

基于深度学习的靶区自动勾画

电子工程系 无54

朱海东 2015011068

指导老师 吴及教授

2019.6



清华大学
Tsinghua University



目录

- 课题研究背景及意义
- 毕设工作
 - - 基于深度学习的靶区勾画模型
 - - 噪声标注下分割模型的训练算法
 - - 靶区勾画系统搭建
- 工作总结



课题研究背景及意义 - 靶区勾画

靶区勾画

- 临床放射治疗前进行癌变区域的部位进行勾画
- 依据不同部位局部复发和区域淋巴结转移几率定义勾画区域

- **GTV (Gross Target Volume) 肿瘤区**

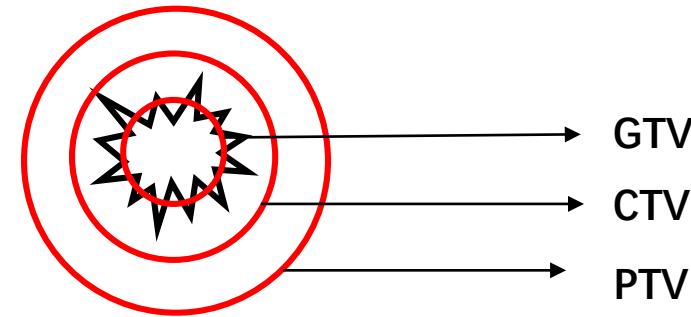
临床灶，为一般的诊断手段能够诊断出的可见的具有一定形状和大小的恶性病变的范围，包括转移的淋巴结和其它转移的病灶

- **CTV (Clinical Target Volume) 临床靶区**

CTV指按一定的剂量模式给予一定剂量的肿瘤的临床灶（GTV）亚临床灶以及肿瘤可能侵犯的范围。

- **PTV (Planning Target Volume) 计划靶区**

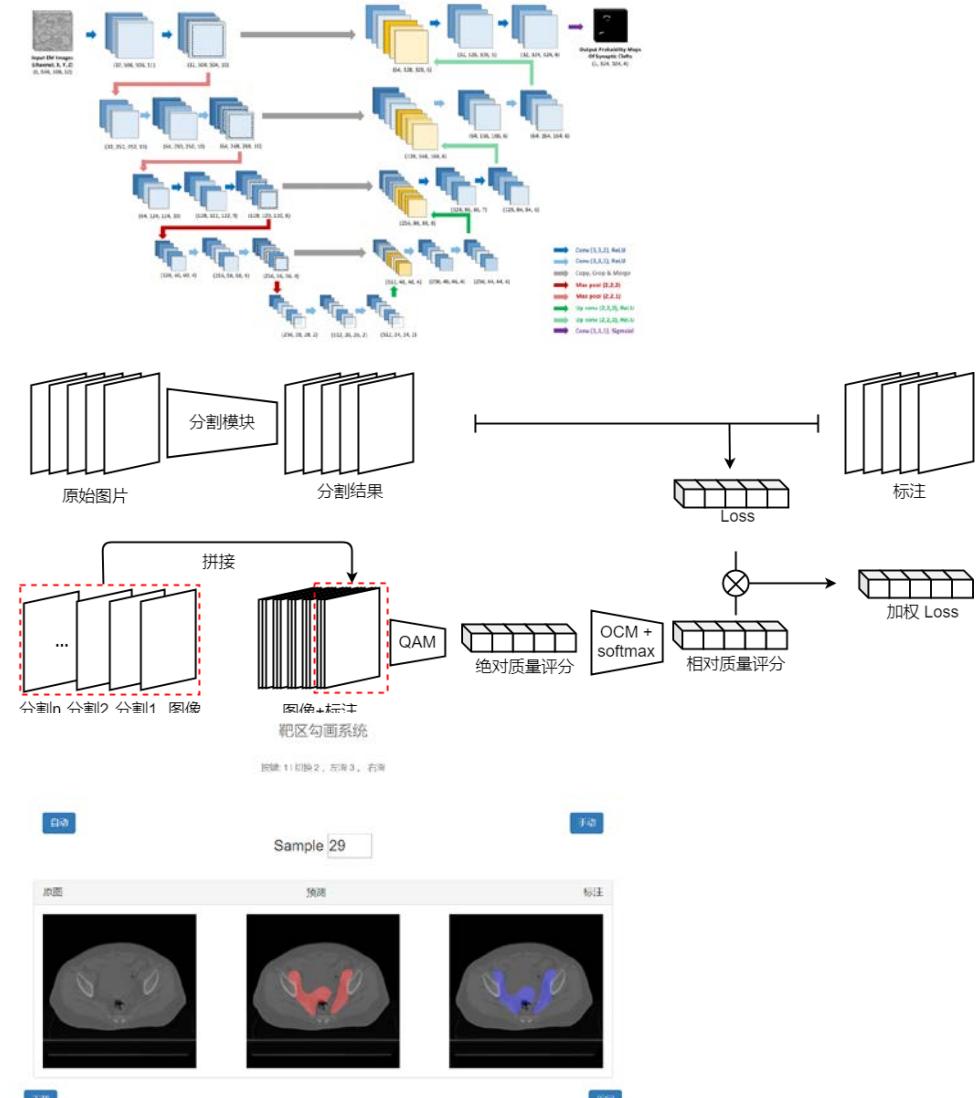
PTV是指包括CTV本身、照射中患者器官运动，和由于日常摆位治疗中靶位置和靶体积变化等因素引起的扩大照射的组织范围，以确保CTV得到规定的治疗剂量。





课题研究背景及意义 - 工作介绍

构建基于深度学习的靶区勾画模型



提出噪声标注样本下分割模型训练的算法

搭建可使用的靶区勾画系统

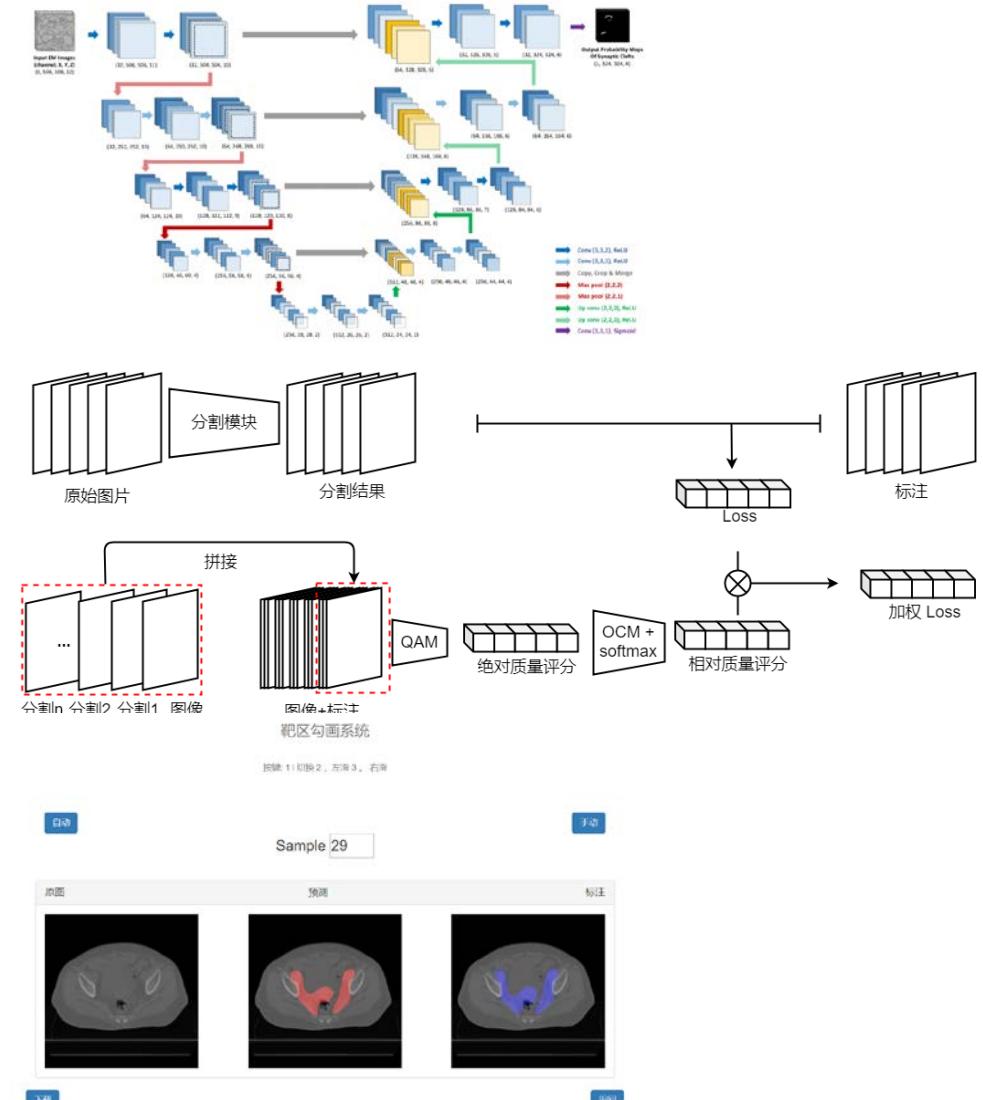


靶区勾画模型

构建基于深度学习的靶区勾画模型

提出噪声标注样本下分割模型训练的算法

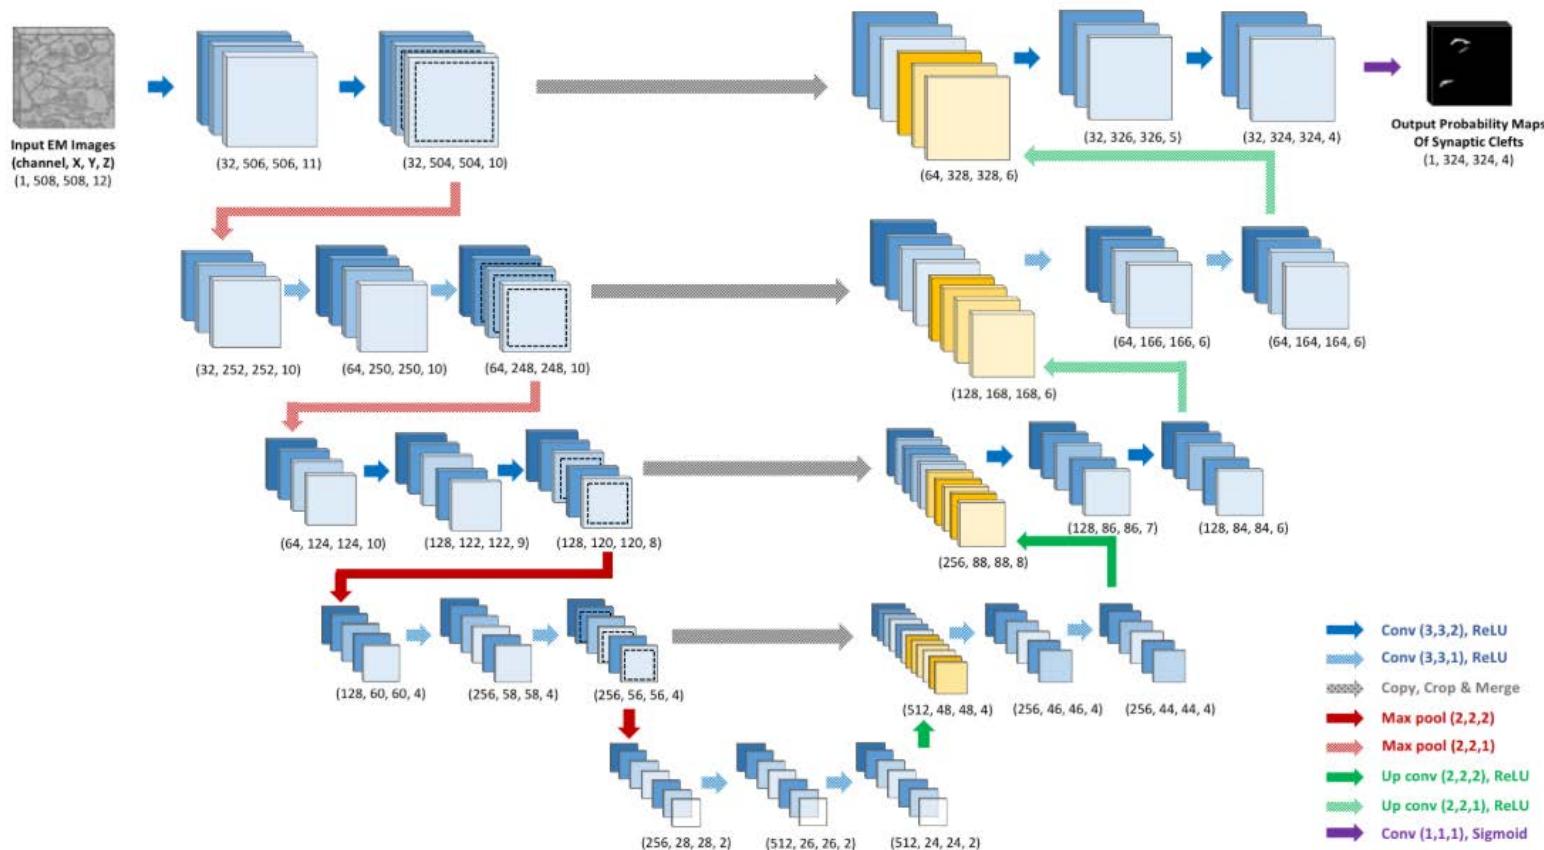
搭建可使用的靶区勾画系统





靶区勾画模型 - 方法设计

• Baseline – Unet 3D



网络参数

- 下采样5次，通道数分别为16、32、64、96、128
- 卷积核大小3x3x3

评价指标

- dice ratio

$$d = \frac{2 \times \text{Intersection}(V_{pred}, V_{gt})}{V_{pred} + V_{gt}}$$

Baseline average dice ratio – 0.747



靶区勾画模型 - 实验结果

Unet (Baseline)

-> dice value: 0.747

Res - Unet

-> dice value: 0.753

Res - Unet + SE module

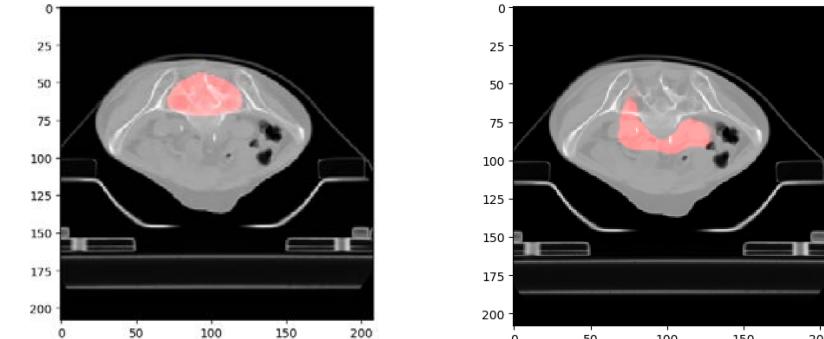
-> dice value: 0.755

Res - Unet + SE + Cycle

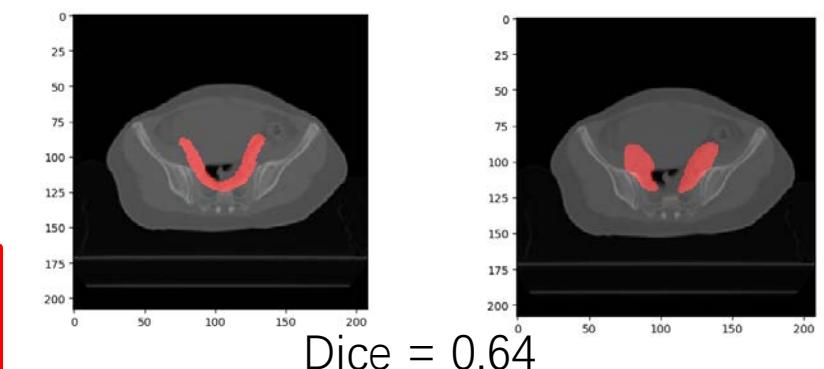
-> dice value: 0.757

Res - Unet + SE + Cycle + Dice -> dice value: 0.763

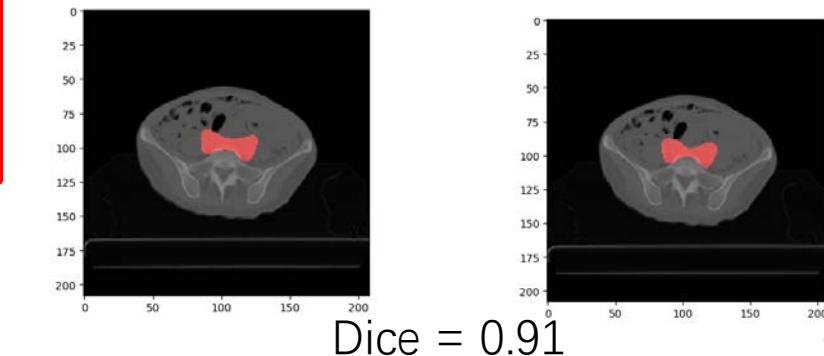
- 单个模块有一定的小提升
- 不同的医生的标注习惯存在较大的差异，使得衡量标准无法统一



Dice = 0.01 (left-gt right-pred)



Dice = 0.64

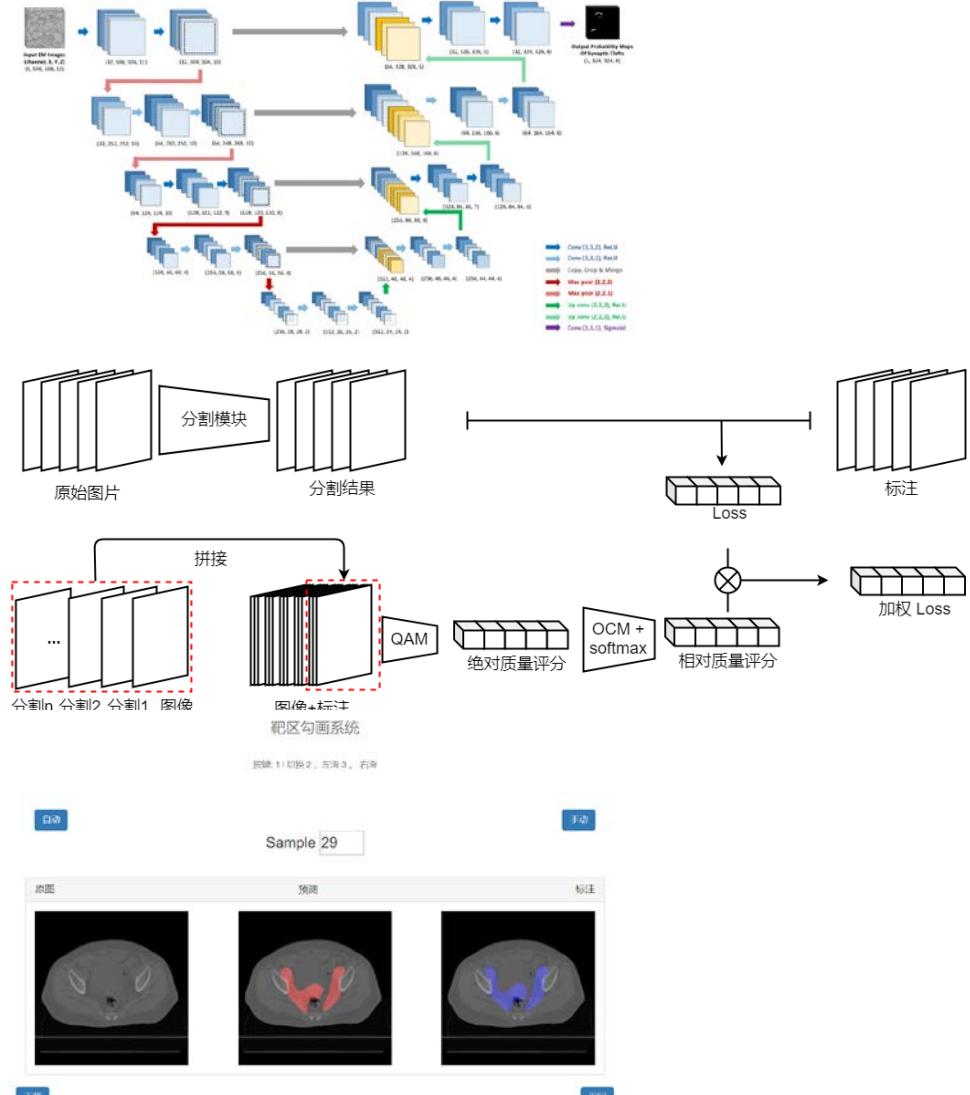


Dice = 0.91



含噪声标注的训练算法

构建基于深度学习的靶区勾画模型



提出噪声标注样本下分割模型训练的算法

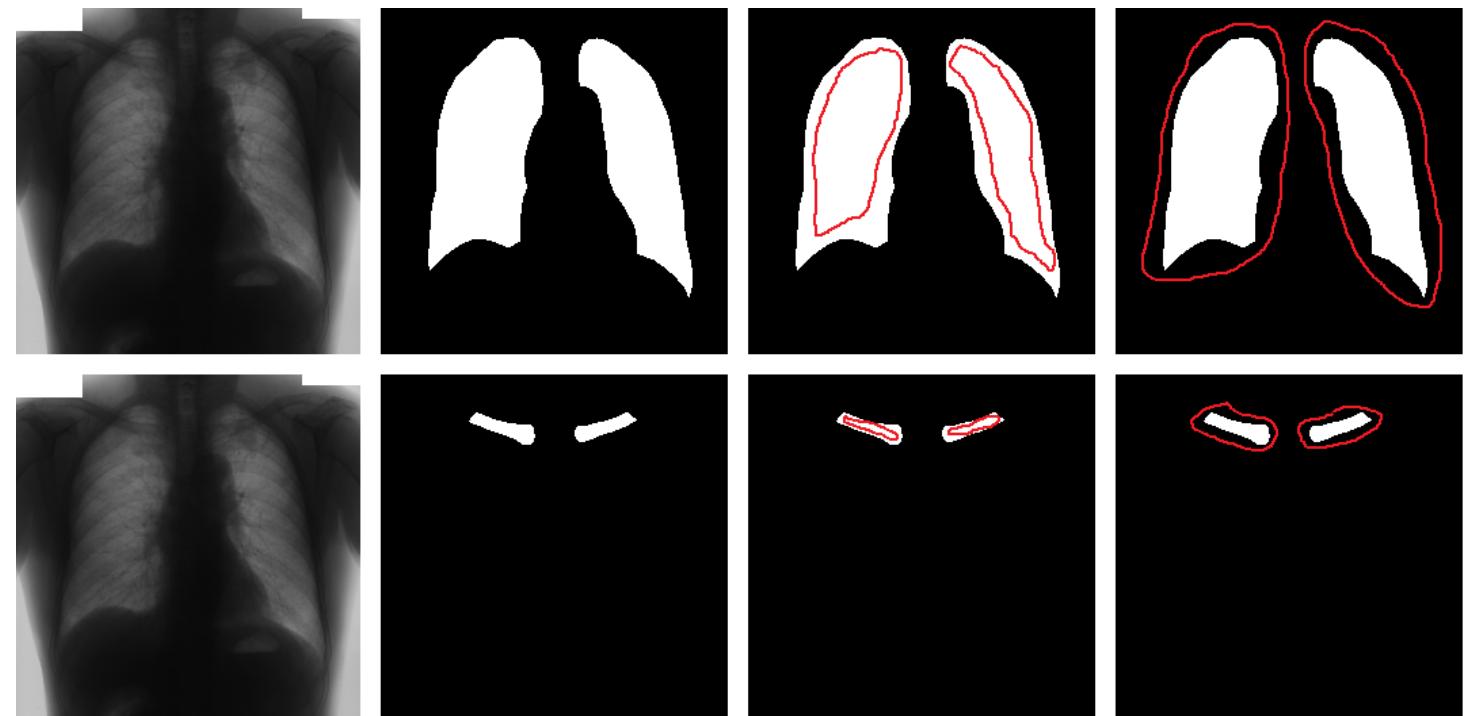
搭建可使用的靶区勾画系统



含噪声标注的训练算法 – 问题介绍

含有噪声标注的训练集中得到较精确的分割结果

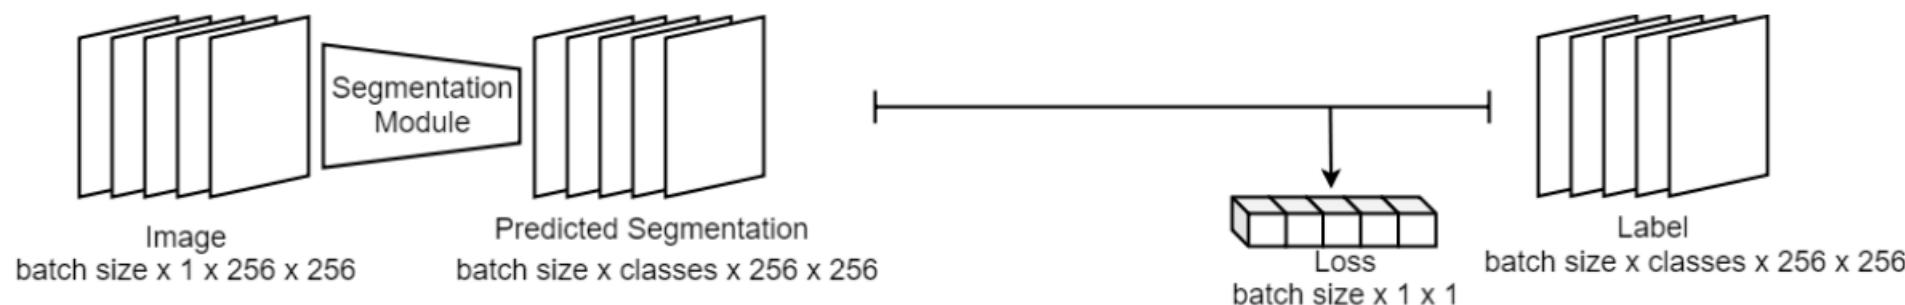
医学图像标注需要大量的具有专业知识的人员对于图片进行标注，不同医生的标注标准不统一，造成了训练集中标注不统一的问题。





含噪声标注的训练算法 – 现有算法

现有基于深度学习的分割算法描述



现有的分割学习算法流程

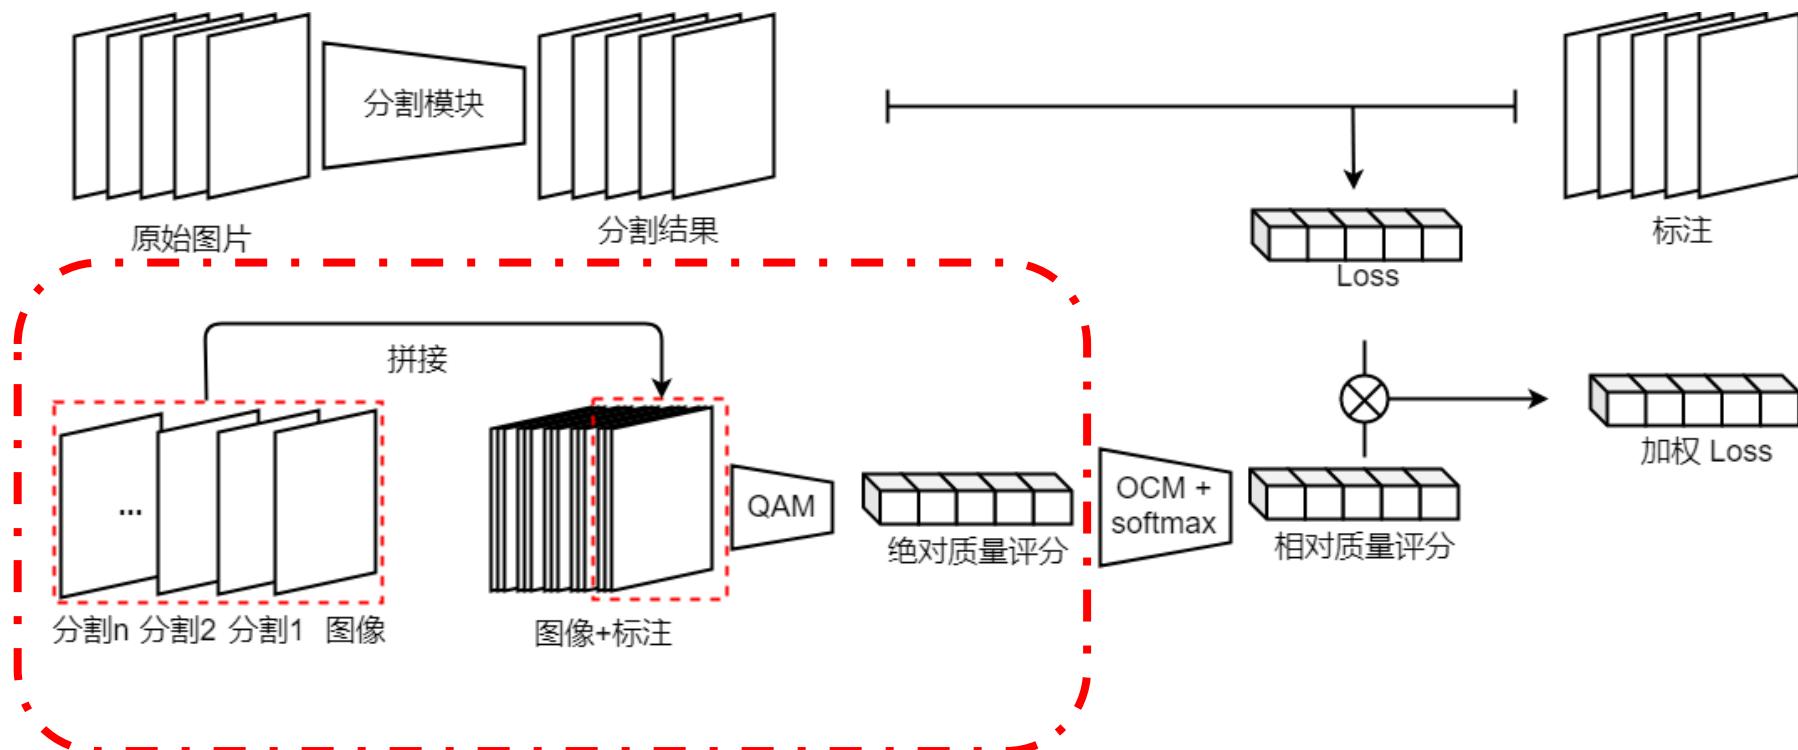
- 分割模块生成分割结果
- 生成结果与标签进行loss计算
- 梯度回传优化模型

无法对于标注的质量
进行评估判断



含噪声标注的训练算法 – 质量评估模块

质量评估模块

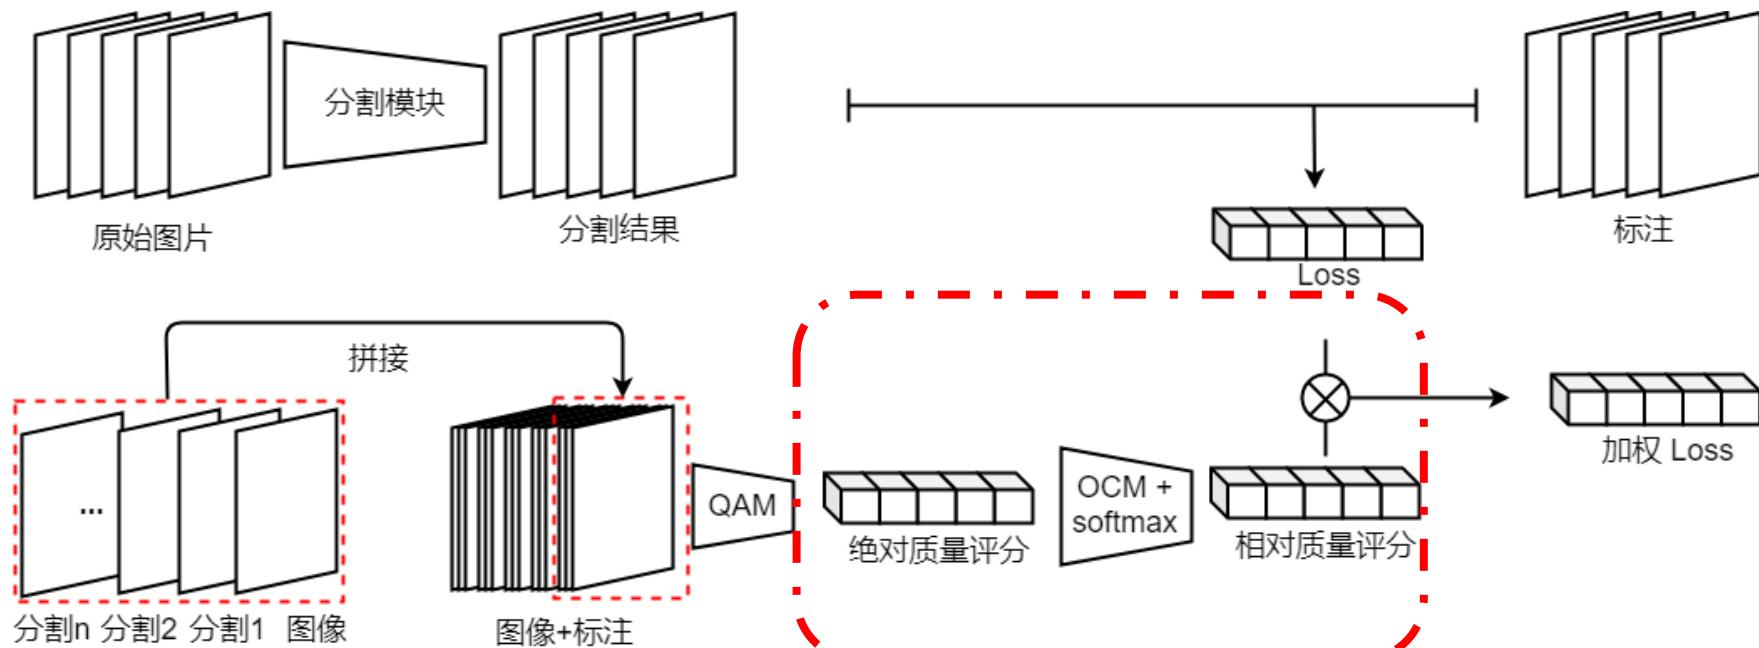


结合原始图像和分割
结果产生原始得分



含噪声标注的训练算法 – 防过拟合模块

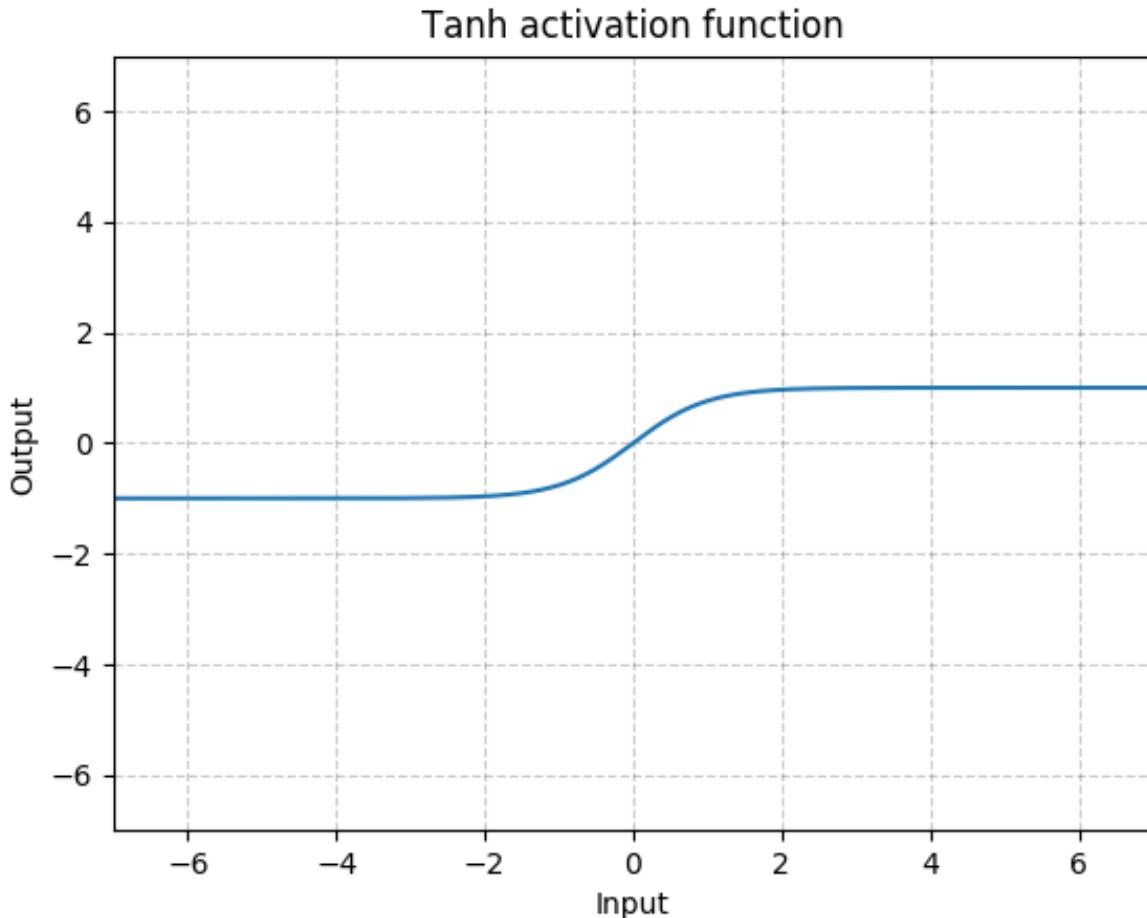
防过拟合模块



通过OCM模块进行
过拟合控制



含噪声标注的训练算法 – OCM原理



$$\text{OCM} \quad f(x) = \lambda \tanh(x)$$

使用OCM的优势

- 将绝对质量从 $(-\infty, \infty)$ 缩小到 $(-\lambda, \lambda)$
- 将Softmax后相对质量比值从 ∞ 缩小到 $e^{2\lambda}$
- 优化过程中满足权值不过于突出



含噪声标注的训练算法 – 结果

噪声占比	噪声程度	方法	肺部分割	心脏分割	锁骨分割	平均分割
无	-	InvertedNet[31]	0.972	0.935	0.902	0.936
无	-	基础方法	0.943	0.941	0.862	0.915
无	-	QAM	0.939	0.923	0.831	0.898
无	-	QAM+OCM	0.941	0.940	0.852	0.911
25%	1-8像素	基础方法	0.868	0.888	0.538	0.765
25%	1-8像素	QAM	0.925	0.926	0.748	0.866
25%	1-8像素	QAM+OCM	0.936	0.925	0.823	0.895
50%	1-8像素	基础方法	0.873	0.884	0.539	0.765
50%	1-8像素	QAM	0.922	0.925	0.726	0.857
50%	1-8像素	QAM+OCM	0.936	0.929	0.828	0.898
75%	1-8像素	基础方法	0.745	0.738	0.381	0.621
75%	1-8像素	QAM	0.898	0.825	0.536	0.753
75%	1-8像素	QAM+OCM	0.937	0.939	0.809	0.895

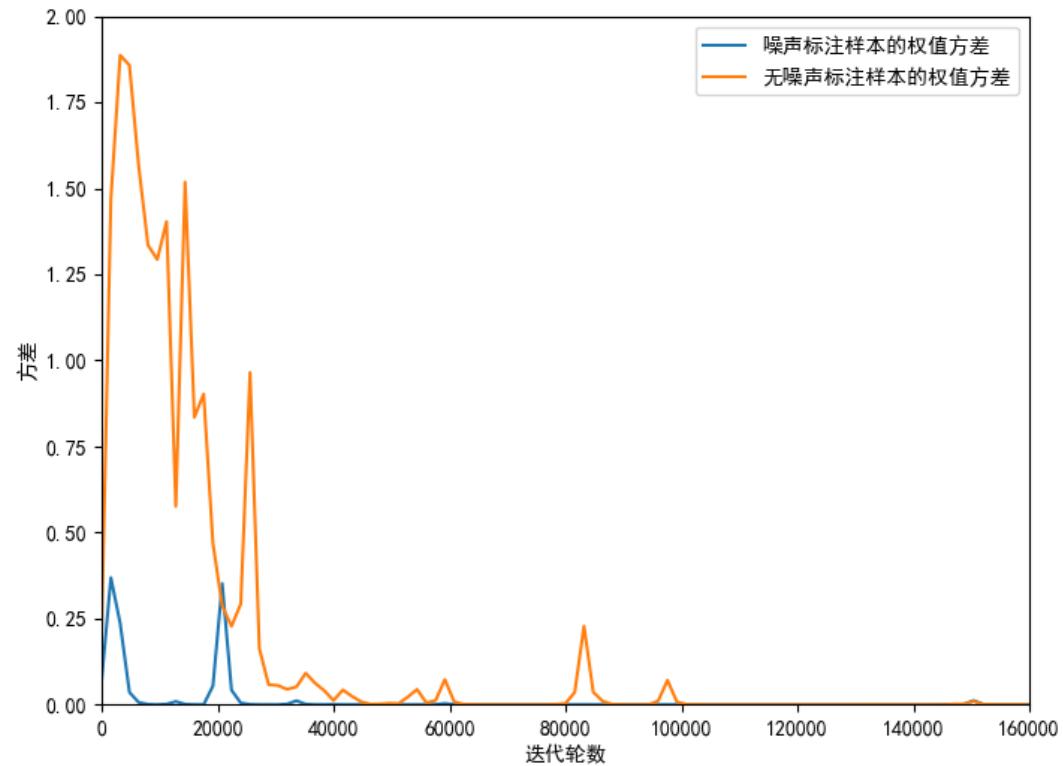
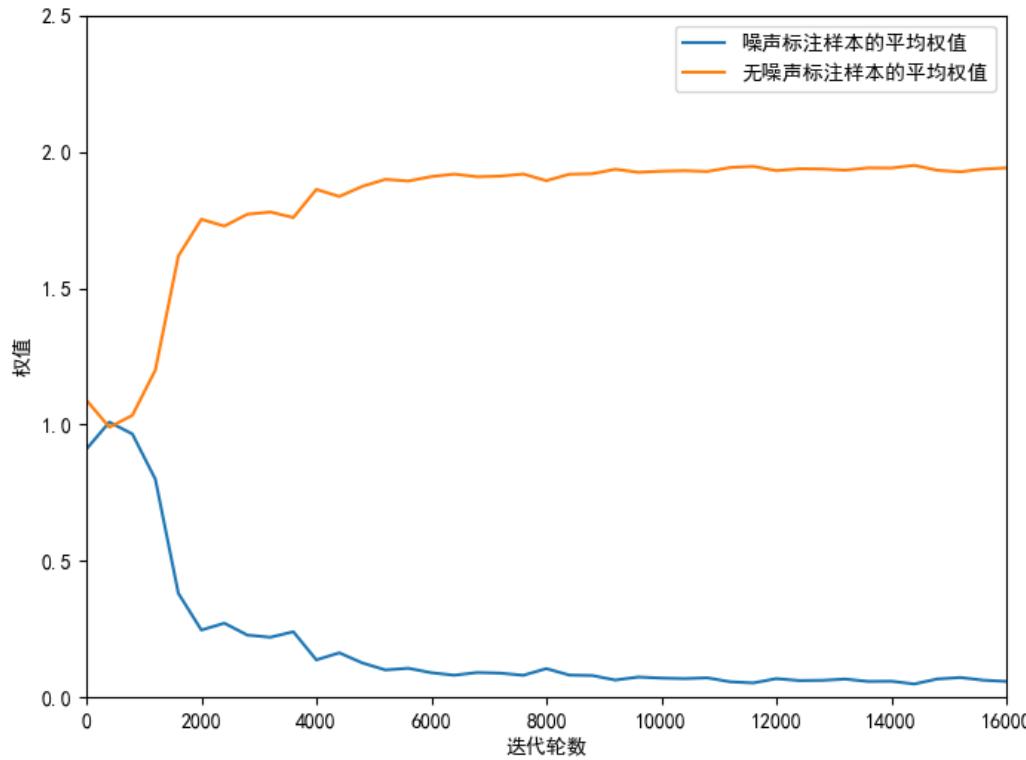


含噪声标注的训练算法 – 结果

噪声占比	噪声程度	方法	肺部分割	心脏分割	锁骨分割	平均分割
无	-	InvertedNet[31]	0.972	0.935	0.902	0.936
无	-	基础方法	0.943	0.941	0.862	0.915
无	-	QAM	0.939	0.923	0.831	0.898
无	-	QAM+OCM	0.941	0.940	0.852	0.911
25%	5-13像素	基础方法	0.865	0.857	0.422	0.715
25%	5-13像素	QAM	0.893	0.835	0.615	0.781
25%	5-13像素	QAM+OCM	0.935	0.935	0.801	0.890
50%	5-13像素	基础方法	0.755	0.807	0.393	0.652
50%	5-13像素	QAM	0.828	0.853	0.491	0.714
50%	5-13像素	QAM+OCM	0.942	0.942	0.853	0.912
75%	5-13像素	基础方法	0.820	0.828	0.512	0.720
75%	5-13像素	QAM	0.770	0.772	0.366	0.636
75%	5-13像素	QAM+OCM	0.938	0.937	0.801	0.892



含噪声标注的训练算法 – OCM性能分析



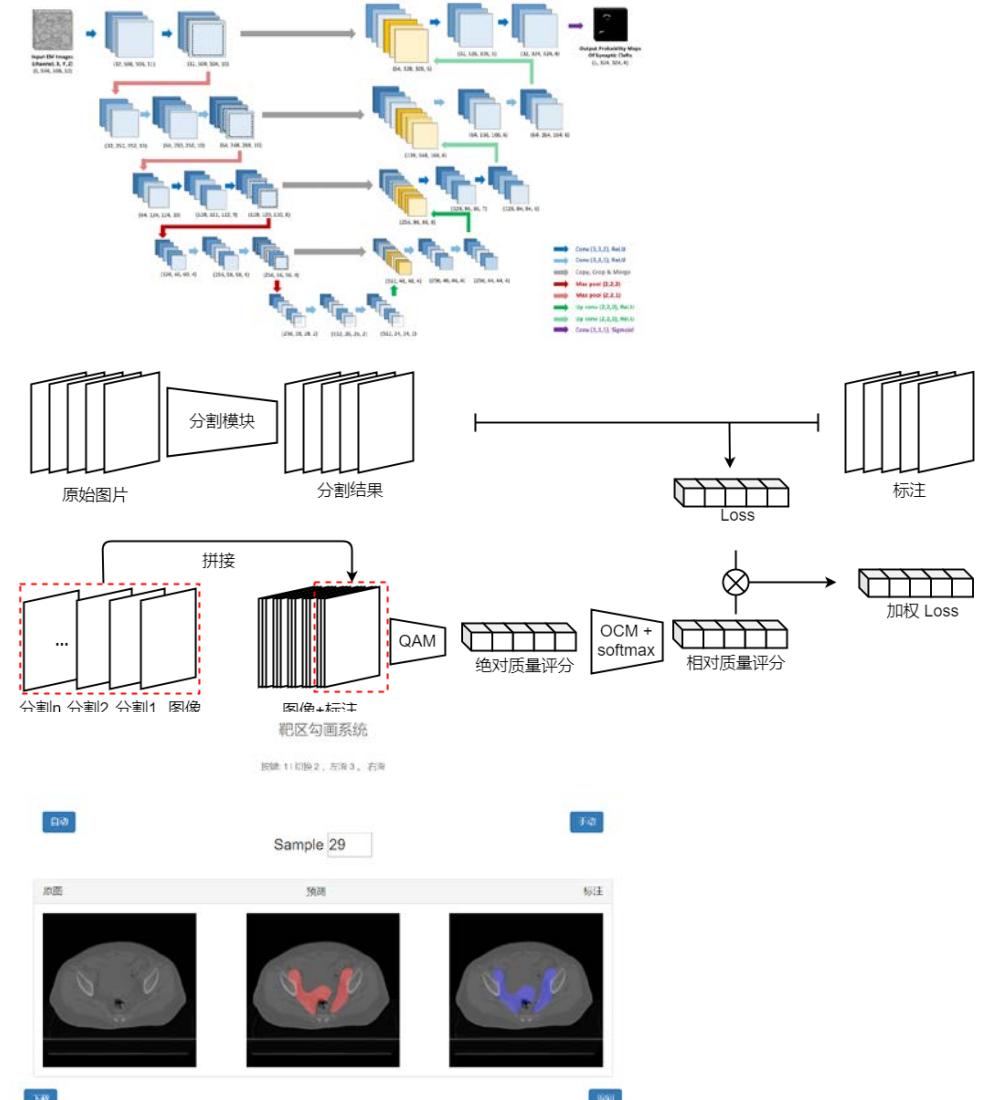


靶区勾画系统搭建

构建基于深度学习的靶区勾画模型

提出噪声标注样本下分割模型训练的算法

搭建可使用的靶区勾画系统

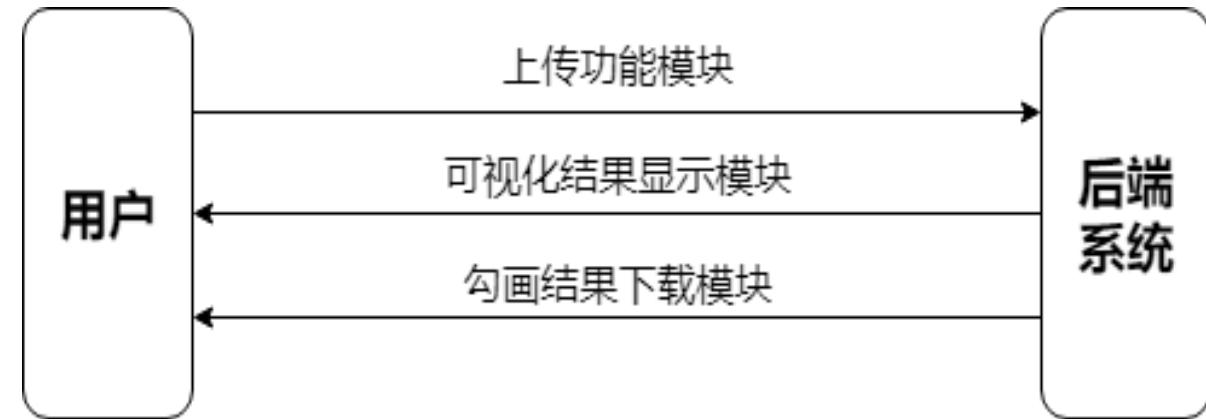




靶区勾画系统搭建 - 架构

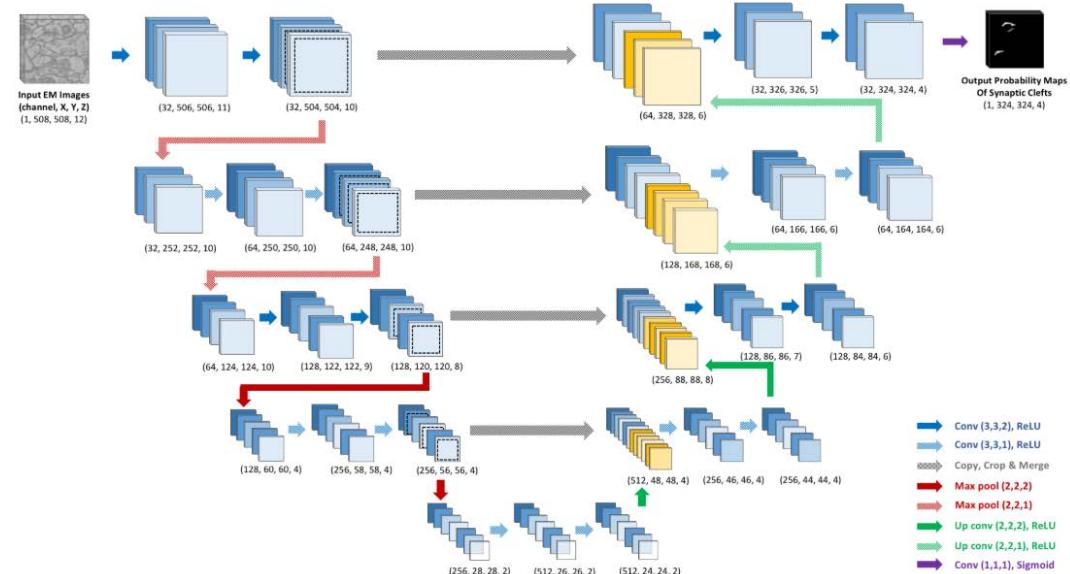
前端系统

- 上传功能模块
- 可视化结果显示模块
- 勾画结果下载模块



后端系统

- 预处理与数据转换模块
- 勾画结果生成模块
- 勾画可视化结果生成模块
- 数据上传与下载管理模块





靶区勾画系统搭建 – demo

- 网页端使用

<http://101.6.64.59:10134/>

功能

- 上传
- 自动生成靶区勾画部位
- 网页自动显示结果
- 下载生成结果

待改进

- 压力测试
- 与Dicom图片之间转换

靶区勾画系统

按键: 1 | 切换 2 , 左滑 3 。右滑

Sample 29

自动 手动

原图	预测	标注

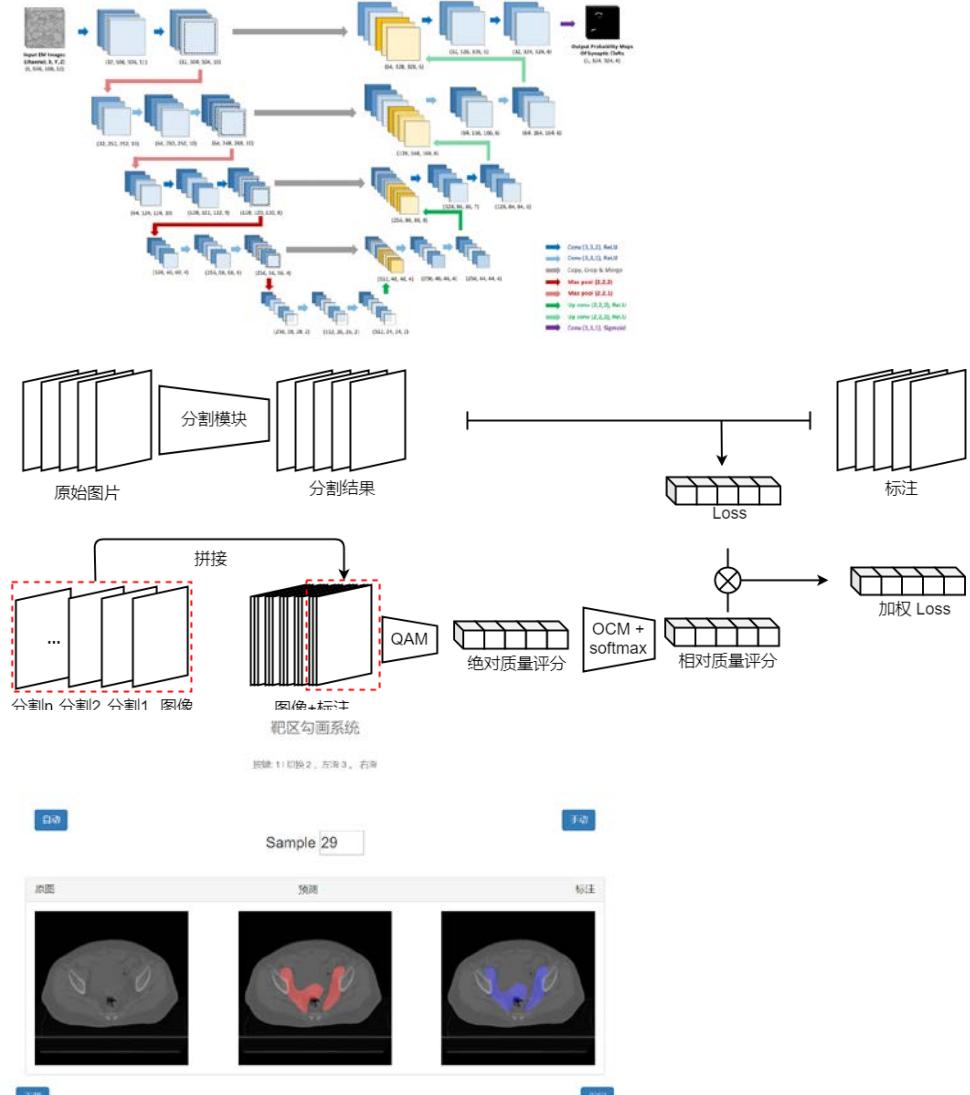
下载 返回



工作总结

构建基于深度学习的靶区勾画模型

- 搭建了一个基于深度学习的靶区勾画模型
- 对于模型多层次的修改进行性能提升



提出噪声标注样本下分割模型训练的算法

- 提出质量检测模块 (QAM)
- 提出防过拟合模块 (OCM)

搭建可使用的靶区勾画系统

- 分析需求并系统化现有模型
- 构建demo



Q&A

谢谢！



参考文献

- [1] Shi J, Malik J. Normalized cuts and image segmentation[J]. *IEEE Transactions on pattern analysis and machine intelligence*, 2000, 22(8): 888-905.
- [2] Tobias O J, Seara R. Image segmentation by histogram thresholding using fuzzy sets[J]. *IEEE transactions on Image Processing*, 2002, 11(12): 1457-1465.
- [3] Felzenszwalb P F, Huttenlocher D P. Efficient graph-based image segmentation[J]. *International journal of computer vision*, 2004, 59(2): 167-181.
- [4] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[C]. *Advances in neural information processing systems*. 2012: 1097-1105.
- [5] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. *arXiv preprint arXiv:1409.1556*, 2014.
- [6] Chen L C, Papandreou G, Kokkinos I, et al. Semantic image segmentation with deep convolutional nets and fully connected crfs[J]. *arXiv preprint arXiv:1412.7062*, 2014.
- [7] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015: 3431-3440.
- [8] Noh H, Hong S, Han B. Learning deconvolution network for semantic segmentation[C]. *Proceedings of the IEEE international conference on computer vision*. 2015: 1520-1528.
- [9] Badrinarayanan V, Kendall A, Cipolla R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation[J]. *arXiv preprint arXiv:1511.00561*, 2015.
- [10] He K, Gkioxari G, Dollár P, et al. Mask r-cnn[C]. *Computer Vision (ICCV), 2017 IEEE International Conference on*. IEEE, 2017: 2980-2988.
- [11] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]. *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015: 234-241.
- [12] C. Rother, V. Kolmogorov, and A. Blake, GrabCut: Interactive foreground extraction using iterated graph cuts, *ACM Trans. Graph.*, vol. 23, pp. 309–314, 2004.
- [13] Ciresan D, Giusti A, Gambardella L M, et al. Deep neural networks segment neuronal membranes in electron microscopy images[C]. *Advances in neural information processing systems*. 2012: 2843-2851.
- [14] Kamnitsas K, Ledig C, Newcombe V F J, et al. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation[J]. *Medical image analysis*, 2017, 36: 61-78.
- [15] Dou Q, Chen H, Jin Y, et al. 3D deeply supervised network for automatic liver segmentation from CT volumes[C]//*International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, Cham, 2016: 149-157.
- [16] Roth H R, Shen C, Oda H, et al. Deep learning and its application to medical image segmentation[J]. *Medical Imaging Technology*, 2018, 36(2): 63-71.
- [17] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[J]. *arXiv preprint arXiv:1709.01507*, 2017, 7.
- [18] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//*Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016: 770-778.
- [19] Mosinska A, Marquez-Neila P, Kozinski M, et al. Beyond the Pixel-Wise Loss for Topology-Aware Delineation[C]//*Conference on Computer Vision and Pattern Recognition (CVPR). 2018 (CONF)*.
- [20] Zhang R, Isola P, Efros A A. Colorful image colorization[C]//*European Conference on Computer Vision*. Springer, Cham, 2016: 649-666.