

doi:10.3969/j.issn.1673-9833.2025.05.007

基于 RSE-Vnet 卷积网络的肺结节分割方法研究

闫永强¹, 秦 斌²

(1. 湖南工业大学 计算机学院, 湖南 株洲 412007; 2. 湖南工业大学 交通与电气工程学院, 湖南 株洲 412007)

摘 要: 针对在细粒度图像的分割任务中容易出现欠分割与漏检的问题, 提出一种改进的端到端 3D 分割算法——RSE-Vnet。加入 Res2net 网络捕获不同结节的多尺度细粒特征, 为网络馈送更多精准的结节位置信息; 同时残差连接避免了网络退化问题, 建立了结节数据驱动模型; 注意力机制能够有效为重要特征通道自适应加权, 减少背景图像的干扰。构建的方法在一定程度上解决了多类型结节欠分割和漏检问题, 最终在 LUNA16 数据集中得以验证, 模型 DSC 提升了 7%, 检测灵敏度提升了 6%。

关键词: 计算机辅助诊断; 多尺度细粒特征; 注意力; Res2net 网络; 多类型结节

中图分类号: TP183

文献标志码: A

文章编号: 1673-9833(2025)05-0046-06

引文格式: 闫永强, 秦 斌. 基于 RSE-Vnet 卷积网络的肺结节分割方法研究 [J]. 湖南工业大学学报, 2025, 39(5): 46-51.

Research on Lung Nodule Segmentation Method Based on RSE-Vnet Convolutional Network

YAN Yongqiang¹, QIN Bin²

(1. School of Computer, Hunan University of Technology, Zhuzhou Hunan 412007, China;

2. School of Transportation and Electrical Engineering, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: In view of the flaws of under-segmentation and missed detection in fine-grained image segmentation tasks, an improved end-to-end 3D segmentation algorithm, RSE-Vnet, has thus been proposed. With Res2net network incorporated, multi-scale fine-grained features of different nodules can be captured, thus feeding more accurate nodule location information to the network. Meanwhile, residual connections help to avoid network degradation issues, thus establishing a data-driven model for nodules. The attention mechanism can effectively weight important feature channels so as to reduce the interference of background images, with the constructed method solving the problem of under-segmentation and missed detection of multiple types of nodules to some extent. Finally, it can be verified in the LUNA16 dataset, with a 7% increase in model DSC and a 6% increase in detection sensitivity specifically.

Keywords: computer-aided diagnosis; multi-scale fine-grained feature; attention; Res2net network; multi-typed nodule

0 引言

由于肺结节内部密度不均匀、外部形态多样、结节与肺部血管和胸腔易发生粘连, 给结节分割带来了

难度。在传统结节分割方法中, Ren H. 等^[1]在改进的区域生长方法中, 利用数据集提供的结节坐标信息, 在分割图像前景信息中评估周围像素的相似性, 将三维 CT 图像中的结节进行连续性分割, 其方法能

收稿日期: 2025-03-20

基金项目: 湖南省自然科学基金资助项目 (2023JJ50166)

作者简介: 闫永强, 男, 湖南工业大学硕士生, 主要研究方向为医学图像, E-mail: 3200363063@qq.com

通信作者: 秦 斌, 男, 湖南工业大学教授, 主要研究方向为复杂电气系统测控技术及应用, E-mail: 857275307@qq.com

够较完整地提取出重要的结节信息。但由于结节周围的肺部组织与真实结节像素具有一定相似度,部分结节图像在预处理后还具有一定的噪声干扰,容易使该方法在分割结节图像中出现边缘欠分割的现象。在聚类算法中,Liu H. 等^[2]提出的自适应 FCM 聚类算法实现了速度更快与精度更高的结节分割,但对直径小于 10 mm 的结节分割效果不佳。在后续研究中,Li X. X. 等^[3]使用 GMM (Gaussian mix-ture mode) 统计方法,将结节先验信息引入传统 FCM 算法中,通过消除结节强度不均匀和周围组织的干扰,大幅度提升了分割精度。这种传统的分割方式本质上是基于数学方法,其鲁棒性强、无需标签且计算资源损耗小,但依赖于人工标注。随着深度学习的发展,神经网络在肺结节研究中逐渐引起较多研究者的注意。邓忠豪等^[4]改进了 Unet 网络,减少了模型计算量,解决了传统算法检测灵敏度不足的问题。钟思华等^[5]使用密集连接模块改进 Unet,提高了网络对特征的复用性,有效建立了不同层次特征之间的联系。Tong G. F. 等^[6]提出一种基于改进的 U-Net 的肺结节分割算法,利用跳跃连接学习输入与输出之间的图像信息,提高了网络对结节权重参数的调整能力,其深层网络模式也增强了模型对结节抽象特征的提取。该方法在 Luna16 上进行实验验证,肺结节分割系数 DSC (dice similarity coefficient) 的结果为 73.6%。

针对这些问题,本文提出一种改进的 RSE-Vnet 网络。多尺度信息对于小型结节的分割极为重要,由于小型结节在图像中所占比例较小,其特征不够明显,模型容易出现漏检和误判。利用结节多尺度信息能够更精准地定位图像中的结节部分,解决了网络对于多类型结节检测灵敏度低与欠分割的问题。

1 算法设计

1.1 Vnet 网络结构

Vnet 网络是一种专门用于医学图像分割的模型,其基础模块是 3D 全卷积技术^[7],如图 1 所示。




图 1 Vnet 基础网络结构

Fig. 1 Vnet basic network structure

如图 1 所示,该网络结构分为左右两部分:左侧是压缩路径,右侧则是解压缩路径。该网络对细粒度多类型结节图像的分割效果较好。在压缩路径中,提取图像的深层结节特征。为了减小特征图的尺寸,Vnet 网络采用增加卷积步长的方式进行图像下采样,并在网络中间使用残差连接,模型通过融合图像原始输入特征,防止网络在深层学习过程中丢失结节位置信息。解压缩路径中,利用反卷积技术将上一个模块的特征图进行上采样,使特征图的尺寸增大。这些上采样后的特征图会与压缩路径中对应大小的特征图进行拼接,可融合不同层次的特征信息。通过进一步的特征提取,实现对医学图像的高效分割。

1.2 Res2net 网络结构

网络的不断叠加也让训练过程出现梯度消失或者梯度爆炸的问题,残差网络 Resnet 有效地解决了这个问题^[8]。对于多类型结节分割任务,不同尺度信息包含不同的结节特征点信息。因此,能够在多个尺度上表达多类型结节特征非常重要。Res2net 在网络上改变了基本残差模块的内部结构,新模块用多组 $3 \times 3 \times 3$ 滤波器代替原滤波器,并将不同的卷积组进行组合。这种方式能够减少冗余的背景信息,模型参数能够充分表达结节特征信息。Res2net 模块使用了新的尺寸 ($scale=4$ ($scale$ 为尺度维度) 的特征组的数量),在 $1 \times 1 \times 1$ 卷积后转换为 8 个通道。另外, x_1 表示通道号为 1、2 的特征图, x_2 表示通道号为 3、4 的特征图;如果将通道分组后再训练,则每个分组通道训练卷积核的权重也是不同的。通过消融实验证明,该技术在结节分割任务中显示出较好的分割性能,如图 2 所示。




图 2 三维残差网络 (3D-Res2Net) 模块

Fig. 2 Three-dimensional residual network (3D-Res2Net) modules

从计算资源消耗上来说,虽然 Res2net 模块的计算负荷与残差网络架构相似,但分层连接的网络具有强大的多尺度特征提取能力,使得改进的网络架构能够在更细粒度的层面上表达多尺度特征。

1.3 SE 注意力模块

SE (squeeze-and-excitation) 注意力机制与 SK (selective kernel attention) 注意力机制, 在计算机视觉任务中应用广泛^[9-10]。注意力机制会根据输入数据的重要性, 进行自适应的加权特征处理。在本文中将其应用在模型的上采样阶段, 为结节特征数据提供自适应加权。在特征图融合过程中, 该方法使得模型既能有效复用特征, 又能减少背景图的干扰。SK 模型在处理多尺度特征时需要融合不同尺寸的特征图。当与 Res2net 网络结合时, 由于 Res2net 网络本身已经包含多个残差块与多尺度特征, 这些尺度特征的引入可能会产生额外的噪声干扰。而在结节数据等精细图像的处理中, 这种模糊与干扰降低了模型的准确性。因此本文采用 SE 模块, 其 SE 模块如图 3 所示。




图 3 SE 注意力模块

Fig. 3 SE attention module

图 3 中包含 Squeeze、Excitation、Scale 共 3 种操作。其中: Squeeze (压缩), 通过平均池化, 将多通道特征图压缩成一个单通道的全局特征表示; Excitation (激励), 利用两层全连接网络对压缩后的全局特征进行非线性变换, 其中第一层使用 ReLU 激活函数, 第二层使用 Sigmoid 函数, 用于生成每个通道的权重; Scale (缩放), 将得到的权重乘以原始的特征张量, 以强化重要特征并抑制次要特征, 提高模型的表征能力。

1.4 改进 Vnet 网络结构

将 Res2net 网络内嵌到 Vnet 网络中, 如图 4 所示。




图 4 改进的 Vnet 网络结构图

Fig. 4 Improved Vnet network structure diagram

细粒度级别的多尺度特征提取层, 通过多个感受野增强了网络的表征能力, 同时拓展了网络的深度。弥补了原网络层缺乏对卷积输入和输出的连续特征图拼接不足的缺点, 提高了特征复用率。在模型上采样中利用 SE 模块动态调整通道权重, 与下采样中的特征进行信息融合。在不增加过多计算负担的情况下,

提升了模型的检测灵敏度, 并降低了模型的漏检率。通过消融实验证明了改进的 Vnet 网络, 解决了模型对结节边界特征捕捉能力不足导致的欠分割现象。

通过消融实验可知, 轻量化的注意力模块能够在加入了 Res2net 结构的 Vnet 网络模型中, 发挥其优势, 增强网络识别结节特征的能力, 提升分割准确率与敏感度。

1.5 损失函数

Dice loss 是 Dice 系数的一种转化形式, 用作损失函数对模型进行优化。在肺结节分割中, 由于肺结节通常较小, 使用 Dice loss 可以使得模型更加关注这些小的目标区域。

课题组采用 Dice loss^[11-12] 损失函数, 并添加拉普拉斯平滑系数 (Laplace smoothing), 将其设为 1。该系数可以避免零除问题, 同时避免了网络的过拟合。当 Laplace smoothing 为 1 时, Dice loss 可以表示如下:

$$Diceloss = 1 - \frac{2|X \cap Y| + 1}{|X| + |Y| + 1} \quad (1)$$

式中: X 、 Y 分别为预测二值体和真实二值体; $X \cap Y$ 为两者重合点值的总和; $|X|$ 为预测二值体值的总和; $|Y|$ 为真实二值体值的总和。

2 实验与结果分析

2.1 数据集及预处理

LUNA16 (Lung Nodule Analysis 2016)^[13] 数据集排除了 LIDC-IDRI 数据集中切片厚度大于 3 mm、切边间隔不一致且出现部分切片丢失情况的 CT 文件, 最后产生了 888 张以 mhd 格式保存的 CT 文件。

由于数据集有不包含结节的图像, 以及其它不适用的图像, 因此在取出结节图像时过滤了数据集中的不相关图像, 这种方式也能够平衡结节和非结节的图像样本。在 LUNA16 的标注文件 XML 中, 包含了有关结节的各种特征描述。通过 XML 文件读取每个结节的位置和大小, 遍历 roi 避免肺部粘连。将图的标签信息处理好后, 将图乘以掩模, 再对图进行重采样, 并通过将像素值转换为 HU (亨氏单位) 值进行归一化和去均值, 本文 CT 图像预处理如图 6 所示。考虑计算资源, 保留 CT 图的大小为 $96 \times 96 \times 96$, 并将训练集、验证集和测试集比例划分为 8:1:1。




图 5 预处理 CT 图

Fig. 5 Preprocessed CT map

2.2 实验环境及参数设置

本次实验使用 Window10 操作系统,处理器为 Inter(R)Xeon(R)CPU E5-2680 v4@GHz (2 处理器),计算机内存为 64 GB。整个网络模型代码都使用 Python 3.7 版本进行编写,并用 Pytorch 深度学习框架进行网络搭建。同时使用显存为 11 455 MB 的 NVIDIA Tesla M40 显卡,在 GPU 上加速模型训练。

在实验中,将训练迭代次数 epoch 设置为 200,动量为 0.9,使其更容易落入低点。优化器使用 SGD,学习率衰减为原来的 10%。在训练过程中每 5 个 epoch 进行 1 次验证,如图 6~7 所示。




图 6 RSE-Vnet 模型训练损失

Fig. 6 RSE-Vnet model training loss




图 7 RSE-Vnet 模型验证损失

Fig. 7 RSE-Vnet model validation loss

如图 6~7 所示,改进后的模型在训练中损失下降到 0.4 后进入缓慢下降过程,在保存了 80 次训练损失后进入平缓阶段。

2.3 评测指标

在计算评测指标时会用到以下 4 个变量:真阳性 (true positive, TP), 实际为正样本,并被预测为正样本;假阳性 (false positive, FP), 实际为负样本,但被预测为正样本;真阴性 (true negative, TN), 实际为负样本,并被预测为负样本;假阴性 (false negative, FN), 实际为正样本,但被预测为负样本。医学图像分割中常用的评测指标如下。

DSC 是一种集合相似度度量指标,其值的范围是 0~1。DSC 展示了预测结节分割与真实结节分割之间的相似度。DSC 值越高,表示预测分割与真实分割越接近,其计算式如下:

$$DSC(A, B) = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (2)$$

式中: $|A \cap B|$ 为预测结节与实际结节重叠部分的大小; $|A|$ 为预测结节区域; $|B|$ 为实际结节区域。

TPR (true positive rate) 灵敏度,是指所有实际为正类别的样本中,模型能够正确预测为正类别的比例。在分割任务中,要确保正样本能够被正确识别,遗漏任何病变区域都会导致诊断错误。其计算式为

$$TPR = \frac{TP}{TP + FN} \quad (3)$$

PA 是评估模型分割正样本和负样本总数的正确率,其值为 [0, 1], 分割结果越靠近 1 越好,最差为 0。PA 越高,说明模型在区分正负样本方面的性能越好。计算式如下:

$$PA = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

F_1 分数 (F_1 score), 是精确率和召回率的调和平均数,最大为 1, 最小为 0^[14]。考虑了模型在识别正样本和避免误报方面的性能。其计算式如下:

$$F_1 = \frac{2TP}{2TP + FP + FN} \quad (5)$$

2.4 消融实验与对比

在 Vnet 网络上做了 3 次消融实验,其模型指标结果见表 1。

表 1 Vnet 网络消融实验结果

Table 1 Vnet network ablation experiment

实验模型	方法	灵敏度	DSC	PA	F_1
Vnet		0.693	0.701	0.996	0.720
Res2net-Vnet	3D	0.749	0.764	0.997	0.777
RSK-Vnet	3D	0.745	0.757	0.997	0.771
RSE-Vnet	3D	0.753	0.770	0.997	0.781

原 Vnet 的灵敏度、DSC、PA 与 F_1 分别为 0.693, 0.701, 0.996, 0.720。改进的 RSE-Vnet 网络得到的实验数据为 0.753, 0.770, 0.997, 0.781。Res2 模块中的残差单元允许网络学习并保留输入和输出之间的残差,这有助于网络学习更加丰富的特征表示。在本次任务中,这些丰富的特征可以帮助模型更好地捕捉图像中的细节和边缘信息,从而提升分割的准确性。Res2net 模块允许网络学习残差映射,因此网络在训练过程中可以更快地收敛到最优解。这有助于减少训练时间并提升训练效率,其实验结果表明 Res2net 模块对模型效果具有显著性提升。在训练过程中将 SE 嵌入上采样过程中,SE 模块会增强那些对任务有用的特征通道,并抑制那些对任务无用的特征通道,这有助于模型更加关注对任务有用的信息。SE 模块增加了一些

额外的参数和计算量,但这些额外的计算量相对于整个网络来说是非常小的。因此,在引入 SE 模块后,模型的计算复杂度与模型大小并没有显著增加,但性能却得到了提升。为验证本文方法的有效性,在表 2 中与其他文献中的改进方法进行了详尽的比较。

表 2 相关算法比较试验

Table 2 Correlation algorithm comparison tests

方 法	灵敏度	DSC	PA	F_1
Dual-Attention Network ^[15]		0.735	0.965	
2.5D Unet ^[16]		0.830		
MSDS-Unet ^[17]	0.746	0.675		0.682
Pyramid and Grab Cut ^[18]		0.875	0.933	
MSEV-net ^[19]		0.837	0.998	
RSE-Vnet	0.753	0.770	0.997	0.781

文献 [15] 提出的级联双注意力模块与具有上下文感知能力的金字塔特征提取模块。此方法分别在多中心肺炎、肺结节和肺结核数据上取得不错的测试效果。但是在结节测试数据上 DSC 表现力不足,说明该模型受限制于特定的应用场景中。文献 [16] 利用 3D Unet 作为定位,2.5D Unet 精确分割结节。但这种两阶段的分割方式,模型参数量大,不利于实现和应用。文献 [17] 很好地利用了深度监督与多尺度信息。深度监督在不同尺度引入监督信息,能在更精细的尺度上识别结节结构。分割结节的灵敏度较高,但还存在一定的漏检问题。文献 [18] 提出增强金字塔和改进分割方法,利用增强金字塔方法在模型中对不同类型的结节图像进行多尺度表征,增强网络对结节轮廓信息的提取能力,其模型预测结果较好地展示了对结节边缘的分割。文献 [19] 利用联合损失函数与多尺度特征,解决了区域特征小且不易分割的问题。而 RSE-Vnet 方法考虑多尺度特征信息,同时在上采样模块中,加入 SE 轻量级计算模块,关注模型中的重要通道特征。通过消融与对比可知,本文方法不仅在一定程度上解决了模型在处理多类型结节时的欠分割与漏检问题,还具有一定的实际应用价值。

2.5 模型参数(模型大小对比,运行时间对比)

实际应用中,通常要求在模型足够小的情况下进行部署和应用,降低应用成本。如表 3 所示,在提高分割精度的情况下,降低了模型复杂度,其测试时间也大幅缩短,为未来的应用部署提供了参考价值。

表 3 模型参数大小

Table 3 Size of the model parameters

模 型	权重大小 /MB	测试实际时间 /s
Vnet	424	95.8
Res2net-Vnet	166	189.2
RSE-Vnet	172	74.4

2.6 预测结果可视化

模型预测部分结果可视化如图 8 所示,分为 A 和 B 两组,其中 A 组是标签图,B 组是经过模型测试的结果图。从对比结果可知,此方法可以在一定程度上解决结节欠分割与过分割的现象,且模型对部分小结节与结节边界的分割效果较好。




图 8 结节预测可视化展示

Fig. 8 Visualization display of the nodule prediction

图 9 是本文算法对肺结节图像的分割可视化图。

从左到右分别为小型结节、中型结节、大型结节、血管粘连型结节与磨玻璃型结节。对于 V-net 模型,在结节分割上出现较多欠分割问题,且模型对于结节边界定位模糊,难以精确分割。相比之下,RSE-Vnet 获得较好分割效果,特别是对于血管粘连型与磨玻璃型等特殊结节也能进行标准分割。这说明改进后的模型能够提升分割效果,在一定程度上解决结节欠分割问题。




图 9 结节分割可视化

Fig. 9 Visualization of the nodule segmentation

3 结语

本文提出的 RSE-Vnet 网络,充分利用了多尺度特征与网络的跳跃连接能力,使其网络结构能有效馈送结节信息。在使用较少参数量的情况下,网络能够敏锐定位结节点与结节边界信息。解决了模型漏检与欠分割问题,提高了模型的 DSC 系数与检测灵敏度。

受资源和时间限制,该算法仍有改进空间。本文仅用 LUNA16 数据集进行训练与测试,网络对其数据较为适应。但是在实际应用中会存在不同剂量的 CT 影像,迫使不同数据采用同一方法,会损失模型

精度特征。在之后的研究中会采用多个数据集,训练具有泛化能力的分割模型。

参考文献:

- [1] REN H, ZHOU L X, LIU G, et al. An Unsupervised Semi-Automated Pulmonary Nodule Segmentation Method Based on Enhanced Region Growing[J]. Quantitative Imaging in Medicine and Surgery, 2020, 10(1): 233-242.
- [2] LIU H, CAO H C, SONG E M, et al. A Cascaded Dual-Pathway Residual Network for Lung Nodule Segmentation in CT Images[J]. Physica Medica, 2019, 63: 112-121.
- [3] LI X X, LI B, LIU F, et al. Segmentation of Pulmonary Nodules Using a GMM Fuzzy C-Means Algorithm[J]. IEEE Access, 2020, 8: 37541-37556.
- [4] 邓忠豪, 陈晓东. 基于深度卷积神经网络的肺结节检测算法[J]. 计算机应用, 2019, 39(7): 2109-2115.
DENG Zhonghao, CHEN Xiaodong. Pulmonary Nodule Detection Algorithm Based on Deep Convolutional Neural Network[J]. Journal of Computer Applications, 2019, 39(7): 2109-2115.
- [5] 钟思华, 郭兴明, 郑伊能. 改进 U-Net 网络的肺结节分割方法[J]. 计算机工程与应用, 2020, 56(17): 203-209.
ZHONG Sihua, GUO Xingming, ZHENG Yineng. Improved U-Net Network for Lung Nodule Segmentation[J]. Computer Engineering and Applications, 2020, 56(17): 203-209.
- [6] TONG G F, LI Y, CHEN H R, et al. Improved U-NET Network for Pulmonary Nodules Segmentation[J]. Optik, 2018, 174: 460-469.
- [7] XU Xiaoaru, DU Lingyan, YIN Dongsheng. Segmentation of Nodules in CT Images of the Lung Using an Improved V-Net Network Model[J]. Academic Journal of Computing & Information Science, 2023, 6(11). DOI: 10.25236/AJCIS.2023.061104.
- [8] 黄冬云, 王欣, 秦斌. 基于3D卷积神经网络的肺结节检测[J]. 湖南工业大学学报, 2023, 37(1): 75-82.
HUANG Dongyun, WANG Xin, QIN Bin. Pulmonary Nodule Detection Based on 3D Convolutional Neural Network[J]. Journal of Hunan University of Technology, 2023, 37(1): 75-82.
- [9] HOU Q B, ZHOU D Q, FENG J S. Coordinate Attention for Efficient Mobile Network Design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Nashville: IEEE, 2021: 13713-13722.
- [10] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module[C]// Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 3-19.
- [11] KATO S, HOTTA K. Adaptive T-vMF Dice Loss: An Effective Expansion of Dice Loss for Medical Image Segmentation[J]. Computers in Biology and Medicine, 2024, 168: 107695.
- [12] KITAGUCHI D, ITO M. Author Reply: Correction to Dice Similarity Coefficient Formula[J]. Diseases of the Colon & Rectum, 2024: E304.
- [13] SETIO A A A, TRAVERSO A, DE BEL T, et al. Validation, Comparison, and Combination of Algorithms for Automatic Detection of Pulmonary Nodules in Computed Tomography Images: The LUNA16 Challenge[J]. Medical Image Analysis, 2017, 42: 1-13.
- [14] BREVE F A. COVID-19 Detection on Chest X-Ray Images: A Comparison of CNN Architectures and Ensembles[J]. Expert Systems with Applications, 2022, 204: 117549.
- [15] WANG L, ZHOU H, XU N, et al. A General Approach for Automatic Segmentation of Pneumonia, Pulmonary Nodule, and Tuberculosis in CT Images[J]. iScience, 2023, 26(7): 107005.
- [16] NI Y F, XIE Z, ZHENG D Z, et al. Two-Stage Multitask U-Net Construction for Pulmonary Nodule Segmentation and Malignancy Risk Prediction[J]. Quantitative Imaging in Medicine and Surgery, 2022, 12(1): 292-309.
- [17] YANG J Z, WU B, LI L T, et al. MSDS-UNet: A Multi-Scale Deeply Supervised 3D U-Net for Automatic Segmentation of Lung Tumor in CT[J]. Computerized Medical Imaging and Graphics, 2021, 92: 101957.
- [18] WANG D, HE K, WANG B, et al. Solitary Pulmonary Nodule Segmentation Based on Pyramid and Improved Grab Cut[J]. Computer Methods and Programs in Biomedicine, 2021, 199: 105910.
- [19] 李丽, 林晓明, 彭丰平, 等. 基于改进的 V-Net 模型肺结节分割算法的研究[J]. 计算机技术与发展, 2024, 34(4): 82-88.
LI Li, LIN Xiaoming, PENG Fengping, et al. Research on Lung Nodule Segmentation Algorithm Based on Improved V-Net Model[J]. Computer Technology and Development, 2024, 34(4): 82-88.

(责任编辑: 申剑)