

深度学习在肝脏及肝脏肿瘤分割中的应用进展

崔慧¹, 郭英慧², 蔡肖红¹, 王晓燕¹⁺

1. 山东中医药大学 医学信息工程学院, 济南 250355

2. 山东中医药大学 中医学院, 济南 250355

+ 通信作者 E-mail:sdnuwxy@126.com

摘要:肝癌作为一种恶性肿瘤,其发病率和死亡率正呈逐年上升趋势,临床中精准分割肝脏与肿瘤对肝癌的诊断与治疗至关重要。传统的肝脏及肿瘤分割依赖医生手工操作,过程耗时且高度依赖医生经验,在大规模数据处理中难以确保效率和精度,且易因主观判断差异导致误差。近年来,深度学习因能自动提取图像特征被广泛应用于医学图像处理,在肝脏及肝脏肿瘤分割任务中也取得了显著进展。为更深入开展深度学习在肝脏及肝脏肿瘤分割的应用研究,从常用公开数据集及评价指标入手,分别从有监督与无监督学习的角度,梳理近年来深度学习在肝脏及其肿瘤分割领域的应用进展,总结各模型的优缺点,对比各类方法的性能差异,并以此为基础讨论现有研究尚存的不足及挑战,展望其未来发展方向,以期为进一步研究提供参考。

关键词:肝脏及肝脏肿瘤;图像分割;深度学习;有监督学习;无监督学习

文献标志码:A **中图分类号:**TP391 **doi:**10.3778/j.issn.1002-8331.2411-0100

Progress in Application of Deep Learning in Liver and Liver Tumor Segmentation

CUI Hui¹, GUO Yinghui², CAI Xiaohong¹, WANG Xiaoyan¹⁺

1. School of Medical Information Engineering, Shandong University of Traditional Chinese Medicine, Jinan 250355, China

2. College of Traditional Chinese Medicine, Shandong University of Traditional Chinese Medicine, Jinan 250355, China

Abstract: Liver cancer is a malignant tumor with increasing morbidity and mortality. Precise segmentation of the liver and tumor is crucial for diagnosing and treating this disease. Traditional liver and tumor segmentation relies on manual work by doctors, which is time-consuming, experience-dependent, and challenging to ensure accuracy and efficiency in large-scale data processing. Recent advances in deep learning, particularly with its automatic feature extraction capabilities, have significantly improved liver and tumor segmentation. This review introduces widely-used public datasets and evaluation metrics, and summarizes progress in liver and tumor segmentation from supervised and unsupervised learning perspectives. Advantages and limitations of various models are discussed, and performance comparisons across methods are presented. Finally, limitations and challenges in current research are highlighted, along with future research directions, providing a reference for further studies.

Key words: liver and liver tumors; image segmentation; deep learning; supervised learning; unsupervised learning

肝脏作为人体主要解毒器官,其健康状况直接影响个体生命质量与生存率。据国际癌症研究机构(IARC)发布的最新全球癌症统计数据^[1-2]显示,2022年全球新发肝癌约87万例,排名第6,年致死数76万例,居癌症致死量第3位。临床医生通常借助计算机断层扫描(CT)、磁共振成像(MRI)等提供的高质量图像,观察肝脏及肿瘤形状、大小、位置等信息进行肝脏肿瘤诊断^[3-5],因此,如

何高效精准完成肝脏与肿瘤分割,对诊断与制订治疗计划都至关重要。但肝脏周围还存在胰腺、肾脏与胆囊等其他器官,影像灰度值与肝脏相近,对比度较低,且影像信息本身的多样性与不一致性,也进一步增加了肝脏与肿瘤分割的挑战难度^[6]。传统手动分割耗时费力,且高度依赖于操作人员的能力与经验,阅片疲劳或能力与经验不足均易导致误诊。

基金项目:国家自然科学基金(82074293);山东省中医药科技项目(2021M146);山东中医药大学科学研究基金(KYZK2024M13)。

作者简介:崔慧(2001—),女,硕士研究生,研究方向为健康医疗大数据研究;郭英慧(1976—),女,博士后,教授,研究方向为中医肝藏象及情志病证生理病理、发病及药物干预机制研究;蔡肖红(1989—),女,硕士,讲师,研究方向为健康医疗大数据研究;王晓燕(1979—),女,博士,副教授,研究方向为健康医疗大数据研究、中医药智能化研究。

收稿日期:2024-11-07 **修回日期:**2025-03-24 **文章编号:**1002-8331(2025)17-0047-15

近年来,深度学习技术的兴起为医学影像的自动分析带来了深刻变革^[7-9],陆续涌现出很多优秀的研究。张欢等^[10]深入研究U-Net网络及其改进模型在肝脏及肝脏肿瘤分割中的应用,全面总结U-Net及其改进方法的研究进展,从U-Net模型的编码器、解码器及跳跃连接等结构出发,分析各类改进技术及其具体应用效果。Gul等^[11]从理论与实践角度对U-Net、U-Net++、全卷积网络(fully convolutional network, FCN)、特征金字塔网络及生成对抗网络在肝脏及肝脏肿瘤分割中的应用进行系统性综述,同时提及3D深度监督网络、SAR-UNet及H-DenseUNet等新型架构在提升分割精度方面的贡献。陈英等^[12]系统性综述了肝脏肿瘤分割方法,涵盖传统方法(如区域增长法、阈值法等)与深度学习技术相关研究,基于分割网络维度,深度学习方法被划分为2D、2.5D和3D模型,并探讨传统方法与深度学习方法结合的潜在可行性。夏栋等^[13]针对深度学习方法在肝脏肿瘤CT图像分割中的应用现状开展系统性综述,基于输入数据维度,卷积神经网络(convolutional neural network, CNN)方法被划分为2D、3D和2.5D网络,并对各类网络的特点、优缺点及改进方向进行深入分析。Egala等^[14]综述了深度学习在医学图像上的应用,特别是CNN在医疗图像分析中的应用现状与发展,阐述深度学习的基本架构及其在医学图像处理中的关键作用,包括图像增强、分割、特征提取和分类等领域,详细分析DL-CNN在肝癌等重大疾病中的具体应用及性能表现。目前,大多数综述主要关注有监督学习方法,探讨在标注数据充分的条件下,如何实现高效分割。然而标注数据较少,且获取的经济和时间成本高昂,如何在无标注数据上进行有效学习,已成为当前研究中的挑战之一。近年来,无监督学习(包括生成对抗网络、聚类等)在肝脏及肝脏肿瘤图像分割方面取得了一定的进展,但公开发表的相关研究系统性综述较少。正因如此,本文不仅系统回顾了有监督学习方法的研究进展,更重点综述了无监督学习在该领域的最新进展。此外,本文综述的文献多为近年的新研究,以期全面反映该领域的技术前沿。

为便于后续研究,本文将系统总结常用的公开数据集和评价指标,并从有监督和无监督学习两个角度进行归纳,前者按照CNN、FCN、U-Net、融合模型及各模型的改进进行,后者按照生成对抗网络的应用、基于聚类的分割方法及跨模态域适应方法进行。有监督学习作为当前主流技术,对相关优秀论文进行总结将有助于深入了解如何解决精度较低和计算成本较高等挑战;而无监督学习则有助于解决数据集丰富度不足的问题。本文还将进一步对各类算法的性能进行综合讨论,深入分析并总结其优缺点,归纳现有研究的不足与挑战,并探

索其未来发展方向,以期提供一个更全面、更新颖的视角,为后续研究提供参考。

1 公开数据集

图像分割研究中数据集不仅可以决定算法的开发方向与评估标准,也会直接影响研究结果的可比性与通用性。目前,肝脏及肝脏肿瘤分割研究中常用公开数据集详情如表1所示。

表1 常用肝脏肿瘤图像分割公开3D数据集

Table 1 Common liver tumor image segmentation open 3D data sets

数据集	模态	数据量(例)	文件格式	备注
CHAOS ^[15]	CT+	训练集 20	Dicom	
	MRI	测试集 20		
LiTS ^[16]	CT	训练集 131	.nii	
		测试集 70		
3D-IRCADb ^[17]	CT	男性 10	Dicom	3D-IRCADb-01
		女性 10		
		匿名患者 2	vtk	3D-IRCADb-02
SLIVER07 ^[18]	CT	训练集 20	Mhd	
		测试集 10		

1.1 CHAOS

CHAOS(combined (CT-MR) healthy abdominal organ segmentation)数据集是腹部医学影像分割的经典数据集之一^[15],最大的特色在于提供了成对的多模态CT和MRI数据,并提供了对应的标注。CHAOS数据集是在ISBI2019竞赛中向外放出的,总共有40例成对的CT和MRI数据,其中只有20例作为训练集提供了标注,剩下20例官方宣布将不会放出有标注的版本。尽管数据是成对的,但在CT和MRI上的标注内容不尽相同,CT只提供了肝脏的标注,而MRI则提供了4种器官的标注。

1.2 LiTS 2017

LiTS 2017数据集(liver tumor segmentation 2017 dataset)^[16]是专为肝脏肿瘤分割任务设计的医学图像数据集,广泛应用于医学影像分析、计算机视觉及深度学习领域,尤其在肝脏及肝脏肿瘤分割算法的开发与评估中具有重要价值。该数据集汇集了来自7个不同医学中心的CT扫描图像数据,包括131例训练集病例和70例测试集病例,每个病例包含多个CT切片,训练集总切片数为58 638张。因其数据量较为庞大,该数据集已成为该领域中最常用的数据集之一。每张图像均配有肝脏区域和肝脏肿瘤的高质量分割标签,这些标签由多位经验丰富的放射科医生提供,确保数据标注的准确性与可靠性,但不足之处是其测试集的标注并未公开。

1.3 3D-IRCADb

3D-IRCADb数据集提供了肝脏大小、肿瘤位置等信息^[17],并包含有挑战性的分割案例。其中,3D-IRCADb-01

是一个包含 10 名女性和 10 名男性的 3D CT 扫描数据库,其中 75% 的病例有肝肿瘤;3D-IRCADb-02 则包括 2 个匿名患者的 3D CT 扫描图像。1 个文件夹对应 1 位患者,其中提供了有关图像的信息,如肝脏大小(宽度、深度、高度)等。由于与邻近器官的接触、肝脏的非典型形状或密度,甚至图像中的伪影,增加了分割难度。

1.4 SLIVER07

SLIVER07(segmentation of the liver competition 2007)^[18],是一个非常经典的用于对比增强 CT 中对肝脏进行分割的数据集,提供 20 例 CT 图像和肝脏标注用于训练,以及 10 例不公开标注的数据用于测试,最早用于 MICCAI 2007 的竞赛中。

2 常用评价指标

评价指标是衡量图像分割模型效果的定量方法,不同指标可从不同角度反映模型图像处理的准确度及精度,帮助研究者客观比较各算法及改进方法的优劣^[19]。常用评价指标如表 2 所示,其中, A、B 分别为预测与真实的分割结果,TP、FN 分别为真阳性、假阴性数量,TPR 为真阳率,FPR 为假阳率;∂A 与 ∂B 分别为预测与

真实分割结果的边界, $d(a,b)$ 为点 b 与 a 之间的欧几里得距离; μ_r 和 μ_g 是真实图像和生成图像的特征均值, Σ_r 和 Σ_g 是它们的协方差矩阵。

3 深度学习在肝脏及肝脏肿瘤分割上的应用

深度学习通过模拟人类大脑的思维过程,自动从海量图像数据中提取关键特征,在医学图像研究中应用极为广泛且效果显著^[20-21],可辅助医生进行更精确的疾病诊断、病灶分割、个性化治疗方案制定及治疗效果评估,在肝脏及肝脏肿瘤图像分割领域中的应用也非常广泛。本章将从有监督学习与无监督学习两个角度进行梳理。

3.1 有监督学习

有监督学习是肝脏及肝脏肿瘤图像分割领域的主流方法,高度依赖于数据标注,通过训练深度神经网络自动提取与学习特征,实现高精度的图像分割。1998 年,Lecun 等^[22]提出了 CNN,最初用于手写数字识别,主要通过卷积层、池化层与全连接层进行特征提取与分类。2015 年,Long 等^[23]提出用于图像分割的全卷积神经网络 FCN,创新地消除了全连接层,采用全卷积层与上采样(反卷积)层实现端到端像素级分类,并通过跳跃连接结合浅层与深层特征,极大提升了分割精度。随后,Ronneberger 等^[24]提出了专注于生物医学图像分割的 U-Net,通过对称编码器-解码器结构结合跳跃连接与多尺度特征融合,在分割细节保留与精度提高方面表现优越。随着对分割精度与细节要求的不断提高,基于以上三种基础模型的众多改进模型相继涌现,进一步提高了深度学习在复杂医学图像分割中的表现。

3.1.1 CNN 及其改进模型

(1)CNN 模型简介

CNN 是一种深度学习模型^[25],专门用于处理二维网格数据(如图像),在图像分类、目标检测和图像分割等任务中表现优异。CNN 通过卷积层提取特征,利用池化层降低特征图尺寸,从而减少计算复杂度和过拟合。其主要组成部分包括输入层、卷积层、池化层、全连接层和输出层。输入层接收图像,卷积层提取层次特征,池化层进行降维,全连接层汇总信息,输出层进行分类或回归。这一架构设计使 CNN 在图像数据处理上具备强大的特征提取能力和高效学习性能。其模型架构如图 1 所示。

表 2 常用评价指标

Table 2 Common evaluation indicators

评价指标及其涵义	公式
相似系数:描述预测与真实结果重叠程度	$Dice = \frac{2 \times A \cap B }{ A + B }$
体积重叠误差:反映预测与真实结果间体积重叠误差	$VOE = 1 - \frac{ A \cap B }{ A \cup B }$
相对体积误差:测量预测与真实结果间相对体积差异	$RVD = \frac{ A - B }{ B }$
平均对称表面距离:测量预测与真实结果间平均表面距离	$ASD(A,B) = \frac{\sum_{a \in \partial A} \min_{b \in \partial B} d(a,b) + \sum_{b \in \partial B} \min_{a \in \partial A} d(b,a)}{ \partial A + \partial B }$
召回率:衡量正类体素被预测为正类的比例	$Recall = \frac{TP}{TP + FN}$
曲线下面积:描述预测结果判别能力	$AUC = \int_0^1 TPR(FPR) dFPR$
弗雷歇特进程距离:衡量生成图像与真实图像之间的距离	$FID = \left\ \mu_r - \mu_g \right\ ^2 + \text{Tr} \left(\Sigma_r + \Sigma_g - 2 \sqrt{\Sigma_r \Sigma_g} \right)$




图1 CNN模型架构图
Fig.1 CNN model architecture diagram

(2) 卷积网络及改进模型的应用

因肝脏形状不规则、边界模糊,且周围组织复杂,导致肝脏及肝脏肿瘤分割任务面临诸多挑战。为此,研究者们提出了基于CNN的多种改进方法。Aghamohammadi等^[26]提出了一种新型的双路径CNN(TPCNN),其一路径用于提取局部特征,其二路径用于提取半全局特征,以提高对复杂纹理和形状变化的检测能力。提出一种新编码方法LDOG,该方法通过基于梯度和灰度值的编码技术,生成具有光照不变性的纹理表示,增强对边界和细节特征的检测能力。Khan等^[27]提出改进的Mask-Region卷积神经网络(cm-RCNN),该网络在传统的Mask-RCNN基础上加入四个最大池化层和八个反卷积层,并引入Dropout层进行正则化,采用改进的Sigmoid激活函数(m-Sig),同时结合ResNet特征、形状特征(如面积、周长)和增强的中值二值模式(e-MBP)提取纹理特征,提高分割精度。Selvaraj等^[28]提出卷积编码-解码残差神经网络(CEDRNN),使用残差连接以更好地捕获特征,在编码器和解码器中采用CBR块(卷积+批归一化+ReLU激活)组合以优化特征提取,在卷积层中尝试不同的滤波器配置,最终选择了最佳配置,以减少训练参数数量并提高分割性能,CEDRNN模型能够直接从CT图像中分割肝肿瘤,而不需要进行事先的肝脏分割。尽管TPCNN、cm-RCNN和CEDRNN模型在整体性能上有明显提高,但在处理复杂边界模式和低强度对比区域时仍存在一定的挑战,这也是在分割肝脏及其肿瘤任务中的难点之一。

Meng等^[29]提出一种三维双路径多尺度卷积神经网络(TDP-CNN),并结合条件随机场(CRF)技术用于提高分割结果的精度,设计双路径结构,包括局部路径和全局路径,以捕获图像的局部细节和全局上下文信息,通过多尺度处理,在不同分辨率下处理图像块以平衡计算资源和分割性能,采用CRF后处理来消除假分割点,TDP-CNN能够有效分割肝脏和较大肝肿瘤,直接使用3D数据进行分割。Budak等^[30]提出深度卷积编码-解码神经网络(CEDCNN)模型,使用两个级联的编码-解码网络,第一个网络用于肝脏分割,第二个网络在第一个网络分割出的肝脏区域基础上进行肿瘤分割,显著减少了假阳性率。TDP-CNN和CEDCNN在肝脏分割方面表现出色,尤其在处理形态复杂的肿瘤时具有较高的Dice系数和较低的误差值,但对于小肿瘤和多发性肿瘤结果仍存在不足,但双路径和级联结构的引入为进一步改进提供了良好的基础。Anil等^[31]提出了一种结合多层深度卷积网络(MDCN)和分形残差网络(FRN)的混合方法(MDCN+FRN),以提高不同部位图像的像素分类精度和对肿瘤区域的识别精度,并使用主动轮廓模型来进一步优化肿瘤边界,减少分割误差。MDCN+FRN在识别小肿瘤和不规则形状的肿瘤时效果显著,引入

FRN使模型在特征提取上更加灵活和高效,但在处理形态复杂的肿瘤时,仍存在一定的假阳性和假阴性,且FRN虽然提高了识别能力,但也增加了模型的计算复杂度。Ahmad等^[32]提出一种轻量级卷积神经网络模型(Ga-CNN),使用高斯分布初始化权重,并通过局部响应归一化提高数据的自适应能力,在有效降低计算复杂度的同时可以保持较高的分割精度,轻量化的设计使其更适用于硬件资源有限的医疗场景。

尽管各模型在处理肝脏及其肿瘤分割任务中取得了显著进展,但在复杂形态、边界模糊和小肿瘤分割方面仍面临一定的挑战,这些问题仍有待在未来的研究中进一步优化解决。

3.1.2 FCN 及其改进模型

基础CNN虽在医学图像分割领域取得了一定进展,但其固有的特征图尺寸限制于分类属性,无法避免精细分割任务中的不足,为此,FCN及其改进模型应运而生。FCN在CNN基础上去除全连接层,改用卷积层保留输入图像的空间信息,并通过上采样低分辨率特征图恢复到与输入时分辨率相同,实现了像素级的图像分割^[33-34],促使FCN及其改进模型被迅速应用于肝脏及肝脏肿瘤分割研究。其模型架构如图2所示。




图2 FCN模型架构图

Fig.2 FCN model architecture diagram

Alim^[35]将基础FCN与基于区域的水平集函数结合,用于肝脏与肿瘤分割,该方法首先使用基础FCN进行粗略分割预测,随后利用水平集函数进一步精细化分割结果。在多个公开数据集上的实验结果表明,该方法具有良好的分割性能与较强的泛化能力,尤善处理结构复杂及强度均匀性不同的CT图像,但基础FCN方法处理对比度低、病变类型不同及扫描协议与分辨率不同的异质数据时存在挑战。为此,Christ等^[36]提出一种基于级联全卷积神经网络(CFCN),结合3D CRF进行后处理,CT图像进行HU窗口化与直方图均衡化,MRI数据进行N4偏差校正,应用镜像、裁剪、噪声添加与弹性变形等数据增强技术,在不同的数据集和成像模式下表现出良好的鲁棒性和泛化能力,特别是在复杂、低对比度的图像上表现出色。Chlebus等^[37]采用了2D FCN,结合基于对象的后处理步骤,选用对称的编码器-解码器结构,经跳跃连接将编码器中高分辨率特征图传递给解码器,该模型可在四个分辨率级别上工作,学习局部与全局特

征,显著减少假阳性,但对小肿瘤检测存在不足。Rafiei等^[38]使用了3D到2D FCN技术(3D-2D-FCN),在编码和解码阶段分别使用3D和2D卷积核,有效实现特征提取与内存优化,并结合CRF进行后处理增强肝脏边界分割效果,该法改进了小肿瘤检测精度不足问题,同时预处理步骤的减少使得分割过程加快,更加适用于紧急医疗中心。Jiang等^[39]提出3D FCN模型AHCNet,使用多个注意力混合连接块,通过长短跳跃连接与自注意力模块实现快速准确语义分割。3D医学图像分割中,空间信息难以有效利用与形状边界信息忽视是共性问题,为此,Han等^[40]结合2D与3D卷积技术,提出一种级联2.5D FCN模型(2.5D FCNs),输入五个相邻切片改进3D数据空间信息利用,并使用全连接CRF对肝脏与肿瘤的概率图进行后处理,提高分割精度。Dong等^[41]运用混合全卷积神经网络(HFCNN)技术,结合多尺度特征融合与注意力机制,将不同层次的特征进行融合,减少背景噪声的影响。Haripriya等^[42]同样使用混合模型HFCNN,结合CNN的特征提取能力与FCN的图像分割优势,在较少的计算资源下实现高精度的肝脏肿瘤检测与分割,克服传统方法在处理复杂肿瘤形态与变化时的局限性。Dong等^[41]提出的HFCNN更侧重于多层次特征融合和边界处理,以提高复杂肝脏恶性肿瘤的检测和分割精度,Haripriya等^[42]提出的HFCNN则更注重多尺度特征提取,优化肝脏及肿瘤分割的效果,尤其在小目标检测方面有较强表现。

3.1.3 U-Net 及其改进模型

尽管FCN在保持图像空间信息与精确定位方面取得了进展,但对图像细节信息的捕捉仍然不够理想。为此,Ronneberger等^[24]提出U-Net模型,其模型架构如图3所示,在FCN的基础上引入跳跃连接^[24,43],通过将编码器与解码器对应层的特征图拼接在一起,保留编码过程中丢失的细节信息,有效提高了分割精度,同时,通过维持全卷积结构可以支持任意大小的输入图像。下面将深入探讨U-Net及其改进模型在肝脏及肝脏肿瘤分割中的应用与改进。

肝脏形状复杂且边界模糊,特别是在动态对比增强MRI图像中,传统方法难以准确分割肝脏及小肿瘤区域,常导致形状失真和较高的假阳性或假阴性。为此,Czipczer等^[44]提出的3D RP-UNet模型通过引入ResPath机制,减小编码器与解码器间的语义差距,保留更多空间信息,上采样替代反卷积,减少参数量并加快收敛。预处理采用supervoxel分割,精准定位肝脏区域,去除多余组织,最终通过形态学处理优化分割结果,提升整体性能。Li等^[45]提出一种结合密集模块、Inception模块与膨胀卷积的U-Net变体BS U-Net,在LITS数据集上进行模型训练与测试,结果显示该模型控制形变能力增强、假阳性与假阴性率显著降低、收敛速度快,整体分割性能上表现优异,但计算开销大、复杂性高,对自然图像的适应性有限。

Deng等^[46]提出一种高效轻量级模型ELU-Net,通过




图3 U-Net模型架构图

Fig.3 U-Net model architecture diagram

引入深度跳跃连接与轻量级设计, ELU-Net在保持高分割精度的同时, 显著减少模型参数量与计算成本, 引入深度跳跃连接, 结合相同尺度与更大尺度的编码器特征, 提升特征提取效果, 同时通过减少第一层编码器通道数, 使用较小卷积核, 显著减少模型参数量, 但ELU-Net对数据质量敏感。Alafer等^[47]提出的L-UNet方法通过引入CLAHE预处理技术和反卷积层, 增强图像对比度和分辨率, 优化局部特征的提取, 同样采用轻量化网络架构, 减少参数数量, 提升计算效率, 同时保持与传统U-Net和Link-Net模型相当的分割精度, 尤其在肝脏区域的准确性和边界识别方面表现优异。Lee等^[48]提出RA V-Net, 在编码部分引入复合原始特征残差模块, 通过更复杂的卷积层与跳跃连接, 增强图像特征提取能力, 防止梯度消失或爆炸, 同时改进ELU-Net和L-UNet对不同类型数据适应性, 进一步提高分割精度。Naaqvi等^[49]提出AU-Net, 引入并行空洞卷积模块, 通过不同尺寸的卷积层进行特征提取, 增强高分辨率特征的学习能力, 同时减少了参数量和计算复杂度, 但小肿瘤分割能力有限。

杨振等^[50]提出一种结合级联Dense-UNet和图割算法的肝脏肿瘤分割方法, 通过级联Dense-UNet模型依次分割肝脏和肿瘤区域, 有效减少其他组织干扰, 提升肿瘤分割精度, 通过图割算法结合像素级灰度特征和区域级概率模型, 在肿瘤感兴趣区域内精细分割, 显著提高低对比度和边界模糊肿瘤的分割精度。Sabir等^[51]结合残差块与U-Net架构的ResU-Net, 引入残差块, 增加短路连接, 使网络训练更容易, 提取特征更有效, 解决深层网络中梯度消失问题。ResU-Net继承U-Net的编码器-解码器结构, 并在编码器与解码器之间加入了桥接层, 使网络不仅能捕捉到图像局部特征, 还能保持全局特征。Li等^[52]提出基于高效通道注意力与Res-UNet++相结合的Eres-UNet++网络, 用于肝脏CT图像分割, 结合高效通道注意力机制与残差模块, 提升网络特征提取能力优化网络性能, 且引入DiceLoss损失函数替代交叉熵损失函数, 可提高分割精度, 改进ResU-Net数据质量敏感问题, 加强边界模糊问题处理效果。Ding等^[53]提出的MulA-nnUNet框架针对3D腹部多器官图像分割任务, 引入大核卷积注意力(LKA)和像素注意力(PA)模块, 解决长距离空间依赖建模和特征融合问题, LKA模块提升深层特征的长程依赖建模能力, PA模块减小编码器与解码器之间的语义差异, 优化跳跃连接特征融合, 通过深度可分离卷积优化计算效率, 提高肝脏分割精度。

3.1.4 融合模型

尽管U-Net及其改进模型在医学图像分割中表现出色, 但单一模型的性能仍然受限于特定架构与参数设置, 为进一步提升分割效果, 多模型融合技术逐渐成为

研究热点。在图像分割领域, 多模型融合能够通过结合不同模型的优势, 提升分割精度和鲁棒性。不同模型通常在特征提取、边界识别和全局上下文建模等方面具有各自的强项, 融合这些模型可以有效弥补单一模型的不足, 优化细节捕捉和边界判定。此外, 融合方法能够提高模型对噪声、数据不平衡和复杂场景的适应能力, 增强分割结果的稳定性与准确性。

例如, 杨本臣等^[54]提出的KTU-Net在肝脏分割技术方面, 通过融合Kite-Net、U-Net和Transformer三种模型, 结合多分支特征融合策略, 显著提升肝脏肿瘤的分割精度, 其中, Kite-Net负责捕捉细节和边缘信息, U-Net提取高级特征, Transformer有效捕获全局多尺度信息, 通过交叉残差特征块(CRFB)融合不同分支的特征, KTU-Net增强局部边缘细节和全局信息的融合, 优化分割性能。Ou等^[55]提出了ResTransUnet, 引入残差学习结构与SE块以适应特征提取, 引入空洞空间金字塔池化模块来捕捉多尺度特征, 有效改善了KTU-Net存在的计算复杂度与数据依赖性问题, 但模型复杂度依然较高, 且在不同数据集上的泛化能力仍待加强。Li等^[56]提出混合可变结构RDCTrans U-Net, 结合ResNeXt50深度特征提取能力、膨胀卷积的多尺度感受野与Transformer的全局上下文信息, 实现高效的多尺度上下文信息捕捉, 优化计算效率。陈丽芳等^[57]提出的肝脏分割方法融合卷积神经网络和Transformer模型, 结合局部特征提取与全局依赖建模, 提升肝脏分割精度, 卷积网络负责捕捉细粒度的局部特征, Transformer通过自注意力机制建模长距离像素依赖, 优化肝脏边界的精确度, 多级特征融合和可变形多尺度模块增强对肝脏及肝脏肿瘤复杂形态的适应性。

融合模型通过结合多个模型的优势, 能够提高图像分割的精度和鲁棒性, 优化特征提取和边界识别, 但数据资源需求变高、计算复杂度增加、模型结构复杂和调参难度大等是普遍存在的问题。

3.2 无监督学习

在肝脏与肝脏肿瘤图像分割研究中, 标注数据集稀缺是一大问题, 无监督学习通过一些其他方式获取训练信号, 为克服人工标注数据依赖提供了多种解决方案^[58-59], 有效提高模型泛化能力。本节将详细探讨生成对抗网络的应用、基于聚类的分割方法以及跨模态域适应方法的研究进展。

3.2.1 生成对抗网络的应用

在无监督学习的背景下, 生成对抗网络(generative adversarial network, GAN)作为一种有效的生成模型, 已广泛应用于医学图像处理^[60]。在肝脏及肝脏肿瘤分任务中, GAN通过对抗训练学习数据分布, 无须依赖标注数据, 生成与真实样本高度一致的伪图像, 进而实现数据补充与图像增强。

Song 等^[61]使用 CycleGAN 进行数据增强(流程图如图 4 所示),将 CT 数据裁剪到肝脏范围,并线性映射到 0~255 的范围,使用随机选取的对比增强 CT 与非对比增强 CT 切片进行 CycleGAN 训练,将生成的非对比增强 CT 切片堆叠成 3D 体积,作为 3D U-Net 训练样本。又如 Li 等^[62]同样使用 CycleGAN,使用正常数据生成伪病变图像,通过数据增强技术提高训练样本的多样性,框架中的生成器将正常图像转换为伪病变图像,并通过对抗训练使生成的伪病变与正常图像相互转换。Wang 等^[63]使用改进的 CycleGAN 生成伪标签,结合 VAE 判别器和 DGCC 模块来提高伪标签质量,生成器将医学图像转换为伪标签,判别器则通过反馈优化生成过程。与前两者不同, Wang 等^[63]生成的是伪标签而非伪图像。相比于伪图像,伪标签能够直接提供像素级的标注信息,且计算成本更低。Rafiq 等^[64]采用基于 CycleGAN 的 EssNet 框架进行腹部 CT 到 MRI 的跨模态伪图像合成,结合双生成器、双判别器和分割网络解决图像对齐和形变问题,通过对抗损失保持图像真实性,循环一致性损失维持转换关系,分割损失使生成的 MRI 适用于下游分割任务,提升跨模态医学图像合成质量。




图4 CycleGAN 数据增强流程图

Fig.4 CycleGAN data enhancement flowchart

Liu 等^[65]提出一种基于掩膜注意力生成对抗网络(MAGAN)的肝脏肿瘤 CT 图像合成方法,该方法利用掩膜注意力机制,将肝脏肿瘤区域标记为注意力图,将原始图像和注意力图输入到生成器网络,生成合成图像,生成器通过与判别器的对抗训练,逐步生成逼近真实肝脏肿瘤 CT 图像的合成图像。Liu 等^[66]提出部分卷积生成对抗网络(PCGAN),用于肝脏病灶合成和增强肿瘤分割,PCGAN 结合 U-Net 生成器和 Wasserstein GAN,利用部分卷积生成更清晰的病灶边界,并通过 PCA 生成掩码确保病灶形态合理。Zheng 等^[67]提出 LF-GAN 生成高质量肝脏肿瘤 CT 图像,采用 SCSE 模块提升梯度传递和特征采样, AEG 注意力增强判别器对肿瘤细节的识别, GLCM 损失约束图像纹理与形状,使合成图像更接近真实数据,且计算效率高、硬件需求低,有助于缓解数据不平衡并提升诊断模型的性能。

3.2.2 基于聚类的分割方法

相比于有监督学习方法,聚类无须大量标注数据,

能够自主挖掘图像特征,适应数据分布的复杂性,尤其在边界模糊、肿瘤形态多变的情况下鲁棒性表现更好。模糊 C 均值聚类(fuzzy C-means, FCM)是无监督图像分割的重要方法,它通过模糊隶属度处理像素分类问题,有效应对图像中模糊边界与噪声干扰问题。Zhang 等^[68]使用 FCM 对肿瘤进行概率估计,使用 Canny 边缘检测器,进一步改进边缘指示函数,使其处理模糊边界更有效。Al-Saeed 等^[69]基于快速广义模糊 C 均值分割方法,引入局部空间信息增强对复杂纹理与噪声的鲁棒性,使用自适应直方图均衡与自适应中值滤波增强图像对比度、减少 CT 扫描中的脉冲噪声,同时保持边缘与细节信息,解决传统方法在处理噪声与肝脏器官重叠问题上的不足。Ranjbarzadeh 等^[70]利用 FCM 聚类方法进行初步分割,以计算像素或体素的归属概率,并结合均值漂移聚类进一步优化分割结果,FCM 通过迭代更新隶属度矩阵,使像素归属于不同类别,提高分割的柔性,同时减少对边界模糊区域的误分类;该法特别结合凹凸点信息,以更准确地识别肝脏及肿瘤的轮廓,提高整体分割精度。Rela 等^[71]对 FCM 进行了改进,主要通过超像素预分割和多尺度形态梯度重建结合小波变换来增强局部特征,使 FCM 聚类更高效;此外,引入颜色直方图到 FCM 的目标函数中,以加速图像分割过程,改进后的方法计算时间更短,精度更高,且完全自动化。Li 等^[72]采用变分模糊 C 均值(V-FCM)方法结合信息论进行术后肝脏肿瘤诊断的多视角聚类,通过特征重建预测缺失视角信息,并利用模糊聚类学习样本隶属度,结合信息论优化跨视角相似度分布,提高数据一致性和聚类性能。

K-means 聚类因计算效率高、实现简单,被广泛用于肝脏及肝脏肿瘤分割。Krishan 等^[73]提出多核 K-means(MK K-means),结合线性核和二次核提升非线性数据的聚类效果,并优化核矩阵计算以降低复杂度。相比于 K-means,该法更适用于复杂结构,但计算成本较高,核参数选择影响结果。林家兴等^[74]结合 K-means 聚类与区域生长算法进行肝脏肿瘤分割, K-means 预处理均匀化图像灰度,优化区域生长的种子点选取,提高分割精度;改进方法减少了计算时间,但在处理复杂图像时计算成本仍较高。Ananth 等^[75]采用自适应 K-means 聚类,以优化 HMRF-EM 的初始分割结果,相比于 K-means,该法在计算像素距离时考虑了归一化属性,使单个特征不会主导聚类过程,同时允许动态调整聚类中心,以减少对初始值的敏感性。Pattwakkar 等^[76]在 K-means 的基础上引入幂律变换进行图像增强,以提高肿瘤区域与肝脏的对比度,并采用形态学处理去除伪分割区域,增强了肿瘤的可见性,提高了 K-means 在复杂背景下的分割能力。

3.2.3 跨模态域适应方法

跨模态域适应方法在肝脏及肝脏肿瘤分割任务中

具有重要价值,其核心优势在于缓解不同影像模态之间的分布差异,提高模型的泛化能力^[77]。在医学影像分析中,由于数据获取方式的多样性,CT和MRI等不同模态的图像往往在对比度和组织边界表现上存在显著差异,使得单一模态训练的模型难以直接适用于另一模态。跨模态域适应方法利用无监督学习策略,在目标域缺乏标注数据的情况下,借助源域的标注信息提升目标域的分割性能,从而减少人工标注成本,并提高模型的适应性和鲁棒性。近年来,研究者提出了多种方法来提升跨模态域适应的效果,并在肝脏及肝脏肿瘤分割任务中取得了显著进展。

Jiang等^[78]采用解耦表示、跨模态图像翻译与对抗学习技术,将图像潜在空间分解为内容空间与风格空间,通过编码器进行表示解耦,并重新组合生成跨模态图像。Xie等^[79]提出一种新的解耦学习与自训练方法(DLaST),解耦学习将图像分解为域不变的解剖结构与域特定的模态组件,设计形状约束与开发自训练策略,通过伪标签与对抗学习提升适应性能。Hong等^[80]提出一种无源数据的无监督域适应框架,通过特征映射统计指导的模型自适应,使目标模型在无须访问源数据的情

况下学习源域特征分布,完成CT到MRI的肝脏分割域适应;采用风格补偿方法,引导目标MRI图像向CT风格转换,增强分割鲁棒性,同时结合熵最小化约束优化预测稳定性,并利用像素自适应掩码优化提高局部一致性。Ozkan等^[81]结合对抗学习对齐CT-MR特征分布,并通过协变量偏移校正优化归一化层和卷积核,减少模态差异,采用无模态标签学习和硬参数共享架构,提升跨模态特征融合能力,实现稳健的肝脏分割。

4 算法分析与比较

4.1 有监督学习方法的分析比较

为深入了解深度学习各种方法在肝脏及肝脏肿瘤分割上的优缺点,对各类有代表性的有监督分割模型进行梳理分析,如表3所示。

(1)CNN及其改进模型在肝脏及肝脏肿瘤分割中主要通过双路径结构、残差连接、级联网络、CRF后处理和轻量化设计等技术优化特征提取和计算效率。其优势包括提高边界识别能力、降低假阳性率、增强小肿瘤识别和减少计算开销。但仍存在误分割、对小肿瘤识别不足和计算复杂度高等问题。例如,cm-RCNN^[27]优化

表3 有监督学习分割方法总结

Table 3 Summary of segmentation algorithms in supervised learning

方法	文献	改进思路	优点	缺点	数据集	实验结果(最优性能)	
						Dice/%	其他指标
基于CNN	文献[26]	采用双路径CNN结构,结合Z-Score标准化和LDOG编码方法的新型图像预处理技术	在处理复杂形状和模糊边界时效果显著	相邻密度相似器官的边界处理仍存在误差	⑤	92.00A 95.00B	—
	文献[27]	引入自适应直方图均衡化,改进了标准的m-RCNN网络	提高了分割精度	模型对噪声和畸变的敏感性较高	⑤	97.16A	—
	文献[28]	使用残差连接和CBR块,在卷积层中选择最佳滤波器配置	多种形状和大小的肿瘤分割效果较好	—	①②③	95.07A	—
	文献[29]	提出双路径多尺度的3D CNN结构,并结合CRF进行后处理	直接使用3D数据进行分割	存在误分割体素的问题	①	96.50A 68.90B	—
	文献[30]	采用级联策略,组合卷积层、批归一化层和ReLU激活函数	计算资源需求降低	对小肿瘤的分割精度有待提高	②	98.82A 64.30B	—
	文献[31]	结合多层深度卷积网络和分形残差网络,使用主动轮廓模型进行边界细化	在识别小和不规则形状的肿瘤时效果显著	存在一定的假阳性和假阴性	⑤	86.00B	—
	文献[32]	采用高斯权重初始化,轻量级设计减少参数数量,引入局部响应归一化层	轻量化设计显著降低了计算成本	性能需在更大规模数据集上进一步验证	①②③	95.07A	—
基于FCN	文献[36]	采用级联结构,并引入3D条件随机场进行后处理	泛化能力高	调参过程耗时长	②⑤	94.30A 56.00B	—
	文献[38]	结合3D和2D卷积,并使用CRF在边界区域进行后处理	分割速度快	分割边界模糊区域时有一定误差	⑤	93.52A	—
	文献[39]	引入软注意力机制和混合连接块	有效提取和融合上下层特征	对GPU性能要求较高	①②⑤	94.50A 62.00B	—
	文献[40]	设计出级联2.5D FCN,提出新的边界损失函数,引入后处理	后处理步骤显著降低假阳性	存在信息损失	①②	94.30A 74.50B	—
	文献[41]	结合Inception、残差网络和预训练权重,结合数据增强和多层次特征融合	适合临床应用	数据集较小,验证有限	⑤	92.00A 91.00B	—
	文献[42]	结合多层卷积和不同分辨率的特征提取	性能提升	训练时间较长	⑤	98.00B	—

表3(续)							
方法	文献	改进思路	优点	缺点	数据集	实验结果(最优性能)	
						Dice/%	其他指标
基于 U-Net	文献[44]	使用ResPath代替跳跃连接,引入super-voxel分割和概率密度函数估计	适用于不同特征的CT图像	存在欠分割的情况	②③	96.40A	VOE=6.92%A RVD=-0.36%A
	文献[45]	引入密集模块、Inception模块和膨胀卷积,设计了权重地图	减少假阳性和假阴性	存在欠分割的情况	①	75.10B	VOE=43.7%B RVD=-22.8%B
	文献[46]	结合了深度跳跃连接,设计了一种新DFK损失函数	模型参数少,计算高效	参数较少限制复杂任务的表现	①	97.37A	—
	文献[47]	结合预处理和简化的卷积层设计,保证分割精度的同时,减少计算复杂度	特别适合资源受限的实际应用	复杂图像分割任务中的表现有待提升	①	97.91B	—
	文献[48]	提出CofRes Module,在残差连接中引入更多卷积操作,引入CA Module,设计AR Module,结合LSTM和空间注意力机制	有效减少了过拟合	存在欠分割的情况	①	96.54A	—
	文献[49]	结合平行Atrous卷积和残差模块,采用Mish激活函数	Atrous卷积减少了模型参数量	需进一步验证其在其他数据集上的泛化能力	①②	—	Recall=99.2%B
	文献[50]	结合级联Dense-UNet和图割	适用于低对比度和边界模糊的肿瘤	依赖于标注数据	①②	78.00B	Recall=71%B
	文献[51]	引入残差块来加强梯度传递并防止梯度消失	有效解决了梯度消失问题	计算开销大	②	97.81A 89.30B	VOE=13%A; 13.15%B RVD=0.018%A; 7.23%B
	文献[52]	引入残差模块和高效通道注意力机制,使用Dice Loss替代交叉熵损失函数	图像特征的表达能力增强	处理较小的感兴趣区域时可能存在欠分割问题	①	—	Recall=96%A; 93.4%B
	文献[53]	引入LKA和PA,用深度可分离卷积替换标准卷积	分割精度显著提高	模型的训练时间和调优过程更为复杂	⑤	97.92A	—
融合 模型	文献[54]	通过多分支特征融合,同时捕捉局部边缘细节和全局上下文信息	在边界细节和小肿瘤分割上表现出色	网络结构复杂	①	96.70A 66.60B	VOE=6.3%A; 3.8%B
	文献[55]	结合U-Net的快速特征学习能力和Transformer的全局特征捕捉能力,并设计了特征增强单元	全局与局部特征融合	模型参数较多	①②③④	95.35A	VOE=8.04%A RVD=-0.07%A
	文献[56]	结合ResNeXt50、膨胀卷积和Transformer,通过膨胀卷积扩大感受野	上下文编码能力增强感受野扩展	模型参数多,计算复杂度高	①	93.38A 89.87B	Recall=98.89%A; 94.31%B
	文献[57]	融合卷积和Transformer,结合混合嵌入层和可变形多尺度模块	在处理肿瘤形状和大小变化较大时表现好	计算复杂度较高	①	92.00A 74.80B	VOE=8.2%A; 39.8%B RVD=1.4%A; 0.3%B

注:数据集中,①表示LiTS,②表示3DIRCADb,③表示SLiver07,④表示CHAOS,⑤表示私有数据集;“—”表示当前无结果,“A”表示肝脏分割结果,“B”表示肝脏肿瘤分割结果。

Mask-RCNN结构提升分割精度但对噪声敏感,CEDCNN^[30]通过级联结构减少假阳性但对小肿瘤效果有限,Ga-CNN^[32]优化计算效率但大规模数据验证不足。

(2)FCN及其改进模型在肝脏及肝脏肿瘤分割中通过技术创新提升了精度。基础FCN通过去除全连接层保留空间信息,能实现像素级分割,但在低对比度和异质数据上存在挑战。改进模型如级联FCN、2.5D FCN和HFCNN通过多尺度特征融合、CRF后处理和数据增强,提升了分割精度和鲁棒性,尤其在复杂和低对比度图像上表现良好。然而,这些模型在处理复杂肝脏形态和多发性肿瘤时仍有局限,且计算复杂度较高。比如,Rafiei等^[38]的3D-2D FCN结合CRF后处理提高了小肿

瘤的检测精度,但对复杂结构分割仍有挑战。

(3)U-Net及其改进模型通过引入跳跃连接、残差模块、膨胀卷积等技术,提升了肝脏及肝脏肿瘤的分割精度。基础U-Net通过跳跃连接有效保留细节信息,但在处理复杂边界和小肿瘤时存在局限。改进模型如RP-UNet通过ResPath减少编码器与解码器的语义差距,BS U-Net结合Inception模块和膨胀卷积增强了形变控制能力,但计算复杂度较高。ELU-Net通过轻量化设计提高了效率,但对数据质量敏感。AU-Net使用空洞卷积模块提升高分辨率特征的提取能力,但对小肿瘤分割效果较弱。例如,Li等^[45]提出的BS U-Net结合Inception模块和膨胀卷积,在减少假阳性和假阴性率的同

时,提升了分割精度,但计算开销较大,复杂性较高。

(4)融合模型在提高分割精度方面具有显著优势,尤其是在处理肿瘤的大小、形状、边界等复杂特征方面。融合多种模型的技术虽然在提升分割精度方面表现突出,但也面临一些普遍的问题和挑战。首先,多个模型的融合通常会导致模型复杂度的增加,例如,KTU-Net^[54]融合了三种不同的模型,在分割精度上取得了显著提升,但也因此增加了计算复杂度。其次,混合模型的性能往往高度依赖于数据集的质量和多样性,例如,ResTransUnet模型^[55]虽然提高了分割精度,但其在不同

数据集上的泛化能力仍然存在局限。总的来说,融合模型结合了多种架构的优势,但其存在的问题仍需进一步优化解决。

4.2 无监督学习方法的分析比较

进一步对各类无监督学习方法在肝脏及其肿瘤图像分割上的优缺点与性能进行整理,如表4所示。

(1)GAN在无监督学习的肝脏及肝脏肿瘤分割中,通过对抗训练生成与真实样本相似的伪图像,增强训练数据并提高模型的泛化能力,其优势在于无须标注数据即可生成高质量的伪图像,缓解数据不足问题,提升分

表4 无监督学习分割算法总结

Table 4 Summary of segmentation algorithms in unsupervised learning

方法	模型	改进思路	优点	缺点	数据集	实验结果(最优性能)	
						Dice/%	其他指标
生成对抗网络的应用	文献[61]	利用 CycleGAN 将对对比增强 CT 数据转化为无对比剂 CT 数据,使用生成的无对比剂 CT 样本进行混合训练	生成更多无对比增强 CT 训练样本	仅在少量数据上进行测试	①	94.20A	—
	文献[62]	引入伪病灶数据增强策略,通过正常数据生成伪病灶数据,提出一种基于图像梯度感知的重建误差指数	伪病灶数据增强技术丰富训练数据	依赖伪病灶生成质量	①⑤	—	AUC=86.1%A
	文献[63]	采用改进的 CycleGAN,引入 VAE-based 判别器和 DGCC 模块,以高层次形状约束提升伪标签质量	伪标签质量提升	对域间差异敏感	④	88.90A	ASSD=5.656 pixelA
	文献[65]	结合注意力机制和 GAN,通过肝脏肿瘤区域的掩码引导合成带有肿瘤的肝脏 CT 图像	专注病灶合成,合成质量高	未验证泛化性	①	65.80B	—
	文献[66]	利用部分卷积和 Wasserstein GAN 进行肝脏肿瘤合成,并通过自动生成的肿瘤掩码生成具有真实纹理的肿瘤图像	部分卷积优化合成质量	仅限于 2D 训练	①	71.40B	—
	文献[67]	通过跳层通道采样激励提高梯度传递效率,自适应高效组注意力增强判别器区分能力,并设计基于 GLCM 特征的损失函数约束模型	计算高效,适用于低算力设备	未进行 3D 训练	—	—	FID=75.73
基于聚类的分割方法	文献[68]	结合深度学习和 FCM 的 Level-Set 方法,使用 FCM 估算肝脏肿瘤的概率分布	提高边缘检测精度	计算复杂度增加	③	72.45B	—
	文献[70]	结合 FCM 和 Mean Shift 聚类,通过凹凸点特征提取精确分离肝脏及其病灶	适用于复杂肿瘤形态	泛化能力未验证	①	94.00A 91.00B	ASD=1.5 mm
	文献[72]	通过特征重建优化视图特征,结合模糊聚类与信息论学习视图间的互信息	适用于不完整多视图数据	只适用于双视图数据	⑤	—	ACC=77.5%B
	文献[73]	提出多核 K-means 聚类方法,结合线性核和二次核函数	降低传统 K-means 局限性	计算复杂度较高	—	—	ACC=97.75%B
	文献[75]	提出自适应 K-means 聚类+隐马尔可夫随机场方法,通过 K-means 进行初始聚类	迭代次数更少,计算效率更高	需要调整多个超参数	—	—	—
	文献[76]	K-means 聚类结合 SegNet 深度神经网络,通过功率律变换增强图像对比度	多相位 CT 影像适用性强	假阳性较高	②	96.46A 85.07B	—
跨模态域适应方法	文献[78]	解耦表示和跨模态图像翻译的域适应方法,将医学影像的潜在空间分解为内容空间和风格空间	无须目标域标注	仅限 2D 图像处理	④	81.10A	—
	文献[79]	提出结合解耦习和自训练的全新无监督域自适应方法,引入形状感知的几何表示	双向适应	计算复杂度高	④	89.65A	—
	文献[80]	无源数据的无监督域适应方法,特征映射统计引导的模型自适应、风格补偿网络和循环学习机制	无须源域数据	未处理 3D 体数据	④	88.40A	ASSD=0.331 mm
	文献[81]	采用对抗损失和协变量偏移策略,结合深度卷积神经网络	无须显式模态信息	在部分复杂场景表现有限	④	83.50A	—

注:数据集中,①表示 LiTS,②表示 3DIRCADb,③表示 SLiver07,④表示 CHAOS,⑤表示私有数据集;“—”表示当前无结果,“A”表示肝脏分割结果,“B”表示肝脏肿瘤分割结果。

割精度。GAN还可以生成伪标签,提供像素级标注信息,减少计算成本并提高训练效率。缺点包括生成图像与真实数据存在差异,可能影响分割精度,且训练过程易受模式崩溃影响,导致图像缺乏多样性。生成高分辨率图像时,计算复杂度较高,消耗大量资源。例如,Song等^[61]使用CycleGAN进行数据增强,通过生成非对比增强CT切片并堆叠成3D体积扩展训练样本,尽管提高了训练效果,但生成的伪图像在细节上与真实图像有所偏差,影响分割精度。

(2)基于聚类的分割方法在肝脏及肝脏肿瘤的无监督学习中具有较强的鲁棒性,尤其在处理边界模糊和肿瘤形态多变时。FCM通过模糊隶属度对像素分类,有效应对噪声和模糊边界,结合边缘检测和局部空间信息进一步提升了分割精度。 K -means聚类因其高效性广泛应用于肝脏肿瘤分割,尤其是与区域生长算法或图像增强技术结合后,能有效提高分割精度。然而,这些方法在处理复杂图像时计算成本较高,尤其是在大规模图像处理时,仍面临计算效率和精度的挑战。

(3)跨模态域适应方法在肝脏及肝脏肿瘤分割中,主要通过无监督学习策略解决不同影像模态间的分布差异,提升模型的泛化能力。其核心技术是利用源域的标注数据增强目标域的分割性能,减少人工标注需求并提高模型的适应性和鲁棒性。通过图像翻译、解耦学习和对抗学习等技术,跨模态域适应能够有效对齐源域和目标域的特征,优化图像分割精度。然而,目标模态与源模态之间的细节差异可能导致生成图像的分割精度下降。此外,对抗学习、解耦学习等方法增加了计算复杂度,使训练过程更为复杂。例如,Jiang等^[78]采用解耦表示、跨模态图像翻译与对抗学习技术,将图像潜在空间分解为内容空间和风格空间,通过编码器进行解耦并重新组合生成跨模态图像。尽管该方法显著提升了分割性能,但生成的目标模态图像在细节上与真实图像仍存在差距,影响了分割精度。

5 总结与未来展望

深度学习在肝脏与肝脏肿瘤分割中的研究虽已取得可喜进展,在自动化、准确性和复杂图像数据处理等方面表现出色,但就现状来看,依然存在以下不足与挑战:

(1)数据集多样性与规模不足。可用公开数据集较少,常用的只有LITS、3D-IRCADb、SLIVER07与CHAOS,研究人员多使用私有数据集;同时,公开数据集的多样性欠缺,跨机构与跨设备的数据差异较大,也影响模型的鲁棒性。

(2)追求高精度分割导致计算复杂度增加。为了提高分割精度,增加网络深度和参数量,导致计算资源需

求大幅增加。这不仅延长了训练和推理时间,还增加了内存消耗,高计算成本和复杂性还降低了模型的可解释性,阻碍了其在临床的推广应用。

(3)无监督学习在该领域的研究中仍面临诸多挑战。首先,缺乏统一的评价标准,使得不同研究间结果难以对比;其次,分割精度偏低,在肝脏肿瘤边界复杂情况下尤甚;再次,无监督方法对图像质量敏感,噪声和伪影影响较大,且现有数据集规模有限,多样性不足;最后,模型对细粒度特征的提取能力不足,训练过程易不稳定,且缺乏领域适应性。这些问题限制了无监督学习方法在肝脏肿瘤分割中的广泛应用。

未来可从以下三个方面进行应对:

(1)扩展公开数据集并进行标准化。促进跨机构合作与数据资源共享,建立更大规模的标准化数据集,增加标注数据集的规模与多样性;采用GAN等无监督学习技术,生成更高质量的合成数据,提升模型泛化能力;同时需要制定规范合成图像的质量指标,如图像与真实数据的对比度、边缘清晰度、纹理一致性等,以提高生成数据的质量,从而保证模型训练的有效性和可靠性。

(2)探索新兴技术在肝脏及肝脏肿瘤图像分割中的适用性。例如,Segment anything model^[82]是一种大规模预训练模型,可通过少量标注数据进行快速适应,具有强大迁移学习能力;此外,像神经形态计算(neuromorphic computing)^[83]与量子计算(quantum computing)^[84]等前沿技术也显示出在大规模数据处理与复杂模型训练中的潜力,可进一步提升模型计算效率与性能。

(3)采用轻量级模型与边缘计算。开发更轻量级的深度学习模型,减少计算资源需求,提高模型推理速度;同时,结合边缘计算,将模型部署在靠近数据源的设备上,实现快速响应与实时处理;在追求准确率的同时注重分割效率。

参考文献:

- [1] 王培宇,黄祺,王少东,等.《全球癌症统计数据2022》要点解读[J].中国胸心血管外科临床杂志,2024,31(7):933-954.
WANG P Y, HUANG Q, WANG S D, et al. Interpretation of the key points of "global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries"[J]. Chinese Journal of Clinical Thoracic and Cardiovascular Surgery, 2024, 31(7): 933-954.
- [2] BRAY F, LAVERSANNE M, SUNG H, et al. Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA: A Cancer Journal for Clinicians, 2024, 74(3): 229-263.
- [3] 郭振宁. 超声造影诊断微小原发性肝癌患者临床价值研究[J]. 实用肝脏病杂志, 2018, 21(5): 741-744.

- GUO Z N. Contrast-enhanced ultrasound monitoring in early diagnosis of patients with small primary liver cancer[J]. Journal of Practical Hepatology, 2018, 21(5): 741-744.
- [4] 朱凤叶, 李红, 乔继红, 等. CT与MRI在诊断原发性肝癌介入术后病灶残留及复发中的应用价值[J]. 中国CT和MRI杂志, 2018, 16(3): 76-78.
- ZHU F Y, LI H, QIAO J H, et al. The value of CT and MRI in the diagnosis of the residual and recurrent lesion of primary liver cancer after interventional therapy[J]. Chinese Journal of CT and MRI, 2018, 16(3): 76-78.
- [5] 冯焕, 姜晖, 王雪梅. 功能磁共振成像在肿瘤学领域的应用[J]. 电工技术学报, 2021, 36(4): 705-716.
- FENG H, JIANG H, WANG X M. Application of functional magnetic resonance imaging in the field of oncology[J]. Transactions of China Electrotechnical Society, 2021, 36(4): 705-716.
- [6] ALTINI N, PRENCIPE B, CASCARANO G D, et al. Liver, kidney and spleen segmentation from CT scans and MRI with deep learning: a survey[J]. Neurocomputing, 2022, 490: 30-53.
- [7] 谭健权, 伊力亚尔·加尔木哈买提. 基于深度学习的医学图像分割综述[J]. 电脑知识与技术, 2024, 20(18): 97-99.
- TAN J Q, YILIYAER J. Summary of medical image segmentation based on deep learning[J]. Computer Knowledge and Technology, 2024, 20(18): 97-99.
- [8] LUNDERVOLD A S, LUNDERVOLD A. An overview of deep learning in medical imaging focusing on MRI[J]. Zeitschrift Für Medizinische Physik, 2019, 29(2): 102-127.
- [9] 王霄, 朱恩照, 艾自胜. 卷积神经网络的原理及其在医学影像诊断中的应用[J]. 中国医学物理学杂志, 2022, 39(12): 1485-1489.
- WANG X, ZHU E Z, AI Z S. Principle of convolutional neural network and its applications in medical imaging diagnosis[J]. Chinese Journal of Medical Physics, 2022, 39(12): 1485-1489.
- [10] 张欢, 刘静, 冯毅博, 等. U-Net及其在肝脏和肝脏肿瘤分割中的应用综述[J]. 计算机工程与应用, 2022, 58(2): 1-14.
- ZHANG H, LIU J, FENG Y B, et al. Review of U-Net and its application in segmentation of liver and liver tumors[J]. Computer Engineering and Applications, 2022, 58(2): 1-14.
- [11] GUL S, KHAN M S, BIBI A, et al. Deep learning techniques for liver and liver tumor segmentation: a review[J]. Computers in Biology and Medicine, 2022, 147: 105620.
- [12] 陈英, 郑铖, 易珍, 等. 肝脏及肿瘤图像分割方法综述[J]. 计算机应用研究, 2022, 39(3): 641-650.
- CHEN Y, ZHENG C, YI Z, et al. Review of liver and tumor image segmentation methods[J]. Application Research of Computers, 2022, 39(3): 641-650.
- [13] 夏栋, 张义, 巫彤宁, 等. 深度学习在肝脏肿瘤CT图像分割中的应用[J]. 北京生物医学工程, 2023, 42(3): 308-314.
- XIA D, ZHANG Y, WU T N, et al. Applications of deep learning in liver tumor segmentation from CT scans[J]. Beijing Biomedical Engineering, 2023, 42(3): 308-314.
- [14] EGALA R, SAIRAM M V S. A review on medical image analysis using deep learning[C]//Proceedings of the 5th International Conference on Innovative Product Design and Intelligent Manufacturing Systems, 2024: 7.
- [15] KAVUR A E, GEZER N S, BARIŞ M, et al. CHAOS challenge-combined (CT-MR) healthy abdominal organ segmentation[J]. Medical Image Analysis, 2021, 69: 101950.
- [16] BILIC P, CHRIST P, LI H B, et al. The liver tumor segmentation benchmark (lits)[J]. Medical Image Analysis, 2023, 84: 102680.
- [17] SOLER L, HOSTETTLER A, AGNUS V, et al. 3D image reconstruction for comparison of algorithm database[EB/OL]. (2010-01-08) [2023-12-23]. <https://www.ircad.fr/research/datasets/liver-segmentation-3d-ircadb-01>.
- [18] AL-SHAIKHLI S D S, YANG M, ROSENHAHN B. Automatic 3D liver segmentation using sparse representation of global and local image information via level set formulation[J]. arXiv:1508.01521, 2015.
- [19] 于营, 王春平, 付强, 等. 语义分割评价指标和评价方法综述[J]. 计算机工程与应用, 2023, 59(6): 57-69.
- YU Y, WANG C P, FU Q, et al. Survey of evaluation metrics and methods for semantic segmentation[J]. Computer Engineering and Applications, 2023, 59(6): 57-69.
- [20] 蒋西然, 蒋韬, 孙嘉瑶, 等. 深度学习人工智能技术在医学影像辅助分析中的应用[J]. 中国医疗设备, 2021, 36(6): 164-171.
- JIANG X R, JIANG T, SUN J Y, et al. Deep learning in computer aided analyses of medical images[J]. China Medical Devices, 2021, 36(6): 164-171.
- [21] ALJABRI M, ALGHAMDI M. A review on the use of deep learning for medical images segmentation[J]. Neurocomputing, 2022, 506: 311-335.
- [22] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [23] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2015: 3431-3440.
- [24] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//Proceedings of the Medical Image Computing and Computer-Assisted Intervention. Cham: Springer International Publishing, 2015: 234-241.
- [25] 李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508-2512.
- LI Y D, HAO Z B, LEI H. Survey of convolutional neural

- network[J]. Journal of Computer Applications, 2016, 36(9): 2508-2512.
- [26] AGHAMOHAMMADI A, RANJBARZADEH R, NAIEMI F, et al. TPCNN: two-path convolutional neural network for tumor and liver segmentation in CT images using a novel encoding approach[J]. Expert Systems with Applications, 2021, 183: 115406.
- [27] KHAN R, SU L, ZAMAN A, et al. Customized m-RCNN and hybrid deep classifier for liver cancer segmentation and classification[J]. Heliyon, 2024, 10(10): e30528.
- [28] SELVARAJ A, NITHIYARAJ E. CEDRNN: a convolutional encoder-decoder residual neural network for liver tumour segmentation[J]. Neural Processing Letters, 2023, 55(2): 1605-1624.
- [29] MENG L, TIAN Y, BU S. Liver tumor segmentation based on 3D convolutional neural network with dual scale[J]. Journal of Applied Clinical Medical Physics, 2020, 21(1): 144-157.
- [30] BUDAK Ü, GUO Y H, TANYILDIZI E, et al. Cascaded deep convolutional encoder-decoder neural networks for efficient liver tumor segmentation[J]. Medical Hypotheses, 2020, 134: 109431.
- [31] ANIL B C, DAYANANDA P. Automatic liver tumor segmentation based on multi-level deep convolutional networks and fractal residual network[J]. IETE Journal of Research, 2023, 69(4): 1925-1933.
- [32] AHMAD M, QADRI S F, QADRI S, et al. A lightweight convolutional neural network model for liver segmentation in medical diagnosis[J]. Computational Intelligence and Neuroscience, 2022, 2022: 7954333.
- [33] 李梦怡, 朱定局. 基于全卷积网络的图像语义分割方法综述[J]. 计算机系统应用, 2021, 30(9): 41-52.
- LI M Y, ZHU D J. Review on image semantic segmentation based on fully convolutional network[J]. Computer Systems & Applications, 2021, 30(9): 41-52.
- [34] ROTH H R, ODA H, ZHOU X, et al. An application of cascaded 3D fully convolutional networks for medical image segmentation[J]. Computerized Medical Imaging and Graphics, 2018, 66: 90-99.
- [35] ALIRR O I. Deep learning and level set approach for liver and tumor segmentation from CT scans[J]. Journal of Applied Clinical Medical Physics, 2020, 21(10): 200-209.
- [36] CHRIST P F, ETTlinger F, GRÜN F, et al. Automatic liver and tumor segmentation of CT and MRI volumes using cascaded fully convolutional neural networks[J]. arXiv:1702.05970, 2017.
- [37] CHLEBUS G, SCHENK A, MOLTZ J H, et al. Automatic liver tumor segmentation in CT with fully convolutional neural networks and object-based postprocessing[J]. Sci Rep, 2018, 8(1): 15497.
- [38] RAFIEI S, NASR-ESFAHANI E, NAJARIAN K, et al. Liver segmentation in CT images using three dimensional to two dimensional fully convolutional network[C]//Proceedings of the 25th IEEE International Conference on Image Processing. Piscataway: IEEE, 2018: 2067-2071.
- [39] JIANG H Y, SHI T Y, BAI Z Q, et al. AHCNet: an application of attention mechanism and hybrid connection for liver tumor segmentation in CT volumes[J]. IEEE Access, 2019, 7: 24898-24909.
- [40] HAN Y X, LI X L, WANG B, et al. Boundary loss-based 2.5D fully convolutional neural networks approach for segmentation: a case study of the liver and tumor on computed tomography[J]. Algorithms, 2021, 14(5): 144.
- [41] DONG X, ZHOU Y Z, WANG L T, et al. Liver cancer detection using hybridized fully convolutional neural network based on deep learning framework[J]. IEEE Access, 2020, 8: 129889-129898.
- [42] HARIPRIYA T, DHARMARAJAN K, CHOWDHURY S. An innovative research of liver malignancy imaging using HFCNN based on deep neural network model[J]. Samvakti Journal of Research in Information Technology, 2024, 5(1): 1-16.
- [43] 崔珂, 田启川, 廉露. 基于U-Net变体的医学图像分割算法综述[J]. 计算机工程与应用, 2024, 60(11): 32-49.
- CUI K, TIAN Q C, LIAN L. Review of medical image segmentation algorithms based on U-Net variants[J]. Computer Engineering and Applications, 2024, 60(11): 32-49.
- [44] CZIPCZER V, MANNO-KOVACS A. Adaptable volumetric liver segmentation model for CT images using region-based features and convolutional neural network[J]. Neurocomputing, 2022, 505: 388-401.
- [45] LI S, TSO G K F, HE K J. Bottleneck feature supervised U-Net for pixel-wise liver and tumor segmentation[J]. Expert Systems with Applications, 2020, 145: 113131.
- [46] DENG Y J, HOU Y L, YAN J T, et al. ELU-Net: an efficient and lightweight U-Net for medical image segmentation[J]. IEEE Access, 2022, 10: 35932-35941.
- [47] ALAFER F, SIDDIQI H M, KHAN S M, et al. A comprehensive exploration of L-UNet approach: revolutionizing medical image segmentation[J]. IEEE Access, 2024, 12: 140769-140791.
- [48] LEE Z Q, QI S M, FAN C C, et al. RA V-Net: deep learning network for automated liver segmentation[J]. Physics in Medicine & Biology, 2022, 67(12): 125022.
- [49] NAAQVI Z, HAIDER M A, FAHEEM M R, et al. Modified U-Net model for segmentation and classification of liver cancer using CT images[J]. Journal of Computing & Biomedical Informatics, 2024: 1-12.
- [50] 杨振, 邸拴虎, 赵于前, 等. 基于级联 Dense-UNet 和图割的肝脏肿瘤自动分割[J]. 电子与信息学报, 2022, 44(5):

- 1683-1693.
- YANG Z, DI S H, ZHAO Y Q, et al. Automatic liver tumor segmentation based on cascaded Dense-UNet and graph cuts [J]. Journal of Electronics & Information Technology, 2022, 44(5): 1683-1693.
- [51] SABIR M W, KHAN Z, SAAD N M, et al. Segmentation of liver tumor in CT scan using ResU-Net[J]. Applied Sciences, 2022, 12(17): 8650.
- [52] LI J, LIU K Y, HU Y T, et al. Eres-UNet++: liver CT image segmentation based on high-efficiency channel attention and Res-UNet++[J]. Computers in Biology and Medicine, 2023, 158: 106501.
- [53] DING J S, NI W, WAN J H, et al. Mula-nnUNet: a multi-attention enhanced nnUNet framework for 3D abdominal multi-organs segmentation[J]. IEEE Access, 2024, 12: 106658-106671.
- [54] 杨本臣, 贾宇航, 金海波. 融合多分支特征的肝脏和肝脏肿瘤的体积分割[J]. 计算机工程, 2023, 49(10): 194-201.
- YANG B C, JIA Y H, JIN H B. Volume segmentation of liver and liver tumor with fusion of multi-branch features [J]. Computer Engineering, 2023, 49(10): 194-201.
- [55] OU J J, JIANG L F, BAI T, et al. ResTransUnet: an effective network combined with Transformer and U-Net for liver segmentation in CT scans[J]. Computers in Biology and Medicine, 2024, 177: 108625.
- [56] LI L, MA H. RDCTrans U-Net: a hybrid variable architecture for liver CT image segmentation[J]. Sensors (Basel), 2022, 22(7): 2452.
- [57] 陈丽芳, 罗世勇. 融合卷积和Transformer的多尺度肝肿瘤分割方法[J]. 计算机工程与应用, 2024, 60(4): 270-279.
- CHEN L F, LUO S Y. Multi-scale liver tumor segmentation algorithm by fusing convolution and transformer[J]. Computer Engineering and Applications, 2024, 60(4): 270-279.
- [58] 马露凡, 罗凤, 严江鹏, 等. 深度医学图像配准研究进展: 迈向无监督学习[J]. 中国图象图形学报, 2021, 26(9): 2037-2057.
- MA L F, LUO F, YAN J P, et al. Deep-learning based medical image registration pathway: towards unsupervised learning [J]. Journal of Image and Graphics, 2021, 26(9): 2037-2057.
- [59] RAZA K, SINGH N K. A tour of unsupervised deep learning for medical image analysis[J]. Current Medical Imaging, 2021, 17(9): 1059-1077.
- [60] XUN S Y, LI D W, ZHU H, et al. Generative adversarial networks in medical image segmentation: a review[J]. Computers in Biology and Medicine, 2022, 140: 105063.
- [61] SONG C, HE B, CHEN H, et al. Non-contrast CT liver segmentation using CycleGAN data augmentation from contrast enhanced CT[C]//Proceedings of the 3rd International Workshop on Interpretable and Annotation-Efficient Learning for Medical Image Computing, 2020: 122-129.
- [62] LI H, IWAMOTO Y, HAN X, et al. An accurate unsupervised liver lesion detection method using pseudo-labels [C]//Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer Nature Switzerland, 2022: 214-223.
- [63] WANG L, GUO D, WANG G, et al. Annotation-efficient learning for medical image segmentation based on noisy pseudo labels and adversarial learning[J]. IEEE Transactions on Medical Imaging, 2021, 40(10): 2795-2807.
- [64] RAFIQ M, ALI H, MUJTABA G, et al. Cross modality medical image synthesis for improving liver segmentation[J]. arXiv:2503.00945, 2025.
- [65] LIU Y, MENG L, ZHONG J. MAGAN: mask attention generative adversarial network for liver tumor CT image synthesis[J]. Journal of Healthcare Engineering, 2021, 2021: 6675259.
- [66] LIU Y, YANG F, YANG Y. A partial convolution generative adversarial network for lesion synthesis and enhanced liver tumor segmentation[J]. Journal of Applied Clinical Medical Physics, 2023, 24(4): e13927.
- [67] ZHENG Z C, WANG M, FAN C, et al. Light&fast generative adversarial network for high-fidelity CT image synthesis of liver tumor[J]. Computer Methods and Programs in Biomedicine, 2024, 254: 108252.
- [68] ZHANG Y, WU J, JIANG B X, et al. Deep learning and unsupervised fuzzy C-means based level-set segmentation for liver tumor[C]//Proceedings of the IEEE 17th International Symposium on Biomedical Imaging. Piscataway: IEEE, 2020: 1193-1196.
- [69] AL-SAEED Y, SOLIMAN H, ELMOGY M. Liver segmentation using fast-generalized fuzzy C-means (FG-FCM) from CT scans[C]//Proceedings of the International Conference on Data Analytics for Business and Industry: Way Towards a Sustainable Economy. Piscataway: IEEE, 2020: 1-6.
- [70] RANJBARZADEH R, SAADI S B. Automated liver and tumor segmentation based on concave and convex points using fuzzy C-means and mean shift clustering[J]. Measurement, 2020, 150: 107086.
- [71] RELA M, NAGARAJA S, RAMANA P. Liver tumor segmentation using superpixel based fast fuzzy C means clustering[J]. International Journal of Advanced Computer Science and Applications, 2020, 11(11): 230120927.
- [72] LI S, LI X. Fully incomplete information for multiview clustering in postoperative liver tumor diagnoses[J]. Sensors (Basel), 2025, 25(4): 1215.
- [73] KRISHAN A, MITTAL D. Effective segmentation and classification of tumor on liver MRI and CT images using multi-kernel K-means clustering[J]. Biomedizinische Technik, 2020, 65(3): 301-313.
- [74] 林家兴, 吕东瀚. 基于区域生长与K-means聚类结合的肝

- 脏肿瘤分割[J]. 电脑知识与技术, 2021, 17(26): 134-137.
- LIN J X, LYU D H. Segmentation of liver tumors based on regional growth combined with K -means clustering[J]. Computer Knowledge and Technology, 2021, 17(26): 134-137.
- [75] ANANTH C, AMUTHA S, NIHA K. Enhancing segmentation approaches from super pixel division algorithm to hidden Markov random fields with expectation maximization (HMRf-EM)[J]. International Journal of Early Childhood Special Education, 2022, 14(5): 2400-2410.
- [76] PATTWAKKAR V N, KAMATH S, KANABAGATTE NANJUNDAPPA M, et al. Automatic liver tumor segmentation on multiphase computed tomography volume using SegNet deep neural network and K -means clustering[J]. International Journal of Imaging Systems and Technology, 2023, 33(2): 729-745.
- [77] GUAN H, GUAN H, LIU M. Domain adaptation for medical image analysis: a survey[J]. IEEE Transactions on Biomedical Engineering, 2022, 69(3): 1173-1185.
- [78] JIANG K D, QUAN L, GONG T. Disentangled representation and cross-modality image translation based unsupervised domain adaptation method for abdominal organ segmentation[J]. International Journal of Computer Assisted Radiology and Surgery, 2022, 17(6): 1101-1113.
- [79] XIE Q S, LI Y X, HE N J, et al. Unsupervised domain adaptation for medical image segmentation by disentanglement learning and self-training[J]. IEEE Transactions on Medical Imaging, 2024, 43(1): 4-14.
- [80] HONG J, ZHANG Y D, CHEN W T. Source-free unsupervised domain adaptation for cross-modality abdominal multi-organ segmentation[J]. Knowledge-Based Systems, 2022, 250: 109155.
- [81] OZKAN S, SELVER M A, BAYDAR B, et al. Cross-modal learning via adversarial loss and covariate shift for enhanced liver segmentation[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2024, 8(4): 2723-2735.
- [82] 王淼, 黄智忠, 何晖光, 等. 分割一切模型SAM的潜力与展望: 综述[J]. 中国图象图形学报, 2024, 29(6): 1479-1509.
- WANG M, HUANG Z Z, HE H G, et al. Potential and prospects of segment anything model: a survey[J]. Journal of Image and Graphics, 2024, 29(6): 1479-1509.
- [83] RATHI N, CHAKRABORTY I, KOSTA A, et al. Exploring neuromorphic computing based on spiking neural networks: algorithms to hardware[J]. ACM Computing Surveys, 2023, 55(12): 1-49.
- [84] WEI L, LIU H W, XU J, et al. Quantum machine learning in medical image analysis: a survey[J]. Neurocomputing, 2023, 525: 42-53.