

基于血管内超声图像的心血管动脉粥样硬化斑块组织自动定征的研究

黄志杰 王伊依 王 青

(南方医科大学生物医学工程学院医学信息研究所 广州 510515)

(南方医科大学广东省医学图像重点实验室 广州 510515)

摘 要 为了获取患者血管内斑块特征的准确信息,并辅助临床医生对动脉粥样硬化区域进行判断和识别,文中进行了基于血管内超声(IVUS)图像的心血管粥样硬化斑块组织自动定征的研究。本研究收集了 10 个心血管疾病患者的 IVUS 图像,共 207 块斑块样本。首先,确定滑动邻域块的尺寸,令其中心像素遍历斑块区域,遍历过程中计算每个滑动邻域块的灰度均值和熵,并沿 4 个方向运用灰度共生矩阵法求出共生矩阵的 10 个局部特征;然后,对 IVUS 图像进行 Gabor 滤波和局部二值模式(LBP)处理,获得了更多的图像纹理特征;最后,通过线性分类器 Liblinear、随机森林分类器(Random Forests)和调和最小值-广义学习向量量化分类器(H2M-GLVQ)对降维后的特征数据进行分类判决。将医生人工标记的结果作为金标准,自动定征的实验结果表明,随机森林和 H2M-GLVQ 分类器总体上对斑块组织的识别准确率均达到 80% 以上,其中随机森林分类器识别纤维化、脂质和钙化样本斑块的平均识别准确率分别为 89.04%,80.23%和 73.77%。

关键词 血管内超声图像,自动定征,纹理特征,分类判决

中图法分类号 TN919.85

文献标识码 A

DOI 10.11896/j.issn.1002-137X.2018.05.045

Automatic Characterization Study of Atherothrombotic Plaques Based on Intravascular Ultrasound Images

HUANG Zhi-jie WANG Yi-nong WANG Qing

(Institute of Medical Information, School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China)

(Guangdong Provincial Key Laboratory of Medical Image Processing, Southern Medical University, Guangzhou 510515, China)

Abstract In order to obtain the accurate information of atherothrombotic plaques in the cardiovascular and assist the diagnosis and classification of the plaque tissues, this study applied a machine learning method to automatically characterize the atherothrombotic plaques in intravascular ultrasound(IVUS) grayscale images. In this study, 207 plaque samples in the IVUS images were collected from 10 patients with cardiovascular disease in the hospital. Firstly, the size of a sliding patch is determined and then its centre pixel traverses in the plaque area. The values of the mean and entropy are calculated. Ten features of the patch along 4 directions are respectively obtained by using co-occurrence matrix method. Secondly, more texture features of the plaque region in the IVUS images are obtained by using Gabor filter and local binary pattern(LBP) methods. Finally, the classifiers of Liblinear, random forests and Harmonic to Minimum-Generalized LVQ(H2M-GLVQ) are used to classify these pixels in the plaque tissues based on the features obtained through reducing dimension by using principal component analysis(PCA). The manual characterization by an experienced physician is considered as the gold standard. Results of the proposed automatic characterization method show the general identification rates of classifiers of random forests and H2M-GLVQ are over 80%. Compared with other two classifiers, the identification rate of random forests is relatively higher, i. e. 89.04%, 80.23% and 73.77% respectively for fibrotic, lipidic and calcified plaque tissues.

Keywords Intravascular ultrasound image, Automatic characterization, Texture features, Classification judgment

到稿日期:2017-06-24 返修日期:2017-12-02 本文受广东省自然科学基金(2014A030313329),国家自然科学基金(81371560),广东省省级科技计划基金(2013B021800039)资助。

黄志杰(1992-),男,硕士,主要研究方向为血管内超声成像、图像处理;王伊依(1993-),女,博士,主要研究方向为生物医学超声成像、图像处理;王青(1970-),女,副教授,主要研究方向为生物医学超声、图像处理,E-mail:wq8740@smu.edu.cn(通信作者)。

1 引言

心血管疾病已成为导致全球人类死亡的主要原因,其中冠心病等疾病正逐渐剥夺越来越多人的生命^[1]。动脉粥样硬化是一种影响动脉血管壁的增生性炎症,是易引起心脑血管类致命疾病的潜在状态^[2]。随着超声影像技术的发展,一种重要的介入影像技术逐步形成,即血管内超声(Intravascular Ultrasound, IVUS)^[3]。IVUS 通过将导管顶端的微小超声探头置于血管内,在导管回撤过程中获取血管内腔和血管壁的图像。目前,IVUS 可为临床提供血管的可视化观察和检测,有助于获取动脉粥样硬化斑块的成分和形态等信息,从而对斑块的稳定性和风险性进行有效评估。

由于管腔内不同组织结构的超声波回声不同,因此 IVUS 图像可以显示出血管腔壁的结构。临床上,医生主要根据经验对斑块进行识别判断,因此主观性较强。近年来,IVUS 新技术发展迅速,如虚拟组织技术(Virtual Histology IVUS, VH-IVUS)及弹性技术(IVUS Elastography, IVUS-E)。VH-IVUS 技术利用反向散射的超声射频信号,通过功率频谱处理(包括傅里叶转换、韦尔奇功率频谱和自动回归模型等)进行特征提取来识别斑块成分。该方法虽然可进行斑块组织学分类,并重建类似组织病理切片的组织分类图像^[4-6],但仍具有局限性,如 VH-IVUS 图像中各组织成分的边界的识别能力较差,通常需要手动校准,并且图像重建时间较长。IVUS-E 通过检测动脉内斑块的机械力学特性来评估斑块的硬度性质^[7],但仅依靠力学参数很难区分纤维组织与脂质组织,而且与斑块破裂率及破裂位置之间的关系尚未明确。

IVUS 图像纹理丰富,富含灰阶信息^[8-9],可以提取多个图像特征,基于这些特征值可进行血管内不同斑块组织的识别。目前有多种特征提取方法,如灰度共生矩阵法、Gabor 滤波、局部二值模式(Local Binary Pattern, LBP)等方法,其中灰度共生矩阵法所提取的特征可用于 IVUS 图像中斑块区域的局部模式和排列规则的分析,但是仅使用灰度共生矩阵法对 IVUS 图像斑块进行分类识别,难以区分纤维化和脂质化斑块^[10-11]。Gabor 滤波器是一种具有多尺度特性的滤波器,其频率和方向表达与人类视觉系统类似,因此适用于提取图像的纹理特征^[12]。而 LBP 是由 Ojala 等提出的一种利用局部处理方法提取整幅图像纹理特征的方法^[13-14],它反映了每个像素与周围像素的关系,具有旋转不变性和灰度不变性等显著的优点,适用于提取 IVUS 图像的纹理特征。

因此,本研究利用灰度共生矩阵、Gabor 滤波和 LBP 等多种方法来提取 IVUS 图像的纹理特征,并结合均值和熵两个特征对所有图像特征进行归一化处理,同时通过主成分分析(Principal Component Analysis, PCA)方法降维处理特征数据,最后进行斑块组织的三分类识别。采用的分类器是线性支持向量机分类器 Liblinear^[15]、随机森林(Random Forests)^[16]与调和最小值-广义学习向量量化(Harmonic to Minimum-Generalized LVQ, H2M-GLVQ)^[17-18]。本研究比较了 3 种分类器的纤维化、脂质和钙化斑块的自动识别效果,并与一种利用 Gentle AdaBoost 分类器的两次二分类方法^[19]的识别效果进行了对比。

2 方法

2.1 斑块样本库的建立

IVUS 图像由南方医科大学南方医院心内科提供,数据来自于 10 个心血管疾病患者。采用冠脉超声成像导管(Atlantis SR Pro, America)进行 IVUS 图像采集,配有 2.9F, 40MHz 的超声探头,由步进电机驱动,回撤速度为 0.5mm/s。本研究共采集了 10 位心血管疾病患者的 143 张斑块 IVUS 图像,共计 207 块斑块样本,同时聘请了有经验的医生来鉴别每张 IVUS 图像中的斑块性质,并对其进行手工标记,从而建立斑块样本库,其中包含纤维斑块 91 块,脂质斑块 66 块和钙化斑块 50 块。图 1 给出了典型的纤维斑块、脂质斑块、钙化斑块的 IVUS 图像。




图 1 动脉粥样硬化 IVUS 图像及斑块组织放大图像
Fig. 1 IVUS image of atherosclerotic plaques and enlarged images of plaque tissue

2.2 斑块特征的提取方法

2.2.1 滑动邻域块的选择

如图 2 所示,基于医生标记的斑块区域,建立滑动邻域块,令其中心像素遍历斑块区域的每个像素点,并提取斑块区域的局部特征,包括滑动邻域块的灰度均值和熵,以及灰度共生矩阵的特征值。




图 2 3×3 滑动邻域块遍历整个斑块区域的示意图
Fig. 2 Schematic of 3×3 sliding patch traversing entire area of plaque tissue

为了分析滑动邻域块的尺寸对基于局部特征的斑块识别率的影响,确定了滑动邻域块的最佳尺寸,本研究选取了多个尺寸,分别为 7×7, 9×9, 11×11, 13×13, 15×15, 17×17 和 19×19(像素×像素),并定义了识别准确率(见式(1))来评价不同尺寸的滑动邻域块对基于局部特征的斑块识别准确率的影响。

$$\begin{cases} AC_i = \frac{N_{i_correct}}{N_{i_total}} \times 100\% \\ AC_{overall} = \sum_{i=1}^k \left(\frac{N_{i_total}}{N_{totalROI}} \times AC_i \right) \times 100\% \end{cases} \quad (1)$$

其中, $k=2, 3$ 。 AC_i 是第 i 类斑块样本块的识别准确率; $N_{i_correct}$ 是被正确分类的第 i 类斑块的像素数目; N_{i_total} 是第 i 类斑块

样本块的像素总数数目; AC_{overall} 是样本块的总体识别准确率; $N_{i_{\text{total}}}$ 是第 i 类斑块样本块的像素总数; N_{totalROI} 是用于测试的全部样本块的像素总数。

2.2.2 灰度均值和灰度熵的计算

如图 2 所示,在滑动邻域块遍历斑块区域中的每个像素点的过程中,计算滑动邻域块的灰度均值和熵。滑动邻域块的灰度均值和灰度熵的计算式如下:

$$f_{\text{mean}} = \frac{1}{M} \sum_{(x,y) \in N} P(x,y) \quad (2)$$

$$H_{\text{entropy}} = \sum_{i=0}^{L-1} p_i \log_2(p_i) \quad (3)$$

其中, N 是滑动邻域块; (x, y) 是在滑动邻域块内的坐标; $P(x, y)$ 是像素点 (x, y) 的灰度值; M 是滑动邻域块内像素点总数; L 是指 256 级灰度值; p_i 为第 i 灰度级在滑块 N 中出现的概率。

2.2.3 灰度共生矩阵法

利用不同尺寸的滑动邻域块,分别在 $0^\circ, 45^\circ, 90^\circ$ 和 135° 4 个角度方向上计算共生矩阵,并根据共生矩阵统计出自相关系数、对比度、能量、熵等 10 个灰度共生矩阵特征参数^[20],并将这些灰度共生矩阵特征参数与上述灰度均值和灰度熵相结合,形成一个新的特征数据集,以探究像素块尺寸对斑块识别准确率的影响,从而确定滑动邻域块的最佳尺寸。

2.2.4 Gabor 滤波器

Gabor 滤波器可检测图像中不同方向和角度上的边缘和线条。式(4)为二维 Gabor 滤波器的计算式,在空间域中二维 Gabor 滤波器可描述为一个由正弦平面波调制的高斯核函数。

$$G(x,y) = \left(\frac{1}{2\pi\sigma_x\sigma_y} \right) \times \exp\left(j \frac{2\pi x'}{\lambda} + \phi\right) \times \exp\left[-\frac{1}{2} \left(\left(\frac{x'}{\sigma_x} \right)^2 + \left(\frac{y'}{\sigma_y} \right)^2 \right)\right] \quad (4)$$

其中, $x' = x \cos \theta + y \sin \theta$, $y' = -x \sin \theta + y \cos \theta$ 。 x' 和 y' 分别代表空间坐标 (x, y) 旋转某一角度 θ 之后的坐标; θ 表示滤波器的方向; σ_x 和 σ_y 是高斯型包络的标准差; λ 是 Gabor 滤波核的波长,其值以像素为单位,决定着 σ_x 和 σ_y 的数值。在提取图像特征时,分别设置 θ 和 λ 如下: $\theta = [0, \pi/8, \pi/4, 3\pi/8, \pi/2, 5\pi/8, 3\pi/4, 7\pi/8]$, $\lambda = [10, 14, 14, 20, 28, 28, 40]$ 。

2.2.5 局部二值模式(LBP)

LBP 算法是一种纹理图像特征提取方法,原始的 LBP 定义为 8 邻域,即 3×3 像素块。将中心像素点的灰度值作为阈值,把邻域的 8 个像素点的灰度值与之进行比较,二值化后,再与对应位置像素的权重值相乘、求和,从而获得该像素点的 LBP 值。同样地,本研究选取的邻近点离中心像素距离(即半径 R)为 1、2 和 3 像素,其圆形邻域所包含的邻域点数分别为 8、16 和 24,然后计算 LBP 值,如式(5)所示:

$$LBP_{P,R}(x_c, y_c) = \sum_{i=0}^{p-1} s(g_p - g_c) \times 2^i \quad (5)$$

其中, $s(t) = \begin{cases} 1, & t > 0 \\ 0, & t < 0 \end{cases}$ 。 g_c 为中心像素点的灰度值; p 代表中心像素点 (x_c, y_c) 周围邻域像素点的数目; g_p 表示第 p 个邻域像素点的灰度值。

本研究通过上述方法获得 IVUS 图像的纹理特征之后,归一化处理特征数据,再进行 PCA 降维,然后进行斑块组织类别的识别。

2.3 斑块分类的判决

动脉粥样硬化斑块一般可分为纤维斑块、钙化斑块、脂质斑块和混合性斑块。不同类型的斑块组织具有不同的声学特征。在 IVUS 图像中,脂质斑块表现为低回声区,透声性强;纤维斑块的回声强度与钙化斑块接近,不伴随声影出现;钙化斑块回声最强,往往伴随声影出现。若斑块区域混有两种或两种以上类型的斑块组织的声学特征,则此类斑块为混合性斑块^[21]。因此,本研究将对 IVUS 图像中的斑块区域进行分类,即识别纤维化、脂质和钙化斑块组织成分。

基于上一节所提取的图像特征,本研究对比研究 3 种分类器(即线性支持向量机(Liblinear)、随机森林和调和最小值-广义相关学习向量量化(H2M-GLVQ)分类器)对斑块区域内 3 类斑块组成成分的识别效果,并与一种利用 Gentle Ada-Boost 分类器的两次二分类方法的识别效果进行对比。

2.3.1 Liblinear 分类方法

由于本研究采用了基于斑块区域像素的图像特征提取方法,因此收集到的特征数据是一个大数据量的样本集。传统的支持向量机(SVM)处理大规模、大数据的样本集时,具有运行效率低下、耗时长等局限性。因此,尝试通过 Liblinear 分类器来突破传统 SVM 的局限性,从而提高算法的运行效率。

2.3.2 随机森林分类方法

随机森林(Random Forests)是一种集成学习的方法,利用 bootstrap 重抽样方法从原始样本中抽取多个样本,对每个 bootstrap 样本进行决策树建模,然后组合多棵决策树的预测,通过投票得出最终预测结果,其实质是对决策树算法的一种改进。组成森林的每棵树具有相同的分布,分类准确率与每棵树的决策能力和它们之间的相关性有关。本文将随机森林分类器的决策树数目设置为 300。

2.3.3 H2M-GLVQ 分类方法

学习向量量化(Learning Vector Quantization, LVQ)通过寻找一组原型向量来刻画聚类结构。如果数据样本带有类别标记,则可以在学习过程中利用样本的这些标记信息来辅助聚类。其基本原理是对样本集的各维度分配权重,形成原型向量即神经元权向量,不断迭代选取样本以更新原型,直到在整个数据集的空间分布中找到各类样本的原型,最后利用输出的原型向量和最近邻法实现识别。

为了提高收敛速度和更好地促使神经网络收敛至局部最小,有学者提出了 H2M-GLVQ,并基于 LVQ 进行了如下改进^[22]: 1) 通过最小化能量函数,限制每一次迭代过程中权向量的更新步长,确保权向量的快速收敛,从而得到广义学习向量量化分类器(GLVQ); 2) 在 GLVQ 算法中,定义所选取的训练样本到最近的同类权向量的距离以及到异类权向量的距离分别为 d_k 和 d_l ,根据 K 调和均值算法,用调和平均距离 d_k^H 和 d_l^H 代替最小距离 d_k 和 d_l ,从而得到 H2M-GLVQ。

综上所述,本研究运用机器学习的方法处理 207 块斑块样本,并进行斑块组织成分的识别。图 3 为本研究所提出的实验方法的流程图。

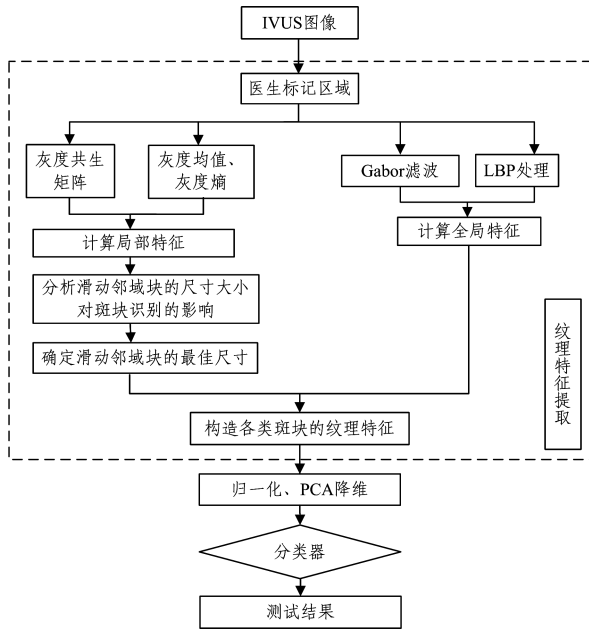


图 3 本研究整体流程图

Fig. 3 Global flowchart of this study

3 结果与讨论

3.1 滑动邻域块尺寸对斑块识别准确率的影响

为了更充分、可靠地利用样本库,将样本库随机分成了 5 个部分,将其中 4 个部分作为分类器的训练集,剩下 1 个部分作为分类器的测试集。其中,每一部分都有 3 种斑块的 IVUS 图像。从 4 个部分中的每种斑块样本抽取 300 个点构成训练组;从剩下的 1 个部分中随机抽取 3 块不同的斑块样本构成测试组,5 个部分轮流进行训练和测试。由式(1)计算得出每种分类器对于不同滑动邻域块的总体识别准确率,即 $AC_{overall}$ 值。

本研究中,滑动邻域块的尺寸大小分别是: $7 \times 7, 9 \times 9, 11 \times 11, 13 \times 13, 15 \times 15, 17 \times 17$ 和 19×19 。基于这 7 个滑动邻域块获得图像特征数据后,利用 Liblinear、随机森林和 H2M-GLVQ 这 3 个分类器对斑块区域内的像素进行类型识别。将医生的人工标记结果作为金标准,基于不同大小的滑动邻域块的自动定征结果如图 4 所示。




图 4 3 种分类器的组织分类总体准确率 $AC_{overall}$ 与滑动邻域块尺寸的关系

Fig. 4 Relationship between overall accuracy $AC_{overall}$ of three classifiers and size of sliding patches


由图 4 可知,随着滑动邻域块尺寸的增大,斑块区域的 $AC_{overall}$ 逐渐升高,且尺寸在 15×15 像素之后,随机森林和 H2M-GLVQ 的变化趋势较为平缓,而 Liblinear 曲线则有轻

微下降的趋势。因此,从整体上考虑,本研究选择像素为 15×15 的滑动邻域块来对测试图像的斑块区域进行局部特征提取。


另外,研究发现,Liblinear 分类器的识别准确率明显低于随机森林和 H2M-GLVQ 分类器,如滑动邻域块为 15×15 时,Liblinear 分类器的 $AC_{overall}$ 值仅为 80.62%,而后两个分类器的识别率分别为 86.46% 和 86.64%。H2M-GLVQ 的总体识别能力较强,这可能是由于 Liblinear 对于非线性模型的性能较差,使得其平均分类准确率比其他两个分类器都要低。

3.2 Gabor 滤波和 LBP 的斑块全局特征结果

如图 5 所示,利用不同尺度和方向的 Gabor 滤波器对 IVUS 图像提取特征,所提取的特征与滤波器的方向角度 θ 和 Gabor 滤波核的波长 λ 有关。可见,Gabor 滤波在 90° 的方向上比较敏感,可识别出斑块,其中钙化斑块较为清晰。当 λ 较小时,所得特征图像比较模糊。随着 λ 的增大,斑块表现得越来越明显,纹理特征也越来越突出。



(a) IVUS 原图



(b) Gabor 滤波处理结果

图 5 不同方向和尺度下 IVUS 图像的 Gabor 滤波处理结果
Fig. 5 Results of IVUS images processed by Gabor filtering in different directions and scales

图 6 给出了 LBP 特征图像。基于不同半径值 R 和不同像素点数值 P 的圆形邻域对图像进行局部二值处理,可见,半径 R 为 1、像素点 P 为 8 的 LBP 图能体现出更细微的纹理特点,而随着半径的增加和邻域像素点的增多,图像的纹理细节的表现得越来越模糊。




图 6 IVUS 图像(图 5(a))的 LBP 处理结果

Fig. 6 Results of IVUS images processed by LBP

3.3 斑块区域的组织成分的识别结果

本研究选取 5 张 IVUS 图像(图 7 第 1 列的 5 张图像)作

为测试图像。经过本文提出的机器学习方法可对 IVUS 图像自动定征,识别出纤维、脂质和钙化斑块组织,如图 7 中的第 3—5 列所示,其分别为经过 Liblinear、随机森林和 H2M-GLVQ 分类器的斑块组织成分的识别结果,图 7 中灰色区域是纤维斑块,浅灰色区域是脂质斑块,深灰色区域是钙化斑块。




图 7 5 张用于测试的 IVUS 图像及斑块识别结果

Fig. 7 Five IVUS test images and resultant images of classified plaques

将医生的手动标定结果作为金标准(图 7 中的第 2 列),对比研究 3 种分类器对 5 张测试图的总体识别表现,如表 1 所列。可见,Liblinear 分类器对测试图的斑块组织成分的总体识别准确率比较低,而随机森林和 H2M-GLVQ 分类器对测试图的斑块组织成分的总体识别准确率均在 80% 以上,且 H2M-GLVQ 的总体识别准确率稍高。对于含有不同类型斑块的 IVUS 图像,H2M-GLVQ 的总体识别准确率较稳定。

表 1 3 种分类器对测试图的总体识别准确率

Table 1 Overall accuracy of three classifiers for test images

测试图	医生标记的斑块结果	3 种分类器对测试图 $AC_{overall}$ 的值/%		
		Liblinear	随机森林	H2M-GLVQ
图 7(a)	纤维 脂质	61.77	82.69	84.60
图 7(b)	纤维 脂质	74.38	80.02	82.97
图 7(c)	纤维 钙化	89.53	91.26	91.05
图 7(d)	纤维 脂质 钙化	81.36	85.33	87.02
图 7(e)	纤维 脂质 钙化	84.44	87.34	87.60

从图 7(a)、图 7(b)以及表 1 可以看出,IVUS 图中的纤维斑块和脂质斑块能被随机森林和 H2M-GLVQ 分类器较好地识别。但结合图 7(c)—图 7(e)分析,钙化斑块会被误分为纤维斑块,纤维斑块也常会被误分为钙化斑块。分类器对测试图 中所含斑块的识别准确率如表 2 所列。从表 2 中可以看出,Liblinear 和 H2M-GLVQ 分类器对钙化斑块组织的识别表现不佳,其中可能的主要原因是纤维斑块的回声强度与钙化斑块接近,因此钙化斑块区域和纤维化斑块区域容易被互

相错判。只有在钙化特征明显的区域,钙化斑块才易于被识别。而随机森林分类器对钙化斑块组织的平均识别准确率稍高,达到 73.77%。这 3 种分类器对纤维斑块和脂质斑块的识别准确率均较高。而从分类器所需的判决时间上看,随机森林分类器的测试平均用时约为 84.10 s,而 Liblinear 和 H2M-GLVQ 分类器测试所用的平均用时分别为 20.38 s 和 701.03 s。因此,综合考虑 3 种分类器的时间和性能,随机森林分类器对 3 种斑块识别表现更好,更适合对 IVUS 图像斑块进行分类识别。

表 2 分类器对测试图中所含斑块的识别准确率

Table 2 Accuracy of classifiers in classifying different types of plaque tissue

分类器	3 类斑块的 AC_i 平均值		
	纤维化	脂质	钙化
Liblinear	84.43	67.63	66.15
随机森林	89.17	80.23	73.77
H2M-GLVQ	85.22	89.50	57.95

(单位:%)

3.4 三分类与两次二分类的结果比较

已有学者提出了一种利用 Gentle AdaBoost 分类器进行两次二分类的方法来完成纤维化、脂质和钙化 3 种斑块的识别^[19],而本研究所采用的分类器可直接完成斑块组织的三分类。为对比两种方法的分类效果,本研究分别采用 Gentle AdaBoost 分类器的两次二分类方法和随机森林分类器的三分类方法来处理图 7 中的 5 张 IVUS 原图(即图 7 中的第 1 列),其对比结果如表 3 所列。对比两次二分类方法的斑块的平均识别准确率(纤维化斑块 72.09%、脂质斑块 71.23%和钙化斑块 49.99%),结果表明,利用随机森林分类器的三分类方法的分类效果均有提高,尤其是对钙化斑块的识别能力进一步得到了提高。其可能的原因在于,后者适当地添加了灰度共生矩阵特征参数,并采用了直接三分类算法,而前者方法仅提取了 16 维 Gabor 特征数据和 1 维 LBP 纹理特征,然后通过 Gentle AdaBoost 分类器对斑块区域进行两次二分类来完成 3 种斑块的分类,即先将纤维斑块和钙化斑块看作一类,将脂质斑块看作另一类,通过 Gentle AdaBoost 分类器进行第一次二分类;然后再运用 Gentle AdaBoost 将纤维化斑块和钙化斑块识别出来并进行分类。

表 3 两种方法的平均识别准确率的结果对比

Table 3 Comparison of average accuracy of two methods

(单位:%)

方法	分类器	3 类斑块的 AC_i 平均值		
		纤维化	脂质	钙化
两次二分类	Gentle AdaBoost	72.09	71.23	49.99
三分类	随机森林	89.17	80.23	73.77

结束语 本研究通过灰度共生矩阵、Gabor 滤波和 LBP 等方法提取了 IVUS 图像的纹理特征,并结合均值和熵两个特征,归一化处理并降维处理图像局部和全局特征数据,然后利用 Liblinear、随机森林和 H2M-GLVQ 分类器依据特征数据进行斑块区域组织的自动识别。通过以上方法的训练和测

试,得到了5张测试图的识别结果,从这5张测试图可知,本文所提方法基本可以实现对血管内斑块组织的种类识别。与医生手工标定的结果相比,随机森林和H2M-GLVQ分类器的斑块组织的总体识别准确率均达到了80%以上,其中随机森林分类器对3类斑块的整体识别能力较高,纤维斑块、脂质斑块和钙化斑块的平均识别准确率分别为89.04%,80.23%和73.77%。另外,值得注意的是,在提取局部图像特征时,滑动邻域块选择较大的尺寸可提高斑块组织成分的识别准确率。

致谢 感谢南方医科大学南方医院心内科修建成教授为本研究提供IVUS图像。

参考文献

- [1] HANSSON G K. Inflammation, atherosclerosis, and coronary artery disease[J]. *The New England Journal of Medicine*, 2005, 352(16):1685-1695.
- [2] VIRMANI R, KOLODZIE F D, BURKE A P, et al. Atherosclerotic plaque progression and vulnerability to rupture-angiogenesis as a source of intraplaque hemorrhage[J]. *Arteriosclerosis Thrombosis and Vascular Biology*, 2005, 25(10):2054-2061.
- [3] JEERS S, NARBUTE I, ERGLIS A. Use of intravascular imaging in managing coronary artery disease[J]. *World Journal of Cardiology*, 2014, 6(6):393-404.
- [4] NAIR A, KUBAN B D, OBUCHOWSKI N, et al. Assessing spectral algorithms to predict atherosclerotic plaque composition with normalized and raw intravascular ultrasound data[J]. *Ultrasound in Medicine Biology*, 2001, 27(10):1319-1331.
- [5] KATOZIAN A, SATHYANARAYANAN S, BASERI B, et al. Challenges in atherosclerotic plaque characterization with intravascular ultrasound: From data collection to classification[J]. *IEEE Transactions on Information Technology in Biomedicine: A Publication of IEEE Engineering in Medicine and Biology Society*, 2008, 12(3):315-327.
- [6] NAIR A, KUBAN B D, TUZCU E M, et al. Coronary plaque classification with intravascular ultrasound radiofrequency data analysis[J]. *Circulation*, 2002, 106(17):2200-2206.
- [7] MAURICE R L, FROMAGEAU J, BRUSSEAU L, et al. On the potential of the lagrangian estimator for endovascular ultrasound elastography: In vivo human coronary artery study[J]. *Ultrasound in Medicine and Biology*, 2007, 33(8):1199-1205.
- [8] ARAKI T, IKEDA N, SHUKLA D, et al. PCA-based polling strategy in machine learning framework for coronary artery disease risk assessment in intravascular ultrasound: A link between carotid and coronary grayscale plaque morphology[J]. *Computer Methods and Programs in Biomedicine*, 2016, 128:137-158.
- [9] LO VERCIO L, ORLANDO J I, DEL FRESNO M, et al. Assessment of image features for vessel wall segmentation in intravascular ultrasound images[J]. *International Journal of Computer Assisted Radiology and Surgery*, 2016, 11(8):1397-1407.
- [10] ATHANASIOU L S, KARVELIS P S, TSAKANIKAS V D, et al. A novel semiautomated atherosclerotic plaque characterization method using grayscale intravascular ultrasound images: Comparison with virtual histology[J]. *IEEE Transactions on Information Technology in Biomedicine*, 2012, 16(3):391-400.
- [11] JABASON E. Performance analysis of contourlet features with SVM classifier for the characterization of atheromatous plaque in intravascular ultrasound images[J]. *International Journal of Engineering Research & Applications*, 2014, 4(3):35-42.
- [12] ZHANG J, TAN T, MA L. Invariant texture segmentation via circular gabor filters[C]// *IEEE International Conference on Pattern Recognition*. 2002:901-904.
- [13] PIETIK O T, INEN M, et al. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2002, 24(7):971-987.
- [14] GIANNOGLOU V G, STAVRAKOUDIS D G, THEOCHAIRS J B. IVUS-based characterization of atherosclerotic plaques using feature selection and SVM classification[C]// *IEEE International Conference on Bioinformatics & Bioengineering*. 2012:715-720.
- [15] FAN R E, CHANG K W, HSIEH C J, et al. Liblinear: A library for large linear classification[J]. *Journal of Machine Learning Research*, 2008, 9(9):1871-1874.
- [16] BREIMAN L. Random forests[J]. *Machine Learning*, 2001, 45(1):5-32.
- [17] QIN A K, SUGANTHAN P N. Rapid and brief communication: Initialization insensitive LVQ algorithm based on cost-function adaptation[J]. *Pattern Recognition*, 2005, 38(5):773-776.
- [18] Sato A. Generalized learning vector quantization[C]// *Conference on Neural Information Processing Systems*. 1996:423-429.
- [19] SUN Z, WANG L X, ZHOU Y. Automated tissue characterization of intravascular ultrasound gray-scale images[J]. *Journal of Biomedical Engineering*, 2016, 33(2):287-294. (in Chinese)
孙正, 王立欣, 周雅. 血管内超声灰阶图像的自动组织标定[J]. *生物医学工程学杂志*, 2016, 33(2):287-294.
- [20] HARALICK R M. Texture features for image classification[J]. *IEEE Transactions on Systems Man & Cybernetics*, 1990, 3(6):610-621.
- [21] SCHOENHAGEN P, CROWE T, NICHOLL S, et al. IVUS make easy[M]. America, Paul G. Informa Healthcare, 2008.
- [22] QIN A K, SUGANTHAN P N, LIANG J J. A new generalized LVQ algorithm via harmonic to minimum distance measure transition[C]// *IEEE International Conference on Systems, Man & Cybernetics*. 2004:4821-4825.