

面向CT肺结节分割的动态区域优化方法

杨国虎, 刘平, 金雨纯, 甄元元

(宁夏大学电子与电气工程学院, 宁夏 银川 750021)

摘要: 肺结节的精准分割是肺癌早期筛查与临床诊断的关键前提, 然而 CT 影像中结节存在形态不规则、边界模糊、尺寸差异大(从几毫米到数十毫米)等问题, 且易受血管、胸膜等周围组织的干扰, 导致传统深度学习分割方法(如 U-Net、基线 V-Net)存在边界定位误差大、小病灶漏诊率高、分割一致性差等局限; 此外, 固定感兴趣区域(ROI)的设置易造成目标信息冗余或关键细节丢失, 进一步制约分割精度。针对上述挑战, 提出一种结合自适应 ROI 算法与多视角三维分割策略的两阶段肺结节分割方法。第 1 阶段采用 V-Net 架构沿轴向进行初始分割, 通过创新的自适应感兴趣区域(A-ROI)算法动态调整 ROI 位置和尺寸, 保持结节与 ROI 面积比低于阈值(R_t), 减少无关组织干扰; 第 2 阶段沿冠状轴和矢状轴进行补丁式分析, 最终通过共识模块整合多平面预测结果, 提升分割稳定性。在 LUNA16 和 LNDb 公开数据集上的实验表明, 该方法 Dice 系数分别达到 92.6% 和 92.3%, 较基线 V-Net 提升 6.2% 和 6.1%, Hausdorff 距离降低至 2.92 ± 1.89 mm; 相较于传统 U-Net, 分割精度亦有显著提升。多平面协同分析使形状相似度提升 29.8%, 能有效应对 CT 影像中结节分割的核心挑战, 为临床肺癌早期精准诊断与疗效评估提供可靠技术支持。

关键词: 肺结节; 自适应 ROI 算法; 多视角分割; V-Net 架构; 分割稳定性

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.2096-3750.WLW25123

Dynamic region optimization method for CT pulmonary nodule segmentation

Yang Guohu, Liu Ping, Jin Yuchun, Zhen Yuanyuan

School of Electronics and Electrical Engineering, Ningxia University, Yinchuan 750021, China

Abstract: Accurate segmentation of pulmonary nodules is a crucial prerequisite for early lung cancer screening and clinical diagnosis. However, pulmonary nodules in CT images exhibit challenges such as irregular shapes, blurred boundaries, and significant size variations (ranging from a few millimeters to tens of millimeters). Additionally, they are easily interfered with by surrounding tissues like blood vessels and pleura, which leads to limitations in traditional deep learning segmentation methods (e.g., U-Net, baseline V-Net), including large boundary localization errors, high missed diagnosis rates of small lesions, and poor segmentation consistency. Furthermore, the fixed setting of the region of interest (ROI) tends to cause redundancy of target information or loss of key details, further restricting segmentation accuracy. To address the above challenges, a two-stage pulmonary nodule segmentation method was proposed that combined an adaptive ROI algorithm with a multi-view 3D segmentation strategy. In the first stage, the V-Net architecture was employed to perform initial segmentation along the axial axis. The position and size of the ROI were dynamically adjusted by an innovative adaptive ROI (A-ROI) algorithm, maintaining the area ratio of the nodule to the ROI below a threshold R_t to reduce interference from irrelevant tissues. In the second stage, patch-based analysis was conducted along the coronal and sagittal axes,

收稿日期: 2025-08-05; 修回日期: 2025-09-10

通信作者: 刘平, Liuping@nxu.edu.cn

基金项目: 宁夏回族自治区自然科学基金资助项目 (No. 2023AAC03140)

Foundation Item: The Natural Science Foundation of the Ningxia Hui Autonomous Region (No. 2023AAC03140)

and finally, the multi-plane prediction results were integrated by a consensus module to enhance segmentation stability. Experiments on the public LUNA16 and LNDb datasets show that this method achieves Dice coefficients of 92.6% and 92.3%, respectively, representing an improvement of 6.2% and 6.1% compared to the baseline V-Net, while the Hausdorff distance is reduced to 2.92 ± 1.89 mm. Compared with the traditional U-Net, the segmentation accuracy is also significantly improved. Multi-plane collaborative analysis improves shape similarity by 29.8%. This method effectively addresses the core challenges in pulmonary nodule segmentation in CT images, providing reliable technical support for clinical accurate diagnosis of early lung cancer and efficacy evaluation.

Key words: lung nodule, adaptive ROI algorithm, multi-view segmentation, V-Net architecture, segmentation stability

0 引言

肺癌是威胁人类健康的重大疾病，其早期诊断高度依赖于肺结节的精准量化分析。肺结节的连续体积监测对评估恶性程度和预测肺癌风险至关重要^[1-3]。然而，传统手动分割方法不仅耗时费力，还存在显著的观察者间差异。虽然计算机辅助诊断系统在提高放射科医生工作效率方面展现出不错的潜力，但基于深度学习^[4]和传统图像处理技术^[5]的自动化分割方法仍面临重大挑战。这些方法均需依赖三维感兴趣体积（VOI）作为输入，但VOI内部的结节形态变异及其与周围组织的相似性，严重制约着分割的准确性和鲁棒性。现有技术需要一个三维感兴趣体积作为输入，以准确估计结节的形状。这个VOI可以由结节检测模块输出，也可以由放射科医生提供。然而，即便有了VOI，结节内部的形状变化以及结节与周围环境（即非结节组织）之间的视觉相似性，仍然对开发高度精确和鲁棒的结节分割解决方案构成了障碍。肺结节切片轴向视图如图1所示，显示了结节内部和不同结节之间的变化，可以观察到不同结节形状的差异以及单个结节在多个轴向视图中的表现。




图1 肺结节切片轴向视图

注：结节变化从(I)~(IV)列，结节间差异从(a)~(c)行呈现。

肺结节精准评估是判断其恶性程度和肺癌风险的重要前提。鉴于结节分割的关键作用，学术界已开发出多种高精度、高鲁棒性的自动分割系统以辅助放射科诊断。现有研究方法主要分为两大类：基于传统图像处理的方法和基于深度学习的方法。传统方法中，Kucharski等^[6]针对磨玻璃结节（GGN, ground-glass nodule）设计了可变形模型，但不能有效解决CT影像中结节形态多变的挑战。Wang等^[7]开发的三维残差U型网络通过残差连接强化编码器—解码器特征交互，结合两阶段损失函数优化策略，显著提升细粒度特征学习能力，但是会漏掉一些关键信息。这些方法普遍存在泛化性差、鲁棒性不足的问题。深度学习技术展现出显著优势，V-Net架构^[8]极大提升了分割性能，后续研究如CF-CNN^[9]和多视图卷积神经网络^[10]（CNN, convolutional neural network）通过多平面分析改进结果，但仍受限于固定尺寸输入的问题。卢娟等^[11]结合低层边界和高层特征，提升对小尺寸、异形结节的定位能力，并且通过卷积块和反向注意力，聚焦结节区域，减少与周围组织的混淆，但是增加了训练和推理时间。李奇翰等^[12]和王伯霄等^[13]分别改进U-Net架构，但前者缺乏3D分析，后者采用静态VOI窗口影响大结节分割精度^[14-16]。因此，通过将3个预测掩模相加来计算最终分割结果。VOI选择标准是静态的，并固定为给定体素周围的 $128 \times 128 \times 12$ 窗口，这使得无法在大结节上实现高精度分割。为此，本文创新性地引入自适应二维感兴趣区域选择算法，结合改进的V-Net模型，通过冠状面和矢状面自动分析实现精确的3D结节分割。

该轴向视图序列系统展示肺结节形态特征：图1(I)~(IV)列显示单个结节连续切片变化，实性成分占比从32%增至59%；图1(a)~(c)行对比3种亚型，图1(a)为纯磨玻璃结节，图1(b)为部分实性结节，图1(c)为恶性结节。3类结节纹理熵值差异达

2.3 倍 ($p < 0.001$), 为小于等于 10 mm 的结节良恶性鉴别提供重要依据。

1 基本原理

本文方法的两个阶段如图 2 所示。第 1 阶段, 估计结节的三维形状 (沿着轴向提取 VOI)。第 2 阶段, 利用提取的 VOI 进一步执行沿着冠状轴和矢状轴的 2D 补丁式调查。最后, 使用共识模块来计算结节的 3D 分割。每个阶段的细节描述如下。

第 1 阶段, 提供包含结节的 2D 感兴趣区域 (ROI), 该 ROI 可以覆盖结节的任何部分 (来自任何切片)。随后, 利用 V-Net 架构对该 ROI 进行处理, 得到结节的 2D 分割结果, 并将其传递给自适应感兴趣区域 (A-ROI) 算法。该算法根据当前 ROI 内的结节位置, 动态调整下一切片的 ROI 大小和位置。最终, 通过连接所有 2D 分割掩模, 构建出结节的三维体积分割结果。A-ROI 算法旨在动态选择下一切片的 ROI, 搜索结节的存在。其目标包括: 通过调整 ROI 位置, 使其与预测结节掩模保持同心; 通过改变 ROI 大小, 确保结节与 ROI 的面积比低于预设阈值 (R_T)。

A-ROI 算法效果如图 3 所示, 当前切片内的 ROI 和下一切片的估计 ROI (使用 A-ROI 算法计算) 分别以红色和绿色显示。图 3(a) 和图 3(b) 呈现了 ROI 位置变化以及尺寸变化。图 3(a) 显示了当前

切片中的 ROI, 图 3(b) 显示了下一切片中 ROI 大小和位置的变化, 其中红色方框表示根据 A-ROI 算法调整的 ROI 大小, 绿色方框表示 ROI 在连续切片中的位置变化。首先, 在用户提供的手动 ROI 上执行结节分割。在预测掩模中通过识别的边缘来调整 ROI 位置和大小。在算法中, A_{N_i} 、 A_{ROI_i} 和 $A_{ROI_{i+1}}$ 分别表示第 i 张切片中结节的面积、第 i 张切片中 ROI 的面积和第 $i+1$ 张切片中 ROI 的建议面积。

A-ROI 算法整体效果如图 4 所示, 展示了恒定 ROI 和自适应 ROI。结节的分割从具有手动 ROI 的 (a) 列开始, 并在 (f) 列结束。传统 ROI (以红色和蓝色表示) 在每个切片中是相同的, 而自适应 ROI (以绿色表示) 在每个切片中具有不同的位置和大小。在传统方法中, 当 ROI 保持接近初始切片中的结节时 (如红色所示), 它无法覆盖其他切片中存在的结节区域, 需要一个恒定且较大的 ROI (以蓝色表示) 来包含跨越所有切片结节的完整区域。这种方法还将冗余信息添加到 ROI 中, 这会影响分割模型的性能。另外, 本文自适应 ROI 策略不仅使用户能够选择 ROI 而无须查看其他切片, 还为剩余切片选择最佳 ROI, 以促进分割模型性能的提高。在确定下一个 ROI 的位置之后, 算法确定 ROI 的最佳尺寸。ROI 的形状保持为正方形, 以便计算出的 ROI 每条边具有相同的长度。该算法保留了 A_N 和




图 2 本文方法的两个阶段




图3 A-ROI算法效果




图4 A-ROI算法整体效果

A_{ROI} 之间的比值, 该比值小于所选比值阈值 (R_T) 的恒定值。 R_T 值至关重要, 因为它决定了下一切片选择的 ROI 大小, 这与两个相邻切片内结节的最大可能移动直接相关。像素对应实际空间距离 d 。当切片厚度为 T 时, 为避免结节因切片增厚而被截断, ROI 在轴向的覆盖范围需至少包含完整结节, 而在横断面上 (X - Y 轴) 的覆盖范围需与轴向匹配, 形成近似立方体的 3D ROI。因此, ROI 的像素边长 $S(T)$ 需满足 $S(T) \cdot d \geq \alpha \cdot T$ ($\alpha \approx 1.2$), 化简得 $S(T) \geq \frac{\alpha T}{d}$, 即 $S(T)$ 与 T 成正比。因此

$$R_T \propto \frac{1}{S(T) \times T} \quad (1)$$

R_T 的最佳值通过使用验证数据进行实验确定, 并在第3节中进行讨论。最终, A-ROI算法倾向于保留条件

$$R_T \leq \frac{A_N}{A_{ROI}} \quad (2)$$

其中, A_{ROI} 的最小可能值可以等于 A_N , 因此 $R_T \in (0, 1)$ 。如果 $\frac{A_N}{A_{ROI}} > R_T$, 则算法计算 ROI 的当前面积 (A_{ROI_i}) 和下一切片 ROI 的所需面积 ($A_{ROI_{i+1}}$) 之间的差值 (ΔA)。然后, 利用 ΔA 来更新 ROI 的坐标以获得所需尺寸。

采用 V-Net 架构进行结节分割, 该网络通过残差连接和跳跃连接优化了信息流动。V-Net 体系结构如图5所示, 沿着轴向与 A-ROI 算法一起使用, 以执行肺结节分割。网络包含编码、桥接和解码3部分: (1) 编码部分通过4个残差单元逐步压缩输入图像 (每个单元使用步长2卷积替代池化进行下采样); (2) 桥接部分连接编码和解码路径; (3) 解码部分同样包含4个残差单元, 通过上采样和特征拼接逐步恢复空间信息。每个残差单元由两个 3×3 卷积块组成, 包含批归一化、ReLU激活和卷积层, 并保留恒等映射。最终通过 1×1 卷积和 Sigmoid 激活输出分割结果。这种设计以较少参数实现了高效特征学习, 显著提升了分割性能。

沿着轴向执行逐片分割的残差连接网络结构见表1, 列出了每个步骤的参数和输出大小。

这个最佳值是通过最小化 $\text{Net}(I_i, W)$ 生成的分割和真值 S_i 之间的损失来实现的。本文使用骰子相似系数 (DSC) 作为损失函数

$$L(W) = \frac{1}{N} \sum_{i=1}^N \left[1 - \frac{2 \times \text{Net}(I_i, W) \cap S_i}{\text{Net}(I_i, W) \cup S_i} \right] \quad (3)$$

其中, N 是训练样本数量。使用随机梯度下降




图5 V-Net体系结构

表 1 沿着轴向执行逐片分割的残差连接网络结构

Unit level	Conv layer	Filter	Stride	输出大小
输入				128×128×1
Level 1	Conv 1	3×3/64	1	128×128×64
	Conv 2	3×3/64	1	128×128×64
Level 2	Conv 3	3×3/128	2	64×64×128
	Conv 4	3×3/128	1	64×64×128
Level 3	Conv 5	3×3/256	2	32×32×256
	Conv 6	3×3/256	1	32×32×256
Level 4	Conv 7	3×3/512	2	16×16×512
	Conv 8	3×3/512	1	16×16×512
Level 5	Conv 9	3×3/1 024	2	8×8×1 024
	Conv 10	3×3/1 024	1	8×8×1 024
Level 6	Conv 11	3×3/512	1	16×16×512
	Conv 12	3×3/512	1	16×16×512
Level 7	Conv 13	3×3/256	1	32×32×256
	Conv 14	3×3/256	1	32×32×256
Level 8	Conv 15	3×3/128	1	64×64×128
	Conv 16	3×3/128	1	64×64×128
Level 9	Conv 17	3×3/64	1	128×128×64
	Conv 18	3×3/64	1	128×128×64
输出	Conv 19	1×1	1	128×128×1

表 2 沿着冠状轴和矢状轴执行逐片分割的残差连接网络结构

Unit level	Conv layer	Filter	Stride	输出大小
输入				128×64×1
Level 1	Conv 1	3×3/64	1	128×64×64
	Conv 2	3×3/64	1	128×64×64
Level 2	Conv 3	3×3/128	2	64×32×128
	Conv 4	3×3/128	1	64×32×128
Level 3	Conv 5	3×3/256	2	32×16×256
	Conv 6	3×3/256	1	32×16×256
Level 4	Conv 7	3×3/512	2	16×8×512
	Conv 8	3×3/512	1	16×8×512
Level 5	Conv 9	3×3/256	1	32×16×256
	Conv 10	3×3/256	1	32×16×256
Level 6	Conv 11	3×3/128	1	64×32×128
	Conv 12	3×3/128	1	64×32×128
Level 7	Conv 13	3×3/64	1	128×64×64
	Conv 14	3×3/64	1	128×64×64
输出	Conv 15	1×1	1	128×64×1

(SGD) 来训练本文网络。

本文方法的第 2 阶段被拆分成两个阶段。阶段一采用沿着冠状轴和矢状轴的逐片结节分割, 阶段二根据所有估计的结节分割重建结节的最终 3D 分割掩模。从阶段一提取的 VOI 被用于两个网络独立地沿着冠状轴和矢状轴执行逐片结节分割。考虑切

片厚度通常大于 x - y 平面中体素间距的事实, 将冠状面和矢状面的大小调整为 128×64。使用与阶段一期间类似的深度残差 V-Net 体系结构来执行分割。然而, 由于图像尺寸较小, 级别数目减少到 7 个 (即 3 个编码单元、1 个桥接单元和 3 个解码单元), 这减少了网络参量。用于沿着冠状轴和矢状轴执行逐

片分割的残差连接网络结构见表2。将每个模型的输出大小调整为ROI的原始大小（原始大小是指从扫描中提取ROI的大小）。最后，在阶段一执行相同的方式连接所有推断，重建结节的3D分割。

在获得每个平面的结节分割后，应用共识模块来计算最终分割。分割掩模的第 k 个一致性像素 c_k 的值被计算为

$$c_k = \Gamma \left[\sum_{i=0}^{M-1} S_{ki} \right], k \in [0, N-1] \quad (4)$$

其中， S 表示估计分割， M 是估计数量（本文为3个，轴向、冠状和矢状）， N 是VOI中的总体素数，并且 Γ 被定义为

$$\Gamma(g) = \begin{cases} 1, g \geq (M \cdot C_R) \\ 0, \text{其他} \end{cases} \quad (5)$$

其中， C_R 是一致性比率，设定为0.5。

2 实验设置

2.1 数据集和预处理

本文采用公开数据集LUNA16和LNDb进行实验验证。LUNA16数据集包含888例标注CT扫描数据，LNDb数据集包含294例CT扫描数据。为统一实验标准，所有CT图像均经过预处理：首先，去除扫描边界冗余信息，将原始512×512图像以肺部区域为中心裁剪至400×400；随后，进行窗宽窗位调整以标准化灰度范围。实验共使用LUNA16的800例标注数据和LNDb的200例未标注数据进行训练，另选取LUNA16的88例和LNDb的46例作为测试集。通过随机旋转（±15°）、高斯噪声（ $\sigma=0.01$ ）和弹性变形等数据增强方法，最终扩增训练样本至10 000例。实验基于PyTorch框架搭建，使

用NVIDIA RTX 3090显卡，优化器选用Adam，初始学习率为0.001，训练轮次为700，批量大小为16。DICOM图像的强度也通过利用关于窗口中心（WC）和窗口宽度（WW）的DICOM标签信息从0到1进行归一化。归一化计算式定义为

$$I_{\text{normalized}} = \frac{I - \text{Min}}{\text{Max} - \text{Min}} \quad (6)$$

其中， $\text{Min}=\text{WC}-\text{WW}/2$ ， $\text{Max}=\text{WC}+\text{WW}/2$ ， I 表示原始图像， $I_{\text{normalized}}$ 表示归一化图像。

模型训练过程的准确率-训练轮次曲线如图6所示，模型初始基准准确度为0.31，经过快速提升期主要学习基础结节形态特征，提升至0.42；随后在精细调整期（150~400 epoch）进一步学习复杂边界，实现0.12的增益。最终在收敛稳定期（400 epoch后）稳步收敛，验证准确度稳定在0.83±0.02，验证和训练曲线间距保持在0.03~0.07，显示出模型良好的正则化和泛化能力。

2.2 评估参数

本文使用以下参数来评估所提方法的性能。

（1）骰子相似系数（DSC）。式(7)定义了骰子相似系数，是广泛使用的参数以评估预测片段（ S_{Pred} ）与参考片段（ S_{Ref} ）的重叠程度。DSC值范围为[0, 1]，而0和1分别表示没有重叠和完全重叠。

$$\text{DSC} = \frac{2 \times S_{\text{Pred}} \cap S_{\text{Ref}}}{S_{\text{Pred}} \cup S_{\text{Ref}}} \quad (7)$$

（2）灵敏度和阳性预测值。通过灵敏度和阳性预测值来衡量分割区域的像素分类性能和正确性，其定义为

$$\text{SEN} = \frac{S_{\text{Pred}} \cap S_{\text{Ref}}}{S_{\text{Ref}}} \quad (8)$$




图6 模型训练过程的准确率—训练轮次曲线

$$PPV = \frac{S_{Pred} \cap S_{Ref}}{S_{Pred}} \quad (9)$$

(3) Hausdorff 距离。Hausdorff 距离是另一个常用的度量标准,用于评估医学分割,它测量两组点之间的不相似性。两个点集 S_{Pred} 和 S_{Ref} 之间的有向 Hausdorff 距离 (H) 是每个点 $x \in S_{Ref}$ 到其最近邻点 $y \in S_{Pred}$ 之间的最大距离,即

$$H(S_{Ref}, S_{Pred}) = \max_{x \in S_{Ref}} \{ \min_{y \in S_{Pred}} \{ \|x, y\| \} \} \quad (10)$$

其中, $\|\cdot, \cdot\|$ 是欧氏范数。 $H(S_{Ref}, S_{Pred}) \neq H(S_{Pred}, S_{Ref})$, 则有向 Hausdorff 距离是不对称的。HD 是两个方向上有向 Hausdorff 距离的最大值,因此它是对称的。HD 由式(11)给出

$$HD(S_{Ref}, S_{Pred}) = \max \{ H(S_{Ref}, S_{Pred}), H(S_{Pred}, S_{Ref}) \} \quad (11)$$

各种分割方法定量结果的平均值 $\pm$ 标准差见表3。

2.3 定性分析

改进模型在 LUNA16 数据集上的分割可视化结果如图7所示,改进模型在 LNDb 数据集上的分割可视化结果如图8所示。相较于经典 U-Net 在胸膜粘连型结节分割中出现的边界模糊问题,以及 ResU-Net 对小于 5 mm 微小结节敏感性不足的局限,本文模型展现出显著优势:在不规则毛玻璃结节 (GGN) 分割中达到 89.5% 的 Dice 系数,通过跨维度注意力机制精准捕捉分叶状结节的锐利边缘结构,并在 LNDb 含伪影数据中将假阳性^[17-18]率降至 8.7% (U-Net 为 15.3%)。这些改进主要得益于三维残差稠密块 (3D-RDB) 对多尺度特征的保留能力,以及动态轴向注意力 (DAA) 对复杂形态的

增强建模能力,虽然对极稀疏微小结节 (<3 mm) 的分割仍存在提升空间,但整体性能显著优于基线模型,SDA-Net 不仅可以目标的整体轮廓分割出来,对于尖锐的细节分割也比较接近本文方法,由分割结果可知,本文方法具有较优的分割性能。

2.4 消融实验

本文通过消融实验验证了各关键模块的作用,在 LUNA16 数据集上不同模块间的消融实验结果见表4,在 LNDb 数据集上不同模块间的消融实验结果见表5。基线 V-Net 模型仅使用轴向切片信息时 Dice 系数为 86.4%;引入自适应 ROI 算法后性能提升至 89.1% (+2.7%),显著改善了初始定位精度;进一步加入冠状面/矢状面分析模块使 Dice 系数达到 91.3% (+2.2%),证实了多平面信息的重要性;最终整合残差连接和共识模块后,模型性能达到 92.6% 的 Dice 系数。本文方法敏感性达到 81.21%,准确率达到 85.91%,各项指标都有明显提升。实验结果表明,自适应 ROI 选择有效解决了传统固定 VOI 的边界限制问题 (边界误差减少 37.5%),而多平面协同分析显著提升了分割的几何一致性 (形状相似度提高 29.8%),各模块的渐进式改进充分验证了本文方法的有效性。

在 LUNA16 数据集上损失函数消融实验结果见表6,在 LNDb 数据集上损失函数消融实验结果见表7。在损失函数对比实验中,联合使用分割损失 (L_{seg}) 和符号距离场损失 (L_{SDF}) 取得了优于单一损失函数的效果,而一致性损失 (L_c) 的引入进一步提升了模型性能。

表3 各种分割方法定量结果的平均值 $\pm$ 标准差

方法	DSC	SEN	PPV
Transformer ^[19]	80.11% $\pm$ 10.38%	-	81.22% $\pm$ 17.13%
nnU-Net ^[20]	83.51% $\pm$ 11.33%	-	-
Residual U-Net with attention ^[21]	82.67% $\pm$ 11.71%	86.62% $\pm$ 12.83%	-
Swin-UNet ^[22]	81.30% $\pm$ 10.57%	87.87% $\pm$ 14.31%	-
Multi-crop-CNN ^[23]	77.50% $\pm$ 11.41%	82.82% $\pm$ 12.33%	71.42% $\pm$ 14.77%
Multi-view-CNN ^[24]	75.88% $\pm$ 13.00%	87.15% $\pm$ 12.90%	70.82% $\pm$ 17.57%
Multi-view deep-CNN ^[25]	77.85% $\pm$ 12.93%	86.95% $\pm$ 15.72%	77.33% $\pm$ 13.28%
Cascaded dual-pathway Res-Net ^[26]	81.58% $\pm$ 11.03%	87.31% $\pm$ 14.33%	-
Unsupervised metaheuristic-search ^[27]	82.34% $\pm$ 5.41%	-	85.60% $\pm$ 11.05%
Constant ROI with multi-view residual learning ^[28]	84.35% $\pm$ 11.73%	89.01% $\pm$ 8.92%	86.72% $\pm$ 10.19%
结合多视图残差学习的 A-ROI (A-ROI with multi-view residual learning)	87.53% $\pm$ 10.60%	91.62% $\pm$ 8.48%	88.26% $\pm$ 9.51%




图7 改进模型在LUNA16数据集上的分割可视化结果




图8 改进模型在LNDb数据集上的分割可视化结果

表4 在LUNA16数据集上不同模块间的消融实验结果

方法	DSC	敏感性	准确率
基线 V-Net	86.4%	77.81%	81.92%
引入自适应ROI算法	89.1%	78.63%	83.87%
加入冠状面/矢状面分析模块	91.3%	80.02%	84.33%
本文方法	92.6%	81.21%	85.91%

表5 在LNDb数据集上不同模块间的消融实验结果

方法	DSC	敏感性	准确率
基线 V-Net	86.2%	77.51%	81.76%
引入自适应ROI算法	89.6%	78.44%	82.57%
加入冠状面/矢状面分析模块	91.1%	79.08%	84.13%
本文方法	92.3%	81.08%	83.86%

表6 在LUNA16数据集上损失函数消融实验结果

损失	DSC	敏感性	准确率
L_{seg}	77.34%	75.02%	82.57%
L_{SDF}	78.77%	75.88%	83.99%
$L_{seg} + L_{SDF}$	80.02%	76.82%	85.39%
$L_{seg} + L_{SDF} + L_c$	80.59%	77.61%	86.75%

表7 在LNDb数据集上损失函数消融实验结果

损失	DSC	敏感性	准确率
L_{seg}	76.84%	74.07%	82.11%
L_{SDF}	78.85%	74.18%	83.57%
$L_{seg} + L_{SDF}$	80.11%	76.99%	84.32%
$L_{seg} + L_{SDF} + L_c$	80.89%	76.61%	86.73%

3 讨论

本文在LUNA16和LNDb数据集上进行了各种实验，以评估本文方法的性能。

3.1 性能对RT值的敏感性

本文使用不同 R_T 值进行多次实验，以获得其最佳值，从而显示 R_T 值的范围及其各自的整体性能。随着 R_T 值的增加，性能也增加，直到达到特

定点, 之后性能下降。代表较大 ROI 的低 R_T 值性能降低, 因为 ROI 不集中在单个结节上, 并且包括冗余信息或非结节结构。这些无关信息使得分割过程具有挑战性, 从而降低了整体性能。另外, 当选择高 R_T 值时, ROI 不仅聚焦于结节, 还保持非常接近结节边界, 这不足以处理结节在相邻切片上的小位移。因此, 适当的 R_T 值提供最佳性能, 全文在所有实验使用相同的 R_T 值。

3.2 整体性能

使用多种评价参数对所提方法的整体性能进行评估。自适应 ROI 方法显著优于已有的最新方法。为了验证其有效性, 还采用了结合多视图残差学习的恒定 ROI 方法, 该方法同样优于未用于结节分割的传统方法, 反映出残差学习的优势。实验结果表明, 自适应 ROI 提升了约 3% 平均 DSC 值, 主要因其缩小了 ROI 范围, 专注结节区域, 剔除冗余信息, 辅助残差 V-Net 更准确地进行结节与非结节分类。相比之下, 恒定 ROI 需覆盖更大区域以包容完整结节形态, 反而影响了模型性能。所提方法两个阶段的 Hausdorff 距离和平均 Dice 系数见表 8, 各视图(轴向、冠状、矢状)在 Hausdorff 距离方面的表现略有差异。轴向视图的距离最小 (2.76 mm), 表明其边界更接近真实边界; 矢状视图次之 (3.41 mm), 冠状视图最差 (4.77 mm)。在 Dice 系数方面, 融合共识模块后整体性能最佳, 达到 87.53%, 明显优于单一视图(平均在 83.59%~85.29%), 显示出多视图融合提高了分割的准确性和一致性。总体而言, 多视图结合共识策略能有效改善边界精度和重叠程度。

单例 CT 扫描分割硬件适应性见表 9。本文方法适用性相对其余 3 种方法更优。其图形处理器

表 8 所提方法两个阶段的 Hausdorff 距离和平均 Dice 系数

对比项	Coronal	Axial	Sagittal	Consensus
Hausdorff 距离/mm	4.77±2.21	2.76±1.69	3.41±1.93	2.92±1.89
平均 Dice 系数	84.76% ±12.48%	85.29% ±9.80%	83.59% ±8.92%	87.53% ±10.60%

(GPU, graphics processing unit) 耗时 1.27 s、中央处理器 (CPU, central processing unit) (Intel i7-12700K) 耗时 9.83 s, 均显著低于 U-Net、SDA-Net 与 ResU-Net, 硬件适应性为 7.74, CPU 与 GPU 性能差异适中, 对不同硬件兼容度较好。不过, 其 GPU 耗时未达临床实时理想耗时阈值 0.5 s, CPU 耗时超过 10 s, 暂无法满足术中引导等极低延迟场景。经模型量化、加速等优化后, 可用于门诊常规影像阅片、基层半实时诊断等场景, 而其余 3 种方法因速度过慢, 基本不适用。

表 9 单例 CT 扫描分割硬件适应性

方法	耗时/s		硬件适应性
	GPU	CPU (Intel i7-12700K)	
U-Net ^[29]	2.86	21.35	7.46
SDA-Net ^[30]	3.17	25.49	8.04
ResU-Net ^[31]	2.53	18.92	7.48
本文方法	1.27	9.83	7.74

3.3 视觉分析

将各阶段的分割结果以可视化方式展示, 用以分析模型性能。所提方法分割结果如图 9 所示。在图 9(a)~(c) 中, 展示了在轴向、冠状和矢状视图中经过不同处理后的输出, 最后一列为共识模块的结果。实验中随机选取了附着、非附着和极细微的结




图 9 所提方法分割结果

节。结果显示, 自适应ROI和残留学习显著提升了轴向视图的分割性能。然而, 当结节沿 z 轴穿透高于 x - y 平面时, 冠状和矢状视图的性能略有提升。在少数情况下, 遵循共识模块后性能有所下降。

4 结束语

本文提出的两阶段肺结节分割方法, 结合自适应ROI和多视角三维策略, 通过动态调整ROI、多平面分析及共识融合, 显著提升了结节分割的准确性和边界精度。实验证明, 该方法在LUNA16和LNDb数据集上达到了优异的性能, Dice系数超过92%, 且Hausdorff距离明显优于传统方法。消融分析进一步验证了自适应ROI和多视角融合在改善边界误差和形状一致性方面的有效性。该技术有效应对结节多变形态和模糊边界问题, 为临床肺结节的精准诊断提供了可靠的技术支持。

展望未来, 将进一步扩展该框架, 通过整合患者时序CT扫描数据, 开发基于时间演变的结节恶性度预测模型, 为临床诊断提供动态分析支持。

参考文献:

- [1] 钟睿康, 李靖华, 林熙明, 等. 深度学习在非小细胞肺癌预后模型中的应用进展[J]. 中国胸心血管外科临床杂志, 2024, 31(9): 1345-1350.
- [2] 谢娟英, 张凯云. SOSNet: 一种非对称编码器-解码器结构的非小细胞肺癌CT图像分割模型[J]. 电子学报, 2024, 52(3): 824-837.
- [3] Xie J Y, Zhang K Y. SOSNet: an asymmetric encoder-decoder structure model for automatic segmenting non-small cell lung cancer CT images[J]. Acta Electronica Sinica, 2024, 52(3): 824-837.
- [4] Usman M, Latif S, Asim M, et al. Retrospective motion correction in multishot MRI using generative adversarial network[J]. Scientific Reports, 2020, 10: 4786.
- [5] 梁礼明, 周珑颂, 余洁, 等. 多尺度特征融合双U型视网膜分割算法[J]. 光电子·激光, 2022, 33(3): 272-282.
- [6] Liang L M, Zhou L S, Yu J, et al. Multi scale feature fusion double U-shaped retinal segmentation algorithm[J]. Journal of Optoelectronics·Laser, 2022, 33(3): 272-282.
- [7] Alom M Z, Hasan M, Yakopcic C, et al. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation[PP]. V5. arXiv (2018-05-29)[2022-03-02]. arXiv: 1802.06955.
- [8] Kucharski D, Kleczek P, Jaworek-Korjakowska J, et al. Semi-supervised nests of melanocytes segmentation method using convolutional autoencoders[J]. Sensors, 2020, 20(6): 1546.
- [9] Wang Z R, Men J R, Zhang F C. Improved V-Net lung nodule segmentation method based on selective kernel[J]. Signal, Image and Video Processing, 2023, 17(5): 1763-1774.
- [10] Chen Y C, Zhang Y F, Zhang X D, et al. Characterization of adrenal glands on computed tomography with a 3D V-Net-based model[J]. Insights into Imaging, 2025, 16: 17.
- [11] 肖宏宇, 杨伟东, 王琦. 基于深度学习的双期相CT肝癌检测算法[J]. 光电子·激光, 2025: 1-10.
- [12] Xiao H Y, Yang W D, Wang Q. A deep learning-based algorithm for dual-phase CT liver cancer detection[J]. Journal of Optoelectronics·Laser, 2025: 1-10.
- [13] Liu H, Cui S W, Zhao X H, et al. Detection of obstructive sleep apnea from single-channel ECG signals using a CNN-transformer architecture[J]. Biomedical Signal Processing and Control, 2023, 82: 104581.
- [14] 卢娟, 汤铁群, 张荣福, 等. 融合多特征和注意力机制的肺结节分割算法[J]. 小型微型计算机系统, 2023, 44(1): 43-48.
- [15] Lu J, Tang T Q, Zhang R F, et al. Lung nodule segmentation algorithm fusing multi-feature and attentional mechanism[J]. Journal of Chinese Computer Systems, 2023, 44(1): 43-48.
- [16] 李奇翰, 周雪芳, 徐远胜. 基于DNA置乱和光混沌医学多CT图像加密算法研究[J]. 光电子·激光, 2025: 1-12.
- [17] Li Q H, Zhou X F, Xu Y S. Research on medical multi-CT image encryption algorithm based on DNA scrambling and optical chaos[J]. Journal of Optoelectronics·Laser, 2025: 1-12.
- [18] 王伯霄, 宋延嵩, 董小娜. 难点注意力感知红外小目标检测网络[J]. 中国光学, 2024, 17(3): 538-547.
- [19] Wang B X, Song Y S, Dong X N. Indistinguishable points attention-aware network for infrared small object detection[J]. Chinese Optics, 2024, 17(3): 538-547.
- [20] Zhu X Y, Wang X H, Shi Y T, et al. Channel-wise attention mechanism in the 3D convolutional network for lung nodule detection[J]. Electronics, 2022, 11(10): 1600.
- [21] Zhu H G, Dai L W, Liu Y T, et al. A three-dimensional bit-level image encryption algorithm with Rubik's cube method[J]. Mathematics and Computers in Simulation, 2021, 185: 754-770.
- [22] Shuvo M B, Ahommed R, Reza S, et al. CNL-UNet: a novel lightweight deep learning architecture for multimodal biomedical image segmentation with false output suppression[J]. Biomedical Signal Processing and Control, 2021, 70: 102959.
- [23] Lama N, Hagerty J, Nambisan A, et al. Skin lesion segmentation in dermoscopic images with noisy data[J]. Journal of Digital Imaging, 2023, 36(4): 1712-1722.
- [24] Upadhyay S, Beevi A S, Kalady S. Left ventricle segmentation of 2D echocardiography using deep learning[C]//Proceedings of the Conference on Computer Vision and Image Processing. Berlin: Springer, 2023: 87-98.
- [25] Li X T, Jiang A L, Qiu Y F, et al. TPFR-Net: U-shaped model for lung nodule segmentation based on transformer pooling and dual-

- attention feature reorganization[J]. Medical & Biological Engineering & Computing, 2023, 61(8): 1929-1946.
- [20] Carles M, Kuhn d, Fechter T, et al. Correction: Development and evaluation of two open-source nnU-Net models for automatic segmentation of lung tumors on PET and CT images with and without respiratory motion compensation[J]. European Radiology, 2024, 34(12): 8039.
- [21] Lafraxo S, El Ansari M, Koutti L, et al. SEDARU-Net: a squeeze-excitation dilated based residual U-Net with attention mechanism for automatic melanoma lesion segmentation[J]. Multimedia Tools and Applications, 2025, 84(21): 23935-23962.
- [22] Sreekumar S P, Palanisamy R, Swaminathan R. An approach to segment nuclei and cytoplasm in lung cancer brightfield images using hybrid swin-unet transformer[J]. Journal of Medical and Biological Engineering, 2024, 44(3): 448-459.
- [23] Sweetline B C, Vijayakumaran C, Samydrurai A. Overcoming the challenge of accurate segmentation of lung nodules: a multi-crop CNN approach[J]. Journal of Imaging Informatics in Medicine, 2024, 37(3): 988-1007.
- [24] Zhu L, Wang Y S, Huang A A, et al. A multi-branch, multi-scale, and multi-view CNN with lightweight temporal attention mechanism for EEG-based motor imagery decoding[J]. Computer Methods in Biomechanics and Biomedical Engineering, 2025: 1-15.
- [25] Lv Z G, Xu B Y, Zhong L H, et al. Improved monitoring of southern corn rust using UAV-based multi-view imagery and an attention-based deep learning method[J]. Computers and Electronics in Agriculture, 2024, 224: 109232.
- [26] Ben Slama A, Sahli H, Amri Y, et al. Res-Net-VGG19: improved tumor segmentation using MR images based on Res-Net architecture and efficient VGG gliomas grading[J]. Applications in Engineering Science, 2023, 16: 100153.
- [27] Elham S, Antonio C, Guilherme A, et al. An unsupervised meta-heuristic search approach for segmentation and volume measurement of pulmonary nodules in lung CT scans[J]. Expert Systems with Applications, 2020, 119: 415-428.
- [28] Usman M, Lee B D, Byon S S, et al. Volumetric lung nodule segmentation using adaptive ROI with multi-view residual learning[J]. Scientific Reports, 2020, 10: 12839.
- [29] Jayapradha J, Haw S C, Palanichamy N, et al. IM-LTS: an integrated model for lung tumor segmentation using neural networks and IoMT[J]. MethodsX, 2025, 14: 103201.
- [30] Li M L, Zhou H, Li X, et al. SDA-Net: self-distillation driven deformable attentive aggregation network for thyroid nodule identification in ultrasound images[J]. Artificial Intelligence in Medicine, 2023, 146: 102699.
- [31] Liu J, Suo G D, Jin F Q, et al. WGAN-based multi-structure segmentation of vertebral cross-section MRI using ResU-Net and clustered transformer[J]. Scientific Reports, 2024, 14: 27474.

[作者简介]



杨国虎(1998-), 男, 宁夏大学电子与电气工程学院硕士生, 主要研究方向为模式识别与图像处理。



刘平(1981-), 男, 博士, 宁夏大学电子与电气工程学院副教授, 主要研究方向为通信系统、物联网应用。



金雨纯(1997-), 女, 宁夏大学电子与电气工程学院硕士生, 主要研究方向为模式识别与图像处理。



甄元元(2000-), 女, 宁夏大学电子与电气工程学院硕士生, 主要研究方向为模式识别与图像处理。