

基于DeepLab V3+深度神经网络的结直肠息肉内镜图像分割

朱世祺^{1,2}, 徐昶^{1,2}, 周鑫³, 刘璐^{1,2}, 林嘉希^{1,2}, 殷民月^{1,2}, 刘晓琳^{1,2}, 许春芳^{1,2}, 朱锦舟^{1,2}

1. 苏州大学附属第一医院消化内科, 江苏 苏州 215006; 2. 苏州市消化病临床医学中心, 江苏 苏州 215006; 3. 江苏大学附属金坛医院消化内科, 江苏 常州 213200

【摘要】目的:基于深度神经网络DeepLab V3+建立结直肠息肉内镜图像语义分割模型。**方法:**选取Hyper-Kvasir数据库1000张、苏州大学附属第一医院500张结直肠息肉内镜图像,分为训练集($n=1\,200$)和验证集($n=300$),同时收集江苏大学附属金坛医院肠息肉图像作为测试集($n=220$)。对内镜图像进行分割标记,载入以DeepLab V3+为框架的深度神经网络中训练,建立语义分割模型。**结果:**在内部验证集中,该模型的准确性(ACC)达97.2%,平均交并比(MIoU)达85.8%,Dice系数达0.924。在外部测试集中,ACC达98.0%,MIoU达80.1%,Dice系数达0.890。**结论:**基于DeepLab V3+深度神经网络,构建结直肠息肉内镜图像的语义分割模型,具有良好的预测性能,可作为检测结直肠息肉的有效工具。

【关键词】语义分割;深度学习;DeepLab V3+;结直肠息肉

【中图分类号】R318;R574

【文献标志码】A

【文章编号】1005-202X(2023)08-0944-06

Colorectal polyp segmentation in endoscopic images using DeepLab V3+

ZHU Shiqi^{1,2}, XU Chang^{1,2}, ZHOU Xin³, LIU Lu^{1,2}, LIN Jiashi^{1,2}, YIN Minyue^{1,2}, LIU Xiaolin^{1,2}, XU Chunfang^{1,2}, ZHU Jinzhou^{1,2}

1. Department of Gastroenterology, the First Affiliated Hospital of Soochow University, Suzhou 215006, China; 2. Suzhou Clinical Centre of Digestive Disease, Suzhou 215006, China; 3. Department of Gastroenterology, Jintan Affiliated Hospital of Jiangsu University, Changzhou 213200, China

Abstract: Objective To establish a semantic segmentation model for colorectal polyps in endoscopic images based on DeepLab V3+. **Methods** A total of 1 500 endoscopic images of colorectal polyps were collected, including 1 000 from Hyper-Kvasir public dataset and 500 from the First Affiliated Hospital of Soochow University, and randomly divided into training set ($n=1\,200$) and validation set ($n=300$). Meanwhile, the images from Jintan Affiliated Hospital of Jiangsu University were collected as test set ($n=220$). After the endoscopic image segmentation and labeling, the images and masks were loaded into a deep learning neural network with DeepLab V3+ as the architecture for training, thereby developing a semantic segmentation model. **Results** The accuracy, mean intersection over union, and Dice coefficient of the developed model were 97.2%, 85.8% and 0.924 in the internal validation set, and 98.0%, 80.1% and 0.890 in the external test set. **Conclusion** The DeepLab V3+ based semantic segmentation model for colorectal polyps in endoscopic images exhibits excellent performances, and it can serve as an effective method for the detection and diagnosis of colorectal polyps.

Keywords: semantic segmentation; deep learning; DeepLab V3+; colorectal polyp

前言

结直肠癌作为全球癌症死亡人口的第二大病

因^[1],通常经“腺瘤-癌”模式进展,由腺瘤样息肉发展到结直肠癌的病例约占所有结直肠癌的75%^[2]。近年来有研究发现增生性息肉也可以通过锯齿状或微卫星不稳定途径发展成结直肠癌^[3-4]。通常,息肉恶性转化前有一个持续数年、可检测并可治疗的临床前阶段^[5]。因此,早期筛查,早期检出和及时切除肠息肉对降低结直肠癌发生率至关重要。结肠镜检查可以直接寻找结直肠息肉,观察病灶表面情况,必要时进行钳夹活检,是息肉筛查诊断的金标准手段,也是临床医生主要依靠的方式^[6]。但是对缺乏经验的低年资内镜医师或同时伴有两个及以上息肉的情

【收稿日期】2023-02-18

【基金项目】国家自然科学基金(82000540);苏州市科教兴卫青年项目(KJXW2019001);苏州大学医学部学生课外科研项目(2021YXBKWKY050);苏州市科技计划(SKY2021038);苏州市消化病临床医学中心(Szlcyxzx202101)

【作者简介】朱世祺,硕士,研究方向:人工智能在消化病中的应用,E-mail: 1830805021@stu.suda.edu.cn

【通信作者】朱锦舟,博士,副主任医师,研究方向:人工智能在消化病中的应用,E-mail: jzzhu@zju.edu.cn

况,容易导致漏诊风险显著增加^[7-8]。结直肠息肉漏诊率居高不下,漏诊率为2%~26%^[8-9],同时结肠镜检查后结直肠癌(Post-Colonoscopy Colorectal Cancer, PCCRC)发生率逐年增高,约占结直肠癌的9%。PCCRC指在结肠镜检查结果为阴性后出现结直肠癌的事件,通常与不良预后相关,PCCRC发生率已成为预防结直肠癌和评估结肠镜检查质量的一项指标^[10]。因此,亟需一项内镜下自动识别结直肠息肉的客观诊断技术,以降低息肉漏诊率和PCCRC发生率。

近年来,人工智能(Artificial Intelligence, AI)得到了迅速发展,AI及其衍生的计算机辅助诊断(Computer Aided Diagnosis, CAD)在医疗领域得到了广泛应用^[11]。在消化内镜领域,内窥镜检查结合CAD提高了消化系统疾病的检出率。语义分割技术作为计算机辅助系统的重要组成部分,其与传统的图像分割不同,能够自动标注出图像中每个像素所属的对象类别,做到对图像场景的高级别分析和理解^[12-13]。随着卷积神经网络(Convolutional Neural Networks, CNN)的提出,图像识别和语义分割领域得到巨大的发展。而深度卷积神经网络(Deep Convolutional Neural Networks, DCNN)作为多层次的卷积神经网络,对复杂特征的提取能力更强,提高了在分类、检测和分割任务中的可应用性和可塑性^[14]。

目前,DeepLab V3+作为一种较为新颖的DCNN模型,实现了空洞空间卷积池化金字塔的优化,运用多个并行的具有不同采样率的空间卷积层和一个全局平均池化层分别对原始图像进行深层和浅层特征提取,捕获更多的特征,从而提高分割任务的性能和精度^[15]。基于DeepLab V3+的优点,本文利用该深度学习网络模型对结直肠息肉内镜图像进行语义分割,旨在内镜下检测结直肠息肉,并在正常肠黏膜中准确描绘息肉边界,降低息肉漏诊率,为未来自动化内镜下诊疗提供思路。

1 对象与方法

1.1 研究对象

选取来自挪威Bærum Hospital内镜中心开源数据集Hyper-Kvasir的1 000张肠息肉内镜原始图像和对应的1 000张黑白勾勒标签^[16]。同时随机选取苏州大学附属第一医院消化内镜中心数据库2022年5月~11月的500张肠息肉内镜原始图片。共计1 500张肠息肉内镜原始图片以8:2的比例随机分为训练集($n=1\,200$)和内部验证集($n=300$)。另外,选取来自江苏大学附属金坛医院消化内镜中心肠息肉内镜原始图像作为外部测试集($n=220$)。具体流程如图1所示。

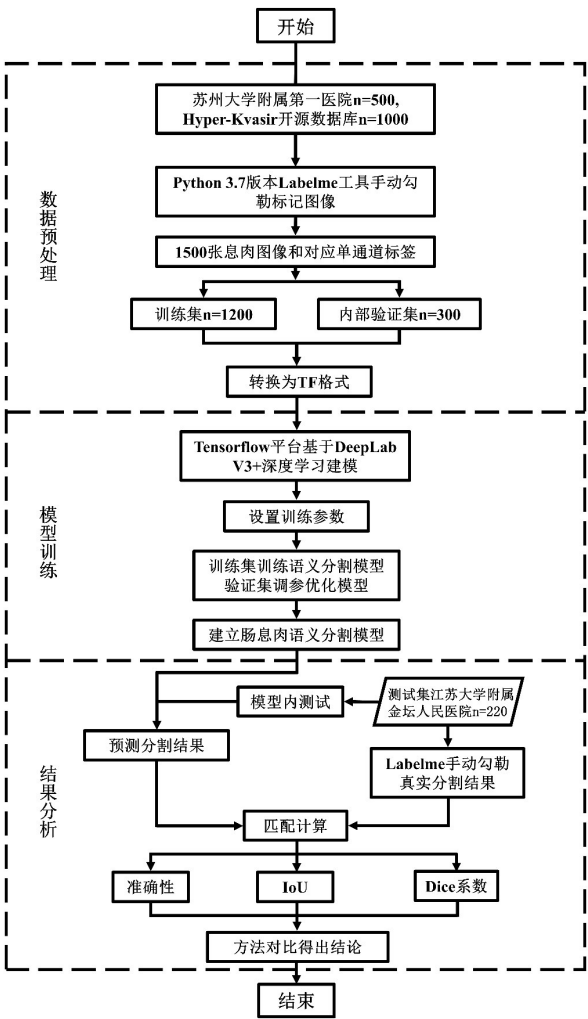


图1 研究流程图

Figure 1 Research process

1.2 图片预处理

分别由苏州大学附属第一医院和江苏大学附属金坛医院消化内镜中心高年资内镜医师对500张训练验证图像和220张测试图像手动勾勒出息肉病灶边界并进行标注。图像的勾勒和标注使用Python 3.7版本的开源图像标注工具Labelme,该工具可以用来标注图像,处理分类、检测、分割等常见的视觉任务。勾勒标注任务完成后,导出二值化的PNG格式标签,该标签只含息肉和背景区域,设置息肉区域的值为1(白色),背景区域的值为0(黑色)。图像预处理后,将1 500张原始图像和标签载入以DeepLab V3+为框架的网络模型中进行训练和验证。

1.3 DeepLab V3+网络

DeepLab V3+是基于DCNN的语义分割模型,其在模型结构上进行了改进,在保留DeepLab V1^[17]的空洞卷积层和DeepLab V2^[18]的空洞空间卷积池化金字塔层的基础上,引入编码-解码器结构进行拓展,以实现多尺度特征的融合。本研究使用Python软件

(版本 3.9)的 Tensorflow 框架(版本 2.8)训练和验证模型,采用分类交叉熵作为损失函数,为寻求最小损失值,采用 Adam 优化器对参数进行调整。

DeepLab V3+主要由两个部分构成:编码器和解码器。编码器模块通过在多个尺度上应用扩张卷积处理多尺度的上下文信息,获得输入图像的特征信息,而解码器对得到的特征信息解码分析,沿着物体的边界完善并预测分割结果,即输入图像中每个像素所属的对象类别。输入图片首先进入编码器内,通过深度卷积神经网络获得两个有效特征层,第一个特征层以 ResNet50 框架为骨干,辅以 4 个不同采样

率的空洞卷积(1×1,rate1;3×3,rate6;3×3,rate12;3×3,rate18)提高网络感受野,提取深度特征,获得 4 个不同的特征层,再将特征层与单独池化层(Image Pooling)进行堆叠,以 1×1 的卷积核压缩成一个深度特征层;第二个特征层直接通过 1×1 卷积核对输入图像进行浅层特征提取,形成一个浅层特征层。在解码器中,对深度特征层进行 4 次上采样,并与浅层特征层进行堆叠,融合浅层和深度特征,再通过 3×3 卷积核进一步提取特征,最终通过 4 次上采样调整输出图像大小,使其与输入图像大小一致,此时即得到了模型的预测结果。DeepLab V3+模型架构如图 2 所示。

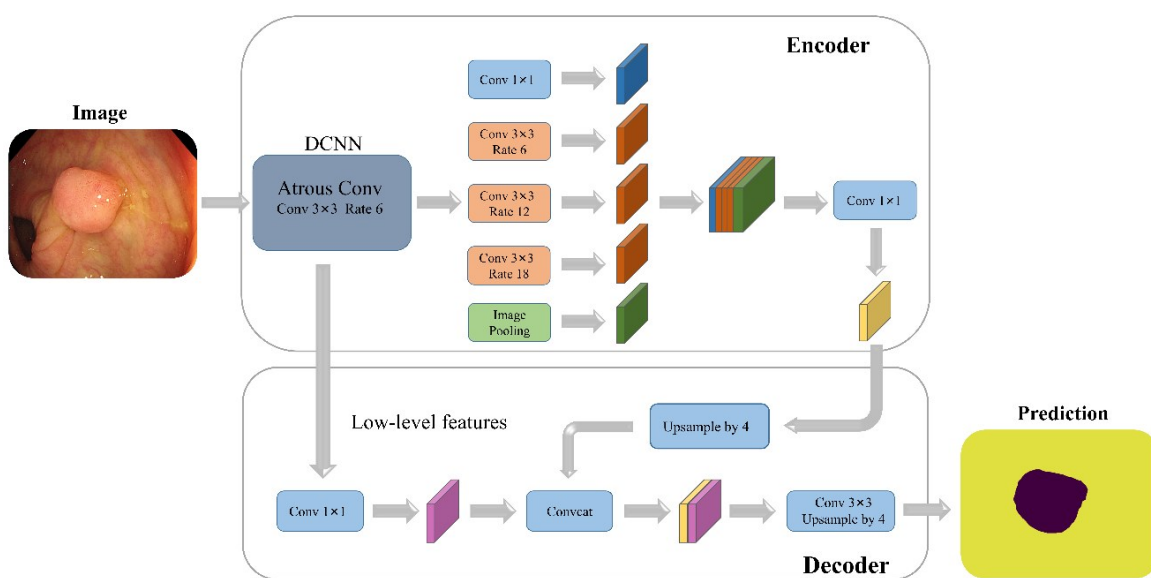


图 2 DeepLab V3+模型的框架示意图
Figure 2 Architecture of DeepLab V3+ model

1.4 模型性能评估

将 1 500 张内镜原始图像和标签输入 DeepLab V3+模型中,对训练集中的 1 200 张图像进行训练,再基于模型对验证集中 300 张图像的预测性能进行超参数调整。最后将训练好的模型在测试集的 220 张图像上进行预测并评价模型性能。

对于语义分割任务,平均交互比(Mean Intersection over Union, MIoU)、准确率(Accuracy, ACC)和Dice系数通常会被用于评估性能。

ACC 表示所有样本中完全分割正确的样本量占比,可以用来表示模型的准确性,其公式为:

$$ACC = \frac{TP + TN}{TP + FP + FN + TN} \times 100\% \quad (1)$$

其中,TP 为真阳性,表示为被正确分割的息肉区域像素数目;FP 为假阳性,表示为被错误分割为息肉区域的背景像素数目;TN 为真阴性,表示为被正确分割的

背景区域像素数目;FN 为假阴性,表示为被错误分割为背景区域的息肉像素数目。

MIoU 表示所有图像真实分割区域和预测分割区域交集与并集之比的平均值,即平均交互比,通常用于评估分割区域之间的重合程度,其表达式为:

$$MIoU(y, p) = \frac{|y \cap p|}{|y \cup p|} \times 100\% \quad (2)$$

Dice 系数是集合相似度的度量函数,表示真实分割区域与预测分割区域之间的相似性,两个分割区域越相似得分越趋近于 1,其表达式为:

$$Dice(y, p) = \frac{2 \times |y \cap p|}{|y| + |p|} \quad (3)$$

其中,y 表示为真实分割区域;p 表示为预测分割区域。

2 结果

2.1 语义分割预测结果

从训练集、验证集和测试集中分别随机选取3张

结直肠息肉图像,见图3。在图3的每个数据集中,依次展示了原始结直肠息肉病灶图像、人工勾勒的结直肠息肉病灶图像和DeepLab V3+网络模型预测的结直肠息肉病灶图像。

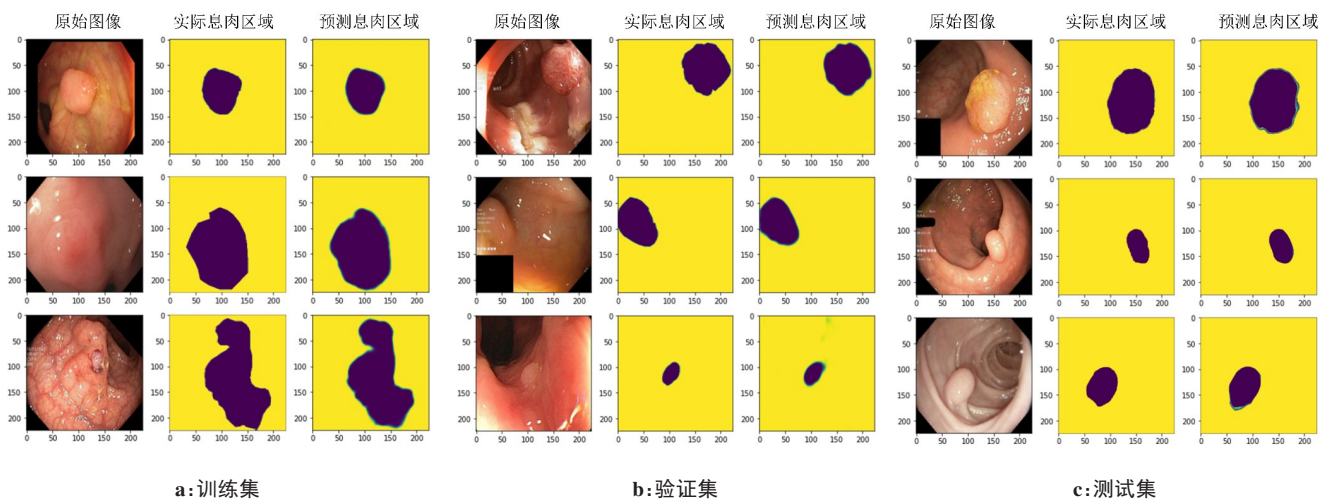


图3 DeepLab V3+模型在各数据集上对息肉图像的预测结果
Figure 3 Prediction results of DeepLab V3 + model on polyp images

2.2 模型性能评价指标

基于DeepLab V3+深度神经网络框架的语义分割模型在训练集、验证集及测试集中预测结直肠息肉的ACC分别为98.7%、97.2%、98.0%,MIoU分别为92.3%、85.8%、80.1%,Dice系数分别为0.960、0.924、0.890。

3 讨论

本研究收集多中心来源的1 720张结直肠息肉内镜图像作为数据集,基于DeepLab V3+深度神经网络框架,建立针对结直肠息肉内镜图像的计算机视觉语义分割模型,在内部验证集和外部测试集中均显示出较好的分割性能。

结直肠息肉内镜图像分割任务历经了从传统方法到深度学习方法的发展,传统的分割方法通过手工提取息肉内镜图像的形状、颜色、纹理等低层次特征,再通过分类器实现对息肉的区分。Mamonov等^[19]于2014年提出通过提取息肉形状和纹理特征,结合合适的球半径作为决策参数构建二元分类器完成对内镜下结直肠息肉的检测,其算法在93.5%的特异性下保持了81.3%的敏感性。但是由于提取的特征多为纹理、形态等浅层特征,并且特征的提取、参数的选择高度依赖研究者的经验,传统分割方法存在耗时长、自动化不足、准确性不稳定等缺点。

为更好地解决结直肠息肉内镜图像的分割任

务,基于深度学习方法的图像检测分割方法被广泛应用。Shelhamer等^[20]首次采用全卷积神经网络(FCNs),针对像素点进行分类,保证输入和输出的图像尺寸一致,达到图像分割的目的。在此之后,基于深度学习的结直肠息肉内镜图像分割方法屡见不鲜^[21-22],这些方法虽然在精度、召回率等方面优于传统方法,但大多使用边框识别息肉,缺乏对边界的准确定位。随着UNet网络在生物医学图像领域的首次应用,越来越多的研究通过改进UNet网络模型来进行息肉内镜图像的语义分割。Zhang等^[23]报道了深度残差结构的U型网络ResUNet,该网络将UNet与residual单元结合,一方面简化了深层网络的训练过程,另一方面提高了分割结果的准确率。Zhou等^[24]提出了另一种UNet改进的网络结构:UNet++,该网络模型在保留深度监督和剪枝结构同时增添了跳跃路径互相连接,减少未知的网络深度,降低特征图中的语义缺失,提高分割性能。除此以外,其他的网络模型也被用于肠息肉内镜图像的语义分割任务,Wang等^[25]采用一种16层的语义分割SegNet网络模型进一步提高息肉图像分割的精度及网络的性能鲁棒性。Han等^[26]提出一种平行残差金字塔网络模型PRAPNet,充分运用不同区域的上下文信息,实现结直肠息肉内镜图像的分割,MIoU和Dice系数在Kvasir-SEG数据集上均达到0.90以上。

作为近年来最新的语义分割模型之一,DeepLab

V3+融合多尺度的卷积层与编码-解码器,可同时对图像的低级和高级特征进行提取,并对边界进行识别,有效提高分割精确率,其优点如下:(1)采用空洞卷积,在扩大感受野的同时,捕获多尺度的上下文信息,精确定位信息;(2)结合空间卷积池化金字塔和编码-解码器构架二者的优点,在获得图像丰富特征信息的同时,逐步恢复边界信息,获得清晰的物体边界;(3)通过空洞卷积层控制编码器特征图的分辨率,完善编码-解码器模块。DeepLab V3+在目前的语义分割任务中有着优异表现,Wang等^[27]发现运用DeepLab V3+神经网络对胃癌病理切片进行识别和分割,其敏感性、特异性和准确度均能达到90%以上;在肺结节的检测和分割任务中,结合DeepLab V3+网络模型可使MIoU达到70%以上,远优于其他的网络模型(Dual-Path Residual U-Net、Traditional U-Net)^[28],这都提示DeepLab V3+也可以成为医学图像检测分割的优异选择。在肠息肉内镜图像的检测分割任务中,相比于其他经典模型(UNet、ResUNet等),DeepLab V3+在各项性能指标上均有一定程度的提升,在Kvasir-SEG开源数据库中,Dice系数达0.866,提高4%~35%,MIoU达81.9%,提高6%~38%,如表1所示。

表1 DeepLab V3+对比其他算法性能表现
Table 1 Comparison of segmentation performance between DeepLab V3+ with other models

数据库	算法	Dice系数	MIoU/%
Kvasir-SEG	UNet ^[29]	0.715	43.3
	ResUNet ^[23]	0.514	43.6
	UNet++ ^[24]	0.821	74.3
	DeepLab V3+ ^[30]	0.866	81.9
CVC-ClinicDB	UNet ^[29]	0.642	47.1
	ResUNet ^[23]	0.451	45.7
	UNet++ ^[24]	0.794	72.9
	DeepLab V3+ ^[30]	0.899	85.9

目前使用DeepLab V3+对肠息肉内镜图像分割的研究较少^[30-32],使用DeepLab V3+对结直肠息肉内镜图像进行识别和分割仍有很大的研究空间。徐昌佳^[30]基于DeepLab V3+网络对结直肠息肉内镜图像分割算法进行研究,在不牺牲分割准确率的条件下进行改进,通过替换骨干网络以及引入BAM注意力机制,提高了网络的训练速度和特征提取能力,在Kvasir-SEG数据集上Dice系数达0.893,MIoU达

82.6%;在CVC-ClinicDB数据集上Dice系数达0.908,MIoU达86.7%。徐昌佳^[30]证明了DeepLab V3+在结直肠息肉内镜图像语义分割任务中的可行性,但由于缺乏外部测试集,其临床效果有待进一步证明。王亚刚等^[32]也提出了一项基于DeepLab V3+网络的肠息肉图像分割方法,为了提高息肉的检出率,在数据预处理阶段首先对息肉图像进行了去反光处理,再通过Grab Cut算法得到粗分割结果与去反光处理后的图像叠加增强息肉位置的信号。在改进DeepLab V3+网络方面,王亚刚等^[32]在编码器中加入DPC架构进一步捕获多尺度特征信息并在解码器中将3×3卷积改进为3层深度可分离卷积以实现空间和深度信息的控制。在CVC-ClinicDB数据集上进行验证,其MIoU达94.7%,其余指标也均高于93.5%,但由于需要对数据进行去反光和叠加预处理,并且改进算法计算量较大、复杂度较高,其实际临床意义值得商榷。

上述研究多从DeepLab V3+网络框架出发,通过对原始DeepLab V3+网络框架进行改进,加强特征提取能力,以获得更优的评价指标。但是使用同一个开源数据库进行训练、验证和测试,缺乏来源于医院的外部测试,模型网络具体应用于临床的效果仍不明确,模型泛化性不足。除此以外,为降低图片高光区域对算法的影响,徐昌佳和王亚刚等都预先对图片进行了去反光处理并排除了大量干扰图像,这一处理虽然能够更有效地获得息肉的纹理特征,但在临床中的实用性有待商榷。笔者构建的模型同样使用了DeepLab V3+网络模型,不同的是,我们并没有对模型本身进行改进,而是拓展了样本来源,同时收集了Hyper-Kvasir开源数据库、苏州大学附属第一医院、结直肠息肉内镜图像,样本容量超过1000张,解决了小样本训练不足,容易过拟合的弊端,同时多中心来源的样本可以克服模型泛化性不足的缺点;另一方面,使用了江苏大学附属金坛医院220张结直肠息肉内镜图像作为外部测试集,能够在临床实际中客观地评价模型的表现。

关于测试集中MIoU较低的情况,笔者给出如下解释:一是DeepLab V3+自身存在欠缺,包括空间金字塔结构在该数据集上表现不理想以及解码器未能对低级和高级特征进行充分融合,导致部分边缘信息丢失,甚至出现错误分割的现象^[33];二是由于训练集、验证集、测试集来源不同,不同设备、不同内镜医生可能会对结直肠息肉图片的选取、勾勒造成一定影响。针对上述问题,在之后的研究中,笔者将对DeepLab V3+网络模型进行改进,通过融合多尺度特征和引入注意力机制减少边缘信息的丢失^[33],在数

据集的管理上,将对内镜医师统一进行培训,减小人为因素造成的误差。

综上所述,本研究构建的DeepLab V3+网络模型在检测结直肠息肉内镜图像上具有较高的准确性,实现了临床上对肠息肉内镜图像像素级的分割。一方面为低年资内镜医师提供了息肉诊断的辅助参考,降低漏诊率,提高诊断效率。另一方面,优秀的语义分割模型,为未来智能化机器人辅助内镜下息肉治疗打下基础。但是该模型对息肉区域的边缘分割不够准确,测试集交互比较低,下一步将对此进行改进。此外,需要进行更多的研究和临床试验来进一步证实DeepLab V3+模型用于检测结直肠息肉内镜图像的有效性和实用性。

【参考文献】

- [1] Sung H, Ferlay J, Siegel RL, et al. Global Cancer Statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA Cancer J Clin, 2021, 71(3): 209-249.
- [2] Lieberman DA, Rex DK, Winawer SJ, et al. Guidelines for colonoscopy surveillance after screening and polypectomy: a consensus update by the US Multi-Society Task Force on Colorectal Cancer[J]. Gastroenterology, 2012, 143(3): 844-857.
- [3] Hawkins NJ, Ward RI. Sporadic colorectal cancers with microsatellite instability and their possible origin in hyperplastic polyps and serrated adenomas[J]. J Natl Cancer Inst, 2001, 93(17): 1307-1313.
- [4] He XS, Wu K, Ogino S, et al. Association between risk factors for colorectal cancer and risk of serrated polyps and conventional adenomas[J]. Gastroenterology, 2018, 155(2): 355-373.
- [5] Bretthauer M, Kalager M, Adami HO. Do's and don'ts in evaluation of endoscopic screening for gastrointestinal cancers[J]. Endoscopy, 2016, 48(1): 75-80.
- [6] Nishihara R, Wu K, Lochhead P, et al. Long-term colorectal-cancer incidence and mortality after lower endoscopy[J]. N Engl J Med, 2013, 369(12): 1095-1105.
- [7] Kaminski MF, Regula J, Kraszevska E, et al. Quality indicators for colonoscopy and the risk of interval cancer[J]. N Engl J Med, 2010, 362(19): 1795-1803.
- [8] Leufkens AM, Van Oijen MG, Vleggaar FP, et al. Factors influencing the miss rate of polyps in a back-to-back colonoscopy study[J]. Endoscopy, 2012, 44(5): 470-475.
- [9] Heresbach D, Barrioz T, Lapalus MG, et al. Miss rate for colorectal neoplastic polyps: a prospective multicenter study of back-to-back video colonoscopies[J]. Endoscopy, 2008, 40(4): 284-290.
- [10] Rutter MD, Beintaris I, Valori R, et al. World endoscopy organization consensus statements on post-colonoscopy and post-imaging colorectal cancer[J]. Gastroenterology, 2018, 155(3): 909-925.
- [11] He JX, Baxter SL, Xu J, et al. The practical implementation of artificial intelligence technologies in medicine[J]. Nat Med, 2019, 25(1): 30-36.
- [12] Hoar D, Lee PQ, Guida A, et al. Combined transfer learning and test-time augmentation improves convolutional neural network-based semantic segmentation of prostate cancer from multi-parametric MR images[J]. Comput Methods Programs Biomed, 2021, 210: 106375.
- [13] Yang RX, Yu YY. Artificial convolutional neural network in object detection and semantic segmentation for medical imaging analysis[J]. Front Oncol, 2021, 11: 638182.
- [14] Li ZW, Liu F, Yang WJ, et al. A survey of convolutional neural networks: analysis, applications, and prospects[J]. IEEE Trans Neural Netw Learn Syst, 2022, 33(12): 6999-7019.
- [15] Chen LC, Zhu Y, Papandreou G, et al. Encoder-Decoder with atrous separable convolution for semantic image segmentation [C]//Proceedings of the European Conference on Computer Vision (ECCV). 2018: 801-818.
- [16] Borgli H, Thambawita V, Smedsrud PH, et al. HyperKvasir, a comprehensive multi-class image and video dataset for gastrointestinal endoscopy[J]. Sci Data, 2020, 7(1): 283.
- [17] Chen LC, Papandreou G, Kokkinos I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs [C]//International Conference on Learning Representations. 2014.
- [18] Chen LC, Papandreou G, Kokkinos I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Trans Pattern Anal Mach Intell, 2018, 40(4): 834-848.
- [19] Mamonov AV, Figueiredo IN, Figueiredo PN, et al. Automated polyp detection in colon capsule endoscopy[J]. IEEE Trans Med Imaging, 2014, 33(7): 1488-1502.
- [20] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(4): 640-651.
- [21] Yu LQ, Chen H, Dou Q, et al. Integrating online and offline three-dimensional deep learning for automated polyp detection in colonoscopy videos[J]. IEEE J Biomed Health Inform, 2017, 21(1): 65-75.
- [22] Zhang RK, Zheng YL, Poon CC, et al. Polyp detection during colonoscopy using a regression-based convolutional neural network with a tracker[J]. Pattern Recognit, 2018, 83: 209-219.
- [23] Zhang Z, Liu Q, Wang Y. Road extraction by deep residual U-Net[J]. IEEE Geosci Remote Sens Lett, 2018, 15(5): 749-753.
- [24] Zhou Z, Siddiquee MM, Tajbakhsh N, et al. UNet++: a nested U-Net architecture for medical image segmentation [C]//4th Deep Learning in Medical Image Analysis (DLMIA) Workshop, 2018, 11045: 3-11.
- [25] Wang P, Xiao X, Glissen Brown JR, et al. Development and validation of a deep-learning algorithm for the detection of polyps during colonoscopy[J]. Nat Biomed Eng, 2018, 2(10): 741-748.
- [26] Han J, Xu C, An ZH, et al. PRAPNet: a parallel residual atrous pyramid network for polyp segmentation [J]. Sensors (Basel), 2022, 22(13): 4658.
- [27] Wang J, Liu XP. Medical image recognition and segmentation of pathological slices of gastric cancer based on DeepLab V3+ neural network[J]. Comput Methods Programs Biomed, 2021, 207: 106210.
- [28] El-Bana S, Al-Kabbany A, Sharkas M. A two-stage framework for automated malignant pulmonary nodule detection in CT scans[J]. Diagnostics (Basel), 2020, 10(3): 131.
- [29] 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. 2015: 234-241.
- [30] 徐昌佳. 基于深度学习的结直肠息肉图像分割算法研究[D]. 赣州: 江西理工大学, 2022.
- [30] Xu CJ. Research on colorectal polyp image segmentation algorithm based on deep learning[D]. Ganzhou: Jiangxi University of Science and Technology, 2022.
- [31] Xiao WT, Chang LJ, Liu WM. Semantic segmentation of colorectal polyps with DeepLab and LSTM networks [C]//2018 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW). IEEE, 2018.
- [32] 王亚刚, 郝怡媛, 潘晓英. 改进DeepLab V3+网络的肠道息肉分割方法[J]. 计算机科学与探索, 2020, 14(7): 1243-1250.
- [32] Wang YG, Xi YY, Pan XY. Method for intestinal polyp segmentation by improving DeepLab V3+ network [J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(7): 1243-1250.
- [33] 张文博, 瞿珏, 王巍, 等. 融合多尺度特征的改进DeepLab V3+图像语义分割算法[J]. 电光与控制, 2022, 29(11): 12-16.
- [33] Zhang WB, Qu J, Wang W, et al. An improved DeepLab V3+ image semantic segmentation algorithm incorporating multi-scale features [J]. Electronics Optics & Control, 2022, 29(11): 12-16.

(编辑:薛泽玲)