

基于深度学习的肝囊型包虫病超声图像中小病灶检测方法研究

米吾尔依提·海拉提 热娜古丽·艾合麦提尼亚孜 卡迪力亚·库尔班 严传波

摘 要 肝包虫病是一种呈全球性分布的人畜共患性疾病。超声作为该病的首选诊断方法,虽能及时发现大病灶位置并进行评价,但对早期小病灶的检测能力不佳。本文基于经预处理的高质量肝囊型包虫病超声图像小病灶数据集,提出了一种基于YOLOv7的检测肝囊型包虫病5类分型超声图像中小病灶的方法,以实现肝包虫病的自动检测,提高临床诊断效率。首先,用硬件感知神经网络EfficientRep替换原特征提取主干,实现在保证精度和速度不受影响的前提下,提高对硬件设备的适配度;其次,用更优的WIoU(Wise-IoU)替换CIoU(Complete Intersection over Union),改善了YOLOv7网络的评价指标CIoU在作为损失函数时,梯度计算效果差,导致检测精度下降的问题;最后,在主干的最后第4层加入CBAM注意力,进一步提高了模型检测精度。本文在自建的肝囊型包虫病超声图像小病灶数据集上进行了训练,结果显示,改进后的模型平均精度均值为88.1%,相较原始的模型性能得到了提升,并超过了对比的其余主流检测方法。说明本模型能更高效地检测并分类肝囊型包虫病超声图像中小病灶的位置和类别,应用于临床上能节约医师资源、缩短报告时长、提高诊断效率。

关键词 肝囊型包虫病;深度学习;目标检测;YOLOv7;EfficientRep;Wise-IoU;CBAM

[中图分类号]TP751;R532.32

[文献标识码]A

Research on deep learning-based detection method for identifying small lesions in ultrasound images of hepatic cystic echinococcosis

Miwueryiti·HAILATI, Renaguli·AIHEMAITINIYAZI, Kadiliya·KUERBAN, YAN Chuanbo

College of Public Health, Xinjiang Medical University, Urumqi 830011, China

ABSTRACT Hepatic hydatid disease is a globally distributed zoonotic disease. The ultrasound, being the preferred diagnostic method for this disease, although capable of timely detection and evaluation of major lesion locations, exhibits limited efficacy in detecting early small lesions. Therefore, this study utilizes a preprocessed high-quality dataset of small lesions in ultrasound images of liver cystic hydatid disease and proposes an improved YOLOv7-based method for detecting small lesions in the 5 classification ultrasound images of liver cystic echinococcosis to achieve automatic detection and improve clinical diagnostic efficiency. Firstly, replace the original feature extraction backbone with EfficientRep, a hardware-aware neural network, to enhance adaptability to hardware devices without compromising accuracy and speed. Secondly, the replacement of CIoU with a more refined WIoU (Wise-IoU) can improve the evaluation metric CIoU (Complete Intersection over Union) of YOLOv7 Network. However, this modification adversely affected gradient calculation performance and led to a decline in detection accuracy when employed as a loss function. The CBAM attention module was finally incorporated into the fourth layer of the backbone, resulting in a further enhancement of model detection accuracy. This study was trained on a self-built dataset of small lesions in ultrasound images of hepatic cystic echinococcosis. The results demonstrate that the modified model achieved an improved detection accuracy of 88.1% in terms of mAP in comparison to the original model, thereby outperforming other

基金项目:国家自然科学基金项目(81560294);省部共建中亚高发病成因与防治国家重点实验室开放课题(SKLIHIDCA-2020-YG2);一流本科课程建设专项经费(010302010112)

作者单位:830011 乌鲁木齐市,新疆医科大学公共卫生学院(米吾尔依提·海拉提、热娜古丽·艾合麦提尼亚孜、卡迪力亚·库尔班);新疆医科大学医学工程技术学院(严传波)

通讯作者:严传波, Email:ycbsky@126.com

mainstream detection methods. The proposed model demonstrates improve the efficacy in the detection and classification of lesions in ultrasound images of hepatic cystic echinococcosis, thereby facilitating its application in clinical settings. This innovative approach optimizes physician resources, reduces reporting time, and improves diagnostic efficiency.

KEY WORDS Hepatic cystic echinococcosis; Deep learning; Object detection; YOLOv7; EfficientRep; Wise-IoU; CBAM

包虫病是幼虫棘球蚴寄生于人(或动物)引起的一种人畜共患寄生虫病^[1],多流行于畜牧业较发达地区,发病具有地域性特点,在我国新疆维吾尔自治区、宁夏回族自治区、内蒙古自治区、青海省、西藏自治区等地区较常见^[2]。其中新疆维吾尔自治区是我国肝包虫病流行的重点发病区域^[3-4]。一旦发病会危及患者的身体健康,使许多家庭“因病致贫,因病返贫”,造成极大的经济损失^[5]。包虫病的好发部位为肝脏,占发病总数的80%^[6],其次是肺脏等其他器官,最后累及全身^[7]。肝包虫病从病理上可分为肝细粒棘球蚴病和肝泡状棘球蚴病,其中肝细粒型囊肿较多见^[8],占包虫病病例的98%以上^[9]。世界卫生组织根据肝包虫病的超声图像特征将其分为囊型肝包虫病和泡型肝包虫病,其中囊型肝包虫病分为5个类型,分别为单囊型(CE-1)、多子囊型(CE-2)、内囊塌陷型(CE-3)、坏死实变型(CE-4)和钙化型(CE-5)。见图1。泡型肝包虫病分为3个类型,分别为浸润型、钙化型和液化空洞型。肝泡型包虫病较肝囊型包虫病发病率低,约占肝包虫病的3%~5%^[10]。由于包虫在肝脏感染初期生长缓慢,患者通常不会出现明显的临床症状,仅部分会出现过敏症状或肝区偶感不适,随着包虫病灶的逐渐增长,可能压迫周围血管或破坏胆管,此时患者会出现腹部不适、疼痛或黄疸等较明显的临床症状^[11],加之牧区医疗条件相对落后、医学人才缺失等诸多因素,目前对肝包虫病的防治仍然面临诸多困难^[12]。临床上一般采取临床诊断、影像学诊断、免疫学及血清学检查等确诊包虫病^[13]。其中,超声检查是肝包虫病诊断和筛查的首选方式,其作为一种

无创检查手段^[14],运用物理学成像特性,实现对人体软组织的物理特性形态结构和功能状态的判断^[15]。但是常规超声图像均需进行定量分析,需超声医师和肿瘤专家耗费大量的时间和精力才能初步完成疾病的诊断,存在人为主观性强、测量结果准确性差、可再现性差等问题,常导致疾病的漏诊或误诊^[16]。临床上医师面对体检所产生的海量超声图像,难以保证有足够的精力寻找到所有的肝包虫病灶,特别是面对结构相似的疾病时难以有效地鉴定所有的囊型肝包虫病灶^[17]。

针对此类情况,有学者^[18]提出使用计算机辅助诊断(computer aided diagnosis, CAD)的方法来辅助医师对肝囊型包虫病做出诊断,以此弥补部分地区医疗资源不足的情况。随着深度学习网络的快速发展,图像处理中的目标检测任务也有了跨越性的进展^[19]。目前小病灶主要有2种定义,一种是指物理尺寸较小的病灶(最大径<5 cm);另一种则是在MS-COCO^[20]度量评估中提出的像素<32×32的病灶。虽然不断有新的检测方法被提出,但肝包虫病超声图像中的小病灶具有面积较小、图像清晰度低及成像方式的差异等特点^[21],如直接将现有针对自然图像检测的主流算法用于肝囊型包虫病小病灶的检测上效果较差^[22-24]。本文针对肝囊型包虫病超声图像中小病灶检测困难的问题,以YOLOv7为基底进行优化,提出了一种基于深度学习的方法用于检测肝囊型包虫病5类分型超声图像中小病灶的方法,从而更好地辅助临床医师快速检测肝囊型包虫病,降低早期误诊率,实现早发现、早治疗,为进一步推动偏远地区医疗卫生事业的发展贡献力量。



A:单囊型(CE-1); B:多子囊型(CE-2); C:内囊塌陷型(CE-3); D:坏死实变型(CE-4); E:钙化型(CE-5)

图1 各类型囊型肝包虫病超声图像

一、基本原理

(一)YOLOv7

目标检测包括2类:双阶段(two-stages)和单阶段(one-stage)检测。双阶段是先生成一系列样本的候选框,再利用卷积神经网络对样本进行分类;典型代表有R-CNN^[25]、Fast R-CNN^[26]、Faster R-CNN^[27]等。单阶段则无需生成样本的候选框,采用回归方法定位目标进行检测。常见算法有SSD(single shot multibox detector)^[28]和YOLO(you only look once)^[29]。双阶段目标检测算法的阶段检测过程导致模型整体检测速度较慢,不适用于实时监测。单阶段的SSD算法虽检测速度较快,但准确率低于YOLO系列。YOLO通过省略生成样本的候选框这一步骤,直接将目标框定位的问题转化为回归问

题进行处理,输入图片后仅经过一个神经网络得到边界框的位置及其所属的类别,使YOLO系列算法的检测速度较为快速。目前YOLO系列已发展至YOLOv7^[29]系列,性能有了巨大提升,其在准确率和速度方面超越了以往的YOLO系列算法。YOLOv7引入了一些新的技术和策略,包括模型重参数化、标签分配策略、ELAN 高效网络架构和带辅助头的训练。YOLOv7输入图片后相应经过Backbone、Head等模块,最终在不同尺度的特征图上得到病灶的位置信息与分类置信度。总之,YOLOv7是一种先进的目标检测算法,具有高准确率和快速的运行速度,其采用了多种技术和策略以提高检测性能,并在实时系统中得到广泛应用。其网络结构见图2。




图2 YOLOv7网络结构图

(二)EfficientRep

深度学习网络的硬件效率设计和部署一直是研究的重点和热点。传统的推理效率评估指标是浮点运算次数(FLOPs)和参数计数,但这些指标不能表示与硬件的关系,如内存访问成本和I/O吞吐量。RepVGG是一种基于Winograd算法在GPU或CPU上高度优化的具有3×3卷积核的新型网络^[30]。单路径模型可以在GPU等设备上快速训练和推断。图3示RepConv在训练状态与推理状态之间的转换。在训练状态下,由于增加了1×1的Conv和残差链,RepConv可以保证训练时的准确性。在推理状态下,重新参数化结构可以等价地转换为推理状态。EfficientRep是近年提出的具有类似RepVGG架构且硬件友好的卷积神经网络,其网络结构见图4,RepConvs通过残差方式线性连接,构成Bep单元,接着由Bep单元组成一个Repblock再与CSP式(CSPstyle)结构相结合,组成一种新的BepC3块结构,在BepC3模块的基础上,分别设计了CSPBep主干和CSPRepPAN

颈部,形成最终的EfficientRep模型。EfficientRep对计算能力和内存带宽在内的硬件不敏感,能在保证良好检测精度的前提下有效平衡模型的精度-速度。




图3 RepConv的设计图

(三)损失函数

1.IoU Loss(Intersection over Union Loss)。其是目标检测领域常用的一种损失函数,用于衡量预测框与真实框之间的相似度。其通过计算预测框和真实框的交集与并集的比值来评估




图 4 EfficientRep 网络结构图

两者的重叠程度。如公式 1 中所示, A 为真实边框, B 为预测边框, A 和 B 的交集除以 A 和 B 的并集得到 IoU 值。一般在计算机检测任务中, $\text{IoU} \geq 0.5$ 属于检测正确, IoU 越接近于 1, 说明预测框与真实框重合程度越高, 代表模型预测越准确、平均精度 (AP) 值越大。

$$\text{IoU} = \frac{A \cap B}{A \cup B} \quad (1)$$

然而, IoU 并不能精确地表示 2 个框的相似度, 因为其仅考虑了框的位置信息, 而未考虑框的形状和大小。因此, 为了改进 IoU 的不足, 出现了一些相关改进方法, 其中包括 GIoU Loss、DIOU Loss 和 CIOU Loss 等。GIoU Loss (Generalized Intersection over Union) 是对 IoU Loss 的改进, 其引入了一个能够将预测框与真实框最小包围的框 C, 通过计算 C 的面积来惩罚预测框与真实框之间的偏移。DIOU Loss (Distance-IoU Loss) 是对 GIoU Loss 的改进, 其在 GIoU Loss 的基础上添加了一个能够衡量预测框与真实框中心点距离的项, 用于进一步提升框的回归效果。CIOU Loss 是对 DIOU Loss 的改进, 其在 DIOU Loss 的基础上添加了一个能够衡量预测框与真实框宽高比差异的项, 用于进一步优化框的回归效果。这些改进方法的目的均是为了更准确地衡量预测框与真实框之间的相似度, 从而提高目标检测算法的性能。

2. Wise-IoU (WIoU) Loss。2023 年 Tong 等^[30]提出了一种更高效、更直接的回归损失函数 Wiou。Wiou 通过估计锚框的离群度定义一个动态聚焦机制 (FM) $f(\beta)$, $\beta = \frac{\text{LIoU}}{\text{LloU}}$ 。FM 通过将小梯度增益分配到具有小 β 的高质量锚框, 使锚框回归能够专注于普通质量的锚框。同时, 该机制将小梯度增益分配给 β 较大的低质量锚框, 有效削弱了低质量样例对锚框回归的危害。具体分为 3 个步骤:

(1) Wiou v1: 由于训练数据不可避免地包含低质量的例子, 距离、纵横比等几何因素会加重低质量例子的惩罚, 从而降低模型的泛化性能。一个好的损失函数应该在锚盒与目标盒重合良好时弱化几何因素的惩罚, 训练中较少的干预会使模型

获得更好的泛化能力。构建距离度量距离注意力, 可得到具有两层注意力机制的 Wiou v1, 如公式 2 所示。公式中, $R_{\text{Wiou}} \in [1, e]$, 这将显著放大普通质量锚框的 LIoU。LloU $\in [0, 1]$, 这将显著降低高质量锚框的 R_{Wiou} , 并在锚框与目标框重合良好时, 将焦点集中在中心点之间的距离上。 W_g, H_g 是最小的包围框的大小。为了防止 R_{Wiou} 产生阻碍收敛的梯度, H_g 从计算图中分离 (*表示此操作)。因为其有效地消除了阻碍收敛的因素, 所以没有引入诸如长宽比之类的新指标。

$$\begin{aligned} L_{\text{WiouV1}} &= R_{\text{Wiou}} L_{\text{IoU}} \\ R_{\text{Wiou}} &= \exp \left(\frac{(x - x_{\text{gt}})^2 - (y - y_{\text{gt}})^2}{(W_g^2 - H_g^2)^*} \right) \end{aligned} \quad (2)$$

(2) Wiou v2: 为降低简单示例对损失值的贡献, 在交叉熵设计了一个单调 FM, 有效降低了简单示例对损失值的贡献。这使得模型能够聚焦于困难示例, 获得分类性能的提升。公式 3-2 为 Wiou v2 反向传播过程, $r = L_{\text{IoU}}^{\gamma^*} \in [0, 1]$ 为梯度增益, 在模型训练过程中, 梯度增益随着 L_{IoU} 的减小而减小, 导致训练后期收敛速度较慢。因此, 引入 L_{IoU} 的均值作为归一化因子, 如公式 3-3 所示。

$$L_{\text{WiouV2}} = L_{\text{IoU}}^{\gamma^*} L_{\text{WiouV1}}, \gamma > 0 \quad (3-1)$$

$$\frac{\partial L_{\text{WiouV2}}}{\partial L_{\text{IoU}}} = L_{\text{IoU}}^{\gamma^*} \frac{\partial L_{\text{WiouV1}}}{\partial L_{\text{IoU}}}, \gamma > 0 \quad (3-2)$$

$$L_{\text{WiouV2}} = \left(\frac{L_{\text{IoU}}^*}{L_{\text{IoU}}} \right)^{\gamma} L_{\text{WiouV1}} \quad (3-3)$$

其中, L_{IoU} 是动量为 m 的运行均值。动态更新归一化因子使梯度增益 $r = \left(\frac{L_{\text{IoU}}^*}{L_{\text{IoU}}} \right)^{\gamma}$ 总体上处于较高的水平, 解决了训练后期收敛缓慢的问题。动态非单调 FM 是锚框的离群度由 L_{IoU} 的比值表征。如公式 4 所示。

$$\beta = \left(\frac{L_{\text{IoU}}^*}{L_{\text{IoU}}} \right) \in [0, \infty) \quad (4)$$

(3) Wiou v3: 利用 β 构造了一个非单调聚焦系数, 并将其应用于 Wiou v1 就得到了具有动态非单调 FM 的 Wiou v3。利用动态非单调 FM 的明智的梯度增益分配策略, Wiou v3 获得了优越的性能。如公式 5 所示。

$$\begin{aligned} \beta &= \frac{L_{\text{IoU}}^*}{L_{\text{IoU}}} \in [0, +\infty) \\ L_{\text{WiouV2}} &= r L_{\text{WiouV1}}, r = \frac{\beta}{\delta \alpha^{\beta - \delta}} \end{aligned} \quad (5)$$

(四) CBAM 注意力

使用注意力机制的目的是使网络更多地关注到病灶的位置, 增强存在病灶位置的权重来提高提取信息能力, 得到更高的平均检测精度。CBAM (convolutional block attention module) 是一种轻量的注意力模块, 可以在空间和通道上进行注意力机制, 沿着通道和空间 2 个维度推断出注意力权重系数, 然后再与特征图相乘。CBAM 包含通道注意力模块和空间注意力模块, 2 个注意力模块采用串联的方式, 具体为: ①通道注意力模块。通道注意力是关注哪个通道上的特征是有意义的, 输入特征图

是 $H \times W \times C$, 先分别进行一个全局平均池化和全局最大池化得到 2 个 $1 \times 1 \times C$ 的特征图, 再将其利用共享的全连接层 (Shared MLP) 进行处理, 然后将共享的全连接层所得到的结果进行相加再使用 Sigmoid 激活函数, 进而获得输入特征层每一个通道的 0~1 权重得到最终输出特征图; ②空间注意力模块。通道注意力输出之后, 再引入空间注意力模块, 关注空间中哪部分的

特征有意义。空间注意力模块输入特征图为 $H \times W \times C$, 分别进行一个通道维度的最大池化和平均池化得到 2 个特征图, 然后将这 2 个特征图在通道维度拼接起来, 得到特征图 $H \times W \times 2$, 然后再经过一个 7×7 卷积操作, 降为 1 个通道, 同时保持 H 、 W 不变, 输出特征图为 $H \times W \times 1$, 然后再通过 Sigmoid 函数生成空间权重系数, 之后与输入特征图相乘得到最终特征图。见图 5~7。




图5 CBAM注意力模块结构图




图6 通道注意力模块结构图




图7 空间注意力模块结构图

二、方法

考虑到YOLOv7在Backbone中使用大量ELAN网络, 每个ELAN网络由多个标准卷积密集连接构成, 网络结构复杂, 造成过多计算量和大量的参数, 部署在不同的硬件设备上很难达到模型的精度-速度平衡, 导致模型性能参差不齐。其次, YOLOv7选用的CIoU由于易受离群值影响的原因, 损失函数的值变化波动较大, 最终在评判正负样本时效果不佳。为此, 本文考虑采用更为硬件友好的网络进行特征提取, 在保证丰富特征的前提下, 实现精度-速度平衡, 得到更高的检测精度。

1. 借鉴对硬件友好的网络EfficientRep思想并进行调整, 作为本文模型YOLOv7的主干, 以解决YOLOv7在部署的硬件上无法获得合适的精度-速度平衡问题。

2. 在模型的标签分配部分, 用更优的WIoU Loss替换原CIoU Loss, 在保证丰富特征不被丢失的前提下, 尽可能地降低损失, 获得较高的精度。

3. 在主干的最后第4层加入CBAM注意力, 进一步提高了模型检测精度。

三、试验结果与分析

1. 数据集与数据预处理。从新疆医科大学第一附属医院超声科获取2008年1月至2022年12月1220例患者共计6854张肝囊型包虫超声图像, 在专业医师的指导下, 从收集到图像中挑选小病灶图像(病灶最大径 ≤ 5 cm或像素 $\leq 32 \times 32$)建立数据集, 按照8:2的比例将数据集分为训练集和验证集, 进而使用Labeling图像标注软件对其进行了手工标注, 按VOC数据集中的规范要求完成保存。另外, 基于肝囊型包虫病超声图像特

征, 本文采用灰度尺寸归一化、自适应直方图均衡化、双边滤波、数据扩增4种方法对数据进行预处理, 最终得到了2170张高质量图像(单囊型438副、多子囊型446副、坏死实变型454副、内囊塌陷型388副、钙化型444副), 用于模型的训练和评估。

2. 试验环境和评价指标。试验环境是基于Linux操作系统Ubuntu 18.04.2 LST, 使用GPU版Pytorch 1.11深度学习框架Python 3.7编程语言实现。设置输入图像尺寸为 224×224 , 权重衰减参数设置为 5×10^{-4} , batchsize设置为14, 初始学习率为0.001, 最大迭代次数150, 再迭代150次得到最终网络训练模型。同时采用平均精度均值(mAP)、画面每秒传输帧数(Fps)、参数量(Params)和FLOPs作为评价指标, 其中mAP是目标检测中对多个验证样本个体求平均AP值的方式, 是衡量检测精度的指标, 其值越大表示检测准确率越高; Fps表示每秒内可以处理的图片数量, 用来评估目标检测的速度, 其值越大表示模型检测速度越快, 该算法的实时检测性能越好; Params和FLOPs是评估模型规模大小的指标, 其值越小, 说明模型越轻便。

3. 消融试验。为了验证本文提出的各项改进是否有效, 设计一组消融试验进行对比分析, 为保证试验准确性, 训练过程中均采用相同参数, 在自制肝囊型包虫病小病灶数据集上进行试验, 试验I是将EfficientRep网络作为新的骨干网络; 试验II是将CIoU Loss替换为WIoU Loss; 试验III是在主干的最后第4层中加入CBAM注意力。消融试验结果见表1。可以看出, 将原始YOLOv7模型直接作为检测网络进行试验(表1中第1行所示), 所得模型mAP为86.0%, Params、FLOPs和Fps分别为36.5 M、103.2 G、46.0 帧/s。将EfficientRep网络作为YOLOv7的骨干

网络进行试验(表 1 第 2 行所示),mAP 较原始 YOLOv7 提升了 0.4%,Params、FLOPs 和 Fps 分别为 21.7 M、59.4 G、40.0 帧/s,模型大小明显得到了缩小。将 WIoU Loss 嵌入 YOLOv7 的 Head 部分进行试验(表 1 第 3 行所示),mAP 较原始 YOLOv7 提升了 1.2%,Params、FLOPs 和 Fps 分别为 21.7 M、59.4 G、56.0 帧/s,性能得到了明显的提高。将 CBAM 注意力加入 YOLOv7 的主干部分进行试验(表 1 第 4 行所示),mAP 较原始 YOLOv7 提升了 0.1%,Params、FLOPs 和 Fps 分别为 22.2 M、59.5 G、57.0 帧/s,性能得到了一定的提高。将 EfficientRep 网络作为 YOLOv7 骨干网络的同时在 Head 部分嵌入 WIoU Loss 进行试验(表 1 第 5 行所示),mAP 较原始 YOLOv7 提升了 0.6%,Params、FLOPs 和 Fps 分别为 21.7 M、59.4 G、59.0 帧/s,在此基础上加入 CBAM 注意力,mAP 较原始 YOLOv7 提升了 2.1%,Params、FLOPs 和 Fps

分别为 22.2 M、59.4 G、62.7 帧/s,证明了改进的有效性。

4. 方法对比。与当前主流的目标检测算法模型(包括 YOLOv3、YOLOv5、SSD、Faster R-CNN 和 DETR)进行对比试验,结果见表 2 和图 8。结果显示,与基于 CNN 的模型 YOLOv3、YOLOv5、YOLOv7、SSD、Faster R-CNN 比较,本文改进后的 YOLOv7 算法 mAP 分别提高了 6.2%、2.2%、2.1%、7.3%、1.7%,Params 分别下降 39.7 M、8.7 M、14.3 M、18.8 M、114.8 M;与基于 Transformer 的模型 DETR 比较,其 mAP 提高了 5.1%,Params 下降 14.5 M。由图 8 可知,相比其他几个主流目标检测模型,改进后的 YOLOv7 检测精度高、速度快,同时参数量少,属于轻量级高精度模型。总之,改进后的 YOLOv7 在模型轻量化的同时,又提高了模型的精度,有效地平衡了精度-速度。

表 1 消融试验结果


模型	mAP(%)	Params(M)	FLOPs(G)	Fps(帧/s)
YOLOv7	86.0	36.5	103.2	46.0
YOLOv7+ I	86.4	21.7	59.4	40.0
YOLOv7+ II	87.2	21.7	59.4	56.0
YOLOv7+ III	86.1	22.2	59.5	57.0
YOLOv7+ I + II	86.6	21.7	59.4	59.0
YOLOv7+ I + II + III(本文算法)	88.1	22.2	59.5	62.7

mAP: 平均精度均值;Params: 参数量;FLOPs: 浮点运算次数;Fps: 画面每秒传输帧数

表 2 改进后的 YOLOv7 与同类型目标检测模型评价验证集中肝囊型包虫病小病灶超声图像结果

主流目标检测模型	mAP(%)	Params(M)	FLOPs(G)	Fps(帧/s)
SSD	80.8	41.0	387.0	34.8
Faster R-CNN	86.4	137.0	370.2	39.8
DETR	83.0	36.7	114.2	46.6
YOLOv3	81.9	61.9	66.2	33.0
YOLOv5	85.9	30.9	67.9	87.0
YOLOv7	86.0	36.5	103.2	46.0
YOLOv7+ I + II + III(本文算法)	88.1	22.2	59.5	62.7

mAP: 平均精度均值;Params: 参数量;FLOPs: 浮点运算次数;Fps: 画面每秒传输帧数



横坐标 Fps 为画面每秒传输帧数,表示模型检测速度;mAP 是平均精度均值,表示模型检测准确率;圆圈大小表示模型 Params

图 8 改进后的 YOLOv7 与同类型目标检测模型评价验证集中肝囊型包虫病小病灶超声图像性能比较

四、检测效果分析

为了比较本文改进模型与原模型的检测效果,选择肝囊型包虫病超声图像中的坏死实变型(CE-4)图像进行检测,在一张图上的热力图可视化效果对比中可以看出,改进后的 YOLOv7 模型有着更好的定位能力。见图 9。

五、结论

本文选取 YOLOv7 作为基础网络,用标注后的肝囊型包虫病图像数据集,针对肝包虫病在肝脏区域常发病位置和类型分类,借鉴 EfficientRep 网络思想改进了骨干网络,有效增强了特征提取能力;相继将 WIoU Loss 和 CBAM 注意力加入 Head 和 Backbone 部分,得到了高精度检测效果,为肝囊型包虫病计算机诊断系统的构建提供了理论基础。结果表明,改进后的 YOLOv7 在准确度上有更良好的表现,对验证集的 mAP 达到了 88.1%,高于其他同类目标检测网络算法。检测速度也能够满足实时检测小病灶的要求,能够有效检测小病灶及其位置等信息。




图9 原始模型与改进后的YOLOv7模型检测坏死实变型(CE-4)肝囊型包虫病图像效果对比

参考文献

- [1] 柳源,王海久.青海地区肝包虫病临床诊断与治疗进展[J].世界最新医学信息文摘,2019,19(82):114-115.
- [2] 张宇,张刚.泡型肝包虫病治疗进展[J].四川医学,2018,39(11):1294-1297.
- [3] 张杰,齐宝文,宋巍,等.新疆地区肝包虫病患者临床特征和诊疗模式及预后的十年回顾性分析:一项单中心研究[J].中国全科医学,2020,23(36):4573-4577.
- [4] 王泽宇,杨婧,温钰鹏,等.新疆北部地区肝包虫病适宜技术及方案推广效果观察[J].临床合理用药杂志,2019,12(11):158-159.
- [5] 高伟,王浩,马有良,等.2018年青海省久治县人群肝棘球蚴病流行现状分析[J].中国寄生虫学与寄生虫病杂志,2019,37(6):681-684.
- [6] 董妮,张淑娟,魏秀丹,等.探讨超声造影对泡型肝包虫病与肝血管瘤的诊断价值[J].中国现代药物应用,2022,16(3):116-118.
- [7] 赵永玲,王梅英,王凯,等.肝包虫病患者手术部位感染危险因素的logistic回归分析[J].中国感染控制杂志,2022,21(3):280-286.
- [8] 唐健,徐治国,赵明星,等.肝包虫病诊断及治疗进展[J].世界最新医学信息文摘,2019,19(43):73-74,76.
- [9] 张洪胡,周永利,杨孟磊,等.肝包虫病外科治疗进展[J].中国卫生标准管理,2021,12(17):166-168.
- [10] 毕建斌,庞青,王志鑫,等.肝泡型包虫病138例的临床特征与手术疗效[J].中华消化杂志,2016,36(9):629-632.
- [11] 刘文亚,蒋奕,王健.肝包虫病影像学诊断专家共识[J].临床肝胆病杂志,2021,37(4):792-797.
- [12] 王春艳,周林勇,徐忠碧,等.甘孜县通达玛地区肝包虫病人间流行情况分析[J].预防医学情报杂志,2021,37(6):765-771.
- [13] 孙玉,凌宾芳,卜美玲,等.多学科协作快速康复护理在肝包虫病患者围术期中的应用[J].护理与康复,2021,20(10):50-53.
- [14] 德钦,胡青青,刘小林.超声结合CT影像学特征在囊型肝包虫病中的临床应用价值分析[J].中国CT和MRI杂志,2021,19(10):110-111,129.
- [15] 魏丽,熊静,卿志灵.MRI与MSCT对肝包虫病的诊断价值[J].中国CT和MRI杂志,2021,19(11):123-126.
- [16] A J, Zhang J, Chai J, et al. Comparison of the efficacy of anatomic and non-anatomic hepatectomy for hepatic alveolar echinococcosis: clinical experience of 240 cases in a single center[J]. Front Public Health, 2022, 9(1): 816704.
- [17] 吴维佳.肝包虫病的超声声像图特征及其诊断价值[J].世界最新医学信息文摘,2019,19(30):236-237.
- [18] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks[J]. Adv Neural Information Processing Systems, 2012, 60(6): 84-90.
- [19] Deng J, Dong W, Socher R, et al. Imagenet: a large-scale hierarchical image database[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248-255.
- [20] Lin TY, Maire M, Belongie S, et al. Microsoft coco: common objects in context[C]//European Conference on Computer Vision, 2014: 740-755.
- [21] 裘静娟,邹俊忠,郭玉成,等.应用化肝脏病灶分割的预测方案[J].计算机工程与应用,2020,56(20):173-178.
- [22] 吕培杰,刘娜娜,王落桐,等.深度学习重建算法优化能谱CT低单能量图像质量及检测肝脏低对比度小病灶能力[J].中国医学影像技术,2023,39(1):104-108.
- [23] 吴德蓝.基于改进Faster R-CNN的肝脏CT图像小病灶检测[D].南宁:广西大学,2022.

- [24] 陈洪, 杨世艳. 对肝脏实质性小病灶应用超声造影的早期诊断价值分析[J]. 世界最新医学信息文摘, 2019, 19(85): 186, 190.
- [25] Girshick R, Donahue J, Darrell T, et al. Region-based convolutional networks for accurate object detection and segmentation [J]. IEEE Trans Pattern Anal Mach Intell, 2016, 38(1): 142-158.
- [26] Girshick R. Fast-RCNN [C]//Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [27] Ren S, He K, Girshick R, et al. FasterRCNN: towards real-time object detection with region proposal networks[J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(6): 1137-1149.
- [28] 茹仙古丽·艾尔西丁. 基于深度学习的肝囊型包虫病 CT 图像分类方法研究[D]. 乌鲁木齐: 新疆医科大学, 2020.
- [29] 刘志华, 李丰军, 严传波, 等. 卷积神经网络在肝包虫病 CT 图像诊断中的应用[J]. 电子技术应用, 2019, 45(11): 17-20.
- [30] Tong ZJ, Chen YH, Xu ZW, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism [EB/OL]. (2023-01-24) [2023-02-03]. <https://arxiv.org/abs/2301.10051>.

(收稿日期: 2023-07-25)

• 病例报道 •

Ultrasonic manifestations of ovarian rupture in early pregnancy: a case report 卵巢妊娠早期破裂超声表现 1 例


曾欣 罗纪清

[中图法分类号] R445.1; R714.22

[文献标识码] B

患者女, 28 岁, 因停经 41 d, 间断性腹痛 4 d 就诊。孕 4 产 1, 平素月经规律, 周期为 30 d, 本次停经 30 d 时出现阴道流血 1 次, 量较平时少。4 d 前无明显诱因出现下腹胀痛, 持续 1 h 好转, 后呈间断性隐痛。妇科检查: 右附件区增厚, 轻压痛, 宫颈光滑、无举痛, 宫颈闭合、未见出血。实验室检查: 尿人绒毛膜促性腺激素(HCG)阳性。经阴道超声检查: 右附件区见一大小约 22 mm×19 mm 混合回声, 边界欠清晰, 形态欠规则, 内见一大小约 9 mm×8 mm 无回声, 该混合回声侧方见一丝状相连, 连于右侧卵巢, 右侧卵巢侧方见一丝状相连, 连于混合回声(图 1A), CDFI 于混合回声内探及少许血流信号; 右侧卵巢内见部分小卵泡, 另见一窄带状稍强回声贴于卵巢表面(图 1B)。右侧混合回声周边及盆腔见一大小约 86 mm×28 mm 不规则片状稍高回声, CDFI 于其内部可探及点状血流信号。子宫直肠窝及盆腹腔见液性无回声区, 较大深度 34 mm, 超声提示: ①右附件区混合性包块, 考虑异位妊娠伴血凝块; ②盆腔积液。入院后查血 HCG: 4816.09 mU/ml。术中见: 右卵巢表面长约 10 mm 破口, 破口处见绒毛组织附着并活动性出血(图 2); 右卵巢与肠管膜粘连。术中诊断: ①右侧

卵巢妊娠; ②慢性盆腔炎并肠粘连。术后病理诊断: 右侧卵巢送检物为绒毛组织及出血(图 3)。



A: 白色箭头示右附件区混合回声; 红色箭头示右侧附件区混合回声与卵巢相连部分; B: 黄色箭头示右侧卵巢表面的窄带状稍强回声; 白色箭头示右侧卵巢与右附件区混合回声相连部分

图 1 本例患者声像图




图 2 本例患者术中图像(白色箭头示右侧卵巢破口; 黄色箭头示血液覆盖卵巢表面)




图 3 右侧卵巢送检物病理图可见胎盘绒毛及出血(HE 染色, ×100)

(下转第 174 页)

作者单位: 401331 重庆市沙坪坝区陈家桥医院超声科

通讯作者: 罗纪清, Email: 764712401@qq.com