

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

2019.4



清华大学

Tsinghua University



目录

- 问题介绍
- 方法设计
- 实验结果
- 问题拓展
- 问题分析
- 进度安排



问题介绍 - 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**

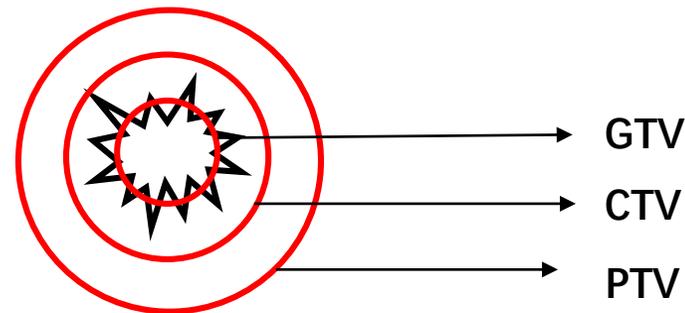
临床灶，为一般的诊断手段能够诊断出的可见的具有一定形状和大小的恶性病变的范围，包括转移地淋巴结和其它转移的病变

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

CTV指按一定的时间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。





问题介绍

目的

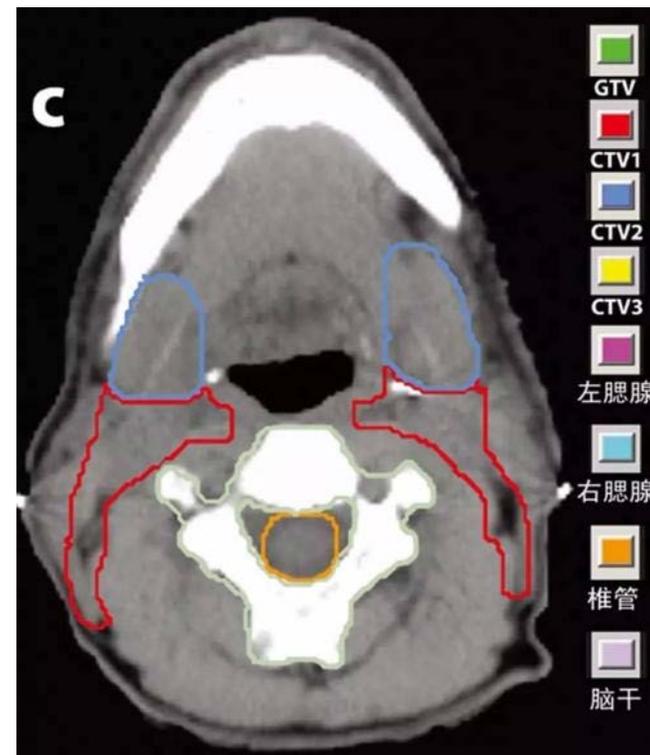
- 可使用的自动化的靶区勾画系统

方法

- 深度学习的语义分割方法

意义

- 极大程度减少医生勾画工作量
- 对于不同的靶区类别的高维特征提取进行类别间聚类分析
- 问题拓展 【算法提升】





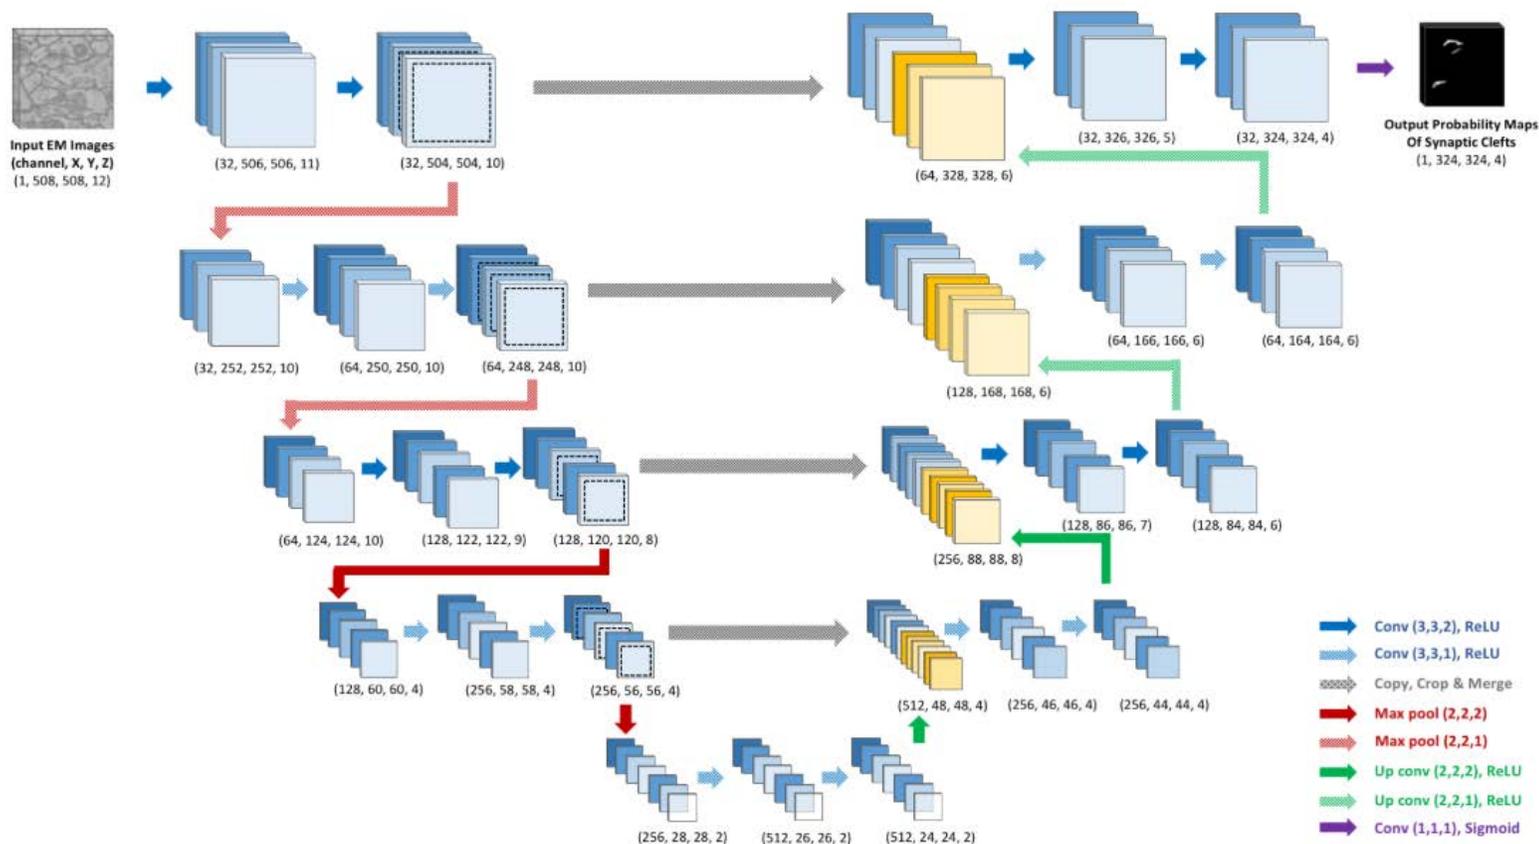
方法设计

- **Baseline**
 - UNet 3D [1]
- **模块改进(I)**
 - Res-unet [2]
- **模块改进(II)**
 - Squeeze-and-Excitation Module [3]
- **损失函数(I)**
 - Cycle Loss [4]
- **损失函数(II)**
 - Dice Loss [5]
- ...



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

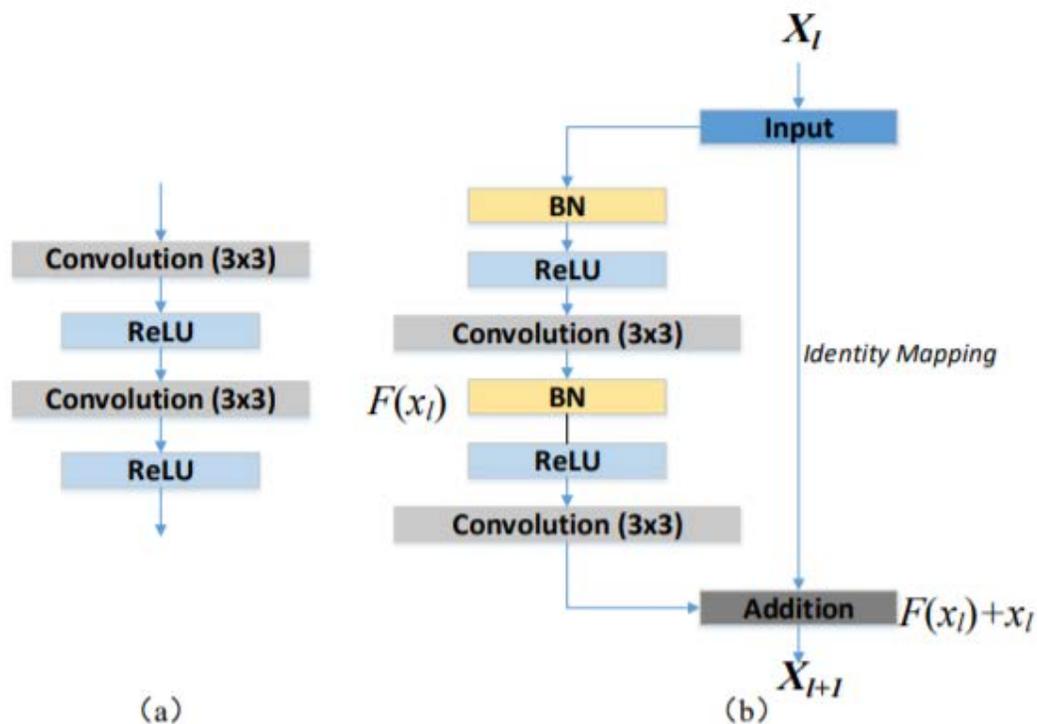
$$d = \frac{2 \times Intersection(V_{pred}, V_{gt})}{V_{pred} + V_{gt}}$$

Baseline average dice ratio – 0.747



方法设计

• 模块改进(I) – Res-UNet



结构改进

- 添加了residual网络结构

优势

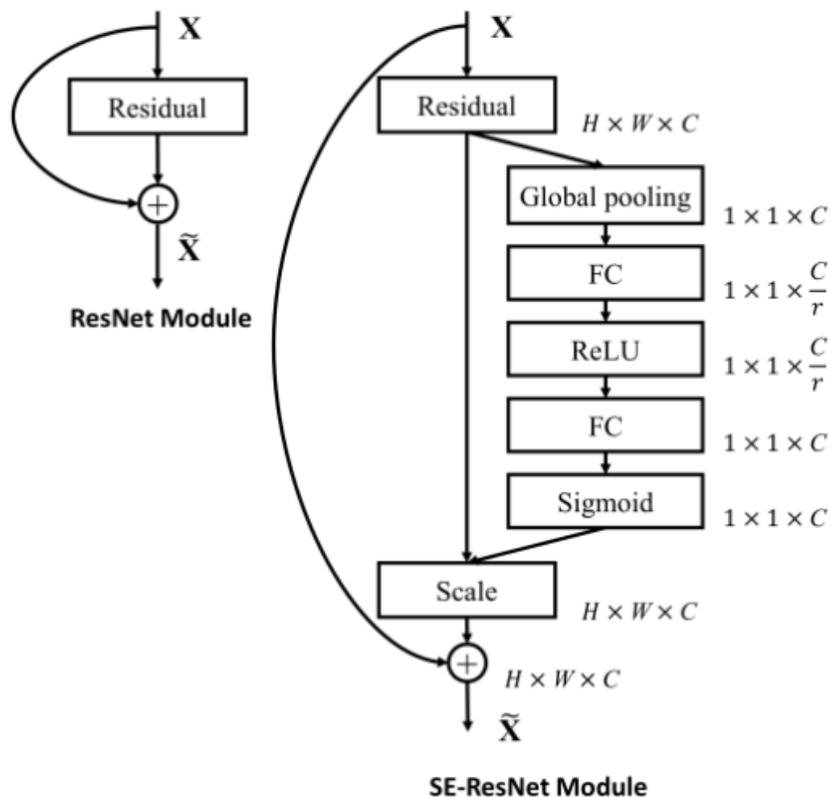
- 更深的网络结构
- 优化效果更稳定

dice ratio – 0.747 -> 0.753



方法设计

• 模块改进(II) – SE Module



结构改进

- 添加了SE module网络结构

优势

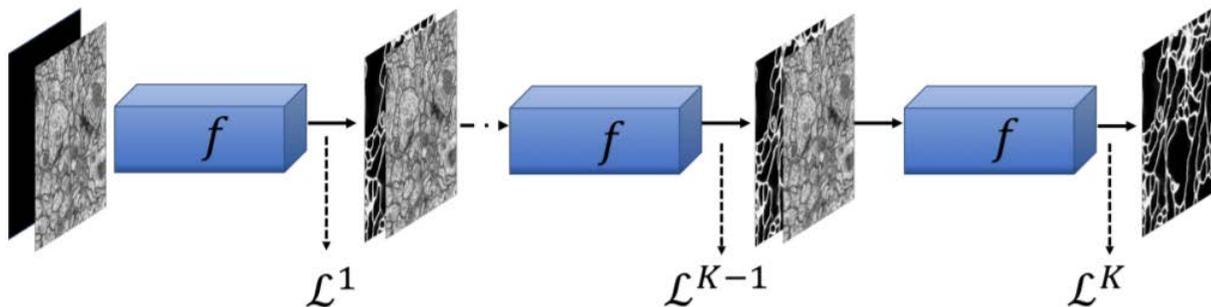
- Global Information Embedding
- Adaptive Recalibration
- Channel attention

dice ratio – 0.753 -> 0.755



方法设计

• 损失函数(I) – Cycle Loss



结构改进

- Cycle Loss

优势

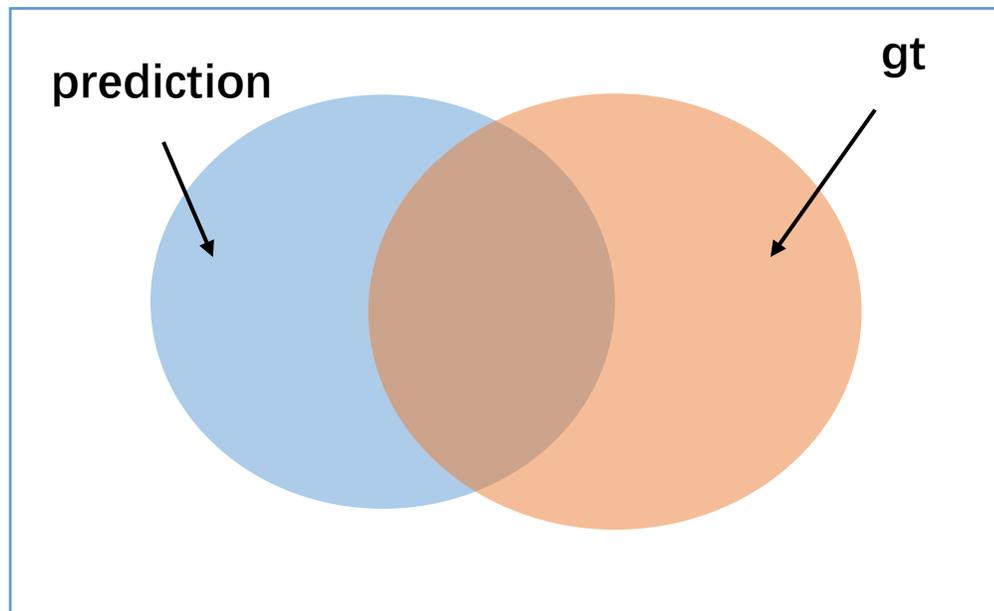
- 多次生成
- 提升对于细节分割效果

dice ratio – 0.755 -> 0.757



方法设计

• 损失函数(I) – Dice Loss



结构改进

- Dice Loss

$$\text{loss} = 1 - \frac{2 \times \text{Intersection}(V_{\text{pred}}, V_{\text{gt}})}{V_{\text{pred}} + V_{\text{gt}}}$$

优势

- 试验中显著降低FP的出现
- 收敛速度加快

dice ratio – 0.757 -> 0.763



实验结果

Unet (**Baseline**)

-> dice value: 0.747

Res - Unet

-> dice value: 0.753

Res - Unet + SE module

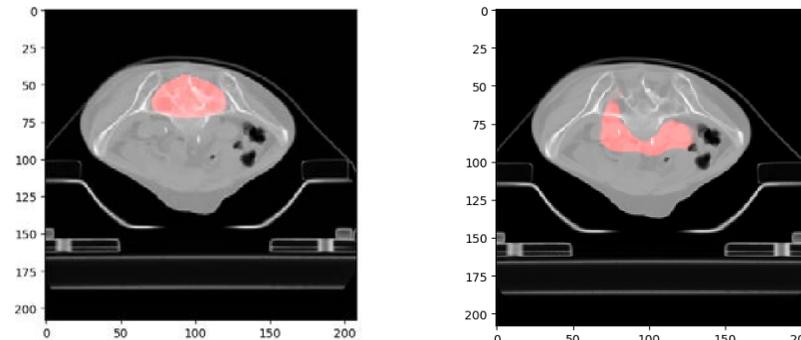
-> dice value: 0.755

Res - Unet + SE + Cycle

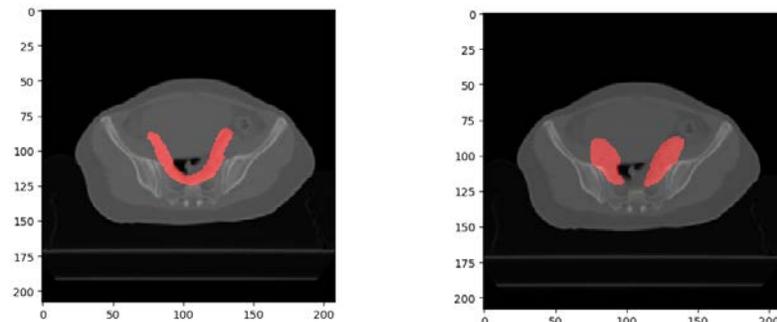
-> dice value: 0.757

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

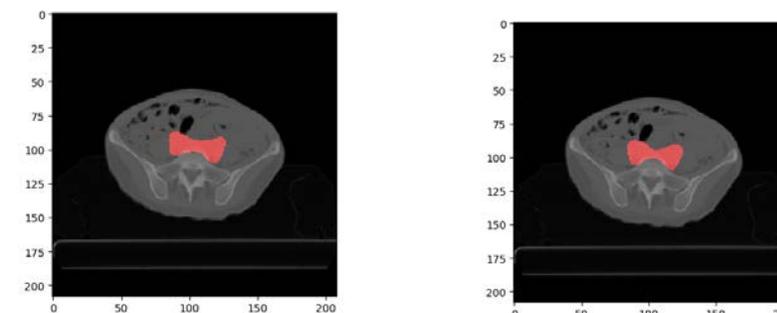
- 单个模块有一定的小提升
- 不同的医生的标注习惯存在较大的差异，使得衡量标准无法统一



Dice = 0.01 (left-gt right-pred)



Dice = 0.64



Dice = 0.91



实验结果

• 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

自动

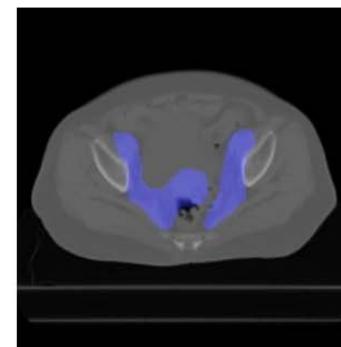
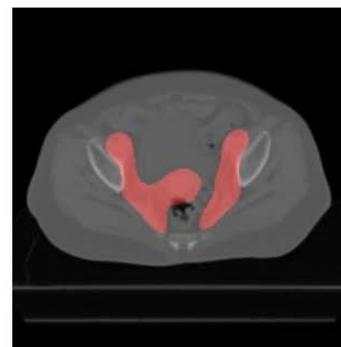
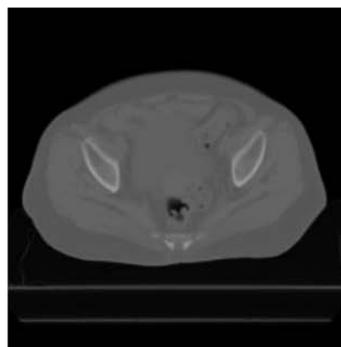
手动

Sample 29

原图

预测

标注



下载

返回



问题拓展

含有噪声标注的训练集中得到较精确的分割结果

- 问题描述

- 在含有噪声标注较多或标注标准不统一的数据集中，在没有额外的标注数据可获取的情况下维持较高的图像分割准确性

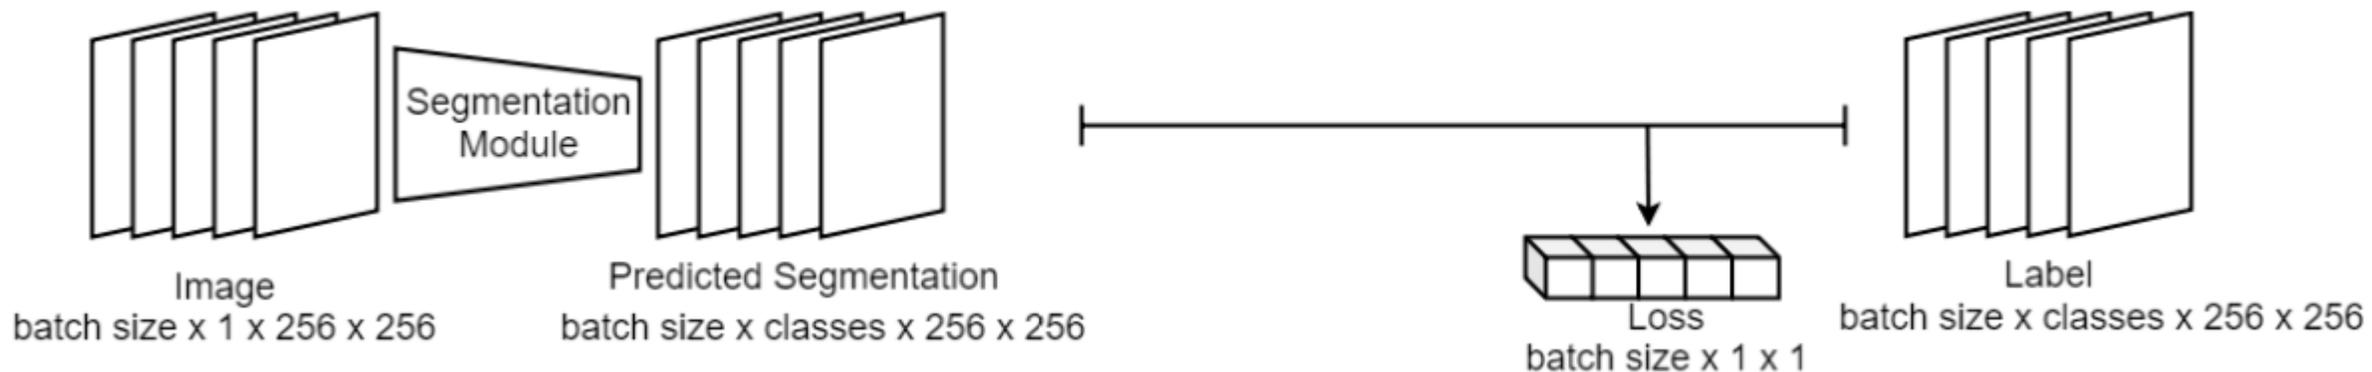
- 解决方法

- 弱监督分割
- 样本中不同标注质量的自我评估



问题拓展

样本中不同标注质量的自我评估



思路

- 通过网络的自动评估功能，对于每一个label进行打分
- 利用标注噪声的自身矛盾和冲突进行质量评估与二次权值重置
- 在无法获得更多的额外标注数据的情况下，通过筛选方法挑选出同一batch中质量较高的label对应的样本，对于batch中所有样本进行二次权重赋值



问题分析

靶区自动分割系统

- 标注边界较为模糊，没有额外质量评估标注，不适合弱监督
- 实验样本中标注不统一的现象较为明显，限制了模型的准确率上限

样本中不同标注质量的自我评估

- 需要对于标注相对质量的高低无标注下进行评分
- 过拟合到较少样本上，模型泛化能力受到极大影响
- 分割准确性可能不稳定，与初始化参数具有极大的关系



进度安排

- ~2018.12 [x] 文献调研
- ~2018.1 [x] 数据准备与baseline实现
- ~2019.4 [x] 算法改进与提升, 系统设计与demo展示
- ~2019.5 拓展问题研究-在噪声标注下如何训练出高精度的模型
- ~2019.6 材料准备 毕业答辩



参考文献

- [1] Çiçek, Özgün, et al. "3D U-Net: learning dense volumetric segmentation from sparse annotation." International conference on medical image computing and computer-assisted intervention. Springer, Cham, 2016.
- [2] Zhang, Zhengxin, Qingjie Liu, and Yunhong Wang. "Road extraction by deep residual u-net." IEEE Geoscience and Remote Sensing Letters 15.5 (2018): 749-753.
- [3] Hu, Jie, Li Shen, and Gang Sun. "Squeeze-and-excitation networks." Proceedings of the IEEE conference on computer vision and pattern recognition. 2018.
- [4] Milletari, Fausto, Nassir Navab, and Seyed-Ahmad Ahmadi. "V-net: Fully convolutional neural networks for volumetric medical image segmentation." 2016 Fourth International Conference on 3D Vision (3DV). IEEE, 2016.
- [5] Mosinska, Agata, et al. "Beyond the pixel-wise loss for topology-aware delineation." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018.