

引用格式:马巧梅,梁昊然,王明俊,等. 多策略融合的肺结节检测模型与算法[J]. 微电子学与计算机,2021,38(6):38-44.
[MA Q M, LIANG H R, WANG M J, et al. Multi-strategy fusion model and algorithm for lung nodule detection[J]. Microelec-
tronics & Computer, 2021, 38(6): 38-44.]

多策略融合的肺结节检测模型与算法

马巧梅^{1,2}, 梁昊然^{1,2}, 王明俊^{1,2}, 程 鑫^{1,2}

(1 中北大学 软件学院, 山西 太原 030051; 2 山西省军民融合软件技术工程研究中心, 山西 太原 030051)

摘 要: 肺结节早期检测可以提高病人的生存率, 自动检测算法可以有效辅助医生进行诊断. 为了提高肺结节检测精确度、降低漏诊率, 提出了基于循环残差注意力门机制的 U-Net (Recurrent Residual Attention Gate U-Net, R2AGU-Net) 肺结节检测模型. 首先在原始的 U-Net 基础上改进, 添加循环残差卷积模块并融合注意力门机制, 在增强特征提取性能的同时将注意力放在目标结节区域, 通过抑制无关的特征响应获得较高的检测精度; 其次改进损失函数解决肺结节图像数据不均衡问题, 获得较高的检测敏感度; 最后通过三维卷积神经网络 (3D CNN) 分类候选结节, 降低检测的假阳性. 在两个数据集上进行实验验证, 结果表明本文提出的算法提升了检测速度和敏感度, 取得了比现有算法更好的性能, 具有较好的泛化能力.

关键词: 计算机辅助诊断; 肺结节; 循环残差; U-Net; 注意力门机制

中图分类号: TP391

文献标识码: A

文章编号: 1000—7180(2021)06—0038—07

Multi-strategy fusion model and algorithm for lung nodule detection

MA Qiao-mei^{1,2}, LIANG Hao-ran^{1,2}, WANG Ming-jun^{1,2}, CHENG Xin^{1,2}

(1 Software School, North University of China, Taiyuan 030051, Shanxi China; 2 Shanxi Military and Civilian Integration Software Technology Engineering Research Center, Taiyuan 030051, Shanxi China)

Abstract: Early detection of lung nodules can effectively improve the survival rate of patients. Automatic detection algorithm can effectively assist doctors in diagnosis. In the lung nodule detection task, in order to improve the detection accuracy and reduce the missed diagnosis rate, the lung nodule detection algorithm based on the recurrent residual attention gate U-Net (R2AGU-Net) was proposed. Firstly, recurrent residual convolution module and fusion attention gate mechanism were added in U-Net. The improved method can enhance the feature extraction performance, focus on the target nodule area and suppress irrelevant feature responses to obtain higher detection accuracy. Secondly, improved loss function can solve the problem of unbalanced image data of lung nodules to obtain higher detection sensitivity. Finally, the candidate nodules are classified by a three-dimensional convolutional neural network (3D CNN) to reduce false positive. Experimental verification on two datasets shows that the algorithm proposed in this paper improves the detection speed and sensitivity, achieves better performance than existing algorithms, and has better generalization capabilities.

Key words: computer-aided diagnosis; lung nodule; recurrent residual; U-Net; attention gate mechanism

1 引言

肺癌是目前最常见的恶性肿瘤之一, 在所有癌

症中的发病率和死亡率均居首位^[1]. 肺结节作为肺癌的早期表现形式, 是诊断肺癌的重要内容. 然而, 由于结节形态和位置的多样性以及与周围区域器官

的相似性,使得肺结节检测具有一定的挑战性。

肺结节检测的方法主要包括传统方法^[2]和基于深度学习的方法^[3-4]。Ronneberger 等人^[5]针对医学图像分割提出 U-Net 网络,为小数据集医学图像的识别和分割提供解决思路。随后,许多研究人员改进 U-Net 应用在肺结节检测任务中^[6-9]。然而,目前大多数方法需要预先分割肺实质区域并采用三维结构分割,虽然得到较好的检测精度但耗时长且需要消耗较多的计算资源。本文提出多策略融合的肺结节检测模型与算法,通过实验表明该方法可以高效精准的检测肺结节。


2 相关技术

2.1 U-Net

U-Net 是一个对称的 U 型编码-解码(Encoder-Decoder)结构,应用于不同医学图像分割任务中均取得较好的效果,然而目前仍存在问题。例如,编码器连续的池化和卷积操作会导致部分空间信息丢失;编码器直接与解码器级联或拼接,可能存在语义鸿沟等问题,造成检测精度损失。为解决这些问题,目前许多研究针对 U-Net 做出了一系列的改进结构,如 U-Net++^[10]、CE-Net^[11]、GC-Net^[12] 和 MultiResUNet^[13] 等。

2.2 注意力模块

注意力机制(Attention Mechanism, AM)的本质是通过注意力权重参数强调目标信息,聚焦于图像的局部信息从而抑制无关信息。本文在 U-Net 结构上建立融合的注意力门机制,用于关注输入肺部图像的结节区域信息,提高对其特征提取的精确度。



(a)通道注意力模型
(b)空间注意力模型
图 1 注意力模块

2.2.1 通道注意力模块

通道注意力机制通过图像通道间的依赖关系建模^[14],自适应调整各通道间的特征响应值,分配不

同的权重对通道进行强调或者抑制。如图 1(a)是 CBAM^[15] 网络中提出的通道注意力模块。采用全局平均池化和最大池化两种方式并联提取通道特征,获得两个 $1 \times 1 \times C$ 的特征描述。经过两层的神经网络得到两个特征,将特征相加并通过 sigmoid 激活函数,最终生成通道注意力机制的权重,公式为:

$$M_C(F) = \sigma(W_1(W_0(F_{avg}^C)) + W_1(W_0(F_{max}^C))) \quad (1)$$

式中, F_{avg}^C 和 F_{max}^C 分别为对通道上的特征进行全局平均池化和最大池化操作; W_0 和 W_1 为神经网络上的两层权重参数; σ 为 sigmoid 激活函数。

2.2.2 空间注意力模块

空间注意力机制通过图像的空间信息建模,针对特征图的不同位置分配权重,增强对局部特征的代表能力。如图 1(b)是空间注意力模块。采用全局平均池化和最大池化两种方式提取特征,将所提取特征拼接融合,通过 1×1 的卷积和 sigmoid 激活函数操作,最终生成空间注意力机制的权重,公式为:

$$M_S(F) = \sigma(f([F_{avg}^S; F_{max}^S])) \quad (2)$$

式中, F_{avg}^S 和 F_{max}^S 分别为对空间上的特征进行全局平均池化和最大池化操作, f 为对两个拼接融合的特征使用 1×1 的卷积核学习, σ 为 sigmoid 激活函数。

3 候选结节分割网络

3.1 改进的网络结构

本文提出了 R2AGU-Net 分割网络用于候选结节分割,如图 2 所示。




图 2 候选结节分割网络

U-Net 结构中编码器用于提取语义信息,然而随着网络加深会缺乏底层特征和空间细节信息。本文在编码器阶段融合注意力门机制,使其具有良好的特征表示能力有效提取特征,保留结节局部特征的同时抑制图像中的不相关区域。通过跳跃连接将

注意力门机制与上采样过程相拼接,使跳跃连接更具有选择性,从而更好的恢复结节部分的语义信息,提高分割精度。

本文在编码器部分采用的循环残差卷积模块如图 3 所示,该模块由 R2U-Net^[16] 网络提出. 编码器通过添加循环残差卷积模块累积特征,加深网络捕获更优的特征表示,同时避免网络加深造成梯度消失等问题,提升网络的分割性能。




图 3 循环残差卷积模块

循环残差卷积模块包括两个卷积核大小为 3×3 的循环卷积层,采用残差连接的方式构成. 本文将原始网络中的 ReLU 均替换为 Leaky ReLU 激活函数,解决 ReLU 在负半轴神经元不学习造成梯度消失的问题,Leaky ReLU 的计算公式为:

$$\text{LeakyReLU}(x) = \begin{cases} x & \text{if } x > 0 \\ \alpha x & \text{if } x \leq 0 \end{cases} \quad (3)$$

3.2 融合的注意力门机制

为改进网络在下采样过程中造成结节细节信息丢失等问题,本文提出一种融合的注意力门机制. 融合通道注意力和空间注意力模块,学习通道和空间上的重要特征. 采用注意力门^[17] (AGs)的思想与解码器的上采样部分拼接,更好的融合高层和浅层特征,将注意力放在目标结节区域,抑制无关的特征响应,具体结构如图 4 所示。




图 4 注意力门机制

编码器部分将融合的注意力门机制与上采样部分分别进行 1×1 的卷积运算后相加,经过 Leaky ReLU 激活函数和卷积运算,通过 sigmoid 激活函数得到最终注意力权重,最后与当前层做乘积. 跳跃连接通过添加融合的注意力门机制可以更好的拼接

编解码器不同层次的信息,突出强调肺结节区域的特征,抑制不相关区域. 本文提出的融合的注意力门机制计算开销小且易于集成嵌入在大多数卷积神经网络中,有助于提高模型的检测精度。

3.3 损失函数

医学图像分割任务中常用的损失函数为 Dice 相似系数损失函数,通过 Dice 距离比较预测结果和真实结果像素间的相似性,公式如下:

$$L_{\text{Dice}} = 1 - \frac{2 \sum_{i=1}^N p_i g_i}{\sum_{i=1}^N p_i + \sum_{i=1}^N g_i} \quad (4)$$

式中, p_i 和 g_i 分别表示预测值和真实标签值. Dice 相似系数损失函数在训练准确性上表现较好,然而有时会造成梯度变化剧烈,导致网络训练困难,丢失部分真实结节。

在医学图像分割任务中,感兴趣区域通常只占整张图像的小部分,其类别极度不平衡. 为解决医学图像分割中数据不平衡问题,更好的平衡精确度和敏感度,Abraham 等人^[18] 提出了 Focal Tversky 损失函数,通过 Tversky 相似系数灵活的平衡 FP 和 FN. Focal Tversky 损失函数公式为:

$$L_{\text{FT}} = \sum (1 - L_T)^{\frac{1}{\gamma}} \quad (5)$$

式中, Tversky 相似系数损失函数 L_T 公式为:

$$L_T = \frac{\sum_{i=1}^N p_i g_i}{\sum_{i=1}^N p_i g_i + \alpha \sum_{i=1}^N p_i (1 - g_i) + (1 - \alpha) \sum_{i=1}^N (1 - p_i) g_i} \quad (6)$$

式中, p_i 和 g_i 分别表示预测值和真实标签值,假阳性 (FP) 表示将阴性样本预测为阳性结果即误诊率,由 α 控制;假阴性 (FN) 表示将阳性样本预测为阴性结果即漏诊率,由 $(1 - \alpha)$ 控制. 超参数 α 可以控制假阳性 (FP) 和假阴性 (FN) 之间的平衡,超参数 γ 的范围为 $[1, 3]$ 用来控制背景和感兴趣区域. 当 $\gamma > 1$ 时,损失函数更关注被错误分类的较少的预测,本文选取在分割任务中获得最佳性能的 $\gamma = 4/3$ 进行后续的肺结节分割实验。

4 假阳性减少网络

在候选结节分割网络中,可以较为准确的分割肺结节部分. 然而由于检测敏感度的提高,分割的候选结节往往会存在较高的假阳性,需要去除假阳性

结节. 本文采用三维卷积神经网络(3D CNN)对结节和非结节分类,充分利用肺结节空间上下文信息

去除假阳性,具体结构如图 5 所示.




图 5 三维卷积神经网络

假阳性减少阶段选取所获得候选结节的像素中心截取图像,堆叠为三维块作为分类网络的训练数据集,充分利用结节的空间上下文信息分类. 网络输入大小为 $32\times32\times8$ 的候选结节块,分别经过卷积核为 $3\times3\times3$ 的卷积层以及 $2\times2\times2$ 的最大池化层提取结节特征,并在卷积层后采用批量标准化 (Batch Normalization, BN) 和 ReLU 激活函数处理,最后通过全连接层输出分类结果.

5 实验

5.1 数据集

为验证本文提出的多策略融合的肺结节检测模型与算法,在两个肺部医学图像数据集上进行对比实验. 分别为 LIDC-IDRI 数据集中选取的小尺寸肺结节构成的数据集以及 LUNA16 数据集. 在 LIDC-IDRI 数据集中选取 400 张 3 mm~5 mm 的小尺寸肺结节图像,将图像分为训练集 320 张,测试集 80 张进行实验,验证在小结节上的检测效果. 另外,采用 LUNA16 数据集进行实验,验证在整体肺结节数据集上的检测效果.

5.2 实验细节

5.2.1 训练细节

本文实验中采用 Keras 深度学习框架进行训练,均采用 Python3.6 进行编码,在实验过程中使用 GPU 加速网络的训练和测试. 网络采用 Adam 优化器并设置初始学习率为 0.0001,Adam 算法具有较高的计算效率和较低的内存需求,可以自适应的调节学习率大小,提高训练速度,网络模型训练阶段将 batchsize 设置为 8. 为防止训练中出现过拟合,在网络中加入 Dropout 和 L2 正则化操作.

5.2.2 数据增强

由于医学图像数据集样本较少,采用深度学习方法对医学图像进行检测易造成模型过拟合. 为避免网

络模型训练过程中出现过拟合等问题,对预处理后的数据集图像进行数据增强,提高模型的泛化能力. 本文通过对每张图像随机的旋转、翻转和平移等操作进行数据增强. 为减小在训练过程中占用的计算资源,将数据集图像缩放为 320×320 像素输入网络进行训练.

5.2.3 评估指标

为衡量本文提出方法的效果,采用 Dice 相似系数值 (DSC)、敏感度 (Sensitivity) 和准确率 (Accuracy) 作为评估指标,具体计算公式为:

$$DSC = \frac{2TP}{2TP + FN + FP} \tag{7}$$

$$Sensitivity = \frac{TP}{TP + FN} \tag{8}$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{9}$$

式中真阳性 (TP) 表示将阳性样本正确预测为阳性结果,真阴性 (TN) 表示将阴性样本正确预测为阴性结果. Dice 相似系数值是衡量医学图像分割性能的重要指标,用来评估预测值与真实值的相似度,值越大相似度越高;敏感度是指正确预测为肺结节总数所占真实值总数的比例,值越高漏诊率越低. 另外,采用受试者操作特性 (ROC) 曲线下面积 (AUC) 评估假阳性减少阶段的分类性能,AUC 值越大分类效果越好.

5.3 实验结果与分析

为验证本文所提检测算法的有效性,分别对损失函数参数的选取和模块添加位置的选取进行实验,并与目前先进的方法进行比较.

5.3.1 损失函数参数实验

损失函数中的超参数的选取可以调整肺结节检测中假阳性和假阴性之间的权衡,本文在两个数据集上对超参数 α 大小的选取进行对比实验. 表 1 是超参数 α 大小对检测性能的结果对比,分别将 α 大小设置为 0.5、0.4、0.3、0.2 和 0.1 取得的结果.

表 1 超参数 α 大小对检测性能对比

超参数 α	小尺寸肺结节		LUNA16	
	Dice 系数	敏感度(%)	Dice 系数	敏感度(%)
0.5	0.722 1	66.96	0.681 8	70.02
0.4	0.722 0	72.82	0.691 6	76.94
0.3	0.737 1	80.43	0.722 8	80.05
0.2	0.714 0	85.11	0.709 4	87.48
0.1	0.697 4	91.72	0.695 6	93.20

结果表明,R2AGU-Net 网络在小尺寸肺结节数据集上获得更好的分割精度,在 LUNA16 数据集上获得更好的检测敏感度. 损失函数的参数在两个数据集上对检测性能的对比显示,当超参数 α 为 0.3 时均取得最优的分割精度;当超参数 α 为 0.1 时均取得最优的检测敏感度. 为防止肺结节检测出现漏诊,本文在候选结节检测阶段设置超参数 α 为 0.1,通过牺牲一定的分割精度以获得更高的检测敏感度.

5.3.2 网络模型各模块实验

为验证检测算法中添加模块的有效性,在两个数据集上进行了对比实验,将循环残差卷积模块和融合的注意力门机制添加在 U-Net 网络的不同位置检测模型性能. 如图 6 所示,(a)为不添加模块的 U-Net 结构;(b)为编码器添加注意力门机制的结构;(c)为编码器添加注意力门机制,解码器添加循环残差卷积模块的结构;(d)为编码器同时添加循环残差卷积模块和注意力门机制的结构.




图 6 网络模块位置

表 2 为在两种数据集下,分别将两个模块添加在 U-Net 网络编码器和解码器不同位置(图 6 中 4 种情况)的实验结果对比.

表 2 网络模块不同位置结果对比

模块位置	小尺寸肺结节		LUNA16	
	Dice 系数	敏感度(%)	Dice 系数	敏感度(%)
(a)	0.635 7	87.65	0.607 8	88.21
(b)	0.653 9	89.08	0.642 2	89.47
(c)	0.662 2	90.31	0.655 9	90.82
(d)	0.697 4	91.72	0.695 6	93.20

结果表明,将循环残差卷积模块和注意力门机制添加在(d)的位置,有效提高了网络的分割精度和检测敏感度. 将注意力门机制添加在编码器可以提高其特征学习能力,更好的提取特征获得特征映射. 同时添加注意力门机制仅需增加极少的参数和计算量就能获得显著的提高,在肺结节的检测和诊断中起到了有效的作用.

5.3.3 与其他方法对比实验

为验证本文所提方法在肺结节检测任务中的有效性,在 LUNA16 数据集上与目前的先进方法进行对比,分别比较了候选结节检测阶段和假阳性减少阶段的实验结果. 表 3 是候选结节检测阶段实验结果与其他优秀方法的对比结果.

表 3 候选结节分割网络结果对比

检测算法	模型	敏感度(%)
文献[19]	3D CNN	85.62
文献[20]	Faster R-CNN	86.42
文献[4]	3D CNN	91.00
Baseline	U-Net	88.21
本文算法	R2AGU-Net	93.20

结果表明,本文提出的检测算法相比目前其他先进算法的敏感度提升了 2.2%,仅增加了极少的参数量,提高了检测性能. 候选结节检测阶段通过较快的检测速度和较高的敏感度获得丰富的结节信息,可以检测出不同尺寸的肺结节,在小尺寸结节上也得到了较好的检测性能. 图 7(a)展示了本文方法测试阶段检测到的候选结节,包括第一行对较小尺寸候选结节的检测以及第二行对靠近胸膜部位等困难样本的检测结果,均得到较好的效果.


候选结节检测阶段可以较为准确的检测肺结节,然而较高的检测敏感度会使检测结果包含部分假阳性结节,需要进一步降低候选结节的假阳性. 本文采用 3D CNN 网络进一步分类候选结节中的结节和非结节. 表 4 是本文假阳性减少网络的分类结果与其他优秀的肺结节分类方法的性能对比.

表 4 假阳性减少网络结果对比


检测系统	模型	准确率(%)	敏感度(%)	AUC(%)
文献[19]	3D CNN	85.96	—	90.00
文献[20]	2D CNN	—	79.00	95.40
文献[21]	DeepLung	90.44	95.80	—
文献[22]	Local-Global	88.46	88.66	95.62
文献[8]	改进的 U-Net	91.00	—	—
本文算法	3D CNN	96.56	95.98	98.35

结果表明,本文算法对比其他方法在三种评估标准下均有所提升. Xie 等人^[20]候选结节检测阶段采用 Faster R-CNN,假阳性减少阶段结合 boosting 分类器思想使用 2D CNN 分类,在时间和空间上优于其他算法,然而 2D 网络的检测敏感度较低. 本文采用 3D CNN 网络分类,可以充分获得结节三维空间上下文信息,其中敏感度的提升表明本方法正确预测候选结节中肺结节的性能提升,同时 AUC 值的提升表明分类效果较好. 对比其他优秀的检测算法,本文不需要预先对肺实质进行分割,仅需输入肺部图像即可检测到肺结节,虽然牺牲了一定的分割 Dice 相似度精度,但却大大减小了检测方法的复杂度,降低了肺结节检测的漏诊率.

图 7(b)显示了利用 3D CNN 网络对不同类型的真实结节的检测结果,模型对不同形态特征的结节都取得了良好的鉴别性能.



(a) 候选结节检测结果



(b) 结节分类结果

图7 肺结节检测结果样例

6 结束语

本文针对目前肺结节检测精度低和漏诊率高等问题,提出了多策略融合的肺结节检测模型与算法. 在编码-解码结构的 U-Net 网络中添加循环残差卷积模块并融合注意力门机制,聚焦于肺部 CT 图像的肺结节区域,提升检测准确率;改进损失函数解决数据不均衡问题,提升检测敏感度;最后利用 3D CNN 结构进一步分类,去除假阳性结节. 在两个数据集上进行对比实验,获得了较好的结果,可以高效

准确的检测肺结节. 然而,由于医学图像数据量较少,加深网络层数极易出现过拟合问题,影响检测精确度. 未来将通过数据增强等方法提升数据量,同时融合不同模态和尺度的肺结节进一步提高检测性能.

参考文献:

- [1] SIEGEL R L, MILLER K D, JEMAL A. Cancer statistics, 2019[J]. CA: A Cancer Journal for Clinicians, 2019, 69(1): 7-34. DOI: 10.3322/caac.21551.
- [2] HAN F F, WANG H F, ZHANG G P, et al. Texture feature analysis for computer-aided diagnosis on pulmonary nodules[J]. Journal of Digital Imaging, 2015, 28(1): 99-115. DOI: 10.1007/s10278-014-9718-8.
- [3] SABA T, SAMEH A, KHAN F, et al. Lung nodule detection based on ensemble of hand crafted and deep features[J]. Journal of Medical Systems, 2019, 43(12): 332. DOI: 10.1007/s10916-019-1455-6.
- [4] PEZESHKA, HAMIDIAN S, PETRICK N, et al. 3-D convolutional neural networks for automatic detection of pulmonary nodules in chest CT[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(5): 2080-2090. DOI: 10.1109/JBHI.2018.2879449.
- [5] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//Proceedings of the 18th International Conference on Medical Image Computing and Computer-assisted Intervention. Munich, Germany: Springer, 2015. DOI: 10.1007/978-3-319-24574-4_28.
- [6] ROCHA J, CUNHA A, MENDONÇA A A M. Conventional filtering versus U-Net based models for pulmonary nodule segmentation in CT images[J]. Journal of Medical Systems, 2020, 44(4): 81. DOI: 10.1007/s10916-020-1541-9.
- [7] CAO H C, LIU H, SONG E M, et al. A two-stage convolutional neural networks for lung nodule detection[J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(7): 2006-2015. DOI: 10.1109/JBHI.2019.2963720.
- [8] 朱辉, 秦品乐. 基于多尺度特征结构的 U-Net 肺结节检测算法[J]. 计算机工程, 2019, 45(4): 254-261. DOI: 10.19678/j.issn.1000-3428.0051769.
ZHU H, QIN P L. U-Net pulmonary nodule detection algorithm based on multi-scale feature structure[J]. Computer Engineering, 2019, 45(4): 254-261. DOI: 10.19678/j.issn.1000-3428.0051769.
- [9] 王磐, 强彦, 杨晓棠, 等. 基于双注意力 3D-U-Net 肺结节分割网络[J]. 计算机工程, 2021, 47(2): 307-

313. DOI: 10.19678/j.issn.1000-3428.0057019.
- WANG P, QIANG Y, YANG X T, et al. Network model for lung nodule segmentation based on double attention 3D-UNet[J]. Computer Engineering, 2021, 47(2): 307-313. DOI: 10.19678/j.issn.1000-3428.0057019.
- [10] ZHOU Z W, SIDDIQUEE M M R, TAJBAKHS N, et al. UNet++: redesigning skip connections to exploit multiscale features in image segmentation[J]. IEEE Transactions on Medical Imaging, 2020, 39(6): 1856-1867. DOI: 10.1109/TMI.2019.2959609.
- [11] GU Z W, CHENG J, FU H Z, et al. CE-Net: context encoder network for 2D medical image segmentation[J]. IEEE Transactions on Medical Imaging, 2019, 38(10): 2281-2292. DOI: 10.1109/TMI.2019.2903562.
- [12] NI J J, WU J H, TONG J, et al. GC-Net: global context network for medical image segmentation[J]. Computer Methods and Programs in Biomedicine, 2020, 190: 105121. DOI: 10.1016/j.cmpb.2019.105121.
- [13] IBTEHAZ N, RAHMAN M S. MultiResUNet: rethinking the U-Net architecture for multimodal biomedical image segmentation[J]. Neural Networks, 2020, 121: 74-87. DOI: 10.1016/j.neunet.2019.08.025.
- [14] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023. DOI: 10.1109/TPAMI.2019.2913372.
- [15] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer, 2018: 3-19. DOI: 10.1007/978-3-030-01234-2_1.
- [16] ALOM M Z, HASAN M, YAKOPCIC C, et al. Rescurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation[J]. arXiv preprint arXiv:1802.06955, 2018.
- [17] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-Net: learning where to look for the pancreas[J]. arXiv preprint arXiv:1804.03999, 2018.
- [18] ABRAHAM N, KHAN N M. A novel focal tversky loss function with improved attention U-Net for lesion segmentation[C]//Proceedings of 2019 IEEE 16th International Symposium on Biomedical Imaging. Venice: IEEE, 2019.
- [19] LIAO F Z, LIANG M, LI Z, et al. Evaluate the malignancy of pulmonary nodules using the 3-D deep leaky-noisy-or network[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(11): 3484-3495. DOI: 10.1109/TNNLS.2019.2892409.
- [20] XIE H T, YANG D B, SUN N N, et al. Automated pulmonary nodule detection in CT images using deep convolutional neural networks[J]. Pattern Recognition, 2019, 85: 109-119. DOI: 10.1016/j.patcog.2018.07.031.
- [21] ZHU W T, LIU C C, FAN W, et al. DeepLung: deep 3D dual path nets for automated pulmonary nodule detection and classification[C]//Proceedings of 2018 IEEE Winter Conference on Applications of Computer Vision. Lake Tahoe, USA: IEEE, 2018: 673-681. DOI: 10.1109/WACV.2018.00079.
- [22] AL-SHABI M, LAN B L, CHAN W Y, et al. Lung nodule classification using deep Local-Global networks[J]. International Journal of Computer Assisted Radiology and Surgery, 2019, 14(10): 1815-1819. DOI: 10.1007/s11548-019-01981-7.

作者简介:

马巧梅 女,(1969-),博士,副教授.研究方向为图形图像处理、算法优化.

梁昊然(通讯作者) 女,(1994-),硕士研究生.研究方向为图形图像处理、深度学习. E-mail:380876659@qq.com

王明俊 男,(1993-),硕士研究生.研究方向为深度学习、图像处理.

程鑫 女,(1995-),硕士研究生.研究方向为深度学习、图像处理.