

基于深度学习的肾上腺CT图像分割研究综述

房子洋¹, 王津梁¹, 肖裴垚¹, 李轶凯¹, 张治^{1,2}

(1. 上海理工大学健康科学与工程学院, 上海 200093; 2. 上海交通大学医学院附属第一人民医院 心内科, 上海 200080)

摘要: 肾上腺是微小内分泌器官, 在控制血压、心率及其他由交感神经系统调节的活动中起重要作用。肾上腺CT图像分割是肾上腺相关疾病智能诊断中的关键技术之一。近年来, 深度学习方法在肾上腺CT图像自动分割中发挥了重要作用, 推动了这一领域的持续进步。通过系统总结现有研究中常用的图像预处理策略、卷积神经网络与Transformer等深度学习模型, 梳理了基于深度学习的肾上腺分割在肾上腺相关疾病诊断中的研究现状。此外, 探讨了肾上腺CT图像分割在数据集建设、模型优化与多任务联合分析等方面的未来发展方向, 旨在为相关研究与临床应用提供参考。

关键词: CT图像; 肾上腺; 深度学习; 图像分割; 卷积神经网络

DOI: 10.11907/rjdk.251571

中图分类号: TP391.41

文献标识码: A

文章编号: 1672-7800(2026)004-0213-08

扫描二维码阅读全文:



A Review of Deep Learning-Based Adrenal CT Image Segmentation Research

FANG Ziyang¹, WANG Jinliang¹, XIAO Peiyao¹, LI Yikai¹, ZHANG Zhi^{1,2}

(1. School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;

2. Department of Cardiology, Shanghai General Hospital, Shanghai Jiao Tong University School of Medicine, Shanghai 200080, China)

Abstract: Adrenal glands are tiny endocrine organs that play an important role in controlling blood pressure, heart rate, and other activities regulated by the sympathetic nervous system, and adrenal CT image segmentation is one of the key technologies in the intelligent diagnosis of adrenal-related diseases. In recent years, deep learning methods have played an important role in the automatic segmentation of adrenal CT images, which has driven the continuous progress in this field. In this paper, we systematically summarize the image preprocessing strategies, convolutional neural network and Transformer, and other deep learning models commonly used in existing research, and sort out the current research status of adrenal segmentation based on deep learning in the diagnosis of adrenal-related diseases. Finally, the future development direction of adrenal CT image segmentation in terms of dataset construction, model optimization and multi-task joint analysis is discussed, aiming to provide references for related research and clinical applications.

Key Words: CT image; adrenal gland; deep learning; image segmentation; convolutional neural network

0 引言

肾上腺是一个微小的内分泌器官, 附着在我们身体每个肾脏的顶部。它在控制血压、心率和其他由交感神经系统调节的活动中起着重要作用^[1]。右肾上腺通常呈锥体状, 位于膈肌后部和前内侧下腔静脉之间, 而左肾上腺则

呈新月体形态, 位于膈肌、胃、胰腺和左肾之间^[2]。在临床实践中, 肾上腺相关疾病的发病率呈逐年上升趋势, 其表现形式多样, 包括原发性醛固酮增多症(PA)、嗜铬细胞瘤、库欣综合征和肾上腺肿瘤等。以原发性醛固酮增多症(PA)为例, 它是继发性高血压的重要病因之一^[3]。其发病机制是由肾上腺过度分泌醛固酮, 导致水钠潴留和血压升高。PA患者主要表现为肾上腺源性高血压, 因此早期准

收稿日期: 2025-08-20

基金项目: 国家自然科学基金项目(82270536)

作者简介: 房子洋(2001-), 男, 上海理工大学健康科学与工程学院硕士研究生, 研究方向为医学图像处理; 王津梁(1998-), 男, 上海理工大学健康科学与工程学院硕士研究生, 研究方向为心音智能听诊; 肖裴垚(2001-), 男, 上海理工大学健康科学与工程学院硕士研究生, 研究方向为心音智能听诊; 李轶凯(2001-), 男, 上海理工大学健康科学与工程学院硕士研究生, 研究方向为人工智能在肺音检测中的应用; 张治(1978-), 男, 博士, 上海交通大学医学院附属第一人民医院心内科主任医师、硕士生导师, 研究方向为无线听诊器和人工智能诊断、医学图像处理、难治性高血压的器械和药物治疗。本文通讯作者: 张治。

确诊断对制定有效治疗方案至关重要^[4]。PA 的主要病因包括单侧肾上腺腺瘤(醛固酮瘤)和双侧肾上腺增生等,其中明确病变性质及定位是判断是否适合手术治疗的关键步骤。

计算机断层扫描(CT)因其具有出色的空间分辨率、广泛的可用性以及表征病变密度和增强特征的能力,是临床上用于诊断肾上腺疾病的重要影像学检查手段,可为 PA 的分类和定位诊断提供可靠依据^[5]。然而,肾上腺作为一种腹膜后的小器官,其体积小、位置深且形态变异大,占腹部 CT 切片的比例不到 1%。传统方法依赖放射科医生进行判读,存在经验依赖性强、主观性高和重复性较差等问题,这给肾上腺相关疾病的影像诊断带来了困难。

近年来,深度学习技术(DL)的飞速发展医学图像分析带来了革命性变革,特别是在器官自动分割领域,其强大的特征提取与判别能力得到了充分展现^[6-9]。肾上腺 CT 图像分割旨在通过自动化技术对肾上腺区域进行精确的定位与轮廓勾画,并有效地将肾上腺从周围正常组织中分离出来,以提取其形态、结构以及大小等关键特征。因此,精准的肾上腺 CT 图像分割,能够助力临床医生实现早期、准确的疾病诊断与分型,从而改善相关肾上腺疾病的预后。

本文旨在系统总结近年来基于深度学习的肾上腺 CT 图像分割研究进展。首先,介绍肾上腺疾病诊断的需求及 CT 影像的重要性,讨论深度学习在其中的应用价值;然后,综述深度学习在肾上腺 CT 图像的分割流程,包括 CT 数据集与图像预处理、主流深度学习方法及其性能评估等;最后,展望未来研究挑战与方向。通过对现有文献的梳理,希望为研究者和临床人士提供全面参考,助力肾上腺相关疾病的智能诊断技术发展。

1 肾上腺 CT 数据集

尽管肾上腺在临床 CT 检查中较为常见,但由于其解剖结构小、形态复杂且位置相对隐匿,目前公开且标注完

备的肾上腺 CT 分割数据集依然相对稀缺。近年来,随着小器官自动分割技术的发展,一些用于肾上腺分割的高质量数据集逐渐被提出,成为算法评估和模型训练的重要支撑。Medical Segmentation Decathlon(MSD)中的 Task08 即为专门面向肾上腺的分割任务,包含 63 例腹部增强 CT 数据,均由放射科医生手工标注在左右肾上腺区域^[10]。AMOS (Abdominal Multi-Organ Segmentation)数据集提供 200 例腹部增强 CT,支持多器官联合分割,其中也包括左、右肾上腺标签^[11]。Yang 等^[12]针对肾上腺这一小体积器官,提出并公开了一个新型 3D 数据集 ALAN,该数据集不仅包含了结构化的体素数据,还附带临床诊断标签,为小器官分析提供了重要的基准资源。ALAN 数据集来源于 792 位患者的腹部 CT 检查,每位患者包含左右肾上腺,共计 1 584 个 3D 肾上腺体积($128 \times 128 \times 128$, spacing 为 1 mm^3)。每个肾上腺都附带一个由临床专家标注的二分类诊断标签(正常/异常),并由两位临床医生和一位内分泌高级专家达成共识,确保标签的可靠性。此外,AbdomenCT-1K 子集 DGS 也被用于肾上腺分割测试,其将目标区域裁剪为 $128 \times 128 \times 128$ 的标准立方体并重采样处理,为模型提供更集中、规范化的输入^[13]。

在私有数据方面,有研究者自建了临床数据集 Ad-Seg,该数据集涵盖了 65 例患者的近 2 万张 CT 切片,并对左右肾上腺进行了精细标注,充分反映了实际临床数据中肾上腺目标稀疏、边界模糊等挑战^[14]。总体而言,肾上腺相关的公开数据集在当前的研究领域中显得极为稀缺,仅有为数不多的几个数据集可供使用,并且这些数据集所包含的样本数量也相对较少,难以满足大规模研究的需要。由于公开数据的匮乏,大多数涉及肾上腺分割的研究工作不得不依赖于相关科研机构或医疗机构自行进行数据的收集和标注,从而构建仅供内部使用的私有数据集。尽管已有研究探索了肾上腺的自动分割,但由于公开可用的肾上腺数据集稀缺,该领域的研究仍处于起步阶段。因此,目前亟需建立更多公开数据集,以进一步推动肾上腺分割技术的发展。常用的肾上腺 CT 数据集如表 1 所示。

Table 1 Common adrenal CT datasets

表 1 常见肾上腺 CT 数据集

数据集	发布年份	类型	来源	数量	标注内容	主要优势	主要局限性
MSD Task08 ^[10]	2019	公共	Dresden TU	63 例	左右肾上腺分割	标注质量高,作为国际通用 benchmark;利于方法间横向比较	样本量有限;采集协议较单一
AMOS2022 ^[11]	2022	公共	AMOS 挑战	200 例	15 个腹部器官(含肾上腺)	多中心、多厂家采集,增强模型泛化性	肾上腺 CT 样本稀少、未做细粒度标注
ALAN ^[12]	2022	公共	上海交大+EPFL	1 584 例	3D 分割 + 诊断标签	样本量大,附带诊断标签,利于分割+分类联合研究	数据主要来源于少数医院,存在中心偏倚
AbdomenCT-1K ^[13]	2021	公共	多中心	100 例	3D 肾上腺分割	统一预处理,适配 3D 网络	样本量仍偏少;对肾上腺未重点优化
Ad-Seg ^[14]	2023	私有	私有临床数据	65 例	左右肾上腺分割	更贴近真实临床场景	无法公开,限制可重复性与可比性

2 图像预处理

在腹部CT图像中,肾上腺的占比极小,而背景部分的比例较大,这为肾上腺区域的特征提取带来了较大挑战。为减轻背景噪声的负面影响,并确保肾上腺分割的准确性,在将数据输入深度学习模型之前,通常需要进行一系列图像预处理操作,如数据清洗、数据筛选、HU值截断、数据裁剪、归一化和标准化等。

首先,进行数据清洗和筛选,这是数据预处理的首要环节。由于肾上腺体积较小(大约4~6 cm长,0.5~1 cm厚),建议使用1.5 mm以下的薄层扫描进行CT图像采集。其次,待数据采集完成后,应由多名经验丰富的医生反复检查并校对,确保数据质量。经过多次清洗和校对,最终建立适用于理论与临床实践相结合的肾上腺CT图像分割数据集。在此过程中,需要排除数据标签错误、不标准或采集区域不准确的样本,以确保数据集的准确性和一致性。

在同一CT图像中,相同的组织通常具有相似的外观特征,其亮度值范围也相对一致。然而,由于CT图像的背景通常较暗,亮度值较低,而腹部CT图像中器官的CT值跨度较大,通常会达到几千个单位。若不进行处理,背景区域的噪声影响会显著增加,相对于目标区域,非目标区域的噪声会对特征挖掘造成较大干扰,导致肾上腺分割困难。此外,肾上腺与其他腹部器官(如胰腺、肾脏、肺部等)在CT值上的重叠使得模型容易受到噪声影响,进而影响性能。因此,在进行肾上腺分割之前,必须通过调整CT窗宽窗位,去除肾脏、胰腺和肺部等不相关区域,从而增强肾上腺区域的对比度。为了更准确地分割肾上腺,同时保留丰富的灰度信息,我们需要对CT值进行HU值截断操作。通过这种操作,可以有效抑制不相关区域的噪声,同时增强目标区域的对比度。表2展示了调整窗宽和窗位的推荐值及其原理。表2中窗宽/窗位推荐值参考常用腹部软组织窗设置、相关放射学指南及文献[15-16](软组织窗:WW≈300-400 HU,WL≈40-60 HU),以增强肾上腺与周围软组织的对比,提高小目标可检出率。

Table 2 Recommended values for CT window width and window position and their rationale

表2 CT窗宽和窗位的推荐值及其原理			
参数	推荐值	显示范围(HU)	原理与优势
窗宽(WW)	300~400 HU	以窗位为中心,上下各150~200 HU	覆盖肾上腺平扫CT,增强对比度
		窗宽300 HU、窗位50 HU时,显示区域,灰度显示适中,与肝脏(40~100~200 HU、脂肪形成层次对比	确保肾上腺位于窗宽中心区
窗位(WL)	40~60 HU	50 HU	80 HU)

在医学图像分割任务中,归一化和标准化是提升模型训练稳定性和泛化能力的重要预处理步骤。由于CT图像中不同病例、不同扫描设备间的灰度分布存在较大差异,

尤其在小体积器官如肾上腺的分割中更为敏感。因此,通常先对图像进行HU值截断,以聚焦软组织密度信息,去除高密度骨组织与低密度空气的干扰。随后,将截断后的灰度值进行线性归一化至[0,1]区间,使模型输入具有统一的动态范围,从而减少训练过程中的梯度波动。此外,对于跨患者或多中心数据集,还可进一步执行零均值单位方差的标准化的(z-score standardization),即对每张图像或整个数据集按通道减去均值再除以标准差,以消除个体间灰度分布差异。合理的归一化与标准化策略,有助于提升模型对边界模糊和小目标结构的敏感性,是医学图像建模中不可或缺的预处理环节。肾上腺CT分割的基本流程如图1所示。




Fig. 1 Adrenal CT segmentation process
图1 肾上腺CT分割流程

3 基于深度学习的肾上腺CT图像分割

3.1 传统方法

在过去的研究中,对于肾上腺及其肿瘤的图像分割任务,主要依赖于数学模型与机器学习算法实现。传统的图像分割方法如水平集法^[17]、阈值分割法^[18]、区域生长法^[19]和边缘检测法^[20]等在医学图像中被广泛应用,但这些方法在面对肾上腺这种小体积、边界模糊的器官时,效果有限。

Koyuncu等^[21]提出了一种肾上腺肿瘤分割(ATUS)管道。ATUS融合了多种图像处理方法,包括对比度受限的自适应直方图均衡化、基于二叉树分解的分割与合并、均值漂移分割、大灰度消除器和区域生长等。这些方法通过不同的技术手段综合提升了分割精度。Barstuğan等^[22]则提出了一种基于多种传统方法组合的图像处理方法,以实现肾上腺肿瘤的分割。该方法结合了主动轮廓、适应性阈值分割、对比度限制自适应直方图均衡、图像侵蚀和区域增长等方法。Zhang等^[23]根据相邻CT图像中肾上腺之间的形状渐进变化关系,构建了一个形状渐进变化模型,并使用三维拉普拉斯算子改善了肾上腺的灰度信息。

尽管传统分割方法在一定程度上解决了肾上腺图像分割的挑战,但它们在肾上腺这类小体积、边界模糊的器官上往往依赖于经验参数、手工特征与局部启发式规则,导致对噪声、采集差异与病理变异敏感且难以推广。与之

不同,基于深度学习的方法,通过端到端的数据驱动训练能够自动学习多尺度、多层次的图像特征。其中,局部卷积层捕获边界与纹理信息,深层语义特征刻画形态与上下文关系,级联/注意力机制与定位网络可增强对稀疏小目标的定位能力,从而在鲁棒性、准确性与自动化程度上都显著优于传统方法。上述优势使得深度学习成为目前肾上腺分割领域的主流解决方案。

3.2 深度学习分割方法

3.2.1 基于卷积神经网络的肾上腺分割研究

肾上腺位于腹膜后,其体积小、形态多变且易与周围器官黏连,导致图像分割具有较大挑战^[23-26]。近年来,深度学习方法在医学影像分析领域展现出强大潜力。其中,卷积神经网络(Convolutional Neural Networks, CNN)凭借其强大的特征学习能力,为肾上腺自动分割提供了突破性解决方案。CNN模型能够通过层级化卷积操作自动提取图像的深层语义特征,显著提升了分割精度与效率,有效

降低了人工勾画的依赖性,从而为临床提供可靠的自动化工具支撑。常用的卷积神经网络(CNN)结构包括2D和3D版本的U-Net及其变体,广泛应用于医学图像分割^[27]。U-Net网络架构是由Ronneberger等^[28]于2015年提出的,采用独特的编码器-解码器(Encoder-Decoder)对称结构,具体包含:编码器通过下采样路径逐步压缩空间维度并提取高层语义特征;解码器则通过上采样路径恢复分辨率并输出分割掩膜。其核心创新在于引入跳跃连接(Skip Connections),通过跨层融合浅层高分辨率特征(富含空间细节)与深层抽象特征(蕴含语义信息),解决了在小目标器官定位精度与上下文感知之间取得平衡的难题。为了充分利用CT数据的三维空间信息,提出了3D U-Net,该方法通过将二维卷积扩展为三维卷积,能够更全面地捕获空间上下文信息,从而在体积结构分割精度上取得了显著提升^[29-30]。3D U-Net网络结构图如图2所示。




Fig. 2 3D U-Net network structure diagram

图2 3D U-Net网络结构图

多项实证研究验证了U-Net系列模型在肾上腺分割中的有效性。陈元翀等^[31]基于3D U-Net构建分割模型,使用520例正常肾上腺的标注CT数据进行模型训练后,测试结果显示左侧与右侧肾上腺Dice系数分别高达0.942和0.937,展现出了优异的性能。Kim等^[32]开发了基于U-Net的3D分割模型,对308例对比增强腹部CT进行训练,测试结果显示左、右腺Dice约为0.700 9,正常组体积分割ICC $\geq$ 0.89,并通过测量其体积并结合体格参数,进而构建分类模型来鉴别肾上腺增生。Meng等^[33]最新研究采用nnU-Net(一种自动配置的3D U-Net),使用1 301例无增强CT和2 000例正常对照进行训练测试。在测试集中,左侧腺Dice $\approx$ 0.899,右侧腺Dice $\approx$ 0.904,说明3D nnU-Net在大规模数据上能取得近似0.9的精度。Chen等^[34]提出了一种基

于3D V-Net的肾上腺CT图像分割与分类模型,用于肾上腺病变的自动识别与定性分析。该研究基于1 086例腹部增强CT影像建立训练集,通过对肾上腺病变的自动分割,实现了正常与异常肾上腺的二分类。模型在测试集上的Dice相似系数达0.900(四分位范围:0.810~0.965),显示出了优异的分割性能。Bolocan等^[35]采用多相位CT数据对U-Net、SegNet和轻量级NablaNet三种网络进行对比。在868例对比增强CT扫描的测试集中,U-Net取得了最佳分割性能(右腺Dice $\approx$ 0.630 $\pm$ 0.05,左腺Dice $\approx$ 0.660 $\pm$ 0.06),显著优于SegNet(右0.320、左0.335)和NablaNet。这一结果表明,U-Net架构在肾上腺这一小结构分割任务中具有较高的鲁棒性。

在U-Net框架取得显著进展的基础上,研究者进一步

探索了多级级联与注意力机制的引入,以提升分割精度与边界细节。Luo 等^[36]提出了一种两阶段级联网络:第一阶段的定位网络定位候选区域;第二阶段的 Small-organNet 网络结合边界注意力损失进行精细分割。该方法在实验中优于已有深度学习方法,并表现出更少的参数量和更低的计算开销。Zhao 等^[37]提出了一种使用两个级联步骤(定位和分割)在有限的训练数据下进行小器官分割的自动方法。首先,通过图像配准技术确定感兴趣的区域;其次,在分割阶段引入了知识辅助的卷积神经网络。这种方法有效提升了分割的精度,尤其在训练数据有限的情况下表现出显著优势。Robinson-Weiss 等^[38]采用了两阶段分割加分类管道方法,在 274 例开发数据上测试时,分别在正常肾上腺和含病变肾上腺上获得了中位 Dice 0.80 和 0.84 的分割结果。这些结果与放射科医师的标注结果之间不存在显著差异。此外,李旻哲^[39]提出了一种基于多尺度 3D U-Net 的方法,并结合集成学习,通过调整 CT 体素大小,成功实现了平均精度 0.663 的提升,充分体现了多尺度建模与模型融合的潜力。

3.2.2 基于 Transformer 的肾上腺分割研究

尽管卷积神经网络(CNN)在肾上腺图像分割中取得了显著进展,但其感受野有限,难以捕捉远距离依赖信息,限制了对复杂结构的建模能力。为克服这一问题,近年来研究者将 Transformer 模型引入医学图像分割任务,借助其全局自注意力机制增强对微小目标器官的识别能力。

早期研究中,Bi 等^[40]提出了一种使用全卷积网络(FCN)和多尺度集成的自动化方法来检测低对比度 CT 扫描的肾上腺病变。该方法以分层方式整合了深层语义信息和浅层外观信息,并实现了图像范围内的位置和语义编码。通过结合 CNN 与随机游走(RW)方法进行肾上腺肿

瘤分割,取得了 F1-score 为 0.729 的结果。随后,Alimu 等^[41]提出了基于 Transformer 的三阶段肾上腺肿瘤分割与诊断网络,尽管其 Dice 系数仅为 0.690,但在所提出模型的帮助下,临床医生在区分乏脂性肾上腺腺瘤(FAT)方面达到了 0.925 的准确率,而仅凭自身判断的准确率为 0.806($P < 0.05$)。Wang 等^[42]进一步提出一种编码器-Transformer-解码器结构的 3D 网络,在 182 例肾上腺转移瘤 CT 数据集上实现了 0.858 的平均 Dice 系数,验证了 Transformer 在建模远程依赖关系方面的优势,尤其适合处理微小器官的复杂形态结构。

Fayemiwo 等^[43]提出一种集成式深度学习肾上腺分割流程,结合 CLAHE 对比度增强、关键切片筛选、测试时增强(TTA)与非连接区域剔除等策略,在 AMOS 和 MICCAI 两个数据集上显著提升了分割精度,平均 Dice 提升超过 0.1,部分模型可达 0.44,同时显著减少了假阳性结果。这表明,Transformer 与优化流程的结合,为微小结构分割提供了具有临床应用前景的解决方案。此外,混合架构如 TransUNet(将 UNet 与 Transformer 融合)在其他腹部器官分割中表现优异,已被逐步引入肾上腺研究中^[44]。Transformer 及其衍生结构为肾上腺 CT 图像分割提供了新的研究思路,尤其在捕捉跨通道和跨空间层级的信息方面表现出良好潜力。未来有望通过 3D 注意力机制和多模态融合等方式,进一步提升精度与泛化能力。表 3 总结了上述研究者在肾上腺分割领域的具体工作细节。

3.2.3 新型网络结构在肾上腺 CT 分割中的探索

Li 等^[45]提出了 MCNet 分割模型,这是一种专为肾上腺 CT 图像分割设计的创新型深度学习网络架构,旨在解决分割过程中面临的小体积、边界模糊以及与周围组织相似等挑战。MCNet 网络结构图如图 3 所示。

Table 3 Summary of adrenal segmentation methods
表 3 肾上腺分割方法汇总

作者	研究目的	模型	训练样本量	Dice 系数
陈元翀等 ^[31]	自动肾上腺分割及测量	3D U-Net	520 例肾上腺正常腹部 CT	左 0.942, 右 0.937
Kim 等 ^[32]	开发基于 U-Net 的 3D 分割模型进行肾上腺分割	3D U-Net	308 例增强腹部 CT	左右约为 0.700 9
Meng 等 ^[33]	采用 nnU-Net 进行大规模数据集肾上腺分割	nnU-Net	1 301 例无增强 CT, 2 000 例正常对照	左 0.899 右 0.904
Chen 等 ^[34]	基于分割结果的肾上腺分类	3D V-Net	1 086 例含病变肾上腺 CT	0.900
Bolocan 等 ^[35]	比较 U-Net、SegNet、NablaNet 三种网络的性能	U-Net, SegNet, NablaNet	868 例对比增强 CT	U-Net 最佳, 左 0.660, 右 0.630
Luo 等 ^[36]	提出两阶段级联网络进行肾上腺分割	两阶段级联网络(Small-organNet) /		/
Zhao 等 ^[37]	两个级联步骤(定位和分割)在有限的训练数据下 下进行小器官分割	Knowledge-Aided CNN	/	/
Robinson-Weiss 等 ^[38]	分割正常及肾上腺肿块肾上腺	两阶段 CNN	开发集 274 例, 测试集 991 例	正常 0.80, 肿瘤 0.84
李旻哲 ^[39]	多尺度 3D U-Net 肾上腺分割	多尺度 3D U-Net	腹部 CT 训练集(量级未详)	0.663
Bi 等 ^[40]	在低对比度 CT 图像上检测肾上腺病变	全卷积网络(FCN)和多尺度集成	/	0.729
Alimu 等 ^[41]	三阶段肾上腺肿瘤分割与诊断网络	Transformer	训练集 270 例、测试集 60 例和回顾性 试验集 45 例	0.690
Wang 等 ^[42]	肾上腺肿瘤体积分割	编码 Transformer-解码器	182 例肾上腺转移瘤	0.858
Fayemiwo 等 ^[43]	从 CT 图像中准确分割肾上腺	混合后处理技术与深度学习集成	/	提升超过 0.1




Fig. 3 MCNet network structure diagram

图3 MCNet 网络结构图

MCNet 分割模型由多级上下文聚合 MCA 模块和多级上下文引导 MCG 模块组成。其中, MCA 模块通过多分支的膨胀卷积层有效捕捉了多尺度信息, 能够处理肾上腺形态的变化; 而 MCG 模块则通过在解码阶段重建跳跃连接, 充分利用不同分辨率的特征信息, 以减少背景噪声干扰, 从而提高分割精度。MCNet 通过灵活的上下文聚合和引导策略, 增强了对小体积器官的特征提取能力, 特别是在肾上腺这种边界模糊、尺寸不一的器官分割任务中, 展现了出色的性能。研究者在 Ad-Seg 和 DGS 数据集上, 针对其他先进的代表性分割模型开展了对比实验。实验结果表明, MCNet 在 Ad-Seg 和 DGS 数据集上的 Dice 系数分别为 0.713 4 和 0.752 9, 显著优于其他最先进的分割方法。MCNet 与其他代表性分割算法对比情况如表 4 所示。该模型不仅在精度上取得了显著突破, 也为小器官(尤其是肾上腺)的精细分割提供了新的研究方向。

近年来, 涌现出一批专为小体积的器官(包括肾上腺)设计的先进分割方法, 这为该领域带来了新的活力。Lyu 等^[46]在 2024 年 MICCAI 会议上提出了 MetaUNETR 模型, 该模型对 token-mixer 的设计思路进行了重新考量, 并创新性地引入 TriCruci 模块。在 BTCV、AMOS 和 AbdomenCT-1K 等多器官分割基准数据集上的实验结果表明, 该模型不仅参数量更为精简, 其性能还能与主流模型持平甚至实现超越, 充分展现了轻量化架构与高效特征建模的发展潜力。Pang 等^[47]在 2024 年 MICCAI 会议上提出的 ASA 模型则从解剖一致性与子体积空间关系建模出发, 通过引入解剖先验和细粒度外观特征约束, 显著改善了小器官的定位与边界恢复。与此同时, Chen 等^[44]在 Medical Image Analysis (2024) 中系统性探讨了 Transformer 与 U-Net 的融合, 进一步证明了全局注意力机制在小目标分割

Table 4 Comparison of MCNet with other representative segmentation algorithms

表 4 MCNet 与其他代表性分割算法对比表

算法名称	网络结构	多尺度机制	跳跃连接设计	注意力机制	适配小目标
UNet	编码-解码结构	无	对称连接	无	一般
Attention UNet	UNet + Attention Gate	无	注意力跳连	Spatial Attention	一般
TransAttU-Net	CNN + Transformer U-Net +	Transformer 模块	加强语义融合	Self-attention	中等
UCTransNet	Channel Trans	通道交互	CTrans-guided skip	Channel attention	一般
ScaleFormer	Transformer 为主干	多尺度感受野	简单连接	Cross-scale transformer Spatial +	较好
MCNet	WRN38 + MCA + MCG	多尺度融合 (MCA)	skip 重构 (MCG)	Channel + Non-local	优秀

中的价值。上述最新研究不仅推动了主干网络结构与 token-mixer 的持续演化, 也为应对肾上腺分割的独特挑战提供了可借鉴的解决思路。

综上, 肾上腺 CT 图像分割研究已经形成了从经典 U-Net 框架到 Transformer 模型, 再到专为小器官特点设计的新型网络结构的渐进发展路径。其中, U-Net 及其变体凭借结构简洁和性能稳定的特点, 在小体积器官分割中仍占据核心地位; Transformer 的引入则突破了卷积神经网络的局部感受野限制, 利用全局注意力机制显著增强了对复杂形态与边界模糊病灶的识别能力; 而 MCNet 等新型架构则进一步结合多尺度上下文建模与特定任务优化策略, 在精细分割方面展现出新的突破。这些方法既体现了深度学

习模型在肾上腺分割领域的不断迭代与优化,也为未来研究指明了方向,即通过结合多尺度建模、全局上下文信息以及任务定制化设计,有效推动肾上腺分割在精度、鲁棒性与临床应用价值上的全面提升。

4 结语

随着深度学习技术在医学图像分析中的应用越来越多,基于深度学习的肾上腺CT图像分割方法也越来越受到关注。现在,这类方法已经成为肾上腺疾病智能诊断中的一种重要工具。本文总结了近年来肾上腺CT图像分割领域的研究工作,并对相关方法进行了整理。通过总结已有研究和应用经验,本文梳理了基于深度学习的肾上腺分割在疾病诊断中的研究情况,也说明了该领域在深度学习推动下的发展过程。目前,肾上腺分割研究还处在探索阶段。在技术精度、模型稳定性和临床应用适应性方面,还有较大的提升空间。未来可以从下面两个方面继续改进肾上腺分割技术。

(1)数据集建设与共享问题。数据集问题仍然是当前的重要挑战。肾上腺体积较小,结构比较复杂,在CT图像中占的比例也很小。目前公开的高质量标注数据集数量不多,因此很难满足深度学习模型对大量训练数据的需求。另外,CT图像在采集时容易受到噪声、伪影、运动模糊和分辨率不足等因素影响,这些问题也会增加分割难度。肾上腺分割对图像质量和标注精度要求很高。如果要训练一个具有较好泛化能力的模型,不仅需要足够多的样本,还需要专业人员进行精细标注,这在实际操作中面临较大挑战。因此,推动高质量肾上腺影像数据集的建设与开放共享,对于提升分割算法的性能和实用性具有重要意义。

(2)未来肾上腺分割研究还应在模型设计方面持续优化,进一步提升分割的精度与泛化能力。现有主流架构如U-Net及其变体虽已广泛应用于医学图像分割,但在处理肾上腺这类形态变化大、边界模糊的小器官时仍显不足。为了解决这个问题,可以尝试设计更灵活的模型,多考虑不同病情下肾上腺的区别。此外,还可以进行多模态融合方法,把不同类型的图像结合起来。临床上除CT外,MRI、PET等成像方式能够提供更丰富的组织对比和功能信息。将多源影像数据进行联合建模,能把特征抓得更全,定位也更准,可以更好地识别复杂的病变。不仅如此,还可以用多任务学习的方法,将肾上腺分割和找病灶、疾病分类等任务联合建模。这样多个任务可以互相帮忙,不仅能提高整体效果,还能在样本有限的情况下提高训练效率。

综上,深度学习技术为肾上腺CT图像分割提供了新的发展机遇,尤其是卷积神经网络和Transformer架构的引入,使得肾上腺分割的精度和效率得到了前所未有的提升。未来,随着更多数据集的建设、算法的优化以及临床

验证的深入,肾上腺CT图像分割有望在肾上腺相关疾病的早期诊断和个性化治疗中发挥更大的作用。

参考文献:

- [1] ZHAO W, HE H, ZHAO J, et al. Adrenal tumor vessels segmentation using convolutional neural network in computed tomography angiography [C]// Berlin: 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2019.
- [2] BLAKE M A, HOLALKERE N-S, BOLAND G W. Imaging techniques for adrenal lesion characterization [J]. Radiologic Clinics of North America, 2008, 46(1): 65-78.
- [3] MITCHELL B D, WHITLATCH H B. Decoding hypertension through primary aldosteronism [J]. Circulation, 2023, 147(14): 1110-1111.
- [4] ZENNARO M C, BOULKROUN S, FERNANDES-ROSA F L. Pathogenesis and treatment of primary aldosteronism [J]. Nature Reviews Endocrinology, 2020, 16(10): 578-589.
- [5] CHEN C, MA Z L. Advances in imaging studies of primary hyperaldosteronism [J]. International Journal of Medical Radiology, 2024, 47(6): 712-718.
陈晨,马占龙.原发性醛固酮增多症的影像学研究进展[J].国际医学放射学杂志,2024,47(6):712-718.
- [6] FU Y, LIU J, SHI J. TS-Net: transformer based spatial-channel attention segmentation network for medical images [J]. Computers in Biology and Medicine, 2024, 170: 107938.
- [7] LEI W, SU Q, JIANG T, et al. One-shot weakly-supervised segmentation in 3D medical images [J]. IEEE Transactions on Medical Imaging, 2024, 43(1): 175-189.
- [8] LI J, LIU K, HU Y, et al. Eres-UNet++: liver CT image segmentation based on high-efficiency channel attention and Res-UNet plus [J]. Computers in Biology and Medicine, 2023, 158: 106501.
- [9] QADRI S F, LIN H, SHEN L, et al. CT-based automatic spine segmentation using patch-based deep learning [J]. International Journal of Intelligent Systems, 2023(1): 2345835.
- [10] SIMPSON A L, ANTONELLI M, BAKAS S, et al. A large annotated medical image dataset for the development and evaluation of segmentation algorithms [DB/OL]. <https://arxiv.org/abs/1902.09063>.
- [11] JI Y, BAI H, GE C, et al. Amos: a large-scale abdominal multi-organ benchmark for versatile medical image segmentation [J]. Advances in Neural Information Processing Systems, 2022, 35: 36722-36732.
- [12] YANG J, SHI R, WICKRAMASINGHE U, et al. Neural annotation refinement: development of a new 3d dataset for adrenal gland analysis [C]// Singapore: 25th International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI), 2022.
- [13] MA J, ZHANG Y, GU S, et al. Abdomenct-1k: is abdominal organ segmentation a solved problem? [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 44(10): 6695-6714.
- [14] LI H Y. A study on adrenal gland segmentation in CT images based on multi-level context-aware approaches [D]. Xiangtan: Xiangtan University, 2023.
李湖英.基于多层上下文感知的CT图像肾上腺分割研究[D].湘潭:湘潭大学,2023.
- [15] MURPHY A, WILCZEK M, FEGER J, et al. Windowing (CT) [EB/OL]. <https://radiopaedia.org/articles/52108>.
- [16] HARTUNG MICHAEL P, BROWN A. Abdominal CT: windows advanced [EB/OL]. <https://litfl.com/abdominal-ct-windows-advanced/>.
- [17] OSHER S, FEDKIW R P. Level set methods: an overview and some re-

- cent results [J]. *Journal of Computational physics*, 2001, 169(2): 463–502.
- [18] SIRI S K, KUMAR S P, LATTE M V. Threshold-based new segmentation model to separate the liver from CT scan images [J]. *IETE Journal of Research*, 2022, 68(6): 4468–4475.
- [19] HOJJATOLESAMI S, KITTLER J. Region growing: a new approach [J]. *IEEE Transactions on Image Processing*, 1998, 7(7): 1079–1084.
- [20] NOVIANA R, FEBRIAN I, RASAL I, et al. Axial segmentation of lungs CT scan images using canny method and morphological operation [C]// Surabaya: 2nd International Conference on Mathematics – Pure, Applied and Computation (ICoMPAC), 2016.
- [21] KOYUNCU H, CEYLAN R, ERDOGAN H, et al. A novel pipeline for adrenal tumour segmentation [J]. *Computer Methods and Programs in Biomedicine*, 2018, 159: 77–86.
- [22] BARSTUĞAN M, CEYLAN R, ASOGLU S, et al. Adrenal tumor segmentation method for MR images [J]. *Computer Methods and Programs in Biomedicine*, 2018, 164: 87–100.
- [23] ZHANG G, LI Z. An adrenal segmentation model based on shape associating level set in sequence of CT images [J]. *Journal of Signal Processing Systems*, 2019, 91(10): 1169–1177.
- [24] WANG X, JIN Z Y, XUE H D, et al. Evaluation of normal adrenal gland volume by 64-slice CT [J]. *Chinese Medical Sciences Journal*, 2012, 27(4): 220–224.
- [25] SCHNELLER J, REISER M, BEUSCHLEIN F, et al. Linear and volumetric evaluation of the adrenal gland—MDCT-based measurements of the adrenals [J]. *Academic Radiology*, 2014, 21(11): 1465–1474.
- [26] XIE L, YU Q, ZHOU Y, et al. Recurrent saliency transformation network for tiny target segmentation in abdominal CT scans [J]. *IEEE Transactions on Medical Imaging*, 2019, 39(2): 514–525.
- [27] LI Y, ZHAO Y, YANG P, et al. Adrenal volume quantitative visualization tool by multiple parameters and an nnU-Net deep learning automatic segmentation model [J]. *Journal of Imaging Informatics in Medicine*, 2025, 38(1): 47–59.
- [28] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation [C]// Munich: 18th International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI), 2015.
- [29] LI P, WU W, LIU L, et al. Automatic brain tumor segmentation from multiparametric MRI based on cascaded 3D U-Net and 3D U-Net++ [J]. *Biomedical Signal Processing and Control*, 2022, 78: 103979.
- [30] ÇIÇEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation [C]// Athens: 19th International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI), 2016.
- [31] CHEN Y C, YANG J J, ZHANG Y F, et al. Research on adrenal gland segmentation in CT images using deep learning [J]. *Radiology Practice*, 2023, 38(3): 305–312.
陈元翀, 杨洁瑾, 张耀峰, 等. 基于深度学习在CT图像上分割肾上腺的研究 [J]. *放射学实践*, 2023, 38(3): 305–312.
- [32] KIM T M, CHOI S J, KO J Y, et al. Fully automatic volume measurement of the adrenal gland on CT using deep learning to classify adrenal hyperplasia [J]. *European Radiology*, 2023, 33(6): 4292–4302.
- [33] MENG F, ZHANG T, PAN Y, et al. A deep learning algorithm for automated adrenal gland segmentation on non-contrast CT images [J]. *BMC Medical Imaging*, 2025, 25(1): 142.
- [34] CHEN Y, ZHANG Y, ZHANG X, et al. Characterization of adrenal glands on computed tomography with a 3D V-Net-based model [J]. *Insights into Imaging*, 2025, 16(1): 17.
- [35] BOLOCAN V-O, NICU-CANAREICA O, MITOI A, et al. Deep learning for adrenal gland segmentation: comparing accuracy and efficiency across three convolutional neural network models [J]. *Applied Sciences*, 2025, 15(10): 5388.
- [36] LUO G, YANG Q, CHEN T, et al. An optimized two-stage cascaded deep neural network for adrenal segmentation on CT images [J]. *Computers in Biology and Medicine*, 2021, 136: 104749.
- [37] ZHAO Y, LI H, WAN S, et al. Knowledge-aided convolutional neural network for small organ segmentation [J]. *IEEE Journal of Biomedical and Health Informatics*, 2019, 23(4): 1363–1373.
- [38] ROBINSON-WEISS C, PATEL J, BIZZO B C, et al. Machine learning for adrenal gland segmentation and classification of normal and adrenal masses at cT [J]. *Radiology*, 2023, 306(2): 212–222.
- [39] LI M Z. Automated segmentation of adrenal glands on computed tomography images using multi-scale 3D U-Net [D]. Taipei: National Taiwan University, 2023.
李旻哲. 利用多尺度 3D U-Net 在电脑断层扫描影像上进行肾上腺的自动化分割 [D]. 台北: 国立台湾大学, 2023.
- [40] BI L, KIM J, SU T, et al. Adrenal lesions detection on low-contrast CT images using fully convolutional networks with multi-scale integration [C]// 2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI), 2017: 1082–1085.
- [41] ALIMU P, FANG C, HAN Y, et al. Artificial intelligence with a deep learning network for the quantification and distinction of functional adrenal tumors based on contrast-enhanced CT images [J]. *Quantitative Imaging in Medicine and Surgery*, 2023, 13(4): 2675–2687.
- [42] WANG L, YE M, LU Y, et al. A combined encoder-transformer-decoder network for volumetric segmentation of adrenal tumors [J]. *Biomedical Engineering Online*, 2023, 22: 106.
- [43] FAYEMIWO M, GARDINER B, HARKIN J, et al. A novel pipeline for adrenal gland segmentation: integration of a hybrid post-processing technique with deep learning [J]. *Journal of Imaging Informatics in Medicine*, 2025, 38: 3698–3710.
- [44] CHEN J, MEI J, LI X, et al. TransUNet: rethinking the U-Net architecture design for medical image segmentation through the lens of transformers [J]. *Medical Image Analysis*, 2024, 97: 103280.
- [45] LI J, LI H, ZHANG Y, et al. MCNet: a multi-level context-aware network for the segmentation of adrenal gland in CT images [J]. *Neural Networks*, 2024, 170: 136–148.
- [46] LYU P, ZHANG J, ZHANG L, et al. MetaUNETR: rethinking token mixer encoding for efficient multi-organ segmentation [C]// Marrakesh: 27th International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI), 2024.
- [47] PANG J, MA D, ZHOU Z, et al. ASA: learning anatomical consistency, sub-volume spatial relationships and fine-grained appearance for CT images [C]// Marrakesh: 27th International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI), 2024.

(责任编辑:陈维捷)