

基于改进U-Net和注意力机制的肝脏肿瘤图像分割

何晓明

河北工业大学理学院, 天津

收稿日期: 2026年2月22日; 录用日期: 2026年3月20日; 发布日期: 2026年3月27日

摘要

针对肝脏肿瘤图像中病灶形态复杂、与周围组织边界模糊, 导致分割精度受限的问题, 提出一种基于改进U-Net和注意力机制的肝脏肿瘤图像分割模型(DMCAU-Net)。该模型通过设计双分支多尺度残差卷积模块替代传统卷积结构, 利用多分支方式提取不同感受野下的特征信息, 从而增强对多尺度肿瘤特征的表达能力。同时, 在跳跃连接中引入CBAM双重注意力机制, 对通道维和空间维特征进行自适应加权, 有效抑制背景噪声干扰, 使模型更加关注肝脏肿瘤关键区域。此外, 构建了结合二元交叉熵损失和Dice损失的混合损失函数, 以进一步平衡分类性能与分割精度。实验结果表明, 与基线模型U-Net相比, 所提出模型在IoU和DSC指标上分别达到90.07%和94.78%, 分别提升了18.73%和11.51%。结果验证了该模型在肝脏肿瘤图像分割任务中的有效性, 可为临床诊断与治疗提供可靠的技术支持。

关键词

肝脏肿瘤分割, 深度学习, 多尺度卷积, 注意力机制

Liver Tumor Image Segmentation Based on an Improved U-Net and Attention Mechanisms

Xiaoming He

School of Science, Hebei University of Technology, Tianjin

Received: February 22, 2026; accepted: March 20, 2026; published: March 27, 2026

Abstract

Aiming at the problem that the segmentation accuracy of liver tumor images is limited due to the

complex morphology of lesions and the blurred boundaries between tumors and surrounding tissues, a liver tumor segmentation model based on an improved U-Net and attention mechanisms (DMCAU-Net) is proposed. In this model, a dual-branch multiscale residual convolution module is designed to replace the traditional convolution module, and feature information with different receptive fields is obtained through a multi-branch structure, thereby enhancing the extraction and representation ability of multiscale tumor features. At the same time, a CBAM dual attention mechanism is embedded into the skip connections, and the feature fusion is optimized by dynamically adjusting channel and spatial weights, which suppresses background noise interference and enables the model to accurately focus on tumor regions. In addition, a hybrid loss function combining binary cross-entropy loss and Dice loss is constructed to further balance classification performance and segmentation quality. Experimental results show that, compared with the base-line model U-Net, the IoU and DSC of the proposed model reach 90.07% and 94.78%, respectively, with improvements of 18.73% and 11.51%, respectively. The proposed model significantly improves the segmentation accuracy of liver tumors and provides reliable evidence for clinical diagnosis and treatment.

Keywords

Liver Tumor Segmentation, Deep Learning, Multiscale Convolution, Attention Mechanism

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

肝脏作为人体重要实质性器官之一，是机体新陈代谢最活跃的组织，承担营养物质的合成与分解、解毒及排泄等关键生理功能。近年来，肝脏疾病发病率持续上升[1]，提高病灶诊断的准确性对临床治疗至关重要。超声(US)、计算机断层扫描(CT)与磁共振成像(MRI)等影像技术为肝癌诊疗提供了多维信息。然而，CT检查中通常包含大量切片，传统依赖人工勾画肿瘤区域的方法不仅耗时耗力，还高度依赖医师经验。特别是在肿瘤与正常组织对比度低、形态变化大的情况下，漏分或误分的情况常常发生，影响诊断效率与准确性。

近年来，深度学习技术[2]的兴起为医学影像分析带来突破，全卷积神经网络因其端到端的像素级预测能力，在肝脏及肿瘤等医学影像分割任务中取得了显著进展。其中，U-Net网络[3]凭借典型的编码器-解码器结构与跳跃连接设计，可在下采样过程中提取高层语义信息，并在上采样阶段融合浅层细节特征，从而更好地恢复目标边界与形态信息，目前已成为医学图像分割领域应用最广泛的基准模型之一。

为提升肝脏肿瘤分割精度，研究者围绕U-Net结构开展了多方面改进。张欢等[4]对U-Net在编码器、解码器与跳跃连接等结构改进进行了系统归纳，并总结其在肝脏肿瘤分割中的应用。李秀华等[5]提出融合混合空洞卷积、注意力机制及Focal Tversky损失的改进模型，LiTS2017实验显示其Dice系数提升3.56%~4.21%。莫亚霓等[6]通过级联网络将肝脏分割与肿瘤分割结合，在提取肿瘤感兴趣区域(ROI)后，通过第二阶段进一步精细分割肿瘤，从而提高了分割精度。

上述深度学习在医学图像分割领域取得不错的分割效果，但肝脏肿瘤分割领域仍然存在肝脏肿瘤数据集较少，肝脏肿瘤与四周的正常组织之间边界模糊，从而影响病灶的边缘信息分割的准确性的问题。同时多数网络在对病灶区域进行分割时仅利用CNN (Convolutional Neural Network) [7]，会导致图像信息在一定程度上被削弱，从而影响后续的边界轮廓信息的提取的问题。

为解决上述模型在分割形状复杂、边界模糊的肝脏肿瘤图像时存在分割结果精确率低的问题，本文提出了一种新的网络架构，以提升 CT 影像中对肝脏肿瘤的分割精度。本文的主要贡献总结如下：1) 提出了双分支多尺度残差卷积模块(Dual-branch Multi-scale Residual Convolution Block, DMRCB)，通过多分支使用不同感受野的卷积核，从多个尺度提取肝脏肿瘤特征，增强了对不同尺寸肿瘤的表征能力；2) 在跳跃连接中嵌入了 CBAM (Convolutional Block Attention Module)注意力机制，动态调整特征通道与空间权重，优化了浅层与深层语义信息的融合，避免了背景噪声干扰，使模型能够更精确地聚焦肝脏肿瘤区域；3) 设计了一种混合损失函数，结合了二元交叉熵损失与 Dice 损失，进一步提升了模型的稳定性与分割精度。

2. 方法

2.1. 整体网络架构

针对肝脏肿瘤图像分割任务中存在的肿瘤尺寸差异大、边界模糊以及特征融合粗糙等问题，本文提出了一种改进的 U-Net 网络架构——DMCAU-Net (Dual-branch Multi-scale Convolution and Attention U-Net)，如图 1 所示。该网络在保持 U-Net 经典对称式编码-解码结构的基础上，通过引入双分支多尺度残差卷积模块(DMRCB)和通道-空间注意力机制(CBAM)，有效提升了多尺度特征提取能力和空间上下文建模效果。

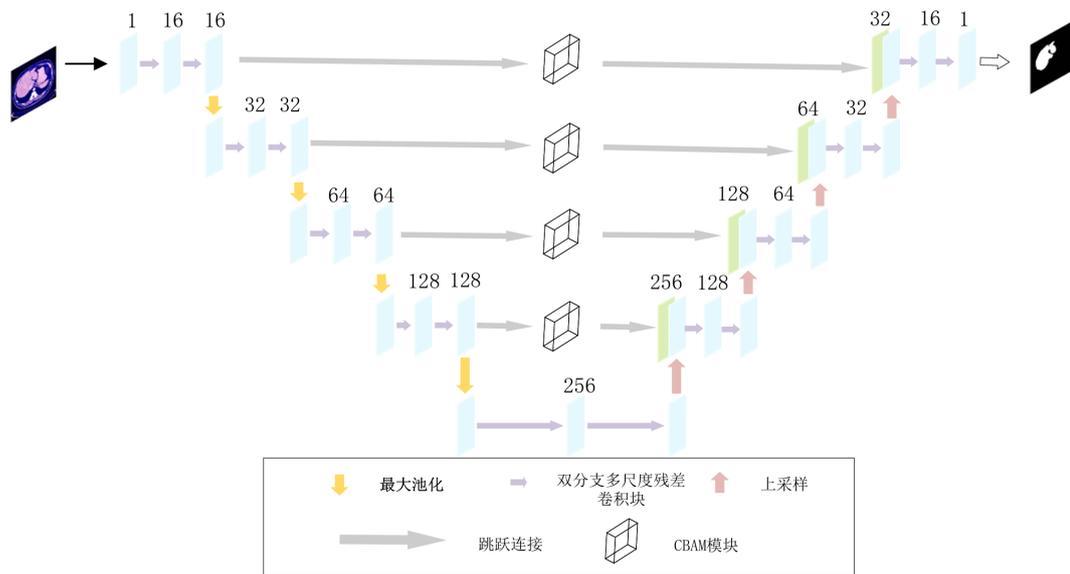


Figure 1. Architecture of DMCAU-Net
图 1. DMCAU-Net 网络结构图

DMCAU-Net 的整体架构由编码器、解码器和跳跃连接三部分组成。编码器部分包含四级下采样结构，每级由一个 DMRCB 模块与一个 2×2 最大池化操作组成。DMRCB 模块作为核心特征提取单元，采用双分支并行方式提取多尺度信息，能够同时捕获微小肿瘤的局部细节与大尺寸肿瘤的全局上下文信息。在下采样过程中，特征图尺寸逐级减半，而通道数逐级倍增，形成多尺度特征金字塔。

在跳跃连接路径中，本文在每条连接末端引入了 CBAM 模块。该模块包括通道注意力和空间注意力两个子模块，串联组成对浅层特征的注意力筛选机制。在与解码器特征融合前，CBAM 对编码器传来的浅层语义信息进行自适应调节，强化目标区域的显著响应，有效抑制肝脏血管、胆管等解剖结构产生的背景噪声干扰。

解码器部分与编码器对称，同样包含四级上采样结构。每级首先通过转置卷积实现尺寸还原，然后将上采样特征与经 CBAM 调节后的编码器特征进行通道拼接，随后送入 DMRCB 模块进行特征融合与重建。该结构充分利用多尺度语义信息与跳跃连接细节，有效弥补了上采样过程中潜在的信息损失。最后一层采用 1×1 卷积将多通道特征图映射为单通道，配合 Sigmoid 激活函数输出肿瘤的二值掩膜图，实现像素级分割。

2.2. 双分支多尺度残差卷积模块(DMRCB)

传统 U-Net 编码器采用单一尺度的卷积核，难以同时捕获不同尺寸肿瘤的特征信息。肝脏肿瘤直径可从数毫米至数十厘米不等，而固定尺寸卷积操作对多尺度特征的适应性较差，易导致小肿瘤漏检或大肿瘤边缘分割不准确。为解决这一问题，本文设计了双分支多尺度残差卷积模块，如图 2 所示。

DMRCB 模块的结构由两个分支组成，每个分支并行使用不同尺寸的卷积核来处理输入特征。第一分支包含 1×1 卷积和 3×3 卷积，用于提取通道间的关系和局部空间特征。第二分支则包含 1×1 、 3×3 和 5×5 卷积，分别用于捕捉不同尺度的特征信息。通过这种并行结构，DMRCB 能够同时从多个尺度处理图像中的细节和全局特征，提升特征提取的多样性。

在每个卷积操作后，使用批量归一化(Batch Normalization)和 ReLU 激活函数，以增强网络的非线性表达能力。随后，模块通过残差连接将输入特征与卷积操作后的输出相加，确保信息的有效传递，并优化梯度的流动。这种残差结构解决了深层网络中的梯度消失问题，同时保留了输入特征中的高频细节信息，提升了网络训练的稳定性。

在多分支并行处理特征后，DMRCB 通过拼接操作将两个分支的特征图沿通道维度进行合并，形成一个包含多尺度信息的特征图。拼接后的特征图经过 1×1 卷积融合，去除冗余特征并强化有效信息，最终输出优化后的特征图。这一过程确保了来自不同尺度的特征能够被充分融合，从而提升模型的表现力。

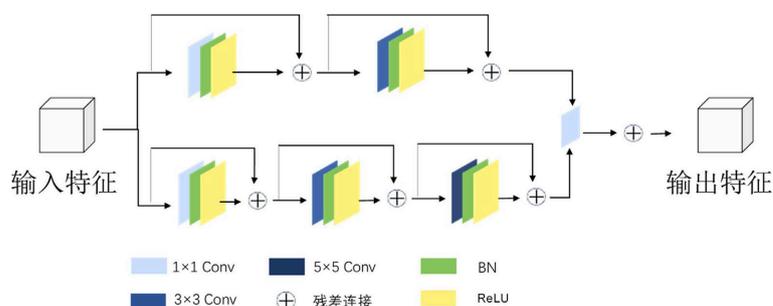


Figure 2. Structure of DMRCB module
图 2. DMRCB 模块结构图

2.3. CBAM

原始 U-Net 的跳跃连接直接拼接编码器的浅层特征与解码器的深层特征，忽视了不同尺度特征的差异以及通道与空间维度的权重分配。在肝脏肿瘤分割任务中，肝脏血管、胆管等解剖结构的干扰常使肿瘤区域的响应被背景噪声淹没。为此，本文在跳跃连接中嵌入了 CBAM 双注意力机制[8]，通过动态特征选择优化编码器与解码器间的特征融合过程。

CBAM 是一种轻量级注意力机制，通过通道和空间双重注意力权重动态调整特征重要性。其结构分为通道注意力子模块(Channel Attention Module, CAM)和空间注意力子模块(Spatial Attention Module, SAM)两部分，以串联方式组成通道 - 空间的注意力流程，如图 3 所示。通道注意力子模块通过计算各通道全

局特征的重要性权重，突出重点关注的特征，增强特征在通道维度上的表现。空间注意力子模块则分析像素间关系，动态捕捉局部至全局的显著区域，识别空间维度上的重要信息。这两种机制可独立整合进 CNN 的不同层级，如通道注意力可放置在卷积层后进行初步特征增强，空间注意力用于最终的特征提纯阶段，这种灵活性使 CBAM 适应各类网络架构，尤其轻量化模型和复杂任务。通过双重注意力机制，CBAM 可优化编码器与解码器间的特征融合过程：低级特征中的解剖结构信息和高级特征中的语义信息通过注意力加权后，能更精准地对齐和互补。

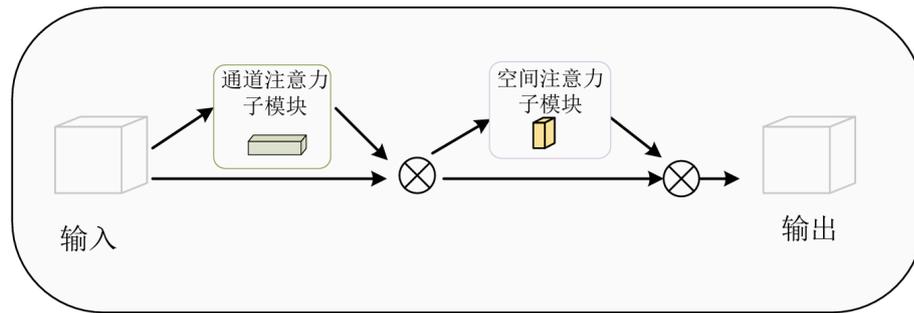


Figure 3. Structure of CBAM module

图 3. CBAM 模块结构图

通道注意力子模块通过全局空间信息压缩和通道间非线性交互，实现特征通道的权重分配。首先采用全局平均池化(GAP)和全局最大池化(GMP)对输入特征图进行双路径空间压缩，分别提取特征图的整体分布特征和局部显著特征。随后，通过共享权重的双层全连接网络(MLP)建立通道间的非线性依赖关系，最终通过 Sigmoid 函数生成归一化的通道权重向量，如图 4 所示。

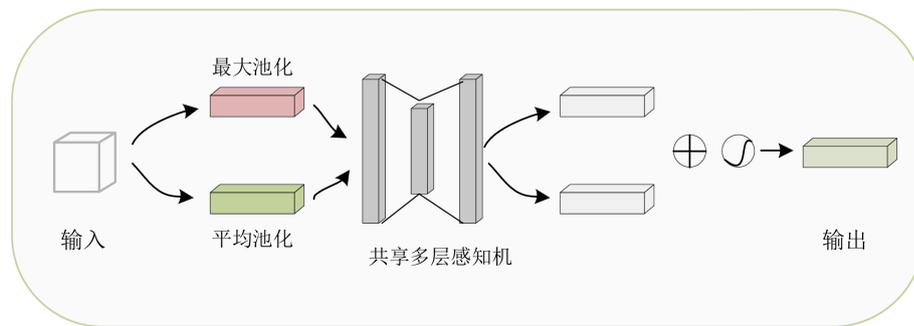


Figure 4. Channel attention module

图 4. 通道注意力子模块

空间注意力子模块侧重于特征图的空间维度优化，通过建立像素级的位置相关性模型，强化目标区域的响应强度。首先对通道注意力输出的特征图进行通道维度的全局平均池化和最大池化操作，将特征图压缩为空间描述符。接着采用卷积核进行空间卷积运算，通过扩大感受野捕捉长距离的空间依赖关系，最终生成的空间权重图能够精准定位肝脏肿瘤的边界区域，如图 5 所示。

2.4. 损失函数

在肝脏肿瘤图像分割任务中，由于肿瘤区域在整幅图像中占比较小，存在严重的类别不平衡问题。单一的损失函数难以有效平衡分类性能和分割精度。为此，本文设计了一种混合损失函数，结合二元交

叉熵损失与 Dice 损失的优势，优化模型性能。

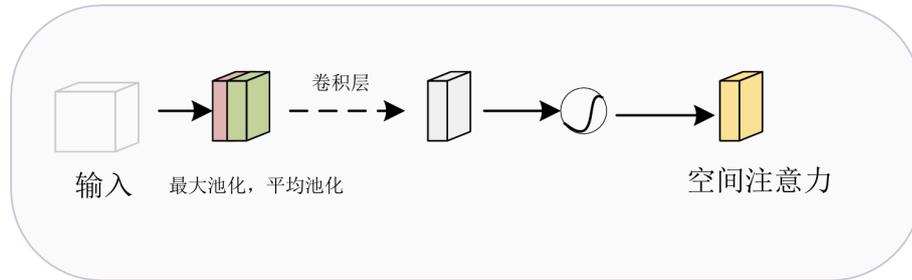


Figure 5. Spatial attention module
图 5. 空间注意力子模块

二元交叉熵损失(Binary Cross-Entropy Loss, BCE)通常用于二分类任务, 在肝脏肿瘤分割中, 每个像素被分为前景(肿瘤)或背景(非肿瘤), 该函数可以有效计算预测值与真实标签之间的差异。BCE 损失对预测置信度敏感, 能够提供稳定的梯度信号, 但对类别不平衡问题较为敏感, 计算公式如下:

$$L_{\text{BCE}} = -\frac{1}{N} \sum_{i=1}^N [y_i \log p_i + (1 - y_i) \log(1 - p_i)], \quad (1)$$

其中, N 为样本数, p 代表模型预测值, y 表示真实标签。

Dice 损失是基于 Dice 相似系数(DSC), 常用于图像分割任务, 直接优化预测区域与真实区域的重叠程度。Dice 损失对类别不平衡不敏感, 能够直接优化目标区域匹配度, 但对预测置信度的绝对数值不敏感, 训练初期梯度可能剧烈波动, 计算公式如下:

$$L_{\text{Dice}} = 1 - \frac{2TP}{2TP + FP + FN}。 \quad (2)$$

为了更准确地分割肿瘤区域, 结合二元交叉熵和 Dice 两个损失函数, 有效地平衡分类性能和分割精度, 从而优化模型性能, 定义如下:

$$\text{Loss} = \alpha \text{Loss}_{\text{BCE}} + \beta \text{Loss}_{\text{Dice}}, \quad (3)$$

其中 α 和 β 是混合损失函数中的超参数, 本文选择 $\alpha = 0.4$, $\beta = 0.6$, 这种权重配置对各类肿瘤区域的分割结果在边界清晰度、内部填充完整性以及与真实病理切片对比的一致性等方面均达到较优水平。

3. 实验结果与分析

为验证本文所提出的 DMCAU-Net 模型在肝脏肿瘤分割任务中的有效性, 本节在公开数据集 LiTS2017 上开展了系统性实验研究。首先介绍实验所用数据集及预处理方法, 随后阐述实验环境配置与评估指标, 最后通过对比实验和消融实验对模型性能进行全面分析。

3.1. 数据集及预处理

本研究采用 LiTS2017 (Liver Tumor Segmentation Challenge 2017)数据集[9]进行模型训练与验证。该数据集由国际医学图像计算与计算机辅助干预会议(MICCAI)发起, 整合了全球多家医学中心的临床增强 CT 影像数据, 是医学影像领域权威的肝脏肿瘤分割基准数据集。

LiTS2017 数据集包含 131 例训练样本(含 76 例男性与 55 例女性病例)及 70 例测试样本。每张 CT 图像及其对应标签的原始尺寸均为 512×512 像素, 平面内分辨率为 0.55 mm 至 1.0 mm, 层间间距为 0.45

mm 至 6.0 mm。所有病例均经病理学验证为肝细胞癌或转移性肝癌，肿瘤直径覆盖 8 mm 至 185 mm 范围，具有较高的临床代表性和数据多样性。

在数据预处理阶段，本研究采取以下策略：首先，为降低模型计算复杂度并提升对小目标的检测精度，将原始 512×512 分辨率的 CT 图像统一缩放至 128×128 像素。其次，为充分利用有限的训练数据并增强模型泛化能力，对训练样本及其对应标签实施数据增强操作，具体包括：随机旋转、水平翻转、平移缩放以及随机裁剪等。最后，将数据集依据病人层面(Patient-level)按照 8:1:1 的比例划分为训练集、验证集和测试集，严格确保同一病人的所有 CT 切片仅出现在同一子集中，避免因切片级划分导致的数据泄露问题。

3.2. 实验设置及评估指标

本实验的硬件平台配置如下：中央处理器为 Intel Core i7-14650HX (主频 2200 MHz, 16 核心 24 线程)，系统内存为 16 GB，图形处理器为 NVIDIA GeForce RTX 4060 Laptop GPU (显存 8 GB)。软件环境基于 Python 3.11.7 构建，深度学习框架采用 TensorFlow 2.10.0，GPU 加速库为 CUDA 11.2。模型训练参数设置如表 1 所示。

Table 1. Model training parameter settings
表 1. 模型训练参数设置

模型训练	参数
优化器	Adam
初始学习率	0.0001
Batch Size	4
Epoch	50

同时为全面评估模型的图像分割性能，本研究采用三项定量评价指标：交并比(Intersection over Union, IoU)、Dice 相似系数(Dice Similarity Coefficient, DSC)、准确率(Accuracy, Acc)。

IoU 衡量的是预测与实际标签的重叠程度，值越大表示模型预测越准确，计算公式如下所示：

$$\text{IoU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}}。 \quad (4)$$

DSC 用于评估两个样本的相似度，值越接近于 1，表示预测与实际标签越相似。通常在分割任务中，DSC 被广泛用于衡量分割结果的准确性，计算公式如下所示：

$$\text{DSC} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}}。 \quad (5)$$

Accuracy 衡量的是模型正确分类的样本占总样本的比例，通常用于评估分类任务的整体效果，计算公式如下所示：

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}， \quad (6)$$

其中，TP 为肿瘤像素被正确预测为肿瘤的数量，TN 为非肿瘤像素被正确预测为非肿瘤的数量，FP 为非肿瘤像素被错误预测为肿瘤的数量，FN 为肿瘤像素被错误预测为非肿瘤的数量。

3.3. 对比实验与分析

为验证本文提出的 DMCAU-Net 模型的有效性，在 LiTS2017 数据集上选取 U-Net [3]、U-Net++ [10]、

TransUNet [11]作为基准模型进行对比实验，实验结果如表 2 所示。

从表 2 实验结果可以观察到，本文提出的 DMCAU-Net 在核心评价指标上均展现出显著优势。在肝脏肿瘤区域分割精度方面，IoU 和 DSC 分别达到 90.07%和 94.78%，较经典 U-Net 提升 18.73 个百分点和 11.51 个百分点，较 TransUNet 提升 4.43 个百分点和 5.86 个百分点。这一改进归因于双分支多尺度残差卷积模块对肝脏肿瘤边缘细节的增强提取能力，以及 CBAM 注意力机制对特征通道与空间权重的动态校准，有效缓解了传统方法中因固定感受野导致的特征遗漏问题。从全局性能看，DMCAU-Net 以 99.65% 的准确率先所有对比模型，表明其在高复杂度的肝脏肿瘤 CT 图像中具有更强的整体判别能力。值得注意的是，U-Net++ 虽在 IoU 上表现优于基础 U-Net，但其 DSC 显著下降，反映出密集跳连结构可能因特征冗余导致分割一致性降低。而 TransUNet 通过引入 Transformer 捕获长程依赖关系，在 DSC 取得优势，但其准确率略低于 U-Net，提示全局注意力机制可能放大背景噪声干扰。

Table 2. Comparison experimental results
表 2. 对比实验结果

Method	IoU	DSC	Accuracy
U-Net	71.34%	83.27%	98.84%
U-Net++	77.69%	73.17%	98.62%
TransUNet	85.64%	88.92%	98.03%
Ours	90.07%	94.78%	99.65%

3.4. 可视化结果与分析

为直观展示各模型的分割效果差异，本研究选取具有代表性的测试样本进行可视化对比分析。从图 6 可视化结果可以观察到：U-Net 模型在处理边界模糊的肝脏肿瘤区域时存在明显的欠分割现象，部分肿瘤边缘信息丢失严重；U-Net++ 模型虽然在整体轮廓捕获方面有所改善，但在肝脏肿瘤内部存在空洞和不连续区域，分割一致性欠佳；TransUNet 模型借助 Transformer 的全局建模能力，在大尺寸肿瘤分割中表现较好，但对小尺寸肿瘤和复杂形态病灶的检测精度仍有不足。相比之下，DMCAU-Net 在多形态肝脏肿瘤分割任务中展现出卓越性能。在边界清晰度方面，DMRCB 模块通过多尺度卷积核的并行处理，能够同时捕获肿瘤边缘的精细纹理和整体轮廓信息，使预测边界与真实标注高度吻合。在内部填充完整性方面，CBAM 注意力机制有效抑制了背景噪声干扰，使模型能够更准确地聚焦于肿瘤区域，避免了分割结果中的空洞和断裂现象。

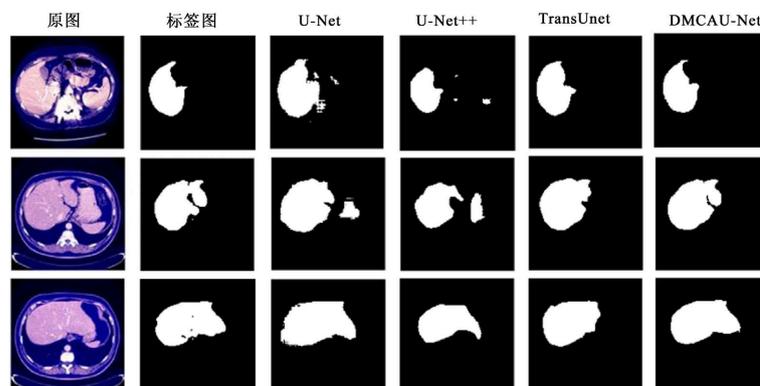


Figure 6. Visualization results of comparison models
图 6. 对比模型可视化结果

3.5. 消融实验与分析

为了验证提出的双分支多尺度残差卷积模块(DMRCB)与融合 CBAM 模块的有效性,本研究设计四组消融实验:U-Net、U-Net + CBAM、U-Net + DMRCB、完整模型(U-Net + DMRCB + CBAM),实验结果如表 3 所示。

由表 3 的消融实验结果可以看出,各模块对模型分割性能均产生了积极影响。基线模型 U-Net 在 IoU、DSC 和 Accuracy 指标上分别为 71.34%、83.27%和 98.84%,整体分割性能相对有限。在 U-Net 中引入 CBAM 注意力机制后, IoU 和 DSC 分别提升至 88.55%和 90.44%, Accuracy 提升至 99.39%,表明 CBAM 能够通过通道与空间注意力增强模型对肝脏肿瘤区域的关注能力,从而有效改善分割效果。仅引入 DMRCB 模块的 U-Net + DMRCB 模型同样取得性能提升,其 IoU 和 DSC 分别达到 86.45%和 89.76%,说明多尺度残差卷积结构有助于增强模型对不同尺度肝脏肿瘤特征的表征能力。进一步将 DMRCB 与 CBAM 模块相结合后,完整模型在各项评价指标上均取得最优结果, IoU、DSC 和 Accuracy 分别达到 90.07%、94.78%和 99.65%。上述结果表明, DMRCB 与 CBAM 模块在特征提取与特征筛选方面具有良好的互补性,其协同作用能够显著提升肝脏肿瘤分割的精度与鲁棒性。

Table 3. Ablation experimental results
表 3. 消融实验结果

Method	IoU	DSC	Accuracy
U-Net	71.34%	83.27%	98.84%
U-Net + CBAM	88.55%	90.44%	99.39%
U-Net + DMRCB	86.45%	89.76%	98.96%
U-Net + DMRCB + CBAM	90.07%	94.78%	99.65%

4. 结束语

本文针对肝脏肿瘤图像中肿瘤形态复杂、边界模糊以及多尺度特征难以有效建模等问题,提出了一种改进的 U-Net 分割模型 DMCAU-Net。该模型通过引入双分支多尺度残差卷积模块增强了对不同尺度肿瘤特征的表征能力,并在跳跃连接中融合 CBAM 双注意力机制,有效提升了浅层与深层特征的融合质量。同时,设计了结合二元交叉熵损失与 Dice 损失的混合损失函数,以进一步提高模型训练的稳定性与分割精度。

在 LiTS2017 数据集上的实验结果表明,所提出的 DMCAU-Net 在 IoU、DSC 和 Accuracy 等评价指标上均优于基线模型 U-Net 及多种改进模型,消融实验进一步验证了多尺度残差模块与注意力机制的有效性及其协同作用。实验结果充分说明,所提出的方法能够在复杂肝脏肿瘤分割任务中取得更为准确和稳定的分割效果。

尽管本文方法取得了一定效果,但仍存在一些不足,例如对大规模多中心数据的泛化能力有待进一步验证。未来工作将考虑引入更丰富的数据集及轻量化网络设计,以提升模型在实际临床应用中的适用性与推广价值。

参考文献

- [1] 美琰乐, 千越魏, 炜邓, 等. 基于电子计算机断层扫描图像的肝癌病灶自动分割方法研究进展[J]. 生物医学工程杂志, 2018, 35(3): 481-487.
- [2] 曹玉红, 徐海, 刘苏傲, 等. 基于深度学习的医学影像分割研究综述[J]. 计算机应用, 2021, 41(8): 2273-2287.

-
- [3] Ronneberger, O., Fischer, P. and Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W. and Frangi, A., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 234-241. https://doi.org/10.1007/978-3-319-24574-4_28
- [4] 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.
- [5] 李秀华, 朱水成. 一种基于改进 U-Net 的肝脏肿瘤分割方法[J]. 计算机技术与发展, 2023, 33(2): 71-76.
- [6] 莫亚霓, 陈晓婕, 张本鑫. 基于级联网络的肝脏肿瘤 CT 图像分割[J]. 电视技术, 2024, 48(1): 38-41.
- [7] Li, Z., Liu, F., Yang, W., Peng, S. and Zhou, J. (2022) A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, **33**, 6999-7019. <https://doi.org/10.1109/tnnls.2021.3084827>
- [8] Woo, S., Park, J., Lee, J. and Kweon, I.S. (2018) CBAM: Convolutional Block Attention Module. In: Ferrari, V., Hebert, M., Sminchisescu, C. and Weiss, Y., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 3-19. https://doi.org/10.1007/978-3-030-01234-2_1
- [9] Bilic, P., Christ, P., Li, H.B., *et al.* (2023) The Liver Tumor Segmentation Benchmark (Lits). *Medical Image Analysis*, **84**, Article 102680.
- [10] Zhou, Z., Rahman Siddiquee, M.M., Tajbakhsh, N. and Liang, J. (2018) Unet++: A Nested U-Net Architecture for Medical Image Segmentation. In: Stoyanov, D., *et al.*, Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 3-11. https://doi.org/10.1007/978-3-030-00889-5_1
- [11] Chen, J., Lu, Y., Yu, Q., *et al.* (2021) Transunet: Transformers Make Strong Encoders for Medical Image Segmentation. arXiv preprint arXiv:2102.04306.