

## 全局与局部特征结合的肝硬化病程分类方法

朱佳琦<sup>1</sup>, 刘翔<sup>1</sup>, 宋家琳<sup>2</sup>

1. 上海工程技术大学电子电气工程学院, 上海 201620; 2. 中国人民解放军第二军医大学长征医院超声诊疗科, 上海 200003

**【摘要】目的:**提出一种肝脏组织全局特征与局部特征结合的肝硬化病程分类方法,用于解决目前肝硬化诊断主要依赖于人工检测的问题。**方法:**收集47例乙型肝炎肝硬化患者(依据Child-Pugh改良分级标准分为轻度肝硬化组、中度肝硬化组、重度肝硬化组)及20名健康志愿者(正常对照组)的二维高频超声图像,提出差分滤波器方法提取图像的码距,并提取角点、条索、腹水等特征进行定量分析。建立两阶段分类模型,第一阶段采用RBF核函数的SVM,将轻度与中度肝硬化归为一组,正常与重度肝硬化归为一组进行分类,避免两组之间的互相干扰。第二阶段采用贝叶斯对RF进行参数调优,调整不同特征的重要性权重,对每组的两个类别分别分类,提升肝硬化病程分类的准确率。**结果:**提出的特征均具有统计学意义( $P<0.05$ ),采用SVM-RF模型对正常对照组、轻度肝硬化组、中度肝硬化组、重度肝硬化组4个阶段的最终分类准确率分别达到93.11%、88.19%、91.93%和96.86%。**结论:**本文方法可以有效提取符合医生视角的全局特征以及局部特征,辅助诊断肝硬化病程。

**【关键词】**肝硬化;计算机辅助诊断;超声图像处理;特征分析

**【中图分类号】**R318;R657.31

**【文献标志码】**A

**【文章编号】**1005-202X(2023)11-1362-08

## Classification of liver cirrhosis using global and local features

ZHU Jiaqi<sup>1</sup>, LIU Xiang<sup>1</sup>, SONG Jialin<sup>2</sup>

1. School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China; 2. Department of Ultrasound Diagnosis and Treatment, Shanghai Changzheng Hospital, Naval Medical University, Shanghai 200003, China

**Abstract: Objective** To propose a classification method for liver cirrhosis diagnosis using both global and local features of liver tissues, thereby overcoming the current problem that the diagnosis of liver cirrhosis mainly relies on manual detection. **Methods** The two-dimensional high-frequency ultrasound images were collected from 47 patients with hepatitis B cirrhosis (divided into mild, moderate and severe cirrhosis groups according to Child-Pugh score) and 20 healthy volunteers (normal control group). The differential filter was used to obtain the code distance of the image, and then detect the corner point, cord, ascites and other features for quantitative analysis. A two-stage classification model was established. The support vector machine (SVM) of radial basis function was used in the first stage of classification to group mild and moderate cirrhosis into one category, while normal controls and severe cirrhosis into the other category for avoiding mutual interference between the two categories. In the second stage, after parameters tuning with Bayesian, random forest (RF) algorithm was used to adjust the importance weights of different features for further enhancing the classification accuracy of liver cirrhosis. **Results** All of the selected features were statistically significant ( $P<0.05$ ), and the SVM-RF model had an accuracy of 93.11%, 88.19%, 91.93% and 96.86% for diagnosing normal liver, mildly cirrhosis liver, moderate cirrhosis liver and severe cirrhosis liver. **Conclusion** The proposed SVM-RF method can effectively extract the global and local features that conform to the doctor's perspective, and assist in cirrhosis diagnosis.

**Keywords:** liver cirrhosis; computer-aided diagnosis; ultrasound image processing; feature analysis

**【收稿日期】**2023-07-05

**【基金项目】**上海市自然科学基金(19ZR1421500)

**【作者简介】**朱佳琦, 硕士研究生, 研究方向: 医学图像处理, E-mail: 1481784173@qq.com

**【通信作者】**刘翔, 博士, 教授, 研究生导师, 研究方向: 计算机视觉与人工生命, E-mail: xliu@sues.edu.cn

## 前言

乙型和丙型肝炎导致数亿人罹患慢性疾病,是肝硬化、肝癌和病毒性肝炎死亡的最常见致因。据世界卫生组织2021年7月发布消息,全球约有3.25亿人患有乙型和/或丙型肝炎,2019年约有82万人死于乙型肝炎,29万人死于丙型肝炎,主要死于肝硬化

和肝细胞癌。超声图像作为一种安全可靠的影像学检查技术,具备安全经济、无创无痛、方便直观等诸多优点,目前已成为最广泛使用的方式<sup>[1-3]</sup>。对肝硬化分类有助于病情诊断和进一步治疗<sup>[4-5]</sup>。针对肝硬化超声图像的计算机辅助诊断,主要分为传统的机器学习方法以及流行的深度学习方法。对于传统方法,Wang等<sup>[6]</sup>利用多尺度多目标优化算法确定肝包膜的位置,提出从肝包膜和实质纹理中提取组合特征,采用支持向量机识别肝硬化分期。Zhao等<sup>[7]</sup>通过空间上下文约束的多尺度方法提取肝包膜的边界,检测尺度空间中所有可能的边缘,基于空间上下文等能量函数过滤掉不相关的边,提出肝包膜两个新的几何特征用于肝硬化分类。Ribeiro等<sup>[8]</sup>提出一种表征形态的肝脏半自动轮廓分割算法和表征肝实质的纹理特征提取方案,采用贝叶斯分类器区分非肝硬化和肝硬化类别,该方法依赖于专家操作员手工选择感兴趣区域(ROI),过程繁琐。

对于深度学习方法,Xu等<sup>[9]</sup>通过神经网络对肝硬化阶段进行自动诊断,首先将超声图像输入自动编码器,对增强图像进行二值化,基于最小二乘多项式拟合定位肝包膜,最后利用残差神经网络来确定分期。该方法过于依赖前期的预处理,预处理不当对后续结果影响会很严重,使得结果发生较大变化。Kalyan等<sup>[10]</sup>对每张图像提取46个特征,然后通过WEKA (Waikato Environment for Knowledge Analysis)软件进行筛选,提取出具有较高显著性的特征,输入到神经网络中。Liu等<sup>[11]</sup>提出一种辅助诊断系统,基于重度优先策略提出增量分类模型,第一层识别属于重度阶段的图像,下一层将剩余图像分为正常、轻度和中度阶段;在每一层中,提出一种数据拆分和聚合方案。该模型缺乏与临床观察一致的指标特征,不直观。

对文献的回顾表明,在超声图像的分析上,对包膜线性结构的研究、包膜周围组织的相关信息利用不够,对轻度以及中度的分期不理想。对肝实质纹理的研究虽然很早,但对颗粒度与条索特征的描述不够。本文结合肝包膜和肝实质特点,提取码距、角点、条索、腹水等特征,并进行定量描述,建立SVM-RF二阶段分类模型实现对正常组和肝硬化组各个阶段的精准分类。

## 1 资料与方法

### 1.1 一般资料

收集的数据源于第二军医大学上海附属长征医院超声科,按照Child-Pugh改良分级计标准将肝硬化分为A、B、C 3个等级,A级为5~6分,B级为7~9

分,C级为10~15分。数据集包括47例乙型肝炎肝硬化患者和20例健康志愿者,其中有18例轻度肝硬化患者,年龄31~71岁;16例中度肝硬化患者,年龄28~67岁;13例重度肝硬化患者,腹水8例,年龄33~77岁。为了与肝硬化患者的年龄范围一致,选择了广泛年龄范围的健康对照组,其中男15例,女5例,年龄26~76岁。健康组与肝硬化组在性别、体质量等差异没有统计学意义( $P>0.05$ )。同时,通过体格检查、实验室检查(含血液检查)、超声或其他影像学检查确认患者无肝病。本研究获医院伦理委员会批准,检查前受检者均签署知情同意书。本研究所纳入的肝硬化患者分级均通过实验室检查进行验证。

### 1.2 仪器与方法

采用GE Voluson E8超声诊断仪,11L线阵探头,频率4~10 MHz。嘱受检者平卧或左侧卧,扫查肝脏,调整图像深度及增益,以清晰显示肝包膜及浅层肝实质,并存储显示肝脏左、右叶肝包膜的二维超声图像。之后从肝实质角度出发,通过观察数据集中的67张超声图像,并结合前人的研究,提取肝实质的角点、条索特征;其次计算肝硬化超声图像的行码距以及列码距,得到两个码距特征。整体结构流程如图1所示。

**1.2.1 ROI提取** 考虑到后续对肝实质进行角点与条索特征提取时,不需要考虑肝包膜及以上区域,因此结合遍历搜索法<sup>[12]</sup>对肝包膜进行提取,以肝包膜最低点划一条水平线为基准线,取出基准线以下的ROI区域,进行角点与条索检测。包膜定位公式如下所示:

$$\tau = \arg \max_A \sum_{i=1}^{n_{\Gamma_0}} A(C_i) \left[ l_{C_i} \cdot \delta(l_{C_i}), \frac{1}{n_{\Gamma} n_{C_i}} \sum_{j=1}^{n_{C_i}} y_i^j \right]$$

$$A(x) = \{0, 1\}, \delta = \begin{cases} 0, & x < \varepsilon_l \\ 1, & \text{else} \end{cases}, n_{\Gamma} = \sum_{i=1}^{n_{\Gamma_0}} y_i^j A(C_i) \quad (1)$$

其中, $l_{C_i}$ 是曲线段 $C_i$ 的长度,提取到的包膜示例图如图2所示。

**1.2.2 码距特征提取** 对图像研究发现,正常组的超声图像细腻平滑,肝包膜平滑连续,厚度均匀,曲率也更低,肝实质部分回声均匀,如图3a所示;随着肝硬化程度的加重,肝包膜增厚或厚度不均,实质部分线条状更加明显,如图3b所示。本文提出差分滤波器方法对图像亮度急剧变化的边缘有提取效果,可以获得邻近像素的差值。对单张图像进行纵向差分 and 横向差分处理,突出表现出图像的变化部分。

(1)行码距特征计算方法:将一幅尺寸为 $m \times n$ 的肝脏超声图像进行像素相减,得到一个 $m-1$ 列 $n$ 行的像素矩阵,表示为 $M_1$ ,如式(2)所示。

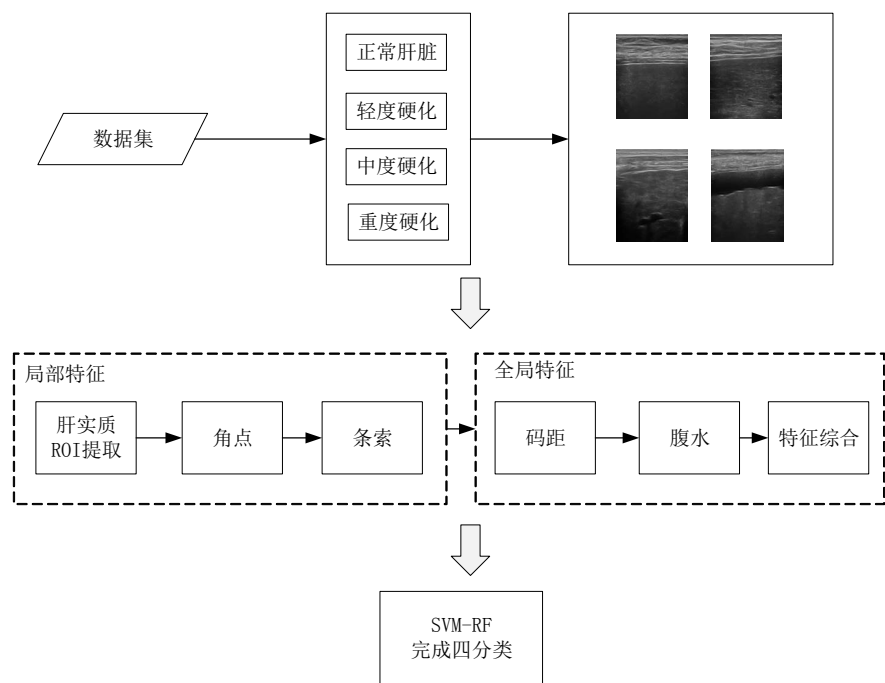


图1 肝硬化高频超声图像分类流程图

Figure 1 Flowchart of high-frequency ultrasound image classification for liver cirrhosis




图2 包膜提取示意图

Figure 2 Schematic diagram of capsule extraction




图3 肝硬化高频超声图像举例

Figure 3 Examples of high-frequency ultrasound images of liver cirrhosis

$$\mathbf{M}_1 = \begin{bmatrix} a_{1,1} - a_{1,2} & \cdots & a_{1,n-1} - a_{1,n} \\ \vdots & \ddots & \vdots \\ a_{m,1} - a_{m,2} & \cdots & a_{m,n-1} - a_{m,n} \end{bmatrix} \quad (2)$$

得到的  $\mathbf{M}_1$  可以表征图像列像素差距的大小, 差距越大, 代表像素跳跃度越大。如果差距大于 64 则设置为 1, 否则设置为 0, 这是通过实验得到的最佳阈值。本文采用的是十进制, 如式(3)所示:

$$\begin{cases} 1, & |a_{ij}| > 64 \\ 0, & |a_{ij}| \leq 64 \end{cases} \quad (3)$$

以此得到一个全部为 1、0 元素的矩阵, 然后对每一列元素求和, 得到一个一维列矩阵, 再求该行矩阵的平均值, 表示为  $\text{Ave}_{\text{row}}$ :

$$\text{Ave}_{\text{row}} = \frac{\sum_{i=1}^{n-1} x_i}{n-1} \quad (4)$$

(2) 列码距特征计算方法: 类比行码距计算方法, 首先对每一行像素值求差, 转换成“01 矩阵”; 其次对每一行元素求和, 得到一维列矩阵; 最后求该列矩阵的平均值得到  $\text{Ave}_{\text{col}}$ , 即得到了图像的码距特征。本文同样验证了行、列码距方差、协方差等特征, 但其对于分类精度提升不大, 因此舍去。

**1.2.3 角点特征提取** 在高频超声图像中, 随着病程的加重, 会出现局部亮度较强的区域, 尺度不变特征变换 (Scale-Invariant Feature Transform, SIFT) 用来侦测与描述影像中的局部性特征, 它在空间尺度中寻找极值点, 并提取出其位置、尺度、旋转不变量<sup>[13]</sup>。利用 SIFT 可以找到精确的特征点, SIFT 效率更高, 不受照片拍摄角度的影响; 对比常用的角点检测算法 Harris Corner, 其仅采用水平与垂直两个方向的导数信息构建二维结构张量积, 容易造成角点的错检和漏检问题。角点的数量与肝硬化的病程有关, 角点量函数如式(5)所示:

$$\text{cornerness} = \det \mathbf{M} - k(\text{trace}(\mathbf{M}))^2$$

$$\mathbf{M} = \begin{bmatrix} I_x^2 & I_{xy} \\ I_{xy} & I_y^2 \end{bmatrix} \rightarrow \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix} R, \det \quad (5)$$

其中,  $\text{trace}(\mathbf{M})$  表示对  $\mathbf{M}$  求迹, 系数  $k$  取 0.04。使用局部结构矩阵的行列式和迹计算角点响应函数, 判定某像素点为角点的条件有两个: ①该点的角点响应值应为局部邻域内极大值; ②该点的角点响应值应超过预先设置的门限阈值。本文根据上述两个条件进行角点判决, 并使用角点匹配实验用于验证角点提取的准确性。以一张轻度肝硬化图像为例, 提取到的角点如图 4 所示。

**1.2.4 条索特征值计算** 实质组织受损、纤维化和假小叶逐渐形成, 出现线条状结构。Canny 算子能够抑




图4 角点特征提取示意图

Figure 4 Schematic diagram of corner detection

制肝实质明亮区域的点状特征, 保留并增强其线状部分, 将其与周围组织区分开来<sup>[14]</sup>。对于亮度区域较多的图像, 意味着其条索数量更多, 肝硬化病程也较重。为了处理方便, 先对像素值进行归一化处理, 并对其进行浮点数转化。设超声图像为  $M \times N$  维, 利用 Canny 算子对原始超声图像进行卷积, 分别提取水平和垂直方向的梯度, 计算平均灰度值, 如式(6)所示:

$$\text{Ave}_{\text{gray}} = \frac{\sum_{i=1}^M \sum_{j=1}^N \sqrt{G_i^2(i,j) + G_j^2(i,j)}}{M \times N} \quad (6)$$

其中,  $G_i(i,j)$  和  $G_j(i,j)$  分别表示超声图像像素点  $f(i,j)$  和卷积模板作用的结果。同时, 分别使用 Laplace、Sobel 和 Scharr 检测算法对相同条件下的肝实质区域进行条索检测, 实验效果如图 5 所示。结果可以看出, Canny 效果最好, Laplace 与 Sobel 对条状信息的保存比较粗糙, 留下的均为点状信息, 而 Scharr 算子检测又过于关注细节, 导致出现很多误判结果。之后采用遍历追踪搜索, 从肝实质的图像左下角出发, 按行扫描整个 ROI 区域, 对 Canny 算子检测到的亮度区域绘制最小外接矩形, 并采用比值能量函数与致密性能量函数, 如式(7)所示:

$$E_{\text{ratio}} = \text{Exp}\left(\frac{\text{length}}{\text{width}} - \bar{r}\right)$$

$$E_{\text{compact}} = \text{Exp}\left(\frac{\text{length}^2}{\text{area}} - \bar{c}\right) \quad (7)$$

其中,  $\bar{r} = \frac{1}{n} \sum_{i=1}^n \frac{\text{length}}{\text{width}}$ ,  $\bar{c} = \frac{1}{n} \sum_{i=1}^n \frac{\text{length}^2}{\text{area}}$ ,  $n$  为所检测到的特征个数之和。评分策略<sup>[15]</sup>如式(8)所示:

$$\text{score} = \begin{cases} 1, & \text{粗颗粒} \\ 2, & \text{粗颗粒} + \text{细条索} \\ 3, & \text{细条索} \\ 4, & \text{细条索} + \text{粗条索} \\ 5, & \text{粗条索} \end{cases} \quad (8)$$

**1.2.5 腹水检测** 肝腹水是肝硬化晚期由于肝功能损害和门脉高压引起的腹水综合征, 由于腹水的存在,






图5 检测结果图  
Figure 5 Detection results

图像显示结构发生变化,这意味着超声图像可分为两大类:腹水和无腹水。设置腹水特征,检测到腹水则设置特征值为1,反之设置为0。由于本文只需要检测是否有腹水,而无需对其进行量化分析,采用局部灰度差法对图像进行腹水检测。从图像左上角开始,设置10×10的窗口大小,步长为10个像素,依次进行扫描,当窗口内像素的平均灰度值小于阈值60时,确定含有腹水。本文提前截取多个腹水区域窗口,发现所有窗口像素最大灰度值的平均值为60,因此确定60为阈值。检测示意图如图6所示。




图6 腹水检测示意图  
Figure 6 Ascites detection

**1.2.6 特征综合** 与健康肝包膜细滑的线状结构相比,肝硬化包膜可表现为增厚或增薄不均,呈波浪形、锯齿状、阶梯状变化<sup>[16]</sup>。Liu等<sup>[17]</sup>采用包膜的连

续性和平滑性作为描述肝硬化病程的指标,继续使用相同的想法,下面给出具体定义。

(1)肝包膜的连续性:

$$\text{CoC} = \arg \min \left\{ \left( \sum_{i=1}^K L_i \right) > fW \right\}, f \in [0.8, 1.0]$$
$$L_i \in L, L = \{L_j | \text{len}(l_j) > \text{len}(l_{j+1}), j = 1, \dots, S - 1\} \quad (9)$$

其中, $S$ 表示包膜轮廓的段数, $L$ 为连续边界段的集合,函数 $\text{len}(l_j)$ 被定义为 $L_j$ 的长度,集合 $L$ 中的元素按长度顺序排列。

(2)肝包膜平滑度:

$$\text{SoC}_\mu = \frac{1}{K-2} \sum_{i=0}^{k-2} A_i$$
$$\text{SoC}_\sigma = \frac{1}{K-2} \sum_{i=0}^{k-2} (A_i - \text{SoC}_\mu)^2 \quad (10)$$
$$A_i = \left| \arccos \left( \frac{(V_{i+1} - V_i) \cdot (V_{i+2} - V_{i+1})}{|V_{i+1} - V_i| |V_{i+2} - V_{i+1}|} \right) \right|, i \in [1, k-2]$$

其中, $K$ 代表控制点集合的点数。提取特征后,分别计算4个阶段的特征,均值如表1所示, $S\_L$ 与 $Width$ 代表分别包膜线长度、包膜图像宽度。可以看出,不同肝硬化分期的几个特征均存在明显差异。

1.3 分类器

通过分析图像的全局与局部特征,结合各大分类器的特点,建立了基于SVM-RF两阶段分类模型,实现了正常肝脏和肝硬化4个时期的准确分类。考虑到提出的特征具有非线性特点,而SVM具有小样本、处理非线性能力强、精度高等优势,径向基核

表1 特征结果分析  
Table 1 Feature analysis

组别	Ave <sub>row</sub>	Ave <sub>col</sub>	Corner	Ave <sub>gray</sub>	CoC	SoC <sub>μ</sub>	SoC <sub>σ</sub>	S_L	Width
正常对照组	115	139	36	0.010 7	1.450 0	2.355 5	2	264	291
轻度肝硬化组	162	174	148	0.021 6	3.944 4	4.273 8	11	295	384
中度肝硬化组	160	172	134	0.020 4	6.687 5	9.681 8	45	289	378
重度肝硬化组	135	156	101	0.009 2	9.307 7	26.67 8	212	166	353

(Radial Basis Function, RBF)作为高斯核最常用的一种,在处理大部分问题时效果都不会出现较大偏差,且RBF需要确定的参数相对多项式核函数要少,函数复杂程度更低,因此第一阶段选用RBF核函数的SVM<sup>[18-20]</sup>。RF利用多棵树对样本进行训练并预测,利用该方法,可以输入大量的特征<sup>[21-23]</sup>。在决定肝脏超声图像到底属于哪一类别时,将样本特征分配到

若干棵决策树,对各决策树分类结果进行投票,得出最终结果<sup>[24]</sup>。因此第二阶段结合贝叶斯与RF算法,采用贝叶斯对RF进行参数调优,调整不同特征的重要性权重,得到最优化的结果<sup>[25]</sup>。图7为RF示意图。为了评价所提分类器的性能,引入敏感度、特异性、查准率以及准确率为评价指标。




图7 RF示意图  
Figure 7 Random forest

1.4 统计学方法

采用IBM SPSS 26.0统计学分析软件,采取有序Logistic回归分析方法,对提取特征进行显著性检验,结果见表2。通过数据可以看出,检验中的P值均小于0.05,表明特征分析具有统计学意义。此外,根据

拟合优度、平行线检验、模型拟合信息等进一步确定了特征的有效性。因此,本文所提特征可以用于描述和分析肝脏超声图像,并可进一步用于辅助肝硬化各个阶段的诊断。

表2 特征统计学意义分析  
Table 2 Feature statistical significance analysis

参数	Ave <sub>row</sub>	Ave <sub>col</sub>	Corner	Ave <sub>gray</sub>	CoC	SoC <sub>μ</sub>	SoC <sub>σ</sub>	S_L	Width
P值	0.022	0.023	0.044	0.006	0.012	0.031	0.017	0.045	0.032

2 结果

2.1 第一阶段分类

考虑到数据集较少,本文采取10次五折交叉验证的方法,将数据大致分为5个部分,每次以不同的部分作为SVM模型的输入,重复实验10次,然后取平均值。根据表1可以看出,对于高频超声图像,轻度和中度在码距、角点、条索特征上的均值更为接近,正常和重度硬化肝脏在肝实质区域回声状态相似。因此先进行第一阶段分类,得到正常和重度肝硬化组的分类精度为97.25%,轻度和中度肝硬化组的分类精度为100.00%,结果见表3。

2.2 第二阶段分类

分别对正常和重度肝硬化组、轻度和中度肝硬化组进一步分类,得到的分类结果如表3所示。由表3可以看出,正常对照组、重度肝硬化组的准确率达到了95.74%、99.60%,轻度肝硬化组、中度肝硬化组的准确率达到了88.19%、91.93%。此外,对模型进行敏感度、特异性以及查准率分析,结果如表4所示。其中正常对照组敏感度、特异性、查准率分别为87.58%、95.76%、87.50%,轻度肝硬化组分别为74.17%、86.67%、75.46%,中度肝硬化组分别为80.00%、93.93%、79.67%,重度肝硬化组分别为96.00%、95.76%、95.09%。

表3 两阶段分类模型准确率(%)

Table 3 Accuracy of the two-stage classification model (%)

组别	第一阶段分类	第二阶段分类	最终准确率
正常对照组	97.25	95.74	93.11
重度肝硬化组		99.60	96.86
轻度肝硬化组	100.00	88.19	88.19
中度肝硬化组		91.93	91.93

表4 模型评估指标(%)

Table 4 Model evaluation index (%)

组别	敏感度	特异性	查准率
正常对照组	87.58	95.76	87.50
轻度肝硬化组	74.17	86.67	75.46
中度肝硬化组	80.00	93.93	79.67
重度肝硬化组	96.00	95.76	95.09

表5 特征选择对分类结果的准确率影响分析(%)

Table 5 Effects of feature selection on classification accuracy (%)

特征选择	正常对照组	轻度肝硬化组	中度肝硬化组	重度肝硬化组
基准特征	81.12	78.32	80.23	84.34
+Corner	94.73	75.00	68.83	85.71
+Ave <sub>row</sub> 、Ave <sub>col</sub>	96.31	84.58	90.02	88.23
+Ave <sub>gray</sub>	93.00	86.67	91.67	92.85
+Ascites	93.11	88.19	91.93	96.86




图8 特征权重影响

Figure 8 Effects of feature weight

为了进一步证明本文方法的可行性以及适用性,与最先进的几种方法进行对比,如表6所示,相比文献[6-8, 10, 12],本文的方法在4个时期的效果都更为精确。尽管轻度时期稍微落后,但也与最先进方法相差不多;相比文献[11],本文在重度时期的分类效果要更优,在前3个病程的效果不如文献[11],但由于本文的方法完全依赖于传统的机器学习,对

2.3 特征选择与结果对比分析

为了验证本文特征选择对分类结果的影响,对特征数量与权重影响进行分析,以初始5个特征(CoC、SoC<sub>μ</sub>、SoC<sub>σ</sub>、S\_L、Width)为基准,添加角点、码距、条索、腹水特征按照10次五折交叉验证的方法进行两阶段分类实验,最终得到了5组准确率指标,见表5。在添加角点与码距后,正常对照组的准确率有明显提高,但由于存在部分轻度与中度硬化的误分类,导致这两组数据更多被误判为正常对照组,而添加条索与腹水后,这种误分类明显减少,准确率回升并达到最高。实验表明,本文提取的特征对肝硬化超声图像的综合分类准确率最高。图8为采用RF对特征权重进行计算的结果,可以看出整体特征权重较为均衡,其中值最高的为本文提出的码距特征,而腹水特征由于存在大量0值,导致整体权重占比较小,但其对重度肝硬化的分类准确率有较大影响,因此予以保留。

硬件算力和复杂度要求更低,并且本文速度更快,训练时间更短,便于实现。

3 总结

本文提出一种全局与局部特征结合的肝硬化病程分类方法,既考虑到包膜与实质局部特征,又考虑到码距、腹水全局特征,可以更全面描述肝硬化的阶段变化,实现肝硬化病程的精准分类。本文方法可以自动提取ROI,过程简单易操作,不再依赖于专家的手动勾画,可以减少人为误差,并且由于本文方法完全依靠传统的机器学习,不需要进行繁琐的预处理,也不需要考虑因网络训练而消耗的大量时间。因此在实现速度和流程复杂度上要远远优于深度学习,对硬件的算力成本要求较低。但本研究尚存在部分局限性:①针对轻度肝硬化组的分类准确率依然有提升空间,在分类算法上可以进一步优化;②肝硬化病程分类研究样本量相对较小,为验证模型的鲁棒性和可重复性,应加入更多样本。

表 6 与现有先进方法的对比结果(%)

Table 6 Comparison of classification accuracy with the existing state-of-the-art methods (%)

方法	正常对照组	轻度肝硬化组	中度肝硬化组	重度肝硬化组
Liu 等 <sup>[12]</sup>	92.54	88.46	89.23	94.55
Wang 等 <sup>[6]</sup>	92.46	80.49	83.93	91.98
Zhao 等 <sup>[7]</sup>	92.50	74.71	70.08	86.17
Ribeiro 等 <sup>[8]</sup>	84.07	71.16	75.19	89.31
Kalyan 等 <sup>[10]</sup>	90.12	76.30	75.03	80.06
Liu 等 <sup>[11]</sup>	95.00	88.90	94.10	92.30
本文方法	93.11	88.19	91.93	96.86

综上所述,本研究提取的特征更好地描述了肝脏状态,具备很好的临床解释性,符合医生视角。构建的分类模型有利于对肝硬化进行准确的预后和诊断,能够作为辅助临床医师对患者病情诊断决策、预后评估的支持工具,对临床具有重要意义。

【参考文献】

[1] Sudharsan S, Pratap T, Kokil P. Noise level estimation for effective blind despeckling of medical ultrasound images[J]. Biomed Signal Proces, 2021, 68(1): 102744.

[2] Zhang PF, Huang H, Xiong QJ, et al. Feature analysis and automatic classification of B-mode ultrasound images of fatty liver[J]. Biomed Signal Proces, 2023, 79(1): 104073.

[3] Mabrouk AG, Hamdy A, Abdelaal HM, et al. Automatic classification algorithm for diffused liver diseases based on ultrasound images[J]. IEEE Access, 2021, 9(1): 5760-5768.

[4] Hanif I, Khan MM. Liver cirrhosis prediction using machine learning approaches [C]//2022 IEEE 13th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON). New York, 2022: 28-34.

[5] Vinutha MR, Chandrika J. EANNMHO: a novel ensemble based technique for liver cirrhosis detection[J]. iJOE, 2021, 17(4): 96-106.

[6] Wang SH, Liu X, Zhao JW, et al. Learning to diagnose cirrhosis via combined liver capsule and parenchyma ultrasound image features [C]//2016 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). IEEE, 2016: 799-804.

[7] Zhao JW, Wang SH, Liu X, et al. Early diagnosis of cirrhosis via automatic location and geometric description of liver capsule[J]. Vis Comput, 2018, 34(12): 1677-1689.

[8] Ribeiro R, Marinho RT, Suri J, et al. Ultrasound liver surface and textural characterization for the detection of liver cirrhosis [M]// Abdomen and Thoracic Imaging. Springer: Boston, 2014: 145-168.

[9] Xu ZP, Liu X, Cheng XE, et al. Diagnosis of cirrhosis stage via deep neural network [C]//2017 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). IEEE, 2017: 745-749.

[10] Kalyan K, Jakhia B, Lele RD, et al. Artificial neural network application in the diagnosis of disease conditions with liver ultrasound images[J]. Adv Bioinformatics, 2014.

[11] Liu X, Ma RL, Zhao JW, et al. A clinical decision support system for predicting cirrhosis stages via high frequency ultrasound images[J]. Expert Syst Appl, 2021, 175(1): 114680.

[12] Liu YW, Liu X, Wang SH, et al. A novel method for accurate extraction of liver capsule and auxiliary diagnosis of liver cirrhosis based on high-frequency ultrasound images[J]. Comput Biol Med, 2020, 125(1): 104002.

[13] 李宁, 景军锋, 章为川, 等. 基于多方向结构张量积的快速角点检测算法[J]. 激光与光电进展, 2021, 58(20): 2015005.

Li N, Jing JF, Zhang WC, et al. Fast corner point detection algorithm

based on multidirectional structure tensor product [J]. Progress in Laser and Optoelectronics, 2021, 58(20): 2015005.

[14] Lapušinskij A, Suzdalev I, Goranin N, et al. The application of hough transform and canny edge detector methods for the visual detection of cumuliform clouds[J]. Sensors, 2021, 21(17): 5821.

[15] 牛广利, 刘翔, 宋家琳, 等. 结合快速傅里叶变换的肝实质病变特征量化检测[J]. 中国医学物理学杂志, 2022, 39(2): 188-193.

Niu GL, Liu X, Song JL, et al. Quantitative detection of liver parenchymal lesion characteristics combined with rapid Fourier transform[J]. Chinese Journal of Medical Physics, 2022, 39(2): 188-193.

[16] 蒋芙蓉, 赵静文, 刘翔, 等. 漂移迭代搜索算法提取高频超声声像图肝包膜线并量化评估肝硬化[J]. 中国医学影响技术, 2022, 38(5): 747-752.

Jiang FR, Zhao JW, Liu X, et al. Drift iterative search algorithm extracts high-frequency ultrasound image hepatic envelope line and quantitatively evaluates liver cirrhosis[J]. Chinese Journal of Medical Impact Technology, 2022, 38(5): 747-752.

[17] Liu X, Song JL, Zhao JW, et al. Extracting and describing liver capsule contour in high-frequency ultrasound image for early HBV cirrhosis diagnosis [C]//IEEE International Conference on Multimedia & Expo. IEEE, 2016.

[18] Zhuang Z, Yang Z, Zhuang S, et al. Multi-features-based automated breast tumor diagnosis using ultrasound image and support vector machine[J]. Comput Intel Neurosc, 2021, 2021(1): 1-12.

[19] Zhang HL, Guo LK, Wang J, et al. Multi-view feature transformation based SVM+ for computer-aided diagnosis of liver cancers with ultrasound images[J]. IEEE J Biomed Health, 2023, 27(3): 1512-1523.

[20] Baek J, Swanson TA, Tuthill T, et al. Support vector machine (SVM) based liver classification: fibrosis, steatosis, and inflammation [C]// 2020 IEEE International Ultrasonics Symposium (IUS). IEEE, 2020: 1-4.

[21] Swarnalatha A, Manikandan M. Intravascular ultrasound image classification using wavelet energy features and random forest classifier [C]//Intelligent Computing in Engineering: Select Proceedings of RICE 2019. Springer: Singapore, 2020: 803-810.

[22] Cui M, Zhu HJ. Research on application of improved random forest in medical ultrasound image classification[J]. JPCS, 2020, 1584(1): 012007.

[23] Wang YX, Zeng QQ. Ovarian tumor texture classification based on sparse auto-encoder network combined with multi-feature fusion and random forest in ultrasound image[J]. J Med Imaging Health Inform, 2021, 11(2): 424-431.

[24] Yang U, Oh S, Wi SG, et al. Classification of germination images of pear pollen using random forest and convolution neural network models[J]. IEEE Access, 2021, 9: 45993-45999.

[25] Kumar P, Nair GG. An efficient classification framework for breast cancer using hyper parameter tuned Random decision forest classifier and bayesian optimization[J]. Biomed Signal Process Control, 2021, 68(1): 102682.

(编辑:陈丽霞)