

嵌套UNet++模型的脑肿瘤图像分割算法研究

付 豪, 郭家豪

江西理工大学电气工程与自动化学院, 江西 赣州

收稿日期: 2025年3月13日; 录用日期: 2025年4月22日; 发布日期: 2025年5月9日

摘 要

针对计算机辅助脑肿瘤图像边缘分割模糊、分割精度不高等问题, 提出了一种改进的嵌套UNet++脑肿瘤图像分割算法。首先设计MCAM (Mish Coordinate Attention Module)模块代替原UNet++的特征提取部分, 嵌入坐标注意力机制(Coordinate Attention, CA)关注不同方向上的位置信息以增强特征提取能力, 使用Mish激活函数替换ReLU激活函数防止出现梯度消失, 提高脑肿瘤图像分割精度和泛化能力; 其次在特征提取后加入SME (Squeeze Mish Excitation Block)模块进行挤压和激励, 扩大特征图的感受野以增强对肿瘤特征的学习能力; 最后利用焦点Dice损失函数关注模糊样本的分割, 从而改善脑肿瘤图像边缘分割模糊的问题。提出的算法在Figshare数据集上进行仿真实验, 实验结果表明在MIoU、MPA、Dice和Hausdorff评估指标上分别达到83.26%、81.91%、86.45%和18.57 mm。与3DUnet、Swin-UNet、DD-UNet、LRAE-UNet和AI-UNet等主流算法进行对比, 证明提出的算法分割效果更优。

关键词

脑肿瘤图像分割, UNet++, MCAM, CA注意力机制, SME

Research on the Brain Tumor Image Segmentation Algorithm Based on an Improved UNet++ Model

Hao Fu, Jiahao Guo

School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou Jiangxi

Received: Mar. 13th, 2025; accepted: Apr. 22nd, 2025; published: May 9th, 2025

Abstract

Aiming at the problems of blurred edge segmentation and low segmentation accuracy of computer-aided brain tumor images, an improved nested UNet++ brain tumor image segmentation algorithm

文章引用: 付豪, 郭家豪. 嵌套 UNet++模型的脑肿瘤图像分割算法研究[J]. 传感器技术与应用, 2025, 13(3): 211-221.
DOI: 10.12677/jsta.2025.133021

was proposed. Firstly, the MCAM module is designed to replace the feature extraction part of the original UNet++. The CA attention mechanism is used to focus on positioning information in different directions to improve feature extraction capabilities. The Mish activation function is used to replace the ReLU activation function to prevent gradient disappearance and improve segmentation. Accuracy and generalization ability; then add the SME module after feature extraction for squeezing and excitation to enhance the receptive field of the feature map to enhance the learning ability of tumor features; finally, use the focus Dice loss function to focus on fuzzy samples segmentation, thereby improving the problem of blurred edge segmentation of brain tumor images. The proposed algorithm was simulated on the Figshare dataset. The experimental results showed that it achieved 83.26%, 81.91%, 86.45% and 18.57 mm in MIoU, MPA, Dice and Hausdorff evaluation indicators respectively. Comparison with algorithms such as 3DUnet, Swin-UNet, DD-UNet, LRAE-UNet and AI-UNet proves that the proposed algorithm has a better segmentation effect.

Keywords

Brain Tumor Image Segmentation, UNet++, MCAM, Coordinate Attention Mechanism, SME

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

脑肿瘤[1]作为病死率高的肿瘤之一, 一直是令人恐惧的疾病, 它是一种脑组织的癌症, 是当脑组织癌变或转移到颅骨中的其他组织时形成的。而随着医学成像技术的发展, 成像技术逐渐应用于肿瘤检测, 最初是使用计算机断层扫描(CT)技术进行检测, 但随着磁共振的发展, 结合数字图像重建的理论和技術, 磁共振成像[2] (MRI)就慢慢形成, 因为它具有许多成像参数且不会造成电离辐射损伤身体, 所以逐渐成为医学脑肿瘤检测的主流[3]。然而, 目前大多数临床脑肿瘤的診斷都是基于临床医生的经验, 所以诊断时对肿瘤图像的要求很高, 否则很容易错过患者的最佳治疗时期[4]。因此, 如何通过颅部图像对脑肿瘤进行有效诊断, 减少诊断错误已成为许多研究者关注的焦点。

此前, 许多技术被开发用于 MRI 图像中脑肿瘤的分割, 常见的图像分割方法包括: 区域增长法[5]、基于聚类的方法[6]、基于阈值的方法[7]和基于边缘的方法[8], 然而这些技术对噪声与伪影的敏感性和技术的时效性是有限的。随着计算机的发展, 大量基于深度学习[9]的脑肿瘤图像分割算法被提出。例如, Ronnerberger [10]等人通过转置卷积、上采样、融合上下文特征和细节特征形成 U-Net, 可以获得足够的数据特征, 且分割效果明显优于全卷积网络, 但仍存在边缘细节丢失的问题; Huang [11]等设计一种前置跳跃连接倒残差 U 形网络来解决特征提取过程中信息丢失的问题; Cao [12]等提出上下文注意模块, 利用空间上下文信息捕获和过滤高级特征, 在解码结构中引入通道注意力机制以实现高级特征与低级特征的融合; Maji [13]等利用一种具有引导解码器的 Res-UNet 深度学习架构, 来指导每个解码器层的学习过程生成更好的特征图; 侯奕辰[14]等提出一种残差块替换编码器部分的密集连接 UNet++脑肿瘤自动分割网络, 以提高脑肿瘤分割的准确性; 张顾瀛[15]等采用通道交换和 Swin-transform 技术来获得图像局部互补特征。虽然以上算法在脑肿瘤图像分割任务中都有较好的效果, 但是仍然存在脑肿瘤图像边缘分割模糊、图像存在不均衡的特点和梯度消失等问题。

针对以上问题, 本文提出一种改进的 U-Net 编解码架构, 主要的改进内容为: 引入 MCAM 模块替换 UNet++的特征提取部分, 通过 CA 注意力机制获取不同方向上的位置信息来增强模型对脑肿瘤图像特征

的提取能力, 通过 Mish 激活函数来防止梯度消失, 从而提升模型对脑肿瘤图像特征语义的充分提取。采用 SME 模块对特征提取后的特征图进行挤压和激励, 进一步扩大模型感受野, 以加强特征图对肿瘤区域关注度, 使其专注于肿瘤区域的学习, 从而提高脑肿瘤图像分割精度。设计焦点 Dice 损失函数, 解决脑肿瘤图像边缘分割模糊的问题。

2. 本文方法

2.1. 整体框架

针对脑肿瘤图像分割边缘精度不高、过拟合和感受野不足等问题, 本文对 UNet++ 进行改进, 提出 CA-UNet++ 网络模型, 网络结构如图 1 所示。该网络以 UNet++ 为原始结构, 用 MCAM 模块替代原来的特征提取部分, 增强网络提取语义信息的能力; 再将各层 MCAM 模块的输出特征图通过 SME 模块进行挤压和激励, 让模型能更精准的关注重要特征而抑制不重要的特征; 输出的特征图使用二维最大池化 (MaxPooling2D) 的方式下采样到下一层, 下一层的特征通过双线性插值上采样后融合上一层的特征, 最后与同一层的模块跳跃连接进行融合输出; 对模型最上层的模块通过 1×1 卷积进行降维后输出, 监督 Encoder 编码部分的每个分支, 最后得到效果最佳的肿瘤分割图。




Figure 1. Improving the overall structure of the UNet++ model

图 1. 改进 UNet++ 模型整体结构

2.2. MCAM 模块

UNet++ 网络和 UNet 网络都是基于 Encoder-Decoder 编解码模型的框架, Zhou [16] 等人利用图像分割中的多尺度特征重新设计跳跃连接, 在 UNet 的基础上提出了 UNet++, 整个网络的特征提取都依靠两次的卷积、BN 标准化和激活操作的模块来实现, 但是层数的增加, 不仅会使网络训练更困难, 特征提取能力也会有所不足。因此本文提出一个新的 MCAM 模块来替代原网络的模块, 利用深度残差学习框架原理, 在有效提取脑肿瘤图像语义信息的同时, 增强特征提取的能力和抑制过拟合的发生。

模块结构如图 2 所示, 首先设计两路对输入特征图进行不同的卷积操作, 一路通过 3×3 卷积后进行

BN 标准化, 最后通过 Mish 激活操作, 主要的目的是拟合残差; 另一路通过 1×1 卷积再进行 BN 标准化, 在保留浅层网络特征的同时, 避免出现网络深度增加而退化的问题。然后经过 CA 注意力机制增强对边缘分割的能力, 连接两分支进行激活后, 最后通过 1×1 卷积将特征维度恢复到原特征维度, 作为下一个特征提取的输入。总体的计算过程为:

$$F_{Out} = S(C_1(F_{In}) + C_3(F_{In})) \quad (1)$$

式中: F_{Out} 表示输出特征图, F_{In} 表示输入特征图, S 表示 Sigmoid 激活函数, C_1 和 C_3 分别表示 1×1 卷积和 3×3 卷积操作。




Figure 2. MCAM module

图 2. MCAM 模块

2.3. SME 模块

在卷积神经网络中, 感受野是用来决定一层输出结果中一个元素对应的输入层大小, 特征图的感受野越大, 获得的全局信息越多, 越有利于分割。受文献[17]的启发, 本文提出一个 SME 模块, 该模块结构如图 3 所示。整个模块首先是对输入的特征图进行 1×1 卷积操作, 为防止信息连续性的损失, 引入全局平均池化层(Global Average Pooling)进行特征图的挤压(Squeeze)操作, 得到一个长度为 N 的实数列, 通过挤压使通道上的特征图获取全局的感受野, 让浅层特征图也能利用全局信息, 得到丰富的语义信息的同时增强网络特征的可解释性; 然后将得到的实数列通过全连接层降维, 变成 $1 \times 1 \times (N/x)$ 的向量(x 是挤压比, 在本文中取 16), 再使用 Mish 激活函数升维回到 $1 \times 1 \times N$ 的向量, 输入到 Sigmoid 激活函数中计算通道的权重系数, 实现激励(Excitation)操作; 为更新特征图, 最后将权重系数与对应特征通道相乘。




Figure 3. SME module

图 3. SME 模块

2.4. 注意力机制

在处理长序列、大图像等复杂任务时, 传统的深度学习模型存在着信息丢失和计算开销大的问题, 为了解决这些问题, 注意力机制被提出并引入到深度学习模型当中, 以提高模型的性能。注意力机制能够以高权重聚焦重要信息, 以低权重忽略非相关信息, 还可以不断调整权重, 使得在不同的情况下也可以选取重要的信息。

随着级联卷积和非线性变化的叠加, 在高层输出特征图时, 空间细节特征通常会消失, 这会导致分割任务的准确率降低, 因此本文引入文献[18]中的 CA 注意力机制。如图 4, 该注意力机制主要分为两个部分: 坐标信息嵌入部分和坐标注意生成部分, 前者对水平坐标和垂直坐标中的通道信息进行编码, 而后者捕获位置信息并生成权重值。CA 注意力机制可以关注每个坐标中的位置信息, 比原始通道注意力机制具有更好的能力, 并且能够增强对肿瘤全局位置的学习能力, 从而减少 UNet++ 模型误分割的结果。




Figure 4. Coordinate Attention module

图 4. Coordinate Attention 模块

2.5. 激活函数

激活函数是一种非线性的点级函数, 负责对神经网络层中的输入进行非线性变换, 激活函数的选择对于理解神经网络的性能至关重要。原始 UNet++ 网络使用的是 ReLU 激活函数, ReLU 有着收敛速度快、计算速度快和训练稳定的特点, 公式为:

$$\text{Relu}(x) = \max(0, x) \quad (2)$$

当输入 x 大于 0 时, 输出为 x , 否则输出都为 0。但该函数也存在不足, 当非常大的梯度流过一个 ReLU 神经元, 更新过参数之后, 这个神经元再也不会对任何数据有激活现象, 梯度永远为 0, 出现坏死现象, 所以出现梯度消失的问题, 网络难以更好的训练。而本文采用 Misra [19] 等提出的 Mish 激活函数替换原始网络的 ReLU 激活函数, Mish 激活函数的公式为:

$$\text{Mish}(x) = x \times \tanh(\ln(1 + \exp(x))) \quad (3)$$

Mish 和 ReLU 激活函数的曲线如图 5 所示, 从中可以看出, 在 $x > 0$ 的部分, Mish 激活函数和 ReLU 激活函数一样, 是无边界的, 没有饱和区, 可以防止梯度弥散, 而 $x < 0$ 的部分, ReLU 激活函数的输出值始终为 0, Mish 激活函数却有着明显的负凹度, 这保留了负权重, 能通过更好的梯度流, 有效的防止网络饱和, 进而提高网络的正则化效果。由于 Mish 激活函数曲线具有平滑的特点, 在 0 值点处连续, 能减少一些不可预测的问题, 使网络更容易优化和提高泛化性能。




Figure 5. Plot of the ReLU and Mish activation functions

图 5. ReLU 和 Mish 激活函数曲线图

2.6. 损失函数

Shruti Jadon [20]等提出了 log-cosh Dice 损失通过 Lovsz 延展添加平滑来解决 Dice coefficient 损失的非凸函数问题, 公式为:

$$\cosh x = \frac{e^x + e^{-x}}{2} \quad (4)$$

$$L_{lc-dce} = \log(\cosh(\text{DiceLoss})) \quad (5)$$

其中 L_{lc-dce} 表示 log-cosh Dice 损失函数。

虽然 log-cosh Dice 损失解释了非凸性的问题, 但同样的损失系数也被用于不同的分割样本, 这不利于具有不同训练差异的分割样本。本文将在网络训练阶段采用结合焦点损失和 log-cosh Dice 损失的函数, 称为焦点 Dice 损失函数, 它通过减少容易分割样本的权重, 增加模糊分割样本的权重来实现对不同样本的自适应变化, 使模型在训练过程中更关注难以分割的样本, 集中于模型的分类能力和模型的分割能力。合成的损失函数公式为:

$$\text{Focal-DiceLoss} = w_1 (\text{FocaLoss}) + w_2 (\text{DiceLoss})^\gamma \log(\cosh(\text{DiceLoss})) \quad (6)$$

其中 w_1 表示 FocaLoss 的权重, w_2 表示 DiceLoss 的权重, γ 为调节因子。

3. 实验过程与实验分析

为了评估改进 UNet++模型的脑肿瘤分割性能, 本文所使用的实验环境为: 64 位的 Windows 10 操作系统, cuda 12.2 版本, 开发语言为 python 3.8, 以 pytorch 1.12 深度学习框架进行构建, 用 NVIDIA GeForce RTX 3060 Laptop GPU 进行训练。实验模型使用优化器为 SGD, 初始学习率为 0.001, 动量系数和权重衰减分别设置为 0.9 和 0.0001, 设置每批次数量(batch size)为 8 张图片, 训练迭代次数为 200。

3.1. 实验数据集及预处理

本文实验使用的数据集来自 Figshare 数据库, 是 2005 年至 2010 年在广州南方医院和天津医科大学总医院患有不同脑肿瘤疾病的 233 位病人中获取的图像, 该数据集从 kaggle 中下载, 主要分 Testing 和 Training 两部分。Testing 包含神经胶质瘤 183 例、脑(脊)膜瘤 306 例、无肿瘤 405 例和垂体 300 例; Training 包含神经胶质瘤 339 例、脑(脊)膜瘤 1304 例、无肿瘤 1595 例和垂体 1457 例。Figshare 数据集中图片大小不一, 故将其全部裁剪为 256×256 大小的图片进行训练, 本实验取用 Training 中除无肿瘤的图片并对其进行标注, 以 80% 和 20% 的比例分别作为训练集和验证集使用。

3.2. 评估指标

为验证本文研究算法的有效性, 选择了图像语义分割常用的评估指标对本文算法进行评估, 主要包括了 MIoU、MPA、Dice 和 Hausdorff 等评估指标。

MIoU (均值交并比) 是计算出所有类别的交互合并比率的平均值, 是语义分割的常用标准度量函数。它的公式如式(7)所示, 其中 k 为类别、 i 为真实值、 j 为预测值、 p_{ij} 表示预测 i 到 j 的像素数, p_{ji} 表示预测 j 到 i 的像素数, p_{ii} 表示正确预测的像素数。

$$\text{MIoU} = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (7)$$

MPA (类别平均像素准确率) 是 PA 的平均值, PA 表示正确预测的像素数与总像素数的比值, MPA 是各类别的累计平均数。它的公式如下:

$$\text{MPA} = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij}} \quad (8)$$

Dice (骰子系数) 是一种判断两个样本的相似度测量函数, 两个输入集之间的相似性越大, Dice 的系数越大, 分割模型也就越准确, 是图像分割的重要指标之一。它的公式如式(9)所示, 其中 TP 表示样本的预测值与真实值都为正, FP 表示样本的预测值为正, FN 表示样本的预测值为假, 真实值为正, 真实值为负, Y 表示预测的目标, X 表示真实值。

$$\text{Dice} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}} \quad (9)$$

Hausdorff distance (豪斯多夫距离) 用于计算真实值边界与预测值边界之间的距离, 两者之间的距离越小, 表示分割的越好。它的公式如式(10)所示, 其中 $\vec{d}_H(A, B)$ 表示 A 到 B 的豪斯多夫距离, $\vec{d}_H(B, A)$ 表示 B 到 A 的豪斯多夫距离, HD 表示最后取两者中的最大值。

$$\text{HD} = \max\{\vec{d}_H(A, B), \vec{d}_H(B, A)\} \quad (10)$$

3.3. 实验结果与分析

3.3.1. 不同技术性能对比实验

为测试不同的技术对改进 UNet++ 分割性能的影响, 本文以 UNet++ 为原始框架, 将替换不同激活函数和加入不同注意力机制模块做对比实验, 结果如表 1 所示。数据表明, Tanh 函数在 MPA 和 HD 都有不错的效果, 但 Mish 函数在 MIoU 比 Tanh 高 2.81%, 综合来看, 使用 Mish 函数有更好的分割精度。而在引入不同注意力机制模块的数据中, CA 注意力机制虽然对比 CBAM 在 MPA 上低 0.29%, 但是其他数据上均有明显的优势, 因此本文算法采用 Mish 激活函数和 CA 注意力机制进行实验。

Table 1. Comparing the different technical performance results
表 1. 不同技术性能对比结果

模型	激活函数	注意力机制	MIoU/%	MPA/%	Dice/%	HD(mm)
UNet++	ReLU	-	80.71	81.23	84.96	22.35
	Tanh	-	78.75	81.44	85.11	20.39
	Swish	-	81.37	81.38	82.53	21.03
	Mish	-	81.56	81.37	85.34	20.54
	Mish	SE	80.25	81.21	82.44	22.07
	Mish	CBAM	78.78	82.63	83.29	21.98
	Mish	ECA	81.53	81.49	84.66	20.75
	Mish	CA	82.48	82.34	85.21	20.17

注：粗体表示最优值。

3.3.2. 消融实验

为验证所提出改进点的可行性, 本文以 UNet++模型为基础, 逐一组合不同的技术进行了更为详细的消融实验, 结果如表 2 所示。其中 M1 表示基础模型 UNet++, M2 表示将 M1 的特征提取部分替换 MCAM 模块(使用原先的 ReLU 激活函数), M3 表示将 M2 的 ReLU 激活函数替换成 Mish 激活函数, M4 表示在 M3 的 MCAM 模块输出后加入 SME 模块, 最终构成本文算法。

Table 2. Comparison of the ablation experiments on the Figshare dataset
表 2. 在 Figshare 数据集上的消融实验对比

方法	MIoU/%	MPA/%	Dice/%	HD (mm)
M1	80.71	81.23	84.96	22.35
M2	81.64	81.44	85.55	21.74
M3	82.07	82.12	85.56	20.77
M4	83.26	81.91	86.45	18.57

注：粗体表示最优值。

在 M2 操作下, 整体的参数指标均有增长, MIoU 提升 0.93%, MPA 提升 0.21%, Dice 提升 0.59%, HD 减少 0.61 mm, 表明增加 1×1 卷积分路和引入 CA 注意力机制能有效定位肿瘤区域; 在 M3 操作下, 替换 Mish 激活函数后构成 MCAM 模块, 参数指标又有所增长, MIoU 提升 0.47%, MPA 提升 0.68%, Dice 提升 0.01%, HD 减少 0.97 mm, HD 的显著降低表明能使模型获取更多的语义信息, 掌握更多边缘的细节; 最后 M4 阶段加入 SME 模块后, MIoU 达到 83.26%, Dice 达到 86.45%, HD 达到 18.57 mm, 而 MPA 比 M3 阶段减少 0.21%, 整体的指标最优, 证明本文做出的算法改进能实现对脑肿瘤图像的准确分割。

3.3.3. 不同模型的对比实验

本文将 Figshare 数据集分别在所提出的模型和其他主流模型上对 UNet、UNet++、3Dunet [21]、Swin-Unet [22]、DD-Unet [23]、LRAE-Unet [24]和 AI-Unet [25]进行训练对比, 目的是验证改进的 UNet++模型的先进性, 为避免其他因素的干扰, 实验将各模型设置为相同的训练参数, 所得的实验结果如表 3 所示。

在表中，本文算法在不同指标 MIoU、MPA、Dice、HD 的结果分别为 83.26%、81.91%、86.45%和 18.57 mm。实验数据显示本文模型各项指标都比其他模型的结果更好，意味着在 Figshare 数据集上的分割效果更准确，能够提取的语义信息更多，精度更高，这证实了该模型在处理脑肿瘤图像分割任务时，有强大的学习能力。

Table 3. Comparison results of different models on the Figshare dataset
表 3. 不同模型在 Figshare 数据集上的对比结果

Method	Evaluation index (%)			
	MIoU	MPA	Dice	HD (mm)
UNet	79.37	78.91	84.37	27.54
UNet++	80.71	81.23	84.96	22.35
3DUnet	81.11	80.54	85.31	34.12
Swin-UNet	80.27	79.55	83.56	37.35
DD-UNet	81.75	80.86	84.99	21.57
LRAE-UNet	82.23	80.91	85.37	20.88
AI-UNet	81.59	81.37	85.12	20.76
UNet++ (MCAM)	83.26	81.91	86.45	18.57

注：粗体表示最优值。

数据集在不同模型上训练过程的损失值如图 6 所示，实验设置的迭代次数固定为 200 轮，图中的曲线变化能够反映模型在训练过程的波动情况，损失值越小表示模型的鲁棒性越好。其中 3DUnet 的曲线震荡幅度最大，意味着该模型在训练过程中不稳定，而本文设计的模型损失值曲线在 50 轮的时候就趋向稳定，收敛的速度快，并且损失值明显低于其他模型，表明本文模型能有效降低非关键信息的影响，整体拟合程度更好，还有较好的泛化性。




Figure 6. Training of the loss curve
图 6. 训练 loss 曲线

3.3.4. 不同模型的分割结果可视化分析

为了验证模型对脑肿瘤图像的分割效果，本文实验得到一系列可视化对比图，如图 7 所示。图中显示的是通过 5 种不同模型对不同类型脑肿瘤的分割结果和真实标签 GT (Ground_Truth) 的对比，其中白色区域代表胶质瘤肿瘤，红色区域代表脑膜瘤肿瘤，绿色区域代表垂体肿瘤。从图中可以看出，UNet、Swin-UNet、UNet++、3DUNet、DD-UNet、LRAE-UNet 和 AI-UNet 对不同脑肿瘤的分割结果与 GT 相比差异较大一点，特别是边缘的细节不是很理想，会出现缺失或增多的现象。而本文模型对脑肿瘤图像的边缘细节分割的更好，肿瘤边缘处更加平滑，总体分割效果明显优于其他模型，能够得出该模型对 Figshare 数据集具有良好的鲁棒性和细节提取能力。




Figure 7. Plot of segmentation visualization of different models

图 7. 不同模型的分割可视化对比图

4. 结论

针对当前脑肿瘤医学图像分割模型特征提取不充分、精度较低等问题，提出一种改进的 UNet++ 脑肿瘤分割算法。首先，设计 MCAM 模块替换原网络中特征提取部分并结合坐标注意力机制 CA 捕捉上下文之间信道信息和位置关系的能力，提升主干网络在长距离空间上捕捉特征信息的交互能力，抑制网络退化；其次，设计 SME 模块对提取到的特征信息进行挤压和激励，减少图像伪影干扰，增强高频信息的加权融合。在 Figshare 数据集上的实验结果表明，改进的 UNet++ 算法在脑肿瘤分割任务上相较于 Swin-UNet、3DUNet、DD-UNet、LRAE-UNet 和 AI-UNet 等主流模型有更好的精度表现。在 MIoU、MPA、Dice 和 Hausdorff 评估指标上分别达到 83.26%、81.91%、86.45% 和 18.57 mm。今后将继续对模型进行优化，通过引入弱监督和无监督等方法减弱模型对数据的依赖，提高对不同尺度病变区域的特征融合能力，应对脑肿瘤不同区域的分割情况，为我国医学图像分割提供助力。

参考文献

[1] Batool, A. and Byun, Y. (2024) Brain Tumor Detection with Integrating Traditional and Computational Intelligence Approaches across Diverse Imaging Modalities—Challenges and Future Directions. *Computers in Biology and Medicine*, **175**, Article 108412. <https://doi.org/10.1016/j.combiomed.2024.108412>

[2] 唐少平, 陶蕾. 磁共振成像在脑部疾病诊断中的研究进展[J]. 中国现代医生, 2023, 61(25): 132-135.

[3] Mohan, G. and Subashini, M.M. (2018) MRI Based Medical Image Analysis: Survey on Brain Tumor Grade Classification. *Biomedical Signal Processing and Control*, **39**, 139-161. <https://doi.org/10.1016/j.bspc.2017.07.007>

[4] Hu, H., Mao, W., Lin, Z., Hu, Q. and Zhang, Y. (2021) Multimodal Brain Tumor Segmentation Based on an Intelligent UNET-LSTM Algorithm in Smart Hospitals. *ACM Transactions on Internet Technology*, **21**, 1-14. <https://doi.org/10.1145/3450519>

[5] Feng, Z. and Sun, P. (2019) Image Segmentation Based on Improved Regional Growth Method (Article). *International*

Journal of Circuits, Systems and Signal Processing, **13**, 162-169.

- [6] Sasmal, B. and Dhal, K.G. (2023) A Survey on the Utilization of Superpixel Image for Clustering Based Image Segmentation. *Multimedia Tools and Applications*, **82**, 35493-35555. <https://doi.org/10.1007/s11042-023-14861-9>
- [7] 唐璐, 赵英. 基于深度学习的图像分割技术研究综述[J]. 电脑知识与技术, 2023, 19(23): 30-32.
- [8] 王赛男, 郑雄风. 基于边缘计算的图像语义分割应用与研究[J]. 计算机科学, 2020(47): 276-280.
- [9] 彭璟, 罗浩宇, 赵淦森, 等. 深度学习下的医学影像分割算法综述[J]. 计算机工程与应用, 2021, 57(3): 44-57.
- [10] Ronneberger, O., Fischer, P. and Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. In: *Lecture Notes in Computer Science*, Springer, 234-241. https://doi.org/10.1007/978-3-319-24574-4_28
- [11] 黄敬腾, 李锐, 关欣. 一种用于脑肿瘤分割的改进 U 形网络[J]. 工程科学学报, 2023, 45(6): 1003-1012.
- [12] Cao, T., Wang, G., Ren, L., Li, Y. and Wang, H. (2022) Brain Tumor Magnetic Resonance Image Segmentation by a Multiscale Contextual Attention Module Combined with a Deep Residual UNet (MCA-ResUNet). *Physics in Medicine & Biology*, **67**, Article 095007. <https://doi.org/10.1088/1361-6560/ac5e5c>
- [13] Maji, D., Sigedgar, P. and Singh, M. (2022) Attention Res-UNet with Guided Decoder for Semantic Segmentation of Brain Tumors. *Biomedical Signal Processing and Control*, **71**, Article 103077. <https://doi.org/10.1016/j.bspc.2021.103077>
- [14] 侯奕辰, 彭辉, 谢俊章, 等. 改进 Unet++ 在脑肿瘤图像分割的研究[J]. 计算机工程与设计, 2022, 43(6): 1725-1731.
- [15] 张顾瀛, 贺光华. 基于深度学习通道交换的多模态脑肿瘤图像融合的分割模型[J]. 理论数学, 2023, 13(4): 976-986.
- [16] Zhou, Z., Siddiquee, M.M.R., Tajbakhsh, N. and Liang, J. (2020) UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation. *IEEE Transactions on Medical Imaging*, **39**, 1856-1867. <https://doi.org/10.1109/tmi.2019.2959609>
- [17] Hu, J., Shen, L., Albanie, S., Sun, G. and Wu, E. (2020) Squeeze-and-Excitation Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **42**, 2011-2023. <https://doi.org/10.1109/tpami.2019.2913372>
- [18] Hou, Q., Zhou, D. and Feng, J. (2021). Coordinate Attention for Efficient Mobile Network Design. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 20-25 June 2021, 13708-13717. <https://doi.org/10.1109/cvpr46437.2021.01350>
- [19] Misra, D. (2019) Mish: A Self-Regularized Non-Monotonic Neural Activation Function.
- [20] Jadon, S. (2020) A Survey of Loss Functions for Semantic Segmentation. 2020 *IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB)*, Via del Mar, 27-29 October 2020, 1-7. <https://doi.org/10.1109/cibcb48159.2020.9277638>
- [21] 袁雪, 陈茂洲. 基于 3D-Unet 的 sMRI 图像分割研究[J]. 现代电子技术, 2023, 46(23): 71-74.
- [22] Liao, Z., Peng, H. and Liu, T. (2023) Brain Tumor Segmentation Based on Improved Swin-UNet. 2023 *2nd International Conference on Artificial Intelligence and Intelligent Information Processing (AIIIP)*, Hangzhou, 27-29 October 2023, 222-225. <https://doi.org/10.1109/aaiip61647.2023.00048>
- [23] 苏赋, 方东, 王龙业, 等. 基于双解码路径 DD-UNet 的脑肿瘤图像分割算法[J]. 光电子·激光, 2023, 34(3): 328-336.
- [24] 林嘉豪, 王瑜, 肖洪兵, 等. LRAE-Unet: 轻量级 MRI 脑肿瘤全自动分割网络[J]. 中国医学物理学杂志, 2024, 41(1): 43-49.
- [25] 黄炜庭. 基于 AI UNet 的胶质瘤病变图像分割[D]: [硕士学位论文]. 兰州: 兰州大学, 2024.