

文章编号: 2095-2163(2024)01-0102-04

中图分类号: TP391

文献标志码: A

# 基于 AA-UNet 的肝硬化辅助诊断系统

翟欢欢<sup>1</sup>, 赵静文<sup>1</sup>, 刘翔<sup>1</sup>, 石蕴玉<sup>1</sup>, 汤显<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 上海长征医院 超声科, 上海 200003)

**摘要:** 为准确地提取高频肝脏超声图像中的肝包膜, 本文采用注意力门和空洞空间金字塔池化 UNet (Attention gates and Atrous spatial pyramidal pooling UNet, AA-UNet) 分割算法, 对高频肝脏超声图像中的肝包膜进行识别, 并根据肝包膜的物理形状判断肝硬化程度。首先, 将数据增强后的高频肝脏超声图像送入网络模型进行训练; 其次, 将训练好的模型部署到肝硬化辅助诊断系统。实验结果表明, 肝硬化辅助诊断系统能有效识别肝包膜区域并判断肝硬化程度。

**关键词:** 超声图像; 肝包膜; 诊断系统; AA-UNet

## AA-UNet based liver cirrhosis assisted diagnosis system

ZHAI Huanhuan<sup>1</sup>, ZHAO Jingwen<sup>1</sup>, LIU Xiang<sup>1</sup>, SHI Yunyu<sup>1</sup>, TANG Xian<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, Shanghai Changzheng Hospital, Shanghai 200003, China)

**Abstract:** In order to accurately extract the liver capsule in high-frequency liver ultrasound images, this paper adopts the attention gates and atrous spatial pyramidal pooling UNet (AA-UNet) segmentation algorithm to identify the liver capsule in high-frequency liver ultrasound images, and based on the physical shape of the liver capsule to determine the degree of cirrhosis. First, the data-enhanced high-frequency liver ultrasound images were fed into the network model for training; then, the trained model was deployed to the cirrhosis assisted diagnosis system. The experimental results show that the cirrhosis assisted diagnosis system can effectively recognize the liver capsule region and determine the degree of cirrhosis.

**Key words:** ultrasound images; liver capsule; diagnosis system; AA-UNet

## 0 引言

在高频肝脏超声图像中, 根据肝硬化程度划分轻度、中度和重度等级, 肝包膜的物理变化直接反映了肝硬化的病变程度<sup>[1]</sup>。

超声成像诊断肝脏疾病方式具有无创、无辐射、便宜等优点, 是临床医生最为推荐的检查方案<sup>[2]</sup>。目前, 高频超声图像需要临床医生肉眼进行判断, 依赖于医生的专业水平。实现肝脏超声图像的自动识别诊断, 即自动识别肝包膜物理形状, 判断肝硬化程度, 不仅可以减轻医生负担, 还可以实现远程诊断。

疾病辅助诊断系统的关键在于能够准确地识别病变区域并判断疾病类型。目前, 国内外研究学者已经基于深度学习实现了对疾病的自动诊断, Hoo-Chang 等<sup>[3]</sup>将卷积神经网络用于胸腹淋巴结的

检测与间质性肺疾病的分类; Zhang 等<sup>[4]</sup>提出了基于卷积神经网络的图像识别方法, 在对脂肪肝超声图像进行分类的实验中取得了优秀的分类结果; Lee 等<sup>[5]</sup>提出用于肝病分类的 BP-CMAC (Back-Propagation and Cerebellar Model Articulation Controller, BP-CMAC) 神经网络分类器, 并构建肝脏疾病辅助诊断系统, 取得了 87% 的鉴别率; 徐立等<sup>[6]</sup>建立辅助诊断系统, 对脂肪肝 B 超图像进行轻度、中度和重度的分类, 识别率达 88.89%。随着医疗诊断技术的成熟, 也对疾病辅助诊断系统的智能化提出了更高的要求。

本文主要将训练好的模型部署到肝硬化辅助诊断系统, 对肝包膜进行分割, 并依据分割的肝包膜诊断肝硬化。

**基金项目:** 上海市自然科学基金(19ZR1421500)。

**作者简介:** 翟欢欢(1998-), 女, 硕士研究生, 主要研究方向: 计算机视觉、医疗图像。

**通讯作者:** 赵静文(1992-), 女, 博士, 讲师, 主要研究方向: 计算机视觉、生物医学图像分析。Email: jingwen\_echo@outlook.com

**收稿日期:** 2022-12-24

### 1 系统总体设计

肝硬化辅助诊断系统主要由医生操作和管理员管理两个部分组成,其中,医生操作部分实现医生对患者数据的操作,管理员管理部分实现管理员对医生权限的审批和对用户信息的管理,系统总体流程图如图 1 所示。医生进入系统后,可输入病人身份信息来查询相关超声诊断影像,选定列表中的超声影像,系统经过图像预处理与网络模型预测,显示分割分类结果,医生根据系统分割的肝包膜与预测的肝硬化病程,做出综合的诊断结果并将诊断信息保存到数据库。

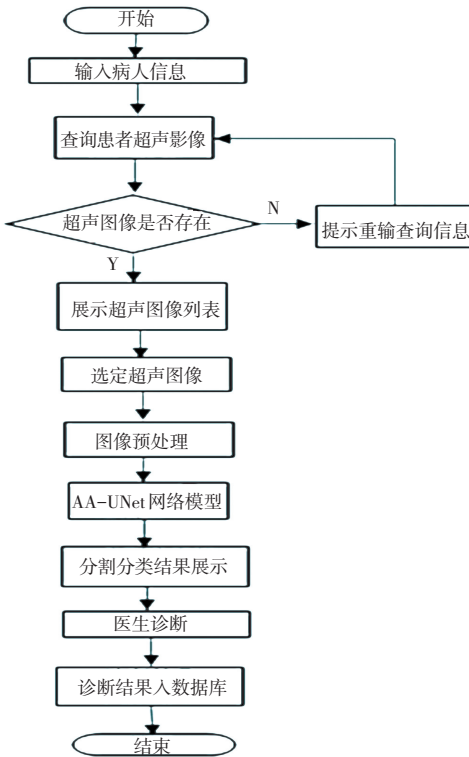


图 1 系统流程图

Fig. 1 System flow chart

### 2 系统数据

#### 2.1 图像采集

本文采用的 67 张图像由上海长征医院超声科提供,其中包括 4 种类型的高频肝脏超声图像:正常、轻度、中度和重度。重度肝硬化患者症状明显,不需要超声检查,因此剔除重度肝硬化超声图像。

#### 2.2 数据增强

为扩充数据集样本量,防止过拟合,使网络充分学习数据特征,本文采用翻转、加噪、调整亮度、镜像等随机组合的数据增强方法,将数据集扩充 30 倍。原来的正常、轻度和中度数据集扩充至 600、540 和 480 张。其中,训练集、验证集和测试集的数量分别为 1 296、144 和 180 张。

#### 2.3 数据标注

在专业医生指导下,使用 labelme 对实验数据进行标注。在标注过程中,沿着肝包膜边缘标记出肝包膜区域,保存后生成相应的.json 文件,并将.json 文件转换成.png 格式的标签文件,送入网络进行训练。

### 3 系统算法

AA-UNet 算法集迁移学习、注意力门机制 (Attention Gate, AG)、空洞空间卷积池化金字塔 (Atrous Spatial Pyramid Pooling, ASPP) 于一体,在医学图像识别方面优势明显<sup>[7]</sup>。AA-UNet 辅助诊断系统处理过程如图 2 所示,输入图像经过数据增强后送入编码器,在编码器与解码器对应特征图进行拼接之前,使用注意力门机制对编码器特征图中的目标特征赋予较大权重,对背景区域等无关特征赋予较小权重,加强网络对目标特征的学习与训练。在解码器末端加入 ASPP,来获得特征图的多尺度特征。另外,加入全连接层和分类器对肝硬化程度进行分类,最终输出肝包膜的分割结果与肝硬化的分类结果。




图 2 AA-UNet 辅助诊断系统处理过程

Fig. 2 AA-UNet assisted diagnostic system processing

## 4 实验

### 4.1 评价指标

使用交并比 (Intersection Over Union,  $IOU$ )、精确率 ( $Precision$ )、 $F$  分数 ( $F\_score$ ) 评估 AA-UNet 算法对高频肝脏超声图像中肝包膜的分割结果, 计算式(1)~式(3):

$$IOU = \frac{|TP|}{|TP| + |FP| + |FN|} \quad (1)$$

$$Precision = \frac{|TP|}{|TP| + |FP|} \quad (2)$$

$$F\_score = \frac{|2TP|}{|2TP| + |FN| + |FP|} \quad (3)$$

其中:  $TP$  表示将正样本分割为正样本;  $FP$  表示将负样本分割为正样本;  $TN$  表示将负样本分割为负样本;  $FN$  表示将正样本分割为负样本。

### 4.2 实验结果

实验结果如图3所示, 可以看出 AA-UNet 算法在  $IOU$ 、 $Precision$  和  $F\_score$  指标上均具备优秀的分割性能。




图3 评价指标

Fig. 3 Evaluation metrics

AA-UNet 算法对正常、轻度和中度肝硬化高频超声图像中肝包膜的分割结果, 如图4~图6所示。标签图像中的红色区域为肝包膜的真实区域, 分割结果图中黑色区域为网络预测的肝包膜区域。由图4~图6可以看出, AA-UNet 预测的肝包膜区域接近真实的肝包膜区域。





图4 正常肝脏高频超声图像分割结果


Fig. 4 Segmentation results of high-frequency ultrasound images of normal liver



(a) 原图 (b) 标签图像 (c) 分割结果

图5 轻度肝硬化高频超声图像分割结果

Fig. 5 Segmentation results of high-frequency ultrasound images of mild liver cirrhosis



(a) 原图 (b) 标签图像 (c) 分割结果

图6 中度肝硬化高频超声图像分割结果

Fig. 6 Segmentation results of high-frequency ultrasound images of moderate liver cirrhosis

AA-UNet 算法对肝硬化的分类结果见表1, 可见 AA-UNet 算法对于不同程度的肝硬化具有较高的识别准确率。

表1 肝硬化的分类结果

Table 1 Classification results of cirrhosis

类别	样本量	准确率(%)
正常	60	90.00
轻度	60	81.67
中度	60	78.33

## 5 系统界面设计

将 AA-UNet 算法训练好的模型部署到肝硬化辅助诊断系统, 将肝包膜的分割结果展示在系统主界面, 并将肝硬化分类结果展示在分割结果图下方。

医生操作部分具体包含注册、登录、诊断数据查询、系统诊断结果展示和诊断信息管理等部分。为保证系统安全, 医生使用该系统前需要注册账号, 并填写姓名、身份证号、密码和联系电话等个人真实信息。医生提交注册信息后, 等待管理员审核通过, 即可进行登录, 登录流程图如图7所示。

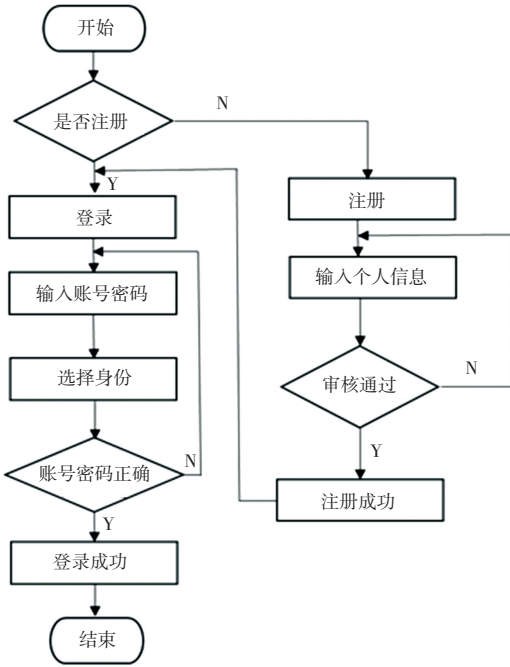


图 7 登录流程图

Fig. 7 Login flowchart

系统分割结果展示如图 8 所示,医生在信息管理模块输入患者姓名和身份证号后,即可查询到患者超声检查图片列表,完成诊断数据查询,显示该检测图片原图和系统的肝包膜分割结果,并将肝硬化分类结果展示在分割结果图下方。医生可根据系统的肝包膜分割结果和肝硬化的分类结果做出最终的诊断结果,填写在主界面右侧病人信息管理模块下方,将诊断数据保存至数据库。

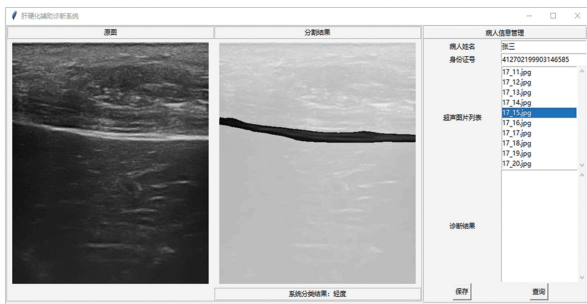


图 8 系统分割结果展示

Fig. 8 Demonstration of system segmentation results

## 6 结束语

本文使用深度学习算法对高频肝脏超声图像中的肝包膜进行分割,并诊断肝硬化程度,通过 python 语言的 Tkinter 标准库进行肝硬化辅助诊断系统开发,实现算法的落地应用。该系统可以自动对高频肝脏超声图像进行诊断,不仅可以保证诊断结果的客观性,还可以减轻医生阅片负担,提高诊断效率。

由于本系统没有针对重度肝硬化的分类,使得系统不够完善,下一步将针对重度肝硬化进行分类。系统对肝硬化的分类精度随肝硬化进程的深入逐步降低,这是由于数据集样本量随肝硬化进程的深入变少,网络学习不充分导致的,下一步将采集更多的肝硬化超声图像数据集。

## 参考文献

- [1] LIU X, ZHAN Z, YAN M, et al. Computer-aided cirrhosis diagnosis via automatic liver capsule extraction and combined geometry-texture features [C]//Proceedings of the 2017 IEEE International Conference on Multimedia and Expo (ICME). IEEE, 2017; 865-870.
- [2] RAETH U, SCHLAPS D, LIMBERG B, et al. Diagnostic accuracy of computerized B-scan texture analysis and conventional ultrasonography in diffuse parenchymal and malignant liver disease [J]. Journal of Clinical Ultrasound, 1985, 13(2): 87-99.
- [3] SHIN H C, ROTH H R, GAO M, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning [J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1285-1298.
- [4] ZHANG L, ZHU H, YANG T. Deep neural networks for fatty liver ultrasound images classification [C]//2019 Chinese Control And Decision Conference (CCDC). 2019; 4641-4646.
- [5] LEE C C, CHUNG P C, CHEN Y J. Classification of liver diseases from CT images using BP-CMAC neural network [C]. 2005 9th International Workshop on Cellular Neural Networks and Their Applications. 2005; 118-121.
- [6] 徐立, 苗玥, 邢俊风. 自组织特征映射网络在脂肪肝 B 超图像识别中的应用研究 [J]. 电子技术与软件工程, 2014(5): 105-106.
- [7] 翟欢欢, 赵静文, 刘翔, 等. 基于注意力门和空洞空间金字塔池化 UNet 模型提取肝包膜及评估肝硬化 [J]. 中国医学影像技术, 2022, 38(9): 1385-1390.