

基于改进YOLOv7的肝囊型包虫病超声图像小病灶检测

米吾尔依提·海拉提¹, 热娜古丽·艾合麦提尼亚孜¹, 卡迪力亚·库尔班¹, 严传波²

1. 新疆医科大学公共卫生学院, 新疆 乌鲁木齐 830011; 2. 新疆医科大学医学工程技术学院, 新疆 乌鲁木齐 830011

【摘要】目的:提出一种基于YOLOv7用于检测肝囊型包虫病超声图像小病灶的方法。**方法:**首先用轻量级特征提取主干网络GhostNet替换原特征提取主干,降低模型总参数量;其次为改善YOLOv7网络的评价指标CIoU在作为损失函数时,检测精度较低的问题,用更优的ECIoU替换CIoU,进一步提高模型检测精度。**结果:**在自建的肝囊型包虫病超声图像小病灶数据集上进行训练,结果显示改进后的模型大小为59.4 G, mAP@0.5检测精度为88.1%,相比原始模型性能得到提升,并超过其余主流检测方法。**结论:**本文模型能更高效地检测并分类肝囊型包虫病超声图像中的病灶位置和类别。

【关键词】囊型包虫病;深度学习;目标检测;YOLOv7;ECIoU;GhostNet

【中图分类号】R318;TP751

【文献标志码】A

【文章编号】1005-202X(2024)03-0299-10

Small lesion detection in ultrasound images of hepatic cystic echinococcosis based on improved YOLOv7

HAILATI Miwueryiti¹, AIHEMAITINIYAZI Renaguli¹, KUEBAN Kadiliya¹, YAN Chuanbo²

1. College of Public Health, Xinjiang Medical University, Urumqi 830011, China; 2. College of Medical Engineering Technology, Xinjiang Medical University, Urumqi 830011, China

Abstract: Objective To propose a novel algorithm model based on YOLOv7 for detecting small lesions in ultrasound images of hepatic cystic echinococcosis. **Methods** The original feature extraction backbone was replaced with a lightweight feature extraction backbone network GhostNet for reducing the quantity of model parameters. To address the problem of low detection accuracy when the evaluation index CIoU of YOLOv7 was used as a loss function, ECIoU was substituting for CIoU, which further improved the model detection accuracy. **Results** The model was trained on a self-built dataset of small lesion ultrasound images of hepatic cystic echinococcosis. The results showed that the improved model had a size of 59.4 G and a detection accuracy of 88.1% for mAP@0.5, outperforming the original model and surpassing other mainstream detection methods. **Conclusion** The proposed model can detect and classify the location and category of lesions in ultrasound images of hepatic cystic echinococcosis more efficiently.

Keywords: cystic echinococcosis; deep learning; object detection; YOLOv7; ECIoU; GhostNet

前言

包虫病又称为棘球蚴病,是由棘球绦虫的幼虫寄生于哺乳动物体内所致的一种呈全球性分布的人畜共患性疾病^[1]。目前全球约有400万人感染肝包虫,有6000万人处于感染风险中^[2-4]。我国的患病程

度也十分严重,在过去20年里,新增包虫病5000余例^[5],尤其西北部地区高发,人群患病率为0.5%~5.0%^[6-7]。目前感染人体的包虫病主要分为囊型包虫病(Cystic Echinococcosis, CE)和泡型包虫病(Alveolar Echinococcosis, AE)两种类型^[8],主要发生于肝脏,其中,65%~80%的CE灶发生在肝脏,98%的AE灶发生在肝脏^[9]。世界卫生组织包虫病专家工作组(WHO/IWGE)将肝CE的进程分为CE1至CE5,共5个阶段^[10],具体见图1。早期的肝包虫病没有明显的临床表现,一般在筛检时才发现。肝CE具有包膜呈膨胀性生长,占总数的70%以上;肝AE无明显包膜,呈浸润性生长。二者的严重程度与病灶的大小、数目、生长的位置及病灶的类型直接相关,随着

【收稿日期】2023-10-20

【基金项目】国家自然科学基金(81560294);省部共建中亚高发病成因与防治国家重点实验室(SKI-HIDCA-2020-YG)

【作者简介】米吾尔依提·海拉提,硕士,研究方向:目标检测, E-mail: 2654458414@qq.com

【通信作者】严传波,教授,研究生导师,研究方向:医学图像处理, E-mail: ycbsky@126.com

病程的进展,可能会导致压迫周围脏器、病灶破裂、感染、过敏等情况发生,对患者造成严重危害。提高早期诊断准确率,减少误诊,在病灶扩大前去除病灶有着重要临床实际意义。超声诊断是肝包虫病的首选诊断方法^[11-12]。超声影像学检查技术具有较高的敏感性和特异性,能及时发现和检测包虫病灶,并能定性、定位和对有无子囊等作出较为客观的评价^[13-14]。然而,超声检查高度依赖于操作医师经验和仪器设备,尤其是肝包虫病的小病灶与周围正常肝

组织之间的边界不明确,外观多样性及密度不均匀等特点都加大了早期病灶检测的难度,如果经验不足,对包虫特征表现认识不够,会导致误诊、漏诊^[15],不仅耽误患者的及时治疗,导致病灶增大引起压迫等并发症,错误的治疗方式更是对患者的身体健康造成不必要的损伤,这在医疗服务不完善的边远地区更为严重,给治疗带来更大的难度,而且使患者承受更多的痛苦,同时也会增加额外的医疗资源损耗。



图1 肝CE病超声影像分型

Figure 1 Ultrasound imaging classification of cystic hepatic echinococcosis

有研究提出使用计算机辅助诊断(Computer Aided Diagnosis, CAD)的方法辅助医生对疾病做出诊断,以此来弥补部分地区医疗资源不足的情况^[16-17]。伴随着深度学习的快速发展,基于深度学习的影像处理技术逐渐被用于医学影像处理任务中,并取得了令人满意的结果。深度学习能自动从大样本的数据中学习,从而获得数据中深层次的特征表达,并且具有良好的特征鉴别能力^[18],可以有效地提升各种机器学习任务的性能,已广泛应用于信号处理、计算机视觉^[19]和自然语言处理^[20]等诸多领域;医学领域里,深度学习在脑肿瘤MR影像诊断^[21]、胰腺疾病诊断、乳腺疾病诊断^[22]等领域都取得了较好进展。目前,基于深度学习的医学影像处理作为一个新型交叉学科已成为智慧医疗领域发展最为迅猛的分支之一,能辅助影像医生解决病灶分割、定量评估、诊断、随访等多种临床问题。随着深度学习的发展,可以省去人工提取特征的步骤,实现病灶图像端到端的全自动诊断。深度学习发展至今,卷积神经网络一直是最常用的模型,只需将病灶图像及标注图像输入模型中进行训练测试,便可输出相应的诊断结果。其中,基于 AlexNet^[23]、VGGNet^[24]、GoogLeNet^[25]等网络的医学图像诊断方面取得了较好的进展^[26-27]。

尽管不断有新的病灶检测方法被提出,但由于肝包虫病超声图像中的小病灶具有面积较小、图像清晰度低以及成像方式的差异等特点^[28-31],将现有的

针对自然图像检测的主流算法直接应用于肝包虫病小病灶的检测上效果较差。目前小病灶主要有两种定义,一种是指物理尺寸较小的病灶($\leq 5\text{ cm}$);另一种则是在 MS-COCO^[32]度量评估中提出的像素 $\leq 32\times 32$ 的病灶。尽管目前目标检测算法在中大病灶上有着较高的检测性能,但将这些目标算法直接应用于小病灶的检测任务上,检测性能却差强人意,这是因为小病灶检测存在以下几个难点:(1)小病灶缺乏将它们与背景或类似类别区分开来所需的外观信息^[33-34];(2)小病灶由于尺寸小,其位置相应具有更多的可能性^[35],也就是说,对小病灶的定位的准确度要求更高;(3)由于先前大多数的研究都是针对自然图像中的中大型目标进行,小病灶检测的相关研究较少^[36],因此缺乏小病灶检测的经验和先验知识。小病灶检测问题现已成为计算机视觉中的研究热点,本研究针对肝CE超声图像中小病灶检测困难的问题,以YOLOv7为基底进行优化,提出一种基于深度学习的方法用于检测肝CE 5类分型的超声图像中的小病灶的方法,从而更好地辅助医生快速检测肝CE,降低早期肝CE的误诊率,实现早发现、早治疗。

1 基于深度学习的方法用于肝CE检测

1.1 YOLOv7

目标检测包括双阶段和单阶段两类。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^[37]、Fast

R-CNN^[38]、Faster R-CNN^[39]等;单阶段则无需生成样本的候选框,采用回归方法来定位目标进行检测,常见算法有YOLO (You Only Look Once)^[40]和SSD (Single Shot Multibox Detector)^[41]。双阶段目标检测算法的阶段性的检测过程导致模型整体检测速度较慢,不太适用于实时监测;单阶段的SSD算法虽检测速度较快,但准确率不如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,只经过一个神经网络,得到边界框的位置及其所属的类别,这使得YOLO系列算法的检测速度较为快速。目前YOLO系列已发展至YOLOv7系列,性能有巨大的提升^[42]。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。YOLOv7主要用于扩展的高效层聚合网络(E-ELAN)、模型缩放、计划重参数化模型等方法,使模型增强不同特征图学习到的特征,提高参数的使用和计算效率。如图2所示,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;其次,YOLOv7选用的CIoU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,本研究考虑采用更为轻量化方案进行特征提取,在保证丰富特征的前提下,减少参数量

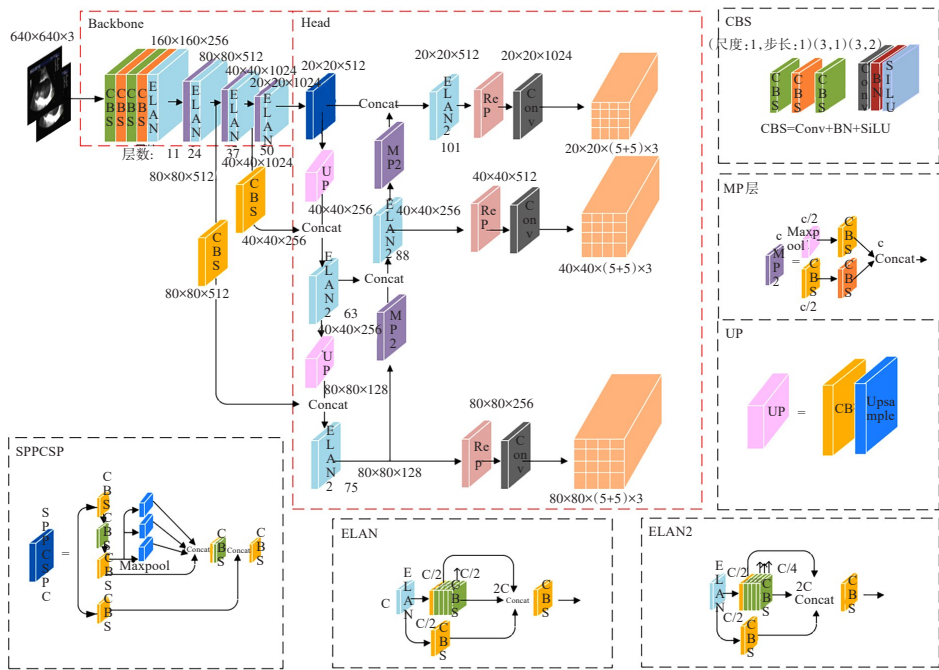


图2 YOLOv7网络结构
Figure 2 YOLOv7 network structure

1.2 GhostNet

GhostNet网络是由诺亚方舟团队在2020年提出的轻量级卷积神经网络,通过使用一些计算量更低的操作去生成更多的特征图,在保证良好检测效果的前提下,有效减少模型的参数量并提高模型的执行速度。如表1所示,GhostNet主要由Ghost模块组成的瓶颈结构(Ghost Bottlenecks)构成,其第1层是一个普通的卷积操作,Ghost Bottlenecks加载于模型的第2层以下的模块中,并随着通道数的增加而增加。Ghost Bottleneck整体架构和ResNet的残差模块非常相似,也可以认为是将残差模块中的普通卷积

操作替换成Ghost模块得到。

如图3所示,Ghost Bottlenecks由两个Ghost模块叠加而成。当步数=1时,第一个Ghost模块对通道数进行扩增,而第2个Ghost模块使其降低为与输入通道数一致,之后进行归一化(BN)和ReLU非线性函数(ReLU只用于第1个模块之后),此操作的功能为加深网络的深度,因此不会对输入特征层的高和宽进行压缩。当步数=2时,在两个Ghost模块之间加入一个步数为2的度可分离卷积层(Depwise Convolutional, DWConv),对特征图高和宽进行压缩,使其大小降为输入的1/2;在残差边部分,也添加

表 1 GhostNet 网络结构
Table 1 GhostNet network structure

输入	操作器	输出	是否使用 SE	步数
224×224×3	3×3 卷积	16		2
112×112×16	Ghost Bottlenecks	16		1
		24		2
24×56×24	Ghost Bottlenecks	24		1
		40	是	2
28×28×40	Ghost Bottlenecks	40	是	1
		80		2
14×14×80	Ghost Bottlenecks	80		1
		80		1
		80		1
		112	是	1
14×14×112	Ghost Bottlenecks	112	是	1
		160	是	2
7×7×160	Ghost Bottlenecks	160		1
		160	是	1
		160		1
		160	是	1
7×7×160	1×1 卷积	960		1
7×7×960	7×7 平均池化	-		-
1×1×960	1×1 卷积	1 280		1
1×1×1 280	全连接	1 000		-

一个步长为 2×2 的 DWConv 和 1×1 的普通卷积,以保证相加(Add)操作可以对齐,此功能会改变输入特征层的形状,因此也会对输入特征层的高和宽进行压缩。也就是说,当输入尺寸为 224×224×3 的图片后,经过一个标准卷积层后,再经过 16 个卷积核尺寸为 3×3 的 Ghost Bottlenecks 进行通道扩增和特征提取,最后经过全局平均池化和全连接将特征映射转换为最终的 1 280 维特征向量,用于分类任务。由此可知,Ghost 模块的计算成本明显低于直接使用传统卷积。

1.3 损失函数

1.3.1 IoU-Loss 目标检测一般分为定位和检测两部分,其中定位的准确率主要由损失函数来主导。交并比(Intersection over Union, IoU)是损失函数之一,在目标检测任务中扮演者度量预测框与真实框的重叠程度和作为边界框回归的损失函数对模型进行优化等角色。IoU 值计算公式如下:

$$IoU = \frac{A \cap B}{A \cup B}$$

(1)

其中,A 为真实边框、B 为预测边框。

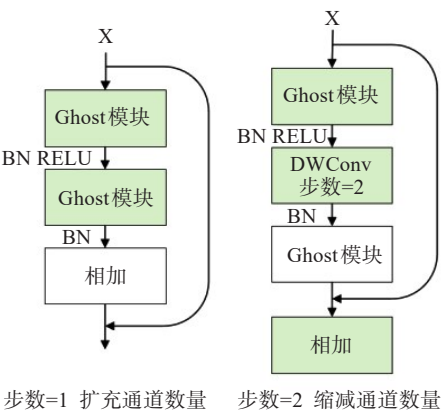


图 3 Ghost Bottlenecks
Figure 3 Ghost Bottlenecks

一般在计算机检测任务中,IoU≥0.5,属于检测正确,IoU 越接近于 1.0,说明预测框与真实框重合程度越高,代表模型预测越准确、平均精度越大。IoU 相关示意图见图 4。当 A 框与 B 框不重合时,IoU 为 0,并没有考虑框之间的距离,作为损失函数反向优化模型的能力弱(图 4a)。因此,在实际应用中使用进化版 IoU 尤为重要。

1.3.2 GIoU-Loss 有研究提出 GIoU^[43]。如图 4b 所示,GIoU 是对于任意的两个 A(真实边框)、B(预测边框),首先找到一个能包住它们的最小外包框 C,进而根据 A、B,算出 C 的面积,接着根据 C 的面积计算出 GIoU:

$$GIoU = IoU - \frac{|C/(A \cup B)|}{|C|}$$

(2)

当 IoU 为 0 时,意味着 A 与 B 非常远时, $\frac{A \cup B}{C}$ 无限接近于 0,GIoU 趋近于-1;当 IoU 为 1 时,两框重合, $\frac{A \cup B}{C}$ 为 1,所以 GIoU 的取值为(-1, 1]。GIoU 作为损失函数时,为 L=1-GIoU,当 A、B 两框不相交时 AUB 值不变,最大化 GIoU 就是最小化 C,这样就会促使两个框不断靠近。虽然 GIoU 解决了在 IoU 的反向优化模型的能力弱等问题,但它仍然存在着一定的不足。如图 4c 所示,当预测框(红色框)和真实框(绿色框)处于包含关系时,以 GIoU 和 IoU 公式进行计算得到的结果相同,也就是说在两框处于包含关系时,GIoU 作为损失函数反向优化模型的能力仍然较弱。

1.3.3 CIoU-Loss Zheng 等^[44]提出 CIoU。如图 4d 所示,CIoU 在 GIoU 中引入最小外包框(灰色框)来最大化重叠面积的惩罚项,修改成最小化预测框(红色框)和真实框(绿色框)中心点(b, b^g)的标准化距离,从而加速损失的收敛过程。CIoU 损失函数如下:




图4 IoU 相关示意图

Figure 4 IoU related schematic diagrams

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \alpha v \tag{3}$$

然而,CIoU 损失函数的最后一项 v 使用反正切函数(arctangent function)构成矩形宽高比的惩罚项,存在以下两个问题,影响CIoU的收敛速度和鲁棒性:(1) v 鲁棒性较弱,对离群值敏感,受离群值影响较大,导致损失函数的值变化波动较大,影响损失函数的性能。(2)反正切函数的值域为 $(0, \pi/2)$,不能直接满足损失函数的归一化要求。为实现罚项的数值归一化,需引入新的系数,这增加了计算复杂度。

1.3.4 ECIoU-Loss Yu 等^[45] 基于 CIoU 损失,提出一种更高效、更直接的回归损失函数 ECIoU。定义如下:

$$L_{\text{ECIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \beta \theta \tag{4}$$

其中, $\beta = \frac{\theta}{1 - \text{IoU} + \theta}$; $\theta = \left(\frac{1}{1 + e^{-\frac{w}{h^{\text{gt}}}}} - \frac{1}{1 + e^{-\frac{w}{h}}} \right)^2$ 。

ECIoU 损失函数的最后一项 θ 将矩形长宽比作

为 Sigmoid ($y=1/(1+\exp(-x))$) 函数的定义域,将预测框与真实框长宽比的差作为为函数的值域,并利用函数思想对损失函数惩罚项进行优化。惩罚项 θ 相比惩罚项 v 的 CIoU 损失函数更具鲁棒性和光滑性,其函数输出值为 $(0, 0.25)$,可以直接满足归一化的要求,简化原始损失函数的复杂性,使回归损失函数 ECIoU 能获得更快的收敛速度、更好的定位结果和模型性能。

1.4 本文方法

本文方法针对 YOLOv7 的上述不足进行改进:(1)借鉴图像分类轻量化网络 GhostNet 思想并对其进行调整,作为本次实验模型 YOLOv7 的主干,以减少密集连接,增加网络深度。减少密集连接可以降低整体的计算量,同时适当增加网络深度,能获得更丰富的特征。(2)在模型的标签分配部分,用更优的 ECIoU 损失替换原 CIoU 损失,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。改进后的 YOLOv7 网络结构如图 5 所示。

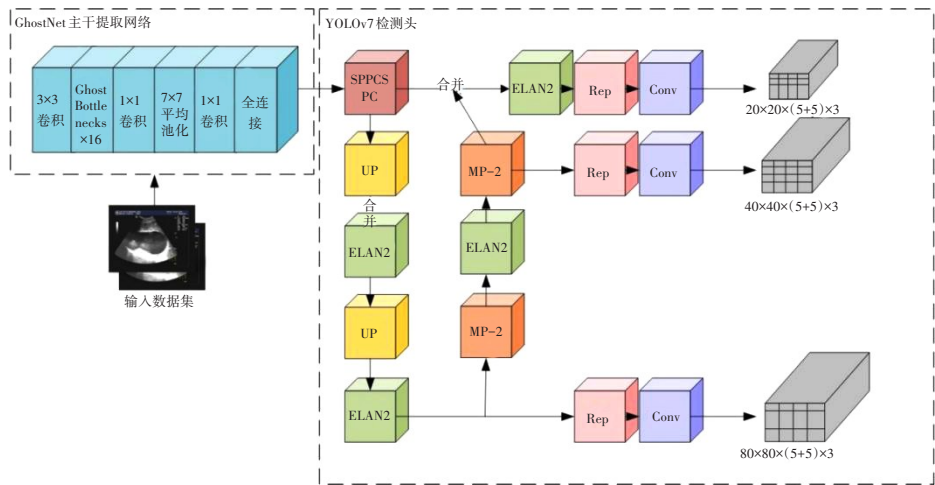


图5 改进后的YOLOv7网络结构

Figure 5 Improved YOLOv7 network structure

2 实验数据与实验环境

2.1 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例病人共计6854张肝CE超声影像图,在专业医生的指导下,从收集到图像中挑选出小病灶图像(病灶直径 ≤ 5 cm或像素大小 $\leq 32 \times 32$),建立小病灶数据集,并使用Labelimg图像标注软件对其进行手工标注,再根据VOC数据集中的规范要求完成保存。另外,基于肝CE超声图像的特征,本研究采用灰度尺寸归一化、自适应直方图均衡化、双边滤波及数据扩增这4种方法对数据进行预处理,最终得到2170张高质量图像(单囊型438张、多子囊型446张、坏死实变型454张、内囊塌陷型388张、钙化型444张),用于模型的训练和评估。

2.2 实验环境

实验环境基于linux操作系统ubuntu18.04.2 LST,使用GPU版Pytorch1.11深度学习框架Python3.7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200,迭代200次得到最终网络训练模型。

3 评价指标

采用平均精度均值(mAP)、每秒传输帧数(Fps)、参数量(Params)、浮点数(Flops)作为评价指标。在目标检测中对多个验证样本个体求mAP,衡量检测精度,mAP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,单位为fps,用来评估检测模型的运行速度,Fps值越大表示模型检测速度越快,其算法的实时检测性能越好。参数量表示模型大小,单位为M,其值越小,说明模型越轻便。浮点数衡量模型的复杂度,解释算法速度,大模型的单位为G,小模型单位为M。此外还采用边缘框损失(Box loss)、定位损失(Objectness loss)、分类损失(Classification loss)、验证集边缘框损失(val Box loss)、验证集定位损失(val Objectness loss)、验证集分类损失均值(val Classification loss)等损失值评估模型的收敛程度,用准确率(Precision)、召回率(Recall)、50%平均精度均值(mAP@0.5)、95%平均精度均值(mAP@0.5:0.95)等评估模型训练效果。

4 研究方法

为验证本研究提出的各个改进是否有效,设计一组消融实验进行对比分析,训练过程中均采用相同参数,在自制肝CE小病灶数据上进行实验。实验I

是将GhostNet网络作为新的骨干网络;实验II是将CIoU-Loss替换为ECIoU-Loss。YOLOv7+I为将YOLOv7的主干替换成GhostNet、YOLOv7+II为将YOLOv7的CIoU-Loss替换为ECIoU-Loss、YOLOv7+I+II为将YOLOv7的主干替换成GhostNet,再将CIoU-Loss替换为ECIoU-Loss。采用混淆矩阵和热力图对模型的性能和病灶定位能力进行可视化展示。此外,本研究将改进后的YOLOv7与当前主流的目标检测网络YOLOv3、YOLOv5、SSD、Faster-R-CNN和DETR等进行对比实验,以进一步验证本文算法的有效性。采用混淆矩阵和热力图对模型的性能和病灶定位能力进行可视化展示。

5 实验结果与分析

5.1 消融实验结果分析

消融实验结果如表2所示。将原始YOLOv7模型直接作为的检测网络进行实验,所得模型精度为86.0%,参数量、浮点数和运行速度分别为36.5 M、103.2 G、46.0 fps。将GhostNet网络作为YOLOv7的骨干网络进行实验(YOLOv7+I),相比原始YOLOv7,精度提升1.2%,参数量、浮点数和运行速度分别为21.7 M、59.4 G、40.0 fps,模型大小明显得到缩小。将ECIoU损失嵌入YOLOv7的Head部分进行实验(YOLOv7+II),相比原始YOLOv7,精度提升0.2%,参数量、浮点数和运行速度分别为36.5 M、59.4 G、39.0 fps,性能得到进一步的提高。将GhostNet网络作为YOLOv7的骨干网络的同时在Head部分嵌入ECIoU损失进行实验(YOLOv7+I+II),相比原始YOLOv7,精度提升2.1%,参数量、浮点数和运行速度分别为21.7 M、59.4 G、52.5 fps,证明改进的有效性。

表2 在肝CE小病灶数据集上消融实验结果
Table 2 Ablation experiment results on the dataset of small hepatic cystic echinococcosis lesions

模型	mAP@0.5/%	Params/M	Flops/G	Fps/fps
YOLOv7	86.0	36.5	103.2	46.0
YOLOv7+I	87.2	21.7	59.4	40.0
YOLOv7+II	86.2	36.5	59.4	39.0
YOLOv7+I+II	88.1	21.7	59.4	52.5

在肝CE小病灶数据集上进行的消融实验性能对比结果如图6所示。其中改进后的YOLOv7(YOLOv7+I+II)的边缘框损失、定位损失、分类损失、

验证集边缘框损失均值、验证集定位损失、验证集分类损失值总体均较其他实验小,准确率、召回率、 $mAP@0.5$ 、 $mAP@0.5:0.95$ 总体均较其他实验大,说明 ECIoU 损失函数的定位与分类效果相比 CIoU 损失函数好,更适用于肝 CE 小病灶检测任务。

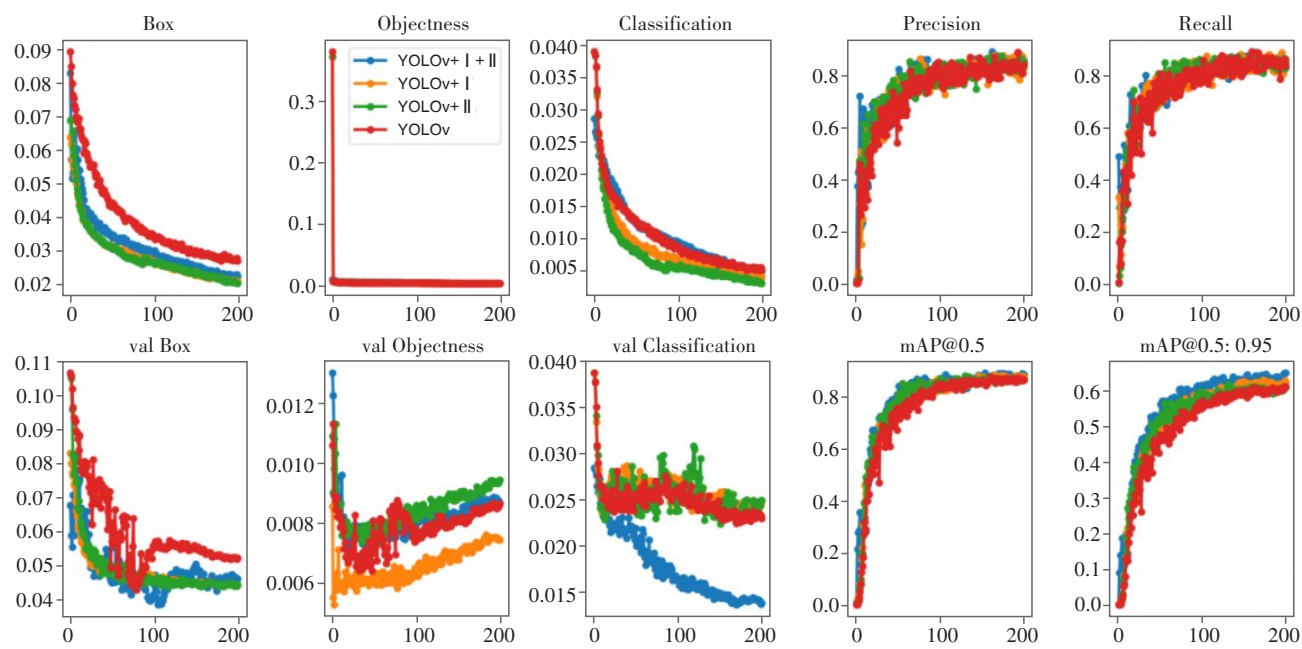


图6 在肝 CE 小病灶数据集上消融实验性能对比

Figure 6 Comparison of ablation performance on the dataset of small hepatic cystic echinococcosis lesions

5.2 与主流目标检测网络进行比较

为进一步验证本文算法的有效性,与当前主流的目标检测算法模型进行对比实验,包括 YOLOv3、YOLOv5、SSD、Faster-R-CNN 和 DETR,对比实验结果如表 3 所示。本文算法与 YOLOv3、YOLOv5、SSD、Faster-R-CNN 等基于 CNN 的模型相比, $mAP@0.5$ 分别提高 6.2%、2.2%、7.3%、1.7%,参数规模和浮点数分别下降 40.2、9.2、19.3、115.3 M 和 6.8、8.5、327.6、310.8 G;运行速度分别提高 19.5、5.5、17.7、12.7 fps。与 DETR 等基于 Transformer 的模型相比 $mAP@0.5$ 提高 5.1%,参数规模和浮点数分别下降 15.0 M 和 54.8 G,运行速度提高 5.9 fps。总体来说,改进后的 YOLOv7 模型在模型轻量化的同时提高了模型的精度,有效地平衡精度和轻量化。

5.3 混淆矩阵

混淆矩阵是一种用于评估分类模型性能的工具,它将实际目标值与模型预测的目标值进行比较,并将结果显示在一个 $N \times N$ 的矩阵中,其中 N 是目标类别的数量。混淆矩阵的 4 个主要元素包括真正例(True Positive, TP)、真反例(True Negative, TN)、假正例(False Positive, FP)和假反例(False Negative, FN),其中,TP 表示模型正确地将正例预测为正例的数量,FN 表示模型

表 3 在肝 CE 小病灶数据集上与目标检测模型结果对比

Table 3 Comparison of detection results between the proposed method and other target detection models on the dataset of small hepatic cystic echinococcosis lesions

模型	$mAP@0.5/\%$	Params/M	Flops/G	Fps/fps
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	47.0
YOLOv7	86.0	36.5	103.2	46.0
YOLOv7+I+II	88.1	21.7	59.4	52.5

错误地将正例预测为反例的数量,FP 表示模型错误地将反例预测为正例的数量,TN 表示模型正确地将反例预测为反例的数量。根据混淆矩阵可以计算出一些重要的分类指标,如准确率、精确率、召回率和 F1 值等,从而评估模型的性能和效果。

图 7 为本模型训练完成后得到的混淆矩阵,其横坐标表示真实标签,纵坐标表示预测标签。对角线上的元素表示分类正确的样本数,而其他元素表示

分类错误的样本数,由图可知在肝CE的5分类中,钙化型的准确率最低,这可能是由于钙化型的病灶形态较复杂,类内相似度低、类间相似度高有关。




图7 混淆矩阵

Figure 7 Confusion matrix

dn:单囊型(CE-1);duo:多子囊型(CE-2);nt:内囊塌陷型(CE-3);hs:坏死实变型(CE-4);gh:钙化型(CE-5)

5.4 检测效果分析

为对比本文改进模型和原YOLOv7模型的检测效果,本研究采用从肝CE超声图像中随机抽出两张图像进行检测和可视化。图8a为肝多囊型病灶超声图像病灶分类检测效果。可以看出,在同一张图像上进行验证,改进后的YOLOv7的检测精度更高。图8b为单囊型病灶超声图像的可视化病灶定位效果。本研究采用Grad-CAM(Gradient-weighted Class Activation Mapping)可视化方法,Grad-CAM是一种用于可视化深度神经网络的热力图的方法,通过计算模型最后某个类别对于特征层的梯度来确定哪些区域对于该类别的预测起到重要作用。将原模型和改进后的YOLOv7模型在一张图像上进行对比,可以看出改进后的YOLOv7模型有着更好的定位能力。

6 结 语

本研究选取YOLOv7作为基础网络,用标注后的肝CE图像数据集,针对肝包虫病在肝脏区域常发病位置和类型进行分类,借鉴GhostNet网络思想改

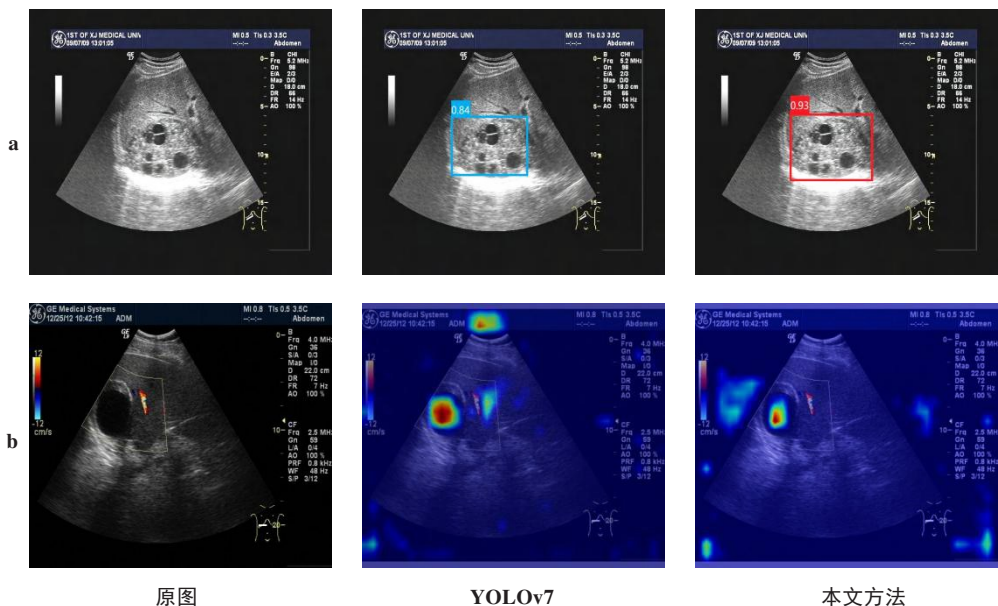


图8 在肝CE的坏死实变型(CE-4)上原始模型与本文模型检测效果对比

Figure 8 Comparison of detection performance between the original model and the improved model on the necrotic variant (CE-4) of hepatic cystic echinococcosis

进骨干网络,有效增强特征提取能力;利用ECIoU-Loss的优势改进模型的Head部分,使得模型在得到高精度检测效果的同时减少不必要的参数量,为肝CE的计算机诊断系统的构建提供理论基础。结果表明改进后的YOLOv7在准确度上有更良好的表现,

在测试数据集上mAP(mAP@0.5)达到88.1%,高于其他同类目标检测网络算法,且能完成对病灶进行实时检测的要求,能有效检测出病灶,从而得到病灶的位置信息。接下来的研究将继续探究提高对难检测病灶的检测精度的方法。

【参考文献】

- [1] Deplazes P, Rinaldi L, Alvarez Rojas CA, et al. Global distribution of alveolar and cystic echinococcosis [J]. *Adv Parasitol*, 2017, 95: 315-493.
- [2] Flisser A. Eliminating cystic echinococcosis in the 21st century [J]. *Lancet Infect Dis*, 2018, 18(7): 703-704.
- [3] Faraj W, Abi Faraj C, Kanso M, et al. Hydatid disease of the liver in the Middle East: a single center experience [J]. *Surg Infect (Larchmt)*, 2022, 23(1): 29-34.
- [4] Tamarozzi F, Akhan O, Cretu CM, et al. Prevalence of abdominal cystic echinococcosis in rural Bulgaria, Romania, and Turkey: a cross-sectional, ultrasound-based, population study from the HERACLES project [J]. *Lancet Infect Dis*, 2018, 18(7): 769-778.
- [5] 中华医学会放射学分会传染病学组, 中国医师协会放射医师分会感染影像专业委员会. 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.
- [6] 马国祥, 严传波, 杨凌菲, 等. 基于深度学习的肝包虫病超声影像诊断方法研究 [J]. *现代电子技术*, 2023, 46(8): 66-72.
- [7] 任阿红, 刘军, 杨大为, 等. 肝囊型包虫病与粘液性囊性肿瘤的影像学鉴别诊断 [J]. *放射学实践*, 2022, 37(9): 1080-1084.
- [8] Bhutani N, Kajal P. Hepatic echinococcosis: a review [J]. *Ann Med Surg (Lond)*, 2018, 36: 99-105.
- [9] Rawla P, Sunkara T, Muralidharan P, et al. An updated review of cystic hepatic lesions [J]. *Clin Exp Hepatol*, 2019, 5(1): 22-29.
- [10] Mihmanli M, Idiz UO, Kaya C, et al. Current status of diagnosis and treatment of hepatic echinococcosis [J]. *World J Hepatol*, 2016, 8(28): 1169-1181.
- [11] 王柄华, 游益娟, 周果, 等. 冰雹型肝泡型包虫病的超声造影增强模式分析 [J]. *中国超声医学杂志*, 2023, 39(4): 418-420.
- [12] 热娜古丽·艾合麦提尼亚孜, 米吾尔依提·海拉提, 王正业, 等. 基于Swin Transformer的肝囊型包虫病超声图分类研究 [J]. *电子技术应用*, 2022, 48(11): 7-12.
- [13] 万敏, 蔡迪明, 李永忠, 等. 超声造影在泡型肝包虫病与肝血管瘤鉴别诊断中的价值 [J]. *西部医学*, 2020, 32(6): 908-913.
- [14] 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.
- [15] 王晓雷, 郝文超, 刘志军, 等. 肝包虫病误诊为肝囊肿原因分析及文献复习 [J]. *临床误诊误治*, 2017, 30(2): 4-6.
- [16] Mannil M, Eberhard M, von Spiczak J, et al. Artificial intelligence and texture analysis in cardiac imaging [J]. *Curr Cardiol Rep*, 2020, 22(11): 131.
- [17] 李诚霖. 数据挖掘中的数据分类算法综述 [J]. *数据*, 2021, 4: 48-50.
- [18] 朱健椿, 魏嘉昕, 毛浚彬, 等. 深度学习在磁共振影像脑疾病诊断中的应用 [J]. *工程科学学报*, 2024, 46(2): 306-316.
- [19] 张湖波, 邹细勇, 邵建文, 等. 基于机器视觉的呼出气体酒精含量检测仪自动检定装置 [J]. *现代电子技术*, 2024, 47(1): 111-117.
- [20] 陈可, 王俊. 基于自然语言处理的非小细胞肺癌知识图谱构建 [J]. *中国卫生信息管理杂志*, 2023, 20(6): 1019-1025.
- [21] 吴双, 陈蔓, 周育夫. 人工智能技术在脑肿瘤影像诊断和评估中的应用 [J]. *中国医疗设备*, 2020, 35(12): 171-176.
- [22] 刘东婷, 黄秀娟, 温兆赢, 等. 人工智能在乳腺钼靶X线摄影诊断乳腺疾病中的应用研究 [J]. *中国医药*, 2022, 17(3): 366-370.
- [23] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks [C]//*Proceedings of the 25th International Conference on Neural Information Processing Systems—Volume 1*. Red Hook, NY, USA: Curran Associates Inc., 2012: 1097-1105.
- [24] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2015-04-10)[2021-04-20]. <https://arxiv.org/abs/1409.1556>.
- [25] Szegedy C, Liu W, Jia YQ, et al. Going deeper with convolutions [C]//*2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway, NJ, USA: IEEE, 2015: 1-9.
- [26] 蒋芙蓉, 赵静文, 刘翔, 等. 基于病理图像的计算机辅助诊断进展 [J]. *中国医学物理学杂志*, 2022, 39(3): 384-389.
- [27] 刘志华, 卡迪力亚·库尔班, 李丰军, 等. Faster RCNN模型和SCP方法在肝包虫病病灶位置估计中的研究 [J]. *中国医疗设备*, 2021, 36(9): 91-94.
- [28] 热娜古丽·艾合麦提尼亚孜, 米吾尔依提·海拉提, 王正业, 等. 改进ConvNeXt的肝囊型包虫病超声图像五分类研究 [J]. *现代电子技术*, 2024, 47(1): 62-68.
- [29] 热娜古丽·艾合麦提尼亚孜, 米吾尔依提·海拉提, 王正业, 等. 改进ConvNeXt的肝囊型包虫病超声图像五分类研究 [J]. *现代电子技术*, 2024, 47(1): 62-68.
- [30] 袁静楠, 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.
- [31] Qiu JT, Zou JZ, Guo YC, et al. Applicable prediction scheme for segmentation of liver and lesion [J]. *Computer Engineering and Applications*, 2020, 56(20): 173-178.

- [32] Lin TY, Maire M, Belongie S, et al. Microsoft COCO: common objects in context [C]//Computer Vision-ECCV 2014. Cham: Springer International Publishing, 2014: 740-755.
- [33] Tong K, Wu YQ, Zhou F. Recent advances in small object detection based on deep learning: a review[J]. Image Vision Comput, 2020, 97: 103910.
- [34] 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.
Lü PJ, Liu NN, Wang LT, et al. Deep learning image reconstruction for optimizing image quality of low-energy spectral monochromatic CT and detecting liver small low-contrast lesions[J]. Chinese Journal of Medical Imaging Technology, 2023, 39(1): 104-108.
- [35] 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.
Wu DL. Detection of small lesions in liver CT images based on improved Faster R-CNN[D]. Nanning: Guangxi University, 2022.
- [36] 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.
Chen H, Yang SY. Analysis of the early diagnostic value of contrast-enhanced ultrasound for small liver parenchymal lesions[J]. World Latest Medicine Information, 2019, 19(85): 186.
- [37] 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.
- [38] Girshick R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2015: 1440-1448.
- [39] Ren SQ, He KM, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(6): 1137-1149.
- [40] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 779-788.
- [41] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector [C]//Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [42] Wang CY, Bochkovskiy A, Liao HY. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2023: 7464-7475.
- [43] Rezatofighi H, Tsoi N, Gwak J, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2019: 658-666.
- [44] Zheng ZH, Wang P, Liu W, et al. Distance-IoU loss: faster and better learning for bounding box regression[J]. arXiv:1911.08287, 2019.
- [45] Yu JM, Wu T, Zhang X, et al. An efficient lightweight SAR ship target detection network with improved regression loss function and enhanced feature information expression[J]. Sensors (Basel), 2022, 22(9): 3447.

(编辑:谭斯允)