

胡旷怡, 辛国江, 梁昊, 等. CAD-Net:一种基于U型网络的胰腺分割方法[J]. 智能计算机与应用, 2026, 16(3): 214-220.
DOI:10.20169/j.issn.2095-2163.24120904

CAD-Net:一种基于U型网络的胰腺分割方法

胡旷怡¹, 辛国江¹, 梁昊², 刘翼奇¹, 吴莹洁²

(1 湖南中医药大学 信息科学与工程学院, 长沙 410208; 2 湖南中医药大学 中医诊断研究所, 长沙 410208)

摘要: 胰腺分割在医学图像分析中是一项极具挑战的任务, 主要由于胰腺形态复杂、大小差异显著, 以及其与周围组织的灰度相似性, 导致分割精度较低。为解决这一问题, 本文提出了一种U型网络模型—CAD-Net, CAD-Net将ConvNeXt作为编码器骨干网络, 并融合注意力机制和动态蛇形卷积。ConvNeXt的多尺度特征提取能力使模型能够更好地捕捉胰腺的复杂结构。利用注意力机制动态调整特征图的权重, 进一步增强了对胰腺特征的提取, 同时有效抑制背景噪声。采用动态蛇形卷积动态调整卷积核, 提高了分割边缘的精度, 精准捕捉胰腺的复杂边界。在NIH数据集上进行实验分析: Dice值达到82.87%, IoU值达到70.76%。实验结果表明, 该方法在NIH数据集上显著提升了胰腺分割的准确性和鲁棒性, 证明了其在胰腺图像分割中的有效性。

关键词: 胰腺分割; CAD-Net; ConvNeXt; 注意力机制; 动态蛇形卷积

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2026)03-0214-08

CAD-Net: A pancreas segmentation method based on U-shape network

HU Kuangyi¹, XIN Guojiang¹, LIANG Hao², LIU Yiqi¹, WU Yingjie²

(1 School of Informatics, Hunan University of Chinese Medicine, Changsha 410208, China;

2 Institute of TCM Diagnostics, Hunan University of Chinese Medicine, Changsha 410208, China)

Abstract: Pancreas segmentation presents a significant challenge in medical image analysis due to the complex morphology, considerable size variations, and the similarity in grayscale values between the pancreas and surrounding tissues, which contribute to low segmentation accuracy. To address this issue, a U-shape network model, named CAD-Net is proposed, which utilizes ConvNeXt as the encoder backbone and integrates attention mechanisms and dynamic snake convolution. The multi-scale feature extraction capability of ConvNeXt enhances the model's ability to capture the intricate structures of the pancreas. By dynamically adjusting the weights of the feature maps through the attention mechanism, the model further improves the extraction of pancreatic features while effectively suppressing background noise. The incorporation of dynamic snake convolution allows for the adjustment of convolutional kernels, enhancing the accuracy of segmentation edges and accurately capturing the complex boundaries of the pancreas. Analysis on the NIH dataset reveals a Dice coefficient of 82.87% and an IoU of 70.76%. The experimental results demonstrate that this method significantly improves the accuracy and robustness of pancreas segmentation on the NIH dataset, confirming its effectiveness in pancreatic image segmentation.

Key words: pancreas segmentation; CAD-Net; ConvNeXt; attention mechanism; dynamic snake convolution

0 引言

胰腺癌(Pancreatic Cancer, PC)是一种起源于胰腺导管上皮及腺泡细胞的高度恶性肿瘤, 被医学界称为“癌中之王”。大约80%的患者在确诊时即晚期, 其中患PC的5年内生存率最低, PC预后差,

因此预防和及时发现就显得尤为重要^[1]。胰腺图像是早期诊断胰腺癌的重要参考, 准确地分割出胰腺图像能为后续的治疗提供辅助依据^[2]。

胰腺在CT图像中通常与周围组织(如肠道、胃和脂肪组织)灰度值相似, 导致其边界不明显。胰腺的形状和大小在不同个体之间差异较大, 且其形

基金项目: 湖南省一流本科课程(2021-896); 湖南省青年科技创新人才项目(2022RC1021); 湖南中医药大学科研基金“揭榜挂帅”专项(2022XJB002)。

作者简介: 胡旷怡(2000—), 男, 硕士研究生, 主要研究方向: 图像处理。

通信作者: 辛国江(1979—), 男, 博士, 副教授, 主要研究方向: 图像处理, 人工智能。Email: Guojiang_Xin@hnu cm.edu.cn。

收稿日期: 2024-12-09

态复杂,增加了分割的难度^[3]。CT图像中的噪声和伪影可能会进一步降低胰腺边界的清晰度。上述问题使得在医学图像分割中,胰腺分割的精度依旧差强人意^[4]。Ronneberger等学者^[5]提出U-Net网络模型,较少受到图像灰度值差异以及噪声影响,具有良好的泛化能力,在胰腺图像分割中应用十分广泛。ConvNeXt^[6]是一种现代化的卷积神经网络架构,结合了卷积神经网络的传统设计原则和视觉Transformer^[7]模型中的创新思想。ConvNeXt在多个视觉基准测试中尤为突出,并在图像分类、目标检测和语义分割任务中表现出优异性能。CBAM(Convolutional Block Attention Module)注意力机制能提升特征图的权重动态调整能力,突出与胰腺相关的重要区域,抑制无关或干扰信息,有效提高模型的分割准确性。动态蛇形卷积^[8](Dynamic Snake Convolution, DSC)能通过动态形变卷积核,增强对胰腺复杂、不规则边界形状的灵活适应能力。针对胰腺在CT图像中的复杂性和多样性,本文结合ConvNeXt、CBAM注意力机制和动态蛇形卷积,提出了一种新的U型网络—CAD-Net。论文主要贡献为:

(1)本文创新性地将ConvNeXt网络作为编码器将其应用到胰腺分割任务中,利用其强大的多尺度特征提取能力,提升了模型对复杂结构的感知能力。

(2)本文在解码器的上采样中引入了动态蛇形卷积来应对胰腺形态的复杂性。动态蛇形卷积能够精确捕捉胰腺的边缘和细微特征,提升了模型在胰腺分割任务中的细节捕捉能力。

1 相关工作

早期的胰腺分割方法采用传统的图像分割技术,利用图像中器官的纹理、灰度和光谱等浅层特征进行分割,例如阈值分割法、区域生长法^[9];或者利用边缘信息进行分割,例如边缘检测法^[10]。这些传统方法需要手动调整大量参数,在处理简单、背景单一的图像时可能效果较好,但对于复杂和多变的胰腺结构来说,常常出现准确性不高、鲁棒性差等问题。

由于深度学习模型可以自动学习和提取图像中的深层特征,可以捕捉到胰腺与周围组织的微妙差异,且深度学习模型在各种条件下都能保持较高的分割精度和鲁棒性,越来越多的研究者开始采用深度学习方法来原因提高胰腺图像分割的准确性和鲁棒性。

1.1 基于U-Net的胰腺分割方法

Man等学者^[11]提出了一种基于深度强化学习的新方法,该方法在CT图像中使用几何感知可变形U-Net网络。该方法先选择CT的单张切片,训练强化学习代理以识别该切片中胰腺的最佳边界框,再利用可变形U-Net对识别出的胰腺区域进行分割,最终结果表明该方法用于胰腺分割有显著优势。Li等学者^[12]概述了一种多尺度注意力密集残留U型网络(MAD-UNet),通过融合密集残差块和多尺度卷积核,提高了模型精确定位胰腺细微差别的能力。这种方法通过注意力机制增强了上下文信息,从而提高了分割边界的精确度。Oktay等学者^[13]在U-Net网络的基础上提出了Attention U-Net网络,在编解码跳跃连接操作之间加一个新型注意力门,以此来实现自动学习关注不同形状和大小的分割区域。这些方法通过跳跃连接保持了高分辨率特征信息,使得分割结果更具准确性,但在处理形态复杂、位置多变的胰腺时,容易丢失一些关键的全局上下文信息。

1.2 基于Transformer与多尺度特征学习的胰腺分割方法

Wang等学者^[14]提出一种具有余坐标空间和通道混合Transformer的多尺度可变形U网(MDHT-Net)用于胰腺分割。该网络将余坐标空间和通道混合Transformer模块设计为一种新颖的跳跃连接,增强了网络感知空间信息的能力,并揭示了不同层特征内的通道间关系。Dai等学者^[15]针对胰腺分割问题提出了一种两阶段的反式Transformer网络。该方法引入了基于小波分解的多输入模块,以增强网络对高频纹理信息的关注,从而更精确地捕捉胰腺的细微特征。此外,还设计了尺度交互活动融合模块,用于有效融合局部特征与全局上下文信息,从而提升网络在多尺度特征处理和胰腺形态建模中的表现。Qiu等学者^[16]提出了残差Transformer U-Net(RTUNet)来适应胰腺的特性。该模型通过残差Transformer块从全局视角提取多尺度特征,有效应对胰腺位置的高变异性。同时还引入了双卷积下采样策略,在保证较大感受野的同时,精准捕获胰腺的形状和大小特征,防止关键信息在下采样过程中丢失,提升了分割精度。Chen等学者^[17]提出了一种结合多尺度监督方法和双视角特征学习的方法。该方法有效捕捉了胰腺的多视角互补信息,并结合了不同尺度的特征,从而提高了分割精度。基于Transformer的方法通过自注意力机制,能够更好地

捕捉全局上下文信息,有助于提升分割的整体效果,但 Transformer 模型的计算复杂度高,尤其在处理医学图像时,对计算资源和硬件设备要求较高,推理速度较慢。

2 方法

在胰腺分割任务中,不仅需要应对噪声的干扰,还必须充分考虑胰腺本身的复杂特性。因此,本文将 ConvNeXt 作为编码器的骨干网络,同时引入注意力机制与动态蛇形卷积,将其应用到 U 型网络结构中,提出了 CAD-Net。

2.1 CAD-Net 网络模型

CAD-Net 网络模型使用编码-解码结构。模型结构如图 1 所示。CAD-Net 将 ConvNeXt 作为编码器的骨干网络,可以在不丢失上下文信息的同时减

少模型的复杂度。编码器首先通过一个卷积模块处理输入胰腺图像,初步提取特征,随后对特征图进行下采样,生成 CAD-Net 网络结构中的第 1 层特征图。ConvNeXt 共有 4 个阶段(见图 1 左侧),将胰腺图像输入 ConvNeXt,得到胰腺图像经过每个阶段后的特征图,将其分别作为 CAD-Net 网络结构中的第 2、3、4、5 层的特征图。在提取特征的过程中,网络不仅需要捕捉到图像中的显著区域,还要有效抑制背景噪声和其他无关信息。因此,CAD-Net 在编码器中加入了注意力机制,增强模型在不同特征层次上对重要信息的感知能力,提高整体分割效果。在解码器中,引入了动态蛇形卷积,以此来有效地还原输入图像的高分辨率细节,并保证分割结果的精确性。最终,解码器通过一个 1×1 的卷积层将特征图映射到目标类别的数量,生成最终的分割结果。

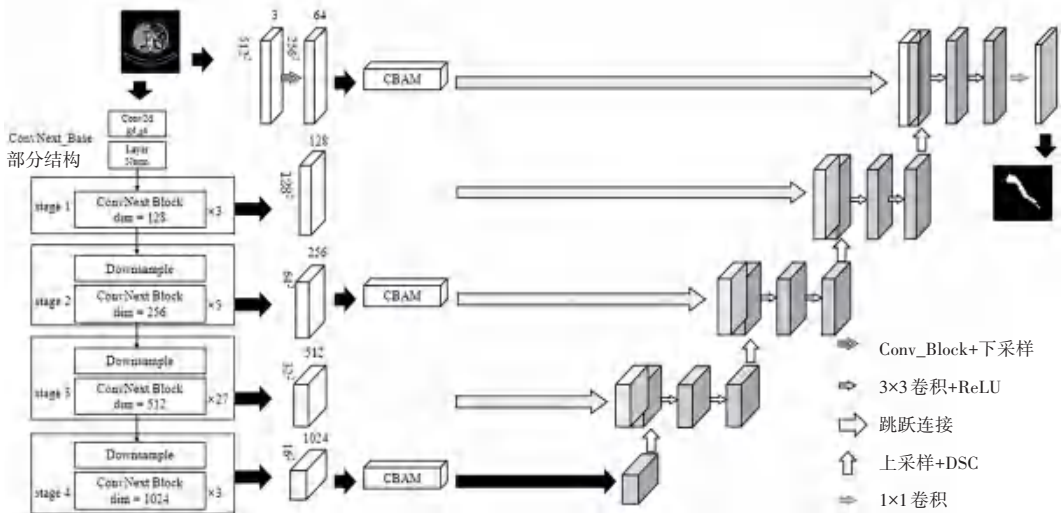


图 1 CAD-Net 网络结构

Fig. 1 CAD-Net network structure

2.2 CBAM 注意力机制

针对胰腺图像边缘模糊的问题,引入 CBAM 注意力机制^[18-19]。CBAM 的双重注意力机制通过分别对特征图的通道和空间维度进行加权,灵活适应胰腺的模糊边界,使得模型在处理形态变化时,能够更好地捕捉胰腺的特征,从而提高分割的精度并减少因胰腺边界模糊所带来的误差。在模型的第 1 层引入 CBAM 模块,能够帮助模型更好地聚焦于输入图像中的关键边缘和局部信息,提升特征的局部辨别能力。在模型的第 3 层引入 CBAM 模块,可以加强模型对多尺度特征的感知,使其能够同时兼顾局部和全局的图像特征。在模型的第 5 层引入 CBAM 模块,有助于进一步增强高阶语义特征的表达,从而确保模型能够捕捉到更复杂的结构信息。CBAM 模

块结构如图 2 所示。

2.3 动态蛇形卷积

针对胰腺图像分割中面临的形态复杂性问题,将解码器中上采样的标准卷积替换为动态蛇形卷积,以此更好地保留全局上下文信息。动态蛇形卷积与标准卷积对比如图 3 所示。分析可知,标准卷积只能使用固定的卷积核,对所有输入位置应用相同的权重,无法有效捕捉细微特征。动态蛇形卷积通过引入可变形的卷积核,动态适应输入特征图的局部几何结构。这种灵活性不仅有助于维持全局特征的一致性,还能够更精细地建模局部几何特征。其独特的卷积路径设计促进了局部特征与全局上下文的有效融合,从而提升模型在复杂胰腺结构上的分割性能。




图 2 CBAM 模块

Fig. 2 CBAM module




图 3 动态蛇形卷积与标准卷积对比

Fig. 3 Comparison of dynamic snake convolution with standard convolutions

3 实验设计

3.1 数据集

本研究使用的数据集来自美国国家卫生研究院 (NIH) 临床中心, NIH 数据集包含 82 张 CT 增强图像, 包括 53 名男性和 27 名女性, 年龄在 18~76 岁之间。每个体积的分辨率为 $512 \times 512 \times L$, 其中 $L \in [181, 466]$, 切片厚度表示为 T (单位为 cm), 其中 $T \in [1.5, 2.5]$ 。本文提出的模型适用于 2D 数据, 因此需要将 3D 数据转化为 2D 数据。依据标签内容舍弃 CT 切片中不包含胰腺的图像, 最终得到原始图像共 7 058 张。通过调节 CT 图像窗宽窗位来提高图像对比度, 将窗宽调整为 350HU, 窗位调整为 40HU。最后进行归一化处理。本实验采用四折交叉验证, 在 82 例患者中随机分割, 每次测试分别为 21、21、20 和 20 例患者。

3.2 实验环境、超参数及评价指标

本文所有实验的环境见表 1。

表 1 实验环境

Table 1 Experimental environment

CPU	GPU	Python version	CUDA version	Torch version
Intel(R) Xeon(R) Silver 4210	NVIDIA RTX3090	3.8	12.0	2.2.2

本文实验的超参数见表 2。

表 2 超参数

Table 2 Hyperparameters

优化器	初始学习率	Epoch	Batch Size
Adam	0.000 1	100	16

在胰腺分割任务中, 为了全面评估模型的分割性能, 本文使用了常见的评价指标: Dice 系数 (Dice)、交并比 (IoU)、准确率 (Precision)、召回率 (Recall)、参数量 (Parameters) 和模型大小 (Model size)。这些指标从不同的角度来衡量分割结果的准确性和完整性。

(1) Dice 系数。衡量类别真实值与预测结果之间的相似度。计算公式为:

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

(2) 交并比。通过计算真实正样本和模型预测正样本的重叠部分占两者联合区域的比例, 来衡量分割结果的精度。计算公式为:

$$\text{IoU} = \frac{TP}{TP + FP + FN} \quad (2)$$

(3) 准确率。用来衡量模型预测的正样本中, 实际为正样本的比例。计算公式为:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

(4) 召回率。是在所有真正为正例的样本中成功预测为正例的比例。计算公式为:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4)$$

其中, TP 表示模型正确预测为正的像素点, 即实际为正且被预测为正的像素; FP 表示模型错误预测为正的像素点, 即实际为负但被模型预测为正的像素; FN 表示模型漏掉的正样本, 即实际为正但被模型预测为负的像素。

(5) 参数量。衡量的是模型中的所有可训练参数的总数。较大的参数量通常意味着模型具有更多的学习能力, 但也可能导致过拟合或计算成本的增加。参数量越大, 模型的复杂度和存储需求也越高。

(6) 模型大小。指的是模型的存储空间, 通常

以兆字节(MB)为单位。较大的模型尺寸通常意味着更多的参数存储,但也可能带来更高的计算和存储成本。

4 实验结果分析

为了验证所提出模型的有效性,本研究将其与当前广泛使用的 DeepLabv3+^[20]、VGG U-Net^[21]、Res U-Net^[22]以及 Segformer^[23]进行了比较。这些

模型代表了不同的分割架构,涵盖了从经典的卷积网络到新兴的 Transformer 模型。选其作为对比对象,能够帮助评估所提模型在多种特征提取方式下的表现,同时验证其在实际应用中的适应性和鲁棒性。5种模型对比结果见表3。本文提出的 CAD-Net 显著高于其他模型,平均 Dice 值以及 IoU 最高,分别达到了 82.87%和 70.76%。

表3 模型对比结果

Table 3 Model comparison results

模型	Dice/% ↑	IoU% ↑	Precision/% ↑	Recall/% ↑	Parameters/M	Model size/MB
DeepLabv3+ ^[20]	80.30	67.11	77.73	83.11	5.82	22.19
VGG U-Net ^[21]	81.45	68.73	83.25	79.84	25.04	95.53
Res U-Net ^[22]	81.77	69.18	82.81	80.88	44.08	168.17
Segformer ^[23]	81.80	69.23	82.32	81.40	89.27	340.54
CAD-Net	82.87	70.76	82.19	83.04	101.28	386.35

为了更加直观地对比各个网络的分割效果,使用 NIH 数据集中第 12 号病例的第 104 张切片(Case #12)、第 15 号病例的第 140 张切片(Case #15)以及

第 18 号病例的第 107 张切片(Case #18)的影像进行分割结果对比。对比结果如图 4 所示。

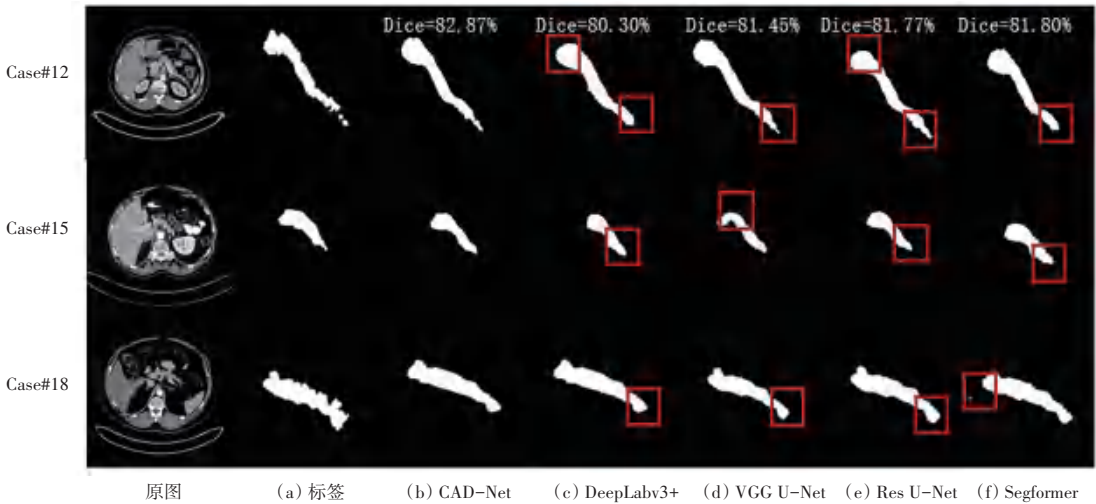


图4 本文方法与其他方法的胰腺分割对比

Fig. 4 Comparison of pancreatic segmentation with other methods

由图 4(c)可以看出,DeepLabv3+^[20]虽然比较完整地分割出了胰腺,但是由于胰腺头部和尾部与其他器官组织混在一起,错误地将其他器官组织作为胰腺头部进行分割,也误以为胰腺尾部属于其他器官组织,分割效果不佳。虽然 DeepLabv3+^[20]通过空洞卷积和特征金字塔来处理多尺度信息,但其解码器结构相对复杂。相比之下,本文所提出的模型采用 ConvNeXt 作为编码器,能够在保留较少计算复杂度的情况下,实现对多尺度特征的高效提取。

从图 4(d)可以看出,VGG U-Net^[21]在分割胰

腺时表现出了一些不完整性,尤其是在胰腺头部和尾部区域,VGG U-Net^[21]的分割存在较大的误差。对于 Case #15,胰腺的头部轮廓分割得不够准确,被过度削减,这显示出 VGG U-Net^[21]在处理复杂形态的胰腺时精度不足。同时,边界模糊的情况较为明显,导致分割的形状失真。

图 4(e)中的 Res U-Net^[22]相比于 VGG U-Net^[21]稍微表现得更好,但却仍然存在一些问题。对于 Case #12 和 Case #18,Res U-Net^[22]在胰腺尾部区域出现了较大的错误分割,将其他组织混入胰腺区

域,同时丢失了胰腺的部分结构。虽然其总体分割较为连贯,但在边缘和细节部分的分割效果欠佳。

与 VGG U-Net^[21] 和 Res U-Net^[22] 的比较,可以进一步验证 CAD-Net 在深层特征提取方面的优势,特别是在胰腺分割中,这种能力对于捕捉细微区域至关重要。

从图 4(f) 可以看出,Segformer^[23] 的分割结果较为不理想。虽然在大体轮廓上能够识别出胰腺,但在细节处理上有明显不足。例如,Case #12 中胰腺尾部的丢失情况较为严重,几乎没有正确识别出胰腺的尾部结构,而 Case #18 的分割也存在明显的形态缺失问题,还将其他器官组织的部分也划分为胰腺。Segformer^[23] 的 Transformer 结构擅长处理长距离依赖关系,能够有效捕获全局信息。通过与 Segformer 的对比,可以揭示在不依赖全局注意力机制的情况下,CAD-Net 如何通过更深的卷积网络提

升分割精度。

本文提出的 CAD-Net 通过引入 ConvNeXt 作为编码器,能够在保证较低计算复杂度的前提下,有效提取多尺度特征,特别是在胰腺边缘区域表现出更高的精度。结合注意力机制和动态蛇形卷积,CAD-Net 能够优化特征学习,增强胰腺与周围组织的区分能力,尤其在胰腺形态复杂的区域提供更为精确的分割结果。相比于其他参照模型,CAD-Net 在处理胰腺分割时,能够更加精准地捕捉到胰腺的形态特征和边缘信息,取得了更好的分割效果。

为了进一步验证模型的有效性,本研究将 CAD-Net 与近几年文献提出方法在 NIH 数据集上的结果进行比较,结果见表 4。从表 4 可以得知,CAD-Net 在近年来所提出的方法中表现最好。相比于 2021 年 Dogan 等学者^[24] 提出的方法,Dice 提高 4.74%,Recall 提高 4.69%。

表 4 近几年文献中的模型和本文模型的对比

Table 4 Comparison of models from recent literatures and the proposed model

方法	Dice ↑	IoU	Precision ↑	Recall ↑
Mo, et al. (2020) ^[25]	82.47	—	—	—
Nishio, et al. (2020) ^[26]	78.90	—	—	—
Tian, et al. (2021) ^[27]	78.13	—	74.64	82.65
Shen, et al. (2021) ^[28]	80.90	—	—	—
Dogan, et al. (2021) ^[24]	78.86	—	79.58	78.35
毕秀丽,等(2022) ^[3]	75.10	—	78.80	76.00
纪建兵,等(2023) ^[29]	82.35	—	84.14	81.07
CAD-Net(本文方法)	82.87	70.76	82.19	83.04

5 消融实验

为了进一步验证模型的有效性和可靠性,设计了 4 组消融实验。消融实验设计见表 5。

表 5 消融实验设计

Table 5 Design of ablation experiment

组编号	ConvNeXt	CBAM	DSC
A	×	×	×
B	√	×	×
C	√	√	×
D	√	√	√

消融实验结果见表 6。从表 6 可以看出,D 组模型的分割指标表现最佳,即本文提出的模型分割效果最好,同时也可以看出注意力机制以及动态蛇形卷积的应用对模型的分割效果产生了增益。

表 6 消融实验结果

Table 6 Results of ablation experiment

组编号	Dice ↑	IoU ↑	Precision ↑	Recall ↑
A	79.93	66.57	79.87	79.99
B	82.54	70.23	82.12	83.04
C	82.56	70.32	83.02	82.27
D	82.87	70.76	82.19	83.04

图 5 更加直观地展示了消融实验分割结果。A 组的结果表明,未添加任何模块的单张切片结果最不理想,模型将其他器官组织作为胰腺区域划分,尤其是胰腺的头部与尾部。从 B 组中可以看出,未使用 CBAM 模块和动态蛇形卷积的模型同样存在将其他器官组织划分为胰腺的情况。C 组的分割效果有所提升,但仍出现胰腺尾部的过分割现象。D 组则在所有模块的共同作用下,显著改善了分割效果,表现出更高的精确度和可靠性。




图5 消融实验分割结果

Fig. 5 Segmentation results of ablation experiment

通过定量和定性分析,可以看出 CAD-Net 以 ConvNeXt 为骨干网络,以及引入 CBAM 模块和动态蛇形卷积的有效性。

6 结束语

本文提出了一种以 ConvNeXt 为骨干网络,融合注意力机制与动态蛇形卷积的 U 型网络结构。将 ConvNeXt 作为编码器的骨干网络,旨在提升胰腺分割的精度和对复杂形态的适应性。通过引入注意力机制,模型能够动态调整对特征图中重要区域的关注以及增强对胰腺边界的识别,从而更好地区分胰腺与周围相似组织。针对胰腺形态的复杂性,在上采样中引入动态蛇形卷积,增强了模型对胰腺细节的捕捉能力。实验结果表明,所提出的方法有效解决了胰腺精确分割的问题,在多个评价指标上取得了显著提升。这一改进的网络结构为胰腺的精细分割提供了新的思路和参考。

参考文献

[1] 谢昊,姜琳,许治清,等. 可能增加胰腺癌风险的药物研究进展[J]. 中国医院药学杂志, 2024, 45(1): 92-98.

[2] 张国栋,唐晓艺,鞠蓉晖,等. 融合双注意力机制的多尺度胰腺分割方法[J]. 计算机工程与设计, 2024, 45(4): 1189-1194.

[3] 毕秀丽,陆猛,肖斌,等. 基于双解码 U 型卷积神经网络的胰腺分割[J]. 软件学报, 2022, 33(5): 1947-1958.

[4] ZHANG Zheyuan, YAO Lanhong, ELIF K, et al. Deep learning algorithms for pancreas segmentation from radiology scans: a review [J]. Advances in Clinical Radiology, 2023, 5(1): 31-52.

[5] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]// Proceedings of International Conference on Medical Image

Computer and Computer Assisted Intervention. Cham: Springer, 2015:234-241.

- [6] LIU Zhuang, MAO Hanzi, WU Chaoyuan, et al. A convnet for the 2020s [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2022: 11976-11986.
- [7] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30:5998-6008.
- [8] QI Yaole, HE Yuting, QI Xiaoming, et al. Dynamic snake convolution based on topological geometric constraints for tubular structure segmentation [C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway, NJ: IEEE, 2023: 6070-6079.
- [9] YAO Xu, SONG Yuqing, LIU Zhe. Advances on pancreas segmentation: A review [J]. Multimedia Tools and Applications, 2020, 79(9):6799-6821.
- [10] 戴俊龙,何聪,武杰,等. 融合双解码和全局注意力上采样模块的胰腺囊性肿瘤分割网络[J]. 波谱学杂志, 2024, 41(2): 151-161.
- [11] MAN Yunze, HUANG Yangsibo, FENG Junyi, et al. Deep Q learning driven CT pancreas segmentation with geometry-aware U-Net [J]. IEEE Transactions on Medical Imaging, 2019, 38(8): 1971-1980.
- [12] LI Weisheng, QIN Sheng, LI Feiyan, et al. MAD-UNet: A deep U-shaped network combined with an attention mechanism for pancreas segmentation in CT images [J]. Medical Physics, 2021, 48(1): 329-341.
- [13] OKTAY O, SCHLEMPER J, FOLGOCL L, et al. Attention U-Net: Learning where to look for the pancreas [J]. arXiv preprint arXiv, 1804.03999, 2018.
- [14] WANG Huifang, YANG Dawei, ZHU Yu, et al. MDHT-Net: Multi-scale deformable U-Net with cos-spatial and channel hybrid transformer for pancreas segmentation [J]. Applied Intelligence, 2024, 54(23): 12272-12292.
- [15] DAI Shunbo, ZHU Yu, JIANG Xiaoben, et al. TD-Net: Trans-Deformer network for automatic pancreas segmentation [J]. Neurocomputing, 2023, 517:279-293.

-
- [16] QIU Chengjian, LIU Zhe, SONG Yuqing, et al. RTUNet: Residual transformer UNet specifically for pancreas segmentation[J]. *Biomedical Signal Processing and Control*, 2023, 79: 104173.
- [17] CHEN Haipeng, LIU Yunjie, SHI Zenan, et al. Pancreas segmentation by two-view feature learning and multi-scale supervision[J]. *Biomedical Signal Processing and Control*, 2022, 74: 103519.
- [18] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module [C]//*Proceedings of European Conference on Computer Vision*. Cham: Springer, 2018:3-19.
- [19] HASSANIN M, ANWAR S, RADWAN I, et al. Visual attention methods in deep learning: An in-depth survey[J]. *Information Fusion*, 2024, 108: 102417.
- [20] CHEN L C, ZHU Yukun, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//*Proceedings of European Conference on Computer Vision*. Cham: Springer, 2018:833-851.
- [21] GHOSH S, CHAKI A, SANTOSH K. Improved U-Net architecture with VGG-16 for brain tumor segmentation[J]. *Physical and Engineering Sciences in Medicine*, 2021, 44(3):1169-1179.
- [22] AIBINDER D, WEISBERG M, GHIDOTTI A, et al. Enhanced attention Res-UNet for segmentation of knee bones[J]. *Mathematics*, 2024, 12(14): 2284.
- [23] XIE Enze, WANG Wenhai, YU Zhiding, et al. SegFormer: Simple and efficient design for semantic segmentation with Transformers [J]. *Advances in Neural Information Processing Systems*, 2021, 34:12077-12090.
- [24] DOGAN R O, DOGAN H, BAYRAK C, et al. A two-phase approach using mask R-CNN and 3D U-Net for high-accuracy automatic segmentation of pancreas in CT imaging [J]. *Computer Methods and Programs in Biomedicine*, 2021, 207: 106141.
- [25] MO Juan, ZHANG Lei, WANG Yan, et al. Iterative 3D feature enhancement network for pancreas segmentation from CT images [J]. *Neural Computing and Applications*, 2020, 32: 12535-12546.
- [26] NISHIO M, NOGUCHI S, FUJIMOTO K. Automatic pancreas segmentation using coarse-scaled 2d model of deep learning: Usefulness of data augmentation and deep U-net [J]. *Applied Sciences*, 2020, 10(10): 3360.
- [27] TIAN Mu, HE Jinchuan, YU Xiaxia, et al. MCMC guided CNN training and segmentation for pancreas extraction [J]. *IEEE Access*, 2021, 9: 90539-90554.
- [28] SHEN Chen, WANG Pochuan, ROTH H R, et al. Multi-task federated learning for heterogeneous pancreas segmentation [C]//*Proceedings of the 24th International Conference on Medical Image Computing and Computer Assisted Intervention*. Cham: Springer, 2021: 101-110.
- [29] 纪建兵, 陈纾, 杨媛媛. 双重降维通道注意力门控 U-Net 的胰腺 CT 分割 [J]. *中国生物医学工程学报*, 2023, 42(3): 281-288.