

U-Net 网络肺结节分割模型

谭小波 何明亮

沈阳理工大学信息科学与工程学院 沈阳 110159

摘要: 针对 U-Net 在对肺结节进行训练时, 存在梯度消失和特征利用率低的问题, 提出了一种基于改进 U-Net 的肺结节分割模型, 即 RAU-Net(U-Net network with residual element and attention mechanism) 模型。该模型基于 U-Net 基础框架, 在编码器和解码器中分别加入残差单元, 以加深网络深度, 提高网络学习能力; 同时在网络长连接加入注意力机制, 尽可能获取含有较多上下文语义和空间位置的特征信息。实验结果表明, RAU-Net 模型在 MeanIOU、Dice、F1-Score 三个指标均高于 Res U-Net 模型, 分别提高了 1.61%, 3.65%, 2.01%, 证明了 RAU-Net 模型具有良好的分割性能。

关键词: U-Net; RAU-Net; 残差单元; 注意力机制; 肺结节分割

肺癌是全球范围内癌症疾病死亡率最高的疾病之一^[1]。CT (Computed Tomography) 检查作为检测早期肺癌的主要手段, 由于肺部 CT 中的病灶特别小, 肉眼难发现, 容易在诊断过程中造成误检, 错检的情况。而随着计算机技术的发展, 可以通过计算机强大的计算能力将肺结节标记出来, 医生再结合自身的经验去得出更准确的结论^[2]。目前医学图像处理方法主要分为两大类, 传统的机器学习方法和深度学习方法。传统机器学习算法主要分为阈值分割^[3], 聚类算法^[4], 区域生长算法^[5]等, 虽然以上这几种算法, 能够完成肺结节分割, 但是需要人工标注特征, 非常不方便。随着不断科技发展, 深度学习的出现给人们一种可以自动提取特征并分割的方法^[6-8]。本文提出 RAU-Net(U-Net network with residual element and attention mechanism) 的肺结节分割模型, 该模型提高了对特征的学习能力, 实现对肺结节边缘精细化分割, 能够大幅度提高分割准确率。

1 RAU-Net 模型

针对 U-Net 网络层数太少和对病灶边缘分割的效果不佳以及医学图像样本少造成的问题, 提出了 RAU-Net, 残差网络单元解决卷积神经网络过深会出现网络梯度消失的问题, 加深整个网络深度, 提升深度学习模型的学习能力, 让 U-Net 网络的分割效果有大幅度的提升; 注意力机制对整个医学图像的特征标定, 使不同通道的权重不同, 聚焦于权重较高的特征。

1.1 网络结构

本文提出的网络结构如图 1 所示。




图 1 RAU-Net 网络模型

RAU-Net 网络模型依然保持 U-Net 的对称编码-解码的整体网络结构, 左半部分是编码结构, 右边是解码结构, 整个编码部分同样包含四层, 每一层包含一个残差网络单元, 残差网络单元是采用 ResNet34^[9], 由两个卷积核大小为 3*3 和一个最大池化组成, 残差单元利用跳跃连接将单元输入卷积核直接传递给残差单元的输出, 最开始的输入与经过两层卷积运算的输出做一个相加操作, 在 U-Net 中每次下采样会使通道数增加一倍, 但利用残差网络单元保持了通道数不变, 但每个残差块在下采样过程中图像特征通道数量会减半。层数少的网络会具有更精细的浅层语义特征信息, 而整个网络层数较多会具有深层语义信息, 浅层语义信息代表的是图像特征信息。而深层语义信息代表的是图像中区域的位置信息。而不断地下采样会造成深层语义信息缺失, 因此残差单元进行相加操作后, 还需要保持 U-Net 网络的长连接, 将浅层网络的语义信息传递到解码部分, 用于恢复由于下采样损失的浅层语义信息。

1.2 损失函数

分割一般被定义为二分类任务，即分割的目标区域与其他区域，这类任务由于只有正和负区域，且两者和为1，只需要预测概率，一般使用二值交叉熵作为损失函数，如公式1所示：

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N (y_i \cdot \ln(p_i) + (1 - y_i) \cdot \ln(1 - p_i))$$

(1) 公式2中， y_i 为像素点*i*的真实类别， p_i 是像素点*i*的预测结果。

另一种损失函数为Dice，如公式2所示：

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

本文综合上述两种混合函数的特点，提出了混合损失函数，如公式4所示：

$$L = \alpha L_{Dice} + (1 - \alpha) L_{BCE} \quad (3)$$

公式3中 α 为权重，目的调节两种损失函数之间的比重。

2 实验及结果分析

本文实验环境是使用pytorch框架结合python语言进行搭建，计算机配置：操作系统是Ubuntu20.04，显卡是3090。

2.1 数据集

Lung Image Database Consortium and Image Database Resource Initiative database(LIDC-IDRI)[10]是由胸部医学图像文件(如CT、X光片)和对应的诊断结果病变标注组成。该数据是由美国国家癌症研究所(National Cancer Institute)发起收集的，目的是为了研究高危人群早期癌症检测，数据格式是标准医学图像格式DICOM(Digital Imaging and Communications in Medicine)[11]，可以解析出相应图像信息，包括医生标注信息。该数据集收录了1018研究病例的肺部CT图像，而CT图像可以当作二维图像序列，合在一起是个三维立体结构。

2.2 评价指标

本课题采用MeanIOU, Dice, F1-Score作为评价指标：

$$MeanIOU = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (4)$$

Mean IOU如公式4所示，其中*i*代表是真实类别，*j*代表是预测类别，*k*+1代表是*k*个前景类别加上一个背景的数值， p_i 表示预测结果为正确值，真实值为*i*，预测值也是*i*，MeanIOU主要是用来解决由于数据集类别不均衡造成困难的分类任务问题。

$$Dice = \frac{2 \sum_{i=1}^N y_i p_i}{\sum_{i=1}^N g_i + \sum_{i=1}^N p_i} \quad (5)$$

Dice如公式5所示，主要是用来计算集合之间的相似性，数值在[0,1]之间，越接近于1代表结果越好。

$$F1-Score = \frac{2TP}{2TP + FN + FP} \quad (6)$$

F1-Score如公式6所示，将预测率和召回率组合在一起，能够混合在一起，综合各自优点F1-Score被提出。

2.3 结果分析

为了展示模型良好效果，将本文模型与U-Net, Attention U-Net^[12], Res U-Net^[13]三种模型做对比。用 $\alpha=0.7$, batch-size为32的模型进行训练，在测试集上进行验证效果。不同模型评价指标对比如表1所示：

表1 不同模型评价指标对比

| 模型 | MeanIOU | Dice | F1-Score |
|-----------|---------|-------|----------|
| U-Net | 81.61 | 79.92 | 78.32 |
| At U-Net | 83.13 | 81.25 | 80.82 |
| Res U-Net | 83.91 | 80.30 | 80.98 |
| RAU-Net | 85.52 | 83.95 | 82.99 |

本文模型loss在100轮的情况下能够达到0.051，如图4所示，已经达到非常好的效果，并且由表3能看出本文模型在相同条件下，各项评价指标明显优于其他模型。




图2 损失函数曲线

最后在预测集的分割效果如图3所示，每一行是同一肺结节不同网络的分割结果，总共选取了6个肺结节的分割结果，能看出来U-Net的分割结果有点粗，边缘部分不够精细，肺结节位置信息与实际略有差距，在没有改进的情况下，U-Net容易受到其他组织的干扰，而U-Net不能识别相似组织，导致结果与真实值有一定的差距。而Res U-Net和Attention U-Net由于在U-Net原本的基础上都有不同程度的优化，分割结果在位置信息和边缘精细度都有改善。而本文提出改进U-Net的肺结节分割模型，能够精确定位肺结节，区分其他组织与肺结节，肺结节边缘也更加精细化，分割效果相比于其他三种模型有明显的提升。




图3 不同模型分割效果

3 结论

针对目前医学图像分割方法不能够同时获得精确的位置信息和良好的病灶轮廓效果，本文通过残差单元和注意力机制与U-Net框架的结合来解决这个问题。在U-Net的原有结构的基础上，保证网络深度的同时，减少整个网络的参数，融入多种机制，大幅度提高了网络性能。与不同的模型进行对比实验，实验结果表明RAU-Net具有良好的分割性能。

参考文献:

[1] 程安琪,肖丹.确诊肺癌后戒烟降低肺癌进展和死亡率风险[J].中华医学杂志,2022(102-024).

[2] 程勇,陈卫国.医学影像CAD的研究和应用[J].医疗设备信息,2006(01):24-27+33.

[3] OTSU N.A threshold selection method from gray-level histograms[J].IEEE Transactions on Systems,Man,and Cybernetics,1979,9(1):62-66.

[4] CHEN YuKe,WU Xiao Ming,CAI Ken,CT Image Segmentation based on Clustering and Graph-Cuts Elsevier,2011,5179-5184.

[5] JIANG HuiYan,SI YuePeng.Medical image segmentation based on improved Ostu algorithm and regional growth algorithm[J].Journal of Northeastern University,2006,27(4):398-401.

[6] 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.

[7] 王磐,强彦,杨晓棠等.基于双注意力3D-UNet的肺结节分割网络模型[J].计算机工程,2021,47(02):307-313.

[8] 闫欢兰,陆慧娟,叶敏超,严珂,金群,徐一格.结合Sobel算子和Mask R-CNN的肺结节分割[J].小型微型计算机系统,2020,41(01):161-165.