

引用格式: ZHANG Muqing, HAN Yutong, CHEN Bonian, et al. Magnetic Resonance Imaging Brain Tumor Segmentation Using Multiscale Ghost Generative Adversarial Network[J]. Acta Photonica Sinica, 2023, 52(8):0817002

张睦卿,韩雨童,陈柏年,等.基于多尺度伪影生成对抗网络的磁共振成像脑肿瘤分割方法[J].光子学报,2023,52(8):0817002

# 基于多尺度伪影生成对抗网络的磁共振成像 脑肿瘤分割方法

张睦卿<sup>1,2</sup>,韩雨童<sup>1,2</sup>,陈柏年<sup>1,2</sup>,张建新<sup>1,2</sup>

(1 大连民族大学 计算机科学与工程学院, 大连 116600)

(2 大连民族大学 机器智能与生物计算研究所, 大连 116600)

**摘要:**针对磁共振成像脑肿瘤分割存在的肿瘤空间信息变化大与精细标注样本数量少的问题,提出一种基于多尺度伪影生成对抗网络的脑肿瘤影像分割方法。该方法采用三维U-Net模型来获取脑肿瘤分割结果并充当生成器,引入三维PatchGAN作为判别器来评判U-Net输出的脑肿瘤结果与真值标签,通过对抗学习方式进行模型训练。为提升脑肿瘤分割效果,在生成器编码阶段引入伪影模块,使得在卷积过程中能够捕获到更丰富的深度特征而提升生成器的脑肿瘤生成结果;同时,在解码过程中采用多尺度特征融合方式来有效整合脑肿瘤的浅层信息与深层信息,并在对抗学习中进一步提升分割性能。在公开的BraTS2019-2020数据集上对该方法进行了评估,实验结果验证了所提出方法在脑肿瘤分割任务中的有效性,在两个验证集上获得的全肿瘤、核心肿瘤和增强肿瘤分割Dice值分别为0.902/0.903、0.836/0.826和0.77/0.782。

**关键词:**脑肿瘤分割;三维U-Net;生成对抗网络;伪影特征;多尺度特征融合

中图分类号:TP391

文献标识码:A

doi:10.3788/gzxb20235208.0817002

## 0 引言

脑肿瘤是一种生长在大脑或头骨之中的异常细胞,可分为良性脑肿瘤和恶性脑肿瘤,可通过积极治疗取得较好的预后效果<sup>[1]</sup>。磁共振成像(Magnetic Resonance Imaging, MRI)可获得高对比度的清晰脑部图像<sup>[2]</sup>,同时因其无损伤和无电离辐射等优点已成为诊治脑肿瘤的首选成像方法<sup>[3]</sup>。临床中对MRI脑肿瘤影像进行精确分割对疾病诊断、手术规划以及术后评估等都至关重要<sup>[4]</sup>,由于医生手动分割较为耗时且主观性较大,因此对自动化分割脑肿瘤产生了迫切需求。但鉴于脑肿瘤病变形态各异、病变位置随机等问题,实现高精度的MRI脑肿瘤影像分割任务仍然具有较高的挑战性。

近年来,随着深度学习在计算机视觉领域取得的突破性发展,深度学习也逐渐被引入到MRI脑肿瘤分割任务中来并成为该任务的主流方法。早期,通常将整个脑肿瘤图像划分为多个不重叠的图像块并构建深度神经网络对其分类,进而将所有图像块按分类结果进行脑肿瘤分割,但该类方法未能有效利用脑肿瘤图像上下文信息而导致分割精度不高。2014年,LONG J等<sup>[5]</sup>提出了用于图像分割任务的全卷积网络(Fully Convolutional Network, FCN),将卷积神经网络中全连接层替换为卷积层,使图像分割以像素级分类方式完成。考虑到医学影像任务中存在的精细标注样本数量有限,RONNEBERGER O等<sup>[6]</sup>受FCN启发提出了应用于医学影像分割的U-Net网络,U-Net由对称的编码器和解码器两部分组成,同时在两部分之间引进了跳跃连接使其可以保留更多语义信息,该网络在结构简单前提下可获得较为优异的分割性能;周涛等<sup>[7]</sup>针对于医学影像中多模态数据提出跨模态多编码U-Net应用于肺部肿瘤分割;黄鸿等<sup>[8]</sup>考虑到神经网络中

基金项目:国家自然科学基金(No. 61972062),辽宁省应用基础研究计划(No.2023JH2/101300191)

第一作者:张睦卿, muqingz2000@163.com

通讯作者:张建新, jxzhang0411@163.com

收稿日期:2023-02-15;录用日期:2023-04-04

<http://www.photon.ac.cn>

的不同深度语义信息改进 U-Net++ 并应用于肺结节分割。考虑到 MRI 脑肿瘤图像为三维图像,为更好地捕获图像中的语义信息以获取更精准的分割性能,CICEK Ö 等<sup>[9]</sup>提出了三维 U-Net 模型。为进一步增强脑肿瘤分割性能,SUN J 等<sup>[10]</sup>和夏峰等<sup>[11]</sup>分别在三维 U-Net 中添加残差模块和跨阶段模块以增强网络提取特征信息能力;MCKINLEY R 等<sup>[12]</sup>和 PEI L 等<sup>[13]</sup>分别提出由二维到三维的 DeepSCAN 全卷积架构和自集成残差神经块构建分割网络以提高网络分割性能;张晓宇等<sup>[14]</sup>则提出一种改进损失函数的三维 U-Net++,使用网络四个不同层级的输出结果作为深度监督信息以更好地结合深层和浅层的特征进行分割;WANG W 等<sup>[15]</sup>将 Transformer 与三维 U-Net 结合构建出 TransBTS 网络,该网络结合局部和全局信息增强分割脑肿瘤性能。然而,由于获得更大规模像素级精细标注的脑肿瘤分割影像数据集过于困难且影像数据质量层次不齐,使得网络分割精度仍然受到数据集样本数量限制。为此,XUE Y 等<sup>[16]</sup>将生成对抗网络(Generative Adversarial Networks, GAN)引入到脑肿瘤分割领域之中,并基于 GAN 提出一个端到端的脑肿瘤分割网络,同时针对损失函数收敛困难问题进行修改来提高网络的收敛速率及稳定性;HANGHALAM M 等<sup>[17]</sup>以三维 FCN 作为生成器来构造生成对抗分割网络架构,将语义分割领域中经典网络有效引入生成对抗分割网络中;考虑到 GAN 模型生成脑肿瘤图像的不稳定性,CIRILLO M D 等<sup>[18]</sup>和 NEMA S 等<sup>[19]</sup>将 Pix2Pix GAN<sup>[20]</sup>和它的升级版 CycleGAN<sup>[21]</sup>引入到脑肿瘤分割任务,生成器可以按照自己规定的方向生成所需要的图像,从而提升网络的分割精度;此外,考虑到生成的图像精细程度不高,为了提取更准确的图像特征,DING Y 等<sup>[22]</sup>在生成器阶段添加 FEM 模块(Fine-grained Extraction Module, FEM)使网络可以更好地提取特征并获得粗略预测图;PEIRIS H 等<sup>[23]</sup>提出在生成器后添加 VAT 模块(Virtual Adversarial Training, VAT),使用虚拟对抗训练监督生成器进行第一次反向传播更新参数,再经判别器后进行第二次反向传播,使生成的图像更加逼真。以上方法可以有效说明采用生成对抗网络结构进行自动分割任务可以作为脑肿瘤分割领域中的一个重要分支。

借鉴三维生成对抗网络在解决脑肿瘤分割任务中精细标注样本数量较少问题的良好效果,同时考虑脑肿瘤形状多样、尺寸和位置信息变换大等问题,着重在三维生成对抗网络基础上强化脑肿瘤的深度特征提取与信息融合能力,提出了一种基于多尺度伪影生成对抗网络的脑肿瘤影像分割新方法。首先,从提升脑肿瘤深度特征表达的丰富性着手,将一种轻量化的伪影模块(Ghost Module)引入生成对抗网络编码阶段中,通过生成更多具有差异性的肿瘤影像深度特征来提升生成器的脑肿瘤分割效果;此外,为弥补网络在上下采样过程中的信息丢失问题,在网络中引入多尺度生成器来有效整合脑肿瘤的浅层信息与深层信息。综上,构建了一种融合伪影模块和多尺度生成器的三维生成对抗网络脑肿瘤分割新模型—多尺度伪影生成对抗网络(Multiscale Ghost Generate Adversarial Network, MG2AN),在公开的 BraTS2019-2020 脑肿瘤分割数据集上对 MG2AN 进行了广泛评估,实验结果验证了所提出方法在脑肿瘤分割任务中的有效性。

## 1 网络框架及算法原理

### 1.1 完整网络框架

所提出的三维多尺度伪影生成对抗脑肿瘤分割网络框架如图 1,在网络主体上采用生成对抗网络架构,将整个网络分为生成器网络和判别器网络两阶段网络,来实现生成器与判别器的零和博弈以提高分割网络

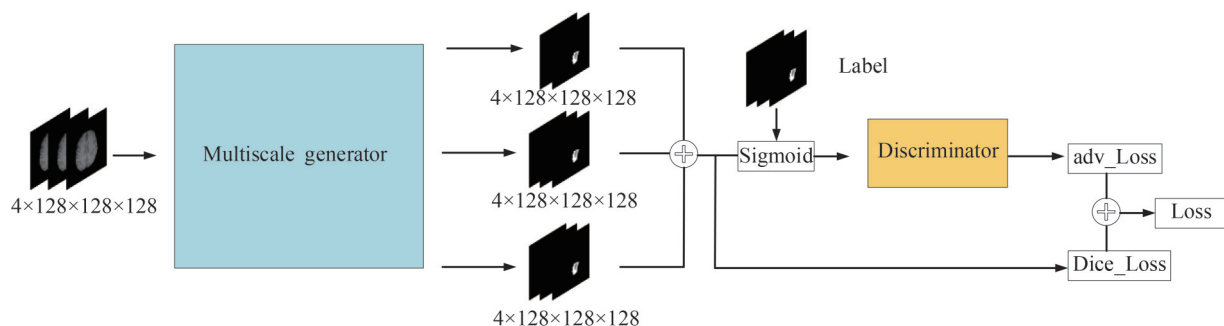


图 1 基于多尺度伪影生成对抗网络的 MRI 脑肿瘤分割方法架构

Fig.1 Overall architecture of multiscale ghost generate adversarial network for MRI brain tumor segmentation

的脑肿瘤分割效果。

多尺度伪影生成对抗网络第一阶段采用改进三维U-Net作为生成器对脑肿瘤影像进行分割,每个U-Net分别有四层编码器和解码器,生成分割后的图像为伪图。网络输入和输出的多模态脑肿瘤尺寸均为 $4 \times 128 \times 128 \times 128$ ,由于三维U-Net在经过卷积层后会生成一些额外冗余的特征图,因此将生成器中的部分卷积替换为轻量化伪影卷积,通过一些线性操作将冗余的特征图成对匹配来增加卷积的特征提取能力,考虑到计算代价以及信息丢失程度的问题,选择在生成器下采样阶段添加伪影模块,并把匹配后的图像信息融合在一起输入到底层中,进行下一步上采样操作。第二阶段使用全卷积和反卷积构成对应于生成器的多尺度判别器,将生成器生成的尺寸为 $4 \times 128 \times 128 \times 128$ 的图像和真值标签一起输入到判别器中,通过判别器判断输入图像为真图或者假图。在训练时先固定生成器训练判别器,使判别器不断提高鉴别能力,再通过固定判别器训练生成器,使生成器生成的图像更加趋近于真值标签,通过不断循环使生成器和判别器的能力都得到不断提升,以此来获得更真实的分割图像,最后采用生成网络生成的图像作为输出图像,图像尺寸为 $4 \times 128 \times 128 \times 128$ 。

考虑到脑肿瘤图像数据量较少,为更好发挥生成对抗网络优势而引入多尺度生成器,在下采样阶段分别连结三个上采样阶段,并将三个上采样阶段生成的图像进行特征融合再输入判别器中,使生成器可以生成更多的图像并更加充分利用脑肿瘤图像的全局信息与局部信息。为能更好地进行网络训练,将经过第一阶段和第二阶段的生成对抗网络损失先进行反向传播,再通过第一阶段的输出与真值图像计算损失值,然后合并为最终损失值共同监督网络。此外,采用浮点运算次数(Floating-point Operations, FLOPs)和参数量(Params)衡量分割网络时间和空间复杂度, FLOPs决定了网络训练和推理时间。初始三维生成对抗分割网络的时间和空间复杂度分别为17.85 GFLOPs和7.09 MParams, MG2AN有效降低了时间和空间复杂度,其数值分别为15.17 GFLOPs和7.09 MParams。

### 1.1.1 伪影模块

在深度卷积神经网络中,普通卷积会输出一些高度相似的特征图,这种特征图之间会产生冗余。为能够更好地利用相似的特征图, Han K等<sup>[24]</sup>提出了伪影模块的概念,使得卷积可以使用简单的线性变换生成更多的成对特征图,利用这些成对的特征图可以使网络获得更强的泛化能力,使模型可以更好地应对不同的脑肿瘤数据从而进行更精细的分割。

在MG2AN上,伪影模块分为两步。首先,使用比原始卷积更少的卷积计算,使第一次生成的特征图的通道数为普通卷积的一半数量,将这部分特征图称为本征图;其次,将第一步生成的特征图先进行深度卷积再进行点卷积,即深度可分离卷积<sup>[25]</sup>,每一个通道只会被一个卷积核进行卷积操作,可同时减少计算量与参数量,这个过程生成的特征图通道数与输入的通道数相同,此部分生成的特征图称为伪影图。最后将第一步生成的本征图与第二步生成的伪影图进行拼接操作,即将本征图与伪影图一起作为输出。经过伪影模块后所产生的特征图是由原始信息和伪影信息两部分组成,从整个网络框架的角度来看,可以看作为在不增加计算量的同时经过简单的线性变换增加生成器生成的特征图数量,并将原始信息与伪影信息一同输入到判别器中进行判别,可以增强判别器的判别能力和生成器生成图像的质量。伪影模块的具体结构如图2。

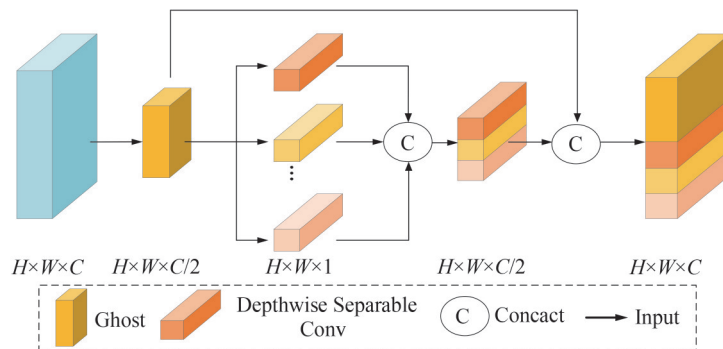


图2 伪影模块结构

Fig.2 Structural of the ghost module

考虑到MRI脑肿瘤图像为三维图像,将原始伪影模块扩展为三维,进一步将生成器下采样阶段中普通卷积替换为三维伪影模块,使网络可以充分利用冗余的特征图信息并将其一并输入到判别器中进行判别,增加网络的泛化能力,使输入的图像通过简单线性变换获得成对的伪影图提升输入分割网络中的数据量,并进一步提升判别器的判别能力和脑肿瘤分割精细程度。

### 1.1.2 多尺度生成器

对于使用生成对抗网络来实施脑肿瘤影像分割任务,生成器生成的图像质量至关重要。为提升生成器产生的脑肿瘤图像质量引入多尺度生成器的模式,在生成器的下采样阶段后分别连接针对图像的全局信息、局部信息和细节纹理信息的三个上采样阶段,来同时生成不同的图像。即每一个生成器在输入一张原始图像后会生成三个着重点不同的高质量图像,使生成器部分提取到比传统生成器更加真实的特征并且更加接近于真实图像。

上采样阶段生成不同尺寸的特征图可以捕获不同针对性的特征信息,大尺寸的特征图着重于全局信息、小尺寸的特征图着重于细节信息,如图3。处在中间的上采样阶段使用四层上采样层,生成大小为 $128 \times 128 \times 128$ 的图像,主要采集脑肿瘤图像全局信息;位于下方的上采样阶段使用三层上采样层,生成大小为 $64 \times 64 \times 64$ 的图像,再经过一个反卷积操作使图像扩大 $128 \times 128 \times 128$ 的尺寸,负责采集样本的局部信息;最后,位于上方的上采样阶段使用两层上采样层,生成大小为 $32 \times 32 \times 32$ 的图像,使用一个反卷积使图像扩大为原来的64倍,变为 $128 \times 128 \times 128$ 大小的图像,负责采集样本的细节纹理信息。此外,将每个上采样阶段乘以不同的权重后相加输入到判别器,从而使生成器生成的图像即兼顾全局信息又注重局部细节信息,增强生成脑肿瘤图像,使其更接近于真实图像。具体结构如图3。

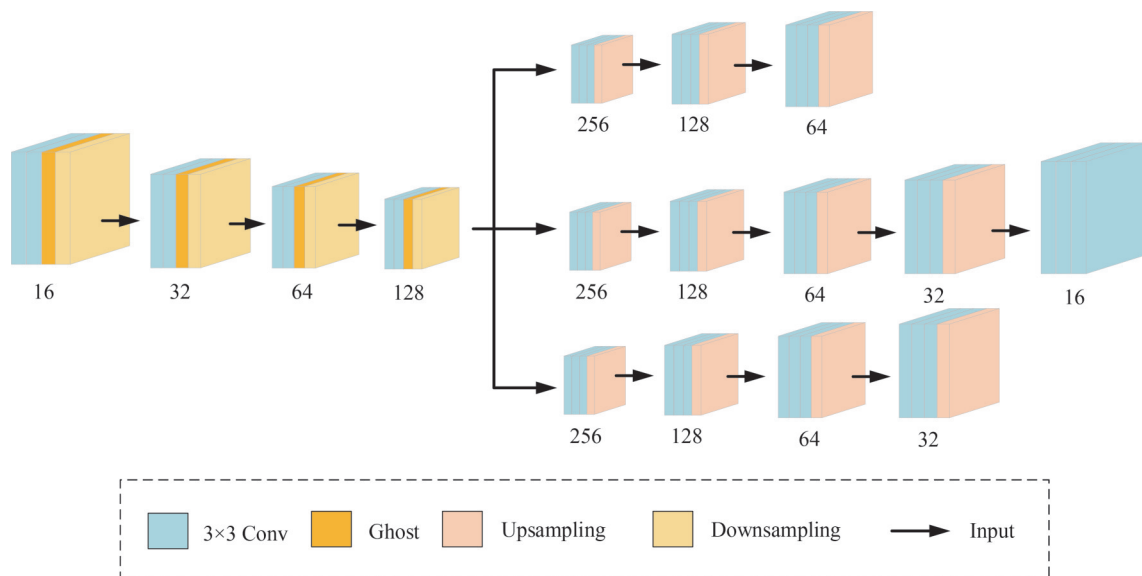


图3 多尺度生成器结构

Fig.3 Structure of the multiscale generator

### 1.1.3 判别器

基于多尺度生成器考虑多维度的图像特征,同样从多尺度特征的角度考虑对基础的PatchGAN判别器进行修改。在保留全卷积层的前提下,对输入判别器的图像进行四次卷积和最大池化操作并保存每次卷积和池化操作后的结果,即保存四张特征图;然后,对这四张特征图按照从小到大的顺序进行反卷积上采样及加和操作,使经过操作后的图像大小与输入判别器的图像大小相一致;最后,经过充当全连接层作用的 $1 \times 1$ 的卷积将图像输出。通过先下采样再上采样的操作在保证分辨率不变前提下过滤掉冗余信息。同时,考虑到生成器骨干架构由三维U-Net分割网络构成,因此对判别器进行升维处理,即将二维PatchGAN升为三维。经过对判别器的修改,通过增强判别器的判别能力进而使分割网络获得更好的分割效果。修改后的判别器具体结构如图4。

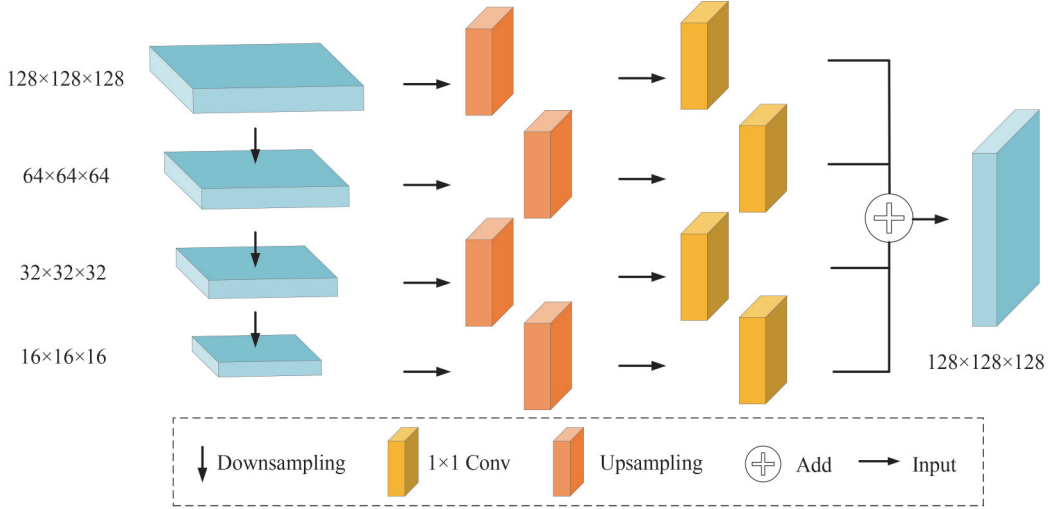


图4 判别器结构

Fig.4 Structure of the discriminator

## 1.2 损失函数

在脑肿瘤分割网络模型的训练过程中,损失函数起到约束和指导的重要作用。损失函数由对立(adversarial)损失函数  $L_{adv}$  与 Dice 损失函数  $L_{DC}$  两部分构成。其中,对立损失可以尽可能地使生成器生成的图像更接近于真实的数据分布,而 Dice 损失是一种常用于医学影像分析中解决类不平衡问题的损失函数。其计算表达式分别为

$$L_{adv}(\theta_G; \theta_C; y) = y \left[ - \sum_{a \in H} \sum_{b \in W} \left\{ (1 - \eta) \log(\psi(Y)[a, b]) + \eta \log(1 - \psi(\hat{Y})[a, b]) \right\} \right] \quad (1)$$

$$L_{DC} = 1 - \frac{2 \sum_{i=0}^N y_i \hat{y}_i}{\sum_{i=0}^N (y_i + \hat{y}_i)} \quad (2)$$

式中,  $y$  表示真值图像,  $\theta_C$  表示生成器生成图像,  $\theta_C$  用于判别样本的真伪,  $\hat{y}$  表示预测的分割结果,  $N$  为样本标签总数。

损失函数分为两部分,第一部分先使用生成器的输出、判别器的输出与真值图像计算对立损失函数  $L_{adv}$ , 进行第一次反向传播更新生成器网络中的参数;第二部分由生成器的输出与真值图像计算 Dice 损失函数  $L_{DC}$ 。此后,将两部分损失函数乘 0.5 的权重系数并进行相加,完整的损失函数  $L_{oss}$  可表示为

$$L_{oss} = 0.5 \times L_{adv} + 0.5 \times L_{DC} \quad (3)$$

## 2 实验与结果

### 2.1 实验环境与配置

MG2AN 是基于 Pytorch 深度学习框架进行开发,实验硬件环境配置为 1 个 Intel(R) Xeon(R) Gold 5222 CPU @3.80 GHZ、1 个 Nvidia RTX3090 GPU 显卡(24 GB)和 32 GB 双通道内存。实验中,网络的迭代次数设置为 1 000,批数大小设置为 4,采用 Adam 优化器,学习率为指数型衰减,初始学习率为 0.001,动量为 0.95,权重衰减系数为  $1 \times 10^{-5}$ 。

### 2.2 数据集与预处理

采用公开的 BraTS 2019 和 BraTS 2020 脑肿瘤分割数据集对所提方法进行评估。BraTS 2019 和 BraTS 2020 数据集包括训练集与验证集,其中训练集图像是由专业医师手动标注的脑肿瘤分割结果,包含健康部位(标签 0)、坏死区域(标签 1)、水肿区域(标签 2)和增强肿瘤(标签 4)四类。验证集的分割标签并不公开,为提高方法评估的公平性,研究者需要将验证集的分割图像结果上传至在线平台进行评估,进而由在线评估平台返回方法评测的指标数值结果。

在 MRI 脑肿瘤数据集规模上, BraTS2019 的训练集包含 259 个高级胶质瘤病例和 76 个低级胶质瘤病

例,验证集则包含 125 个未知肿瘤样本;BraTS2020 的训练集则包含 293 个高级胶质瘤病例和 76 个低级胶质瘤病例,其验证集同样包含 125 个未知肿瘤样本。每个脑肿瘤数据样本分别包含大小为  $240 \times 240 \times 155$  的 T1、T1ce、T2 和 Flair 四个模态,如图 5。此外,用于评估 MRI 脑肿瘤分割的三个区域分别是全部肿瘤(Whole Tumor, WT)、肿瘤核心(Tumor Core, TC)和增强肿瘤(Enhancing Tumor, ET),其中 WT 包含标签 1、2、4,TC 包含标签 1、4,ET 包含标签 4。




图 5 四种模态与真值图像的脑肿瘤 MRI

Fig.5 MRI images in different modes and ground truth

在脑肿瘤图像预处理上,由于 BraTS 数据集中每个样本涉及四个模态图像,不同模态和不同样本的肿瘤图像数据灰度和对比度均存在明显差异,这在很大程度上会影响脑肿瘤分割的精度。为此,采用 Z-score 归一化操作来对脑肿瘤数据进行标准化处理。同时,由于脑肿瘤样本数据量相对较少,为提高方法分割精度与泛化性,也采用沿各轴向的随机旋转、翻转对脑肿瘤图像数据进行增强。此外,由于脑肿瘤图像中存在大量无用背景和类别不平衡等问题,将原始图像数据裁剪为  $4 \times 128 \times 128 \times 128$  尺寸大小作为网络输入以减少相关影响。

### 2.3 评价标准

采用 Dice 相似系数(Dice Similarity Coefficient, DSC)和 Hausdorff 距离两个代表性评价指标来评估网络模型性能。其中,Dice 相似系数主要用来评估模型分割图像与真值分割图像(Ground Truth)之间的重合程度,其取值范围是  $0 \sim 1$ ,数字越大代表两个图像之间越接近,模型的分割效果也越好。Dice 相似系数计算表达式为

$$D_{\text{icescore}} = \frac{2TP}{FP + 2TP + FN} \quad (4)$$

式中,TP、FP 和 FN 分别代表正确预测为肿瘤的体素个数、错误预测为肿瘤的体素个数和错误预测为非肿瘤的体素个数。

Hausdorff 距离是用来评估两个图像边界之间的最大距离,为了消除离群值的一个非常小的子集的影响,一般会将计算出的结果乘以 95%,即 Hausdorff95。数字越小代表两个图像边界之间的距离越小,即两个图像的相似度越接近,可表示为

$$HD(T, P) = \max \left\{ \begin{array}{l} \sup_{t \in T} \inf_{p \in P} d(t, p) \\ \sup_{p \in P} \inf_{t \in T} d(t, p) \end{array} \right\} \quad (5)$$

式中, sup 和 inf 分别代表取上限函数和取下限函数,  $T$  和  $P$  分别代表真值区域和预测区域,  $t$  和  $p$  分别是两个区域上的点。  $d(t, p)$  表示计算点  $t$  与点  $p$  的距离函数。

### 2.4 实验结果与分析

为验证所提出方法的有效性,首先在 BraTS2020 的训练集与验证集上进行消融实验,并与原始分割网

络进行对比;同时,为验证所提出网络模型的泛化性能,在 BraTS2019 和 BraTS2020 验证集上与其他模型进行对比;最后,通过展示部分可视化分割结果进一步说明 MG2AN 的有效性。

#### 2.4.1 消融实验结果

为验证所提出 MG2AN 模型的有效性,首先选择在 BraTS2020 数据集的训练集与验证集上进行消融实验。使用三维 U-Net 作为基线方法,在此基础上将基线网络作为生成对抗网络中的生成器部分,再引入多尺度生成器和伪影模块进行结果验证。为方便各个模型之间的比较,用 GU-Net 表示三维生成对抗网络模型,用 +Ghost 和 +Mul 分别表示添加伪影模块和修改多尺度生成器。

在 BraTS2020 训练集的消融实验中,将训练集的数据 8:2 随机分配,考虑到进行实验的时间成本较高,重复两次实验取平均值来得到消融实验结果,结果如表 1。其中,基线模型在 ET、WT 和 TC 上的 DSC 分别为 78.4%、90% 和 79.7%。相较于基线模型,将生成对抗网络引入到脑肿瘤分割的效果较为显著,GU-Net 分别在 ET、WT 和 TC 上提升了 4.2%、1.5% 和 3.0%,验证了生成对抗网络用于脑肿瘤分割的有效性。进一步,在 GU-Net 中加入伪影模块以及替换生成器为多尺度生成器,在 DSC 的平均值上分别比 GU-Net 提升了 0.3% 和 0.7%,表明了伪影模块和多尺度生成器的有效性。最后,同时将多尺度生成器与伪影模块添加到 GU-Net 中构建了最终的网络模型 MG2AN,在 ET、WT 和 TC 上的 DSC 分别为 82.5%、92.2% 和 85.4%,较基线网络平均提升了 4.0%,证明了 MG2AN 方法可以有效提升脑肿瘤的分割性能。

表 1 BraTS2020 训练集的消融实验  
Table 1 Ablation experiments on BraTS2020 training dataset

Methods	DSC			
	ET	WT	TC	Average
U-Net(baseline)	0.784	0.900	0.797	0.827
GU-Net	0.826	0.915	0.827	0.856
GU-Net+Ghost	0.821	0.921	0.835	0.859
GU-Net+Mul	0.824	0.920	0.846	0.863
MG2AN(ours)	0.825	0.922	0.854	0.867

为验证模型的有效性及其泛化性,在 BraTS2020 脑肿瘤分割验证集上进行相似的消融实验。实验中使用 BraTS2020 训练集的全部脑肿瘤图像数据进行训练,然后使用训练好的模型对 BraTS2020 验证集数据进行分割,最后将分割结果提交至 BraTS 在线评估平台进行评测,实验结果如表 2。可知,基线方法在 ET、WT、TC 上的 DSC 结果分别为 76.9%、89.4% 和 79.9%,平均值为 82.1%,引入生成对抗网络后在三个指标上分别提升了 0.2%、0.5% 和 0.4%,平均值提升了 0.3%。进一步在生成对抗网络中添加伪影模块和修改生成器为多尺度生成器,在 ET 和 WT 上两种方法均提升了 0.5% 和 0.7%,在 TC 上分别提升了 1% 和 2.2%,在平均值上分别提升了 0.7% 和 1.1%,证明了所采用的两种模块在脑肿瘤分割上的有效性。最后,同时将这两种模块引入生成对抗网络中,构建 MG2AN 分割模型,在 ET、WT 和 TC 上的结果分别为 78.2%、90.3% 和 82.6%,平均值为 83.7%。与基线方法进行对比分别提高了 1.3%、0.9% 和 2.7%,平均值提高 1.6%,证明了生成对抗网络架构与两种模块结合后的有效性。

表 2 BraTS2020 验证集的消融实验  
Table 2 Ablation experiments on BraTS2020 validation dataset

Methods	DSC			
	ET	WT	TC	Average
U-Net(baseline)	0.769	0.894	0.799	0.821
GU-Net	0.771	0.899	0.803	0.824
GU-Net+Ghost	0.774	0.901	0.809	0.828
GU-Net+Mul	0.774	0.901	0.821	0.832
MG2AN(ours)	0.782	0.903	0.826	0.837

## 2.4.2 与代表性方法对比

为验证模型的有效性以及竞争力,在 BraTS2019 和 BraTS2020 验证集上将 MG2AN 与其他代表性脑肿瘤分割方法进行对比,比较结果如表 3 和表 4。

表 3 BraTS2019 验证集上与代表性方法对比结果  
Table 3 Compared results with representative methods on BraTS2019 validation set

Methods	DSC				Hausdorff95			
	ET	WT	TC	Average	ET	WT	TC	Average
Ref. [11]	0.707	0.878	0.779	0.788	-	-	-	-
Ref. [14]	0.709	0.873	0.814	0.799	12.30	15.45	12.47	13.40
Ref. [15]	0.789	0.900	0.819	0.836	3.73	5.64	6.05	5.14
Ref. [17]	0.767	0.897	0.790	0.818	4.61	6.92	8.40	6.64
Ref. [23]	0.752	0.899	0.815	0.822	12.56	7.39	8.06	9.34
MG2AN	0.770	0.902	0.836	0.836	3.74	7.06	5.55	5.45

表 4 BraTS2020 验证集上与代表性方法对比结果  
Table 4 Compared results with representative methods on BraTS2020 validation set

Methods	DSC				Hausdorff95			
	ET	WT	TC	Average	ET	WT	TC	Average
Ref. [12]	0.760	0.900	0.800	0.820	26.8	5.25	12.4	14.82
Ref. [13]	0.763	0.899	0.816	0.826	33.26	5.28	7.74	15.43
Ref. [15]	0.787	0.901	0.817	0.835	17.95	4.96	9.77	10.89
Ref. [18]	0.787	0.872	0.811	0.823	24.36	6.44	18.95	16.58
Ref. [23]	0.764	0.899	0.810	0.824	32.56	7.39	12.06	17.33
MG2AN	0.782	0.903	0.826	0.837	29.41	4.54	8.91	13.43

由表 3 可知, MG2AN 在 BraTS2019 验证集上分别在 ET、WT 和 TC 上可以得到 77.0%、90.2% 和 83.6% 的结果, 平均值为 83.6%。在进行比较的具体脑肿瘤分割模型上, 文献[11]使用两种跨阶段网络提取特征信息, 文献[14]采用一种融合损失函数的三维 U-Net++ 网络进行分割, 与这些模型相比 MG2AN 在 ET、WT 和 TC 上都有明显的性能优势; 此外, 文献[15]基于 Transformer 的脑肿瘤分割模型, 虽然在结果与所提出方法相当, 但其需要远高于 MG2AN 数倍的计算资源与训练时间来获得稳定的结果。与其他采用生成对抗分割网络的脑肿瘤分割方法对比, 文献[17]采用生成器为三维 FCN 的生成对抗分割网络架构, 在 ET、WT、TC 上的 DSC 值分别是 76.7%、89.7%、79.0%, 本文方法在 ET 和 WT 上与其相差不大, 但在 TC 上高于该网络 4.9%, 大幅提升了在 TC 上的分割性能。由于文献[23]只在论文中给出基于 BraTS2021 验证集的实验结果, 所以表 3、4 中的结果是经网络复现后于 BraTS2019-2020 验证集的结果。文献[23]采用带 VAT 模块的三维 U-Net 作为生成器的网络架构, 本文方法在 ET 和 TC 上分别领先 1.8% 和 2.1%, 优势明显。综合对比两种评估方式的结果, MG2AN 在 Hausdorff95 结果中排名第二, DSC 结果排名第一, 证明本文方法具有良好的竞争性。

在 BraTS2020 脑肿瘤图像验证集的对比实验结果中, 与文献[12]和文献[13]提出的网络进行对比, MG2AN 在整体上具有较为明显的优势。此外, 在与文献[15]提出的基于 Transformer 的 TransBTS 模型对比上, MG2AN 在 WT 和 TC 的 DSC 值上也仍有一定优势, 分别领先 0.2% 和 1.1%。因此, 与上述典型分割方法相比本文方法具有良好的竞争力。此外, 在生成对抗分割网络的对比上, 文献[18]提出把 Pix2PixGAN<sup>[21]</sup>的思想引入脑肿瘤生成对抗分割网络中; 文献[23]提出生成器后添加 VAT 模块, 使生成器生成的图像先进入 VAT 模块中进行优化再进入判别器中进行判别。相比于文献[23]的生成对抗脑肿瘤分割网络, MG2AN 分别在平均值上领先 1.3% 和 1.4%。从 Hausdorff95 结果上看, MG2AN 在 WT 上可以达到 4.54, 是所有网络中的第一名, 综合平均值来看在所有网络中排第二名。总体来讲, MG2AN 与其他代表方法相比体现出了良好的竞争性, 也表明了该方法用于脑肿瘤分割任务的有效性。



### 2.4.3 结果可视化

为更直观地展示对脑肿瘤图像的分割结果,将BraTS2020训练集中中部分典型脑肿瘤图像的MG2AN、三维U-Net分割结果进行可视化展示,并将肿瘤区域放大使用黑色线条标出MG2AN优于三维U-Net的分割结果位置,同时添加真值图像和Flair图像从右到左排列更方便比较,可视化分割结果如图6。

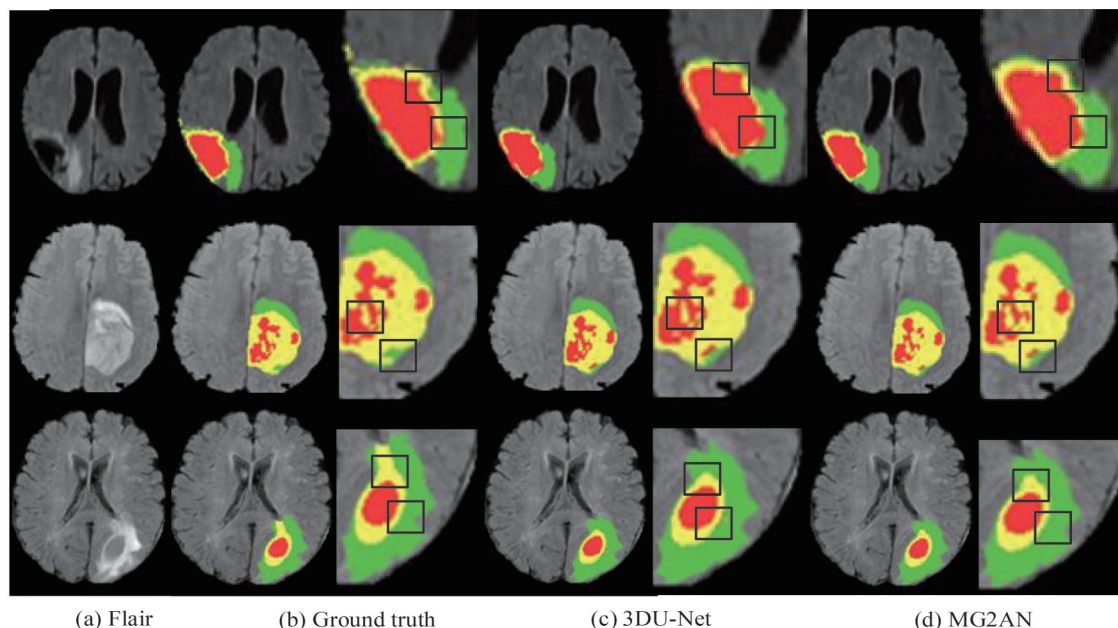


图6 BraTS 2020训练集分割结果可视化示例  
Fig.6 Visualization segmentation results on the BraTS 2020 training dataset

图中绿色、黄色和红色部分分别代表水肿区域、增强肿瘤区域和坏死区域。通过观察分割结果实例,在与真值图像进行对比后,发现MG2AN和三维U-Net在这几个肿瘤图像上均能够获得较好的分割结果,表明这两个方法在脑肿瘤分割任务是有效的。同时,通过观察黑框标出区域,第一行图像肿瘤红色区域右上侧与右下侧和第二行图像肿瘤红色区域中间部分与右下侧MG2AN分割图像明显更接近于真值结果,第三行图像肿瘤黄色区域上半部分更接近于真值结果。整体上看,特别是在肿瘤边缘的细微位置上,MG2AN分割结果图像要优于三维U-Net分割结果图,表明了MG2AN在该任务上具有更好的分割性能。

## 3 结论

本文提出了一种以三维U-Net为基础的三维生成对抗脑肿瘤分割网络,通过在三维生成对抗网络中同时引入伪影模块和多尺度特征融合机制,利用生成网络的高质量图像生成特性来监督脑肿瘤分割网络的训练,同时伪影信息也有效提高了网络的脑肿瘤分割能力。在两个权威的脑肿瘤分割数据集上的消融实验与对比实验的结果证明了所提方法的有效性。在今后的工作中,一方面将在生成对抗网络架构下探索更有效的适用于脑肿瘤分割任务的生成网络模型;另一方面,考虑将近年来新兴的生成网络模型—扩散模型引入到MRI脑肿瘤分割任务中,探索扩散模型在该医学任务中的效果并与生成对抗网络模型做深入对比。

### 参考文献

- [1] BAKAS S, AKBARI H, SOTIRAS A, et al. Advancing the cancer genome atlas glioma MRI collections with expert segmentation labels and radiomic features[J]. Scientific Data, 2017, 4(1): 1-13.
- [2] QI Xingbin, ZHAO Li, LI Xuemei, et al. Automatic segmentation of T2 weighted brain MRI based on histogram gradient calculation.[J]. Application Research of Computers, 2015, 32(5):1576-1579.  
齐兴斌,赵丽,李雪梅,等.基于直方图梯度计算的T2加权脑部MR图像自动分割[J].计算机应用研究,2015,32(5):1576-1579.
- [3] NEMA S, DUDHANE A, MURALA S, et al. RescueNet: AN unpaired GAN for brain tumor segmentation[J]. Biomedical Signal Processing and Control, 2020, 55:101641.

- [4] ZHANG Y, MATUSZEWSKI B J, SHARK L K. A novel medical image segmentation method using dynamic programming[C]. International Conference on Medical Information Visualization Biomedical Visualization, 2007:69-74.
- [5] LONG J, SHELHAMER E, DARRELL T. Fully convolution networks for semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015:3431-3440.
- [6] 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.
- [7] ZHOU Tao, DONG Yali, LIU Shan, et al. Cross-modality multi-encoder hybrid attention U-Net for lung tumors images segmentation[J]. Acta Photonica Sinica, 2022, 51(4):376-392.  
周涛, 董雅丽, 刘珊, 等. 用于肺部肿瘤图像分割的跨模态多编码混合注意力 U-Net[J]. 光子学报, 2022, 51(4): 376-392.
- [8] HUANG Hong, LÜ Rongfei, TAO Junli, et al. Segmentation of lung nodules in CT images using improved UNet++[J]. Acta Photonica Sinica, 2021, 50(2):73-83.  
黄鸿, 吕容飞, 陶俊利, 等. 基于改进 U-Net++ 的 CT 影像肺结节分割算法[J]. 光子学报, 2021, 50(2):73-83.
- [9] ÇICEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation[C]. International Conference on Medical Image Computing and Computer-assisted Intervention, 2016: 424-432.
- [10] SUN J, PENG Y, LI D, et al. Segmentation of the multimodal brain tumor images used Res-U-Net[C]. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 6th International Workshop, BrainLes 2020, 2021: 263-273.
- [11] XIA Feng, SHAO Haijian, DENG Xing. Cross-stage deep-learning-based MRI fused images of human brain tumor segmentation[J]. Journal of Image and Graphics, 2022, 27(3):873-884.  
夏峰, 邵海见, 邓星. 融合跨阶段深度学习的脑肿瘤 MRI 图像分割[J]. 中国图象图形学报, 2022, 27(3):873-884.
- [12] MCKINLEY R, REBSAMEN M, DÄTWYLER K, et al. Uncertainty-driven refinement of tumor-core segmentation using 3d-to-2d networks with label uncertainty[C]. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 6th International Workshop, BrainLes 2020, 2021: 401-411.
- [13] PEI L, MURAT A K, COLEN R. Multimodal brain tumor segmentation and survival prediction using a 3D self-ensemble ResUNet[C]. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 6th International Workshop, BrainLes 2020, 2021: 367-375.
- [14] ZHANG Xiaoyu, WANG Bin, AN Weichao, et al. Glioma segmentation network based on 3DU-Net++ with fusion loss function[J]. Computer Science, 2021, 48(9):187-193.  
张晓宇, 王彬, 安卫超, 等. 基于融合损失函数的 3D U-Net++ 脑胶质瘤分割网络[J]. 计算机科学, 2021, 48(9): 187-193.
- [15] WANG W, CHEN C, DING M, et al. Transbts: multimodal brain tumor segmentation using transformer[C]. Medical Image Computing and Computer Assisted Intervention-MICCAI 2021: 24th International Conference, 2021: 109-119.
- [16] XUE Y, XU T, ZHANG H, et al. SegAN: adversarial network with multi-scale L1 loss for medical image segmentation [J]. Neuroinformatics, 2018:382-392.
- [17] HAMGHALAM M, LEI B, WANG T. Brain tumor synthetic segmentation in 3D multimodal MRI scans[C]. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 5th International Workshop, BrainLes 2019, 2020: 153-162.
- [18] CIRILLO M D, ABRAMIAN D, EKLUND A. Vox2Vox: 3D-GAN for brain tumour segmentation[C]. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 6th International Workshop, BrainLes 2020, 2021: 274-284.
- [19] NEMA S, DUDHANE A, MURALA S, et al. RescueNet: an unpaired GAN for brain tumor segmentation [J]. Biomedical Signal Processing and Control, 2020, 55:101641.
- [20] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1125-1134.
- [21] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2223-2232.
- [22] DING Y, ZHANG C, CAO M, et al. ToStaGAN: an end-to-end two-stage generative adversarial network for brain tumor segmentation[J]. Neurocomputing, 2021, 462: 141-153.
- [23] PEIRIS H, CHEN Z, EGAN G, et al. Reciprocal adversarial learning for brain tumor segmentation: a solution to BraTS challenge 2021 segmentation task[C]. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 7th International Workshop, 2022: 171-181.
- [24] HAN K, WANG Y, TIAN Q, et al. Ghostnet: more features from cheap operations[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580-1589.
- [25] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications[J]. arXiv Preprint, 2017, arXiv:1704.04861.

## Magnetic Resonance Imaging Brain Tumor Segmentation Using Multiscale Ghost Generative Adversarial Network

ZHANG Muqing<sup>1,2</sup>, HAN Yutong<sup>1,2</sup>, CHEN Bonian<sup>1,2</sup>, ZHANG Jianxin<sup>1,2</sup>

(1 School of Computer Science and Engineering, Dalian Minzu University, Dalian 116600, China)

(2 Institute of Machine Intelligence and Biocomputing, Dalian Minzu University, Dalian 116600, China)

**Abstract:** Brain tumors are abnormal cells that grow in the brain or skull, and malignant brain tumors always cause great danger to the life and health of patients. Magnetic Resonance Imaging (MRI) can produce high-quality brain images without damage and skull artifacts, and it is currently one of the main technologies for the diagnosis and treatment of brain tumors. Meanwhile, the automatic segmentation of MRI brain tumor lesion regions is of great significance for the clinical diagnosis, surgical planning, and postoperative evaluation of brain tumor patients. However, due to the complexity and diversity of brain tumor images and the difficulty in obtaining the large-scale high-quality brain tumor segmentation dataset, it is still a difficult task to achieve high-precision automatic segmentation of MRI brain tumors. In recent years, with the breakthrough development of deep learning in computer vision tasks, it has also been successfully applied in the field of medical image analysis, and has achieved significant performance improvement in a number of medical image analysis tasks. Among them, U-Net, with its simple architecture and high performance, has become a mainstream model to solve a series of medical image segmentation tasks, including brain tumor segmentation. To this end, according to the advantages of the U-Net network architecture, focusing on issues of large variation of tumor spatial information and small number of finely labeled samples, a novel brain tumor image segmentation method, called Multi-scale Ghost Generation Adversarial Network (MG2AN), is proposed by combining U-Net with unsupervised generative adversarial network. MG2AN leverages the 3D U-Net model as a generator to obtain brain tumor segmentation results, and introduces 3D PatchGAN corresponding to multi-scale feature information of the generator as a discriminator to judge brain tumor segmentation results and ground truth, and the whole model is trained by adversarial learning. To improve the MRI brain tumor segmentation effect, a ghost module is introduced in the encoding stage of the generator, so that the ghost image and convolution feature map can be captured simultaneously during the convolution process, thus improving the brain tumor generation results of the generator. Considering the computational cost and the degree of information loss, the ghost module is only introduced in the final stage of the encoder. Meanwhile, multi-scale feature fusion is proposed in the decoding process to obtain three different brain tumor segmentation results for detail information, local information and global information, and then three kind of feature information for different emphasis are fused to further boost the segmentation performance in adversarial learning. To train the model, the loss of generated adversarial segmentation network is first back-propagated during the training process, and the new loss value is calculated based on the brain tumor segmentation results with the ground truth. Then, the two parts of the loss value are combined into the final loss value to jointly supervise the network. In addition, considering the obvious differences in grayscale and contrast of brain tumor images from different modalities, the Z-score method is utilized to normalize the image data in preprocessing. Meanwhile, to reduce the influence of large amount of useless background information in brain tumor images, the multi-modal 3D MRI brain tumor images are randomly cropped to a size of  $128 \times 128 \times 128$  as the input of the network. The data augmentation strategies such as random flip and intensity transformation are also adopted to guarantee the segmentation accuracy and generalizability of the model. The proposed MG2AN model is extensively evaluated on the public BraTS2019 and BraTS2020 brain tumor image datasets via ablation experiments, comparison experiments, and visualization results. The dice values of whole-tumor, core-tumor, and enhanced-tumor segmentation obtained by MG2AN on the BraTS2019 validation set are 0.902, 0.836, and 0.77, respectively. Meanwhile, the corresponding dice values on the BraTS2020 training and validation data sets are 0.902/

0.903, 0.836/0.826 and 0.77/0.782, respectively. Compared with the baseline network, the dice values of MG2AN on the BraTS2020 training and validation data sets increase by 4.1%/1.3%, 2.2%/0.9% and 5.7%/2.7% on the whole tumor, core tumor and enhanced tumor, respectively, demonstrating the effectiveness of introducing generative adversarial networks and the improved generators. When comparing MG2AN with the state-of-the-art methods in the field of brain tumor segmentation, it can show comparable or better performance by considering both dice and Hausdorff 95 evaluation results. Finally, it also can be carried out that the segmentation effectiveness of MG2AN model is better than the baseline model in the visual evaluation of brain tumor segmentation. Therefore, the comprehensive experimental evaluation and analysis results demonstrate the effectiveness of the proposed MG2AN for the brain tumor segmentation task.

**Key words:** Brain tumor segmentation; 3D U-Net; Generative adversarial network; Ghost feature; Multi-scale feature fusion

**OCIS Codes:** 170.3880; 100.4996; 100.2960; 100.2000