

基于局部形状结构分类的心血管内 超声图像中-外膜边界检测

袁绍锋^{1,2}, 杨 丰^{1,2}, 刘树杰³, 季 飞³, 黄 靖^{1,2}

(1. 南方医科大学生物医学工程学院, 广东广州 510515;
2. 南方医科大学广东省医学图像处理重点实验室, 广东广州 510515;
3. 华南理工大学电子与信息学院, 广东广州 510641)

摘 要: 本文提出了一种基于局部形状结构分类的心血管内超声 (Intravascular Ultrasound, IVUS) 图像中-外膜边界检测方法. 首先利用 k -均值 (k -means) 聚类方法, 确定局部形状结构类别; 其次通过类别标号索引图像块, 并对其积分通道特征和自相似性特征提取, 构建多分类随机决策森林模型; 最后由分类模型寻找 IVUS 图像的关键点, 采用曲线拟合方法, 实现 IVUS 图像中-外膜边界检测. 实验结果表明, 本文方法能够有效地解决 IVUS 图像中斑块、伪影和血管分支等造成边缘难以准确检测的问题, 与已有算法相比, 其 JM (Jaccard Measure, JM) 达到了 88.9%, PAD (Percentage of Area Difference, PAD) 降低了 19.1%, HD (Hausdorff Distance, HD) 减少了 9.7%, 更准确地识别目标边界的关键点, 成功地检测出完整的中-外膜边界.

关键词: 医学图像分析; 机器学习; 随机决策森林; k -均值聚类; 局部形状结构; 心血管内超声; 中-外膜边界检测

中图分类号: TP391.4 文献标识码: A 文章编号: 0372-2112 (2018)07-1601-08
电子学报 URL: <http://www.ejournal.org.cn> DOI: 10.3969/j.issn.0372-2112.2018.07.009

Media-Adventitia Border Detection Based on Local Shape Structure Classification for Intravascular Ultrasound Images

YUAN Shao-feng^{1,2}, YANG Feng^{1,2}, LIU Shu-jie³, JI Fei³, HUANG Jing^{1,2}

(1. School of Biomedical Engineering, Southern Medical University, Guangzhou, Guangdong 510515, China;
2. Guangdong Provincial Key Laboratory of Medical Image Processing, Southern Medical University, Guangzhou, Guangdong 510515, China;
3. School of Electronic and Information Engineering, South China University of Technology, Guangzhou, Guangdong 510641, China)

Abstract: This paper presents an efficient and effective approach based on local shape structure classification for detecting media-adventitia border in intravascular ultrasound (IVUS) images. First, the category of local shape structures is found by using k -means clustering method. Second, patches from IVUS images indexed by the category are extracted by two kinds of features including integral channel and self-similarities features, and therefore a random decision forest model is constructed. Finally, the key points of testing IVUS images are detected using the trained classification model. Then with the help of curve fitting methods, detection of media-adventitia border is acquired. Experimental results demonstrate that the proposed algorithm effectively relieves the difficulties of interference factors such as plaques, artifacts and side vessel, and more accurately recognizes the key points of target border compared with existing algorithms, detects the whole target border successfully. The Jaccard Measure (JM) of media-adventitia border detected by the algorithm is 88.9%, Percentage of Area Difference (PAD) and Hausdorff Distance (HD) measures are reduced by 19.1% and 9.7% respectively.

Key words: medical image analysis; machine learning; random decision forest; k -means clustering; local shape structure; intravascular ultrasound; media-adventitia border detection

1 引言

心血管内超声 (Intravascular Ultrasound, IVUS) 是一种微创断层成像技术, 适用于冠状动脉造影结果不确定及指导经皮冠状动脉介入治疗 (Percutaneous Coronary Intervention, PCI)^[1], 是心血管疾病诊断的重要方式^[2]. 心内科医生通过 IVUS 图像可观察冠脉壁的两个分界面, 一个位于血管边际和内膜前缘, 为管腔/内膜界面; 另一个为外弹力膜界面, 位于低回声中层和强回声外膜的交界面^[1]. 中-外膜/外弹力膜测量既是临床测量心血管粥样硬化斑块的重要指标, 也是在体评价动脉重构程度和方向的重要特征^[1]. 目前临床上主要由医生来人工勾画中-外膜边界, 易受主观影响, 工作量巨大且耗时. 因此, 自动、准确、快速、基于计算机辅助实现 IVUS 图像的中-外膜边界检测具有十分重要的临床意义.

在 IVUS 图像采集过程中, 常常因斑点噪声大^[3]、图像分辨率和对比度低、血管壁易损斑块、脉侧分支以及运动伪影等各种因素造成内膜、中层和外膜三层结构组织间边界模糊不清, 不利于 IVUS 图像中-外膜准确检测. 目前, 中-外膜边界检测方法主要有基于直接检测的方法^[4-6]、基于统计与概率的方法^[7,8]和基于有监督学习的方法^[8-10]. 基于直接检测的方法主要包括图搜索、活动轮廓和图割模型. 然而, 这些方法的检测结果对 Haar、DoG 等梯度特征较敏感, 这是因为如果强灰度梯度响应在 IVUS 图像钙化组织中出现, 那么易造成检测精度不高. 在加入小波分解和纹理特征^[11]后, 算法的检测准确性有所改善. 基于统计与概率的方法^[7,8]越来越受到重视, 但这些方法仍然会受到超声阴影、纤维斑块等因素的影响. 在有监督分类方法中, 基于支持向量机 (Support Vector Machine, SVM)^[8]、自适应提升 (Adaptive Boosting, AdaBoost)^[9]、纠错输出编码 (Error-correcting Output Codes, ECOC)^[10]的方法被采用. 这些方法往往结合多维特征, 通过对样本特征的学习寻找最优分类器, 实现像素点的分类, 非常适合 IVUS 图像分割. 但是这类方法仅仅使用底层特征, 算法其检测精度会受到一定程度限制.

在视觉识别领域中, 中层特征 (Mid-level Features) 作为一种部件级信息, 在基于像素的底层特征和高层语义特征之间提供了一种纽带^[12], 其对有用的底层像素信息进行抽象, 而对不关联或噪声信号表现很高鲁棒性. 基于图像梯度统计量的特征称为像素级特征即底层特征, 比如 HOG、SIFT、SURF, 而把图像标记为某一语义类别视作目标级特征即高层语义特征. 底层特征在 IVUS 图像中-外膜边界检测中往往被采用, 但如上文所述, 其检测结果易受外界干扰影响^[13], 而高层语义特

征在此类任务中表现出色^[10]. 融合临床医生人工勾画轮廓的先验信息, 基于有监督学习算法缓解了上述检测困难. 但人工勾画过程费时费力, 并且大规模标注数据难以获取, 这导致分类模型缺乏对数据共性特征的有效表达. 中层表示克服这两者的不足^[12], 一方面中层特征通过对临床医生人工勾画边缘的学习而获取, 既解决了标注数据缺乏的问题, 又表达了不同的整体边界可分解为各种不同方向的局部结构这一特点; 另一方面中层特征对底层像素信息进行聚合, 将区域梯度统计量表达为较高层语义信息, 即不同的局部区域代表方向不同的边缘. 前一个过程将中-外膜分解为各类局部形状结构, 为自顶向下过程; 后一个过程通过对局部底层像素信息进行抽象聚合, 为自底向上过程.

综上所述, 本文提出一种结合随机决策森林^[14]和中层表示分类的 IVUS 图像中-外膜边界自动检测方法. 该方法模拟临床医生勾画中-外膜边界的基本过程: 先观察 IVUS 图像中-外膜边界容易识别的轮廓点即“关键点”, 再结合血管的先验形状信息, 避免干扰区域的影响, 确定有效的中-外膜边界. 通过对大量临床 IVUS 图像数据进行实验和定量分析, 以及使用交并比指数 (Jaccard Measure, JM)、面积差异百分比 (Percentage of Area Difference, PAD)、豪斯多夫距离 (Hausdorff Distance, HD) 指标与现有算法进行比较, 评估所提出中-外膜边界检测算法的性能.

2 基本原理

在本文中, 中层表示一方面通过 k -均值聚类将中-外膜边界分解为各类不同方向的局部边缘, 为分类模型提供高层语义监督信息; 另一方面在图像的特征提取中, 局部边缘可整合底层特征, 降低分类模型易受干扰因素影响的可能性, 提高模型的抗干扰能力. 前一个方面体现在局部形状结构的构建过程中; 后一方面则表现在 IVUS 图像的特征提取过程中. 基于以上两个过程, 本文所提出的方法首先构建随机决策森林的训练数据, 然后进行分类器的训练和测试, 最后选择分类结果中的边缘关键点并利用曲线拟合方法实现 IVUS 图像中-外膜边界的检测.

2.1 局部形状结构的构建

在局部形状结构构建阶段中, 本文采用 Lim 等人提出的 Sketch Tokens 中层特征^[12]. 该特征表示的有效性已在自然图像轮廓识别和物体检测任务中获得了验证. 在 IVUS 图像中-外膜边界检测中, 本文将其定义为局部形状结构 (Local Shape Structure, LSS). 各类 LSS 表达了异源 IVUS 图像中-外膜边界可分解为基于不同方向的局部边缘, 其构建步骤如下:

(1) 含有局部边缘的二值图像划分. 利用临床医生

手工勾画边界标注信息,将完整的中-外膜边界二值图像 I_{binary} 分解为局部图像块集合 $B = \{i_{(x,y)}, S\}$, 其中图像块的大小为 S , 坐标 (x, y) 表示局部边缘图像块的中心点, 显然这些图像块包含着高层语义信息.

(2) 二值图像块的 Daisy 特征提取. 为了在局部边缘位置上获得轻微的平移不变性, 计算二值图像块集合 B 的 Daisy 特征^[15], 得到一维向量集合 $V = \{v_i\}$.

(3) LSS 中层特征的生成. 将步骤(2)中的一维向量特征集合 V 输入到 k -均值聚类算法^[16,17] 中, 设定 LSS 的类别数目为 C , 迭代终止后获取每一局部图像块 B_i 的分类标号 C_j , $\{i_{(x,y)}, C_j\}$ 表示局部图像块 i 属于 LSS 中层特征类别 j .

本文方法的训练样本集合由不同的 LSS 对应的局部边缘和背景图像块组成, 即一类样本代表某种方向的局部边缘结构, 一类样本代表各种复杂背景. 这些不同的 LSS 是为了表达 IVUS 图像中各种各样的局部边缘结构, 如图 1 所示. 上述过程通过无监督学习, 将中-外膜边界分解为各类局部形状结构, 是一个自顶向下过程.




图1 局部形状结构 (Local Shape Structure, LSS)

2.2 IVUS 图像的特征提取

在 IVUS 灰度图像特征提取阶段中, 本文采用 Dollar 等人提出的积分通道特征 (Integral Channel Features, ICF)^[18]、Shechtman 和 Irani 设计的自相似性描述子 (Self-similarity Descriptor, SSD)^[19]. ICF 可以自然地整合异质局部图像块的丰富信息, 因此能收集到患者 IVUS 图像的不同底层特征. 此外, ICF 具有比较少的参数, 并且对特定的参数设置不敏感, 加上在计算上高效、准确, 所以比较适合鲁棒地检测大量 IVUS 图像中的边缘关键点. ICF 通过式(1)计算:

$$C = f(I) \quad (1)$$

其中, $f(\cdot)$ 为通道生成函数, I 为输入图像, C 为输出图像, 两图像大小是相同的. $C = I$ 就是把灰度图像视作一个通道图像. 其他通道图像可以是线性变换, 比如 Gabor 滤波、DoG 滤波; 也可以是非线性变换, 比如梯度强度、Canny 边缘^[20]. 除了采用 ICF, 本文还利用了 SSD. 图像中的特征不仅存在于图像梯度值大的区域, 而且会分布在纹理边界上. SSD 可以有效地描述图像中的相似纹理^[19]. SSD 被视为一种局部图像特性, 适合 LSS 这样的局部纹理分析. 其在计算上采用对数极坐标表达, 考虑了局部仿射变形. 为了捕获不同方向 LSS 的纹理特点, 本文采用 SSD 度量 LSS 的内部自相似性, 寻找更有

意义的局部图像模式. SSD 通过式(2)计算:

$$f_{ijk} = s_{jk} - s_{ik} \quad (2)$$

其中, f_{ijk} 表示在第 k 个积分通道图上由区域 j 和区域 i 计算所得的自相关特征值, s_{jk} 和 s_{ik} 分别为图像块中任意两个互斥小区域内的积分通道值之和. 定义一个 $m \times m$ 小区域和一个 $M \times M$ 图像块, 小区域可以将图像块填满, 并且小区域的数量为 $n = (M/m)^2$. s_{jk} 或 s_{ik} 就是 $m \times m$ 个通道值之和. 某个图像块的 SSD 特征值 f_{ijk} 总数为 $C((M/m)^2, 2)$, $C(\cdot)$ 为取组合数. 这一过程通过两种特征提取方法整合局部中-外膜边界的底层特征, 是一个自底向上过程.

2.3 随机决策森林的训练和分类

当输入一幅 IVUS 图像时, 要使用已训练好的分类器对图像中所有像素点进行分类即标记, 其中类别可以是 LSS 的某一类, 也可以是背景类. 这要求分类器能够进行多种类别判定, 并可以进行快速推断, 因此本文采用随机决策森林 (Random Decision Forest, RDF) 算法^[14,21,22]. 该算法是一种以决策树为基学习器, 对样本进行学习并预测的集成学习方法. 随机决策森林由多棵分类回归决策树 (Classification and Regression Tree, CART) 构成, 其最终输出结果由各棵构成树的判定结果综合决定. 每棵 CART 所使用的训练集合是从总的训练集合中有放回抽样获得的 (样本扰动), 所使用的划分属性是从特征空间中按一定比例随机无放回抽样获取的 (特征扰动). 分类器的具体训练如下:

(1) RDF 训练条件的设定. 给定总的训练集合 D , 每个图像块的特征向量维数为 d , 确定构成树的数量 T 以及每棵树的深度 L , 设置节点训练终止条件为每棵决策树的叶子节点所具有类别数目小于等于 n .

(2) RDF 训练数据的采样. 从总的训练集合 D 中, 通过有放回抽样获得由 LSS 正类和背景负类构成的训练集合 $D(i)$, 作为根节点的样本, 从根节点开始训练.

(3) RDF 的学习. 若当前节点不满足终止条件, 从 d 维特征中无放回随机选择 d/T 维特征, 在 d/T 维特征中选取信息增益比最高的一维特征 k 及其门限 T_h , 并把当前样本第 k 维特征值小于 T_h 的样本划分到左叶子节点, 剩余样本划分至右叶子节点; 继续训练其他节点; 若当前节点满足终止条件, 则把当前节点标记为叶子节点. 该节点的输出类别设定为当前节点所含样本最多的一类.

(4) 重复步骤(2)和(3)直到所有节点都被训练过或者被标记为叶子节点.

(5) 重复步骤(2)到(4)直到 T 棵决策树都完成训练.

在分类器的预测过程中, 每一待分类样本首先计算特征向量并同时进入所有决策树中, 接着根据划分

属性逐层深入,然后抵达对应的叶子结点获得属于 LSS 或者背景类别的标号,最后通过简单平均法^[22]求得随机决策森林的输出分类概率 t_{ij} , t_{ij} 为图像块 x_i 属于局部形状结构 j 类的概率,而 t_{i0} 为图像块 x_i 属于背景类的概率. 由于每一类 LSS 在其中心处存在边缘,所以本文使用局部形状结构的概率之和来计算中心位置边缘的概率,即图像块中心存在边缘的估计概率为:

$$e_i = \sum_{j=1}^C t_{ij} = 1 - t_{i0} \quad (3)$$

其中, C 为局部形状结构的类别数目. 一旦计算出局部图像块中心位置属于边缘的概率,标准非最大抑制 (Non-maximum Suppression, NMS) 策略^[20]就用于寻找边缘的峰值响应. 图 2(a) 所示,为决策树判断某一测试图像块属于何种局部形状结构的过程,图 2(b) 和 (c) 分别是 IVUS 输入图像和随机决策森林的分类概率图.



图2

2.4 边缘关键点的选择和拟合

由于 IVUS 图像中存在复杂干扰因素,其边界检测结果往往出现不少错误分类,如图 2(c) 所示,所以针对这个问题,本文采用结合先验知识方法和设置响应阈值方法进一步抑制大部分的错误分类,接着进行边缘关键点的拟合. 对于导管及其邻近地方和最大圆圈处的错误分类,根据先验知识,上述位置不可能出现中-外膜边缘点,因此可抑制这些误分点. 经过上述的抑制之后,再设置概率阈值 P_h 可进一步筛选某些边缘关键点,即大于等于此阈值的坐标点赋值 1, 否则赋值 0. 如图 3(a) 所示为利用所述两种方法抑制误分类点后获得的概率图像.

完成上述步骤,本文采用椭圆曲线拟合方法对 IVUS 边缘关键点进行拟合,完成整个 IVUS 图像中-外膜组织的边界检测. 利用最小化代数距离,可以求解椭圆方程线性最小二乘拟合问题. 不同的约束选择将得到不同的椭圆拟合结果. 在本文,希望所选择的约束在欧式变换下具有不变性,即具有旋转和平移不变性,可考虑的可能约束有三种: Fitzgibbon 约束^[23]、Gander 约束^[24]和 Bookstein 约束^[25]. 本文采用 Bookstein 约束,因为其具有普适性、简洁性和不变性. 二维直角坐标系下的椭圆一般方程为:

$$Q(x, y) = Ax^2 + Bxy + Cy^2 + Dx + Ey + F = 0 \quad (4)$$

也即

$$F(\mathbf{x}) = \mathbf{x}^T \mathbf{a} \mathbf{x} + \mathbf{b}^T \mathbf{x} + c = 0 \quad (5)$$

其中, $\mathbf{x}^T = (x, y)$, $\mathbf{a} = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix}$, $\mathbf{b}^T = (b_1, b_2)$. 上述两式的关系为: $A = a_{11}$, $B = a_{12} + a_{21}$, $C = a_{22}$, $D = b_1$, $E = b_2$, $F = c$. 最小化代数距离即利用线性最小二乘法求解 $\sum F(\mathbf{x})^2$. Fitzgibbon 约束、Gander 约束和 Bookstein 约束分别为:

$$\det(\mathbf{a}) = \lambda_1 \lambda_2 = 1 \quad (6)$$

$$\text{Trace}(\mathbf{a}) = \lambda_1 + \lambda_2 = 1 \quad (7)$$

$$\lambda_1^2 + \lambda_2^2 = 1 \quad (8)$$

其中, λ_1 和 λ_2 是矩阵 \mathbf{a} 的特征值. 如图 3(b) 所示为拟合椭圆叠加在原始 IVUS 图像上的结果.




图3

3 实验结果及分析

针对 IVUS 图像中-外膜边界检测问题,本文提出了一种基于局部形状结构 LSS 分类的方法. 整个方法主要分为 3 个部分实现: (1) 局部形状结构构建和 IVUS 图像特征提取; (2) 随机决策森林的训练和分类; (3) 边缘关键点的选择和拟合. 本文的边界检测方法如图 4 所示.

3.1 实验材料和参数设置

实验数据使用从南方医科大学南方医院采集的 IVUS 图像数据集 (来源于 7 名患者, 4 男 3 女, 年龄 62 ± 9 岁, 图像 915 ± 142 帧, 血管长度 25.24 ± 2.37 mm, 图像大小为 512×512 , 256 阶灰度, 13 组 IVUS 图像序列). 本文实验实际采用 165 幅典型 IVUS 图像, 其中包含分支、超声阴影、各类斑块、环晕伪影和导丝伪影等复杂情况, 每幅 IVUS 图像均有临床医生人工勾画中-外膜边界结果. 这些图像可提取大约 12 万图像块, 作为训练集和测试集. 数据采集设备是波士顿科学公司的 iLab™ Ultrasound Imaging System, 超声探头为机械式旋转型, 频率为 40MHz, 回撤速度为 0.5mm/s, 采样频率为 30 帧/s. 本文算法采用 MATLAB R2014b 编程实现. 实验参数设置如下: (1) 在 2.1 节中, 设置图像块大小 S 为 35, 聚类类别数量 C 为 20, 积分通道特征数量在 3.3 节详

细介绍,自相似性描绘子中的小区域大小 m 为 7, M 值与 S 值相等;(2)在 2.3 节中,设置构成树的数量 T 为 25,树的深度 L 为 20,终止条件中的 n 为 4,每类 LSS 正

样本为 1000,背景类负样本为 800;(3)在 2.4 节中,概率阈值 P_h 为 0.6.




图4 本文方法的基本流程

3.2 评价标准

中-外膜边界检测性能评价指标^[13,26]主要有交并比指数 (Jaccard Measure, JM)、面积差异百分比 (Percentage of Area Difference, PAD) 和豪斯多夫距离 (Hausdorff Distance, HD),其中, JM 越大、PAD 和 HD 越小,表明算法的边界检测性能越好. 这些评价标准的计算由以下公式定义:

$$JM(R_{\text{auto}}, R_{\text{manual}}) = \frac{R_{\text{auto}} \cap R_{\text{manual}}}{R_{\text{auto}} \cup R_{\text{manual}}} \quad (9)$$

$$PAD(A_{\text{auto}}, A_{\text{manual}}) = \frac{|A_{\text{auto}} - A_{\text{manual}}|}{A_{\text{manual}}} \quad (10)$$

$$HD(C_{\text{auto}}, C_{\text{manual}}) = \max_{a \in C_{\text{auto}}, b \in C_{\text{manual}}} \{ \min [d(a, b)] \} \quad (11)$$

其中,下标 auto 和 manual 分别表示算法自动检测和临床医生人工勾画的边界结果, R 代表区域, A 代表面积, C 代表曲线. 式(9)根据两条边界的坐标来计算两血管区域面积,进而求取区域重叠或者吻合程度. 当算法自动检测的边界所围成区域与医生人工描画的区域完全重叠时, JM 的值为 1; 否则其值小于 1. 式(10)计算两血管区域面积的差异,从而评价两条中-外膜边界的差异. 一般来说, JM 值越小, PAD 的值也越小. 式(11)根据两条边界的坐标来计算两曲线上离异最大的两个点的距离,其中 $d(a, b)$ 为欧式距离. 从距离公式可见, HD 指标首先找到点对点的距离,然后取离异最大的距离. HD 值会考虑图像分辨率/大小,然后进行标准化处理,比如 IVUS 图像中的每一像素点代表实际物理长度 $9/512 \approx 0.02\text{mm}$.

3.3 特征提取的分析

在 2.2 节介绍的特征提取过程中,本文采用积分通道特征 ICF 和自相似性描绘子 SSD. 其中,采用积分通道共 14 个,分别为 1 个灰度通道、2 个梯度通道、3 个梯度强度通道和 8 个定向梯度强度通道,如图 5 所示. 因此,积分通道特征大小为 $35 \times 35 \times 14 = 17150$. ICF 主要收集 IVUS 图像中的底层特征. 对于自相似性特征,由 35×35 图像块聚集成 5×5 个小区域,然后进行对称相减,可获取 $C(25, 2) \times 14 = 4200$ 维特征,如图 6 所示. SSD 主要通过抽象底层特征寻找纹理边界,突显局部边缘的对称性. 因此,最终输入特征向量的维数为 21350. 所选取的两种特征适合描述 LSS,并且具有较高级语义

信息的 LSS 可索引 ICF 和 SSD 特征,随机决策森林据此可表达底层特征和高层语义特征之间的复杂非线性关系. 具体来说,图 5 中的 (a) ~ (d)、(e) 和 (j) 可观察到被突显的 IVUS 图像中-外膜边界,而 (f) ~ (i) 和 (k) ~ (n) 进一步提取 4 个固定方向的梯度强度信息;图 6 中的来自不同 IVUS 图像的正例和反例训练图像块具有明显的差异,也即图 6 (a) 和 (b) 同属于某类 LSS,因此有着相似的纹理特征,SSD 突显纹理边界/局部边缘,而图 6 (c) 和 (d) 同属于背景类,并没有相似的局部纹理,更没有感兴趣 IVUS 中-外膜局部边界.




图5 积分通道特征ICF




图6 自相似性描绘子SSD

3.4 算法结果的分析

为评估本文方法进行 IVUS 图像中-外膜边界检测

的有效性和鲁棒性,本文采用5折交叉验证^[27]的方法测试所提出边界检测算法的性能.首先,将南方医院数据集165帧代表性IVUS图像分成 $165/33=5$ 组;然后,使用132帧图像作为训练数据,把剩余33帧图像作为测试数据,一共进行5轮实验.如表1所示为5个分类模型进行交叉验证的结果.注意,JM, PAD和HD分别表示三个性能评价指标的平均值.根据表1三个评价标准得分,实验结果表明,本文方法对5个测试子数据集进行中-外膜边界检测是鲁棒的,其JM达到了88.9%,PAD和HD分别7.14%、0.3390mm.实验结果还表明,在具有代表性的165帧IVUS图像上,本文方法的检测结果与临床医生人工勾画的结果非常接近.

表1 五个分类模型进行交叉验证的结果比较

模型	1	2	3	4	5	平均
JM	0.8795	0.9076	0.8786	0.8808	0.8965	0.8886
PAD(%)	8.43	5.28	9.76	6.07	6.14	7.14
HD(mm)	0.3782	0.3097	0.3929	0.3214	0.2929	0.3390

为评估基于局部形状结分类方法的优越性,本文方法的边界检测结果与基于直接检测的方法文献[4]、基于监督学习的方法文献[10]进行比较.文献[4]提出一种结合硬斑块识别以及改进后的图像梯度信息的IVUS图像中-外膜边界检测算法.该算法的特点是通过 k -均值聚类对图像灰度值进行分割并识别出钙化斑块和纤维斑块,解决硬斑块对中-外膜边界检测算法的干扰问题,同时补偿超声阴影区域能量值,克服声影造成的信号缺失问题.而文献[10]提出一种结合多类多尺度序贯学习和先验形状信息的IVUS图像中-外膜边界检测算法.该方法的特点首先利用监督学习对IVUS图像进行组织(7种)分割并获取内膜区域和外膜间关系,然后收集外弹力膜轮廓的“关键点”,最后结合血管横截面的先验形状信息——光滑的椭圆形状,成功检测出目标边界,这两种算法是近年来性能较好的中-外膜边界检测方法,在南方医院数据集165帧代表性IVUS图像上,本文方法与文献[4,10]两种算法进行了性能评估和比较.根据表2 JM评价标准得分,实验结果表明,本文方法明显优于文献[4]的算法,稍微优于文献[10]的算法,其所获取的中-外膜边界更贴近临床医生人工勾画的轮廓.此外,根据表2 PAD和HD两个评价标准得分,实验结果表明,本文方法比文献[10]的算法更加紧致地检测出中-外膜边界.

表2 三种边界检测方法在南方医院数据集上的结果比较

方法	JM	PAD(%)	HD(mm)
文献[4]	0.8132	24.18	0.7356
文献[10]	0.8850	8.83	0.3755
本文	0.8886	7.14	0.3390

如图7所示为采用本文方法、文献[4]和文献[10]获取的中-外膜边界检测结果,其中包括了正常、含钙化斑块、纤维斑块3种情况的IVUS图像检测实例.实验结果表明,与文献[4]基于图像梯度信息的算法和文献[10]基于组织区域信息的算法相比,本文算法和文献[10]提取的中-外膜边界可以不受钙化斑块和超声阴影的影响,如图7(b)所示;而文献[4]的方法易受超声阴影的干扰,这类影响甚至导致其检测失败.本文算法通过检测超声阴影截断中-外膜边界以外的关键点,利用椭圆拟合的方法连接这些关键点,从而误差较少地、紧凑地跨越声影区域/信号缺失区域.此外,本文算法在正常情况下提取的目标边界可以不受导丝伪影影响,如图7(a)第2行所示,也不受纤维斑块的影响,如图7(c)第2、4行所示.文献[4]和文献[10]的算法对图7(a)第3行血管分支实例图的检测有着非常大的误差.文献[10]的算法因有监督分类误判的血管区轮廓符合冠脉血管的凹凸性要求而导致算法无法校正误差,从而无法正确检测外弹力膜轮廓.当IVUS图像存在血管分支时,本文算法的检测就会受到一定的影响.具体来说,当血管分支离中-外膜比较远的时候,算法检测结果就受到比较大的影响,如图7(c)第2行所示;而如果侧支血管离中-外膜稍微近的时候,本文算法则受




图7 中-外膜检测实例

到的影响会比较小,如图 7(a)第 4 行所示. 因为血管分支的轮廓和中-外膜边界的局部形状结构在低级特征和高级语义上都是相似的,所以本文方法误判侧支血管的关键点为中-外膜边界的关键点,从而造成算法存在或大或小的检测误差. 总之,本文算法采用各类 IVUS 图像中-外膜共同具有的特点——LSS 以及有监督多分类模型,较为成功地检测到中-外膜边界的关键点;同时,利用阈值处理收集具有高概率的边缘关键点,采用满足血管曲率的椭圆拟合方法连接这些关键点,最终较鲁棒、较准确地完成整条目标边界的检测. 除此之外,利用本文算法检测一幅 IVUS 图像的中-外膜边界仅仅需要 2s,可满足临床医生的处理需求.

4 结论

本文针对心血管内超声图像中钙化斑块、导丝伪影、超声阴影等影响 IVUS 图像中-外膜边界检测准确性的困难,提出了基于局部形状结构分类的心血管内超声中-外膜边界检测算法. 本文方法在挑选的具有代表性的 165 帧 IVUS 图像进行实验,并与两种近年来性能较好的算法进行比较. 实验结果表明,本文方法能够有效地克服典型影响中-外膜边界检测准确性的问题,相比已有算法,更准确地识别目标边界的关键点,从而成功地检测出完整的中-外膜边界. 本文算法也存在一定的局限性. 具体地,对检测结果进行分析,发现血管分支与目标血管的局部形状结构非常相似,导致本文分类模型误判分支血管边界的关键点为目标血管的关键点,从而造成检测误差较大或者直接检测失效,进一步地损害了本文方法的自动化特性.

参考文献

- [1] 舍恩哈根, Defranco, 尼森. 轻松掌握血管内超声[M]. 刘茜蓓, 刘健, 陈芸, 译. 北京: 人民军医出版社, 2009. 1 - 31.
Schoenhagen P, Defranco A, Nissen S E, Tuzcu E M. An Introduction to Coronary Intravascular Ultrasound Imaging [M]. Liu Qian-qian, Liu Jian, Chen Yun, Trans. Beijing: People's Military Medical Press, 2009. 1 - 31. (in Chinese)
- [2] 汪友生. 血管壁小应变数学模型研究[J]. 电子学报, 2014, 42(10): 2086 - 2091.
WANG You-sheng. Research on small strain mathematics model of vessel wall[J]. Acta Electronica Sinica, 2014, 42(10): 2086 - 2091. (in Chinese)
- [3] 李春芳, 杨鑫, 张旭明, 丁明跃. 基于 MAP 的超声图像分解去噪算法研究[J]. 电子学报, 2014, 42(7): 1291 - 1298.
LI Chun-fang, YANG Xin, ZHANG Xu-ming, DING Ming-yue. MAP based ultrasound image decomposition and denoising method[J]. Acta Electronica Sinica, 2014, 42(7): 1291 - 1298. (in Chinese)
- [4] 邢东, 杨丰, 黄靖, 等. 结合硬斑块特征的心血管内超声图像中-外膜边缘检测[J]. 中国生物医学工程学报, 2012, 31(1): 25 - 31.
Xing Dong, Yang Feng, Huang Jing, et al. Hard plaque characteristics based media-adventitia border detection in intravascular ultrasound images[J]. Chinese Journal of Biomedical Engineering, 2012, 31(1): 25 - 31. (in Chinese)
- [5] Giannoglou G D, Chatzizisis Y S, Koutkias V, et al. A novel active contour model for fully automated segmentation of intravascular ultrasound images; In vivo validation in human coronary arteries[J]. Computers in Biology and Medicine, 2007, 39(7): 1292 - 1302.
- [6] Essa E, Xie Xiang-hua, Sazonov I, et al. Shape prior model for media-adventitia border segmentation in IVUS using graph cut[A]. International MICCAI Workshop in Medical Computer Vision [C]. Heidelberg, Berlin: Springer, 2012. 114 - 123.
- [7] Unal G, Bucher S, Carlier S, et al. Shape-driven segmentation of the arterial wall in intravascular ultrasound images [J]. IEEE Transactions on Information Technology in Biomedicine, 2008, 12(3): 335 - 347.
- [8] Mendizabal-Ruiz E G, Rivera M, Kakadiaris I A. Segmentation of the luminal border in intravascular ultrasound B-mode images using a probabilistic approach [J]. Medical Image Analysis, 2013, 17(6): 649 - 670.
- [9] Rotger D, Radeva P, Fernandez-Nofrerias E, Mauri J. Blood detection in IVUS images for 3D volume of lumen changes measurement due to different drugs administration[A]. International Conference on Computer Analysis of Images and Patterns [C]. Heidelberg, Berlin: Springer, 2007. 285 - 292.
- [10] 林慕丹, 杨丰, 梁淑君, 等. 结合先验形状信息和序贯学习的心血管内超外弹力膜检测[J]. 中国图象图形学报, 2016, 21(5): 646 - 656.
Lin Mu-dan, Yang Feng, Liang Shu-jun, et al. External elastic membrane border detection based on sequential learning and prior shape information for intravascular ultrasound images [J]. Journal of Image and Graphics, 2016, 21(5): 646 - 656. (in Chinese)
- [11] Papadogiorgaki M, Mezaris V, Chatzizisis Y S, et al. Image analysis techniques for automated IVUS contour detection[J]. Ultrasound in Medicine & Biology, 2008, 34(9): 1482 - 1498.
- [12] Lim J J, Zitnick C L, Dollar P. Sketch tokens: a learned mid-level representation for contour and object detection [A]. Proceedings of IEEE Conference on Computer Vi-

- sion and Pattern Recognition [C]. USA: IEEE, 2013. 3158 – 3165.
- [13] Katouzian A, Angelini E D, Carlier S G, et al. A state-of-the-art review on segmentation algorithms in intravascular ultrasound (IVUS) images [J]. IEEE Transactions on Information Technology in Biomedicine, 2012, 16(5): 823 – 834.
- [14] 魏静明, 李应. 利用抗噪纹理特征的快速鸟鸣声识别 [J]. 电子学报, 2015, 43(1): 185 – 190.
WEI Jing-ming, LI Ying. Rapid bird sound recognition using anti-noise texture features [J]. Acta Electronica Sinica, 2015, 43(1): 185 – 190. (in Chinese)
- [15] Tola E, Lepetit V, Fua P. A fast local descriptor for dense matching [A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition [C]. USA: IEEE, 2008. 1 – 8.
- [16] Lloyd S. Least squares quantization in PCM [J]. IEEE Transactions on Information Theory, 1982, 28(2): 129 – 137.
- [17] Arthur D, Vassilvitskii S. k-means++: The advantages of careful seeding [A]. Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms [C]. USA: ACM, 2007. 1027 – 1035.
- [18] Dollar P, Tu Zhuo-wen, Perona P, Belongie S. Integral channel features [A]. Proceedings of the British Machine Vision Conference [C]. London UK: BMVC Press, 2009. 91 – 101.
- [19] Shechtman E, Irani M. Matching local self-similarities across images and videos [A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition [C]. USA: IEEE, 2007. 1 – 8.
- [20] Canny J. A computational approach to edge detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1986, 8(6): 679 – 698.
- [21] Breiman L. Random forests [J]. Machine Learning, 2001, 45(1): 5 – 32.
- [22] Criminisi A, Shotton J, Konukoglu E. Decision forests: a unified framework for classification, regression, density estimation, manifold learning and semi-supervised learning [J]. Foundations and Trends in Computer Graphics and Vision, 2012, 7(2–3): 81 – 227.
- [23] Fitzgibbon A, Pilu M, Fisher R B. Direct least square fitting of ellipses [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1999, 21(5): 476 – 480.
- [24] Gander W, Golub G H, Strebel R. Least-squares fitting of circles and ellipses [J]. BIT Numerical Mathematics, 1994, 34(4): 558 – 578.
- [25] Bookstein F L. Fitting conic sections to scattered data [J]. Computer Graphics and Image Processing, 1979, 9(1): 56 – 71.
- [26] Balocco S, Gatta C, Ciompi F, et al. Standardized evaluation methodology and reference database for evaluating IVUS image segmentation [J]. Computerized Medical Imaging and Graphics, 2014, 38(2): 70 – 90.
- [27] Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection [A]. International Joint Conference on Artificial Intelligence [C]. 1995. 1137 – 1145.

作者简介



袁绍锋 男, 1991 年 1 月出生于广东省东莞市. 南方医科大学生物医学工程学院硕士研究生, 主要研究方向为机器学习与医学图像处理、深度学习与计算机视觉等.
E-mail: shaofeng.yuan.smu@gmail.com



杨丰(通信作者) 男, 1965 年 10 月出生于湖北省荆门市. 博士, 南方医科大学生物医学工程学院教授、博士生导师, 主要研究方向为模式识别、机器学习、医学图像处理、生物医学信号处理等.
E-mail: yangf@smu.edu.cn