

基于3DV-Net的肺结节检测分割算法

刘方¹, 孙鹏², 陈真诚³

1. 桂林电子科技大学生命与环境科学学院, 广西 桂林 541000; 2. 桂林电子科技大学电子工程与自动化学院, 广西 桂林 541000;
3. 桂林电子科技大学生命与环境科学学院广西高校生物传感与仪器重点实验室, 广西 桂林 541000

【摘要】目的:提出基于深度学习的肺结节识别与分割算法,以辅助医生进行肺部疾病检测。**方法:**针对LUNA16数据集数据量大以及肺结节种类大小多样性等特征,采用基于改进的深度神经网络3DV-Net实现多种肺结节的检测分割,然后使用ResNet对结节图像和非结节图像进行分类。对LUNA16数据集中的肺部CT图像进行图像去噪、插值采样等预处理,然后生成粗分割图像和Mask图像,再使用改进的3DV-Net模型对数据进行多次训练预测。网络层级越深,出现梯度消散、梯度爆炸等问题的概率越大,改进的3DV-Net使用残差连接来改善这一问题。**结果:**改进的3DV-Net的Dice相似系数和IoU分别达到88.29%和88.25%。**结论:**本文方法有助于肺结节的检测分割,在肺结节的辅助诊断方面有重要意义。

【关键词】肺部疾病;CT图像;肺结节分割;3DV-Net;深度学习

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2023)01-0077-06

Detection and segmentation of pulmonary nodules using improved 3DV-Net

LIU Fang¹, SUN Peng², CHEN Zhencheng³

1. School of Life and Environmental Sciences, Guilin University of Electronic Technology, Guilin 541000, China; 2. School of Electronic Engineering and Automation, Guilin University of Electronic Technology, Guilin 541000, China; 3. Key Laboratory of Guangxi Colleges and Universities for Biosensors and Instruments, School of Life and Environmental Sciences, Guilin University of Electronic Technology, Guilin 541000, China

Abstract: Objective To propose a deep learning-based algorithm for the recognition and segmentation of pulmonary nodules, thereby assisting doctors in the diagnosis of pulmonary diseases. **Methods** In view of the large amount of data in LUNA16 data set and the diversity of types and sizes of pulmonary nodules, an improved deep neural network 3DV-Net was adopted to complete the detection and segmentation of various pulmonary nodules, and then ResNet was used to classify the nodule and non-nodule images. The lung CT images in LUNA16 data set were preprocessed by image denoising and interpolation sampling. After coarse segmentation images and mask images were generated, the improved 3DV-Net model was used to carry out multiple training and prediction. The improved 3DV-Net network adopted skip block to solve the problem that with the deeper network level, the probability of gradient dissipation, gradient explosion and other issues was greater. **Results** The Dice similarity coefficient and IoU of the improved 3DV-Net reached 88.29% and 88.25%, respectively. **Conclusion** The proposed method is helpful to the detection and segmentation of pulmonary nodules and is of great significance in the auxiliary diagnosis of pulmonary nodules.

Keywords: pulmonary disease; CT image; pulmonary nodule segmentation; 3DV-Net; deep learning

【收稿日期】2022-06-10

【基金项目】广西自然科学基金(2018GXNSFDA281044);广西创新驱动发展项目(2019AA12005);广西自动检测技术与仪器重点实验室项目(YQ20108)

【作者简介】刘方,硕士研究生,研究方向:医学与信息处理,E-mail: lf91239123@163.com

【通信作者】陈真诚,博士,教授,研究生导师,研究方向:生物医学传感与智能仪器,E-mail: chenzhcheng@163.com

前言

肺是人体的呼吸器官,是血小板生成的场所,更是造血祖细胞的储藏库,肺部疾病的检测一直是研究的热点^[1]。基于CT图像的肺结节识别诊断是肺癌诊断的一个重要指标,而从数百张CT图像中准确地检测和分割出肺结节是极具挑战性的。CT图像中存在的噪声以及灰度不均等问题使得CT图像分割极具难度;此外,肺部有复杂的支气管树内部结构,支气管树是由支气管的重复分支形成的,其中还含有

许多血管,其轮廓大小随切片的不同而不同,容易与小的肺结节混淆,使得肺结节检测分割成为一项非常耗费医生精力的工作^[2]。

随着科学技术的发展,近年来影像组学技术也取得了许多进步,医疗检测设备也在不断更新。许多学者基于CT图像提出或改进了多种肺结节分割算法。在近些年提出的算法中,深度全卷积神经网络凭借其准确提取特征的特点,在医学图像处理领域备受关注^[3]。之后由全卷积神经网络衍生出的Unet被广泛应用于血管分割、肺实质及肺结节分割以及肝肾肿瘤分割^[4-5]。相比Unet算法,3DV-Net算法主要是针对三维医学图像提出的,但其使用的数据集数据量非常大。本研究基于3DV-Net算法进行改进,改进后的算法模型相比原本的算法网络结构和卷积单元更简单,可以有效减少肺结节的检测时间,提升检测效率。

1 算法原理

1.1 神经网络原理

神经网络可视为一个大型并行分布式处理器,使用大量称为“神经元”或者“处理单元”的基本信息处理单元连接来提升性能。神经网络由简单计算单元构成,具有高运算速度、自适应和自组织的特性^[6]。神经元的模型结构如图1所示。

神经元模型包含了一个外部偏置,用 b_k 表示,偏置 b_k 的功能是调整激活函数的输入。图1中的神经元可以由以下的数学方程式表示:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(u_k + b_k) \quad (2)$$

其中, x_1, x_2, \dots, x_m 为输入信号; $w_{k1}, w_{k2}, \dots, w_{km}$ 为神经元 k 的突触权值; u_k 为得到的加权和; y_k 为神经元的输出; $\varphi(\cdot)$ 代表激活函数。许多算法在处理2D图像时

效果较好,而在医学临床的实践中,3D图像更直观实用,是未来发展的重要方向。

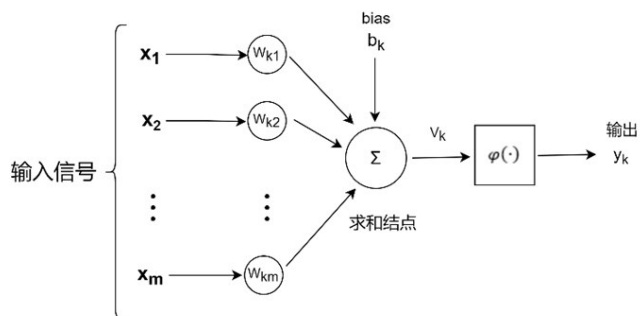


图1 神经元的非线性模型

Figure 1 Nonlinear model of neuron

卷积神经网络是在神经网络的原理上进行发展,3DV-Net是基于全卷积神经网络的改进,主要应用于3D医学图像。在全卷积神经网络中,输入图像大小可为任意尺寸^[7]。神经网络的学习过程包括下采样和上采样,下采样主要用于特征提取,而上采样将经过下采样作用后的影像恢复到原来的大小^[8]。在3DV-Net算法中,利用人工神经网络对每一幅图像的像素进行一次预测,并将其按像素进行分类,可实现对其的分割^[9]。本研究基于3DV-Net来进行研究,使用Dice系数作为目标函数,可以有效地解决图像中的前景与背景像素的不平衡。一些检测方法是通过对图像分段分类获得图像的解剖轮廓,但这种分割效果不尽人意;Vnet采用3D卷积核卷积,并给出一个新的目标函数来改善其分割性能。

1.2 3DV-Net结构

3DV-Net模型主要适用于3D医学图像,其网络结构是由Unet发展而来,模型结构如图2所示。

结构示意图中左半部分为编码器,其作用是对原始图像数据进行编码,并提取特征。编码器由5个编码模块组成,单个模块又由不同结构的卷积层和

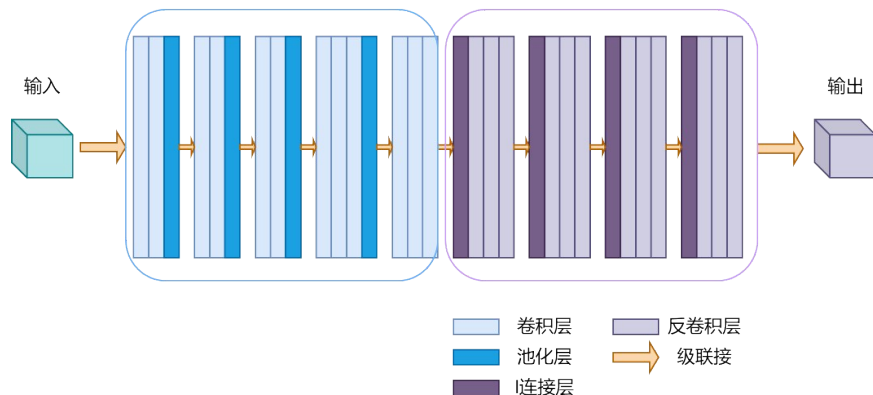


图2 3DV-Net模型结构示意图

Figure 2 Structural diagram of 3DV-Net model

下采样层构成,且具有不同特征分辨率。右侧上采样层用来扩大特征图,采用反卷积层实现,对输入补零再卷积。连接层的作用是将卷积层和上采样层的结果拼接在一起。

神经网络的卷积层由卷积单元组成^[10]。卷积层的主要功能是对图像中的边缘、线条、角度等特征进行提取。随着网络层次的加深,可以提取出更多的复杂特性,而随之带来的是更大的计算量。将输出层与卷积层相连,以 $1\times1\times1$ 为卷积核,其余的卷积为 $3\times3\times3$ 。池化层处于卷积层中间,有保留图像主要特征的作用,并可以压缩数据和减少参数,有效地降低过拟合,提高模型的普适性,本研究采用的是常见的3dMaxPooling层,对于每个 2×2 的窗口选择最大的数作为输出矩阵相应元素的值^[11]。最大池化层也可用增大步长的卷积层替换,且精度不变;为使结构更加

简单,用卷积运算代替池化层。在神经网络中,全连接层的功能是分类^[12];卷积层、池化层、激活函数层的功能是把数据映射到隐藏层,而全连接层则是对抽取的特征进行分配^[13]。下采样层可提高图像特征的鲁棒性,并允许网络改变输入信号的大小,增加后续网络的感受野。

1.3 3DV-Net特点

3DV-Net一个突出的特点是使用了ResNet(残差网络)的短路连接方式,也可视为引入resblock(残差模块)^[14]。3DV-Net与U-Net在各阶段卷积模块数相同,但在单个卷积模块中卷积次数可不同。此外,由于3DV-Net主要用于检测医疗领域图像,因此采用Dice损失函数来对网络分割结果进行评估。感受野较大也是3DV-Net的特点之一,3DV-Net模型感受野大小见表1。

表 1 3DV-Net 模型感受野大小
Table 1 Size of the receptive fields in 3DV-Net model

层数	输入尺寸	感受野	层数	输入尺寸	感受野
L-Stage1	128	5×5×5	R-Stage4	16	476×476×476
L-Stage2	64	22×22×22	R-Stage3	32	528×528×528
L-Stage3	32	72×72×72	R-Stage2	64	546×546×546
L-Stage4	16	172×172×172	R-Stage1	128	551×551×551
L-Stage5	8	372×372×372	Output	128	551×551×551

网络还采用残差连接来防止训练过程中梯度消失现象。一般而言,网络越深,表现力和性能越好;但随着网络层级变深,学习过程中可能遇到梯度消失或梯度爆炸^[15]。残差连接可以有效改善这一问题。残差连接示意图如图3所示。




图 3 skip block 示意图
Figure 3 Schematic diagram of a skip block

网络的输入输出可用函数表达,即输入为 x ,输出为 $F(x)$ 。函数一般包含卷积、激活等过程。残差连

接源于长短期记忆控制门的概念。一般来说,若存在这样的函数,则网络可使用误差的链式反向传播改变参数,使用函数表示如下:

$$f' = f(x, w_f) \tag{3}$$

$$g' = g(f') \tag{4}$$

$$y' = k(g') \tag{5}$$

$$\cos t = \text{criterion}(y, y') \tag{6}$$

其中, f 记为卷积函数; w_f 为权重参数; g 记为激活函数; k 记为分类器函数; y 为分类输出结果。由此, $\cos t$ 对 f 的导数为:

$$\frac{d(f')}{d(w_f)} \times \frac{d(g')}{d(f')} \times \frac{d(y')}{d(g')} \times \frac{d(\cos t)}{y'} \tag{7}$$

若公式中某个导数很小,在多次连乘后梯度将越来越小,即梯度消散;在深层网络,特征传到浅层便会损失较多。加入残差是将每个导数加上恒等项1,当原导数 df/dx 较小时,误差也可继续进行反向传播^[16]。

2 实验与分析

2.1 实验数据

本实验使用 LIDC-IDRI (The Lung Image Database Consortium) 中的 LUNA16 数据集。该数据集共包含 1 018 个由胸部图像文件(如 CT 和 X 光片)以及相应的诊断结果和病变标注组成的研究实例,数据大小为 125 Gb,包括 243 958 张 CT 图像,其中每个实例都先由 4 名放射科医生单独标注,然后对比其他医生的标注情况给出最终方案^[17]。

2.2 实验环境

处理器: Intel(R)Core(TM)i9-9900K CPU@3.60 GHz; 内存: 64 GB; 显卡: RTX 2080Ti; 操作系统: Windows 10; 开发语言在 spyder 开发环境下,使用基于 tensorflow 的 Keras 深度学习框架去搭建网络。

2.3 实验过程

肺结节检测分割框架如图 4 所示。生成 Mask (掩膜)图像文件:在数字图像处理中,图像掩模常用于提取感兴趣区域(Region of Interest, ROI),将预制的 ROI 掩模乘以待处理的图像,以确保 ROI 中的图像值不变,而除 ROI 之外的图像值都为 0,也可用掩模遮蔽图像的 ROI,使 ROI 不参与处理或计算^[18]。本实验将从数据集中获取的 CSV 文件转换为图像掩码文件,然后得到 601 个 MHD 文件和 601 个 RAW 文件,可用于后续实验。

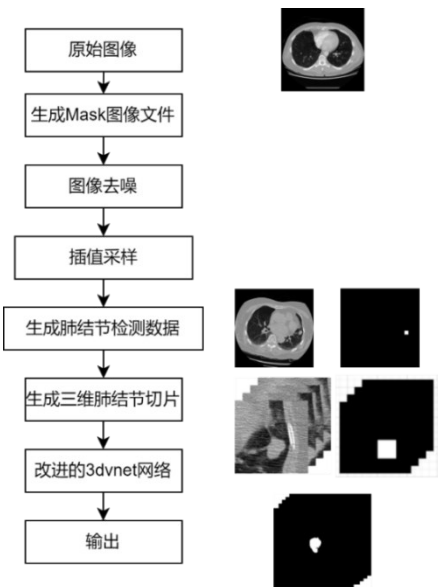


图4 肺结节检测分割框架
Figure 4 Framework of pulmonary nodule detection and segmentation

图像去噪:调整窗宽窗位(-1 000, 600),消除如骨骼亮点、CT床金属线等噪声,并将图像像素标准化为(0, 1)^[19]。

插值采样:对层厚大于 1 mm 的 CT 图像和对应的掩模图像进行插值(CT 图像采用线性插值法,掩模图像

采用最近邻插值法)。插值采样后的层厚为 1 mm。

生成 3D 肺结节切片图:由于肺结节在 CT 图像上占比较小,为减少模型训练的计算量,同时增加训练时目标在整体图像上的占比,需在肺结节周围截取包含肺结节的三维图像块,在 CT 图像和 Mask 图像上按一定步长取 Patch 区域,其尺寸为 96×96×16 (高度×宽度×深度),判断并保留有效的 Patch Mask 图像和相应 Patch 图像。某患者 CT 图像及 Mask 图像如图 5 所示;网络生成两组患者的 Patch 图像和相应 Patch Mask 图像如图 6 所示。




图5 某患者 CT 图像及 Mask 图像
Figure 5 CT image and Mask image of a patient

2.4 参数设置

模型的训练参数需要在训练时进行调整,本实验训练参数包括 Epoch、学习率、Dropout 以及 Batch Size。Epoch 是指用训练集中的数据对模型进行完整训练的次数,本实验的 Epoch 设定为 10。学习率是有监督学习和深度学习中的关键参数,影响着目标函数能否及何时收敛,合适参数可缩短函数收敛时间,经过测试,本实验的学习率设置为 0.001。Dropout 是指在网络训练过程中,选取网络中部分神经元,其他的则被丢弃,可以有效地避免过拟合。Batch 是每次发送到网络的训练数据的一部分数据,Batch Size 是每个批次中训练样本的数量;由于每次只有部分数据被输入到训练中,且需要平衡效率和内存容量,Batch Size 需多次实验寻找最优,经过实验,Batch Size 设置为 6 时,此时网络性能及速度都得到最大化。

2.5 损失函数

通常,利用损失函数对模型的预测值和实际结果进行比较,损失函数数值和模型性能成正相关。损失函数分为经验风险和结构风险^[20]。前者是指预测与真实结果之间的不同,后者是在前者基础上加上正则项。由于本实验中肺结节占整张图的比例较小,这种评估方法更适用于极不均匀样本的情况,因此选择 Dice 相似系数 (Dice Similarity Coefficient, DSC) 的评估方法,DSC 可有效衡量样本之间的重叠



图6 Patch 图像和相应 Patch Mask 图像
Figure 6 Patch images and the corresponding Patch Mask images

度,范围为[0, 1],其中“1”表示完整的重叠。其计算方法为:

$$DSC(X,Y)=\frac{2|X\cap Y|}{|X|+|Y|}$$

(8)

其中,|X∩Y|指集合X、Y的共同元素;|X|指集合X的模;|Y|指集合Y的模。为了计算网络预测的DSC,将|X∩Y|约为预测图和标签的点乘。为了量化计算|X|和|Y|,部分研究人员也会直接使用相加或者取平方求和。

3 实验结果与分析

3.1 训练结果

训练得出损失函数与准确率的关系如图7所示。由图7可知,本文方法的train_loss以及train_acc都可较好地收敛,说明模型权值趋于稳定。




图7 3DV-Net训练结果
Figure 7 3DV-Net training results

为了验证方法的有效性,对本研究预测结果和金标准图像使用交并比函数IoU进行评估。IoU可表述为两图的重叠图像面积除以两图的集合面积,以此来评估方法效果。将本文算法与其他肺结节分割方法在LIDC-IDRI数据集上的实验结果进行对比^[21],进一步验证实验效果,对比结果如表2所示。由表2可知,本文算法性能有明显优越性。

表2 不同肺结节分割方法对比(%)

Table 2 Comparison among different methods for pulmonary nodule segmentation (%)

方法	DSC	准确率	IoU
Pang等 ^[22]	82.32	77.69	76.93
Lau等 ^[23]	81.24	80.47	79.28
Joshi等 ^[24]	80.63	79.58	78.22
Wang等 ^[25]	78.96	78.14	77.31
Zhou等 ^[26]	80.13	79.96	79.26
本文方法	88.29	88.62	88.25

3.2 自动分割结果

基于测试集进行预测结果并与金标准图像对比分析。自动分割结果如图8所示。

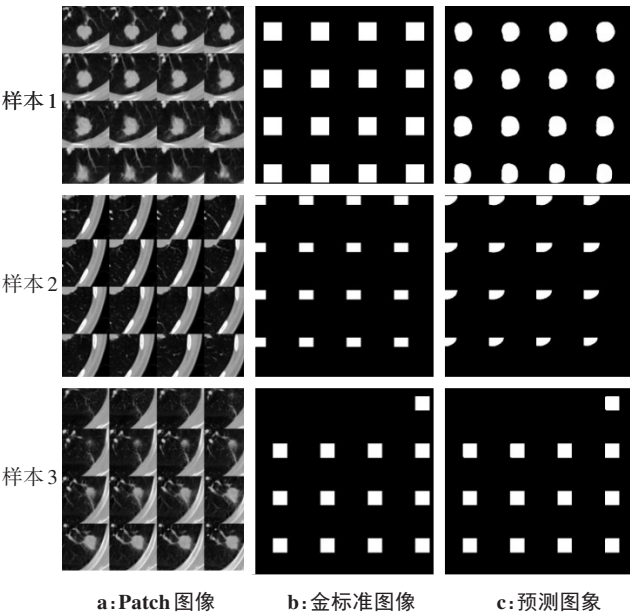


图8 金标准图像与预测图像对比图
Figure 8 Comparison between gold standard images and predicted images

图8给出了对3例样本的检测结果与原始图像以及金标准图像的对比结果(每例样本包含16张patch区域原始图及对应的16张金标准图像及16张

预测图像),图8a表示96×96×96的Patch区域原始图,图8b表示金标准Mask图像,图8c表示本文方法得出的预测图像。

4 结 语

因为肺结节在肺部检测CT图中占比十分小,人工检测非常容易漏检和误检,但肺结节的检测在肺部疾病辅助诊断中占据重要位置。本研究基于深度神经网络进行肺结节检测,实现了肺结节检测和分割。采用改进的3DV-Net检测肺结节,由于数据量较大,先对肺结节进行粗定位,然后对定位后的图像进行进一步的检测分割,可以有效提高分割效率和节省时间。实验表明本文方法有助于检测患者肺部CT图的病变部分,并最终实现了88.29%的DSC值以及88.25%的IoU,优于现有大部分文献的方法。下一步将对检测出的结果进行分类,对肺癌的肺结节进行筛选,进一步提高研究的临床医学价值。

【参考文献】

- [1] Lefranais E, Ortiz-Muoz G, Caudrillier A, et al. The lung is a site of platelet biogenesis and a reservoir for hematopoietic progenitors[J]. *Nature*, 2017, 544(7648): 105-109.
- [2] Yan C, Tan X, Wei Q, et al. Lung MRI of invasive fungal infection at 3 Tesla: evaluation of five different pulse sequences and comparison with multidetector computed tomography (MDCT)[J]. *Eur Radiol*, 2015, 25(2): 550-557.
- [3] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[J]. *IEEE Trans Pattern Anal*, 2015, 39(4): 640-651.
- [4] 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. Cham: Springer, 2015: 234-241.
- [5] Mansoor A, Bagci U, Foster B, et al. Segmentation and image analysis of abnormal lungs at CT: current approaches, challenges, and future trends[J]. *Radiographics*, 2015, 35(4): 1056-1076.
- [6] Haykin S. Neural networks: a comprehensive foundation (3rd Edition) [M]. London: Macmillan Publishers Limited, 1998.
- [7] He K, Wang D, Zhang X. Image segmentation using the level set and improved total-variation smoothing[J]. *Computer Vis Image Und*, 2016, 152: 29-40.
- [8] Lin H, Huang C, Wang W, et al. Measuring interobserver disagreement in rating diagnostic characteristics of pulmonary nodule using the lung imaging database consortium and image database resource initiative [J]. *Acad Radiol*, 2017, 24(4): 401-410.
- [9] He W, Li B, Liao R, et al. An ISHAP-based interpretation-model-guided classification method for malignant pulmonary nodule[J]. *Knowl-Based Syst*, 2022, 237: 107778.
- [10] Roy R, Chakraborti T, Chowdhury AS. A deep learning-shape driven level set synergism for pulmonary nodule segmentation[J]. *Pattern Recogn Lett*, 2019, 123: 31-38.
- [11] Tong G, Li Y, Chen H, et al. Improved U-NET network for pulmonary nodules segmentation[J]. *Optik*, 2018, 174: 460-469.
- [12] Liu H, Cao H, Song E, et al. A cascaded dual-pathway residual network for lung nodule segmentation in CT images[J]. *Phys Med*, 2019, 63: 112-121.
- [13] Zhang N, Lin J, Hui B, et al. Lung nodule segmentation and recognition algorithm based on multiposition U-Net[J]. *Comput Math Method Med*, 2022, 2022: 11.
- [14] Luo S, Zhang J, Xiao N, et al. DAS-Net: a lung nodule segmentation method based on adaptive dual-branch attention and shadow mapping [J]. *Appl Intell*, 2022: 1-15.
- [15] Liu D, Liu F, Tie Y, et al. Res-trans networks for lung nodule classification[J]. *Int J Comput Assist Radiol Surgery*, 2022: 1-10.
- [16] Yamashita R, Nishio M, Do RK, et al. Convolutional neural networks: an overview and application in radiology[J]. *Insights Imaging*, 2018, 9(4): 611-629.
- [17] Çiçek Ö, Abdulkadir A, Lienkamp SS, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation[C]//International Conference on Medical Image Computing and Computer-Assisted intervention. Cham: Springer, 2016: 424-432.
- [18] Han Y, Ye JC. Framing U-Net via deep convolutional framelets: application to sparse-view CT[J]. *IEEE Trans Med Imaging*, 2018, 37(6): 1418-1429.
- [19] Simonyan K, Vedaldi A, Zisserman A. Deep inside convolutional networks: visualising image classification models and saliency maps [J]. *arXiv*, 2013, <https://arxiv.org/abs/1312.6034>.
- [20] Jagerman DL. Some properties of the erlang loss function[J]. *Bell Syst Techn J*, 2014, 53(3): 525-551.
- [21] Armato S, McLennan G, McNitt-Gray M, et al. WE-B-201B-02: the lung image database consortium (LIDC) and image database resource initiative (IDRI): a completed public database of CT scans for lung nodule analysis[J]. *Med Phys*, 2010, 37(6Part6): 3416-3417.
- [22] Pang S, Zhang Y, Ding M, et al. A deep model for lung cancer type identification by densely connected convolutional networks and adaptive boosting[J]. *IEEE Access*, 2019, 8: 4799-4805.
- [23] Lau S, Wang X, Yang X, et al. Automated pavement crack segmentation using fully convolutional U-Net with a pretrained ResNet-34 encoder[J]. *arXiv*, 2020, [arXiv: 2001.01912](https://arxiv.org/abs/2001.01912).
- [24] Joshi K, Tripathi V, Bose C, et al. Robust sports image classification using InceptionV3 and neural networks[J]. *Procedia Comput Sci*, 2020, 167: 2374-2381.
- [25] Wang N, Zhang S, Sun F, et al. Computer-aided diagnosis (CAD) of pulmonary nodule of thoracic CT image using transfer learning[J]. *J Digit Imaging*, 2019, 32(6): 995-1007.
- [26] Zhou Z, Siddiquee M, Tajbakhsh N, et al. UNet++: redesigning skip connections to exploit multiscale features in image segmentation[J]. *IEEE Trans Med Imaging*, 2020, 39(6): 1856-1867.

(编辑:谭斯允)