

CT 图像下结合 RCNN 与 U-Net 的 肺实质自动分割方法

毕蓉蓉, 王进科

(哈尔滨理工大学 荣成学院, 山东 荣成 264300)

摘 要: 针对肺 CT 实质自动分割问题, 提出了一种改进的 U-Net 模型。该模型充分结合了 U-Net 网络和循环卷积神经网络(RCNN) 的优势, 可以提取图像中更加细小的特征, 在拥有较少数量网络参数的情况下获得良好的性能。该模型首先在编码和解码单元中, 使用带有残差单元的循环卷积层代替 U-Net 模型中的前向卷积层。然后, 从基本网络的端到端使用了有效的特征累积方法。最后, 从原始的 U-Net 模型中删除了裁剪和复制单元, 仅保留了级联操作。为了验证提出方法的性能, 将提出的模型与当前最先进的模型在 LUNA16 数据集上进行了实验比较, 实验结果显示, 提出的分割模型在分割精度方面体现出一定的优越性。

关键词: RCNN; U-Net; 医学图像分割; 肺 CT

DOI: 10. 15938/j. jhust. 2021. 03. 011

中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1007-2683(2021) 03-0074-09

Automatic Lung Segmentation Using RCNN Combing U-Net in CT

BI Rong-rong, WANG Jin-ke

(Rongcheng Campus, Harbin University of Science and Technology, Rongcheng 264300, China)

Abstract: Aiming at the problem of automatic lung CT segmentation, an improved U-Net model is proposed. The model fully utilizes the advantages of U-Net model and Recurrent Convolutional Neural Network(RCNN), and it helps extract very low-level features and ensure better performance with fewer numbers of network parameters. Firstly, in the encoding and decoding units, a recurrent convolution layer replaced the forward convolutional layers of the original U-Net models. Secondly, an effective feature accumulation method was utilized from one part of the network to the other. Finally, the cropping and copying units were removed from the original U-Net model and only the concatenation operations were retained. To evaluate the performance of the proposed scheme, the comparative segmentation experiments with state-of-the-art models were conducted in the LUNA16 datasets. The experimental results proved a superiority of the proposed method on segmentation accuracy.

Keywords: RCNN; U-Net; medical image segmentation; lung CT

收稿日期: 2020-06-14

基金项目: 国家自然科学基金(61741106); 黑龙江省自然科学基金(LH2019F023); 山东省高等学校科技计划项目(J16LN60)。

作者简介: 毕蓉蓉(1983—), 女, 硕士, 讲师。

通信作者: 王进科(1983—), 男, 博士, 副教授, E-mail: haligong_b@163.com。

0 引言

医学图像处理技术可以帮助病人获得更快更好的诊断,CT 成像因其高性价比被广泛应用于临床的辅助诊断。然而,手动分割的过程缓慢且繁琐,而自动的 CT 图像分割技术可以减少人为主观错误,降低时间成本和误诊率。因此,研究可靠的鲁棒的自动算法,对于高效、精准的医疗诊断具有重要的临床应用价值。

近年来,深度学习(DL)在图像分类^[1]、分割^[2]、检测^[3]等方面得到了广泛的应用,VGG^[4]、GoogleNet^[5]、ResidualNet^[6]等著名的深度卷积神经网络模型相继被提出。基于 DL 的方法在图像分类、图像分割方面都表现出了优越的性能,然而,在大多数情况下,基于 DL 的方法在对大规模的数据集分类时(如 ImageNet),分类任务的输出是仍然是单个标签概率值。此外,一些基于 DL 的方法被用于语义图像分割(如 FCN),并被广泛应用于在计算机视觉的图像分割领域中。而且,也相继衍生出一些 FCN 的改进模型,例如 SegNet^[7],是一个拥有 13 层的 VGG16 网络,其相应的解码网络使用逐像素分类层。

伴随着深度卷积神经网络(DCNN)在计算机视觉领域取得的巨大成功,它的各种变形方法也被广泛应用于医学图像处理图像,包括分割,分类,检测,配准和医学信息处理。在 [8] 中提出了一种基于 DCNN 的脑肿瘤分割和检测方法,但是,仍然存在局限性,比如数据匮乏和类别不平衡。其中,由于梯度问题,很难训练深度神经网络,但是,可以通过激活函数(例如,修正线性单元(ReLU)或指数线性单元(ELU))来解决。He^[9]等提出了解决该问题的另一种模型,该模型是一种深度残差模型,并且克服了利用恒等式映射来促进训练过程的问题。大多数时候,出于某些原因,大量的训练标签无法使用,标记数据集需要该领域的专家人为参与,这些工作需要耗费大量的精力和时间。因而,出现了一些用于进行不同的数据转换或增强的技术(数据白化,旋转,移位和缩放比例),以增加可用的带标签样本的数量^[10]。与此同时,也包括一些基于补丁的方法,来解决类别不平衡问题。在语义分割中,可以为图像背景分配标签,同时,为前景或目标区域分配不同的

类别,以解决类别不平衡问题。在文 [9,10] 中介绍的交叉熵损失和 Dice 相似度系数可以有效地进行分类和分割模型的训练。

此外,全局定位和上下文信息常被用于医学图像定位,每个像素都被赋予与目标病变边界相关的类别标签,医学图像中的特征点检测就是其中的一个示例。在 DL 方法盛行之前,多种传统机器学习和图像处理技术已用于医学图像分割,包括基于直方图特征的阈值分割^[11],基于区域的分割算法^[12]和 Graph-cut^[13]。然而,近年来,在医学图像分割,病变检测和定位领域中,利用 DL 的语义分割方法变得更加成功,而且,基于 DL 的方法在单模态(MRI,CT 和 X 射线)成像处理中也具有很好的通用性。

此外,在深度学习领域,涌现出其它的一系列基于 U-Net 的方法。例如,医学图像分割中著名的 3D 全卷积神经网络 V-Net^[14],该模型具有对称结构,由编码器和解码器组成,通过引入基于 Dice 系数的新目标函数来解决类别不平衡的问题,同时,使用随机非线性变化和直方图匹配来扩充数据,在测试阶段取得了卓越的性能;3D U-Net^[15]网络结构,从稀疏标注的体积图像中学习,用于体积分割;CE-Net^[16],将新提出的 DAC 模块和 RMP 模块与骨干编码器-解码器结构相结合,来提高学习的效率;Seo 等人提出的 MU-Net^[17],基于对象的上采样,将残差网络中的特征自适应地合并到跳跃连接中,避免低分辨率信息的重复,增强目标的边缘信息和小目标的全局信息;Zhou 等提出的 U-Net++^[18],由深度不同的 U-Net 组成,其解码器通过重新设计的跳跃路径以相同的分辨率紧密连接,可以抓取不同层次的特征,并采用了深度监督学习方案;Li 等提出的 H-Dense-UNet^[19],可以通过混合特征融合层联合优化片内特征和 3D 上下文,以准确地对目标进行分割,克服了 2D 的 CNN 不能够学习到第三维度上的空间信息、3D 的 CNN 需要高额的计算成本以及严重的 GPU 内存消耗的问题;He 等提出的 Mask RCNN^[20],特征提取采用 ResNet-FPN 的架构,在 Faster R-CNN 的基础上添加了一个预测分割 Mask 的分支。

1 经典的 U-Net 模型

U-Net,被视为医学图像语义分割最成功的方法

之一^[2],其模型网络结构如图1所示。

U-Net 网络由两个主要部分组成: 卷积编码和解码单元。对编码和解码单元执行基本卷积操作, 然后执行 ReLU 激活函数。在编码单元中进行下采样, 进行了 2×2 最大池化操作。在解码阶段, 执行反卷积操作来对特征图进行上采样。U-Net 最早应用于从编码单元到解码单元裁剪和复制特征图。

U-Net 模型在图像分割方面有很多优势: 首先, 该模型允许同时使用全局位置和上下文信息。其次, 它只需要很少的训练样本就可以在医学图像分割中有良好的表现。第三, 端对端的处理是以图片为整体进行分割, 并直接生成分割图。这样可以确保 U-Net 保留输入图像完整的上下文信息, 这是与基于补丁的分割方法相比的一个重要优势。




图1 U-Net 的网络结构

Fig.1 U-Net architecture

2 基于循环卷积神经网络的 U-Net 模型

2.1 改进的 U-NET 网络结构

U-Net 模型在具有较少网络参数的情况下分割效果一般, 且仅在训练过程中具有很好的收敛性^[4]。为了克服 U-Net 模型的局限性, 受深度残差模型^[5], 循环卷积神经网络 (RCNN)^[2] 的启发, 我们提出了基于 U-Net 的循环卷积神经网络模型, 称为 RU-Net, 网络结构如图2所示。

从图2可以看出, 用于分类任务的 CNN 模型需要一个编码单元, 并提供分类概率作为输出。在分类任务中, 使用带下采样层的激活函数 ReLU 进行卷积操作, 从而降低了特征图的维度。由于输入样

本遍布网络的每个层, 特征图的数量增加, 但是特征图的维度减少。这显示在模型网络结构的第一部分 (黑色实心)。由于特征图的数量在深层中增加, 因而, 网络参数的数量也相应增加。最后, 使用分类函数来计算目标类的概率。




图2 RU-Net 网络结构

Fig.2 RU-Net architecture

相较于 U-Net 模型, 提出的模型对如下 3 个方面进行了改进:

1) 卷积层。分割任务的网络结构需要设置卷积编码和解码单元。编码单元将输入图像编码为大量低维特征图。解码单元中执行反卷积操作, 生成尺寸与原始输入图像相同的分割图。与分类任务相比, 分割任务的网络结构通常需要大约两倍的网络参数。因此, 为分割任务设计有效的网络架构非常重要。此模型中使用的卷积编码和解码单元与 U-Net 模型是相同的, 但是, 为了开发更加有效的模型, 在编码和解码单元中, 该模型使用 RCL (recurrent convolution layer) 代替常规前向卷积层, 从而确保在较少数量的网络参数的情况下获得更好的性能。展开的 RCL 结构如图3中所示。 $\mu=2$ 个时间步长时, 构成了一个最大深度为 3, 最小深度为 1 的前馈子网络, 包含一个卷积层和两个循环卷积层组成的子序列。 $\mu=3$ 个时间步长时, 构成了一个最大深度为 4, 最小深度为 1 的前馈子网络, 包含一个卷积层和三个循环卷积层组成的子序列。




图3 RU-Net 卷积层

Fig.3 RU-Net convolutional layers

2) 特征累积方式。文 [2] 中提出的 U-Net 改进模型与 U-Net 相比,在训练过程中表现出了显著的性能提升和良好的收敛性,但是,在测试阶段使用特征求和时,并未观察到优越性 [2],说明特征求和一定程度会影响网络的性能。本文提出模型的 RCL (recurrent convolution layer) 单元包含有效的特征累积方法,可以实现网络的端到端的特征累积,其有效性可以通过基于 CNN 的医学图像分割证明。在该模型中,逐个元素的特征求和在 U-Net 模型之外进行,在内部进行特征积累,使得在训练、验证和测试三个阶段均表现出优越性。不同时间步长的特征累积可进行更加丰富的特征表示。因而,有助于提取图像中更加细小的特征,这些特征对于医学图像不同方式的分割任务提供不可忽视的贡献。

3) 特征映射方式。本文从 U-Net 原模型中删除了裁剪和复制单元,而仅保留了级联操作。提出的深度学习模型

RU-Net 是具有正向循环的 U-Net 模型,从编码单元到解码单元的特征映射应用了级联方式,此处 μ 指的是循环卷积操作,在进行了上述改进之后,将提出的模型与 SegNet, U-Net 和 CE-Net 模型相比,所提出的模型可确保在相同或更少数量的网络参数的情况下获得更好的性能。

2.2 改进的 U-NET 算法

该模型利用了深度残差模型, RCNN 和 U-Net 三个深度学习模型的优势。RCNN 及其变体已经在不同基准的对象识别任务中显示了卓越的性能。RCL 是基于 RCNN 的离散时间步长执行的。

假设 φ_i 为残差 RCNN 第 i 层中的输入样本, RCL 中第 k 个特征图上输入样本中的中心像素坐标为 (m, n) 。假设在 μ 时间的网络输出为 $\nu_{mnl}^i(\mu)$ 。输出可以表示如下:

$$\nu_{mnl}^i(\mu) = C_l + (\theta_l^g)^T * \varphi_i^{g(m,n)}(\mu) + (\theta_l^r)^T * \varphi_i^{r(m,n)}(\lambda) \quad (1)$$

其中, $\varphi_i^{g(m,n)}(\mu)$ 与 $\varphi_i^{r(m,n)}(\lambda)$ 分别是标准卷积层与 RCL 第 i 层的输入, $\lambda = \mu - 1$, θ_l^g 与 θ_l^r 的值分别是标准卷积层与 RCL 的第 l 个特征图的权重, C_l 为偏差。RCL 的输出作为 ReLU 激活函数 g 的参数为

$$G(\varphi_i, \theta_i) = g(\nu_{mnl}^i(\mu)) = \max(0, \nu_{mnl}^i(\mu)) \quad (2)$$

$G(\varphi_i, \theta_i)$ 表示 RCNN 单元第 i 层的输出, $G(\varphi_i, \theta_i)$ 的输出分别用于 RU-Net 模型的卷积编码和解码单元中的下采样和上采样层。

与 U-Net 相比,提出的模型具备两方面的优势。一方面,在相同数量的网络参数情况下,该模型在分割任务上表现出更好的性能;另一方面,该模型使用的循环操作不仅不会增加网络参数的数量,而且提高了训练、验证和测试阶段的性能。

2.3 算法评价标准

对实验结果进行定量分析,考虑了几个性能指标,包括准确度 AC,灵敏度 SE,特异性 SP。为此我们使用了真阳性 TP,真阴性 TN,假阳性 FP 和假阴性 FN 4 个变量。计算整体准确度 AC 的等式为式 (3)。式 (4) 计算敏感性 SE 和式 (5) 计算特异性 SP,式 (6) 计算精确率,式 (7) 计算召回率。

$$AC = \frac{TN + TP}{FN + FP + TN + TP} \quad (3)$$

$$SE = \frac{TP}{FN + TP} \quad (4)$$

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

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

另外,根据文 [23] 进行了确定 Dice 系数 (DI) 损失函数的实验,根据文 [24] 确定了 Jaccard 相似系数 (JS),此处 e 代表金标准, f 代表分割结果。式 10 为 F1 分数。

$$DI(e, f) = 2 \frac{|e \cap f|}{|e| + |f|} \quad (8)$$

$$JS(e, f) = \frac{|e \cap f|}{|e \cup f|} \quad (9)$$

$$F1 \text{ 分数} = 2 \times \frac{Precision \cdot Recall}{Precision + Recall} \quad (10)$$

3 实验环节

3.1 实验环境与环境参数

为了验证提出的 RU-Net 模型的性能,我们在 CT 图像数据集上进行了方法测试,实验采用了 LU-NA16 的胸部 CT 数据集。我们删除了切片厚度大于 2.5 mm 的 CT 影像。该数据集总共包括 888 个肺部 CT 影像数据,每个影像包含一系列胸腔的多个轴向切片 [23],原始图像是由不同数量的二维图像组成的三维图像,每个图像包含一系列胸腔的多个轴向切片。此外该数据集还包含了注释,这些注释

是由4名有经验的放射科专家收集的。我们选取其中77名病人,每名病人大约有100~400张切片,最终形成12489张二维图像数据集,原始图像大小为 512×512 ,但是在此实验中,我们将图像的大小调整为 256×256 像素。使用ADAM优化器,学习率设为 2×10^{-4} 。我们设定公式6为DI损失函数,其中70%的样本用于训练,10%用于验证,20%用于测试。所有的训练、测试及验证实验在Ubuntu18.04的工作站上完成,其基本配置为:CPU Intel 银牌 4110 2.1 GHz, 64G DDR4 内存,显卡为RTX2080Ti。

1.2 实验结果与分析

1) 消融实验。为了证明提出模型的有效性,我们进行了消融实验研究。首先我们对卷积层的数量以及时间步长进行消融实验,其次我们移除U-Net模型中的原始编码器块使用残差单元来代替、移除常规前向卷积层使用RCL来代替、移除裁剪和复制单元多方面进行消融研究。

①卷积层及步长。在卷积块中使用不同数量的卷积层评估模型,并根据时间步长 μ 确定层数。表1显示了不同卷积块中的网络结构以及相应的特征图数量。从表1中可以清楚地看到:当 $\mu=2$ 时,卷积块中特征图的数量保持不变;当 $\mu=3$ 时,随着卷积块中卷积层的增加,网络参数的数量也会增加。

我们使用残差、循环和循环残差逐元素加法操作执行特征融合。在网络结构的编码单元中,每个卷积块由两个或3个RCL组成,其中应用了 3×3 卷积内核,ReLU激活层,以及批处理归一化层。对于下采样,在卷积块之间使用 2×2 最大池化层,其

后是 1×1 卷积层。在解码单元中,每个块由卷积转置层、紧随其后的两个卷积层和级联层组成。在网络中的编码和解码单元中的特征之间执行级联操作。然后,将 1×1 卷积核与sigmoid激活函数一起使用,将特征映射到单个输出特征图。最后,使用0.5阈值生成分割区域。

表1 网络结构特征图以及网络参数数量

Tab.1 Architecture and number of network parameters

μ	网络结构	网络参 数数量/ 千万
2	$1 \rightarrow 16(3) \rightarrow 32(3) \rightarrow 64(3) \rightarrow 128(3) \rightarrow 64(3) \rightarrow 32(3) \rightarrow 16(3) \rightarrow 1$	0.103
3	$1 \rightarrow 16(4) \rightarrow 32(4) \rightarrow 64(4) \rightarrow 128(4) \rightarrow 64(4) \rightarrow 32(4) \rightarrow 16(4) \rightarrow 1$	0.128
2	$1 \rightarrow 32(3) \rightarrow 64(3) \rightarrow 128(3) \rightarrow 256(3) \rightarrow 512(3) \rightarrow 256(3) \rightarrow 128(3) \rightarrow 64(3) \rightarrow 32(3) \rightarrow 1$	1.633

②残差单元、RCL、特征积累方式在不同步长下的消融研究。

本文提出的方法基于U-Net的基线模型。采用残差单元来代替U-Net的原始编码器块,旨在增强学习能力,称之为Trunk;

提出的模型采用RCL代替常规前向卷积层,目的是在较少数量的网络参数的情况下获得更好的性能;

此外,本文改变特征积累方式,删除了U-Net模型中的裁剪和复制单元,仅保留了级联操作,旨在提取图像中更加细微的特征。

表2 该模型每个组成部分的消融研究

Tab.2 Ablation study of proposed models

模型	AC	SE	SP	AUC	DI	JS	F1
U-Net($\mu=2$)	0.975 7	0.895 3	0.991 3	0.963 7	0.976 5	0.963 2	0.915 1
Trunk($\mu=2$)	0.976 1	0.901 4	0.992 0	0.971 1	0.976 7	0.969 7	0.925 7
Trunk + RCL($\mu=2$)	0.981 3	0.970 1	0.993 0	0.982 6	0.979 4	0.971 3	0.961 4
RU-Net($\mu=2$)	0.984 2	0.967 9	0.995 2	0.990 1	0.981 4	0.990 7	0.981 0
U-Net($\mu=3$)	0.983 7	0.915 3	0.992 1	0.990 3	0.979 3	0.992 1	0.983 2
Trunk($\mu=3$)	0.989 1	0.922 3	0.992 7	0.973 1	0.977 2	0.973 2	0.935 8
Trunk + RCL($\mu=3$)	0.990 1	0.971 2	0.993 2	0.985 7	0.980 7	0.983 9	0.971 5
RU-Net($\mu=3$)	0.992 1	0.973 9	0.994 7	0.991 1	0.984 3	0.994 1	0.987 1

如表 2 的第 2 行至第 5 行所示,当 $\mu = 2$ 时,RU-Net、U-Net、Trunk 和 Trunk + RCL 相比,在准确度方面,分别提高了 0.85%、0.81% 和 0.29%;当 $\mu = 3$ 时,RU-Net 模型在各方面的性能表现如表 2 的第 6 行至第 9 行所示,在准确度方面分别高出 0.84%、0.30% 和 0.20%。

从表 2 中我们还可以看出,即使网络参数的数量相对于卷积层中的时间步长稍有增加,各方面性能也略有提高。

2) 与其它模型的性能比较。

本文选取了 3 种不同模型(SegNet,U-Net,CE-Net) 与提出的模型(RU-Net) 进行了肺 CT 分割比较实验。

肺 CT 典型分割结果如图 4 所示,其中第一列为输入样本,第二列为金标准,第三,第四,第五和第六列分别给 SegNet,U-Net,CE-Net 和 RU-Net 模型的输出。

从第一行结果可以看出,RU-Net 的分割效果较好,其内部细节与真实细节比较相似。从第二行结果可以看出,RU-Net 的输出可以显示出较好的细分,以及较准确的内部细节,左肺的内孔较清楚地显示了出来。从第三行结果可以看出,RU-Net 模型相比 SegNet 和 U-Net 模型提供了更为准确的细分结果,捕获了病变以外的图像部分。




图 4 肺图像分割结果

Fig. 4 Results of lung image segmentation

表 3 $\mu = 2$ 各模型性能比较

Tab.3 Comparison of proposed models ($\mu = 2$)

模型	AC	SE	SP	AUC	DI	JS	F1
SegNet	0.978 1	0.978 2	0.971 2	0.971 8	0.961 3	0.978 1	0.957 0
U-Net	0.975 7	0.895 3	0.991 3	0.963 7	0.976 5	0.963 2	0.915 1
CE-Net	0.981 9	0.959 8	0.989 4	0.989 5	0.980 1	0.977 8	0.951 9
RU-Net	0.984 2	0.967 9	0.995 2	0.990 1	0.981 4	0.990 7	0.981 0

本文针对 RCL 单位中的时间步长 $\mu = 2$ 评估了 RU-Net 模型。表 3 给出了提出的模型与同等的 SegNet,U-Net,CE-Net 模型相比,各方面性能的表

现。在准确度方面,与同等的 SegNet 和 U-Net,CE-Net 模型相比,RU-Net 模型分别提高了 0.61%、0.85% 和 0.23%。

表 4 $\mu = 3$ 各模型性能比较

Tab.4 Comparison of proposed models($\mu = 3$)

模型	AC	SE	SP	AUC	DI	JS	F1
SegNet	0.987 9	0.976 3	0.986 2	0.985 4	0.973 6	0.988 9	0.978 1
U-Net	0.989 7	0.965 3	0.994 3	0.990 3	0.979 3	0.992 1	0.983 2
CE-Net	0.991 1	0.968 7	0.991 5	0.991 0	0.983 6	0.992 4	0.983 7
RU-Net	0.992 1	0.973 9	0.994 7	0.991 1	0.984 3	0.994 1	0.987 1

表 4 总结了 $\mu = 3$ 时与同等的 SegNet、U-Net 和 CE-Net 模型相比,RU-Net 模型在各方面的性能表现。在准确度方面分别提高了 0.42%、0.24% 和 0.10%。

AUC 和 ROC 曲线是用于医学图像分割任务的

常用评估方法。在本文中,我们使用了该方法来评估所提出方法的性能,带有 AUC 的 ROC 曲线图如下图 5 所示,可以看出提出的 RU-Net 模型在 AUC 曲线下面积均略高于其它 3 种方法—SegNet,U-Net 和 CE-Net。




图5 4种不同模型 ROC 曲线

Fig.5 ROC curves of the four models

验证集的精确度如图6所示,可以看出 RU-Net 模型显示出更好的性能,这说明提出的模型对图像的分割任务具有更强的鲁棒性。




图6 验证集的精确度

Fig.6 Validation accuracy of the four models

为了进一步研究 RU-Net 模型的性能,我们针对不同的训练样本数目展开性能比较研究。我们选取了 $\mu = 2$ 时的 U-Net, CE-Net 和 RU-Net 模型,这些模型包含 1.07 M 网络参数。对于 SegNet,我们考虑了 [14] 中提出的具有 1.7 M 网络参数的类似网络结构。在实验开始时,将整个数据集分为两组,其中 80% 的样本用于训练和验证,而其余 20% 的样本在每个试验期间用于测试。在此实验中,我们选用了 [0.9、0.7、0.5、0.3 和 0.1] 的不同拆分比率,随着训练样本的数量增加,每个连续跟踪的验证样本的数量减少。例如,拆分比率为 0.9 意味着仅 10% 的样本用于训练,其余 90% 的样本用于验证。同样,0.7 的拆分率意味着仅 30% 的样本用于训练,其余 70% 的样本用于验证。

图7和图8显示了关于训练和验证的 DI 系数误差。实验表明,所提出的 RU-Net 模型在所有测试的分割率下均显示出较低的训练和验证误差,但在验证情况下,分割率等于 0.5 的结果除外。在这种情况下, RU-Net 模型的误差比 U-Net、CE-Net 模型的误差稍大。结果表明, RU-Net 模型在训练阶段用于提取、表示和学习能力较强,有助于获取更好的性能。




图7 4种不同模型对不同数量的训练样本的性能

Fig.7 Performance on different numbers of training samples




图8 4种不同模型对不同数量的验证样本的性能

Fig.8 Performance on different numbers of validation samples

此外,在每个试验中,我们用残差的 20% 的样本对模型进行了测试,测试误差如图9所示。与 SegNet、U-Net 和 CE-Net 模型获得的误差相比, RU-Net 模型的误差较低。

3) 计算时间。在测试阶段, LUNA16 数据集的每个样本的处理时间平均是 2.86 s。执行肺分割时,分割整个图像均可以在 1.15 s 之内完成。RU-




图9 不同分割比率的四中模型的测试误差

Fig. 9 Test error rate on different split ratios

Net 模型处理每个样品大约需要 7 s,这在临床使用情况下是可以接受的。

4 结 论

在本文中,我们提出了使用循环卷积神经网络对 U-Net 网络结构的改进。优势在于:第一,在深层结构训练中使用了残差学习单元;第二,具有循环残差卷积层的特征累积确保为分割任务提供更好的特征表示;第三,可以设计更好的具有相同数量网络参数的 U-Net 架构,以获取更优的 CT 图像分割性能。在实验部分,采用公共的肺部 CT 数据集对提出的模型进行评估。实验结果表明,与现有的三种先进方法相比(Seg-Net, U-Net, CE-Net),RU-Net 模型在处理具有相同数量网络参数的分段任务时,往往能够展现出更加优越的性能。通过定量和定性比较,以及训练样本数量与性能之间的折中实验分析,表明 RU-Net 模型在训练过程中具备更强的学习能力,从而确保获得更高的分割精准度。本文提出的模型仍然具有较大的改进空间。首先,为了使模型性能减少对样本数量和质量的依赖,需对样本进行进一步优化,统一的清洗校验;其次,编码和解码单元的特征融合策略还可以进一步优化,在今后的研究工作中,我们将继续研究新颖的特征融合策略来探索更加高效的网络结构。

参 考 文 献:

[1] SZEGEDY Christian, LIU Wei, JIA Yangqing, et al. Going Deeper with Convolutions [C] //IEEE Conference on Computer Vision and Pattern Recognition, Boston, June 7-12, 2015.

[2] 刘侠,匡瑞雪,王波,等. 基于隐马尔可夫场的脊柱 CT 图像分割算法 [J]. 哈尔滨理工大学学报, 2018, 23(2): 1.
LIU Xia, KUANG Rui-xue, WANG Bo, et al. Segmentation Algorithm of Spine CT Image Based on Hidden Markov Random Field [J]. Journal of Harbin University of Science and Technology, 2018, 23(2): 1.

[3] 张培培,吕震宇,赵爽,等. 高速高精度带钢表面检测系统的设计与实现 [J]. 哈尔滨理工大学学报, 2016, 21(6): 44.
ZHANG Peipei, LV Zhenyu, ZHAO Shuang, et al. Research and Implementation for High-speed and High-precision Strip Surface Detection System [J]. Journal of Harbin University of Science and Technology, 2016, 21(6): 44.

[4] 李浩,霍雯,裴春营,等. 融合 VGG 和 FCN 网络模型的智能出租车订单预测系统 [J]. 计算机工程, 2019(12): 1.
LI Hao, HUO Wen, PEI Chunying, et al. Intelligent Taxi Order Prediction System Based on VGG and FCN Network Model [J]. Computer Engineering, 2019(12): 1.

[5] 梁雪慧,程云泽,张瑞杰等. 基于卷积神经网络的桥梁裂缝识别和测量方法 [J]. 计算机应用, 2020, 40(4): 1056.
LIANG Xuehui, CHENG Yunze, ZHANG Ruijie, et al. Bridge Crack Classification and Measurement Method Based on Deep Convolutional Neural Network [J]. Journal of Computer Applications, 2020, 40(4): 1056.

[6] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep Residual Learning for Image Recognition [C] //IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, June 17-30, 2016: 770.

[7] MD Zahangir Alom, MAHMUDUL Hasan, CHRIS Yakopcic, et al. Improved Inception-Residual Convolutional Neural Network for Object Recognition [J]. arXiv preprint 2017, arXiv: 1712.09888.

[8] LITJENS G, KOOTI T, BEJNORDI B E, et al. A Survey on Deep Learning in Medical Image Analysis [J]. arXiv preprint 2017, arXiv: 1702.05747.

[9] ÖZGÜN Çiçek, AHMED Abdulkadir, SOEREN S, et al. 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation [C] //International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer International Publishing, 2016: 424.

[10] RONNEBERGER, OLAF, PHILIPP Fischer, et al. U-net: Convolutional Networks for Biomedical Image Segmentation [C] //International Conference on Medical Image Computing and Computer-assisted Intervention, Germany, October 5-9. Springer, Cham, 2015.

[11] CAI Y, LANDIS M, LAIDLEY D T, et al. Multi-modal Vertebrae Recognition Using Transformed Deep Convolution Network [J]. Computerized Medical Imaging and Graphics, 2016(51): 11.

[12] RAMESH N, YOO J H, SETHI I K. Thresholding Based on Histogram Approximation [J]. IEEE Proceedings-Vision Image and Signal Processing, 1995, 142(5): 271.

- [13] SHARMA, NEERAJ, AMIT Kumar Ray. Computer Aided Segmentation of Medical Images Based on Hybridized Approach of Edge and Region Based Techniques [J] //Proceedings of International Conference on Mathematical Biology, Athematical Biology Recent Trends by Anamaya Publishers, 2006: 150.
- [14] MILLETARI, FAUSTO, NASSIR Navab, Seyed-Ahmad Ahmadi. V-net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation [C] //Fourth International Conference on 3D Vision (3DV), 2016: 356.
- [15] OZGÜN C, i,cek, Ahmed Abdulkadir, Soeren S. Lienkamp, et al. 3DU-Net: Learning Dense Volumetric Segmentation from Sparse Annotation [C] //International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer International Publishing, 2016: 424.
- [16] GU Zaiwang, CHENG Jun, FU Huazhu, et al. CE-Net: Context Encoder Network for 2D Medical Image Segmentation [J]. IEEE Transactions on Medical Imaging, 2019, 38(10): 2281.
- [17] HYUNSEOK Seo, CHARLES Huang, MAXIME Bassenne, et al. Modified U-Net (mU-Net) with Incorporation of Object-Dependent High Level Features for Improved Liver and Liver-Tumor Segmentation in CT Images [J]. IEEE Transactions on Medical Imaging, 2019: 1316.
- [18] ZHOU Zongwei, Md Mahfuzur Rahman Siddiquee, Nima Tajbakhsh, et al. UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation [J]. IEEE Transactions on Medical Imaging. 2019, 39(6): 1856.
- [19] LI Xiaomeng, CHEN Hao, QI Xiaojuan, et al. H-DenseUNet: Hybrid Densely Connected UNet for Liver and Tumor Segmentation from CT Volumes [J]. IEEE Transactions on Medical Imaging, 2018, 37(12): 2663.
- [20] HE Kaiming, Georgia Gkioxari, Piotr Dollar, et al. Mask r-cnn [J] //Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961.
- [21] 程立英, 高宣爽, 申海, 等. 基于 U-Net 网络的肺部组织分割 [J]. 沈阳师范大学学报(自然科学版), 2020, 38(02): 278. CHENG Liying, GAO Xuanshuang, SHEN Hai, et al. Lung Tissue Segmentation Based on U-Net Network [J] Journal of Shenyang Normal University (Natural Science Edition), 2020, 38(2): 278.
- [22] Liang, Ming, HU Xiaolin. Recurrent Convolutional Neural Network for Object Recognition [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3367.
- [23] DICE LEE R. Measures of the Amount of Ecologic Association Between Species [J]. Ecology, 1945, 26(3): 297.
- [24] JACCARD Paul. The Distribution of the Flora in the Alpine Zone [J]. New Phytologist, 1912, 11(2): 37.
- [25] Setio A A A, Traverso A, De Bel T, et al. Validation, comparison, and combination of algorithms for automatic detection of pulmonary nodules in computed tomography images: the LUNA16 challenge [J]. Medical image analysis, 2017, 42: 1.

(编辑: 王 萍)