

基于稠密块和注意力机制的肺部病理图像异常细胞分割

崔文成, 王可丽, 邵虹

(沈阳工业大学信息科学与工程学院, 辽宁 沈阳 110870)

摘要: 针对肺部细胞病理图像亮度不均衡、异常细胞轮廓精准分割难以实现的问题, 提出一种以U-Net为基本框架, 结合稠密块以及注意力机制的异常细胞分割模型。首先, 利用具有编码器-解码器结构的U-Net对异常细胞进行分割; 然后, 在U-Net中引入稠密块, 以提高特征之间的传播能力, 提取更多异常细胞的特征信息; 最后, 利用注意力机制提高异常细胞区域的权重, 降低亮度不均衡对模型的干扰。实验结果表明, 该方法的IoU和Dice相似系数值分别为0.6928和0.8060, 与其他模型相比, 提出的方法能够分割出低对比度区域和形状多样的异常细胞。

关键词: 肺部细胞病理图像; 细胞分割; U-Net; 稠密块; 注意力机制

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202210

Abnormal cell segmentation for lung pathological image based on denseblock and attention mechanism

CUI Wencheng, WANG Keli, SHAO Hong

School of Information Science and Engineering, Shenyang University of Technology, Shenyang 110870, China

Abstract: Aiming at the problems of unbalanced brightness of lung cell images and achieving accurate segmentation of abnormal cell contour difficultly, an abnormal cell segmentation model based on U-Net was proposed, which combined the dense connection mechanism and attention mechanism. Firstly, U-Net with encoder-decoder structure was used to segment abnormal cells. Secondly, the dense block was introduced into U-Net to improve the propagation ability between features and extract more characteristic information of abnormal cells. Finally, the attention mechanism was used to increase the weight of abnormal cell regions and reduce the interference of the imbalance of brightness to the model. The experimental results show that the IoU value and Dice similarity coefficient achieved by this method are 0.6928 and 0.8060, respectively. Compared with other models, this proposed method is able to segment low-contrast regions and abnormal cells with diverse shapes.

Key words: lung cell pathology image, cell segmentation, U-Net, dense block, attention mechanism

0 引言

随着人口老龄化问题日益严重, 癌症已经成为我国重大的公共卫生问题。并且在众多的恶性肿瘤疾病中, 肺癌的发病率以及死亡率也在逐年增加^[1]。通常情况下, 肺部病理图像包括肺部细胞病

理图像和肺部组织病理图像, 且传统的肺部细胞病理学诊断主要依靠经验丰富的病理专家通过肉眼进行阅片。阅片时, 首先观察染色后与正常细胞在细胞形态、染色状态以及排列方式上表现不同的异常细胞; 然后根据先验知识对异常细胞的特征进行深入分析; 最后才能诊断出该疾病是肺癌还是其他肺

收稿日期: 2021-07-12; 修回日期: 2021-08-27

通信作者: 王可丽, 3254589937@qq.com

类疾病^[2]。然而截至2018年,我国持有执照的病理医生仅1万人,缺口率高达90%^[3]。因此,肺部细胞病理图像辅助诊断系统的研究不仅有助于改善目前病理医生阅片时耗时耗力的情况,还能在很大程度上减少早期肺癌误诊现象的发生概率。

近年来,随着人工智能(artificial intelligence, AI)技术的不断发展^[4],越来越多的学者将AI投入医学图像领域的研究中。其中关于肺部细胞病理图像的研究也在逐渐增加,但大多数研究的关注点均在肺癌子类型的分类上。Teramoto A等人^[5]于2017年使用深度卷积神经网络(deep convolutional neural network, DCNN)实现了肺细胞病理学图像自动分类,并且获得了与细胞病理学专家和技术人员相当的、约为71%的分类准确率。其次, Teramoto A等人^[6]又于2019年引入了DCNN将细胞学图像自动分类为具有良性或恶性特征的图像,并达到81.0%的分类准确率。另外, Teramoto A等人^[7]为了进一步提高DCNN的性能,再次于2020年通过使用生成式对抗网络(generative adversarial networks, GAN)合成的细胞图像来提高DCNN的分类准确率。结果发现,相较于2019年论文成果,其分类准确率又提高了,约为85.3%。

然而,很少有学者从肺部细胞图像出发,进行肺部异常细胞分割的研究。在医学图像分割方法的研究中,与传统的医学图像分割算法相比,基于深度学习的算法提供了非常先进的性能且已经成为非常受欢迎的算法^[8]。Shelhamer E等人^[9]首次提出了全卷积网络(fully convolutional network, FCN),实现了端到端的语义分割,但由于没有充分考虑像素与像素之间的关系,该网络在进行细粒度分割时效果较差。在众多FCN模型的变体中, Ronneberger O等人^[10]提出的U-Net模型是非常流行的全卷积网络模型之一,被广泛应用于医学图像分割领域。该网络主要由编码器、解码器以及瓶颈模块(bottleneck)组成,并且具有训练速度快以及在少样本的医学数据集上分割效果仍表现较好的优点。但其分割目标形状上的多样性和结构上的差异性使U-Net无法在多种医学图像上获得较好的分割性能。因此,越来越多的学者以提高分割准确性和分割效率为目标,展开了U-Net的改进工作^[11]。这些面向性能优化的改进模型主要包括针对增强相关性、抑制无关特性的改进模型^[12-13],针对小样本训练数据集的改进模型^[14-16]以及针对内存占用、计算

速度的改进模型^[17-18]。

在U-Net的基础上,上述针对不同医学图像的分割任务提出的相关改进模型对肺部细胞病理图像异常细胞的分割有良好的借鉴和启发意义。因此,针对肺部细胞病理图像亮度不均衡、异常细胞轮廓精准分割难以实现的问题,本文提出了一种以U-Net为基础框架,结合稠密块(denseblock)和注意力机制(attention mechanism)的分割模型。首先,借鉴DenseNet^[19]的思想将稠密块引入编码器,提高了特征之间的传播能力,从而提取到更多异常细胞的特征信息,同时抑制了梯度消失现象的发生;其次,将注意力机制引入编码器与解码器之间,增大了异常细胞特征的权重,降低了图像亮度不均衡对模型的干扰,提高了分割的准确度。

1 模型框架

1.1 整体模型

由于肺部细胞病理图像具有异常细胞形态各异和图像亮度不均衡的问题,而单一的U-Net模型无法有效地降低图像亮度不均衡带来的干扰。因此,本文以U-Net模型为基本框架,结合稠密块和注意力机制对U-Net模型的编码器和瓶颈模块进行了改进,得到本文模型的网络结构,如图1所示。

该网络由编码器、解码器、分类器以及瓶颈模块组成。编码器由稠密块和最大池化层组成,主要负责下采样工作,用于获取丰富的上下文信息,使模型实现对异常细胞和背景的精准分类。其中,每个稠密块主要是对两次 3×3 卷积操作后的特征图进行特征融合处理。特征融合处理指通道拼接操作,这样不仅可以提高特征的重复利用率,还使模型能够获得更多异常细胞的信息。最大池化层负责特征图的下采样工作,能够减少网络的运算量。解码器的结构与原始U-Net的解码器结构一致,主要负责上采样工作,用于实现异常细胞的精确定位。在原始U-Net跳跃连接层的基础上引入了注意力机制,使得模型提高了异常细胞区域的权重,降低了图像亮度不均衡带来的干扰,提高了分割的准确率。最后通过 1×1 的卷积层对异常细胞与背景进行分类。

1.2 稠密块

部分异常细胞小目标区域存在特征难以提取的问题,通常情况下可以通过适当调整卷积核的数量和卷积核的大小来获取更多的特征信息,但较深的




图1 本文模型的网络结构

网络必然会造成网络参数较多。因此，本文借鉴了DenseNet中能够在一定程度上减少网络参数的稠密连接机制，在U-Net编码器中的卷积层之间引入稠密连接机制以提取异常细胞更多的特征信息。稠密块的基础计算式如下：

$$x_l = H_l([x_{l-1}, x_{l-2}, \dots, x_0]) \quad (1)$$

其中， $[x_{l-1}, x_{l-2}, \dots, x_0]$ 指对第 $0, \dots, l-1$ 层输出的特征图进行拼接操作， H_l 表示第 l 层的非线性变换。 H_l 的定义为3个连续的复合函数：批量归一化（batch normalization, BN）、修正线性单元（rectified linear unit, ReLU）激活、 3×3 卷积（conv）。

本文引入的稠密块结构如图2所示，每个稠密模块主要包含两次 3×3 的卷积操作和1次特征融合操作。




图2 稠密块结构

在本文所提模型中，编码器在进行每次下采样的卷积操作时，均是对两个 3×3 卷积操作的特征图进行拼接处理，最后形成新的特征图。此外，每个卷积层均添加了批量归一化层^[20]和修正单元激活层^[21]，以提高网络的性能。批量归一化层具有提高模型学习速度、提高模型泛化能力以及缓解梯

度消失情况等优点。这种通过密集连接将网络中上下卷积层之间的特征进行融合的方式，减少了网络中梯度消失的情况，提高了特征的重复利用率，还有助于提取异常细胞更多的特征信息。

1.3 注意力机制

虽然稠密块强化了异常细胞的传播能力，有效地提取了异常细胞更多的特征信息，但是肺部细胞图像中的异常细胞形状各异、细胞图像背景亮度不均衡等因素均使异常细胞的分割效果不是十分理想。因此本文摒弃了原始U-Net中编码器和解码器对应的特征通道直接进行拼接的思想，在瓶颈模块引入了注意力机制模块。其原理就是在拼接之前引入了一个集成注意门（AGs），重新调整了编码器的输出特征。注意力机制结构如图3所示。

注意力机制主要通过注意力权重 $a(a \in [0, 1])$ 来识别异常细胞的显著特征，其基本原理如下：

$$t_i^l = \sigma_1(W_x^T x_i^l + W_g^T g_i^l + b_1) \quad (2)$$

$$a_i^l = \sigma_2(W^T t_i^l + b_2) \quad (3)$$

其中， i 为像素空间的大小； x_i^l 和 g_i^l 分别为编码模块的低级特征图和解码模块的高级特征图； W_x 和 W_g 均为线性变换参数； b_1 、 b_2 均为偏置项； σ_1 为ReLU激活函数； σ_2 为Sigmoid激活函数，该激活函数对注意力权重进行归一化处理；输出的激活特征图为编码模块的低级特征图与注意力权重逐元素相乘的积：

$$o_i^c = x_{i,c}^l \cdot a_i^l \quad (4)$$

其中， c 为通道尺寸。




图3 注意力机制结构

1.4 损失函数

在二分类的语义分割任务上,常用的损失函数是交叉熵损失函数,其定义为:

$$L_{\text{BCE}} = -\frac{1}{N} \sum_{i=1}^N (y_i \log(\hat{y}_i) + (1-y_i) \log(1-\hat{y}_i)) \quad (5)$$

其中, N 为像素点个数, y_i 为真实标签值, $\hat{y}_i$ 为模型的预测值。由此可见,在每次梯度回传的过程中,交叉熵损失函数采用对每个像素预测类别求平均的方式进行图像中各个像素类别的预测。然而医学图像中常出现像素类别不平衡的问题,这在网络的训练过程中会引起数据集中常见的类别主导模型的现象,进而导致较少类别的像素特征不能被学习到,最终影响模型的分割精度。

因此,为了避免发生图像像素类别分类不均衡造成的模型分割精度较低的现象,本文采用 Dice loss^[22],其计算式如下:

$$L_{\text{Dice}} = 1 - \frac{2 \sum_{i=1}^N y_i \hat{y}_i}{\sum_{i=1}^N y_i + \sum_{i=1}^N \hat{y}_i} \quad (6)$$

2 试验结果与分析

本实验的环境是基于深度学习框架 PyTorch,结合 Python 编程语言进行搭建的。计算机配置如下:操作系统为 Windows 10;处理器为 Intel Core i7-10700k;显卡为 NVIDIA GeForce RTX 3090,内存为 24 GB;系统内存为 62 GB。

2.1 数据集

数据集来源于某医院呼吸科的肺部细胞病理图像。数据集是采用 H&E 染色制成的病理切片,是经全切片扫描放大 40 倍后的无损数字图像,分辨率为 2 000×2 000,位深 24。该数据集包含 249 张肺部异常细胞图像,且对应专家标注的真实标签,并按照 6:2:2 的比例拆分成训练集、验证集和测试集。

由于原始图像尺寸过大,直接使用会导致模型参数爆炸,故将图像尺寸缩放成 256×256。同时,为了避免数据较少导致模型在训练过程中发生过拟合的现象,本文采用数据增强的方法提高模型泛化能力。该方法主要采用图像几何变换,从水平翻转和垂直翻转的角度对训练集分别进行 90°、180°、270° 的旋转,将训练集扩充至原来的 8 倍,最终获得 1 192 张 256×256 的训练图像。部分数据集原图及其真值图如图 4 所示。




图4 部分数据集原图及其真值图

2.2 训练细节

在训练神经网络的过程中,将 Dice loss 作为代价函数,为了选择合适的优化器,采用两种常用的学习率可自适应调整的优化算法(不考虑动量问题

的RMSProp优化器和考虑动量问题的Adam^[23]优化器)进行优化模型对比实验,初始学习率(lr)设置为0.02,批量大小(batchsize)设置为8,训练迭代100次。训练时,采用自适应调整学习率策略,若10次迭代后损失函数(loss)仍不下降,则重新调整学习率。

图5和图6分别为使用两种优化算法进行训练本文模型时,训练集和验证集上的损失函数随训练次数(epoch)的变化曲线。可以看出:当epoch小于10时,相较于Adam优化算法,RMSProp优化算法在模型训练的初始阶段loss震荡情况比较明显,说明了添加动量的Adam优化算法不仅有利于模型找到最优解,还能在降低模型震荡的情况下,尽可能地加快模型的收敛速度;当epoch接近10左右时,使用Adam优化算法的网络优先开始收敛,这更加说明了添加动量的Adam优化算法更有利于优化本文模型;当两种优化算法训练的模型均开始收敛后,loss值十分接近。因此,使用带动量的Adam优化算法更有利于提高本文模型的训练效率。




图5 训练集上的损失函数变化曲线




图6 验证集上的损失函数变化曲线

图7为使用两种优化算法训练模型后,测试集上的Dice相似系数值(DSC)随epoch的变化曲线。对比两种优化算法训练后的模型表现性能,可以发现:当epoch为10左右时,RMSProp优化算法训练的模型泛化能力并不是很稳定,而选择Adam优化算法的模型泛化能力从一开始就稳步上升,这说明了RMSProp优化算法相较于添加动量的Adam优化算法,在进行模型优化时无法很快速地找到模型的最优解;当epoch超过20之后,两种优化算法训练的模型均到达稳定的收敛状态,且测试集测试时,Adam优化算法相较于RMSProp优化算法训练得到的模型DSC更高,这也说明了考虑动量的Adam优化算法不仅更有利于加快本文模型的收敛,也使本文模型具有更好的分割性能。




图7 两种优化算法在测试集上的DSC

各个模型训练的DSC如图8所示。各个模型测试的DSC如图9所示。可以发现,相较于其他模型,本文模型的DSC最高,说明了本文模型的分割性能最好。




图8 各个模型训练的DSC




图9 各个模型测试的DSC

2.3 评价指标

为了对肺部异常细胞分割结果进行评估, 主要从主观评价和客观评价两个角度对分割结果进行相关的分析。主观评价主要从异常细胞的形态出发, 综合分析各个模型的分割结果。客观评价中, 主要将IoU (intersection over union)^[24]和DSC^[25]作为评价指标, 评价各个模型的分割性能:

$$\text{IoU} = \frac{|V_{\text{seg}} \cap V_{\text{gt}}|}{|V_{\text{seg}} \cup V_{\text{gt}}|} = \frac{N_{\text{TP}}}{N_{\text{FP}} + N_{\text{TP}} + N_{\text{FN}}} \quad (7)$$

$$\text{DSC} = 2 \frac{|V_{\text{seg}} \cap V_{\text{gt}}|}{|V_{\text{seg}}| + |V_{\text{gt}}|} = \frac{2N_{\text{TP}}}{N_{\text{FP}} + 2N_{\text{TP}} + N_{\text{FN}}} \quad (8)$$

其中, N_{TP} 、 N_{FP} 、 N_{FN} 分别表示异常细胞像素正确分类数目、背景像素错误分类数目、异常细胞错误分类数目; V_{seg} 、 V_{gt} 分别表示预测值和真实值。IoU从图像整体性上评价图像的分割结果, 是语义分割的标准度量, 是真实值与预测值的交集与并集之比, 其取值范围为[0,1], 且越接近1说明模型对肺部异常细胞的分割效果越好。DSC为医学图像分割的重要衡量标准, 表示真实值与预测值之间的

相似度, 其取值范围为[0,1], 也是越接近1模型分割性能越好。

2.4 不同分割模型的结果分析

为了验证本文模型的分割性能, 选取FCN-8s、U-Net和R2U-Net 3种分割网络与之进行对比, 结果如图10所示, 其中每个样例中方框区域内 ($S_1 \sim S_4$) 的局部细节比较结果 (即异常细胞细节的分割结果) 如图11所示。图10中的白色区域和图11的后四列中的白色区域均为分割得到的异常细胞区域。




图10 不同样例中异常细胞分割结果




图11 异常细胞细节分割结果

由图10中样例1和图11中样例 S_2 的分割结果发现,在不受亮度等因素影响的条件下,FCN-8s的分割结果不够精细,U-Net的分割结果精细度明显提升,相较于U-Net,虽然R2U-Net的分割结果分割轮廓更精细,但仍然出现过分割的现象,这说明对于异常细胞的分割,引入递归神经网络的R2U-Net并没有有效提升分割效果。相较于其他3种模型,本文模型的分割结果更接近于真值图,且本文模型分割结果的轮廓更加精准,说明稠密块对提高特征的重复利用率起到了显著性的作用,从而使本文模型提取到异常细胞更多的特征信息。观察图10中样例1、样例2和图11中样例 S_1 、样例 S_3 的分割结果发现,在受图像亮度不均衡和低对比度干扰的情况下,FCN-8s的分割结果不够精细且出现欠分割现象,说明FCN-8s模型无法有效降低图像亮度不均衡带来的干扰。本文模型相较于R2U-Net的分割轮廓更精细,说明添加了注意力机制和稠密块的本文模型不仅对图像亮度不均衡和低对比度等噪声的适应性更强,而且还能提取到异常细胞更多的特征信息。以上关于本文所提模型分割性能优势的阐述,在图10中样例3和图11中样例 S_4 的分割结果上也得到了体现,对比发现,对于图11中样例 S_4 右下角受低对比度噪声干扰且存在小目标区域的异常细胞来说,相较于其他3种模型,该异常细胞仅被本文模型分割出来,这再一次验证了本文模型的分割性能更优,能够分割出低对比度区域和形状多样的异常细胞。

虽然通过视觉观察分割结果的好坏更加直观,但这种依据肉眼观察分割结果从而判断模型分割性能的方式易受主观因素的影响,因此需要通过客观角度对分割结果进行定量评价,不同分割模型的定量分析见表1。由表1看出,在这4种分割模型中,FCN-8s模型的分割性能略差;U-Net模型通过在FCN的基础上引入反卷积和特征连接,改善了上采样时信息不足的情况,在一定程度上提高了模型的分割性能;相较于U-Net,R2U-Net模型引入递归神经网络各项指标提升并不明显,这说明递归神经的引入并不适用于比较复杂的肺部异常细胞的分割工作;然而本文所提模型的DSC为0.8070,IoU为0.6928,均高于其他3种模型的性能评价指标,这说明注意力机制和稠密块的添加对模型性能的提高起到了显著性的作用,使模型能够分割出形态复杂的肺部异常细胞,降低图像亮度不均衡和低对比

度等噪声的干扰。

表1 不同分割模型的定量分析

模型	IoU	DSC
FCN-8s	0.6231	0.7480
U-Net	0.6519	0.7743
R2U-Net	0.6598	0.7762
本文模型	0.6928	0.8070

2.5 各模块对整体模块的影响

为了验证各模块对整体模块的影响,对U-Net模型、添加稠密块的优化模型(Dense-U-Net)、添加注意力机制的优化模型(Attention-U-Net)、本文所提模型进行对比实验,结果如图12所示,其中每个样例中方框区域($S_1 \sim S_4$)内的局部细节比较结果如图13所示。在图12和图13中,白色区域为得到的异常细胞区域。

对比图12中的样例2、样例3和图13中的样例 S_3 、样例 S_4 的分割结果发现,原始U-Net的分割结果轮廓精细度较差,添加了注意机制的分割结果相较于添加稠密块的分割结果更接近于真值图,说明了注意力机制模块更适用于异常细胞形状的多样性以及复杂性。观察图12中的样例1和图13中的样例 S_1 的分割结果发现,在受图像亮度不均衡和低对比度干扰的情况下,添加了注意机制的分割结果相较于原始U-Net的分割结果反而出现假阳性概率增大的现象,这恰恰验证了注意力机制确实能够降低亮度的干扰,但也加重了颜色特征的权重信息,因此致使假阳性概率增加。添加了稠密块的分割结果与真值图相同,说明了稠密块虽不能降低图像亮度不均衡和低对比度带来的干扰,但能提取到异常细胞更多的特征信息。添加稠密块和注意力机制的本文模型的分割结果说明,注意力机制和稠密块在提取异常细胞的相关特征时起到了叠加的效果。由图12中的样例2和图13中的样例 S_2 的分割结果发现,在不受低对比度噪声影响的条件下,相较于添加了注意力机制的分割结果,添加了稠密块的分割结果更能降低原始U-Net误判为假阳性的概率,说明了稠密块相较于注意机制更能够提取到异常细胞的特征信息,且本文模型的分割结果更加表明了注意力机制和稠密块的共同使用促进了模型分割性能的显著提高。

总体而言,注意机制和稠密块的同时添加使模型对亮度、噪声等干扰因素的适应性更好,能够分




图12 不同样例中异常细胞分割结果




图13 异常细胞细节分割结果

割出低对比度区域和形状多样的异常细胞，因此本文模型的分割性能较好。

对分割结果进行定量评价，各模块对整体模型的影响见表2。U-Net作为基础模型，其IoU为0.6519，DSC为0.7743；添加稠密块之后（Dense-UNet），两项指标均有提升，其中IoU提高了1.61%，DSC提高了0.39%，说明添加稠密块虽然也能使模型提取更多异常细胞的特征信息，但对整体模型分割性能的影响较弱；添加注意力机制之后（Attention-UNet），两项指标也均有提升，其中IoU提高了3.51%，DSC提高了1.7%，说明注意力机制不仅能够有效解决图像亮度不均衡和低对比度带来的问题，而且能够在较大程度上提高模型的分割性能；同时添加稠密块和注意力机制后（本文模型），两项指标的提升更明显，相较于U-Net，其中IoU提高了6.27%，DSC提高了4.22%，说明同时添加注意力机制和稠密块对模型分割性能的影响起到了叠加的作用。因此从客观角度也能说明，本文模型

对亮度、噪声等干扰因素的适应性更好，能够更好地分割出低对比度区域和形状多样的异常细胞。

表2 各模块对整体模型的影响

模型	IoU	DSC
U-Net	0.6519	0.7743
Dense-UNet	0.6624	0.7773
Attention-UNet	0.6748	0.7875
本文模型	0.6928	0.8070

3 结束语

为了解决细胞图像亮度不均衡、异常细胞轮廓精准分割难以实现的问题，本文提出了一种以U-Net为基础框架，结合稠密块和注意力机制的分割模型。将稠密块引入编码器，提高了特征之间的传播能力，提取了更多异常细胞的特征信息，抑制了梯度消失现象的发生；将注意力机制引入编码器与解码器之间，提高了异常细胞特征的权重，降低了

图像亮度不均衡对模型的干扰, 提高了分割的准确率。实验结果表明, 同时添加注意机制和稠密块会使模型对亮度、噪声等干扰因素的适应性更好, 能够分割出低对比度区域和形状多样的异常细胞。虽然本文模型对于肺部异常细胞具有较高的分割精度, 但对于细胞内部亮度不均衡的区域仍会出现分割错误的现象。下一步将着重研究如何更高效地结合图像中的高级语义特征, 减少像素错误分类的问题。

参考文献:

- [1] FENG R M, ZONG Y N, CAO S M, et al. Current cancer situation in China: good or bad news from the 2018 global cancer statistics? [J]. *Cancer Communications* (London, England), 2019, 39(1): 22.
- [2] 刘树范, 阚秀. 细胞病理学[M]. 北京: 中国协和医科大学出版社, 2011.
- [3] LIU S F, KAN X. *Cytopathology*[M]. Beijing: Peking Union Medical College Press, 2011.
- [4] 卞修武, 平铁芳. 我国病理学科发展面临的挑战和机遇[J]. *第三军医大学学报*, 2019, 41(19): 1815-1817.
- [5] BIAN X W, PING Y F. Pathology in China: challenges and opportunities[J]. *Journal of Third Military Medical University*, 2019, 41(19): 1815-1817.
- [6] 王丽会, 秦永彬. 深度学习在医学影像中的研究进展及发展趋势[J]. *大数据*, 2020, 6(6): 83-104.
- [7] WANG L H, QIN Y B. State of the art and future perspectives of the applications of deep learning in the medical image analysis[J]. *Big Data Research*, 2020, 6(6): 83-104.
- [8] TERAMOTO A, TSUKAMOTO T, KIRIYAMA Y, et al. Automated classification of lung cancer types from cytological images using deep convolutional neural networks[J]. *BioMed Research International*, 2017.
- [9] TERAMOTO A, YAMADA A, KIRIYAMA Y, et al. Automated classification of benign and malignant cells from lung cytological images using deep convolutional neural network[J]. *Informatics in Medicine Unlocked*, 2019, 16: 100205.
- [10] TERAMOTO A, TSUKAMOTO T, YAMADA A, et al. Deep learning approach to classification of lung cytological images: two-step training using actual and synthesized images by progressive growing of generative adversarial networks[J]. *PLoS One*, 2020, 15(3): e0229951.
- [11] ZHU H Z, ZHANG Y Y, LI M, et al. Exploring deep learning for efficient and reliable mobile sensing[J]. *IEEE Network*, 2018, 32(4): 6-7.
- [12] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//*Proceedings of 2015 Medical Image Computing and Computer-Assisted Intervention*. [S.l.:s.n.], 2015.
- [14] 崔文成, 张鹏霞, 邵虹. 基于深度可分离卷积网络的皮肤镜图像病灶分割方法[J]. *智能科学与技术学报*, 2020, 2(4): 385-393.
- [15] CUI W C, ZHANG P X, SHAO H. Dermoscopic image lesion segmentation method based on deep separable convolutional network[J]. *Chinese Journal of Intelligent Science and Technology*, 2020, 2(4): 385-393.
- [16] ROY A G, NAVAB N, WACHINGER C. Concurrent spatial and channel 'squeeze & excitation' in fully convolutional networks[C]//*Proceedings of 2018 Medical Image Computing and Computer Assisted Intervention*. [S.l.:s.n.], 2018.
- [17] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-Net: learning where to look for the pancreas[EB]. *arXiv preprint*, 2018, arXiv: 1804.03999.
- [18] WANG W, YU K C, HUGONOT J, et al. Recurrent U-Net for resource-constrained segmentation[C]//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision*. Piscataway: IEEE Press, 2019: 2142-2151.
- [19] CHEN W L, ZHANG Y, HE J J, et al. Prostate segmentation using 2D bridged U-Net[C]//*Proceedings of 2019 International Joint Conference on Neural Networks*. Piscataway: IEEE Press, 2019: 1-7.
- [20] ORLANDO J I, SEEBÖCK P, BOGUNOVIĆ H, et al. U2-Net: a Bayesian U-Net model with epistemic uncertainty feedback for photo-receptor layer segmentation in pathological OCT scans[C]//*Proceedings of 2019 IEEE 16th International Symposium on Biomedical Imaging*. Piscataway: IEEE Press, 2019: 1441-1445.
- [21] LI X M, CHEN H, QI X J, 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): 2663-2674.
- [22] GUAN S, KHAN A A, SIKDAR S, et al. Fully dense UNet for 2-D sparse photoacoustic tomography artifact removal[J]. *IEEE Journal of Biomedical and Health Informatics*, 2020, 24(2): 568-576.
- [23] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2017: 2261-2269.
- [24] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[EB]. *arXiv preprint*, 2015, arXiv:1502.03167.
- [25] HE K M, ZHANG X Y, REN S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification[C]//*Proceedings of 2015 IEEE International Conference on Computer Vision*. Piscataway: IEEE Press, 2015: 1026-1034.
- [26] MILLETARI F, NAVAB N, AHMADI S A. V-Net: fully convolutional neural networks for volumetric medical image segmentation[C]//*Proceedings of 2016 4th International Conference on 3D Vision*. Piscataway: IEEE Press, 2016: 565-571.
- [27] KINGMA D P, BA J. Adam: a method for stochastic optimization[EB]. *arXiv preprint*, 2014, arXiv:1412.6980.
- [28] LEVANDOWSKY M, WINTER D. Distance between sets[J]. *Nature*, 1971, 234(5323): 34-35.
- [29] DICE L R. Measures of the amount of ecologic association between species[J]. *Ecology*, 1945, 26(3): 297-302.

[作者简介]



崔文成 (1973-), 男, 沈阳工业大学信息科学与工程学院副教授, 主要研究方向为智能信息处理。



王可丽（1993- ），女，沈阳工业大学信息学院硕士生，主要研究方向为智能信息处理。



邵虹（1974- ），女，博士，沈阳工大学信息科学与工程学院教授，主要研究方向为图像处理与模式识别、智能信息处理。