A CT Image Brain Hemorrhage Segmentation Model Based on Encoder-Decoder Architecture

GU Junhong[1], XU Xiaojian[2], ZHANG Min[1], MAO Heming[3], LI Hong[1*]
(1.School of Automation, Hangzhou Dianzi university, Hangzhou Zhejiang 310018, China;
2.Department of Radiology, Yuyao City Traditional Chinese Medicine Hospital, Yuyao Zhejiang 315400, China;
3.Yuyao City Hemudu Town Government, Yuyao Zhejiang 315400, China)

Abstract: The issue of blurry edges in the hemorrhagic area and confusion between cerebral calcification spots and hemorrhagic areas in CT images of cerebral hemorrhage, which makes accurate segmentation challenging, is addressed by designing a CT image cerebral hemorrhage segmentation model based on an encoder-decoder architecture. The model consists of a feature extraction module, a multi-scale subtraction module, and a reverse attention module. A feature extraction module is used to extract multi-level features from the image, with shallow feature maps being discarded, and the remaining feature maps are then input into a multi-scale subtraction module for feature processing and fusion. The fused feature maps are subsequently fed into a reverse attention module for segmentation. The segmentation results are output after decoding through an upsampling layer. A Dice coefficient of 0.837 8, an average intersection-over-union (MIoU) of 0.778 9, and an accuracy rate of 99.92% are achieved on the CT image cerebral hemorrhage dataset by the model. Both the Dice coefficient and the MIoU are found to be superior to those of the comparison models. Experimental results demonstrate that the model can accurately segment the cerebral hemorrhage area, aiding in rapid diagnosis by doctors and enabling patients to receive treatment more quickly.

Key words: deep learning; cerebral hemorrhage image segmentation; encoder-decoder architecture; reverse attention
EEACC: 7510 **doi**: 10.3969/j.issn.1004-1699.2026.09.020

一种基于编码器-解码器架构的 CT 图像脑出血分割模型

顾骏鸿[1], 徐晓剑[2], 张 明[1], 毛荷明[3], 李 宏[1*]
(1.杭州电子科技大学自动化学院, 浙江 杭州 310018; 2.余姚市中医医院放射科, 浙江 余姚 315400;
3.河姆渡镇政府, 浙江 余姚 315400)

摘 要: 为了解决由于脑出血 CT 图像出血区域边缘模糊, 脑部钙化斑块和出血区域混淆导致脑出血分割模型难以准确分割脑出血区域的问题, 设计了一种基于编码器-解码器架构的 CT 图像脑出血分割模型, 该模型由特征提取模块、多尺度减法模块、反向注意力模块构成, 其中特征提取模块提取图像多层次特征后舍弃浅层特征图后将特征图输入多尺度减法模块进行特征处理和融合, 融合之后的特征图输入反向注意力模块进行分割, 最终通过上采样层解码后输出分割结果图。本模型在 CT 图像脑出血数据集上的 Dice 系数为 0.837 8, 平均交并比为 0.778 9, 准确率为 99.92%。Dice 系数和平均交并比均优于对比模型。实验结果表明: 本模型实现了脑出血区域的准确分割, 能帮助医生快速诊断, 使患者更快地得到救治。

关键词: 深度学习; 脑出血图像分割; 编码器-解码器架构; 反向注意力;
中图分类号: R743.34 **文献标识码**: A **文章编号**: 1004-1699(2026)09-2083-08

脑出血是指由于局部脑血管破裂引起的脑实质内出血, 脑出血一般是由于硬化的小动脉薄弱处的破裂引起[1]; 每年 10 000 人中平均有 2.5 人诊断出脑出血, 大约 44% 的脑出血患者会在一个月内死亡, 临床上一般通过 CT 和 MRI 检查来判断病人是否存在脑出血[2], 判断的准确性、时效性依赖医生的经验, 时常耽误了患者的宝贵治疗时间。

脑出血分割的研究经历了图像处理和深度学习两个阶段: 图像处理方法首先通过预处理步骤去除 CT 图像的伪影以及颅骨[3], 然后使用模糊 C 均值聚类方法[4]、基于区域的活动轮廓方法[4]、加权灰度直方图[5]等方法来检测和分割 CT 图像中的脑出血区域。相比于手动分割方法, 传统的图像处理方法虽然实现了初步的自动分割, 但是在脑出血区域的分割精度方面还有很大的进步空间。

在很多情况下, 在 CT 图像上脑出血区域是不规则的, 传统的图像处理方法很难将脑出血区域完整且细致地分割出来。随着深度学习方法被越来越多地用于图像分割领域, 一些研究者也尝试将深度学习方法应用于脑出血分割任务。Yao 等[6]采用多

收稿日期: 2024-07-12 **修改日期**: 2024-08-27

视角卷积神经网络用于分割急性脑出血 CT 图像，在测试集上的平均 Dice 系数为 0.697，分割效果一般。Nag 等[7]训练了一个自动编码器模型用于检测脑出血区域，识别出出血区域之后用 Chan-Vese 模型进行精细分割。模型分割的准确率为 71%，分割精度仍然较低。

尽管以 CNN 为基础的分割模型在提升分割精度上取得了一定的进展，但是以 CNN 为基础的模型提取图像特征的能力有限。

随着 U-Net[8]模型的提出，深度学习模型提取图像特征的能力得到加强，U-Net 模型采用多层级联的下采样模块来提升提取图像特征的能力，将浅层特征图和深层特征图拼接来保留图像分割中的细节。

Xu 等[9]使用密集连接（DenseNet）替换了 U-Net 模型中下采样模块中原有的卷积池化层，构建了名为 Dense U-Net 的分割模型，虽然相比 U-Net 分割精度有所提高，但是模型参数过多导致训练较为困难，模型稍显臃肿。Qiu 等[10]采用预先训练的 ResNet 模块代替 U-Net 中的下采样模块，预训练的 ResNet 模块可以减少一部分前期模型训练的工作，只需要对模型参数进行微调即可完成模型的训练。但是预训练模型也存在灵活性差，难以捕捉图像上下文信息等问题。Yuan 等[11]引入结合了残差学习和八度卷积（OctConv）的 ResOctConv 模块，以改善 U-Net 中的语义差距问题，虽然改进后的 U-Net 模型的分割准确度高于原始 U-Net 模型，但是该研究仅纳入 40 名患者，样本量较少，说服力不足。

与此同时，许多研究者将影像学知识与深度学习结合，设计了改进的分割模型。例如，Li 等[12]通过将翻转图像与原始 CT 切片拼接，作为 U-Net 模型的输入，利用图像的对称性显著增强了出血区域与正常区域的对比度，该模型对于较大出血区域的分割能力较强，但是难以分辨较小的出血区域。Fang 等[13]则提出了一个结合了注意力和解剖组学特征的模型，对于不规则形状的出血区域有更好的分割效果。Xu 等[14]针对急性脑出血图像高密度、多尺度、位置多变的特点，提出了一种自动分割模型。以上两个模型专注于增强脑出血区域的特征，然而钙化斑块和脑出血区域特征相似，过分增强脑出血区域特征可能导致钙化斑块被误分为脑出血区域。

综合以上的方法我们可以看出：现有的脑出血分割模型主要有两个问题：第一模型特征提取、特征融合的能力还需要提高；第二虽然已有部分模型根据脑出血 CT 图像的特征进行了针对性设计，但总体来说，现有模型在这方面仍有提升空间。脑出血 CT 图像分割的难点主要有两个：第一脑出血区域和正常区域的边缘模糊；第二 CT 图像中脑部钙化斑块和脑出血区域的特征比较相似，在模型分割时容易混淆，将脑部钙化斑块错误分割。根据这两个问题，本文提出了一种基于编码器解码器架构的脑出血分割模型 SRA-Net。

1 数据与方法

1.1 数据来源

笔者和浙江省余姚市中医医院放射科合作，收集了 2021 年 2 月—2022 年 12 月在余姚市中医医院 128 例患有脑出血症状患者的 CT 图像（典型脑出血 CT 图像见图 1），纳入标准：①经过临床确诊患有脑出血症状的患者；②CT 图像资料完整，质量较好。排除标准：CT 图像质量差，无法进行图像分割。共纳入 128 例患者，其中男性 68 例，女性 56 例，年龄范围为 24 岁~94 岁，平均年龄为 66.95 岁。每例患者的 CT 图像序列均由 28 张 CT 图像组成。图像大小为 512×512 像素。此外，还加入了 216 张 RSNA-2019 数据集[15]的图像，RSNA 数据集是北美放射学会提供的脑出血分类数据集。根据收集到的数据制作了脑出血 CT 图像数据集，含有脑出血病灶的图像共计 890 张，其中训练集包含 801 张图像，测试集包含 89 张图像，所有 CT 图像脑出血区域均由放射医生标注完成。

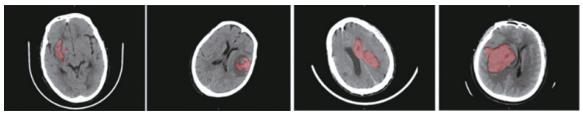

图 1 脑出血 CT 图像

1.2 实验参数设置

本文使用的模型全部基于 Python 语言实现，由 PyTorch 框架搭建。本文使用的实验平台是一台服务器。服务器的 CPU 为 Intel Xeon-4214R，GPU 为 NVIDIA RTX 3080 Ti。本文模型均在此服务器上训练和测试。模型总共训练 50 轮，训练批次设置为 20，学习率为 0.05。

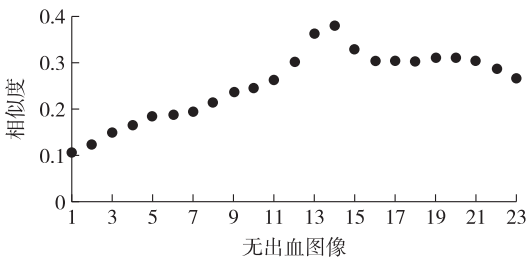

图 2 已标注图像和单个病例中无出血图像相似度

1.3 数据预处理

由于数据集规模较小，训练时可能会导致过拟

合现象发生,所以在训练之前对数据进行增强,数据增强的步骤如下:

①选定一张已标注图像;

②计算已标注图像和所有病例中无出血图像的相似度(相似度统计见图 2),选定每个病例中相似度最高的无出血图像。本文根据互信息[16]衡量二者的相似度,互信息的计算公式为:

$$I(\boldsymbol{X};\boldsymbol{Y})=\sum_{x\in X}\sum_{y\in Y}p(\boldsymbol{x},\boldsymbol{y})\log\frac{p(\boldsymbol{x},\boldsymbol{y})}{p(\boldsymbol{x})p(\boldsymbol{y})} \tag{1}$$

式中:$(\boldsymbol{X};\boldsymbol{Y})$表示两个随机变量,$p(\boldsymbol{x},\boldsymbol{y})$表示随机变量$(\boldsymbol{X};\boldsymbol{Y})$的联合分布,$p(\boldsymbol{x})$、$p(\boldsymbol{y})$是两个随机变量的边缘分布。

③提取已标注图像的出血区域,并且通过随机裁剪的方式生成新的标记,裁剪区域的大小由概率分布决定。

④用原出血区域的像素取代第二张未标记图像中的相应像素。同时新出血区域即是新图像的标记。图 3 展示了数据增强的整体流程,数据增强的计算公式见式(2)~式(5):

$$\mathrm{D}(\boldsymbol{X}_i)=\begin{cases}-d(\boldsymbol{p},\partial\boldsymbol{X}_i) & \boldsymbol{X}_i^p=\boldsymbol{1}\\ d(\boldsymbol{p},\partial\boldsymbol{X}_i) & \boldsymbol{X}_i^p=\boldsymbol{0}\end{cases} \tag{2}$$

$$\boldsymbol{X}_i^p=\begin{cases}1 & D(\boldsymbol{X}_i)\leqslant\lambda\\ 0 & D(\boldsymbol{X}_i)>\lambda\end{cases} \tag{3}$$

$$\lambda\sim\frac{1}{2}U-\frac{1}{2}|D(\boldsymbol{X}_i)_{\min}|,0+\frac{1}{2}U0,|D(\boldsymbol{X}_i)_{\min}| \tag{4}$$

$$\boldsymbol{Y}=\boldsymbol{Y}_i+\boldsymbol{X} \tag{5}$$

式(2)表示计算像素距离 $D(\boldsymbol{X}_i)$,$\partial\boldsymbol{X}_i$ 表示出血区域的边界,$d(\boldsymbol{p},\partial\boldsymbol{X}_i)$表示像素和出血区域边界的距离,$\boldsymbol{X}_i^p$ 表示像素的值,像素距离在边界外为正值,在边界内为负值。式(3)表示将像素距离小于等于阈值 λ 的像素值变为 1。式(4)表示 λ 的值从一个概率分布中抽样,λ 的分布是两个均匀分布的混合分布,$D(\boldsymbol{X}_i)_{\min}$是像素距离的最小值。式(5)表示新出血区域 $\boldsymbol{X}$ 与无出血图像 $\boldsymbol{Y}_i$ 相加得到新图像 $\boldsymbol{Y}$。

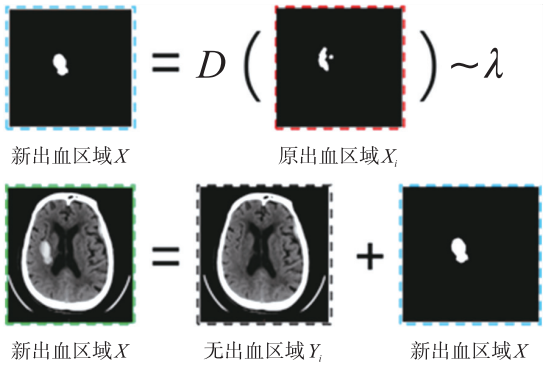

图 3　数据增强整体流程

1.4　模型架构

针对 CT 图像脑出血区域分割问题,设计了基于编码器-解码器架构的减法注意力分割模型 SRA-Net。SRA-Net 的总体架构如图 4 所示。SRA-Net 模型包括特征提取模块、多尺度减法模块、反向注意力模块三个部分:特征提取模块由五层 Block 块串联形成,从第一层到第五层设计通道数分别为 64、256、512、1 024、2 046,通过不同尺度的 Block 块依次提取不同层次的特征;多尺度减法模块由多个减法单元[17]堆叠成的减法金字塔和特征拼接层

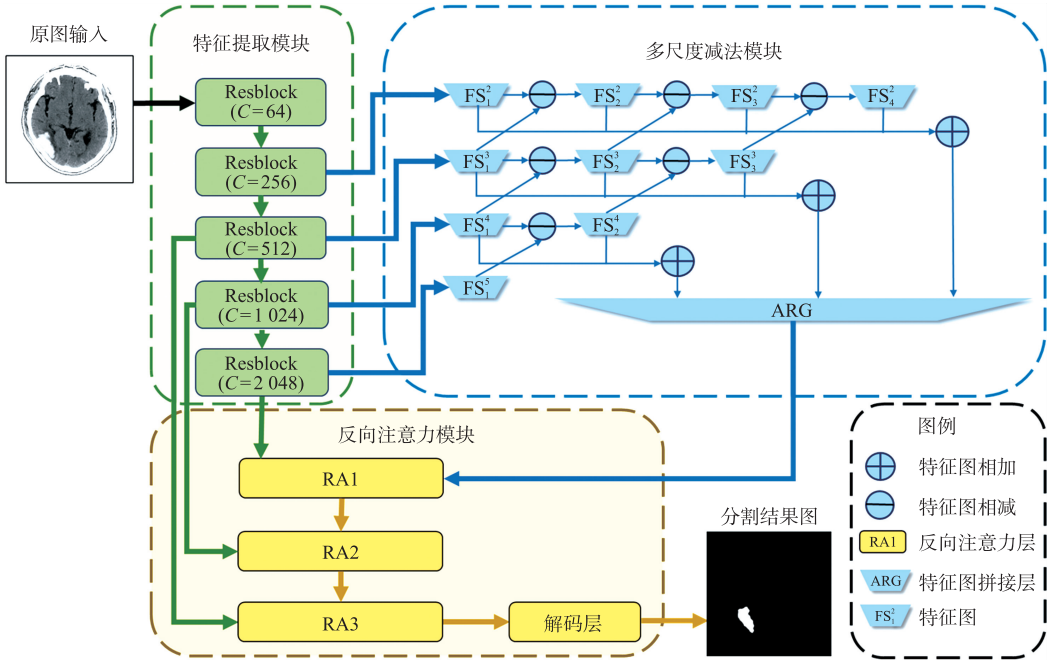

图 4　SR-Net 模型整体架构

(ARG)组成,考虑到现在脑出血分割方法的局限性,通过减法金字塔更好地对不同尺度的特征进行融合,同时抑制钙化斑块的特征,突出脑出血区域的特征,多尺度减法模块输出的特征输入反向注意力模块;反向注意力模块由三层反向注意力层和上采样层组成,特征提取模块提取的特征和多尺度减法模块处理之后的特征输入反向注意力层,进一步地突出分割主体,增强边缘分割效果,最终通过上采样层输出最终分割结果图。

1.4.1 特征提取模块

SRA-Net 中的特征提取模块作用是提取原图中多个层次的特征,本文采用 ResNet[18] 网络中的 Block 块作为构成特征提取模块的基本模块,特征提取模块由五个 Block 块构成:第一个 Block 块主要是由 7×7 卷积层、归一化层、ReLU 激活函数层以及最大池化层组成,主要作用是对输入的图像进行预处理。后续四个 Block 块分别由 3、4、6、3 个 Bottleneck 块组成,Bottleneck 块由两组带有残差连接的 3×3 和 1×1 卷积层和归一化层以及 ReLU 激活函数层组成。

Bottleneck 中的残差连接可以改善模型训练中梯度消失或者梯度爆炸的问题。多个 Block 块串联可以在捕获全局特征的同时不遗漏细节,由于钙化斑块在 CT 图像中很小,一般图像中较小的特征会被提取成为浅层特征,所以在特征处理模块输出特征时将浅层特征丢弃,这样可以减少图像与中钙化斑块相关的特征,防止模型将钙化斑块视为脑出血区域。

1.4.2 多尺度减法模块

多尺度减法模块的结构如图 5 所示。多尺度减法模块的作用是将特征提取模块提取的多尺度特征通过减法模块金子塔进行处理,多尺度特征经过减法模块金字塔处理之后通过 ARG 层进行特征融合,调整不同特征的尺寸并将不同尺度的特征融合成为一组特征输入反向注意力模块。

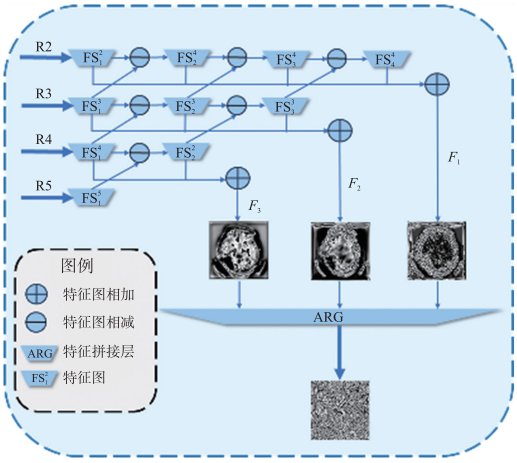

图 5 多尺度减法模块结构图

减法模块金字塔是由多个减法单元堆叠而成,式(6)描述了减法单元的结构:

$$\boldsymbol{F}=\mathrm{Conv}(|\boldsymbol{A}-\boldsymbol{B}|) \tag{6}$$

式中:$\boldsymbol{A}$、$\boldsymbol{B}$ 表示输入的特征图,-表示按元素相减,Conv 表示特征图 $\boldsymbol{A}$、$\boldsymbol{B}$ 按元素相减之后再次输入卷积层获取输出 $\boldsymbol{F}$。式(7)描述了特征图的运算过程,FS_j^{5-i} 和 $\boldsymbol{F}_i$ 表示特征图,Conv 表示卷积层。

$$\boldsymbol{F}_i=\mathrm{Conv}\left(\sum_{j=1}^{5-i}\mathrm{FS}_j^{5-i}\right)\quad i=1,2,3 \tag{7}$$

钙化斑块和出血区域在 CT 图像中均呈现高密度影,二者的区别在于:①通常钙化斑块的 CT 值大于 100,高于脑出血区域;②脑出血区域边缘逐渐过渡到低密度影,钙化斑块一般无过渡;③钙化斑块一般对称分布。

特征图相减既可获取两个特征图之间的互补信息,又可以凸显出两个特征图之间的差异信息,将减法模块在水平和垂直方向上进行串联和堆叠,可以获取跨越多个层次和不同大小感受野的特征信息,从而突出脑出血区域特征,以抑制钙化斑块特征。特征经过减法金字塔处理后,输入 RAG 层进行特征融合。

RAG 层的结构如图 6 所示。RAG 层由三组卷积层构成:每组包括卷积层、归一化层和激活函数层,RAG 层将不同大小的特征图通过卷积层上采样到同一大小,之后将三组特征图拼接为一组特征图并输入到反向注意力模块。图 6 中三组不同尺寸的特征图 F_1、F_2、F_3 输入 RAG 层,首先通过上采样层扩大特征图尺寸,之后通过特征图拼接操作拼接为

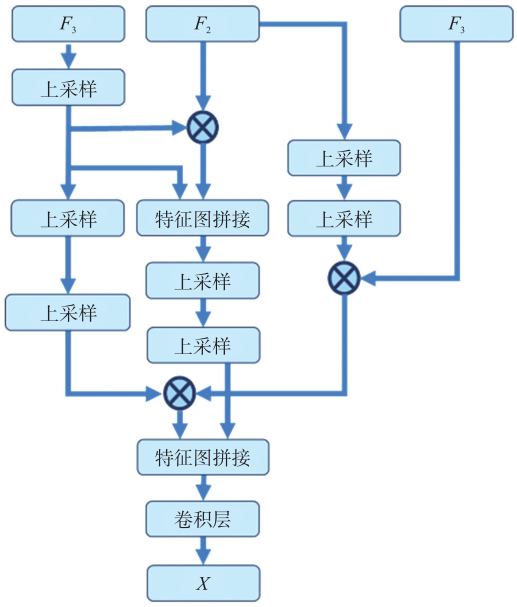

图 6 RAG 层结构图

一组特征图,最后输出到反向注意力模块进行分割。

1.4.3　反向注意力模块

反向注意力模块的结构如图 7 所示。CT 图像中脑出血区域和脑部正常区域之间的边界较为模糊,由于脑出血区域并没有非常清晰的边缘,导致了脑出血分割模型在分割脑出血边缘区域时无法准确判断哪里是正确的边界。为了解决这一问题,本文尝试采用反向注意力模块[19]来提高模型分辨脑出血区域边界的能力。

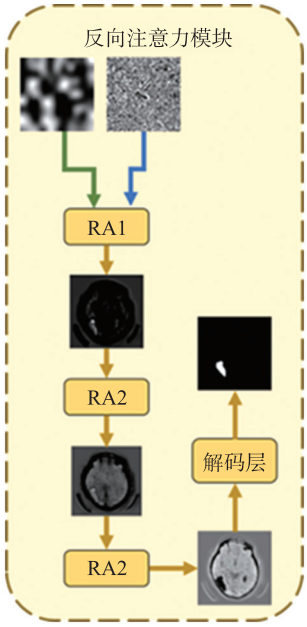

图 7　反向注意力模块结构图

反向注意力模块由三层反向注意力层组成:第一层反向注意力层的输入分为两支,第一支是经过多尺度减法模块处理后的特征图,第二支是特征提取模块第三层输出的特征图;第二层的输入也分为两支,第一支是第一层反向注意力层的输出,第二支是特征提取模块的第四层输出的特征图。第三层反向注意力层的输入分别是上一层的输出和特征提取模块第五层输出的特征图。

反向注意力层的结构如图 8 所示。反向注意力层的内部架构如下:特征提取模块输出的特征图首先通过上采样层调整尺寸以匹配多尺度减法模块输出的特征图尺寸,之后通过 Sigmod 激活函数后取反获得反转的特征图,反转的特征图和多尺度减法模块处理后的特征图相乘得到注意力权重。注意力权重计算公式为:

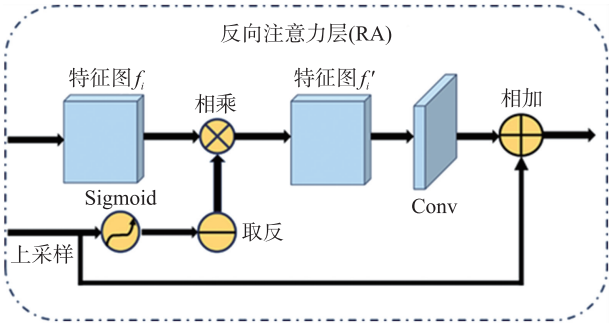

图 8　反向注意力层结构图

$$\mathbf{RA}_i = \boldsymbol{f}_i \odot \boldsymbol{X}_i \tag{8}$$

式中:$\boldsymbol{f}_i$ 和 $\boldsymbol{X}_i$ 表示特征图,⊙表示点乘。

注意力权重通过一组卷积层之后即是反向注意力层的输出。第三层反向注意力层输出的特征图输入上采样层进行解码,最终输出分割结果图。

反向注意力层的作用机制如下:由于脑出血的边缘区域较为模糊,难以分割,反向注意力机制可以抑制模型对于主要区域的响应,引导模型关注分割主体的边缘区域,从而获取更多边缘的信息,提高模型分割边缘区域的能力。

2　结果与讨论

2.1　评价指标

本文采用三个综合评价指标来评估模型对于脑出血区域的分割效果,三个指标分别是 Dice 系数(Dice)、平均交并比(MIoU)、准确率(ACC)。Dice 系数计算公式为:

$$\text{Dice} = \frac{2|X| \cap |Y|}{|X| + |Y|} \tag{9}$$

式中:X 表示模型生成的预测图,Y 表示真实图。

平均交并比计算公式为:

$$\text{MIoU} = \frac{1}{k+1} \sum_{i=0}^{k} \frac{\text{TP}}{\text{FN+FP+TP}} \tag{10}$$

准确率计算公式为:

$$\text{ACC} = \frac{\text{TP+TN}}{\text{TP+TN+FP+FN}} \tag{11}$$

式中:k 表示一批样本的数量。TP 表示真阳性样本数,FP 表示假阳性样本数,FN 表示假阴性样本数,TN 表示真阴性样本数。

2.2　模型评价结果对比

实验结果如表 1 所示。

表 1　模型分割效果评估

评价指标	SRA-Net	U-Net	Dense U-Net	Res U-Net
Dice 系数	0.837 8	0.650 7	0.608 6	0.652 5
平均交并比(MIoU)	0.778 9	0.542 1	0.539 7	0.538 3
准确度(ACC)	0.999 2	0.997 4	0.998 4	0.997 4

本文提出的 SRA-Net 模型在 Dice 系数和平均交并比上均优于对比模型,Dice 系数达到了 0.837 8。

在准确率方面,四个模型的分割准确率都较高,SRA-Net 模型达到了 99.92%的准确率。图 9 展示了几张典型脑出血 CT 图像在本模型和对比模型上的分割结果对比。

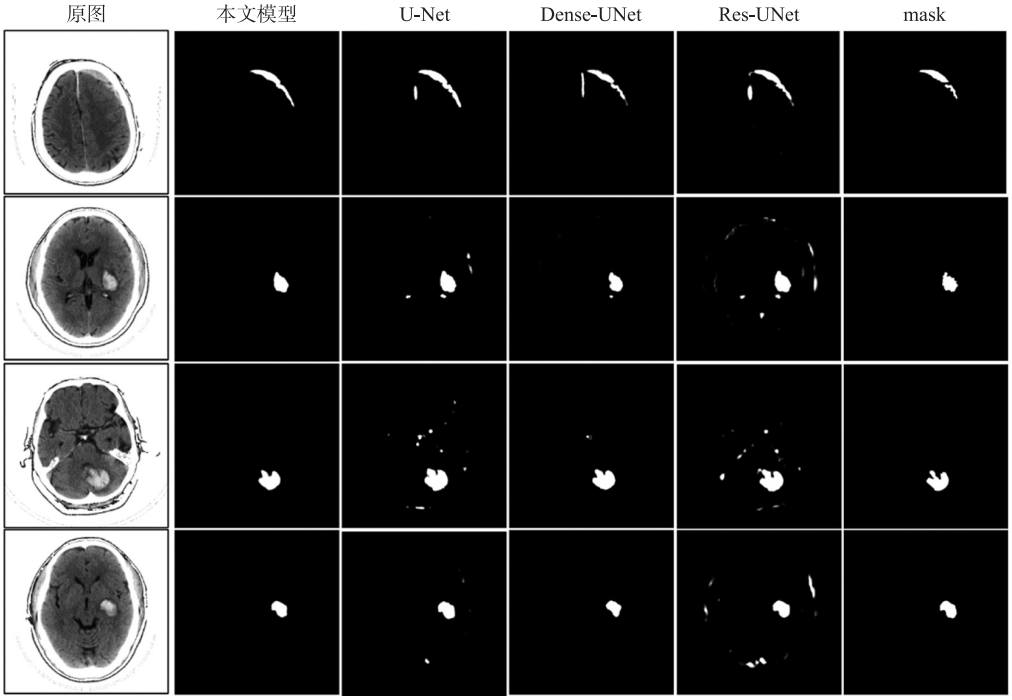

图 9 模型分割结果对比

2.3 消融实验

接下来本文将通过完善的消融实验来检验本文采用的多尺度减法模块和反向注意力模块在脑出血分割模型中的有效性,消融实验分为两个部分,第一个部分是检验多尺度减法模块在脑出血分割模型中的作用。实验步骤如下:①重新设计脑出血分割模型,将特征提取模块直接和反向注意力模块连接,特征提取模块各个层输出的特征图作为反向注意力模块各个层的输入。②训练新设计的模型③使用训练好的模型进行预测生成预测图并进行结果评估。图 10 展示了消融实验的分割结果图,图 11 是消融实验 1 的分割效果统计图。

从图 10 中看出,相比原模型,无多尺度减法模块的模型将钙化斑块区域误认为是脑出血区域,分

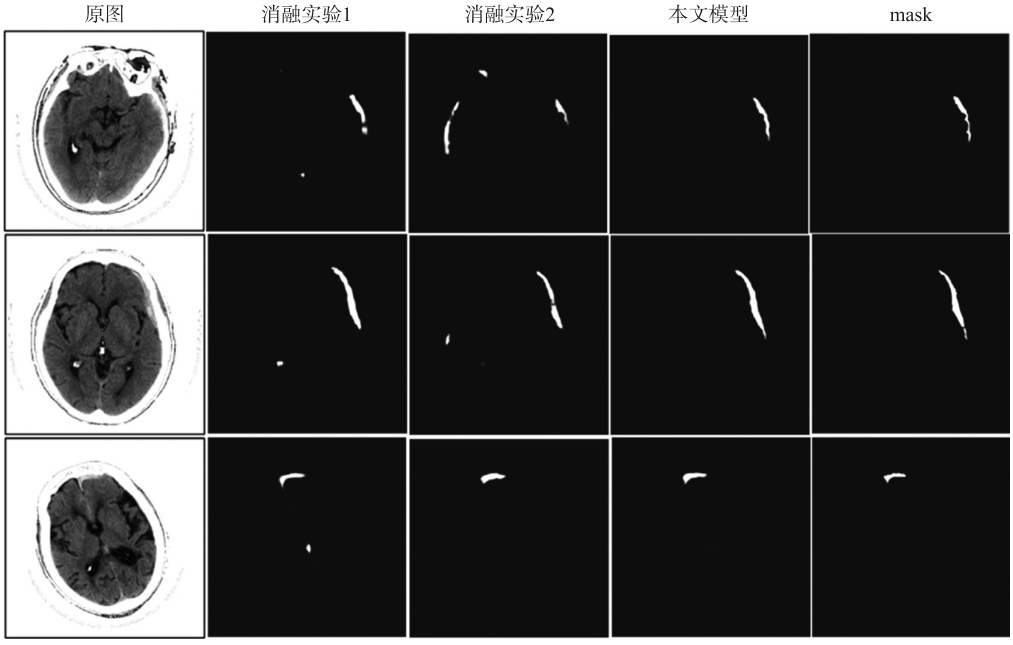

图 10 消融实验结果

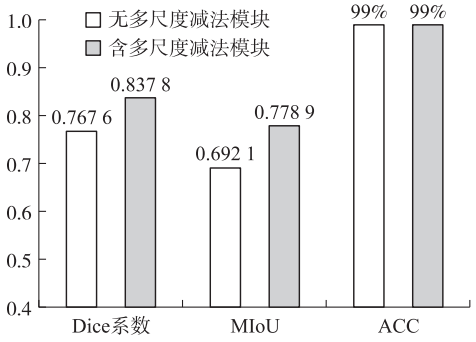

图 11　多尺度减法模块贡献评估

割效果不如原模型。这体现了多尺度减法模块对于钙化斑块特征的抑制作用。同时,去除了多尺度减法模块后,Dice 系数从 0.837 8 下降到了 0.767 6,平均交并比从 0.778 9 下降到 0.692 1。这一结果也有力地说明了多尺度减法模块对于模型分割效果的贡献。

第二部分是检验反向注意力模块在脑出血分割模型中的作用。实验步骤如下:①去除反向注意力模块,将多尺度减法模块的输出接入解码层,其他网络结构及实验设置保持不变;②训练并测试修改后的模型;③根据模型预测结果评估分割效果。图 12 是消融实验 2 的分割效果统计图,从图 10 可以看出,相比于无反向注意力模型,原模型的分割边缘更加清晰。同时,在去除反向注意力模块之后,模型没有专注于分割主体,将部分颅骨和软组织误认为是脑出血区域。这说明了反向注意力模块对于脑出血区域的边缘分辨能力较为出色。从图 12 可以看出,去除反向注意力模块之后,Dice 系数从 0.837 8 下降到 0.714 8,平均交并比从 0.778 9 下降到 0.614 6,这一结果有力证明了反向注意力模块在脑出血分割模型 SRA-Net 的贡献。

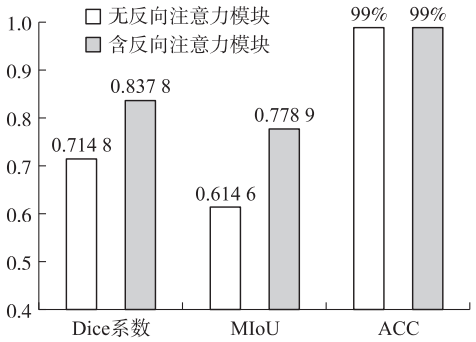

图 12　反向注意力模块分割贡献评估

3　结论

本文提出了一种基于 CT 图像的脑出血分割模型 SRA-Net。在 CT 图像脑出血数据集上的实验结果表明:①SRA-Net 模型取得了优异的分割效果,其分割结果的 Dice 系数、平均交并比(MIoU)和准确度均优于对比模型。在模型结构上,SRA-Net 通过减法金字塔处理特征图,增强了模型对钙化斑块和脑出血区域的分辨能力。②采用反向注意力模块引导模型关注分割主体,提升了脑出血区域边缘分割的精度。③通过消融实验验证了多尺度减法模块和反向注意力模块的有效性。结果显示,在去除多尺度减法模块的情况下,分割的 Dice 系数下降了 0.07,MIoU 下降了 0.08;去除反向注意力模块的情况下,Dice 系数下降了 0.12,MIoU 下降了 0.16。④同时 SRA-Net 模型还存在很多不足,模型目前只能分割脑出血区域,在之后的研究中,会研究估算脑出血出血量的算法。另外,模型目前只能处理二维图像,之后会改进模型,增加模型处理三维图像的能力。

总之,SRA-Net 模型能够准确分割脑出血区域,帮助医生快速诊断,从而使患者更快地得到救治。

参考文献:

[1] Hemphill J C, Greenberg S M, Anderson C S, et al. Guidelines for the Management of Spontaneous Intracerebral Hemorrhage: A Guideline for Healthcare Professionals from the American Heart Association/American Stroke Association[J]. Stroke, 2015, 46(7): 2032-2060.

[2] Caceres J A, Goldstein J N. Intracranial Hemorrhage[J]. Emergency Medicine Clinics of North America, 2012, 30(3): 771-794.

[3] Prakash K N, Zhou S, Morgan T C, et al. Segmentation and Quantification of Intra-Ventricular/Cerebral Hemorrhage in CT Scans by Modified Distance Regularized Level Set Evolution Technique. [J]. International Journal of Computer Assisted Radiology and Surgery, 2012, 7(5): 785-798.

[4] Bhadauria H S, Dewal M L. Intracranial Hemorrhage Detection Using Spatial Fuzzy C-Mean and Region-Based Active Contour on Brain CT Imaging[J]. Signal Image Video Process, 2014, 8(2): 357-364.

[5] Shahangian B, Pourghassem H. Automatic Brain Hemorrhage Segmentation and Classification Algorithm Based on Weighted Grayscale Histogram Feature in a Hierarchical Classification Structure [J]. Biocybernetics Biomedical Engineering, 2016, 36(1): 217-232.

[6] Yao H, Williamson C, Gryak J. Automated Hematoma Segmentation and Outcome Prediction for Patients with Traumatic Brain Injury[J]. Artificial Intelligence in Medicine, 2020, 107: 101910.

[7] Nag M K, Chatterjee S, Sadhu A K, et al. Computer-Assisted Delineation of Hematoma from CT Volume Using Au-

toencoder and Chan Vese Model. [J]. International Journal of Computer Assisted Radiology and Surgery, 2019,14(2):259-269.

[8] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation [C]// MICCAI 2015: 18th International Conference on Medical Image Computing and Computer-Assisted Intervention, Munich, Germany, Springer, 2015:234-241.

[9] Xu J, Zhang R G, Zhou Z J, et al. Deep Network for the Automatic Segmentation and Quantification of Intracranial Hemorrhage on CT[J]. Frontiers in Neuroscience, 2020, 14:541817.

[10] Qiu Y H, Chang C S, Yan J L, et al. Semantic Segmentation of Intracranial Hemorrhages in Head CT Scans[C]//2019 IEEE 10th International Conference on Software Engineering and Service Science, Beijing, China, 2019:112-115.

[11] Yuan Y L, Li Z, Tu W G, et al. Computed Tomography Image Segmentation of Irregular Cerebral Hemorrhage Lesions Based on Improved U-Net[J]. Journal Radiation Research and Applied Sciences, 2023, 16(3):100638.

[12] Li L, Wei M, Liu B, et al. Deep Learning for Hemorrhagic Lesion Detection and Segmentation on Brain CT Images. [J]. IEEE Journal of Biomedical and Health Informatics, , 2021, 25(5):1646-1659.

[13] Fang L L, Jiang Y M, Zhu K N. AOFNet: A Novel Cerebral Hemorrhage Segmentation Network Based on Anatomical-Omics Feature[J]. Biomedical Signal Processing and Control, 2024, 94:106317.

[14] Xu B H, Fan Y W, Liu J M, et al. CHSNet: Automatic Lesion Segmentation Network Guided by CT Image Features for Acute Cerebral Hemorrhage[J]. Computers in Biology and Medicine, 2023, 164:107334.

[15] Flanders A E, Prevedello L M, Shih G, et al. Construction of a Machine Learning Dataset Through Collaboration: The RSNA 2019 Brain CT Hemorrhage Challenge. [J]. Radiology: Artificial Intelligence, 2020, 2(3):e190211.

[16] Kreer J. A Question of Terminology[J]. IRE Transactions on Information, 1957, 3(3):208.

[17] Zhao X, Zhang L, Lu H. Automatic Polyp Segmentation via Multi-Scale Subtraction Network[C]//MICCAI 2021: 24th International Conference on Medical Image Computing and Computer-Assisted Intervention, Strasbourg, France, Springer, 2021:120-130.

[18] He K M, Zhang X Y, Ren S Q, et al. Deep Residual Learning for Image Recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 2016:770-778.

[19] Fan D P, Ji G P, Zhou T, et al. PraNet: Parallel Reverse Attention Network for Poly Segmentation[C]//MICCAI 2020: 23rd International Conference on Medical Image Computing and Computer-Assisted Intervention, Online, Springer, 2020:263-273.

顾骏鸿(1999—),男,硕士研究生,主要研究方向为医学图像处理,gujunhong@hdu.edu.cn;

李 宏(1966—),男,杭州电子科技大学教授,硕士生导师,主要研究方向为智能仪器与再生医学,lihong@hdu.edu.cn。