

# 基于动态卷积的多模态脑 MR 图像生成<sup>①</sup>



孙君顶, 杨鸿章, 闫艺丹, 毋小省, 唐朝生

(河南理工大学 计算机科学与技术学院, 焦作 454000)

通信作者: 唐朝生, E-mail: tcs@hpu.edu.cn

**摘要:** 近年来, 通过自动生成方法获取多模态 MR 图像得到了广泛研究, 但仍难以通过一种模态直接生成其他各类模态的图像. 针对该问题, 本文提出了动态生成对抗网络. 新模型通过将生成对抗网络与动态卷积相结合, 同时加入任务标签这一条件, 实现从一种 MR 模态同时生成其他 3 种 MR 模态. 同时为了提高图像生成质量, 进一步提出了多尺度判别策略, 通过融合多个尺度来提升判别效果. 基于 BRATS19 数据集进行生成验证, 实验结果表明, 新方法不但可以同时生成多种模态的数据, 而且提高了生成图像的质量.

**关键词:** 图像生成; 多模态; 动态卷积; 动态生成对抗网络; 多尺度判别器; 深度学习; 生成对抗网络

引用格式: 孙君顶, 杨鸿章, 闫艺丹, 毋小省, 唐朝生. 基于动态卷积的多模态脑 MR 图像生成. 计算机系统应用, 2022, 31(8): 305-313. <http://www.c-s-a.org.cn/1003-3254/8663.html>

## Multi-modality Brain MR Images Synthesis Based on Dynamic Convolution

SUN Jun-Ding, YANG Hong-Zhang, YAN Yi-Dan, WU Xiao-Sheng, TANG Chao-Sheng

(School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 454000, China)

**Abstract:** In recent years, obtaining multi-modality magnetic resonance (MR) images with automatic generation methods has been widely studied. However, it is still difficult to generate images of all the other modalities by one given modality. To solve this problem, this study proposes a dynamic generative adversarial network (DyGAN) model. By combining the generative adversarial network and dynamic convolution and introducing a task label, the new model can simultaneously generate other three MR modalities from one modality. In addition, a multi-scale discrimination strategy is further proposed to improve the quality of image generation by fusing multiple scales. Image generation is verified on the BRATS19 dataset. The experimental results show that the new method can not only simultaneously generate multi-modality images but also improve the quality of the generated images.

**Key words:** image synthesis; multi-modality; dynamic convolution; dynamic generative adversarial network (DyGAN); multi-scale discriminator; deep learning; generative adversarial network (GAN)

## 1 引言

脑胶质瘤是最常见的原发性颅内肿瘤, 占恶性脑肿瘤的 81%, 虽然相对罕见, 但却造成了显著的死亡率<sup>[1]</sup>. 为了进行有效的治疗, 获取清晰和准确的医学影像是前提. 由于 MR 图像可以提供大脑精细的细节结构, 且不同模态 (T1、T2、T1CE、FLAIR) 的 MR 图像可以从不同的角度反映脑肿瘤引起的组织变化, 因此常用

于脑肿瘤的检测和脑部疾病的诊断<sup>[2,3]</sup>. 然而, 在医学上获取多模态数据存在着费时、价格昂贵和设备缺乏等问题, 使得多模态数据存在缺失<sup>[4,5]</sup>. 因此, 如何通过其他简单的方法获得多模态数据成为了近来研究的热点.

近年来, 随着生成对抗网络 (generative adversarial networks, GAN)<sup>[6]</sup> 的提出, 引起了学者们对图像生成的广泛研究, 尤其是在图像缺乏的医学领域<sup>[7]</sup>. 基于

① 基金项目: 河南省科技厅科技攻关项目 (212102310084); 河南省高等学校重点科研项目 (22A520027)

收稿时间: 2021-11-28; 修改时间: 2021-12-29; 采用时间: 2022-01-06; csa 在线出版时间: 2022-05-30

GAN, 研究人员提出了多种图像合成方法. Radford 等人提出了深度卷积生成对抗网络 (deep convolutional generative adversarial networks, DCGAN)<sup>[8]</sup>, 它将卷积神经网络应用于 GAN 中的生成器和判别器, 使得 GAN 可以更好地生成图像数据. Frid-Adar 等人<sup>[9]</sup> 基于 DCGAN 生成肝脏 CT 不同类别的病变斑块, Bermudez 等人<sup>[10]</sup> 基于 DCGAN 在少量数据集上生成了人眼无法辨别真假的脑 MR 图像. 由于 DCGAN 无法控制输出图像的种类, Mirza 等人提出了条件生成对抗网络 (conditional generative adversarial networks, CGAN)<sup>[11]</sup>, 通过在生成器中加入了条件输入, 从而有效控制输出不同类别的数据. 在 CGAN 中, pix2pix<sup>[12]</sup> 将输入的噪声向量和条件统一用一张图像来代替, 从而为配对的图像转换领域提供了一个通用的框架. 例如, Dar 等人<sup>[13]</sup> 采用 pix2pix 来实现 T1 和 T2 脑 MR 图像的跨模态转换, Yu 等人<sup>[14]</sup> 通过整合边缘信息来改善 pix2pix 的 MR 图像生成结果. 为了提高图像生成质量, Pix2PixHD<sup>[15]</sup> 在构造判别器时考虑了多尺度因素, 为每一个尺度的特征图分别训练一个判别器. 鉴于 pix2pix 无法解决无配对的图像转换问题, Zhu 等人提出了 CycleGAN<sup>[16]</sup>, 它无需配对的图像便可以实现跨模态转换. 例如, Wolterink 等人<sup>[17]</sup> 使用 CycleGAN 将 2D MR 图像转换为 CT 图像; Chartsias 等人<sup>[18]</sup> 将 CycleGAN 用于未配对的图像到图像转换, 将心脏 CT 切片和分割图像生成心脏 MR 图像及其相应的分割掩模; Jiang 等人<sup>[19]</sup> 提出了一种肿瘤感知损失函数用于 CycleGAN, 实现 CT 图像生成 MR 图像.

但是, 上述的方法只解决了诸如数据稀缺和单一模态的图像生成问题, 而 MR 医学图像通常包含 4 种模态, 如果面临另外几种 (不只一种) 模态缺失的情况, 利用传统方法, 则需要通过多个网络来分别生成, 而训练多个网络必然带来计算资源浪费和可扩展性差的问题. 另一方面, GAN 的训练本身又具有脆弱和不稳定性<sup>[20,21]</sup>.

另一方面, 虽然卷积神经网络在诸多领域中取得了巨大成功, 但其性能的提升往往源于模型深度与宽度的增加, 这将导致计算量的提升. 近年来, 动态卷积<sup>[22]</sup> 由于其能够在不增加网络深度或宽度的情况下提高模型的表达能力, 因此一经推出, 便得到了广泛研究<sup>[23-26]</sup>. 动态卷积可以自适应的为每个输入学习自己的卷积核参数, 如 Yang 等人<sup>[23]</sup>、Chen 等人<sup>[24]</sup> 和 Zhang 等人<sup>[25]</sup> 提出通过注意力机制<sup>[27]</sup> 来自适应结合提前初

始化好的卷积权重、参数与注意力网络同时学习; Ma 等人<sup>[26]</sup> 提出在动态卷积 CondConv<sup>[23]</sup> 与注意力机制<sup>[27]</sup> 的基础上直接生成卷积权重. 近年来, 动态卷积已广泛应用于分类<sup>[23-26]</sup>、分割<sup>[28-30]</sup>、检测<sup>[23,24,26,31]</sup> 和语言翻译<sup>[32]</sup> 等领域, 但其在图像生成方面应用还很少.

基于上述问题, 我们将动态卷积和 GAN 结合用于多模态图像的生成, 提出了一种动态生成对抗网络 (dynamic GAN, DyGAN). 新网络通过在卷积核上加入条件, 来控制生成不同模态的图像所对应的卷积核参数, 实现由一种模态同时生成多种模态的 MR 图像. 同时, 为了提高图像生成的质量, 本文又提出了多尺度判别器, 通过在一个网络中同时分别进行多种不同深度的下采样, 实现了综合判别多个尺度特征图的真假. 采用 BRATS19 数据集进行图像生成实验, 实验结果证明了本文方法的有效性.

## 2 相关工作

### 2.1 pix2pix

pix2pix 在有配对的图像转换领域, 可以一对一的将一种模态转换成另一种模态. 它由一个生成器  $G$  和一个判别器  $D$  组成, 其训练过程如图 1 所示. 在训练图像  $x$  生成  $y$  的过程中,  $x$  输入生成器  $G$ , 生成器  $G$  则最大可能的生成和它所对应真实图像  $y$  相似的图像  $G(x)$ , 判别器  $D$  不仅负责判别生成的图像  $G(x)$  是否和  $y$  相似, 而且还要判别它是否和  $x$  配对. 这一判别过程是通过分别将真实图像  $x$  和生成图像  $G(x)$ 、真实图像  $x$  和真实图像  $y$  输入判别器  $D$  实现的, 只有输入  $\{x, y\}$  的组合, 判别器才会判断为真.

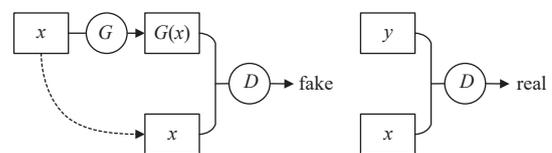


图 1 pix2pix 训练过程

但是, pix2pix 只能一对一的将一种模态转换成另外一种模态, 如果面临多种模态缺失的问题, 想要同时生成多种模态的 MR 图像, 则需要训练多个 pix2pix 网络才能实现. 如图 2(a) 所示, 如果将 T2 模态转化成其他 3 种模态 (FLAIR, T1, T1CE), 则需要分别训练 3 个 pix2pix 网络.

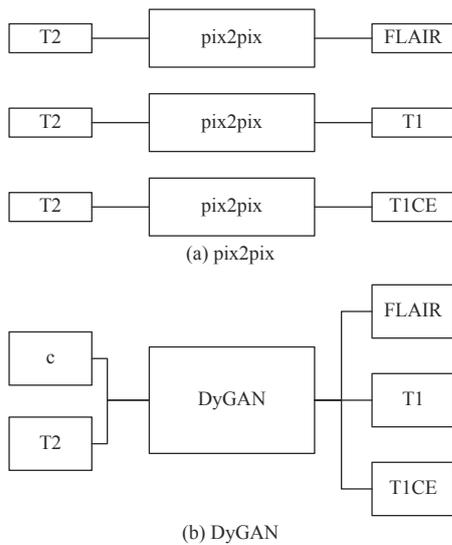


图2 DyGAN 与 pix2pix 多模态转化区别

### 2.2 CondConv

现有的动态卷积大致可以分为两类. 第一, 通过注意力机制来自适应的结合提前初始化好的卷积参数来完成动态变更, 如 Yang 等人<sup>[23]</sup> 和 Chen 等人<sup>[24]</sup> 提出的方法. 第二, 直接生成卷积参数, 如 Ma 等人<sup>[26]</sup> 提出的方法. 若在生成对抗网络中采用第 2 种方法, 会导致参数生成网络最后一层的神经元个数过多. 因此, 本文采用第 1 种动态卷积的方法.

在第 1 种动态卷积的方法中, 最具代表性的是 Yang 等人<sup>[23]</sup> 提出的 CondConv, 其结构如图 3 所示. 前一层输出的特征图 (prev layer output) 经过全局平均池化 (global average pooling, GAP) 后, 再经过注意力层 (attention), 最终生成  $w_1, w_2, w_3, \dots, w_n$  分别对应的权

重  $\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n$ . 其中,  $w_1, w_2, w_3, \dots, w_n$  为提前初始化好的卷积参数, 它们分别与对应的权重相乘然后再相加, 结合成一组新的参数  $W$ . 最后, 前一层的输出再与生成的  $W$  参数做卷积运算. 整个过程中  $w_1, w_2, w_3, \dots, w_n$  与注意力层同时学习和训练, 因而对于每一个不同的输入样例都会生成自己特定的权重.

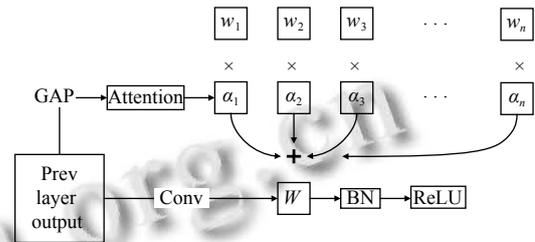


图3 CondConv 结构

## 3 动态生成对抗网络 (DyGAN)

### 3.1 网络结构

在配对的图像转换领域, pix2pix 虽然可以一对一的将一种模态的图像转换成另外一种模态, 但它却无法同时生成多种模态的图像. 针对该问题, 本文在 pix2pix 的基础上, 提出了动态生成对抗网络 DyGAN, 通过结合动态卷积, 并加入任务标签这一条件, 将不同的模态转换定义为不同的任务, 来控制生成器输出不同模态的图像. 如图 2(b) 所示, 如果将 T2 模态同时转化成其他 3 种模态, 只需在 DyGAN 的输入中加入“c”这一条件, 便可同时生成 3 种所需的模态. DyGAN 具体训练过程如图 4 所示, 图中以 T2 模态生成其他模态为例.

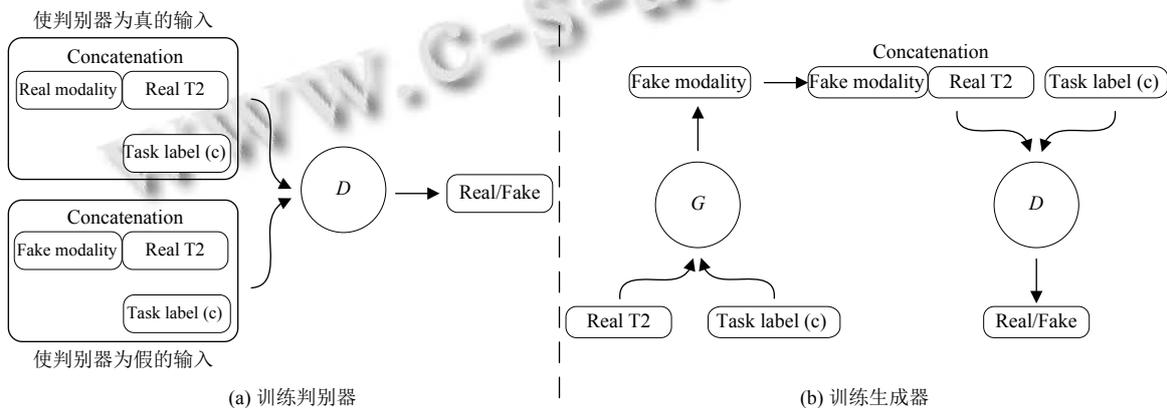


图4 DyGAN 训练过程

在训练判别器中, 上方矩形框中为使判别器判断为真的输入, 下方矩形框中为使判别器判断为假的输

入. 与 pix2pix 类似, 其他模态真实的图像 (real modality) 与真实的 T2 (real T2) 相结合, 同时输入判别器才为真.

相反,生成器生成其他模态的图像(fake modality)与真实的T2(real T2)相结合,输入判别器为假.与pix2pix不同的是判别器D还需要在任务标签(task label)的控制下,判断不同任务下图像的真假.在训练生成器中,在当前任务(task label)下,将真实的T2(real T2)输入生成器G,生成器G使生成的图像(fake modality)越来越接近真实,从而使判别器判断为真.

### 3.2 生成器网络框架

#### 3.2.1 多模态标签

在多任务多模态医学图像生成中,比如T2同时生成其他3种模态T1、T1CE和FLAIR,是同一张图像同时生成3种不同模态的医学图像.为此,我们通过对不同模态的图像编码,并将该编码作为输入的条件.MR医学图像通常有4种模态,由其中一种模态转化成另外3种模态可以有12种任务组合,我们分别对这12种任务分别进行one-hot编码,如表1所示.与StarGAN<sup>[33]</sup>和MGAN<sup>[4]</sup>在GAN中加入条件不同,它们都是在输入层直接控制在不同条件下的图像生成,所有输入共享一套卷积核参数.在本文方法中,不同条件控制生成的是不同的卷积核,不同模态的图像均有自己的卷积核参数.

表1 多模态任务编码

任务	one-hot编码
FLAIR生成T1	00000000001
FLAIR生成T1CE	00000000010
FLAIR生成T2	00000000100
T1生成FLAIR	000000001000
T1生成T1CE	000000010000
T1生成T2	000000100000
T1CE生成FLAIR	000001000000
T1CE生成T1	000010000000
T1CE生成T2	000100000000
T2生成FLAIR	001000000000
T2生成T1	010000000000
T2生成T1CE	100000000000

#### 3.2.2 DyConv 结构

本文提出的多模态动态卷积结构如图5所示.其中,图5(a)为动态卷积CondConv结构,图5(b)为任务标签模块,完成将不同的模态转换定义为不同的任务.将编码好的任务标签c分别与全局平均池化后的张量进行拼接,再经过注意力层,可以控制生成不同任务所对应的动态卷积参数.

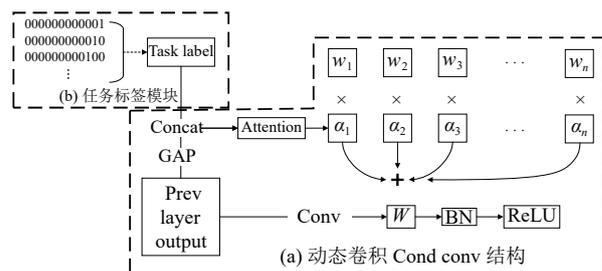


图5 DyConv 结构

#### 3.2.3 编码解码网络

本文生成器采用U-Net网络结构<sup>[34]</sup>,该网络分为4次下采样和4次上采样两部分.为了生成不同模态的图像,本文考虑采用DyConv来替代U-Net中的卷积.首先,进行了3种不同情况的测试:采用DyConv替代下采样卷积操作、采用DyConv替代上采样卷积操作、采用DyConv同时替代上下采样卷积操作3种情况,结果表明后两种情况的效果最好,而第2种情况的参数更少(可参见第4.4节实验部分).其次,因为输出的图像仅有一种模态,因此我们认为下采样过程仅采用卷积操作即可,在上采样过程采用动态卷积,即可实现生成不同模态的任务.为此,在本文的结构中,我们采用DyConv替代上采样过程中的卷积操作.其结构如图6所示.

### 3.3 判别器网络框架

在原生成对抗网络中,判别器仅输出一个值(真或假)来对整幅图像进行评价,显然缺乏对生成图像细节的评价.为了解决这一问题,pix2pix提出了PatchGAN<sup>[12]</sup>,通过把整幅图像平均分成多个块,首先针对每个块作评价,然后取所有块评价的均值作为最终评价结果,从而在一定程度上考虑了生成图像的细节.Pix2pixHD<sup>[15]</sup>在pix2pix的基础上,设计了3个具有相同结构的判别器,在3个不同尺度上分别判断生成图像的质量,但显然存在复杂度高的问题.

为此,在Pix2pixHD的基础上,本文提出在一个判别器中完成对3个不同大小尺度的特征图进行判别,其结构如图7所示.首先,生成的图像和真实的图像在通道上进行拼接,一起输入判别器,并进行3次步幅为2的下采样操作.其次,按照图7虚线框中所示的操作实现多尺度处理.在虚线框所示的结构中,第1层直接经过步幅为1的卷积操作.第2层经过一次步幅为2的下采样后再经过一次步幅为1的卷积操作,然后与

第1层进行拼接. 最后一层经过两次步幅为2的下采样操作, 再经过一次步幅为1的卷积, 然后与前两层进

行拼接. 第三, 经过步幅为1的卷积输出一个单通道的判别结果.

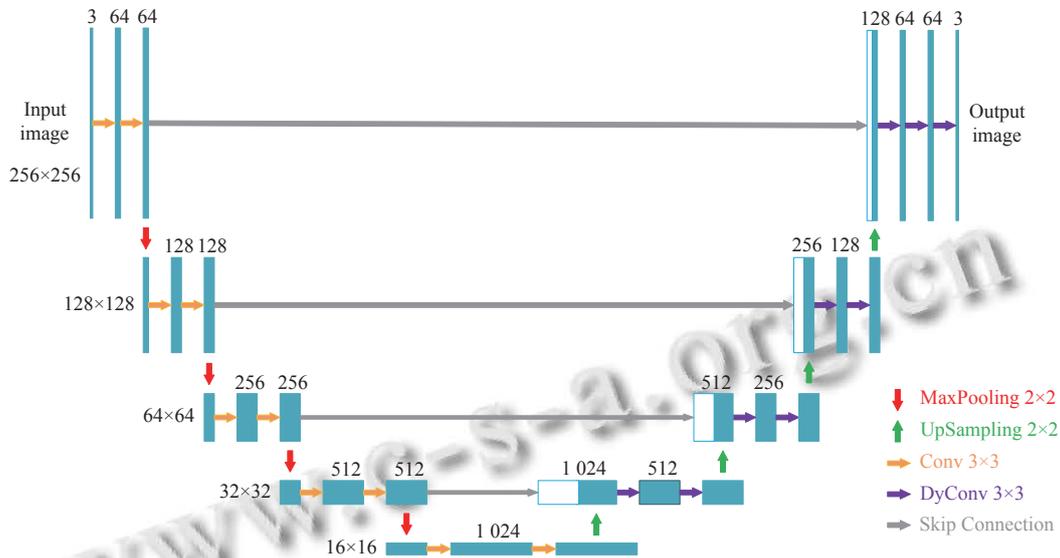


图6 编码解码网络

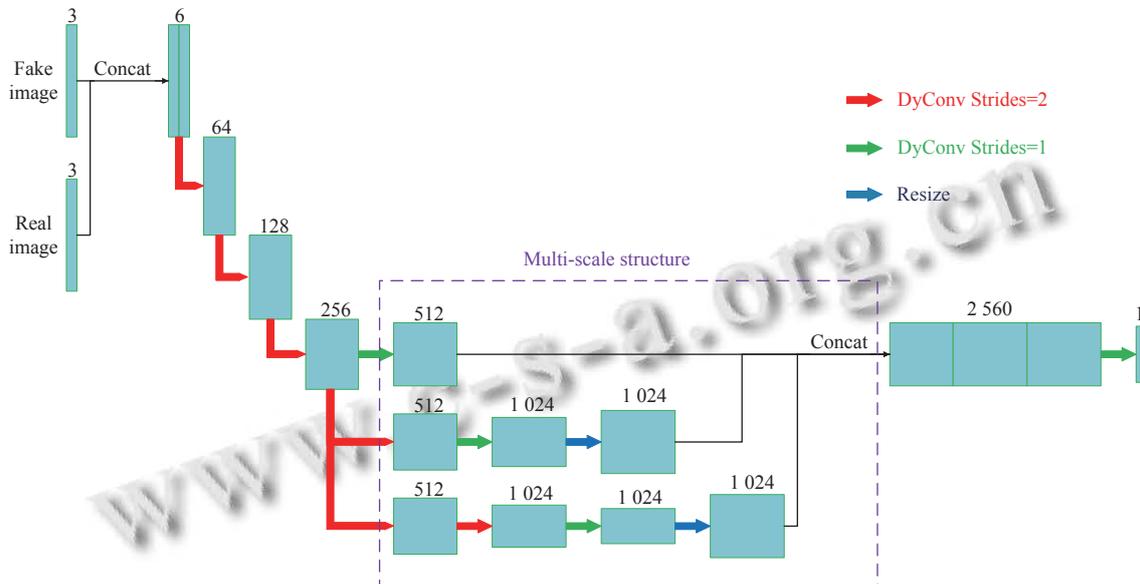


图7 多尺度判别器网络结构

同时, 结合上面的生成器结构, 本文又测试了仅在生成器采用 DyConv 以及在生成器与判别器中均使用 DyConv 两种情况. 结果发现生成器和判别器均采用 DyConv 效果更好, 实验结果见表 2. 因此, 我们在判别器中也采用 DyConv 替代了卷积操作, 文中将该方法简称为 MS\_DyGAN.

### 3.4 目标函数

本文应用 LSGAN<sup>[35]</sup> 中提出的目标函数, 其判别器和生成器的目标函数定义分别如下:

$$\min_D V_{LSGAN}(D) = \frac{1}{2} E_x [(D(x) - 1)^2] + \frac{1}{2} E_z [(D(G(z)))^2] \quad (1)$$

$$\min_G V_{LSGAN}(G) = \frac{1}{2} E_z [(D(G(z)) - 1)^2] \quad (2)$$

表2 多模态图像生成结果

方法	PSNR			SSIM		
	FLAIR	T1	T1CE	FLAIR	T1	T1CE
3*pix2pix	23.2853	22.4321	24.3262	<b>0.8782</b>	0.8932	0.8920
MGAN	23.2601	22.5030	24.2171	0.8614	0.8884	0.8745
DyGAN	23.6634	22.8382	<b>24.8458</b>	0.8765	0.8997	0.8980
Ms_DyGAN	<b>23.7781</b>	<b>22.9610</b>	24.6364	0.8767	<b>0.9000</b>	<b>0.8994</b>

由于本文基于 pix2pix 的方法, 训练网络需要配对的图像  $x$  和  $y$ , 且增加了任务标签“ $c$ ”这一输入, 为此我们定义了新的目标函数:

$$\begin{aligned} \min_D V_{GAN}(D) &= \frac{1}{2} E_{x,y,c} [(D((x,y),c) - 1)^2] \\ &+ \frac{1}{2} E_{x,c} [(D((x,G(x,c)),c) - 1)^2] \end{aligned} \quad (3)$$

$$\min_G V_{GAN}(G) = \frac{1}{2} E_{x,c} [(D((x,G(x,c)),c) - 1)^2] \quad (4)$$

同时, 为了增加生成图像的准确性, 我们进一步加入了  $L1$  损失.

$$L_{L1}(G) = E_{x,y,c} [\|y - G(x,c)\|_1] \quad (5)$$

最终, 新的目标函数定义为:

$$G^* = \min_G V_{GAN}(G) + \min_D V_{GAN}(D) + \lambda L_{L1}(G) \quad (6)$$

其中,  $\lambda$  为参数.

## 4 实验结果

### 4.1 数据集和实验设置

本文实验采用 BRATS19 数据集. 该数据集包含 259 个 HGG 病例和 76 个 LGG 病例. 其中每个病例均有配对的 T1、T2、T1CE 和 FLAIR 四种模态的 MR 图像, 图像大小为  $240 \times 240 \times 155$ . 实验选择 220 个 HGG 病例和 60 个 LGG 病例作为训练集, 剩余的 HGG 和 LGG 病例作为测试集. 对于每个  $240 \times 240 \times 155$  大小的图像, 我们从脑占比最大且较清晰 (75-85 之间) 的图像中切取出 5 张作为本实验的数据集. 由于 T2 磁共振图像是临床中广泛使用的模态, 因此本文的实验使用 T2 模态来合成其他 3 种模态的 MR 的图像.

在数据处理方面, 实验将切取的每张  $240 \times 240$  大小的图像大小调整为  $256 \times 256$ , 然后将原始数据线性缩放至  $[-1, 1]$  之间. 在参数初始化方面, 本文采用 He 等人<sup>[36]</sup> 提出的初始化方法, 动态卷积的卷积核结合

组数设置为 3. 在网络训练方面, epochs 设置为 100, batch size 为 1, 优化器选择 Adam, 学习率采用指数衰减策略, 初始学习率为 0.000 2, 衰减率为 0.98.

### 4.2 评价指标

为评价生成图像的质量, 本文采用峰值信噪比 (PSNR) 和结构相似性 (SSIM) 两个指标. 其中, PSNR 定义为:

$$PSNR = 10 \log_{10} \left( \frac{MAX_I^2}{MSE} \right) \quad (7)$$

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - K(i,j)]^2 \quad (8)$$

其中,  $I$  和  $K$  表示大小为  $m \times n$  的两幅图像.

SSIM 定义如下:

$$SSIM_{(x,y)} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (9)$$

其中,  $\mu_x$  为  $x$  的均值,  $\mu_y$  为  $y$  的均值,  $\sigma_x^2$  为  $x$  的方差,  $\sigma_y^2$  为  $y$  的方差,  $\sigma_{xy}$  为  $x$  和  $y$  的协方差,  $c_1 = (k_1L)^2$ ,  $c_2 = (k_2L)^2$  为两个常数,  $L = 2^B - 1$  为像素值的范围,  $k_1 = 0.01$ ,  $k_2 = 0.03$ .

### 4.3 $\lambda$ 取值

对于本文定义的目标函数, 我们首先通过实验来确定系数  $\lambda$  的取值, 以 T2 生成其他 3 种模态的图像为例, 实验结果如表 3 所示. 可以看出, 当  $\lambda$  取 100 时, 生成图像的多项指标显示为最优, 因此本文在提出的方法中  $\lambda$  均设置为 100.

表3  $\lambda$  不同取值对应结果

$\lambda$ 取值	PSNR			SSIM		
	FLAIR	T1	T1CE	FLAIR	T1	T1CE
1	21.1721	21.9108	23.4667	0.8249	0.8743	0.8491
10	22.7145	22.5283	23.9847	0.8482	0.8761	0.8790
20	22.1168	22.4204	23.8752	0.8423	0.8840	0.8765
30	22.3925	22.2216	24.2719	0.8402	0.8780	0.8732
50	22.4316	22.4352	24.6032	0.8519	0.8886	0.8827
100	<b>22.9480</b>	22.8284	24.7043	<b>0.8691</b>	<b>0.8983</b>	<b>0.8970</b>
150	22.4554	22.4687	24.3741	0.8508	0.8835	0.8857
200	22.5848	22.7946	24.7587	0.8557	0.8951	0.8953
250	22.7390	<b>22.9085</b>	<b>24.8637</b>	0.8533	0.8908	0.8899
300	22.7175	22.7366	24.6900	0.8576	0.8958	0.8938

### 4.4 单一模态 MR 图像生成

为了测试动态卷积的图像生成性能, 针对 pix2pix 的生成器, 我们比较了在生成器中下采样用动态卷积、上采样用动态卷积和上下采样均使用动态卷积、

以及生成器上采样采用动态卷积和判别器也采用动态卷积4种情况,实验结果如表4所示.其中,only down表示下采样使用动态卷积,only up表示上采样使用动态卷积,down+up表示下采样和上采样均采用动态卷积,only up+D表示生成器中上采样用动态卷积、且判别器也使用动态卷积.

实验结果表明只上采样用动态卷积和上下采样均使用动态卷积效果相差不大,但均优于基准模型pix2pix和下采样用动态卷积.同时,本文测试了在判别器中也使用动态卷积,结果证明在生成器和判别器中

均使用动态卷积的效果最好.整个实验过程本文使用T2模态生成T1模态,生成图比较如图8所示,其中红色虚线框中为肿瘤区域.

表4 单一模态图像生成结果

方法	PSNR	SSIM
pix2pix	22.432 1	0.893 2
only down	22.205 2	0.887 2
only up	22.724 2	0.891 5
down+up	22.678 3	0.892 8
only up+D	<b>23.101 2</b>	<b>0.899 6</b>

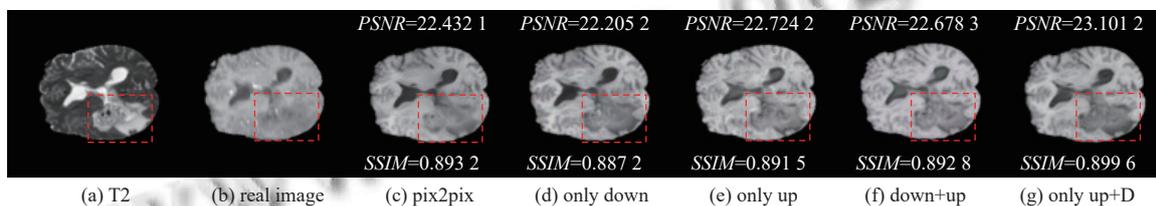


图8 单一模态生成结果图示例

#### 4.5 多模态 MR 图像生成

为了进一步验证本文方法的效果,我们以T2模态生成其他3种模态图像为例,将本文方法与pix2pix、MGAN进行了对比,验证结果如表2所示.3\*pix2pix表示采用pix2pix模型生成其他3种模态数据需分别训练3个模型.

实验结果表明,将DyConv与pix2pix相结合

(DyGAN),各项指标均优于MGAN.不仅如此,除了Flair模态的SSIM稍低于pix2pix,其他指标也均高于pix2pix,而且相比pix2pix本文是同时生成其他3种模态的图像.除此之外,本文提出的多尺度判别器的结构,多项指标中显示它在DyGAN的基础上进一步提升了图像生成的质量.图9给出了多模态图像的生成实例对比情况,其中红色虚线框中为肿瘤区域.

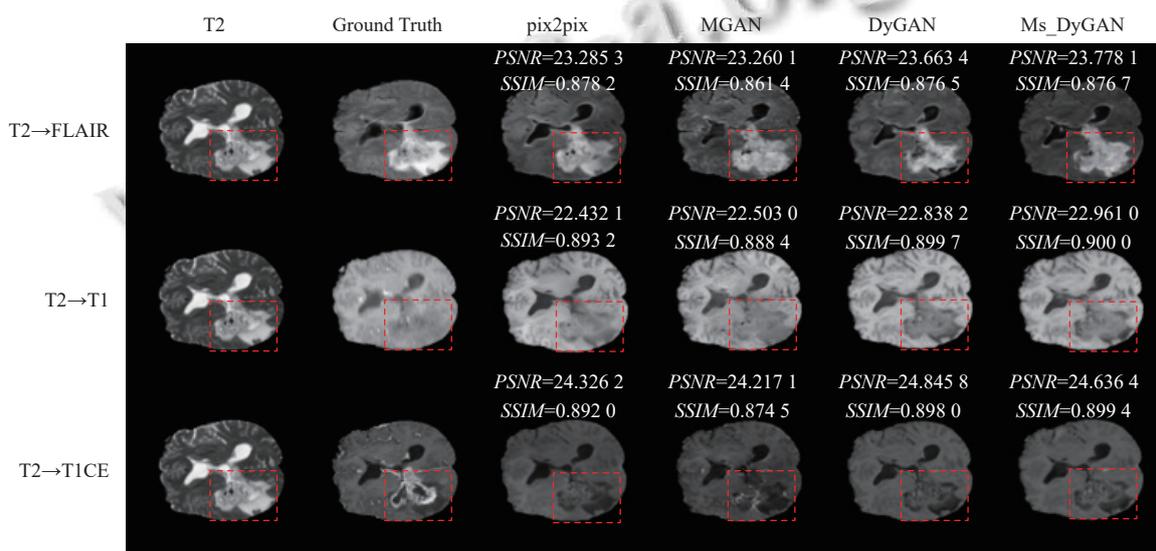


图9 多模态生成结果图示例

## 5 结论

针对多模态 MR 图像的生成方法难以通过一种模态同时生成其他所有模态的问题, 论文一方面将动态卷积应用于生成对抗网络, 提出了动态生成对抗网络模型; 另一方面, 通过任务标签的形式对不同模态的图像进行编码, 并将编码结果与动态生成对抗网络结合, 从而有效实现了由一种模态同时生成多种 MR 模态的数据. 在此基础上, 我们进一步提出多尺度的判别器网络, 提高了判别器的判别性能. 实验结果表明, 本文方法有效解决了难以同时生成多种模态数据的问题, 并同时提高了生成图像的质量.

### 参考文献

- 1 Ostrom QT, Bauchet L, Davis FG, *et al.* The epidemiology of glioma in adults: A “state of the science” review. *Neuro-Oncology*, 2014, 16(7): 896–913. [doi: 10.1093/neuonc/nou087]
- 2 Yu BT, Zhou LP, Wang L, *et al.* 3D cGAN based cross-modality MR image synthesis for brain tumor segmentation. 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018). Washington: IEEE, 2018. 626–630.
- 3 Cai L, Wang ZY, Gao HY, *et al.* Deep adversarial learning for multi-modality missing data completion. Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London: ACM, 2018. 1158–1166.
- 4 Xin BY, Hu YF, Zheng YF, *et al.* Multi-modality generative adversarial networks with tumor consistency loss for brain MR image synthesis. 2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI). Iowa City: IEEE, 2020. 1803–1807.
- 5 Li RJ, Zhang WL, Suk HI, *et al.* Deep learning based imaging data completion for improved brain disease diagnosis. Proceedings of the 17th International Conference on Medical Image Computing and Computer-Assisted Intervention. Boston: Springer, 2014. 305–312.
- 6 Goodfellow IJ, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial nets. Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2014. 2672–2680.
- 7 Kazemina S, Baur C, Kuijper A, *et al.* GANs for medical image analysis. *Artificial Intelligence in Medicine*, 2020, 109: 101938. [doi: 10.1016/j.artmed.2020.101938]
- 8 Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. 4th International Conference on Learning Representations. San Juan: ICLR, 2016. 1–16.
- 9 Frid-Adar M, Klang E, Amitai M, *et al.* Synthetic data augmentation using GAN for improved liver lesion classification. 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018). Washington: IEEE, 2018. 289–293.
- 10 Bermudez C, Plassard AJ, Davis LT, *et al.* Learning implicit brain MRI manifolds with deep learning. Proceedings of SPIE 10574 Medical Imaging 2018: Image Processing. Houston: SPIE, 2018. 1–12.
- 11 Mirza M, Osindero S. Conditional generative adversarial nets. arXiv: 1411.1784, 2014.
- 12 Isola P, Zhu JY, Zhou TH, *et al.* Image-to-image translation with conditional adversarial networks. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 5967–5976.
- 13 Dar SUH, Yurt M, Karacan L, *et al.* Image synthesis in multi-contrast MRI with conditional generative adversarial networks. *IEEE Transactions on Medical Imaging*, 2019, 38(10): 2375–2388. [doi: 10.1109/TMI.2019.2901750]
- 14 Yu BT, Zhou LP, Wang L, *et al.* Ea-GANs: Edge-aware generative adversarial networks for cross-modality MR image synthesis. *IEEE Transactions on Medical Imaging*, 2019, 38(7): 1750–1762. [doi: 10.1109/TMI.2019.2895894]
- 15 Wang TC, Liu MY, Zhu JY, *et al.* High-resolution image synthesis and semantic manipulation with conditional GANs. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 8798–8807.
- 16 Zhu JY, Park T, Isola P, *et al.* Unpaired image-to-image translation using cycle-consistent adversarial networks. Proceedings of the 2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017. 2242–2251.
- 17 Wolterink JM, Dinkla AM, Savenije MHF, *et al.* Deep MR to CT synthesis using unpaired data. Proceedings of the 2nd International Workshop on Simulation and Synthesis in Medical Imaging. Québec City: Springer, 2017. 14–23.
- 18 Chartsias A, Joyce T, Dharmakumar R, *et al.* Adversarial image synthesis for unpaired multi-modal cardiac data. Proceedings of the 2nd International Workshop on Simulation and Synthesis in Medical Imaging. Québec City: Springer, 2017. 3–13.
- 19 Jiang J, Hu YC, Tyagi N, *et al.* Tumor-aware, adversarial domain adaptation from CT to MRI for lung cancer

- segmentation. Proceedings of the 21st International Conference on Medical Image Computing and Computer-Assisted Intervention. Granada: Springer, 2018. 777–785.
- 20 Arjovsky M, Bottou L. Towards principled methods for training generative adversarial networks. Proceedings of the 5th International Conference on Learning Representations. Toulon: ICLR, 2017. 1–17.
- 21 Arjovsky M, Chintala S, Bottou L. Wasserstein GAN. arXiv: 1701.07875, 2017.
- 22 de Brabandere B, Jia X, Tuytelaars T, *et al.* Dynamic filter networks. Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona: Curran Associates Inc., 2016. 667–675.
- 23 Yang B, Bender G, Le QV, *et al.* CondConv: Conditionally parameterized convolutions for efficient inference. Advances in Neural Information Processing Systems 32: Annual Conference on Neural Information Processing Systems 2019. Vancouver: NeurIPS, 2019. 1305–1316.
- 24 Chen YP, Dai XY, Liu MC, *et al.* Dynamic convolution: Attention over convolution kernels. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 11027–11036.
- 25 Zhang YK, Zhang J, Wang Q, *et al.* DyNet: Dynamic convolution for accelerating convolutional neural networks. arXiv: 2004.10694, 2020.
- 26 Ma NN, Zhang XY, Huang JW, *et al.* WeightNet: Revisiting the design space of weight networks. Proceedings of the 16th European Conference on Computer Vision. Glasgow: Springer, 2020. 776–792.
- 27 Hu J, Shen L, Sun G. Squeeze-and-excitation networks. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 7132–7141.
- 28 Tian Z, Shen CH, Chen H. Conditional convolutions for instance segmentation. Proceedings of the 16th European Conference on Computer Vision. Glasgow: Springer, 2020. 282–298.
- 29 He JJ, Deng ZY, Qiao Y. Dynamic multi-scale filters for semantic segmentation. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 3561–3571.
- 30 Wang H, Deng C, Ma F, *et al.* Context modulated dynamic networks for actor and action video segmentation with language queries. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12152–12159. [doi: 10.1609/aaai.v34i07.6895]
- 31 Pang YW, Zhang LH, Zhao XQ, *et al.* Hierarchical dynamic filtering network for RGB-D salient object detection. Proceedings of the 16th European Conference on Computer Vision. Glasgow: Springer, 2020. 235–252.
- 32 Wu F, Fan A, Baevski A, *et al.* Pay less attention with lightweight and dynamic convolutions. Proceedings of the 7th International Conference on Learning Representations. New Orleans: ICLR, 2019. 1–14.
- 33 Choi Y, Choi M, Kim M, *et al.* StarGAN: Unified generative adversarial networks for multi-domain image-to-image translation. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 8789–8797.
- 34 Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer, 2015. 234–241.
- 35 Mao XD, Li Q, Xie HR, *et al.* Least squares generative adversarial networks. Proceedings of the 2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017. 2813–2821.
- 36 He KM, Zhang XY, Ren SQ, *et al.* Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. Proceedings of the 2015 IEEE International Conference on Computer Vision. Santiago: IEEE, 2015. 1026–1034.

(校对责编: 孙君艳)