

基于CT图像语义的COVID-19实例分割与分类网络

柏正尧, 樊圣澜, 陆倩杰, 周雪

引用本文

柏正尧, 樊圣澜, 陆倩杰, 周雪. 基于CT图像语义的COVID-19实例分割与分类网络[J]. 计算机科学, 2023, 50(6A): 220600142-9.

BAI Zhengyao, FAN Shenglan, LU Qianjie, ZHOU Xue. COVID-19 Instance Segmentation and Classification Network Based on CT Image Semantics [J]. Computer Science, 2023, 50(6A): 220600142-9.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于边缘优化和全局建模的多路径语义分割](#)

Multi-path Semantic Segmentation Based on Edge Optimization and Global Modeling

计算机科学, 2023, 50(6A): 220700137-7. <https://doi.org/10.11896/jsjcx.220700137>

[基于数据融合的半监督高分遥感影像语义分割](#)

Semi-supervised Semantic Segmentation for High-resolution Remote Sensing Images Based on DataFusion

计算机科学, 2023, 50(6A): 220500001-6. <https://doi.org/10.11896/jsjcx.220500001>

[基于多尺度原型分层匹配的小样本分割方法](#)

Few-shot Segmentation Based on Multi-scale Prototype Hierarchical Matching

计算机科学, 2023, 50(6A): 220300275-7. <https://doi.org/10.11896/jsjcx.220300275>

[联合语义分割和深度估计的多任务学习研究](#)

Study of Multi-task Learning with Joint Semantic Segmentation and Depth Estimation

计算机科学, 2023, 50(6A): 220100111-10. <https://doi.org/10.11896/jsjcx.220100111>

[基于Swin Transformer和三维残差多层融合网络的高光谱图像分类](#)

Hyperspectral Image Classification Based on Swin Transformer and 3D Residual Multilayer Fusion Network

计算机科学, 2023, 50(5): 155-160. <https://doi.org/10.11896/jsjcx.220400035>

基于 CT 图像语义的 COVID-19 实例分割与分类网络

柏正尧 樊圣澜 陆倩杰 周雪

云南大学信息学院 昆明 650502

摘要 为了辅助临床医生进行 COVID-19 患者的诊断及治疗,提出了一个从患者肺部 CT 图像中分类、检测和分割 COVID-19 病变的辅助诊断网络 AIS-Net。首先,该网络将语义分割与实例分割融合,提升了实例分割精度,提出了信息增强注意力模块(IEAM),用于提升输入特征关键信息的权重。为了提高网络对假阴性的关注度,提出了一个实例分割监督方法,用于不同尺度的病变进行监控。其次,设计了一个包含主分类头与辅助分类头的模块,对新冠肺炎、普通肺炎和非肺炎进行分类。在辅助分类中引入了 Swin Transformer,提出了区分普通肺炎与新冠肺炎病变的方法。在 CC-CCII 分割数据集上实例分割的平均精度均值(mAP)为 56.53%,比目前最好的方法提升了 11.77%;Dice 系数、灵敏度、特异度分别为 80%,85.1%,99.3%,比目前最好的方法分别提升了 4.7%,3.7%,1.2%。在 COVIDX-CT 分类数据集上实现了 99.07%的总体准确度,比目前最好的方法提升了 0.92%。AIS-Net 可通过 CT 图像对 COVID-19 患者进行有效诊断,并对病变部位进行分割及检测。

关键词: COVID-19 分类;实例分割;语义分割;Swin Transformer;CT 图像

中图法分类号 TP391

COVID-19 Instance Segmentation and Classification Network Based on CT Image Semantics

BAI Zhengyao, FAN Shenglan, LU Qianjie and ZHOU Xue

School of Information Science and Engineering, Yunnan University, Kunming 650500, China

Abstract To assist clinicians in the diagnosis and treatment of COVID-19 patients, a computer-aided diagnosis network AIS-Net is proposed to classify, detect and segment COVID-19 lesions in CT images. First, the network integrates semantic and instance segmentation to improve the accuracy. Then, the two modules are designed, the information enhanced attention module(IEAM) for weighing input features and the instance segmentation monitoring module focusing on the lesions at different scales. Furthermore, the classification module with the main header and the auxiliary header discerns COVID-19 pneumonia, common pneumonia, and non-pneumonia. Finally, the Swin Transformer is introduced into the auxiliary classification to distinguish the lesions of common pneumonia and COVID-19. On the CC-CCII dataset, the mean average precision(mAP) of instance segmentation is 56.53%, which is 11.77% higher than the state-of-the-art(SOTA). Dice coefficient, sensitivity and specificity is 80%, 85.1% and 99.3% respectively, which is 4.7%, 3.7% and 1.2% higher than the SOTA. The overall classification accuracy is 99.07% on the COVIDX-CT dataset, 0.92% higher than the SOTA. AIS-Net can effectively diagnose COVID-19 patients through CT images, and segment and detect the lesion sites.

Keywords COVID-19 classification, Instance segmentation, Semantic segmentation, Swin Transformer, CT images

新冠肺炎是由一种新型冠状病毒引起的急性感染性肺炎^[1]。早期对新冠肺炎患者进行快速而准确的诊断,切断病毒的传播路径,是防止疫情扩散的关键。目前,筛查 COVID-19 患者的主要方法是通过鼻咽拭子的实时逆转录酶-聚合酶链反应(Reverse Transcription-Polymerase Chain Reaction, RT-PCR)^[2],该方法被称为“金标准(gold-standard)”,但是随着新冠疫情的大规模爆发以及变异毒株的不断出现,RT-PCR 灵敏度较低,检测耗时的缺点也不断显现出来。为了加快诊断速度,在提高准确率的同时,节省医务人员的时间和精力,胸部射线(CXR)图像和计算机断层扫描(CT)图像逐渐成为筛查 COVID-9 患者的两种主要技术手段。

CT 扫描技术可以弥补 RT-PCR 检测技术的不足,但是该方法仍然具有一定的局限性。临床医生凭经验通过肉眼判读的方式来分析感染情况,容易受到主观因素的影响,最终会

导致出现一定的测量误差;除此以外,判读和诊断时间长是 CT 扫描技术的主要限制,一个患者胸部 CT 图像包含 100~400 幅扫描截面,即使是经验丰富的放射科医生也需要大约 20~30 min 的诊断时间^[3],在新冠大流行期间,世界各地都严重缺乏放射科医生,难以对潜在的新冠肺炎感染者进行识别。

已有不少学者以 CT 扫描技术为基础,利用深度学习技术对新冠肺炎患者 CT 图像病变区域进行分割和识别,实现 COVID-19 快速诊断。目前,基于深度学习的 COVID-19 诊断方法主要借助早期分类模型来对胸部 CT 图像进行分类,最常用的分类模型有:VGGNet^[4], Inception^[5], ResNet^[6], DenseNet^[7], CapsNet^[8]和 EfficientNet^[9]等。文献[10]使用 VGG16 设计 COVID-19 诊断模型 TLCoV,在 COVID-19 的三分类问题上取得了 97.67%的准确率。文献[11]则以 VS-BN(VGG-style Base Network)为骨干网络,引入卷积注意

基金项目:云南省重大科技专项计划项目(202002AD080001)

This work was supported by the Major Science and Technology Project of Yunnan Province(202002AD080001).

通信作者:柏正尧(baizhy@ynu.edu.cn)

模块(Convolutional Block Attention Module, CBAM)^[12]和多路数据扩充方法(IMDA)^[13],提出了一个新型人工智能模型AVNC。其中,CBAM用于细化特征图,以更加关注病变特征,而IMDA则可以减少COVID-19数据集规模过小而导致的过拟合,对于新冠肺炎、普通肺炎、肺结核和非肺炎的四分类问题,灵敏度、精度、F1得分均超过了95%。除了借助深度学习基础分类模型来对COVID-19患者进行预测,不少学者也利用深度学习技术对COVID-19患者肺部CT图像病变区域进行分割研究。例如,文献[14]提出了一种基于编解码器的COVID-19肺部CT图像分割方法,该方法首先对疑似感染区域进行分割,然后对这些分割出来的区域进行细分,在缺乏COVID-19数据集的情况下,Dice系数达到78.6%。

目前基于深度学习的COVID-19诊断模型大多是针对新冠肺炎和非肺炎的二分类问题。但在实际应用中,研究新冠肺炎、普通肺炎和非肺炎的三分类会更有意义。新冠肺炎与普通肺炎的病灶区域极为相似,如果将普通肺炎诊断为新冠肺炎,这会造成重大的医疗事故。在分割方面,如图1中红色矩形框内所示,COVID-19病变形状复杂、尺度多变,在同一幅胸部CT图像中,出现了多种尺度不同的病变区域,容易造成分割过程中出现假阴性。多尺度病变分割问题的解决,依赖于解码器部分不同尺度特征层的成功融合。实例分割最大的特点在于能够对同一幅图像中的每一个病变实例进行单独分割,因此具有更高的灵敏度;其次,实例分割能够同时对病变进行检测和分割,相比单纯的分割而言,具有更高的研究价值。然而,掩码分支部分需要将特征图用RoIAlign池化到 14×14 大小,造成了大量信息的损失,限制了分割精度的提高。

针对以上问题,本文将语义分割方法与实例分割方法进行了融合,提出了区分新冠肺炎与普通肺炎的方法,并在此基础上进一步提出了一个包含分类、检测和分割的COVID-19端到端网络AIS-Net。与其他融合语义特征与实例特征的方法不同,AIS-Net是第一个将语义分割与实例分割方法进行融合的网络。




图1 COVID-19患者胸部CT切片及病变标注(电子版为彩图)

Fig. 1 Chest CT section and lesion labeling in patients with COVID-19

1 AIS-Net 网络模型

AIS-Net的总体结构如图2所示,其工作流程为:1)以ResNext50^[15]为主干输出4层不同尺度的特征图 A_1, A_2, A_3, A_4 ,并采用3个ASPP(Atrous Spatial Pyramid Pooling)^[16]分别对 A_1, A_2, A_3 提取多尺度特征输入FPN(Feature Pyramid Networks)^[17], A_4 用于后续的分类部分;2)对FPN部分输出的特征图分别用信息增强注意力模块(Information Enhances Attention Modules, IEAM)提升关键信息的权重,然后输入解码器得到语义分割结果;3)将分割标签标定好的边界框映射到主干+ASPP提取到的特征图上,经RoIAlign^[18]池化后

输入掩码分支,对语义分割部分以实例分割的方法进行监督,提升网络对假阴性的关注;4)采用Python中的图像处理工具Skimage对经二值化后的语义分割结果进行连通域标记,然后提取每个连通域对应的矩形边界框,输入检测分支,用于预测每个连通域为病变的概率;最后将边界框及病变概率值映射回语义分割结果上;5)在主干输出的最后一级特征图后接一个全局平均池化层和全连接层,对图像进行分类,紧接着对语义分割结果进行灰度变换处理,通过减少分割病变与背景的灰度差,在普通肺炎的分割结果中引入噪声,提升普通肺炎病变与新冠肺炎病变的区别,最后送入Swin Transformer^[19],对分类结果进行调整。

1.1 融合语义分割与实例分割

采用实例分割方法不仅能够对病变区域进行分割,而且能够输出每一个病变区域的预测概率,以及对病变区域进行边界框标注,因此对COVID-19患者的诊断和治疗都更有意义。传统的两阶段实例分割网络都是以区域建议网络(RPN)为建议框提取器。RPN首先在主干部分提取的特征图上生成上万个锚框(anchor),然后利用非极大值抑制算法(NMS)计算上万个锚框(anchor)与真实边界框的置信度,最后进行阈值处理,提取2000个锚框(anchor)作为建议框用于检测;在测试过程中,RPN还要输出1000个建议框(proposal)用于后续的操作。毫无疑问,对于COVID-19病变的单类别实例分割而言,同一个实例的测试结果难免会产生好几个冗余的边界框,这也是传统实例分割网络对COVID-19病变部位分割精度不高的原因。其次,RoIAlign将特征图池化到 14×14 大小(检测部分池化到 7×7),导致了大量的信息损失。相比实例分割,目前的语义分割方法在解码器部分采用特征互补方法,能够有效应对编码器提取特征过程中造成的信息丢失等问题,因此语义分割相比实例分割具有更高的分割精度。为了解决实例分割方法存在的问题,弥补其不足,本文提出了一种融合实例分割与语义分割的方法。

目前改善实例分割精度的方法主要集中在两个方面:1)通过改进FPN,提升网络多尺度目标的检测能力^[20-22];2)采用级联的方法对检测框进行逐级优化^[23]或者在掩码分支中引入语义信息来进行特征互补^[24],提升检测精度和分割精度。然而上述方法都比较复杂,且对平均精度提升的作用不大。若能对语义分割结果中的掩码实例进行单独的病变预测和边界框提取,并将其作为实例分割输出,能直接将实例分割的精度提升到语义分割的水平。

Python中有很多图像处理工具库,其中Skimage中的label函数可以实现连通区域标记,将像素值相同且符合4连通域或者8连通域的相邻像素进行标记,并归为一类。regionprops函数可以测量出所标记图像区域的属性,包括连通域的面积、外接矩形、连通域的质心等。实例分割与语义分割融合的关键在于如何对语义分割结果中的掩码实例进行单独的病变预测和边界框提取,如图2中红色矩形框内所示。首先将语义分割结果进行二值化处理,大于0的像素全部置为1,小于0的像素值全部置为0;用Skimage中的label函数实现连通区域标记。其次用Skimage中的regionprops函数提取各个连通域的矩形边界框。然后将边界框映射到主干+ASPP提取的特征图上,经RoIAlign池化后输入检测分支,预测每个连通域为病变的概率。最后,将边界框及连通域为病变的概率值映射到语义分割结果上,得到最终的实例分割结果。

与普通的语义分割网络相比,AIS-Net 相当于增加了一个预测病变掩码类别分数的操作,而网络总体上依然采用了

Mask-RCNN^[18]的结构。边界框及病变概率映射到连通域上的方法可以参考 Mask-RCNN 中实例分割结果的输出方法。

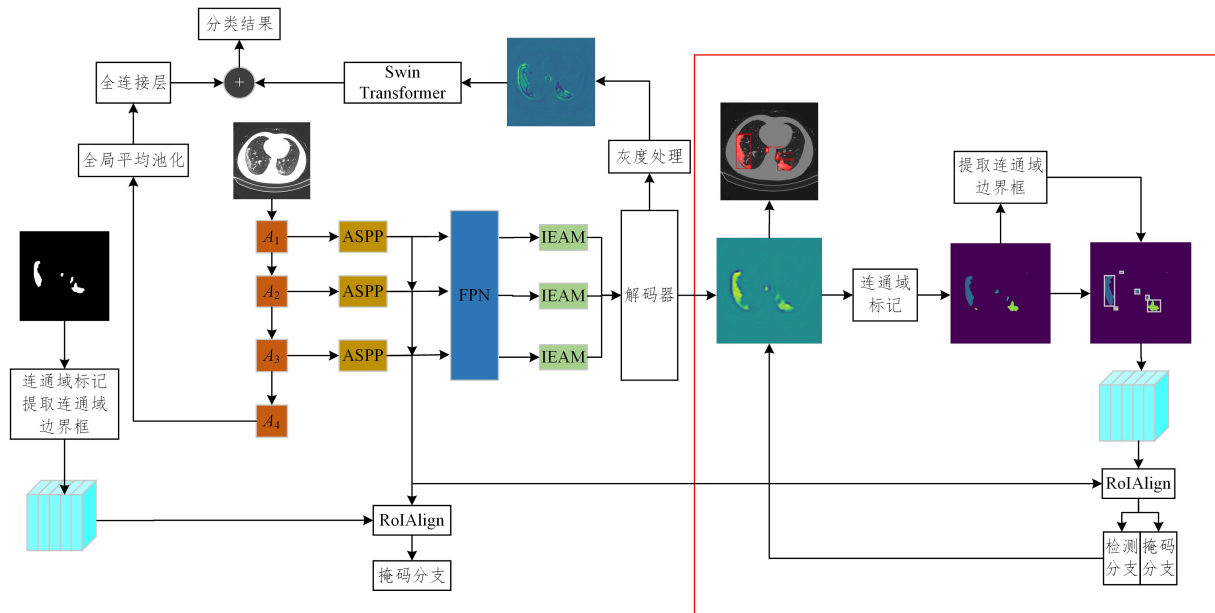


图 2 AIS-Net 的整体架构(电子版为彩图)

Fig. 2 Overall architecture of AIS-Net

1.2 信息增强注意力模块

AIS-Net 的性能主要依赖于语义分割结果的好坏,然而由于网络的结构比较复杂,为了减少计算参数,解码器的设计并不能采用 U-Net^[25]的结构。为了保证分割结果的精度,本文设计了一个信息增强注意力模块,以提升解码器部分输入特征图中关键信息的权重。在对不同层级的特征图进行融合的过程中,根据前景与前景相乘为前景、前景与背景相乘为背景的原则,相乘能让特征图中相同的特征得到加强,不同的特征处得到抑制。本文提出的信息增强注意力模块如图 3 所示。

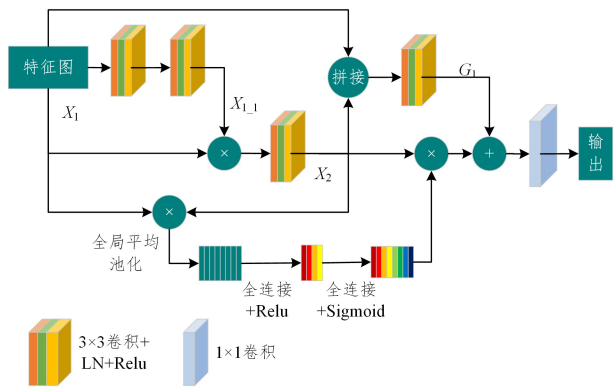


图 3 信息增强注意力模块

Fig. 3 Information enhancement attention module

为了增加关键信息的权重,特征图 X_1 首先经过两次 3×3 的卷积提取关键信息得到 $X_{1,1}$; 然后 $X_{1,1}$ 与原特征图 X_1 相乘,对 X_1 中的关键信息进行增强,经 3×3 卷积后得到特征图 X_2 。为了减少相乘过程对有用信息的抑制,将 X_1, X_2 在维度上进行拼接,经 1 个 3×3 卷积降维后得到全局信息 G_1 ; 同时,为了对特征图在通道维度上进行加权处理,以进一步提升关键通道的权重,将 X_1 与 X_2 相乘,然后接一个自适应平均池化层将尺度降到 1×1 ,之后接上两个全连接层,再用 *sigmoid* 函数激活后与特征图 X_2 相乘,形成通道上的注意,最后与全局信息 G_1 相加,实现全局信息互补。为了防止出现过拟合,

在每个 3×3 的卷积层后都接一个层归一化(Layer Normalization, LN)和 ReLu 激活层。

1.3 解码器

解码器部分同样遵循相乘能让特征图中相同特征处的信息得到加强的想法,通过增强关键信息的权重,在保证计算参数较少的情况下,也具有较高的分割精度。

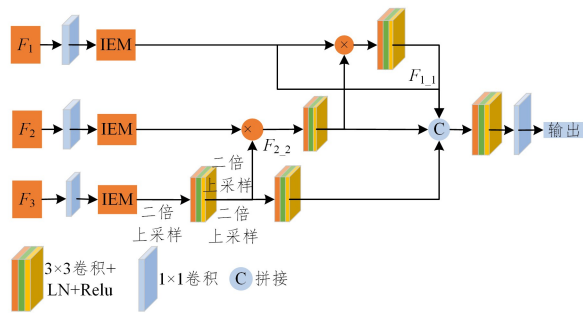


图 4 解码器

Fig. 4 Decoder

如图 4 所示,首先对 ResNext50 + FPN 输出的特征图 F_1, F_2, F_3 用 1×1 的卷积降到 32 维,输入 IEAM 进行信息增强;然后将 F_3 进行二倍上采样后与 F_2 相乘得到 $F_{2,2}$; 之后又将 $F_{2,2}$ 二倍上采样后与 F_1 相乘得到 $F_{1,1}$; 每一次上采样后都通过 3×3 的卷积消除重叠。最后将 $F_1, F_{1,1}, F_{2,2}, F_3$ 经双线性插值统一到同一尺度后,在维度上进行拼接,弥补相乘过程中丢失的信息。与 IEAM 中一样,为了防止出现过拟合,每个 3×3 卷积后都接一个 LN 归一化层和 ReLu 激活层。

1.4 实例分割式的监督

如图 2 中最左边所示,本文将分割标签标定好的边界框映射到主干 + ASPP 提取的特征图上,经 RoIAlign 池化后输入掩码分支,以对语义分割部分以实例分割的方法进行监督。分割标签标定好的边界框为该幅图像中真实病变的边界框,通过这样的监督方式,能够提升整个网络对病变区域的定位能力,并且可以对各个尺度的病变进行有效的把控。

1.5 语义分割结果灰度差处理

目前已有许多方法在语义分割网络中增加分类模块来提升对病变的识别精度,并证明了该方法是有效的。但是对于普通肺炎与新冠肺炎来说,如图 5 所示,将两者分割以后,网络同样能将普通肺炎的病变分割出来,这给新冠肺炎、普通肺炎和非肺炎的 3 分类造成了极大的阻碍。COVIDNet-CT^[26] 采用了大规模数据集(62 045 幅图像)驱动,实现了 97.30% 的新冠识别灵敏度,但是如此多图像的训练成本是极大的。在对语义分割结果采用 Sigmoid 函数保留分割区域之前,由于分割部分的训练只采用了新冠肺炎数据集,分割结果中新冠肺炎病变部位与背景之间的灰度差比普通肺炎的大得多,因此通过减小病变与背景之间的灰度差,能够在普通肺炎的分割结果中引入肺部周围的一些噪声。本文采用伽马变换来对语义分割输出进行灰度变换,减少前景与背景之间的灰度差;由图 5 所示的灰度处理结果可以看到,普通肺炎的分割结果中引入了大量的噪声,而新冠肺炎分割结果中的噪声较少,这对普通肺炎与新冠肺炎的区分是很有用的。




图 5 语义分割结果灰度差处理

Fig. 5 Grayscale difference processing of semantic segmentation results

1.6 Swin Transformer 网络

基于自注意力的架构 Transformer 已成为自然语言处理(NLP)中的首选模型。受到 NLP 的成功启发,许多方法将自注意力替代卷积应用于计算机视觉领域。Vision Transformer^[27] 通过将图像拆分为块(patch),类似于 NLP 应用中的标记(tokens),并将这些图像块的线性嵌入序列作为 Transformer 的输入,并以有监督方式训练图像分类模型,在大规模的数据集上取得了当时最先进的分类精度。与 Vision Transformer 不同,Swin Transformer 使用了类似卷积神经网络中的层次化构建方法。如图 6 所示,Swin Transformer 与 ResNet 一样,在提取特征的过程中也经历了 2 倍、4 倍、8 倍、16 倍的下采样,输出 4 层不同尺度的特征图;其次,在 Swin Transformer 模块中提出了窗口多头自注意力(Windows Multi Head Self Attention, W-MSA)的概念,通过将特征图划分成多个不相交的窗口,然后多头自注意力(Multi Head Self Attention, MSA)只在每个窗口内进行,能够减少大量的计算参数。Transformer 能够利用注意力的方式来捕获全局的上下文信息,提取出更强的特征,因此本文的分类模块中采用 Swin-Transformer 来对灰度变换处理后的语义分割结果进行新冠肺炎、普通肺炎、非肺炎的 3 分类。

1.7 分类模块的设计

AIS-Net 的分类模块由两部分组成,如图 2 所示,第一部分

在主干网络最后一层的输出后连接一个全局平均池化层和全连接层作为主分类头;第二部分将经灰度差处理后的语义分割结果输入 Swin Transformer 作为辅助分类头,用于对主分类的结果进行调整。为了减少计算参数,每一级 Swin Transformer 模块设置的个数都减半,语义分割结果并没有上采样到原图大小,而是 128×128 。

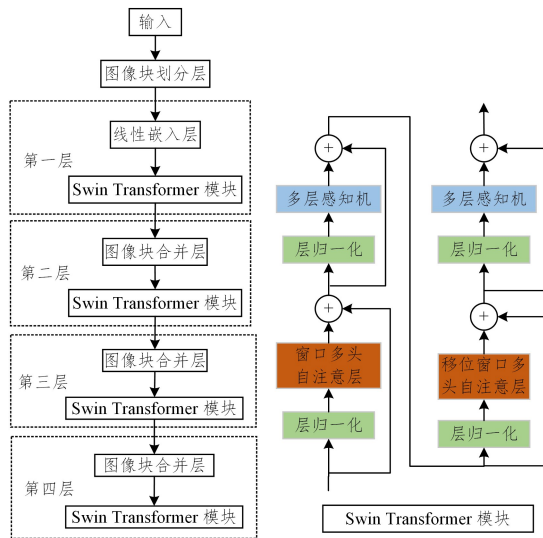


图 6 Swin Transformer

Fig. 6 Swin Transformer

2 实验

2.1 实验设计

2.1.1 数据集

本实验分类部分采用 COVIDX-CT^[26] 数据集,包括 1 489 例患者病例的 104 009 幅胸部 CT 切片。其中训练集 61 756 幅,测试集 21 190 幅,验证集 21 035 幅。分割部分采用中国胸部 CT 图像调查协会(CC-CIIC)^[28] 病变分割数据集,包括 150 例新冠肺炎患者的 21 470 幅 CT 切片,750 幅具有分割标签,标签中的每个像素都是一个从 0 到 3 的 uint8 数字,分别表示背景、肺、磨玻璃阴影和实变。

2.1.2 数据预处理

(1) 分类数据集。从 COVIDX-CT 数据集分配的 61 756 幅训练集图像中随机提取 3 000 幅作为本实验的训练集,其中新冠肺炎、普通肺炎和非肺炎各 1 000 幅。COVIDX-CT 数据集分配的 21 190 幅测试集图像全部作为本实验的测试集。

(2) 分割数据集。根据分割标签的名称,先从 CC-CIIC 的 21 470 幅切片中提取出具有分割标签的 750 幅,然后按照 6.5:1 随机抽取 650 幅作为训练集,100 幅作为测试集。由于 CC-CIIC 数据集的标签图像中存在许多像数值为 0 或和平均像素值极小的图像,为了防止出现类别不平衡问题,将分割标签中的玻璃阴影和实变两种病变区域合并为一种。

(3) 分割标签中病变掩码的边界框标注。分割数据集缺少相应的病变边界框标注,本文首先对分割标签进行二值化;然后采用 Python 中的图像处理工具 Skimage 对其进行连通域标记,并提取每个连通域对应的矩形边界框作为病变掩码的边界框标注。

2.1.3 评估指标

实验评估分为实例分割结果评估、语义分割结果评估、分类结果评估。实例分割结果采用交并比(Intersection Over

Union, IOU) 为 0.5 和 0.75 时的平均精度 (Average Precision, AP) 以及 IOU 为 0.5~0.95 时的平均精度的均值 (Mean Average Precision, mAP) 作为评估指标。语义分割结果采用 Dice 系数、灵敏度 (Sensitivity, SE)、特异度 (Specificity, Sp) 作为评估标准。分类结果采用新冠肺炎、普通肺炎、非肺炎对应的灵敏度、特异度和总体精度 (Overall Accuracy) 作为评估指标。

(1) 平均精度 (AP), 用于衡量网络对某一类目标的平均精度, 计算式如下:

$$AP = \int_0^1 P(R) dR \quad (1)$$

其中, P 和 R 分别代表准确率和召回率, $P(R)$ 代表 $P-R$ 曲线。

(2) Dice 系数, 用于评估预测结果与真实结果的重叠率。

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

其中, TP 表示真阳性, FP 表示假阳性, FN 表示假阴性。

(3) 灵敏度, 也被称为真阳性率、召回率, 用于衡量正确识别真阳性样本的比率。

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

(4) 特异度, 也被称为真阴性率, 用于衡量正确识别真阴性样本的比率。

$$Sp = \frac{TN}{TN + FP} \quad (4)$$

其中, TN 表示真阴性, FP 表示假阳性。

(5) 总体精度, 用于衡量网络在所有测试集上预测正确的个数与总数之间的比值, 计算式为:

$$OAcc = \frac{\sum TP}{\sum TP + \sum FN} = \frac{\sum TP}{\sum TP + \sum FP} \quad (5)$$

2.1.4 损失函数

(1) 本文掩码分支和检测分支中的分类部分均采用二元交叉熵损失函数 (Binary Cross Entropy, BCE)。

$$Loss = -\frac{1}{N} \sum_{i=1}^N [y_i \cdot \log(p(\hat{y}_i)) + (1 - y_i) \cdot \log(1 - p(\hat{y}_i))] \quad (6)$$

其中, \hat{y}_i 为真实的二元标签 0 或者 1, $p(\hat{y}_i)$ 为预测值 \hat{y}_i 属于 y_i 的概率。

(2) 检测分支中的边界框回归参数部分采用 Smooth_L1 损失。

$$S_{L_1}(x) = \begin{cases} 0.5x^2, & \text{if } |x| < 1 \\ |x| - 0.5, & \text{其他} \end{cases} \quad (7)$$

其中, x 代表真实值与预测值的差。

(3) 语义分割部分采用 IOU 损失、二进制交叉熵 (BCE) 损失与 Focal 损失之和。其中, Focal 损失函数的表达式为:

$$L = -((1 - p_i)^\gamma \log(p_i)) \quad (8)$$

$$p_i = \begin{cases} p, & \text{if } y=1 \\ 1 - p, & \text{otherwise} \end{cases}$$

其中, y 为标签, \hat{p} 为预测值, γ 通常取 0.25。

2.1.5 端到端训练方法

与普通网络的训练方法不同, 本文方法需要同时训练分类数据集与分割数据集; 其次, 由于训练的中间环节需要对语义分割结果进行连通域标记与边界框提取, 因此分割部分的 batch size 只能为 1, 然而这对语义分割结果是不利的。为了解决以上问题, 本文提出了一个循环交替的训练方法。如

图 7 所示, 网络首先导入不带边界框标注的分割数据, 只进行语义分割部分的训练, batch size 设置为 4, 学习率为 10^{-4} ; 然后导入带边界框标注的分割数据, 训练整个网络的分割部分, batch size 设置为 1, 学习率为 10^{-5} ; 最后导入分类数据集, 冻结分割部分的权重, 只训练分类部分, batch size 设置为 16, 学习率为 10^{-5} 。像这样循环训练一轮即为一个 epoch, 之后又从语义分割部分开始训练, 进入下一轮循环。由于网络整体的分割效果取决于语义分割部分, 提高 batch size 参数的大小, 对语义分割结果的提升是有帮助的, 因此本文选择了先设置 batch size 为 4 进行语义分割, 在取得了较好语义分割权重的前提下, 再以 batch size 为 1 进行整体的训练, 即保证了语义分割结果的精度, 又能对每个掩码实例为病变的概率进行精准预测。

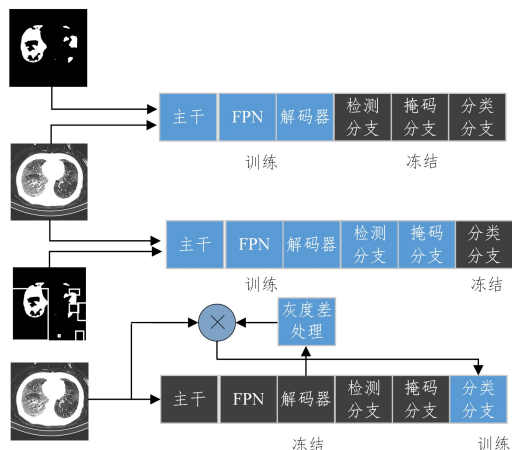


图 7 循环交替的训练方法

Fig. 7 Training method for cyclic alternating

2.2 实验结果分析

实验基于 Pytorch 实现, 并由 RTX3060 GPU 加速, 使用 Adama 优化器进行参数优化, 总共迭代 30 个 epoch。检测分支划分正负样本时, 设置 IOU 值大于 0.5 为正样本, 小于 0.3 为负样本, 正负样本比例为 1:1, 总的样本个数为 56。

2.2.1 实例分割结果

文献[28]首次提出将实例分割技术用于 COVID-19 病变分割的方法, 通过对 Mask-RCNN 网络中的超参数进行研究, 在 CC-CII 数据集上实现了 44.68% 的平均精度; 文献[29]将 Mask R-CNN 网络用于 COVID-19 病变实例分割, 并探讨了 FPN 中各层输出的特征图对分割精度的影响, 提出了轻量化的实例分割网络。以上两种方法是目前仅有的用于 COVID-19 病变单实例分割的网络。由于数据集的分割标签中存在部分不含任何病变的图像, 因此本文在评估时与文献[28]中一样, 当图像不含病变, 且网络没有分割出病变时, 平均精度设置为 1; 当图像含有病变, 但网络没有分割病变时, 平均精度设置为 0。定量结果如表 1 所列。AIS-Net 在 IOU 值为 0.5~0.95 时的平均精度均值 (mAP) 比目前最好的网络提升了 11.77%; IOU 值为 0.5 时的平均精度 (AP) 提升了 16.30%; IOU 值为 0.75 时的平均精度 (AP) 提升了 12.62%。虽然可比较的方法很少, 但是可以看出, 本文方法在各个指标上的提升是非常明显的, 均提升了 10% 以上。与传统的双阶段实例分割网络不同, AIS-Net 的性能主要由语义分割的精度决定, 因此在检测框的提取以及分割的精度方面都比传统的实例分割方法更精确。

表 1 实例分割网络的平均精度指标对比

Table 1 Comparison of average precision indicators of instance segmentation networks

网络	AP@ 0.5IoU	AP@ 0.75IoU	mAP@ [0.5:0.95]
文献[28]	0.6192	0.4522	0.4468
文献[29]	0.5988	0.4506	0.4476
AIS-Net	0.7822	0.5784	0.5653

由于本文采用了循环交替的训练方法,在语义分割部分有较大的 batch size,而表 1 对比的方法中 batch size 都为 1,因此本文取消循环交替的训练方法,做了进一步的对比实验,结果如表 2 所列。

表 2 实例分割网络的平均精度指标对比

Table 2 Comparison of average precision indicators of instance segmentation networks

网络	AP@ 0.5IoU	AP@ 0.75IoU	mAP@ [0.5:0.95]
文献[28]	0.6192	0.4522	0.4468
文献[29]	0.5988	0.4506	0.4476
AIS-Net	0.7913	0.5549	0.5271

AIS-Net 在没有采用循环交替的训练方法时,AP0.5, AP0.75, mAP 分别达到了 79.13%, 55.49%, 52.71%, 比目前最好的网络分别提升了 17.21%, 10.27%, 8.03%。需要说明的是,虽然本文方法仅与现有的两种基于 Mask-RCNN 的方法进行比较,但是即使是目前很先进的实例分割网络,平均精度均值(mAP)对比 Mask-RCNN 网络也很难提升 10% 以上。因此,本文提出的将实例分割技术与语义分割技术融合的方法对实例分割精度的提升具有明显效果, AIS-Net 也是目前第一个将实例分割技术与语义分割技术融合的网络。

2.2.2 语义分割结果

语义分割方法已被广泛应用于医学图像分割领域。传统的实例分割方法由于 RoIAlign 池化会造成大量信息的丢失,

且在掩码分支无法进行有效的特征互补,因此在分割精度方面无法与先进的语义分割方法相比。AIS-Net 中将语义分割方法与实例分割方法进行了融合,为了进一步验证该方法的有效性,本文将实例分割结果按照语义分割结果的形式进行了输出,并与目前先进的几种语义分割方法进行了对比。表 3 所提到的网络中, Pra-Net^[30], PF-Net^[31], HarDNet-MSEG^[32], F3-Net^[33] 都是目前语义分割领域较为先进的网络,并且它们都对小目标的分割问题提出了各自的解决方法。如图 1 所示, COVID-19 病变不仅形状复杂、尺度多变,而且数据集中存在很多切片病变区域极小的情况,这很容易造成类别不平衡问题。因此,本文选择以上几个在小目标分割方面都比较先进的网络进行了对比实验。从表中数据可以看到, AIS-Net 的 Dice 系数、灵敏度、特异度分别为 80%, 85.1%, 99.3%, 均超过了其余的网络;以 Dice 系数作为主要的性能指标时, AIS-Net 较排名第二的 HarDNet-MSEG 分别提升了 4.7%, 3.7%, 1.2%。Dice 系数与灵敏度的明显提升,证明了 AIS-Net 可以达到先进语义分割网络的水平,在相同分割精度的前提下,既能对分割区域为病变的概率进行预测,又能输出分割区域的检测框,这对新冠患者的诊断和治疗都是更有意义的。

表 3 语义分割网络在 CC-C2II 数据集上的指标对比

Table 3 Indicators comparison of semantic segmentation networks on CC-C2II dataset

网络	Dice 系数	灵敏度	特异度
Pra-Net	0.670	0.648	0.955
PF-Net	0.699	0.704	0.964
F3-Net	0.748	0.759	0.993
HarDNet-MSEG	0.753	0.814	0.981
AIS-Net	0.800	0.851	0.993

2.2.3 定性结果分析

为了进行更进一步的验证,本文做了定性结果分析,结果如图 8 所示。




图 8 定性结果

Fig. 8 Qualitative results

本文对表 3 所列的网络都进行了可视化结果输出,其中图 8(e)和图 8(f)分别代表 AIS-Net 不带边界框和带边界框及分类分数的输出。从图中可以看出,AIS-Net 不仅对小病变区域都进行了完整的分割,而且分割精度更高,效果更好;相比其他网络,错误分割、漏分割的情况更少。

2.2.4 分割消融实验

为了验证本文提出的实例分割式的监督方法、信息增强模块、循环交替训练方法的有效性,本文做了消融实验,分别对以上 3 种方法进行了验证。如表 4 所列,对比不采用循环交替的训练方法,Dice 系数、灵敏度、特异度、AP0.5, AP0.75, mAP 分别提升了 1.8%,6.4%,0.1%, -0.91%,5.13%,

1.04%,说明 AIS-Net 虽然用于实例分割,但是网络的性能取决于语义分割,通过对解码器部分进行改进以及按照语义分割网络的超参数进行调整,对提升网络的实例分割水平具有很大的作用。实例分割式的监督方式与信息增强注意力模块在灵敏度方面分别比不采用时提升了 1.8%,2.6%,前者通过引入分割标签的边界框标注,提升了网络对各尺度病变的注意;后者通过增加关键信息的权重,尽可能让病变区域分割更精确;结合两种方法后,Dice 系数、灵敏度、特异度、AP0.5、AP0.75、mAP 分别提升了 1.5%,2.1%,0.1%,3.22%,2.87%,2.82%,证明这两种方法对提升网络的分割能力是有效的。

表 4 分割部分消融实验的各个指标对比

Table 4 Comparison of indicators in segmentation section of ablation experiments

监督	IEM	循环训练	Dice 系数	灵敏度	特异度	AP@0.5IoU	AP@0.75IoU	mAP@[0.5:0.95]
✓	✓	✓	0.8000	0.8510	0.9930	0.7822	0.5784	0.5653
✓	✓		0.7820	0.7870	0.9920	0.7913	0.5271	0.5549
	✓	✓	0.7860	0.8480	0.9920	0.7699	0.5564	0.5369
✓		✓	0.7700	0.8560	0.9910	0.7552	0.5661	0.5371
		✓	0.7850	0.8300	0.9920	0.7500	0.5497	0.5371

2.2.5 分类结果

由于 AIS-Net 是一个包含分类、检测和分割的 COVID-19 辅助诊断网络,因此分类性能是至关重要的。为了进行充分的验证,本文以新冠肺炎、普通肺炎、非肺炎 3 个类别对应的灵敏度、特异度,以及总体的准确率作为评估指标,与目前较为先进的 3 分类方法进行了实验对比。COVID-CT-Mask-Net^[34]将 Mask-R-CNN 网络中带分数的预测边界框用于新冠肺炎、普通肺炎和非肺炎的分类。One Shot Model^[35]通过提前训练 Mask-RCNN 来定位和检测图像中实变和磨玻璃阴影两种病变,然后对这些感兴趣区域进行融合,最后训练这些感兴趣区域用于对图像进行分类;One Shot Model+LSTM+Attention^[36]通过提取一系列包含类别相关信息的感兴趣区域,并应用两个长短期记忆网络来关注该序列以提取类别相关特征。COVIDNet-CT 采用了 62045 幅图像对网络进行训练。ResNext、DenseNet 为目前主流的分类网络,分类结果如表 5 所列,AIS-Net 新冠识别灵敏度为 0.9754,达到了目前最先进的水平,较 COVIDNet-CT 提升了 0.24%,而 AIS-Net 只采用了 3000 幅图像作为训练集,COVID-Net CT 采用了 62045 幅。除了 COVIDNet-CT,在其余均采用 3000 幅图像作为训练集的网络中,AIS-Net 普通肺炎与非肺炎的灵敏度

均优于其他网络。需要注意的是,分类部分的效果与分割部分的性能并没有关系,而是取决于分类模块,因此这里并没有对分割部分的性能与分类结果的关系进行探讨。

2.2.6 分类消融实验

为了验证分类模块的有效性,这里分别对 ResNext50、Swin Transformer、主分类头、主分类头+辅助分类头进行了消融实验。从表 6 中可以看出,将主干最后一层输出的特征图用于分类时,相比单纯使用 ResNext50,新冠肺炎的灵敏度提升了 1.13%,特异度提升了 13.19%,总体准确度提升了 8.35%。相比单纯地使用 Swin Transformer 来进行分类,AIS-Net 各个指标也有不同程度的提升,其中新冠肺炎的灵敏度提升了 1.34%,总体准确度提升了 1.34%。增加辅助分类头时,新冠肺炎的灵敏度提升了 1.02%,总体准确度提升了 0.41%。通过表 5、表 6 发现,大部分网络新冠肺炎的灵敏度都比普通肺炎的差,这也证明了新冠肺炎与普通肺炎的区分难度较大,而增加了辅助分类头以后,AIS-Net 在新冠肺炎的灵敏度达到了最高,对于新冠患者的诊断来说,灵敏度是一个特别重要的指标,这也证明本文分类头的设计方法,以及通过对语义分割结果进行灰度差处理来进一步区分新冠肺炎与普通肺炎的方法是有效的。

表 5 分类网络的指标对比

Table 5 Comparison of indicators for classification networks

网络	COVID-19		普通肺炎		非肺炎		总体精度
	灵敏度	特异度	灵敏度	特异度	灵敏度	特异度	
AIS-Net	0.9754	0.9680	0.9738	0.9839	0.9980	0.9980	0.9907
COVID-CT-Mask-Net ^[34]	0.9268	—	0.9669	—	0.9774	—	0.9663
One Shot Model ^[35]	0.9335	—	0.9556	—	0.9563	—	0.9510
One Shot Model+LSTM+Attention ^[36]	0.9574	—	0.9813	—	0.9927	—	0.9815
ResNext101 ^[36]	0.9158	—	0.9213	—	0.9402	—	0.9286
DenseNet121 ^[36]	0.8264	—	0.9616	—	0.9898	—	0.9669
DenseNet169 ^[36]	0.8937	—	0.9678	—	0.9812	—	0.9586
COVIDNet-CT ^[26]	0.9730	—	0.9900	—	1	—	—

表 6 分类部分消融实验各个指标的对比

Table 6 Comparison of indicators in classification section of ablation experiments

网络	COVID-19		普通肺炎		非肺炎		总体精度
	灵敏度	特异度	灵敏度	特异度	灵敏度	特异度	
ResNext50	0.9539	0.8333	0.8800	0.8907	0.9968	0.9553	0.9031
Swin-Transformer	0.9620	0.9794	0.9632	0.9747	0.9952	0.9782	0.9773
主分类头	0.9652	0.9652	0.9918	0.9706	0.9924	0.9946	0.9866
主分类头+辅助分类头	0.9754	0.9680	0.9738	0.9839	0.9980	0.9980	0.9907

2.2.7 讨论

AIS-Net 的目标并不是让网络的分割精度达到目前最先进的水平,而是为了证明文中所提出的对传统实例分割网络的改进方法,能让实例分割达到先进语义分割网络的精度,因此实验分析部分并没有采用其他的分割数据集进行进一步的验证。为了进一步分析 AIS-NET 的分割能力,这里采用 COVID-19 infection segmentation dataset 数据集^[37]对其进行实验与讨论,该数据集包括 10 例新冠肺炎患者的 829 幅切片,350 幅具有分割标签;按 4:1 随机抽取 280 幅作为训练集,70 幅作为测试集。结果如表 7 所列,同样与 Pra-Net, PF-Net, HarDNet-MSEG, F3-Net 这 4 个网络进行对比;可以看出,HarDNet-MSEG 在 CC-CCII 数据集上取得了第二的效果,但在 COVID-19 infection segmentation dataset 数据集上,PF-Net 的表现更好;AIS-Net 在 Dice 系数方面比排名第一的降低了 0.9%,特异度比排名第一的降低了 0.2%,基本上达到了比较先进的水平。在灵敏度方面,AIS-Net 的表现依然是最好的,达到了 86.6%,较第二名提升了 6.5%。结合表 3 和表 7 中的实验结果可以得出,AIS-Net 能够达到先进语义分割网络的水平,并且在灵敏度方面具有更大的优势。它可以作为一个基线网络用在单实例分割领域,通过对主干以及解码器的研究来提升其分割性能。

表 7 语义分割网络在 COVID-19 infection segmentation dataset 数据集上的指标对比

Table 7 Comparison of indicators for semantic segmentation networks on COVID-19 infection segmentation dataset

网络	Dice 系数	灵敏度	特异度
Pra-Net	0.713	0.752	0.981
PF-Net	0.785	0.801	0.993
F3-Net	0.759	0.776	0.978
HarDNet-MSEG	0.782	0.796	0.993
AIS-Net	0.776	0.866	0.991

结束语 当前新型冠状病毒肺炎(COVID-19)疫情在全球的漫延依然很严重,利用深度学习的方法对 COVID-19 患者肺部 CT 图像中的病变区域进行自动分割、检测和识别,对帮助医生快速准确地诊断 COVID-19 患者具有重要意义。为了提升传统实例分割网络对 COVID-19 病变区域的分割能力,本文提出了一个融合实例分割与语义分割的方法,让实例分割达到了先进语义分割的水平。针对新冠肺炎、普通肺炎和非肺炎的 3 分类问题,提出了一个进一步区分新冠肺炎与普通肺炎的方法,并引入 Swin-Transformer 网络用于分类。最后提出了一种循环交替的训练方法,让网络能够同时对分割、检测和分类进行端到端训练。

AIS-Net 作为一个可以同时进行分割、检测和分类的端到端网络,在 3 个方面都取得了比较先进的效果,在以后的研究工作中可以将其作为一个基线网络来展开研究,对编码器、解码器、检测分支、分类模块等方面进行改进来提升网络的

性能。目前,AIS-Net 也是第一个采用此结构的网络,而不是其他方法的改进。

参考文献

- [1] LU R,ZHAO X,LI J, et al. Genomic characterisation and epidemiology of 2019 novel coronavirus: implications for virus origins and receptor binding[J]. The lancet, 2020, 395(10224): 565-574.
- [2] WANG W, XU Y, GAO R, et al. Detection of SARS-CoV-2 in different types of clinical specimens[J]. Jama, 2020, 323(18): 1843-1844.
- [3] HUANG Z, ZHAO S, LI Z, et al. The battle against coronavirus disease 2019(COVID-19): emergency management and infection control in a radiology department[J]. Journal of the American College of Radiology, 2020, 17(6): 710-716.
- [4] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv: 1409. 1556, 2014.
- [5] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2015: 1-9.
- [6] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [7] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2017: 4700-4708.
- [8] SABOUR S, FROST N, HINTON G E. Dynamic routing between capsules[C]// Advances in Neural Information Processing Systems. 2017: 3859-3869.
- [9] TAN M, LE Q. Efficientnet: Rethinking model scaling for convolutional neural networks[C]// International Conference on Machine Learning. PMLR, 2019: 6105-6114.
- [10] DAS A K, KALAM S, KUMAR C, et al. TLCoV-An automated Covid-19 screening model using Transfer Learning from chest X-ray images[J]. Chaos, Solitons & Fractals, 2021, 144: 110713.
- [11] WANG S H, FERNANDES S, ZHU Z, et al. AVNC: attention-based VGG-style network for COVID-19 diagnosis by CBAM[J]. IEEE Sensors Journal, 2021, 22(18): 17431-17438.
- [12] FU J, ZHENG H, MEI T. Look closer to see better: Recurrent attention convolutional neural network for fine-grained image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 4438-4446.
- [13] WANG S H, GOVINDARAJ V V, GÓRRIZ J M, et al. Covid-19 classification by FGCNet with deep feature fusion from graph convolutional network and convolutional neural network[J]. Information Fusion, 2021, 67: 208-229.

- [14] ELHARROUSS O, SUBRAMANIAN N, AL-MAADEED S. An encoder-decoder-based method for segmentation of COVID-19 lung infection in CT images[J]. *SN Computer Science*, 2022, 3(1):1-12.
- [15] XIE S, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017:1492-1500.
- [16] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 40(4):834-848.
- [17] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017: 2117-2125.
- [18] HE K, GKIOXARI G, DOLLÁR P, et al. Mask r-cnn[C]// *Proceedings of the IEEE international conference on computer vision*. 2017:2961-2969.
- [19] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2021: 10012-10022.
- [20] PANG J, CHEN K, SHI J, et al. Libra r-cnn: Towards balanced learning for object detection[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019: 821-830.
- [21] GHIASI G, LIN T Y, LE Q V. Nas-fpn: Learning scalable feature pyramid architecture for object detection[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019:7036-7045.
- [22] XIANG W, MAO H, ATHITSOS V. ThunderNet: A turbo unified network for real-time semantic segmentation[C]// *2019 IEEE winter Conference on Applications of Computer Vision (WACV)*. IEEE, 2019:1789-1796.
- [23] CHEN K, PANG J, WANG J, et al. Hybrid task cascade for instance segmentation[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019: 4974-4983.
- [24] ZHANG G, LU X, TAN J, et al. Refinemask: Towards high-quality instance segmentation with fine-grained features[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021:6861-6869.
- [25] 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.
- [26] GUNRAJ H, WANG L, WONG A. COVIDNet-CT: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases From Chest CT Images[J]. *Front Med(Lausanne)*, 2020, 7:608525-608525.
- [27] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale[C]// *International Conference on Learning Representations*. 2020.
- [28] TER-SARKISOV A. Detection and Segmentation of Lesion Areas in Chest CT Scans For The Prediction of COVID-19[J]. *Science in Information and Technology Letters*, 2021, 1(2): 92-99.
- [29] TER-SARKISOV A. Lightweight Model for the Prediction of COVID-19 Through the Detection and Segmentation of Lesions in Chest CT Scans[J]. *International Journal of Automation, Artificial Intelligence and Machine Learning*, 2021, 2(1):1-15.
- [30] FAN D P, JI G P, ZHOU T, et al. Pranet: Parallel reverse attention network for polyp segmentation[C]// *International Conference on Medical Image Computing and Computer-assisted Intervention*. Cham: Springer, 2020:263-273.
- [31] MEI H, JI G P, WEI Z, et al. Camouflaged object segmentation with distraction mining[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021: 8772-8781.
- [32] HUANG C H, WU H Y, LIN Y L. Hardnet-mseg: a simple encoder-decoder polyp segmentation neural network that achieves over 0.9 mean dice and 86 fps[J]. *arXiv:2101.07172*, 2021.
- [33] WEI J, WANG S, HUANG Q. F³Net: fusion, feedback and focus for salient object detection[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. 2020:12321-12328.
- [34] TER-SARKISOV A. Covid-ct-mask-net: Prediction of covid-19 from ct scans using regional features[J]. *Applied Intelligence*, 2022, 52(9):9664-9675.
- [35] TER-SARKISOV A. One Shot Model for the Prediction of COVID-19 And Lesions Segmentation In Chest CT Scans Through The Affinity Among Lesion Mask Features[J]. *Applied Soft Computing*, 2021, 116:108261-108261.
- [36] TER-SARKISOV A. One Shot Model For COVID-19 Classification and Lesions Segmentation In Chest CT Scans Using LSTM With Attention Mechanism[J]. *IEEE Intelligent Systems*, 2022, 37(3):54-64.
- [37] FAN D P, ZHOU T, JI G P, et al. Inf-net: Automatic covid-19 lung infection segmentation from ct images[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(8):2626-2637.



BAI Zhengyao, born in 1967, Ph.D, professor, master supervisor. His main research interests include signal processing, image processing, pattern recognition and machine learning.