

# 深度学习在肝脏及肝脏肿瘤分割中的应用进展

陈森焯<sup>1</sup> 孙梦焦<sup>2</sup> 毕晟<sup>1</sup> 李帆<sup>1</sup> 刘镭<sup>1</sup> 张力<sup>1</sup> (通讯作者)

1 承德医学院附属医院, 河北承德, 067000;

2 承德医学院 承德市中心医院, 河北承德, 067000;

**摘要:** 目的: 探讨深度学习技术在肝脏及肝脏肿瘤 CT 影像分割中的应用效果, 评估不同卷积神经网络模型的分割性能。方法: 选取 2022 年 1 月至 2023 年 12 月我院收治的肝脏肿瘤患者 150 例的 CT 影像资料, 随机分为训练集 120 例和测试集 30 例。分别采用 U-Net、3D U-Net、Attention U-Net 深度学习模型 (观察组) 和传统阈值分割方法 (对照组) 进行肝脏及肿瘤分割, 比较各组 Dice 相似系数、Jaccard 指数、Hausdorff 距离及分割时间。结果: Attention U-Net 组 Dice 系数 ( $0.92 \pm 0.03$ ) 显著高于 U-Net 组 ( $0.89 \pm 0.04$ )、3D U-Net 组 ( $0.91 \pm 0.03$ ) 及对照组 ( $0.76 \pm 0.05$ ) ( $P < 0.05$ ); Attention U-Net 组分割时间 ( $12.5 \pm 2.3$ ) s 显著短于对照组 ( $45.2 \pm 8.6$ ) s ( $P < 0.001$ )。结论: 深度学习尤其是 Attention U-Net 模型在肝脏及肝脏肿瘤分割中具有更高的精度和效率, 为临床精准诊疗提供了新的技术手段。

**关键词:** 深度学习; 肝脏肿瘤; 图像分割; U-Net; Attention 机制; 计算机辅助诊断

**DOI:** 10.69979/3029-2808.26.03.030

肝脏肿瘤的准确诊断和分割是制定合理的手术计划、准确的放疗靶区和科学评价病人长期预后的关键。在常规的诊疗方法中, 病灶的识别和描绘主要依靠影像学或医生的个人经验, 既费时又费力, 在边界判断、微小病灶识别等上容易出现主观偏差, 从而影响了诊疗方案的一致性。近年来, 随着人工智能技术的飞速发展, 基于卷积神经网络 (CNN) 的深度学习模型在医学图像分析与处理领域展现出巨大潜力与革命性影响<sup>[1]</sup>。其中, U-Net 及其一系列改进模型 (如 Attention U-Net, U-Net++ 等) 凭借其编码器-解码器结构及跳跃连接设计, 在肝脏实质与肿瘤病灶的自动分割任务中取得了显著突破, 有效提升了分割效率与客观性。然而, 面对临床实践中复杂的图像特征 (如病灶形态多样性、边界模糊性、多模态影像差异等), 不同网络架构的具体性能表现、稳定性及其临床适用场景仍需通过系统性的对比研究进行深入探讨与明确。鉴于此, 本研究旨在通过构建严格的实验框架, 对比分析包括经典 U-Net、注意力机制增强模型在内的多种前沿深度学习分割方法, 并将其与传统半自动分割技术的效果进行量化比较, 以综合评估各方法的精度、鲁棒性与效率, 最终为临床实践筛选并提供一套高效、精准且可推广的肝脏及肝脏肿瘤智能化分割解决方案<sup>[2]</sup>。

## 1 资料与方法

### 1.1 一般资料

选取 2022 年 1 月至 2023 年 12 月我院放射科收治的肝脏肿瘤患者 150 例。纳入标准: (1) 经病理或临床证实为原发性肝癌或转移性肝肿瘤; (2) 行腹部增强 CT 检查, 层厚  $\leq 5\text{mm}$ ; (3) 图像质量清晰, 无严重伪影; (4) 临床资料完整。排除标准: (1) 合并严重肝硬化或弥漫性肝病; (2) CT 图像上肿瘤边界不清或直径  $< 1\text{cm}$ ; (3) 既往有肝脏手术史导致解剖结构严重变形。将 150 例患者 CT 影像按 8:2 比例随机分为训练集 120 例和测试集 30 例。本文将影像数据样本按照一定的比例分成了训练集和测试集。为了避免过度拟合, 我们将使用一个训练集中来对该模型进行参数学习和优化。而在整个过程中, 测试集并没有介入到模型的所有学习过程中, 只是为了客观地、独立地评价所得到的模型的性能, 从而真正地体现出它的推广性能和临床应用价值<sup>[7]</sup>。本研究方案已通过本院伦理委员会审查并获批准, 所有纳入患者均已充分知情并签署书面知情同意书

### 1.2 方法

对照组采用传统图像处理方法, 具体操作如下: 以腹部增强 CT 序列为输入, 首先使用基于灰度阈值的初始分割算法初步区分肝脏组织与背景区域; 随后, 对初步分割结果应用区域生长法, 通过设定种子点和邻域相似性准则进一步细化肝脏轮廓并识别疑似肿瘤区域<sup>[3]</sup>。整个分割过程由 2 名具有 5 年以上腹部影像诊断经验的放射科医师独立完成。医师需根据每例影像的具体灰度分布特征, 手动调整阈值参数与区域生长停止准则, 以

优化分割结果。分割完成后，两名医师的结果通过协商达成一致，作为传统方法的分割金标准，用于后续与深度学习模型的性能对比分析。

观察组采用深度学习模型：

(1)U-Net 模型：该模型采用经典的U型对称编码器-解码器架构。编码器路径通过连续卷积与池化操作实现下采样，逐步提取图像的深层语义特征；解码器路径则通过上采样与反卷积操作恢复空间分辨率，逐步重建分割细节<sup>[4]</sup>。两条路径间通过跳跃连接将编码器各阶段的特征图与解码器对应层融合，有效传递浅层的空间信息与深层的语义信息，缓解了因下采样导致的空间细节丢失问题。该模型结构简洁且高效，特别适用于对二维医学影像（如CT、MRI切片）进行像素级语义分割，在肝脏区域提取等任务中表现出良好的基础性能。

(2)3D U-Net 模型：该模型是经典U-Net在三维医学影像分割领域的直接扩展。其核心改进在于将模型中所有的二维卷积操作替换为三维卷积核，从而能够直接输入并处理由连续断层图像（如CT或MRI序列）构成的三维体数据。这一设计使得模型能够同时捕获并利用切片内部特征以及相邻切片之间的空间关联信息，有效提升了模型对器官与病灶三维形态及解剖结构连续性的建模能力。通过保留并沿编码器-解码器路径传递三维上下文信息，3D U-Net显著增强了分割结果的体积一致性和空间平滑性，尤其适用于对肝脏、肿瘤等具有复杂三维结构的整体分割任务，在精度上较二维模型通常具有更优表现<sup>[5]</sup>。

(3)Attention U-Net 模型：该模型在经典U-Net的跳跃连接结构中创新性地引入注意力机制（Attention Gate）。通过该注意力门控模块，模型在融合编码器与解码器对应层特征时，能够自动学习并生成空间注意力权重图。这一机制实现了特征的自适应筛选：它可有效抑制与分割目标（如肝脏或肿瘤）无关的背景或非目标组织的特征响应，同时显著增强对病灶边界、微小区域等关键信息的关注与提取。这使得模型在应对目标与周围组织对比度低、边界模糊或存在噪声干扰的复杂影

像时，具备更强的特征聚焦与分辨能力，从而在肝脏及肿瘤分割任务中实现了更高的边界精度与整体分割准确率<sup>[6]</sup>。

所有深度学习模型基于PyTorch框架构建，输入图像经预处理（归一化、重采样至256×256像素）。训练参数：batch size=4，学习率初始值0.001，采用Adam优化器，损失函数为Dice Loss与交叉熵损失函数组合。

### 1.3 观察指标

由3名资深放射科医师独立盲法评估分割结果，取平均值作为最终评价指标。

(1)分割精度指标：采用Dice相似系数（DSC）、Jaccard指数（JI）及Hausdorff距离（HD）评估分割准确性。DSC值越接近1表示分割效果越好；HD值越小表示边界匹配度越高。

(2)分割效率指标：记录单例患者CT序列（平均120层）的分割处理时间（秒）。

(3)临床适用性评估：计算肿瘤体积测量误差率（与手工金标准比较）及医师满意度评分（Likert 5级评分法）。

### 1.4 统计学方法

采用SPSS 22.0统计学软件进行数据分析。计量资料以（ $\bar{x} \pm s$ ）表示，多组间比较采用单因素方差分析（One-way ANOVA），两两比较采用LSD-t检验；计数资料以例（%）表示，组间比较采用 $\chi^2$ 检验。P<0.05为差异有统计学意义。

## 2 结果

### 2.1 各组分割精度比较

测试集30例患者共含肝脏病灶45个。观察组各模型DSC、JI均显著高于对照组，HD显著低于对照组（P<0.05）。其中Attention U-Net组DSC（0.92±0.03）显著高于U-Net组（0.89±0.04）和3D U-Net组（0.91±0.03）（P<0.05）。见表1。

表1 各组肝脏肿瘤分割精度指标比较（ $\bar{x} \pm s$ ）

组别	例数	DSC	JI	HD (mm)
U-Net 组	30	0.89±0.04	0.80±0.05	8.42±1.23
3D U-Net 组	30	0.91±0.03*	0.83±0.04*	6.85±1.02*
Attention U-Net 组	30	0.92±0.03*#	0.85±0.04*#	5.62±0.89*#
对照组	30	0.76±0.05	0.61±0.06	15.36±2.14

注：与对照组比较，\*P<0.05；与U-Net组比较，#P<0.05

### 2.2 各组分割效率及临床适用性比较

观察组各模型分割时间均显著短于对照组（P<0.01），其中Attention U-Net组单例处理时间（12.5±

2.3）s，较对照组（45.2±8.6）s缩短72.3%。体积测量误差率方面，Attention U-Net组（3.2±1.1）%显著低于对照组（12.8±3.5）%（P<0.001）。医师满意度

评分观察组均显著高于对照组 ( $P < 0.05$ )。见表 2。

表 2 各组分割效率及临床适用性比较 ( $\bar{x} \pm s$ )

组别	分割时间 (s)	体积误差率 (%)	医师满意度 (分)
U-Net 组	15.3 ± 3.1*	5.8 ± 1.6*	4.1 ± 0.6*
3D U-Net 组	18.6 ± 4.2*	4.5 ± 1.3*	4.3 ± 0.5*
Attention U-Net 组	12.5 ± 2.3*#	3.2 ± 1.1*#	4.6 ± 0.4*#
对照组	45.2 ± 8.6	12.8 ± 3.5	3.2 ± 0.8

注: 与对照组比较, \* $P < 0.05$ ; 与 U-Net 组比较, # $P < 0.05$

### 2.3 典型病例分析

本研究中选取了两例具有代表性的病例进行深入分析, 以直观展示先进分割模型的性能优势。

病例一为一名 56 岁男性原发性肝细胞癌患者。其腹部增强 CT 图像显示肝右叶后段有一孤立性占位性病变, 直径约 3.2cm。在单期相图像上, 病灶与周围肝实质的灰度值部分接近, 边界存在模糊区域, 这给传统阈值分割或区域生长等方法带来了挑战, 其分割结果 Dice 相似系数 (DSC) 仅为 0.74, 肿瘤轮廓欠清晰。相比之下, 基于注意力机制的 Attention U-Net 模型有效克服了此困难。其注意力模块能够自适应地聚焦于肿瘤边缘的细微特征, 抑制背景干扰, 实现了高精度分割, DSC 值达到 0.94, 与放射科医师的勾画金标准高度吻合, 为后续的精准确体积计算与手术规划提供了可靠依据。

病例二为一名多发肝转移瘤患者。影像显示肝脏内存在多个直径小于 2cm 的散在小病灶, 这类微小病灶的漏诊是临床诊断中的常见难点。在该病例中, 基础 U-Net 模型由于感受野和特征提取能力的局限, 对部分低对比度小病灶存在漏检, 整体病灶漏诊率达 20.0%。而 Attention U-Net 模型则展现出了更强的微小病灶检测能力。其多尺度注意力机制能够在特征提取过程中强化病灶区域的特征响应, 即使对于 CT 值不典型的微小转移灶也能进行有效识别与定位, 将该病例的漏诊率显著降低至 6.7%。这表明, 融合注意力机制的深度学习模型在提升肝脏肿瘤, 尤其是早期或微小病灶的识别敏感度方面, 具有重要的临床应用价值。

### 3 讨论

我们的前期研究表明, 基于深度学习的肝脏和肿瘤分割算法比传统的阈值分割算法有更好的效果。该方法的优势在于: 1) 利用多层卷积自动提取图像多层次特征, 克服传统方法中人工设计特征的不足, 尤其是对灰度不均的肿瘤区域有较强的识别能力。其次, 利用三维卷积核捕捉层间空间的连续性, 有效地解决了传统二维

方法分割层间不连续性的难题, 从而有效地保护了肝脏的解剖结构<sup>[8]</sup>。该机制利用门控信号抑制背景区响应, 提高目标区域特征权重, 显著提高肿瘤边界模糊和低对比度病灶分割的准确性。

从临床转化角度分析, 深度学习分割技术可显著提高诊疗效率。本研究中 Attention U-Net 单例处理时间仅 12.5 秒, 较传统方法缩短 72%, 且体积测量误差控制在 3% 以内, 满足临床放疗计划制定对精度的要求<sup>[9]</sup>。

### 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.
- [2] 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.
- [3] 朱风叶, 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.
- [4] 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.
- [5] 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.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] 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.