的分类能力缓慢提升并最终趋于稳定。训练误差最终稳定在 0.03 附近,表明实验所用级联分类器的误差极限约为 3%。

由于级联分类器阈值 T 的设定会显著影响实验结果,这里多次改变 T 值并绘制了相应的 ROC 曲线,如图 7(b)所示,其中横坐标为误报率 R_{fp} ,纵坐标为召回率 R_{re} 。结果显示,当召回率在 92% 而误报率在 12% 左右时,检测性能达到最佳,此时 $T=100$ 。实际上,检测分割结果及贴壁分析均是在 $T=100$ 的条件下得到的。

对于分割结果,用自动分割区域与真实支架区域间的平均 Dice 系数进行定量评估。由表 1 可知,所提方法在 8 组测试集上的平均 Dice 系数为 0.80,即分隔区域与真实区域的重合度达到 80%,表明所提方法具有较高的分割准确性。为了评估所提方法对支架分割的稳健性,计算了各测试组 Dice 系数的方差,结果显示各组方差均小于 0.01,表明所提方法对支架分割兼具较好的准确性和稳健性。

3.4.3 耗时结果

在实验中,采用 MATLAB 2015b 进行计算。计算机配置为: Intel Core i5-4460, CPU 3.20 GHz, 内存 8G。对于一个回拉序列,所提方法的平均耗时为 14.81 s,其中检测耗时 10.69 s,分割耗时 4.12 s。作为对比,传统的人工分析针对一个回拉序列往往耗时多达 5 h。因此,所提方法显著提高了贴壁分

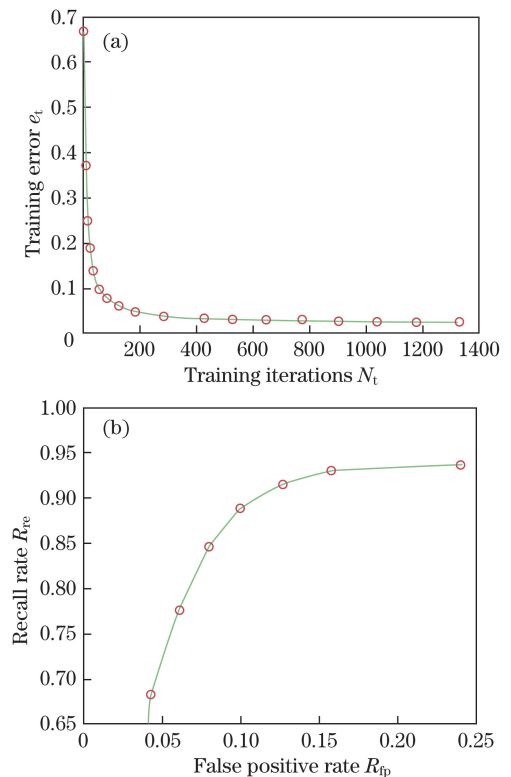


图 7 (a)训练误差曲线;(b)测试 ROC 曲线

析的速度。

4 结 论

提出了一种针对 IVOCT 图像中 BVS 支架贴壁情况自动分析的方法框架。利用先检测、后分割的框架流程,结合机器学习方法,对 BVS 支架进行自动检测与轮廓分割,并对支架的贴壁情况进行自动分析。实验结果显示所提方法对 BVS 支架的检测与分割具有较高的准确性。对于有无伪影的图

像,所提方法均表现出较好的检测及分割性能,表明所提方法对复杂背景具有较好的稳健性,可以实现各种复杂背景下 BVS 支架的自动检测与分割。此外,耗时评估表明所提方法具备较快的检测速度,可实现支架贴壁情况的实时评估。

参 考 文 献

- [1] Serruys P W, Ormiston J A, Onuma Y, *et al.* A bioabsorbable everolimus-eluting coronary stent system (ABSORB): 2-year outcomes and results from multiple imaging methods[J]. *The Lancet*, 2009, 373(9667): 897-910.
- [2] Lu Y, Li Z L, Wang X Z, *et al.* Development of 50 kHz intravascular swept source optical coherence tomographic system[J]. *Chinese Journal of Lasers*, 2017, 44(2): 0207001.
卢宇, 李中梁, 王向朝, 等. 50 kHz 血管内扫频光学相干层析成像系统[J]. *中国激光*, 2017, 44(2): 0207001.
- [3] Shi B Y, Meng Z, Liu T G, *et al.* Non-distorted imaging depth of optical coherence tomography system in human dental tissues[J]. *Acta Optica Sinica*, 2014, 34(2): 0217001.
石博雅, 孟卓, 刘铁根, 等. OCT 系统对人体牙齿组织的非失真成像深度的研究[J]. *光学学报*, 2014, 34(2): 0217001.
- [4] Gonzalo N, Serruys P W, Piazza N, *et al.* Optical coherence tomography (OCT) in secondary revascularisation: stent and graft assessment[J]. *EuroIntervention*, 2009, 5(D): 93-100.
- [5] Xu C Y, Schmitt J M, Akasaka T, *et al.* Automatic detection of stent struts with thick neointimal growth in intravascular optical coherence tomography image sequences[J]. *Physics in Medicine and Biology*, 2011, 56(20): 6665-6675.
- [6] Wang A C, Nakatani S, Eggermont J, *et al.* Automatic detection of bioresorbable vascular scaffold struts in intravascular optical coherence tomography pullback runs[J]. *Biomedical Optics Express*, 2014, 5(10): 3589-3602.
- [7] Amini A A, Weymouth T E, Jain R C. Using dynamic programming for solving variational problems in vision[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990, 12(9): 855-867.
- [8] Viola P, Jones M J. Robust real-time face detection[J]. *International Journal of Computer Vision*, 2004, 57(2): 137-154.
- [9] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting[C]. *European Conference on Computational Learning Theory*, 1995: 23-37.
- [10] Cao Y H, Jin Q H, Chen Y D, *et al.* Automatic identification of side branch and main vascular measurements in intravascular optical coherence tomography images[C]. *IEEE 14th International Symposium on Biomedical Imaging*, 2017: 16968796.
- [11] Duda R O, Hart P E. Use of the Hough transformation to detect lines and curves in pictures[J]. *Communications of the ACM*, 1972, 15(1): 11-15.
- [12] Gogas B D, Farooq V, Onuma Y, *et al.* The ABSORB bioresorbable vascular scaffold: an evolution or revolution in interventional cardiology[J]. *Hellenic J Cardiol*, 2012, 53(4): 301-309.