

基于改进DeepLabV3+的囊型肝包虫病超声图像分割算法

米吾尔依提·海拉提¹, 热娜古丽·艾合麦提尼亚孜¹, 李莉², 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:将基于改进DeepLabV3+的图像语义分割算法应用到囊型肝包虫病超声图像处理中,实现肝包虫病病灶的自动分割与检测,提高临床诊断效率。**方法:**本研究采用了DeepLabV3+图像语义分割网络为基础方法,并对其进行了以下改进。首先,为解决DeepLabV3+图像语义分割方法计算复杂度高,内存消耗大,难以在计算能力有限的嵌入式平台上部署,在提取图像特征信息时难以充分利用多尺度信息等问题,以MobileNetV2替换模型的原主干网络Xception,获得轻量级的模型框架。其次,将高效通道注意力应用于底层特征,降低计算复杂度,提高目标边界的清晰度。最后,将Dice Loss引入模型中,缓解模型更关注背景区域,而忽略了包含目标的前景区域等问题。**结果:**在自建囊型肝包虫病VOC2007数据集5种病灶类型上进行验证,实验结果表明,改进模型的平均交并比和平均像素精度分别达到73.8%和83.5%,能够预测更精细的语义分割结果,有效地优化模型复杂度和分割精度。

【关键词】囊型肝包虫病;深度学习;DeepLabV3+;MobileNetV2;高效通道注意力

【中图分类号】R316;R445.1

【文献标志码】A

【文章编号】1005-202X(2024)06-0702-08

Ultrasound image segmentation algorithm for hepatic cystic echinococcosis based on improved DeepLabV3+

HAILATI Miwueryiti¹, AIHEMAITINIYAZI Renaguli¹, LI Li², YAN Chuanbo²

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

Abstract: Objective To apply the improved DeepLabV3+ based image semantic segmentation algorithm to the ultrasound image processing for hepatic cystic echinococcosis, thereby achieving automatic segmentation and detection of hepatic echinococcosis lesions, and improving clinical diagnostic efficiency. **Methods** DeepLabV3+ based image semantic segmentation network was employed as the basic method, and the following improvements were made. To address the issues of high computational complexity, high memory consumption, difficulty in deploying on embedded platforms with limited computing power, and difficulty in fully utilizing multi-scale information when extracting image feature information, the original backbone network Xception of the model was replaced with MobileNetV2 for obtaining a lightweight model framework. Additionally, efficient channel attention was applied to underlying features for reducing computational complexity and improving the clarity of target boundaries; and finally, Dice Loss was introduced into the model to alleviate the problem of the model focusing more on the background area and ignoring the foreground area containing the target. **Results** Validation was conducted on 5 lesion types in the self-built VOC2007 dataset of hepatic cystic echinococcosis. Experimental results showed that the improved model achieved a mean intersection over union of 73.8 and a mean pixel accuracy of 83.5, indicating that the model can predict more precise semantic segmentation results and effectively optimize model complexity and segmentation accuracy.

Keywords: hepatic cystic echinococcosis; deep learning; DeepLabV3+; MobileNetV2; efficient channel attention

【收稿日期】2024-01-26

【基金项目】国家自然科学基金(81560294)

【作者简介】米吾尔依提·海拉提, 硕士研究生, 研究方向: 医学图像处理,

E-mail: 2654458414@qq.com

【通信作者】严传波, 硕士, 研究方向: 医学图像处理, E-mail: yecsky@126.

com

前言

包虫病又称为棘球蚴病(Echinococcosis),是由棘球绦虫的幼虫寄生于哺乳动物体内所导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400万人感染肝包虫病,有6000万人处于感染风险中^[2]。我国肝包虫病的患病率也较高,在过去的20

年里,我国新增肝包虫病病例5 000余例^[3],尤其在我国的西北部地区高发,人群患病率为0.5%~5.0%,在新疆、甘肃、西藏、宁夏、四川等西北畜牧业发达地区普遍存在。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。分别由带绦虫科棘球绦虫属的两种绦虫即细粒棘球绦虫(*Echinococcus granulosus*)和多房棘球绦虫(*Echinococcus multilocularis*)感染所致^[4-5]。其中CE在我国多见,CE目前临床上主要使用的标准化分型为WHO制定的分型方案^[6],将CE分为5型:单囊型(CE1)、多子囊型(CE2)、内囊塌陷型(CE3)、坏死实变型(CE4)、钙化型(CE5)。肝包虫病在早期时,可服药控制发展,但晚期超过7 cm时就必须进行手术干预^[7-8]。所以在病灶较小,未侵害到周围器官时,及时作出准确诊断极其重要。超声在肝包虫病灶的检测方面有着较高的灵敏度,是诊断肝包虫病的首选影像学检查方法,但由于肝包虫病灶随病程、病情的不同表现,颇具多样性和复杂性。若医师经验不足,或对包虫特征性声像图表现认识不够的话,可能会导致误诊、漏诊等情况发生。因此,在肝包虫病早期进行准确的诊断实现早诊断、早治疗,预防病灶对周围器官的侵害和病情的加重,构建准确高效的肝包虫病早期可疑病灶鉴别诊断模型,可以降低肝包虫病漏诊与误诊率,对后续的治疗有积极意义^[9]。

近年来,医学影像技术快速发展,世界各地每天都会产生各类型医学影像学信息,基于机器学习和深度学习的计算机辅助诊断(Computer Aided Diagnosis, CAD)在影像诊断领域发展迅速^[10]。它可以有效地降低医师的工作量,提高诊断准确度,降低主观误判,加快诊断的速度。CAD主要依靠医学图像处理技术,它是把各种不同成像机制的医学影像当作自己处理对象进行加工操作^[11],包括图像变换、压缩、图像检测、分割、图像融合等^[12]。在肝包虫病的辅助诊断算法研究上,虽然现在也有很多传统的机器学习方法在病灶分类识别、分割、配准、融合等方面取得很好的效果,但是传统方法本身的局限性导致其仍然存在很多问题,传统模型难以适应大规模数据集,模型可扩展性和适用性差且处理速度慢;一种方法或一组参数只适用于某一特定模态甚至是特定的数据集上^[13];由于传统的方法大都是采用迭代优化的方式搜寻最优参数的,这导致其处理速度相当慢,很难应用在实时化场景中^[14]。

基于深度学习的CAD的出现极大地提高了医学领域的诊断效率。语义分割的概念很容易理解。当

人们看到一张图片时,很容易理解图片的内容。语义分割允许机器理解图片的内容。在现实中的应用也越来越广泛,例如自动驾驶技术的场景识别、医学图像分割领域、手术导航、广告推荐等。图像语义分割的广泛应用具有很高的实用价值^[15]。目前基于DeepLabV3+的方法计算复杂度高,内存消耗大,难以在计算能力有限的嵌入式平台上部署^[16]。DeepLabV3+在提取图像特征信息时不能充分利用多尺度信息,容易造成细节信息的丢失,导致分割精度受损。本文模型主要基于DeepLabV3+进行改进。本文的主要贡献总结如下:(1)对DeepLabV3+网络进行改进,使其适合于现实场景的需求。原始特征提取网络参数量过大,模型采用轻量级的MobileNetV2^[17]作为主干网络,在此基础上进一步优化,解决空间细节丢失和特征提取不足的问题。(2)在DeepLabV3+中,在MobileNetV2底层特征之后加入高效通道注意力(Efficient Channel Attention, ECA)机制^[18],恢复更清晰的分割边界。(3)为了解决正负样本不均衡问题,将损失函数Dice Loss^[19]引入到模型中,提高模型的分割性能。

1 数据集采集与处理

本研究选用的数据集来源于新疆医科大学第一附属医院2008年1月~2018年12月采集的囊型肝包虫病患者影像资料,本研究已通过新疆医科大学第一附属医院伦理审查委员会批准(K202207-12)。参考世界卫生组织包虫病非正式工作组关于包虫病灶分型标准^[20],本次纳入研究的囊型肝包虫病超声图像分为5种类型:单囊型、多子囊型、内囊塌陷型、坏死实变型、钙化型。将数据集按照8:2的比例分为训练集和测试集,进而使用Labelme图像标注软件对其进行手工标注,按VOC2007数据集中的规范要求完成保存。另外,基于囊型肝包虫病超声图像的特征,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2 425张高质量图像(单囊型500张、多子囊型501张、坏死实变型496张、内囊塌陷型434张、钙化型494张),用于模型的训练和评估,如图1所示。

2 囊型肝包虫病超声图像分割模型设计

在临床诊断中将囊型肝包虫病与其他病灶区分以及检测出小病灶较为困难。本文结合囊型肝包虫病数据集的特征,以DeepLabV3+模型为基础,通过大量实验对模型进行优化,来提高模型的准确性和实时性。

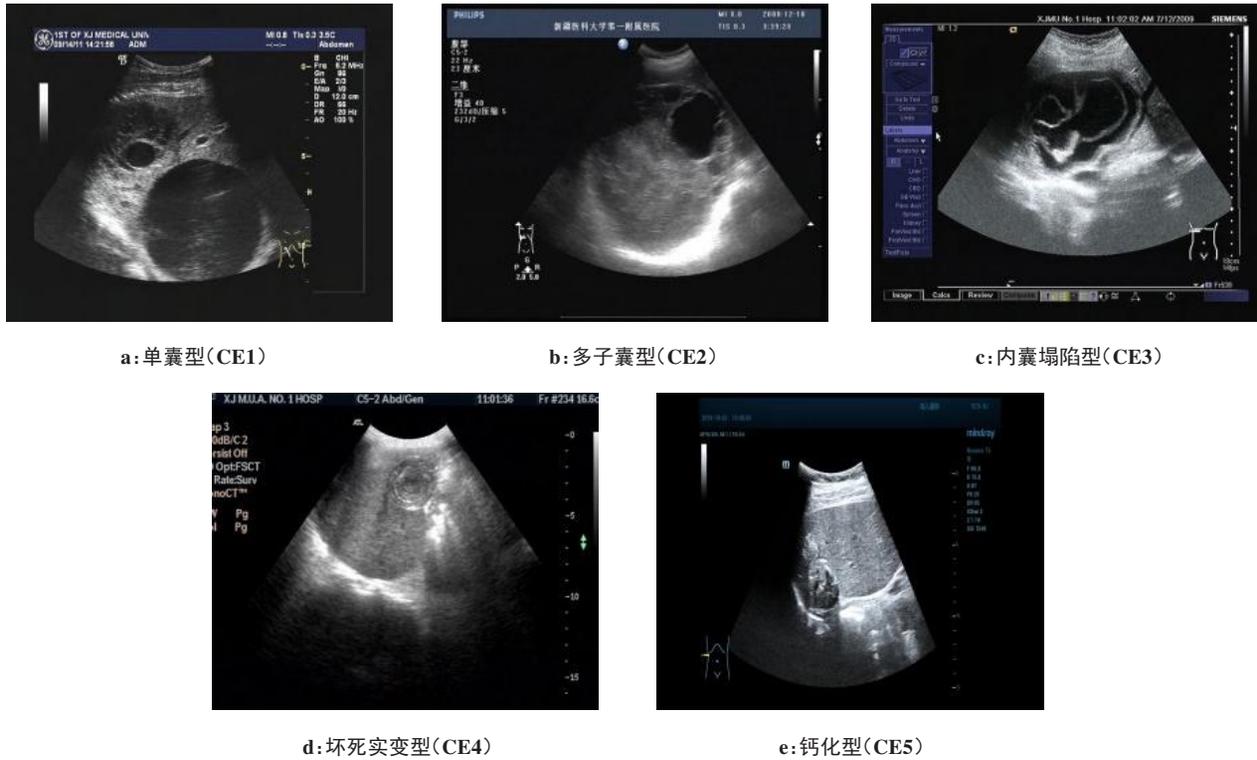


图1 囊型肝包虫病超声影像分型
Figure 1 Ultrasound imaging classification of hepatic cystic echinococcosis

2.1 DeepLabV3+基础网络模型搭建

DeepLabV3+为典型的逐像素语义分割模型,能够为输入图像中的每个像素分配相应的类别标签。DeepLabV3+模型通过编码-解码结构实现对输入图像的逐像素分割,其网络结构如图2所示。首先,在编码器中以Xception作为主干特征提取网络,提取图像的浅层特征并传入解码器。在空洞空间金字塔池化(Atrous

Spatial Pyramid Pooling, ASPP)模块中通过 1×1 卷积、膨胀率分别为6、12、18的多尺度空洞卷积以及池化(Image pooling),将ASPP模块的多个输出结果拼接融合(Concat)得到深层特征图。其次,在解码器中,对获取到的深层特征进行4倍上采样(Upsample),并与浅层特征融合后再经过4倍双线性插值(Bilinear interpolation)上采样恢复到原尺寸,输出最终的预测结果。

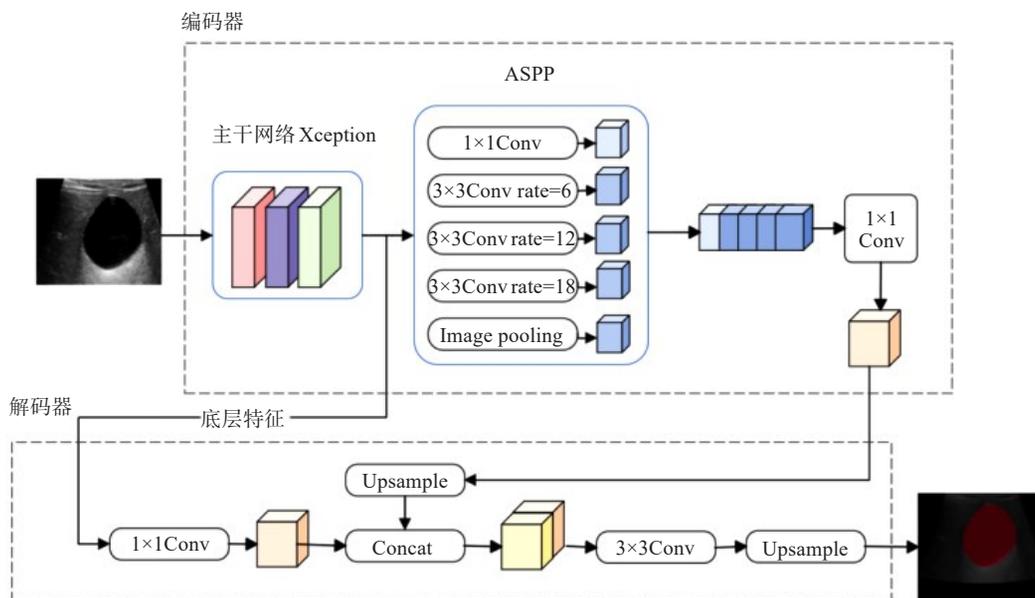


图2 DeepLabV3+模型网络结构
Figure 2 DeepLabV3+ network structure

2.2 改进的囊型肝包虫病超声图像分割模型设计

以DeepLabV3+模型为主体进行改进。在基于DeepLabV3+网络的图像语义分割中,本文采用轻量级的MobileNetV2作为主干网络。然后在ASPP模块

之后加入ECA融合到MobileNetV2中得到更多细节特征。为了解决正负样本不平衡问题,将损失函数Dice Loss引入到模型中,提高模型的分割性能。改进后的模型如图3所示。

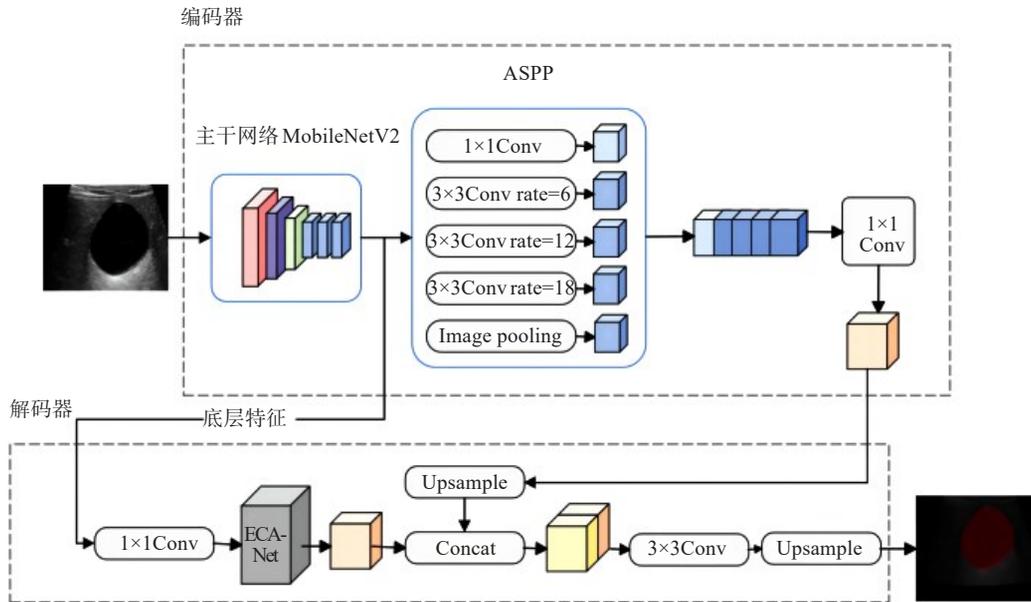


图3 改进后的DeepLabV3+网络结构

Figure 3 Improved DeepLabV3+ network structure

2.2.1 主干特征提取网络 DeepLabV3+原模型以Xception作为主干网络^[21],其结构如图4所示,由Entry flow、Middleflow、Exit flow 3个部分构成,共包含14个模块。Xception的网络层次深,参数量达57.7 M,在训练和应用中的计算量庞大。实际应用于无人机等资源受限的平台时,较大的参数量可能导致推理时间增加,从而影响设备的响应速度。为提高计算效率,采用MobileNetV2作为主干特征提取网络,其模型结构如图5所示。MobileNetV2采用倒残差结构(Inverted residual block),使得网络在保持较小参数量和计算复杂度的同时,仍具有相对较好的特征提取能力。首先进行1×1卷积升维(Expansion layer),得到更多的特征,然后进行3×3深度可分离卷积操作,最后再用1×1卷积降维(Projection layer),使用shortcut(快捷连接),将两者相加输出。

MobileNetV2相较于Xception模型,拥有更少的参数量和更低的计算复杂度,能够更好地适应无人机等移动设备的特殊环境。因此,采用MobileNetV2作为主干特征提取网络,使模型具有更好的实时性,能够更快速地响应任务需求。网络结构见图5。

2.2.2 ECA ECA的优点是利用全局池化将空间矩阵转化为一维向量,然后根据网络通道的数量得到一

维卷积核的大小。主要使用自适应大小的卷积核进行卷积运算,通过加权形式得到输入图像的特征映射;最后,将输入图像与卷积计算后得到的特征映射相乘,提取感兴趣的信息。由于网络采用骨干网络的预训练方法,在MobileNetV2中插入ECA会破坏主干网络的网络结构。因此,在MobileNetV2的浅层特征中插入ECA可以在不破坏网络的情况下提高分割效果。网络结构如图6所示。

2.2.3 损失函数 在图像语义分割任务中,常用的损失函数为交叉熵损失,但是存在样本类别不平衡的问题,交叉熵损失函数并不能很好地解决。针对正负样本严重不平衡问题^[22],本文提出将损失函数Dice Loss引入到模型中,提高模型的分割性能,以此解决正负样本不平衡、样本量少等问题。Dice Loss是一种用于图像分割的损失函数,它可以帮助模型更好地处理类别不平衡的情况。具体来说,Dice Loss使用Dice系数作为相似度度量,将其转化为一个可优化的损失函数,使得模型更加关注边界的准确性。Dice loss基于Dice系数来计算,取值为0~1,当预测结果与真实标签完全一致时,Dice系数为1,Dice Loss为0;当预测结果与真实标签完全不一致时,Dice系数为0,Dice Loss为1。具体计算公式如下:

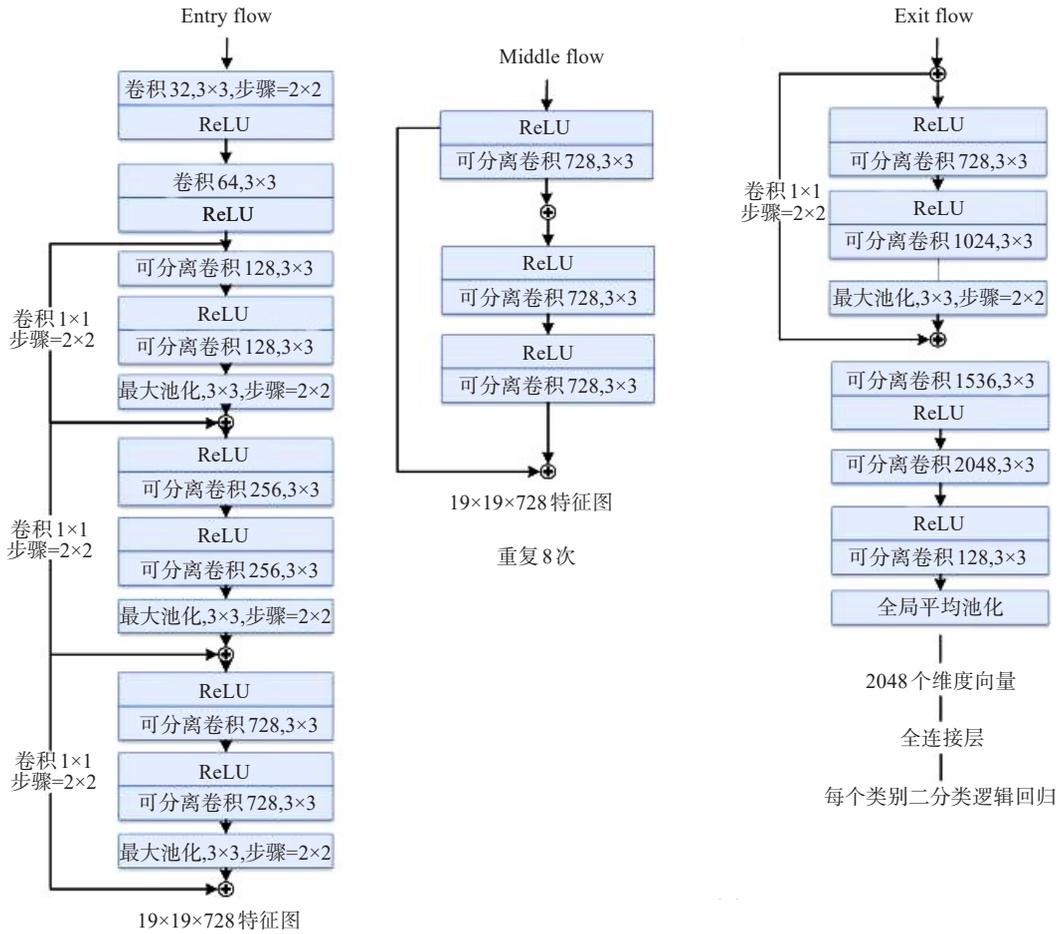


图4 Xception网络结构

Figure 4 Xception network structure



图5 MobileNetV2网络结构

Figure 5 MobileNetV2 network structure

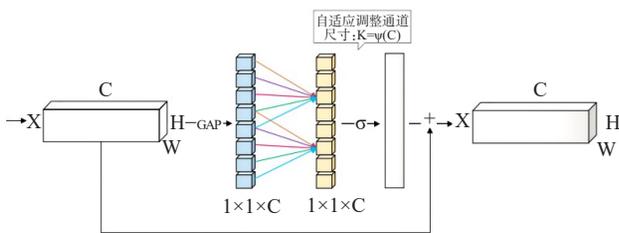


图6 ECA机制

Figure 6 Efficient channel attention mechanism

$$\text{Dice coefficient} = 2 \times \frac{\text{预测结果} \cap \text{真实标签}}{(|\text{预测结果}| + |\text{真实标签}|)} \quad (1)$$

$$\text{Dice Loss} = 1 - \text{Dice coefficient} \quad (2)$$

3 实验结果与分析

3.1 评价指标

本研究将采用平均像素精度 (mean Pixel Accuracy, mPA)、平均交并比 (mean Intersection over Union, mIoU) 和 Dice 系数评价模型的分割精度, 用参数总数 (Params) 和浮点运算数 (Floating Point Operations, FLOPs) 评价模型规模大小, 用每秒处理帧数 (Frames Per Second, FPS) 评价模型分割速度。像素精度 (Pixel Accuracy, PA) 通过计算预测结果中正确分类的像素数量与总像素数量之间的比例, 衡量模型对整个图像的整体分类准确性; mPA 是对多张图像计算 PA 后取平均值得到的指标, 衡量多个图像的分类准确性; mIoU 计算预测结果与真实标签之间的交并比, 并对多个类别取平均值, 衡量模型对每个类别的分割准确性。Dice 系数计算预测结果与真实标签之间的相似度, 衡量模型对每个类别的分割准确性。以上 4 个指标都反映分割准确性, 其值越大越好。具体计算公式如下所示:

$$PA = \frac{\sum_i P_{ii}}{\sum_i P_{ii} + \sum_j P_{ij}} \quad (3)$$

$$mPA = \frac{1}{K+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{j=0}^k P_{ij}} \quad (4)$$

$$mIoU = \frac{1}{K+1} \frac{\sum_{i=0}^k P_{ii}}{\sum_{j=0}^k P_{ij} + \sum_{j=0}^k P_{ji} - P_{ii}} \quad (5)$$

3.2 实验环境与参数设置

实验环境基于 linux 操作系统 Ubuntu20.04.2 LST, 使用 GPU 版 Pytorch1.11 深度学习框架 Python3.7 编程语言实现。本文提出的算法基于原始 DeepLabV3+模型, 使用 SGD 网络模型优化器对算法进行 120 次训练, 达到拟合效果。训练分为两个阶段: 冻结阶段和解冻阶段。在冻结阶段使用 0.005 的学习率, 批量大小设置为 8。解冻阶段的学习率为 0.0005, 批量大小设置为 4。为了防止过拟合, 权重衰

减率设置为 0.005。Epoch 是指所有进入网络的数据完成一次正向计算和反向传播的过程, Epoch 数设置为 120, 其中冻结阶段 50 轮, 解冻阶段 70 轮。本文采用 mIoU、mPA 评价指标体系, 在自建数据集 PASCAL VOC2012 上进行注意力机制添加和消融实验, 验证模型的性能。

3.3 模型分割结果

3.3.1 不同模型分割性能对比结果 为了筛选出最优网络, 本实验在相同实验条件下, 用囊型肝包虫病超声图像分割数据集进行当前主流图像分割网络对比实验, 网络包括 DeepLabV3+、U-Net^[23]、PSPNet^[24]、HRNet^[25]等。结果显示 DeepLabV3+ 的 mIoU、mPA 等分割精度指标均比其他网络高, 但模型规模指标 Params 和 FLOPs 比其他网络大。模型规模较大, 导致运行速度 FPS 也低, 因此 DeepLabV3+ 需要进行继续轻量化, 见表 1 和图 7。

表 1 不同检测模型性能对比

Table 1 Performance comparison among different detection models

模型	mIoU/%	mPA/%	Params/M	FLOPs/G	FPS/Frame·s ⁻¹
DeepLabV3+	71.6	80.7	57.7	166	19
U-Net	67.7	77.7	24.9	451	20
PSPNet	67.6	77.0	2.4	6	55
HRNet	53.7	66.6	29.5	79	13

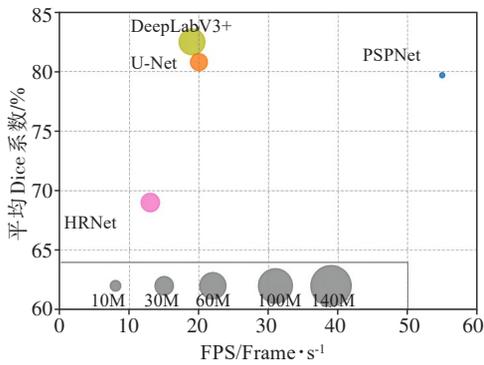


图 7 主流分割网络对比

Figure 7 Comparison with mainstream image segmentation networks

3.3.2 消融实验结果 设计与 DeepLabV3+ 原模型的对比消融实验来验证改进的有效性。模型训练和测试均使用同一数据集和验证集。为确保实验的可靠性, 分别对每个网络进行 2 次训练, 取其结果的平均值进行比较。实验结果如表 2 所示。

由表 2 可得, 改进后的 DeepLabV3+ 在性能方面

有了较大提升, 提出的各模块不仅提升了模型推理速度, 而且有效改善了分割精度。使用轻量化 MobileNetV2 作为主干网络后, 由于缩减了模型深度, 保留了更多的低级特征, 使模型在提升分割精度的同时, 模型占用内存缩小为原来的 1/3; 在模型中增加了 ECA 后, 由于模型更能注意到细节特征, mIoU 和 mPA 分别提升 1.6% 和 0.2%, 运算速度上升 25 Frame/s。将损失函数 Dice Loss 引入模型后, 模型的整体性能得到有效提升, mIoU 和 mPA 分别提升 2.2% 和 2.8%, 同时随着模型占用内存的降低, 大幅提升了模型处理速度。改进后的模型对囊型肝包虫病病灶有效特征提取能力更强, 同时在实时性上表现效果更好, 能更好地完成囊型肝包虫病病灶检测任务。

以上 5 种模型在验证集上的实际预测结果如图 8 所示。由图 8 可知, 相比改进后的模型而言, DeepLabV3+ 原模型的分割结果存在漏识、误识的情况, 对细节的处理不够好; U-Net 可以实现对细小特征的提取, 但分割边缘不准确; PSPNet 存在分割结果

表2 不同方法对模型的影响

Table 2 Effects of different methods on the model

模型	mIoU/%	mPA/%	Params/M	FLOPs/G	FPS/Frame·s ⁻¹
DeepLabV3++Xception	71.6	80.7	57.7	166	19
DeepLabV3++MobileNetV2	72.4	80.3	5.8	52	46
DeepLabV3++MobileNetV2+ECA	73.2	80.9	5.8	52	44
DeepLabV3++MobileNetV2+ECA+Dice Loss	73.8	83.5	5.8	52	73

不连续、误识的问题;HRNet对于边缘细节特征的处理不足,同时存在误识、漏识的现象。改进后的模型在整体和局部分割精度均优于其他模型,误识率低,

能够实现对囊型肝包虫病灶细小特征的提取,同时分割边缘光滑、清晰。

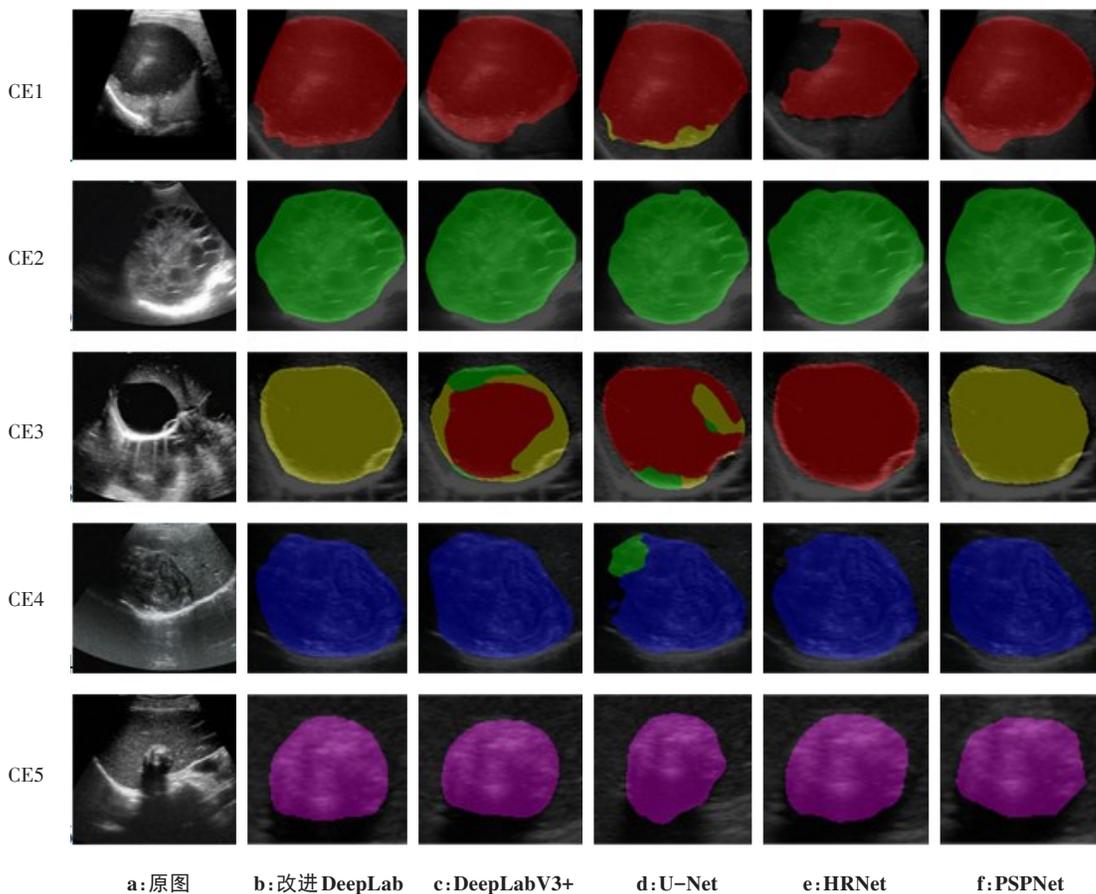


图8 不同分割模型在囊型包虫肝病病灶上的分割效果

Figure 8 Segmentation results of different segmentation models for hepatic cystic echinococcosis lesions

4 结论

本文提出一种基于注意力机制的DeepLabV3+网络。通过在MobileNetV2的底层特征之后加入ECA机制,提高浅层特征的获取,并将损失函数Dice Loss引入模型中,解决正负样本不平衡问题。实验结果表明,将注意力模块作为网络嵌入DeepLabV3+中,可以提高关键类别的准确性,有效提高网络对图

像中物体的分割精度。客观指标mIoU比原模型提升2.2%,mPA在原模型的基础上提升2.8%。笔者工作提高了图像语义分割的性能,为囊型肝包虫病灶的自动分割与检测提供了新的思路,为计算机视觉领域提供了方向。改进后的算法虽然有了很好的性能提升,但仍然存在不足。由于注意力机制的引入在一定程度上增加了模型的复杂性,因此在模型

复杂性和参数数量方面还需要进一步的研究。在未来,笔者将考虑使用模型压缩方法来优化网络,使模型能够平衡高精度和轻量级。

【参考文献】

- [1] 唐普霞, 石丽怡. 基于数据挖掘的图像分类算法[J]. 现代电子技术, 2017, 40(3): 54-57.
Tang PX, Shi LY. Image classification algorithm based on data mining [J]. Modern Electronics Technique, 2017, 40(3): 54-57.
- [2] 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.
Radiology of Infection Sub-branch, Radiology Branch, Chinese Medical Association, Committee on Radiology of Infectious, Radiology Branch, Chinese Medical Doctor Association. Expert consensus on the imaging diagnosis of hepatic echinococcosis[J]. Journal of Clinical Hepatology, 2021, 37(4): 792-797.
- [3] Deplazes P, Rinaldi L, Alvarez Rojas CA, et al. Global distribution of alveolar and cystic echinococcosis [J]. Adv Parasitol, 2017, 95: 315-493.
- [4] 毕建斌, 鹿青, 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.
Bi JB, Pang Q, Wang ZX, et al. Clinical characteristics and surgical efficacy of 138 cases of hepatic alveolar echinococcosis [J]. Chinese Journal of Digestion, 2016, 36(9): 629-632.
- [5] 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.
- [6] Rawla P, Sunkara T, Muralidharan P, et al. An updated review of cystic hepatic lesions [J]. Clin Exp Hepatol, 2019, 5(1): 22-29.
- [7] 吐尔洪江·吐逊, 邵英梅, 吐尔干艾力·阿吉, 等. 棘球蚴病临床领域相关中文专业术语专家共识[J]. 中国寄生虫学与寄生虫病杂志, 2021, 39(1): 76-84.
Tuerhongjiang TX, Shao YM, Tuerganaili AJ, et al. Consensus on Chinese terminology in the clinical field of echinococcosis [J]. Chinese Journal of Parasitology and Parasitic Diseases, 2021, 39(1): 76-84.
- [8] 侯娇, 温浩, 王明坤, 等. 肝细粒棘球蚴病手术患者病灶活性状态的影响因素分析[J]. 中国寄生虫学与寄生虫病杂志, 2022, 40(3): 309-315.
Hou J, Wen H, Wang MK, et al. Analysis of the influencing factors of lesion activity in hepatic cystic echinococcosis patients [J]. Chinese Journal of Parasitology and Parasitic Diseases, 2022, 40(3): 309-315.
- [9] 汤庆, 胡志文, 阮镜良, 等. 肝包虫病超声特征性表现在早期诊断中的应用[J]. 广东医学, 2017, 38(18): 2819-2822.
Tang Q, Hu ZW, Ruan JL, et al. The application of ultrasound characteristic features in early diagnosis of liver hydatid disease [J]. Guangdong Medical Journal, 2017, 38(18): 2819-2822.
- [10] Bankman IN, Morcovescu S. Handbook of medical imaging. processing and analysis [J]. Med Phys, 2002, 29(1): 107.
- [11] Toennies KD. Guide to medical image analysis: methods and algorithms [M]. 2nd ed. Springer, London, 2017: 153-173.
- [12] 左振宇. 基于机器学习的医学图像分割、配准、融合及去噪[J]. 电子设计工程, 2019, 27(17): 135-139.
Zuo ZY. Medical image segmentation, registration, fusion, and denoising based on machine learning [J]. Electronic Design Engineering, 2019, 27(17): 135-139.
- [13] Xin Y, Song G, Cereda M, et al. Semiautomatic segmentation of longitudinal computed tomography images in a rat model of lung injury by surfactant depletion [J]. J Appl Physiol, 2015, 118(3): 377-385.
- [14] Cheng J, Wang HX, Li R, et al. A two-stage multiresolution neural network for automatic diagnosis of hepatic echinococcosis from ultrasound images: a multicenter study [J]. Med Phys, 2022, 49(5): 3199-3212.
- [15] 黄雯珂, 滕飞, 王子丹, 等. 基于深度学习的图像分割综述[J]. 计算机学报, 2024, 51(2): 107-116.
Huang WK, Teng F, Wang ZD, et al. Image segmentation based on deep learning: a survey [J]. Computer Science, 2024, 51(2): 107-116.
- [16] Chen LC, Zhu YK, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]//Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 833-851.
- [17] Sandler M, Howard A, Zhu ML, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 4510-4520.
- [18] Wang QL, Wu BG, Zhu PF, et al. ECA-net: efficient channel attention for deep convolutional neural networks [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2020: 11531-11539.
- [19] Milletari F, Navab N, Ahmadi SA. V-net: fully convolutional neural networks for volumetric medical image segmentation [C]//2016 Fourth International Conference on 3D Vision (3DV). Piscataway, NJ, USA: IEEE, 2016: 565-571.
- [20] 戴婷, 王辉. 超声诊断肝包虫病 1 例及误诊原因分析[J]. 中国实验诊断学, 2021, 25(10): 1551-1552.
Dai T, Wang H. Ultrasound diagnosis of liver hydatid disease: one case and analysis of misdiagnosis reasons [J]. Chinese Journal of Laboratory Diagnosis, 2021, 25(10): 1551-1552.
- [21] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 2818-2826.
- [22] 杨莲, 石宝峰. 基于 Focal Loss 修正交叉熵损失函数的信用风险评估模型及实证[J]. 中国管理科学, 2022, 30(5): 65-75.
Yang L, Shi BF. Credit risk evaluation model and empirical research based on Focal Loss modified cross-entropy loss function [J]. Chinese Journal of Management Science, 2022, 30(5): 65-75.
- [23] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [C]//Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015. Cham: Springer International Publishing, 2015: 234-241.
- [24] Zhao HS, Shi JP, Qi XJ, et al. Pyramid scene parsing network [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 6230-6239.
- [25] Wang JD, Sun K, Cheng TH, et al. Deep high-resolution representation learning for visual recognition [J]. IEEE Trans Pattern Anal Mach Intell, 2021, 43(10): 3349-3364.

(编辑:薛泽玲)