

基于坐标信息与多尺度并行网络的气道分割方法

刘卫朋^{1,2,3}, 李健^{1,2}, 祁业东^{2,3}, 任子文^{2,3}, 王源^{2,3}

1. 河北工业大学生命科学与健康工程学院, 天津 300401; 2. 省部共建电工设备可靠性与智能化国家重点实验室, 天津 300401;
3. 河北工业大学人工智能与数据科学学院, 天津 300401

【摘要】为解决手术导航中气道模型精度不足的问题,提出了一种基于坐标信息与多尺度并行网络的气道分割方法。首先通过并行网络分别学习不同尺度的气道特征,以解决不同尺寸气道之间的特征冲突问题。其次提出坐标引导的上采样模块,通过浅层特征中的坐标信息指导深层特征进行特征重建,限制目标的空间位置,提高模型精度。最后提出通道引导的多尺度特征聚合模块,用于在多个尺度上捕获语义信息并探索不同尺度特征之间的通道关系。在公开数据集LIDC-IDRI和EXACT'09上对提出的方法和其他模型进行训练和测试。实验表明,该方法的平均骰子系数达到了93.20%,相比于3D U-Net提高了2.61%,而假阳性率只有0.012%。此外,树长检测率和分支检测率分别达到了88.59%和97.42%。该方法可用于肺部疾病诊断或导航支气管镜检查等领域。

【关键词】气道分割;坐标信息;多尺度特征聚合;并行网络

【中图分类号】R318;TP391.4

【文献标志码】A

【文章编号】1005-202X(2024)10-1216-09

Airway segmentation method based on coordinate information and multi-scale parallel network

LIU Weipeng^{1,2,3}, LI Jian^{1,2}, QI Yedong^{2,3}, REN Ziwen^{2,3}, WANG Yuan^{2,3}

1. School of Health Sciences and Biomedical Engineering, Hebei University of Technology, Tianjin 300401, China; 2. State Key Lab of Reliability and Intelligence of Electrical Equipment, Tianjin 300401, China; 3. School of Artificial Intelligence, Hebei University of Technology, Tianjin 300401, China

Abstract: An airway segmentation method based on coordinate information and multi-scale parallel network is proposed to solve the problem of insufficient accuracy of airway model in surgical navigation. Airway features at different scales are learned separately by a parallel network to address the feature conflict arising from airways of different sizes. Then, a coordinate guided up-sampling module is designed to utilize coordinate information from shallow features for guiding reconstruction of deeper features, thus restricting the spatial location of the target and improving the model accuracy. Finally, a channel guided multi-scale feature aggregation module is constructed to capture semantic details across multiple scales and investigate channel relationships between features at different scales. The proposed method and other models are trained and tested on two public datasets, namely LIDC-IDRI and EXACT'09. Experimental results show that the proposed method achieves an average Dice coefficient of 93.20% which is 2.61% higher than 3D U-Net, a false positive rate of only 0.012%, a tree length detection rate of 88.59%, and a branch detection rate of 97.42%, demonstrating that the method can be applied to lung disease diagnosis or navigation bronchoscopy.

Keywords: airway segmentation; coordinate information; multi-scale feature aggregation; parallel network

前言

【收稿日期】2024-03-18

【基金项目】国家重点研发计划(2020YFB1313703);国家重大科研仪器设备研制项目(62027813);河北省重点研发计划(21372003D);河北省自然科学基金(F2022202054, F2022202064)

【作者简介】刘卫朋,博士,研究员,研究方向:医学图像处理、手术机器人控制, E-mail: liuweipeng@hebut.edu.cn

肺结节是多数肺癌早期的表现形式,对肺结节进行病理学检查是肺癌确诊的金标准^[1]。随着计算机成像技术的不断发展,支气管镜导航系统的问世使支气管镜可以到达更深的支气管进行病理学检查,从而提高周围型肺癌的诊断率^[2],而精确的气道模型是支气管镜导航系统的基础。

在传统的气道分割方法中,区域生长法是最常用的气道分割方法^[3-5],文献[6]评估了EXACT'09挑战赛中的15种算法,其中有11种为基于区域生长的

方法。区域生长法利用CT图像中气道壁与管腔之间的强度值差异实现气道的分割。然而,随着分支等级的增加,气道壁与管腔之间的对比度会逐渐下降,导致在管腔内生长的气道进入肺实质,造成“泄露”问题。传统的气道分割方法依赖人工选择的特征,而基于深度学习的方法直接从数据中学习气道的语义信息。Garcia-Uceda等^[7]提出了一种基于U-Net的气道分割方法,通过使用能够覆盖整个肺部的大型3D图像块作为网络的输入数据,保证其可以获得完整的气道信息。Yun等^[8]提出基于2.5D卷积神经网络的气道分割方法,通过在图像的冠状面、矢状面、横截面3个方向上进行卷积,使二维网络获得三维信息。Cheng等^[9]通过使用空洞卷积代替下采样操作,减少小气道特征因多次下采样操作造成的特征丢失问题。然而,以上方法均未考虑不同气道之间的尺寸差异问题,这会导致因不同气道所需的上下文尺度不同而造成模型性能下降。针对这一问题,Guo等^[10]通过多信息融合的卷积神经网络对气道进行粗分割,然后再利用基于卷积神经网络的区域生长法获得更多的末端小气道。Qin等^[11]将气道分割任务转化为连通性预测任务,以此保证气道的连通性,同时采用两个尺寸不同的网络分别学习不同尺度的特征信息,保证特征信息的完整性。Nan等^[12]将模糊逻辑与注意力机制结合获得模糊注意力层,用于保证小气道的连续,但会导致较高的假阳性。气道是一个复杂的树状结构,大气道需要更大的感受野以获得足够的上下文信息,而小气道的特征尺寸通常只有几个体素,经过多次下采样操作后很容易丢失,不考虑气道尺寸大小的影响会导致模型对小气道的识别能力变弱。虽然,通过为小气道体素分配更大的权重,可以获得更完整的气道模型,但会导致“泄露”问题。与区域生长的“泄露”不同,此处的“泄露”表现为分割结果的直径比实际情况更大,在手术导航过程中可能会导致手术器械偏离真实位置,增加手术风险。

针对上述问题,本文提出了一种基于坐标信息与多尺度并行网络的气道分割方法,通过利用两个网络分别学习不同尺寸的气道信息,用于解决因大小气道之间差异所导致的特征冲突问题。此外,本文通过提出坐标引导的上采样模块,整合浅层特征中目标的位置信息,帮助深层特征进行特征重建,从而提高模型分割结果的精度。为了获得每个通道中最合适的尺度特征,本文引入通道引导的多尺度聚合模块,捕获多个尺度上的语义信息,同时探索不同尺度特征之间的通道关系。

1 本文方法

1.1 数据预处理

气道标签分类。本文采用两个网络分别学习不同尺寸的气道特征。因此,需要将数据集按照气道大小进行分类。本文通过提取标签的骨架线,并给每段骨架线进行分级从而对标签中所有的气道分支进行分级,然后去除需要保留的气道之外的分支。本文按照数据集中的标签划分为两个不同的子集(L1和L2),第一个子集(L1)包含完整的气道结构,第二个子集(L2)只包含第4代及更小的支气管分支。分类结果如图1所示。

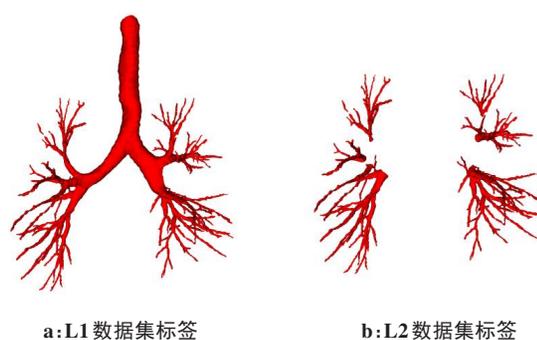


图1 标签分类

Figure 1 Label classification

裁剪感兴趣区域(Region of Interest, ROI)。气道结构呈现复杂的树状结构,气管及主支气管位于胸腔内的中纵隔内,肺叶支气管及更小的支气管则分布在肺叶内^[13]。然而,完整的胸部CT图像不仅有肺部区域还包含躯干、骨骼、背景等复杂且对气道分割无关的区域。本文首先通过大津阈值法进行二值分割,然后使用形态学操作补充孔洞并将主支气管与肺实质连接,最后通过最大连通域提取操作获取肺部掩码图像。计算肺部掩码图像的最大外接边框作为原图的裁剪范围,为了防止使用零填充的卷积操作影响靠近肺部表面气道的预测,本文在提取到肺部掩码图像的边界框后向外扩展30个体素以减少零填充造成的影响。

1.2 网络结构

针对气道复杂的拓扑结构,本文设计了融合坐标信息的多尺度并行网络结构,用于对不同尺寸的气道进行分割。本文的网络框架主要由两个不同尺寸的网络组成,分别是处理完整气道的全尺寸网络(Full-Scale Network, FSN)和以小气道为目标的小尺寸网络(Small-Scale Network, SSN),通过分别设计两个网络的深度和宽度使其适应不同的分割任务。由

于气道的连续性及复杂的分支结构,两个网络均以3D U-Net作为主干网络^[14],相比于使用2D^[15]或2.5D^[8]结构的网络,3D卷积块能够提取更多的空间信息,改善气道分支的断裂问题。此外,两个网络都

包含坐标引导的上采样模块(Coordinate Guided Up-Sampling Module, CGU)和通道引导的多尺度聚合模块(Channel Guided Multi-scale Aggregation Module, CG-MSAM)。网络结构如图2所示。

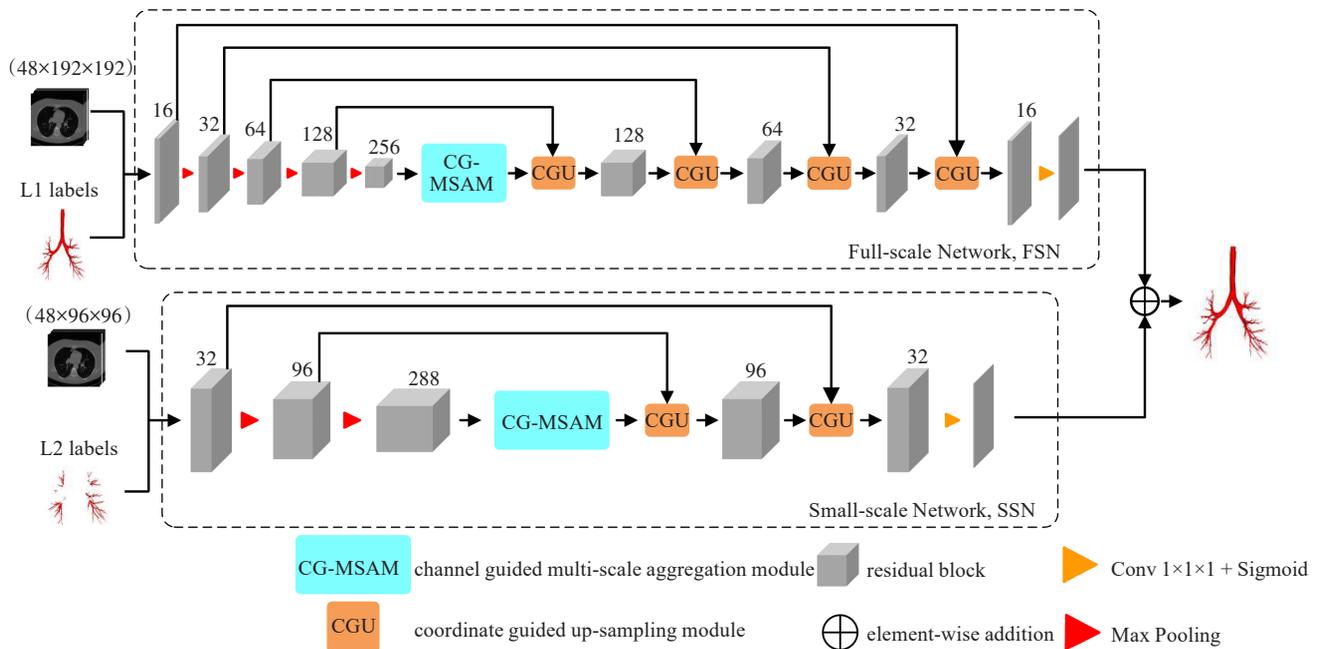


图2 网络结构

Figure 2 Network structure

FSN主要用于捕获大尺寸的气道特征,使用4个池化层来获得足够大的感受野以确保气管和左右主支气管能够完整分割。使用残差结构进行特征提取,残差块的主路由两个带有组归一化(Group Norm, GN)的标准卷积块和一个激活函数组成,残差路由一个用来调整特征通道数的1x1x1卷积和一个GN组成,在残差连接之后执行ReLU激活。在较深的网络中使用残差结构避免了梯度消失或梯度爆炸现象。对于SSN,本文仅采用两次下采样操作以减少小尺寸气道特征信息的丢失,同时采用更宽的网络结构保证网络的特征提取能力。虽然更少的下采样操作可以保证特征图的分辨率,但会因为感受野太小而无法获取足够的上下文信息。针对这一问题,本文对SSN中的残差块进行了调整,在主路径中使用3个连续的空洞卷积保证感受野的获取,为防止空洞卷积造成的“网格效应”,造成局部信息的丢失,本文按照HDC^[16]的设计规则将3个卷积的膨胀

率分别设置为1、2、3。两个网络的残差块如图3所示。最后,将两个网络的气道预测图相加获得最终的分割结果。

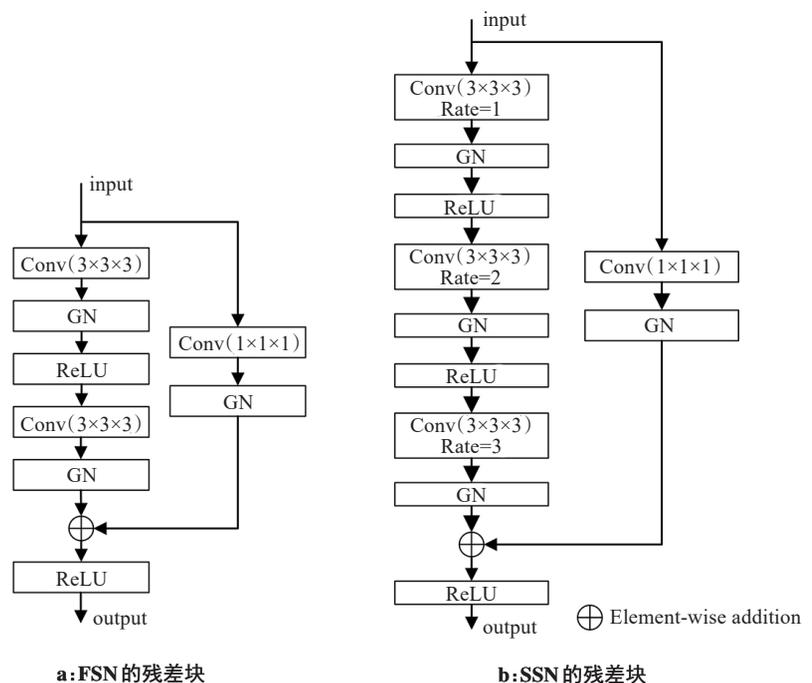


图3 残差块

Figure 3 Residual block

1.3 坐标引导的上采样模块

语义分割网络中解码器部分的主要作用是恢复类别像素的位置^[17],深层特征中包含丰富的语义信息,但位置信息比较模糊,在特征解码阶段无法获得足够的位置信息。相对于深层特征,浅层特征具有较高的空间分辨率和更丰富的细节信息,位置信息

很充足,目标位置相对准确。此外,气道在胸腔内的位置不是随机分布的,所以浅层特征中气道的位置信息可以作为特征重建时的补充信息,帮助深层特征恢复到原始的尺寸和分辨率。本文提出了CGU,通过提取浅层特征的位置坐标信息指导深层特征进行特征重建。模块结构如图4所示。

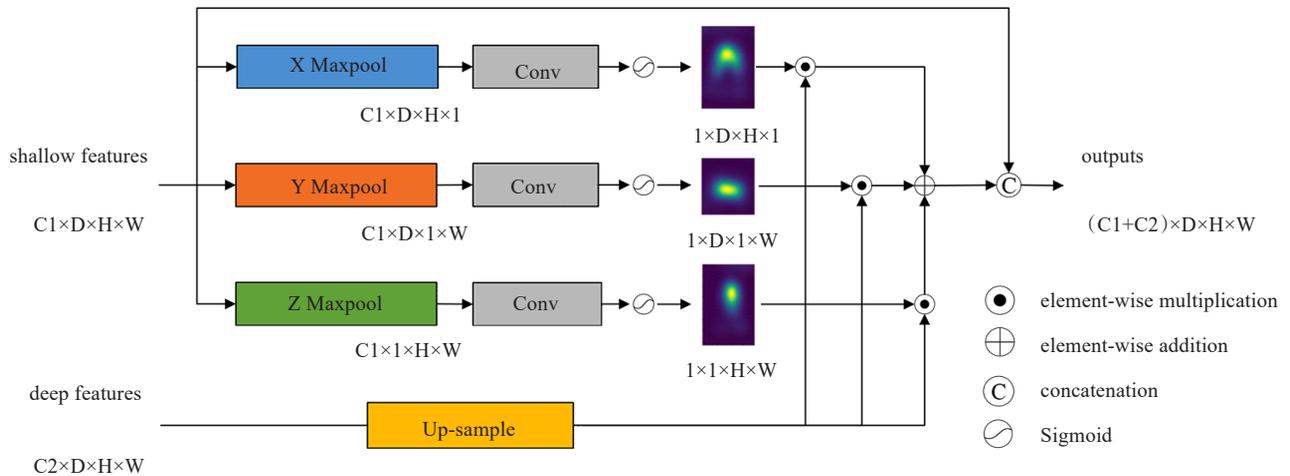


图4 坐标引导的上采样模块

Figure 4 Coordinate guided up-sampling module

CGU 分别在3个方向上对浅层特征执行最大池化操作以提取浅层特征中完整气道的坐标信息,然后经过 $1 \times 1 \times 1$ 卷积和sigmoid激活函数获得坐标注意力权重。对通过上采样操作获得的深层特征进行坐标加权,获得具有位置信息的深层特征图。该模块可以将浅层特征中包含的坐标信息融合到深层特征中,保证了特征图中目标位置的准确性。

1.4 通道引导的多尺度特征聚合模块

气道为复杂的树状结构,随着气道分支等级的增加,气道直径越来越小。而不同尺度的气道特征所需要的感受野大小也不同,大气道通常需要较大的感受野以获得足够的上下文信息,而小气道所需要的感受野相对较小,远距离的特征信息对小气道结构的识别帮助不大。因此,本文提出了CG-MSAM用于多尺度特征的提取与融合。该模块分为多尺度特征提取和多尺度特征融合两部分,模块结构如图5所示。

首先,多尺度特征提取部分通过4个不同尺寸的池化操作获得不同尺度和不同子区域之间的特征信息,以减少不同子区域之间的上下文信息丢失。与金字塔池化模块相比^[18],该部分没有改变特征通道的数量,保证了通道信息的完整性,同时,加入原始

特征图减少因池化操作造成的特征丢失问题。多尺度特征融合部分通过全局全局池化操作将原始特征图压缩成原始通道特征图,并以此为基础构建了5个多层感知器。最后,将通过多层感知器获得的通道权重分别对不同尺度的特征图进行加权,并将其按元素相加进行特征融合,以挖掘不同尺度特征之间的通道关系。

1.5 气道提取

为了从模型输出中获得连续的气道树,本文通过提取最大连通域获得分割结果:首先,对两个网络输出的气道概率图进行阈值分割以获得气道的二值分割结果,本文使用的阈值为0.5。为了保证气道的连通性以及小气道的识别性能,将两张二值图像进行融合,以保证气道的连通性以及补充部分小气道的分割结果。最后,输出结果中可能包含一些气道外分散的假阳性区域,通过对输出的二值图像进行连通域分析,将检索到的最大连通域作为最终的分割结果,获得一个连续且完整的二值气道图像。

2 实验设置及结果分析

2.1 实验数据集

实验数据集包括60张胸部CT扫描,其中40张

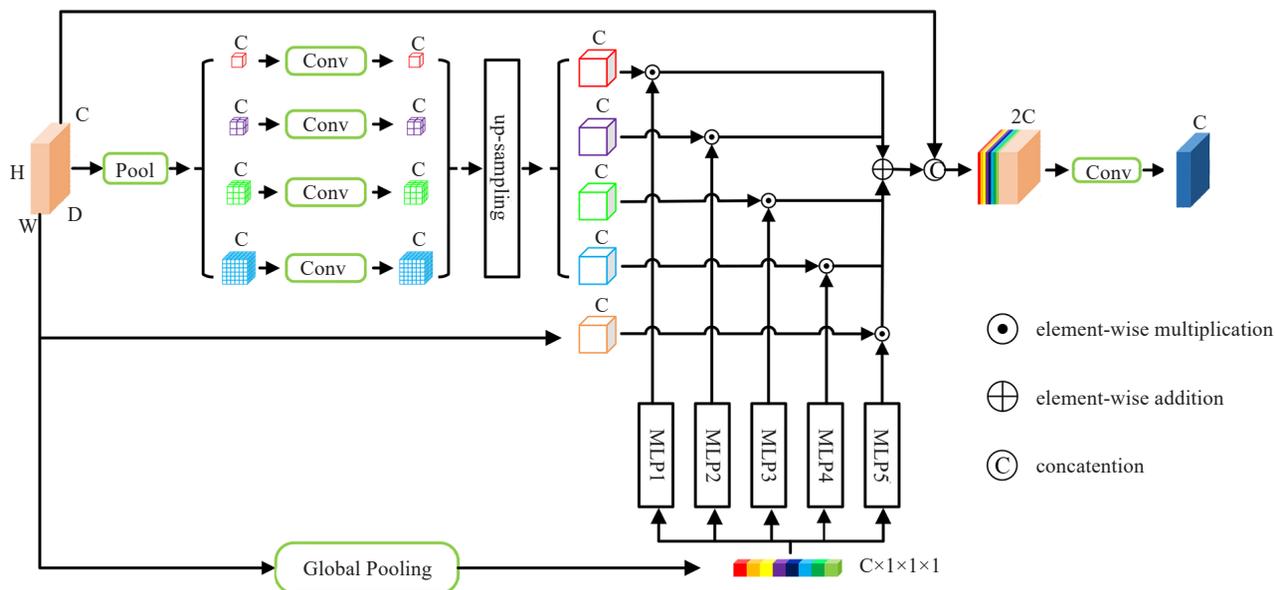


图5 通道引导的多尺度特征聚合模块
Figure 5 Channel guided multi-scale feature aggregation module

来自公共数据集 LIDC-IDRI^[19], 20 张来自公共数据集 EXACT'09 中的训练集^[6]。EXACT'09 仅提供未经气道注释的原始 CT 图像。LIDC-IDRI 包括 1 018 张带有肺结节注释的扫描图像。数据集所有扫描的轴向切片大小相同, 像素大小为 512×512, 空间分辨率为 0.500~0.781 mm, 切片厚度为 0.45~1.0 mm。数据集的气道标注均由上海交通大学提供^[20]。在实验中, 本文将数据集随机分为训练集(40 张)、验证集(10 张)和测试集(10 张)。

考虑到 GPU 内存的限制及标签气道的尺寸, 本文将 L1 数据集裁剪为 48×192×192 的图像块, L2 数据集裁剪为 48×128×128 的图像块, 以适用于两个网络的不同任务。将 HU 值调整为 [-1000, 600], 使窗口(包括窗宽和窗位)适合观察肺部组织, 然后将其映射至 (0, 255) 范围内, 并进行归一化处理。此外, 为了提高模型的泛化性能以及人为地增加可用的训练数据量, 本文还对训练数据进行了一些数据增强操作。在训练过程中对用于训练的图像块应用随机刚性变换和随机弹性变换, 刚性变换包括: 在 3 个方向上的随机翻转; (0.8, 1.2) 范围内的随机缩放; 最大 10° 的随机 3D 旋转。此外, 还通过增加随机噪声、随机伪影进行数据增强, 以进一步提高模型的鲁棒性。以上所有数据增强操作均以 0.5 的概率应用于训练集中所有的图像块上。

2.2 实验设置

本文采用 Tversky 损失函数对模型进行训练^[21], 通过平衡不同类别之间的权重, 更好地解决类别不平衡问题。公式如下:

$$\text{Loss} = 1 - \frac{\text{TP}}{\text{TP} + \alpha\text{FP} + \beta\text{FN}} \quad (1)$$

其中, TP 为真阳性, 即模型预测正确的正样本数量。FP 为假阳性, 即模型预测错误的负样本数量。FN 为假阴性, 即模型预测错误的正样本数量。 α 和 β 是用于调整 FP 和 FN 权重的超参数, 一般设置 $\alpha + \beta = 1$, 当 $\alpha = \beta = 0.5$ 时, Tversky 损失函数等于 Dice 损失函数。

本文使用 Adam 优化器 ($\beta_1=0.900$, $\beta_2=0.999$) 用于训练模型, 学习率为 1.0e-05, 衰减率为 0.4, 每隔 30 次迭代进行一次学习率的调整, 最大训练周期设置为 200。为防止过拟合, 本文统计了连续 30 次迭代内验证损失的变化, 当验证损失连续 30 次迭代不下降时, 训练终止。在本文中, FSN 的损失函数中 α 和 β 分别设置为 0.7 和 0.3, 以此保证主干气道的准确性, SSN 的损失函数中 α 和 β 均被设置为 0.5, 提高小气道检出能力的同时保证检出气道的准确性。本文所提出的模型在 PyTorch 框架上实现, 并在具有 48 G 内存的 RTX A6000 上进行训练。

2.3 评估指标

气道树是一个连续的树状结构, 人工标注的气道标签并不一定是完整的, 可能存在一些遗漏。模型根据气道标签学习气道的特征, 并在原始 CT 扫描中应用学到的气道特征, 找到所有可识别的气道。因此, 模型提供的不是与标签完全匹配的结果, 而是与标签特征匹配的结果。本文采用两种类型的指标来评估气道分割模型的性能。第一种是常见的分割任务中的评估指标, 第二种是针对气道树结构的评估指标。

第一种评估指标包括Dice相似系数(DSC)、灵敏度(Sen)、精度(Prec)和假阳性率(FPR),本文采用这些指标评估模型的整体分割效果。计算公式如下:

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

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

$$Prec = \frac{TP}{TP + FP} \quad (4)$$

$$FPR = \frac{FP}{FP + TN} \quad (5)$$

其中,TP为真阳性,TN为真阴性,FP为假阳性,FN为假阴性。除了上述4个评估整体分割效果的指标外,本文还采用了两个指标用于评估分割结果的结构准确性,分别是树长检测率(TD)和分支检测率(BD)。TD是模型分割的气道长度与标签中气道长度的比值,其公式如下:

$$TD = \frac{T_{det}}{T_{ref}} \quad (6)$$

其中, T_{det} 是模型分割结果中所有与标签重合的分支总长度, T_{ref} 是标签中整个气道树分支的总长度。BD是正确检测到的气道分支与真实分支总数的百分比,其公式如下:

$$BD = \frac{B_{det}}{B_{ref}} \quad (7)$$

其中, B_{det} 是模型分割结果中所有达到要求的分支数量, B_{ref} 是标签中整个气道树的分支数量。在该指标中,只有从分割结果的分支中提取的位于真实标签中的中心线长度占真实标签分支长度>60%,才计入统计数量。由于每个文章中分支检测的评定标准不同,只有本文实现并测试的模型之间,BD才有对比价值,其他模型的BD结果仅作参考。

2.4 对比实验分析

本文方法使用3D U-Net作为分割框架的主干。因此,本文方法与其他基于编码-解码结构的CNN进行了对比实验,使用相同的训练策略和数据处理操作对3D U-Net^[14]、V-Net^[22]和Attention-Gated U-Net(AG U-Net)^[23]这3个常用的医学图像分割模型进行训练,并与其在测试集上的分割结果进行对比。此外,本文还与Qin等^[24]、Wu等^[25]和NaviAirway^[26]这3种最新的气道分割方法进行了比较。Qin等方法通过特征重校准模块加强特征图中关键的空间位置,使模型识别更多的分支,同时,使用注意力蒸馏模块加强管状对象的表征学习。Wu等考虑到气道的连续性提出了一种长期切片传播模块,用于整合相邻切片之间的特征,以此保证气道的连续性。NaviAirway模型受人类视觉启发提出了一种迭代训练策略,通过对不同尺寸的气道进行迭代训练减轻不同尺寸的气道特征之间的相互影响。同时,提出一个损失函数,通过提高对中等置信度体素的惩罚,提高模型对小气道的识别能力。由于部分文章没有提供模型的源代码,所以本文直接从相应文献中引用模型的分割结果。NaviAirway模型的源代码及数据处理过程已经公开,本文在相同数据集上对其进行重新训练并测试了模型的分割性能。

对比结果如表1所示,本文提出的方法具有最好的整体分割性能和良好的结构准确性。在模型的分割性能中,本文方法的DSC达到了93.20%,灵敏度和精度分别达到了95.51%和91.09%,且FPR仅有0.012%。这表明本文方法相比其他模型可以检测到更多的气道,而且分割结果更加精确。对于结构准确性,本文方法的TD和BD分别为88.59%和97.42%。这表明本文方法分割的气道模型更加完整。

表1 不同模型的分割性能对比(%)

Table 1 Comparison of segmentation performance among different models (%)

方法	DSC	灵敏度	精度	FPR	TD	BD
Qin等 ^[24] *	92.50±2.00	93.6±5.0	-	0.035±0.014	90.7±5.8	96.2±5.8
Wu等 ^[25] *	92.95±1.61	-	-	0.030±0.010	87.59±8.71	90.83±9.38
NaviAirway ^[26] **	89.52±1.35	94.01±1.70	86.05±2.04	0.019±0.006	72.65±10.60	71.71±21.31
3D U-Net ^[14] ***	90.59±1.39	91.56±2.52	89.72±2.04	0.013±0.004	64.04±9.39	50.87±13.63
V-Net ^[22] ***	82.63±2.62	96.34±1.58	72.47±4.18	0.046±0.007	81.85±5.12	91.30±6.92
AG U-Net ^[23] ***	87.67±1.12	96.75±1.40	80.17±1.71	0.032±0.010	84.88±6.59	93.55±7.54
本文方法	93.20±1.55	95.51±1.50	91.09±3.18	0.012±0.007	88.59±5.63	97.42±4.52

*表示没有提供源代码的模型,直接从文献中引用分割结果;**表示根据提供的源代码进行训练后,在本文的测试集上获得的结果;***表示常用的医学图像分割模型,重新实现后在本文的测试集上获得的结果

图6显示了不同模型在3D图像上的分割结果。其中,红色表示分割结果,绿色表示假阴性,黄色表示假阳性。从图中可以看出,本文模型(Proposed method)的分割结果更加接近真实情况,未检测到的气道相对较少。相比之下,在NaviAirway和3D U-Net的分割结果中,气道远端具有较多的假阴性区域,在

检测外围末端气道方面仍有一些不足。而AG U-Net和V-Net的分割结果显示,在已分割的气道表面具有较多的假阳性区域,这说明气道壁的一部分被错误分为气道,导致分割的气道直径大于气道的实际直径,在手术导航过程中可能会导致手术器械偏离真实位置,增加手术风险。

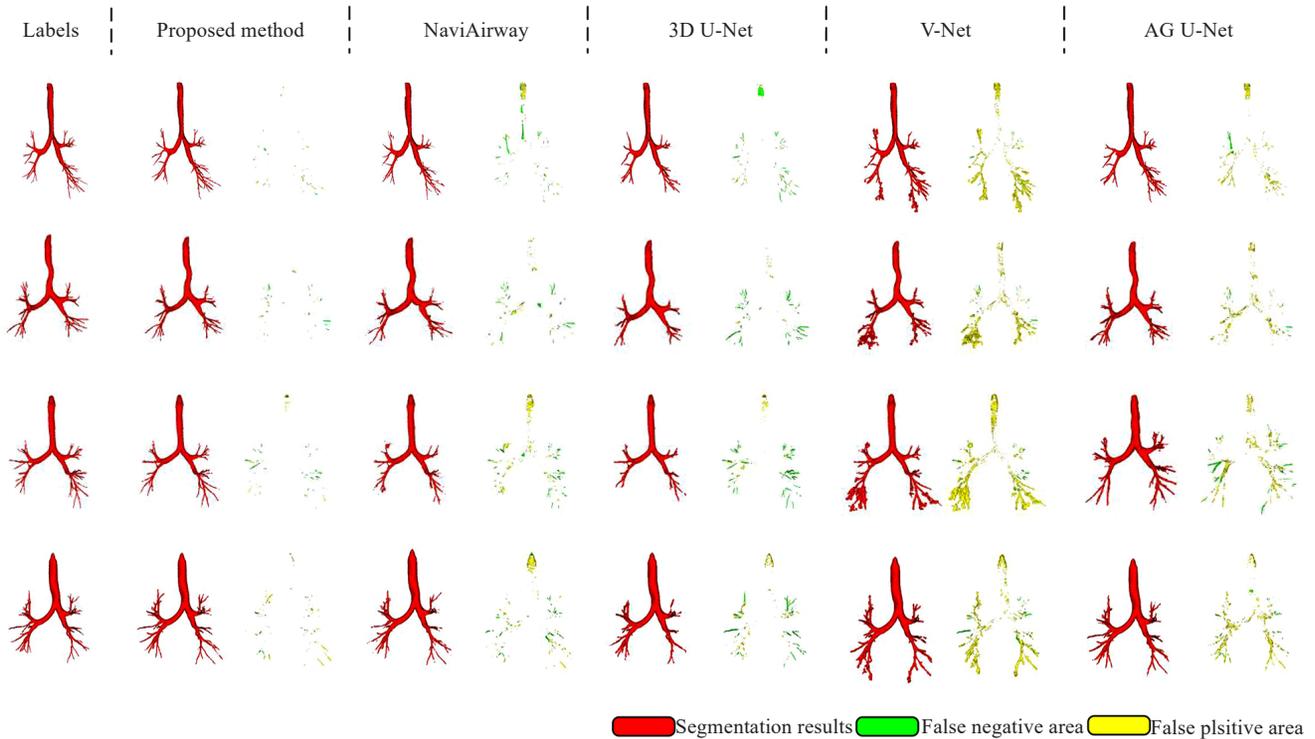


图6 对比实验可视化结果

Figure 6 Visualization results of comparative experiments

图7是本文随机从测试集中选择的一个分割结果的假阳性和假阴性区域分布图。图中蓝色箭头表示CT图像中与分割结果对应的假阴性区域,红色箭头表示CT图像与分割结果对应的假阳性区域。通过图6和图7可以看出,本文方法分割结果的假阳性区域主要分布在小气道末端,而非主干气道区域。从图7c~f可以看出,这些假阳性区域在原始图像中主要是一些标签未识别的真实气道。这说明本文方法不仅能够识别人工标出的气道,还能识别部分人工未标出的小气道。

2.5 消融实验分析

本文通过消融实验进一步研究分割网络中每个模块的有效性,本文对5种不同配置的分割模型进行了测试:(1)采用残差块替换3D U-Net中的传统3×3卷积块,记为“Baseline”;(2)加入CGU,记为“+CGU”;(3)加入CG-MSAM,记为“+CG-MSAM”;(4)同时加入CGU和CG-MSAM,记为“FSN”;(5)同时加入

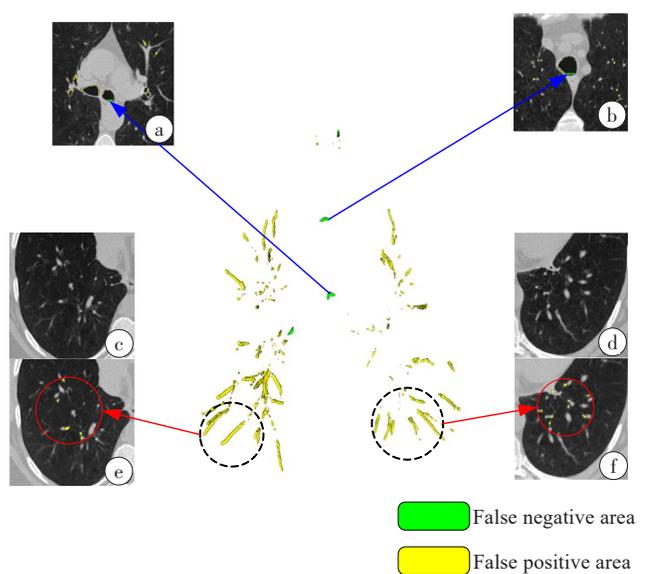


图7 分割结果中假阳性区域和假阴性区域分布图

Figure 7 Distribution of false-positive and false-negative regions in segmentation results

CGU和CG-MSAM,并融合SSN网络模型的分割结果,记为“FSN+SSN”。消融实验结果如表2所示。消融实验可视化结果如图8所示。

表2 消融实验结果(%)
Table 2 Results of ablation study (%)

方法	DSC	灵敏度	精度	FPR	TD	BD
Baseline	90.11±1.32	93.76±1.67	86.77±2.04	0.018±0.005	68.45±9.44	60.08±17.10
+CGU	93.46±1.23	93.42±2.19	93.56±1.87	0.009±0.004	79.29±7.89	84.29±10.05
+CG-MSAM	92.74±1.23	90.57±2.73	95.09±1.14	0.006±0.001	64.87±9.46	57.37±17.06
FSN	93.68±1.07	93.85±1.89	93.59±2.30	0.009±0.005	81.18±7.79	87.76±10.34
FSN+SSN	93.20±1.55	95.51±1.50	91.09±3.18	0.012±0.007	88.59±5.63	97.42±4.52

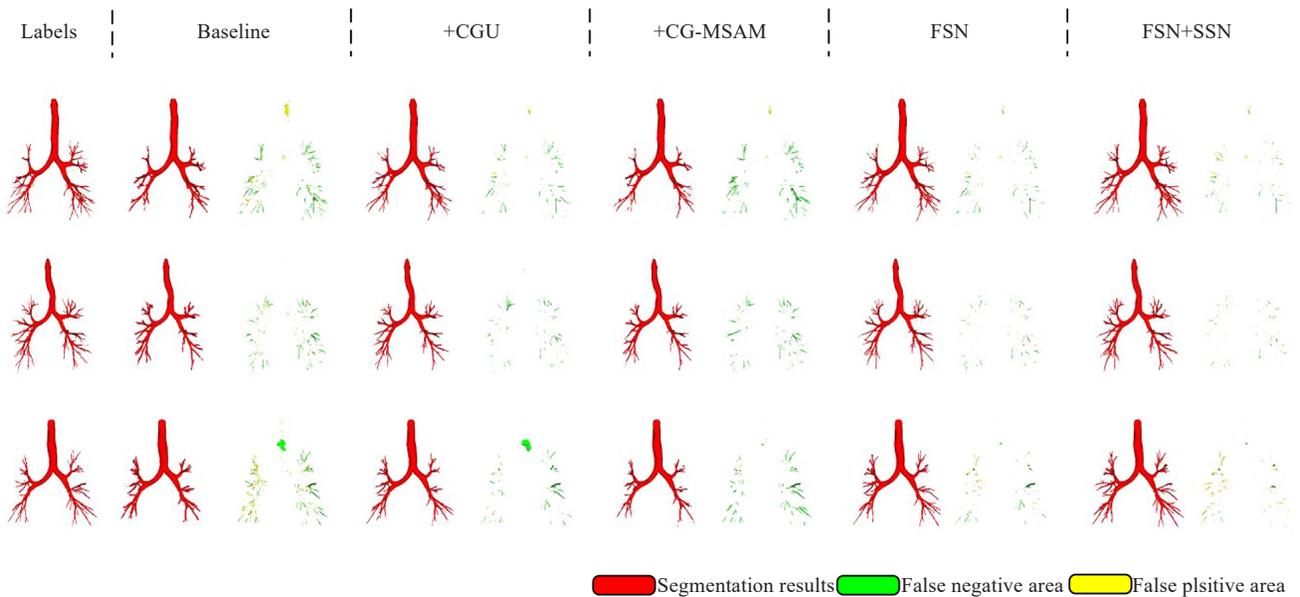


图8 消融实验可视化结果

Figure 8 Visualization results of ablation study

从表2中可以看出,加入CGU和CG-MSAM可以有效提高网络模型的性能,而融合SSN的分割结果后检测出的气道结构明显变多。下面对3个组成部分进行详细的讨论。

(1)CGU。位置信息有利于确定分割结果的边界,限制气道的空间位置,避免气道的“泄露”问题。如图8所示,引入坐标信息后可以明显提高模型的精度,减少假阳性区域。与没有使用CGU的网络相比,精度提高了6.79%,FPR降低了0.009%。此外,坐标信息可以突出特征图中的气道位置,采用最大池化操作可以获得完整的气道结构,减少小气道特征的丢失,从而提高分割结果的结构准确性。

(2)CG-MSAM。考虑到不同尺度的特征在不同通道中的作用,本文通过多层感知器分别学习不同尺度的特征图在不同通道中的权重,提高小尺寸网络的分割性能。如表2所示,使用CG-MSAM可以大幅提高模型的精度,相比Baseline提高了8.32%。但由于多尺度特征提取部分采用池化操作,会造成部分特征的丢失,导致小气道的检测效果相对较差。

(3)SSN。小尺寸网络主要学习远端小气道特征,可以与全尺寸网络的分割结果形成互补,既能补充全尺寸网络遗漏的小尺寸气道,又能连接部分断裂的气道。与没有融合SSN结果的网络相比,灵敏度提高了1.66%,TD和BD分别提高了7.41%和9.66%。

3 结论

针对不同气道分支之间巨大的形态差异,本文提出了一种基于坐标信息与多尺度并行网络的气道分割方法。通过两个网络分别学习不同尺寸的气道特征,可以有效解决气道的类内不平衡问题。同时,考虑到气道在胸腔内的位置不是随机分布的,浅层丰富的坐标信息有助于深层特征的重建工作,通过引入坐标引导的上采样模块,将浅层特征的坐标信息融合到深层特征中,确定气道在图像中的空间位置,从而提高模型的精度。此外,引入通道引导的多尺度聚合模块进一步提高模型对不同尺度特征的识别能力。实验结果表明,本文所提出的方法在保证气道完整性的基础上,拥有更高的精度,在手术导航中,可以提供更精确的气道模型。

【参考文献】

- [1] 罗汶鑫, 杨澜, 王成弟, 等. 肺癌筛查与早期诊断的研究现状与挑战[J]. 中国科学(生命科学), 2022, 52(11): 1603-1611.
Luo WX, Yang L, Wang CD, et al. Current status and challenges of research on lung cancer screening and early diagnosis[J]. Scientia Sinica (Vitae), 2022, 52(11): 1603-1611.
- [2] 方芳. 导向鞘引导的超声支气管镜联合虚拟导航支气管镜对周围型肺癌的临床诊断价值[D]. 西安: 第四军医大学, 2017.
Fang F. Endobronchial ultrasonography with guide-sheath combined with virtual bronchoscopy navigation for peripheral lung cancer[D]. Xi'an: Fourth Military Medical University, 2017.
- [3] Fabijańska A, Janaszewski M, Postolski M, et al. Airway tree segmentation from CT scans using gradient-guided 3D region growing[C]//Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009: 247-254.
- [4] Duan HH, Gong J, Sun XW, et al. Region growing algorithm combined with morphology and skeleton analysis for segmenting airway tree in CT images[J]. J Xray Sci Technol, 2020, 28(2): 311-331.
- [5] 王雷, 高欣, 张桂芝. 形态膨胀的3D区域生长气管分割算法[J]. 生物医学工程学杂志, 2013, 30(4): 679-683.
Wang L, Gao X, Zhang GZ. 3D region growing algorithm driven by morphological dilation for airway tree segmentation in image guided therapy[J]. Journal of Biomedical Engineering, 2013, 30(4): 679-683.
- [6] Lo P, van Ginneken B, Reinhardt JM, et al. Extraction of airways from CT (EXACT'09)[J]. IEEE Trans Med Imaging, 2012, 31(11): 2093-2107.
- [7] Garcia-Uceda A, Selvan R, Saghir Z, et al. Automatic airway segmentation from computed tomography using robust and efficient 3-D convolutional neural networks[J]. Sci Rep, 2021, 11(1): 16001.
- [8] Yun J, Park J, Yu D, et al. Improvement of fully automated airway segmentation on volumetric computed tomographic images using a 2.5 dimensional convolutional neural net[J]. Med Image Anal, 2019, 51: 13-20.
- [9] Cheng GH, Wu XM, Xiang WD, et al. Segmentation of the airway tree from chest CT using tiny atrous convolutional network[J]. IEEE Access, 2021, 9: 33583-33594.
- [10] Guo JQ, Fu RD, Pan L, et al. Coarse-to-fine airway segmentation using multi information fusion network and CNN-based region growing[J]. Comput Methods Programs Biomed, 2022, 215: 106610.
- [11] Qin YL, Chen MJ, Zheng H, et al. AirwayNet: a Voxel-Connectivity aware approach for accurate airway segmentation using convolutional neural networks[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019. Cham: Springer International Publishing, 2019: 212-220.
- [12] Nan Y, Ser JD, Tang ZY, et al. Fuzzy attention neural network to tackle discontinuity in airway segmentation[J]. IEEE Trans Neural Netw Learn Syst, 2024, 35(6): 7391-7404.
- [13] Zhou K, Chen N, Xu XY, et al. Automatic airway tree segmentation based on multi-scale context information[J]. Int J Comput Assist Radiol Surg, 2021, 16(2): 219-230.
- [14] Çiçek Ö, Abdulkadir A, Lienkamp SS, et al. 3D U-net: learning dense volumetric segmentation from sparse annotation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2016. Cham: Springer International Publishing, 2016: 424-432.
- [15] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Cham: Springer International Publishing, 2015: 234-241.
- [16] Wang PQ, Chen PF, Yuan Y, et al. Understanding convolution for semantic segmentation[C]//2018 IEEE Winter Conference on Applications of Computer Vision (WACV). Piscataway, NJ, USA: IEEE, 2018: 1451-1460.
- [17] Li HC, Xiong PF, An J, et al. Pyramid attention network for semantic segmentation[EB/OL]. (2018-11-25) [2023-10-19]. <https://arxiv.org/abs/1805.10180>.
- [18] Zhao HS, Shi JP, Qi XJ, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 6230-6239.
- [19] Armato SG 3rd, McLennan G, Bidaut L, et al. The lung image database consortium (LIDC) and image database resource initiative (IDRI): a completed reference database of lung nodules on CT scans[J]. Med Phys, 2011, 38(2): 915-931.
- [20] Qin YL, Gu Y, Zheng H, et al. AirwayNet-SE: a simple-yet-effective approach to improve airway segmentation using context scale fusion[C]//2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI). Piscataway, NJ, USA: IEEE, 2020: 809-813.
- [21] Salehi SSM, Erdogmus D, Gholipour A. Tversky loss function for image segmentation using 3D fully convolutional deep networks[C]//Machine Learning in Medical Imaging. Cham: Springer International Publishing, 2017: 379-387.
- [22] Milletari F, Navab N, Ahmadi SA. V-Net: fully convolutional neural networks for volumetric medical image segmentation[C]//2016 Fourth International Conference on 3D Vision (3DV). Piscataway, NJ, USA: IEEE, 2016: 565-571.
- [23] Schlemper J, Oktay O, Schaap M, et al. Attention gated networks: learning to leverage salient regions in medical images[J]. Med Image Anal, 2019, 53: 197-207.
- [24] Qin YL, Zheng H, Gu Y, et al. Learning tubule-sensitive CNNs for pulmonary airway and artery-vein segmentation in CT[J]. IEEE Trans Med Imaging, 2021, 40(6): 1603-1617.
- [25] Wu YQ, Zhang MH, Yu WH, et al. LTSP: long-term slice propagation for accurate airway segmentation[J]. Int J Comput Assist Radiol Surg, 2022, 17(5): 857-865.
- [26] Wang AD, Tam TCC, Poon HM, et al. NaviAirway: a bronchiole-sensitive deep learning-based airway segmentation pipeline[EB/OL]. (2023-06-16) [2023-10-19]. <https://arxiv.org/abs/2203.04294>.

(编辑:薛泽玲)