

DOI:10.3969/j.issn.1005-202X.2025.10.003

医学影像物理

## 基于深度学习的医学MR图像合成研究进展

曹石<sup>1</sup>, 巩高<sup>2</sup>, 高俊逸<sup>3</sup>, 杨永昆<sup>1</sup>, 陈超敏<sup>4</sup>, 刘国光<sup>5</sup>, 孙光志<sup>1</sup>

1. 南京医科大学附属泰州人民医院放疗中心, 江苏 泰州 225300; 2. 陕西省人民医院放疗科, 陕西 西安 710000; 3. 南京医科大学附属泰州人民医院影像科, 江苏 泰州 225300; 4. 南方医科大学生物医学工程学院, 广东 广州 510515; 5. 广东省医疗器械质量监督检验所, 广东 广州 510663

**【摘要】**MR图像在软组织成像中的优越性使其在医学诊断和放射治疗中不可或缺,但采集成本和禁忌等因素限制了其广泛应用;相比之下CT扫描具有成像速度快、费用低的优点。研究围绕生成式深度学习模型在CT到MR图像跨模态合成领域的研究进展进行综述与分析,从脊柱病变、急性缺血性脑卒中和肿瘤分割等临床场景分析多种MR图像合成方法的技术特性、性能优势及其面临的挑战。最后进一步探讨医学图像合成的应用价值和未来研究前景。

**【关键词】**医学图像合成;生成式深度学习模型;磁共振成像;CT扫描;综述

**【中图分类号】**R318

**【文献标志码】**A

**【文章编号】**1005-202X(2025)10-1273-07

### Advances in medical magnetic resonance image synthesis based on deep learning

CAO Shi<sup>1</sup>, GONG Gao<sup>2</sup>, GAO Junyi<sup>3</sup>, YANG Yongkun<sup>1</sup>, CHEN Chaomin<sup>4</sup>, LIU Guoguang<sup>5</sup>, SUN Guangzhi<sup>1</sup>

1. Radiotherapy Center, the Affiliated Taizhou People's Hospital of Nanjing Medical University, Taizhou 225300, China; 2. Department of Radiation Oncology, Shaanxi Provincial People's Hospital, Xi'an 710000, China; 3. Department of Radiology, the Affiliated Taizhou People's Hospital of Nanjing Medical University, Taizhou 225300, China; 4. School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China; 5. Guangdong Medical Devices Quality Surveillance and Test Institute, Guangzhou 510663, China

**Abstract:** The superiority of magnetic resonance (MR) images in soft tissue imaging makes them indispensable for medical diagnosis and radiotherapy, but factors such as acquisition cost and contraindications limit their widespread application. In contrast, computed tomography (CT) scanning has the advantages of fast imaging speed and low cost. Herein, this review summarizes the research progress of generative deep learning models in the field of medical CT to MR image synthesis, and especially analyzes the technical characteristics, performance advantages, and challenges of various MR image synthesis methods from clinical scenarios such as spinal lesions, acute ischemic stroke, and tumor segmentation. Furthermore, the application value and future research prospects of medical image synthesis are discussed.

**Keywords:** medical image synthesis; generative deep learning model; magnetic resonance imaging; computed tomography scanning; review

### 前言

磁共振成像 (Magnetic Resonance Imaging, MR)

和计算机断层扫描 (Computed Tomography, CT) 是临床诊断和治疗的重要手段。CT 成像以速度快、成本低和适用范围广等优点广受欢迎,但图像的软组织对比度较低<sup>[1]</sup>。相比之下,MR 提供了优越的软组织对比度,在精确诊断中占据重要地位。然而,MR 的高成本、长成像时间及一些禁忌症 (如幽闭恐惧症和金属植入物) 限制了其广泛应用<sup>[2]</sup>。因此,利用 CT 图像合成对应的 MR 图像具有重要的临床意义和价值。医学图像合成涉及将源图像模态转换为目标图像模态,近年来深度学习 (Deep Learning, DL) 方法已被广泛应用于 CT 到 MR 图像的跨模态合成任务,通过学

**【收稿日期】**2025-03-15

**【基金项目】**国家重点研发计划 (2023YFC2414502)

**【作者简介】**曹石, 硕士研究生, 工程师, 研究方向: 医学图像处理、肿瘤放射治疗, E-mail: 2319603539@qq.com

**【通信作者】**刘国光, 高级工程师, 研究方向: 医疗仪器检测、医学人工智能技术与应用等, E-mail: 571611621@qq.com; 孙光志, 主管技师, 研究方向: 肿瘤放射治疗, E-mail: 45621402@qq.com

习CT图像的结构信息,生成具有相应软组织特征的MR图像<sup>[3-4]</sup>。结合两种成像技术的优势,可提供更全面和精准的诊断信息,图1为基于GAN架构的生成式模型进行MR图像合成的工作流程。本文综述了

基于DL的MR图像合成的研究进展,涵盖了包括脊柱病变、急性缺血性脑卒中和肿瘤分割在内的多种临床应用场景。

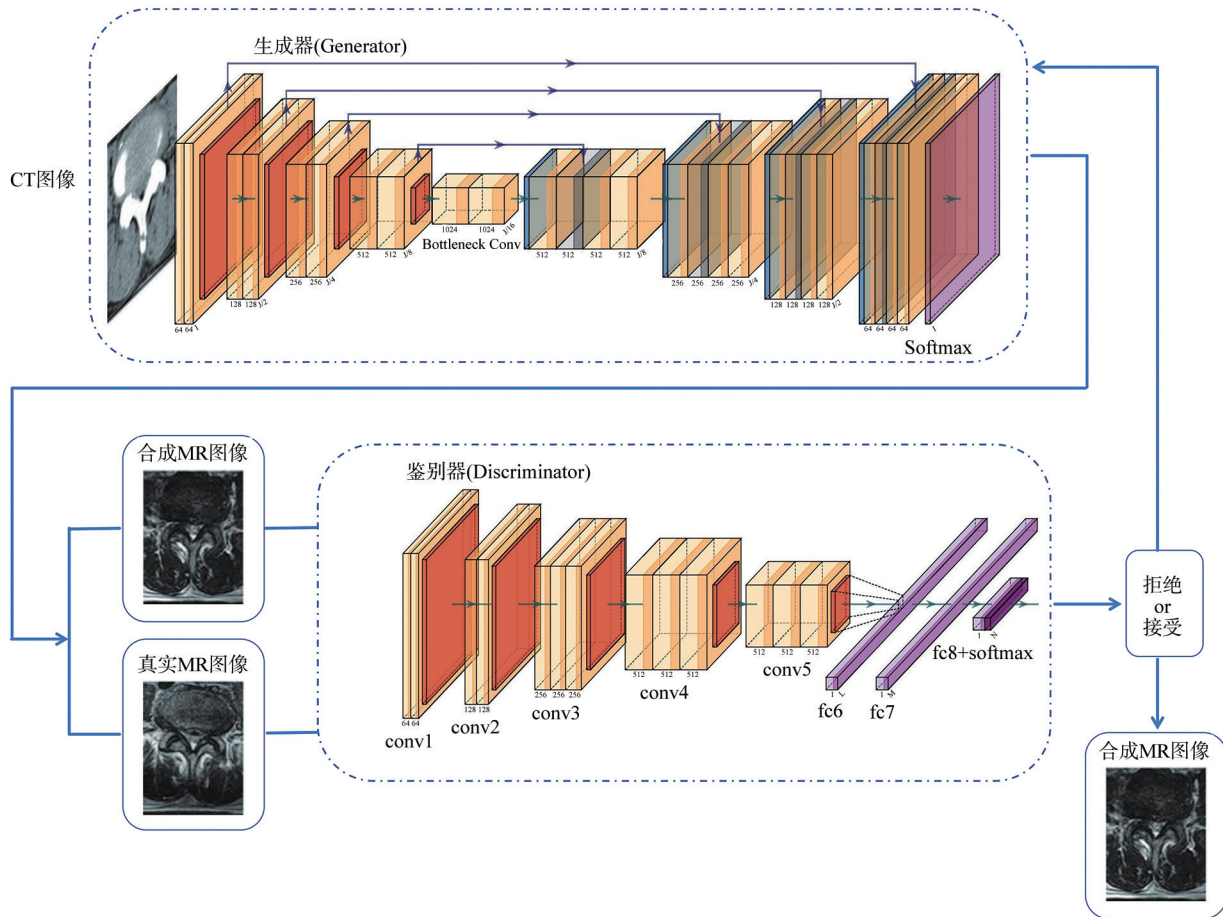


图1 基于生成式模型的工作流程图  
Figure 1 Workflow diagram based on the generative model

### 1 合成 MR 图像评价指标

在评估合成MR图像的质量和效果时,常用的评价指标包括以下几方面。

#### 1.1 图像质量

平均绝对误差(Mean Absolute Error, MAE)测量合成MR图像每个像素与真实MR图像每个像素之间的平均距离。

$$MAE = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n \|I(i,j) - K(i,j)\| \quad (1)$$

其中,  $I$  是真实MR图像,  $K$  是合成MR图像,  $m$  和  $n$  分别是图像的行数和列数。

峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)用于衡量图像的重建质量,较高的PSNR值表示合成MR图像与真实MR图像之间的差异较小,图像质量较高<sup>[5]</sup>。

$$PSNR = 10 \times \log_{10} \frac{MAX^2}{MSE} \quad (2)$$

其中,  $MAX$  是图像像素的最大值,对于12位MR图像,  $MAX=4095$ 。  $MSE$  是均方误差,用于衡量合成MR图像与真实MR图像之间的平均平方差异:

$$MSE = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [I(i,j) - K(i,j)]^2 \quad (3)$$

其中,  $I$  是真实MR图像,  $K$  是合成MR图像,  $m$  和  $n$  分别是图像的行数和列数。

结构相似性指数 (Structural Similarity Index, SSIM) 用于评估合成MR图像与真实MR图像在亮度、对比度和结构上的相似性。SSIM值介于0和1之间,值越接近1,表示两者之间的相似度越高<sup>[6]</sup>。

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (4)$$

其中,  $\mu_x$  和  $\mu_y$  分别是真实 MR 图像  $x$  和合成 MR 图像  $y$  的均值;  $\sigma_x^2$  和  $\sigma_y^2$  分别是两者的方差;  $\sigma_{xy}$  是两者之间的协方差;  $C_1$  和  $C_2$  是常数。

相关系数 (Correlation Coefficient,  $R$ ) 用于评估合成 MR 图像与真实 MR 图像之间的线性相关性。 $R$  值介于 -1 和 1 之间, 值越接近 1, 表示两者之间的相关性越高<sup>[7]</sup>。

$$R = \frac{\sum(I(i,j) - \mu_I)(K(i,j) - \mu_K)}{\sqrt{\sum(I(i,j) - \mu_I)^2 \sum(K(i,j) - \mu_K)^2}} \quad (5)$$

其中,  $I(i,j)$  和  $K(i,j)$  分别表示真实 MR 图像和合成 MR 图像的像素值,  $\mu_I$  和  $\mu_K$  分别是两者的均值。

## 1.2 解剖学一致性

Dice 相似系数 (Dice Similarity Coefficient, DSC) 用于评估合成 MR 图像与真实 MR 图像在目标区域 (如肿瘤、重要器官) 的重叠程度。DSC 值越高, 表示合成图像在解剖学结构上的一致性越好<sup>[8]</sup>。

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|} \quad (6)$$

其中,  $X$  是真实 MR 图像中实际标注的目标区域,  $Y$  是合成 MR 图像中的预测区域,  $X \cap Y$  表示两个区域的交集。

对称 Hausdorff 距离 (Hausdorff Distance, HD) 用于评估合成 MR 图像与真实 MR 图像在感兴趣区域 (Region of Interest, ROI) 边界上的几何一致性<sup>[9]</sup>。设  $X$  与  $Y$  分别为真实 MR 图像与合成 MR 图像中同一 ROI 的表面点集。计算点到集合的最近邻距离为  $d(x, Y) = \min_{y \in Y} \|x - y\|_2$ , 则对称 Hausdorff 距离定义为:

$$HD(X, Y) = \max\left\{d(x, Y)_{x \in X}, d(y, X)_{y \in Y}\right\} \quad (7)$$

考虑到经典 Hausdorff 距离从全局度量边界偏差, 易对孤立异常点较为敏感, HD95 (95<sup>th</sup> Percentile Hausdorff Distance) 以 95% 分位数替代边界极大偏差值 (100% 分位), 在保持对较大偏差灵敏度的同时降低对极少数离群点的敏感性。

$$HD95 = \text{quantile}_{0.95}\{HD(X, Y)\} \quad (8)$$

HD95 越小, 表明合成 MR 图像与真实 MR 图像的 ROI 边界越接近 (单位: mm, 值越小表示几何一致性越高)。

## 2 合成 MR 图像在医学诊疗中的应用

### 2.1 合成 MR 图像辅助诊断脊柱病变

在脊柱结构的影像检查中, CT 图像在软组织对比度方面相对不足, 可能导致对软组织病变的诊断不够准确; 相比之下, MR 提供了优越的软组织对比

度, 能够清晰区分脊柱中的不同软组织结构 (如椎间盘、脊髓、神经根等), 特别适合评估椎间盘突出、椎管狭窄和脊髓压迫等软组织病变<sup>[10-11]</sup>。研究还表明, MR 在区分早期脊柱感染和退行性 Modic I 型变化方面具有显著优势<sup>[12]</sup>。针对现实中 MR 成像成本高、时间长及扫描禁忌等问题, 以易于获取的脊柱 CT 图像生成相应 MR 图像, 从而提升脊柱病变诊断的可靠性和效率。

近年来, 基于 DL 模型的脊柱 CT 合成 MR 图像技术取得了显著进展, Jin 等<sup>[13]</sup>提出了双循环一致性生成对抗网络 (DC<sup>2</sup>Anet) 方法, 通过半监督学习策略生成腰椎 MR 图像。DC<sup>2</sup>Anet 引入了包含 6 个独立损失项的目标函数, 以平衡定量和定性损失, 生成真实且准确的合成 MR 图像。实验对比表明, DC<sup>2</sup>Anet 构建出接近真实的 MR 图像, 同时也优于现有算法 (multi-channel GAN、deep MR-to-CT、DiscoGAN 和 MR-GAN)。Lee 等<sup>[14]</sup>利用生成对抗网络 (GAN) 从脊柱 CT 图像合成 T2 加权 MR 图像。研究中, GAN 生成器通过结合对抗性损失和体素级损失, 生成逼真的 MR 图像。实验使用了 280 对腰椎 CT 和 MR 图像进行训练, 15 对腰椎 CT 和 MR 图像进行测试。两名放射科医生、两名脊柱外科医生和两名住院医师对合成 MR 图像的真实性进行了盲评。结果显示, 尽管数据集较小, GAN 在合成医学图像方面表现出色, 合成 MR 图像的平均总体相似度为 80.2%。Hong 等<sup>[15]</sup>提出了一种无监督生成注意力模块 (U-GAT-IT), 基于生成对抗网络框架设计了两个生成器和两个判别器。见表 1。U-GAT-IT 专注于特定区域, 更有效地将 CT 图像转换为 MR 图像。模型优化结合多种损失函数以平衡定量和定性损失, 包括对抗损失、循环一致性损失、身份损失和注意力损失。两位放射科专家通过视觉图灵测试 (Visual Turing Test, VTT) 验证合成腰椎 MR 图像的真实性。结果表明不同经验的放射科医生找到真实 MR 图像的概率为 52%, 意味着基于 U-GAT-IT 所开发的 GAN 模型生成了难以与真实图像区分的合成腰椎 MR 图像, 有利于提高临床诊断效率。表 1 对近年来腰椎 MR 图像合成研究进行汇总, 不同的研究在算法模型、图像增强和扩增技术、分类标准等方面存在各自的差异。基于大样本和多中心, 能够对不同的模型进行系统比较并确立统一的标准, 将是未来研究的重点之一。

### 2.2 合成 MR 图像辅助诊断急性缺血性脑卒中 (Acute Ischemic Stroke, AIS)

AIS 是一种由于脑血管阻塞导致脑组织局部缺血和缺氧, 从而引起脑细胞损伤或死亡的严重脑血管疾病, 是导致患者致死或致残的主要原因<sup>[16]</sup>。AIS

表1 基于DL的脊柱MR图像生成研究

Table 1 Studies on spinal magnetic resonance image synthesis based on deep learning

作者	研究年份	样本量	模型	结果
Jin, et al. <sup>[13]</sup>	2019	641	DC <sup>2</sup> Anet	MAE: 28.819±7.655
				PSNR: 64.553±1.890
				SSIM: 0.248±0.072
				R: 0.453±0.146
Lee, et al. <sup>[14]</sup>	2020	280	GANs	MAE: 21.193±5.814 PSNR: 64.922±1.857
Hong, et al. <sup>[15]</sup>	2022	285	U-GAT-IT	PSNR: 15.987±1.039
				SSIM: 0.518±0.042

的早期诊断主要依赖于综合的影像学表现,CT扫描因其对脑出血的高敏感性和快速成像能力,是疑似脑卒中患者排除颅内出血的首选方法<sup>[17]</sup>;然而,CT在检测早期缺血性病变方面存在局限。而MR图像,特别是弥散加权成像(Diffusion-Weighted Imaging, DWI),在检测早期缺血性病变方面具有显著优势。DWI能够在数分钟内识别出早期缺血性病灶,并提供更详细的软组织对比和病理信息,从而在AIS的早期诊断中发挥关键作用<sup>[18]</sup>。最新研究表明,DWI在早期识别脑卒中病变方面的敏感性和特异性远高于传统CT<sup>[19]</sup>。

近年来,利用DL实现CT合成MR图像,可以提供更丰富的诊断信息,对AIS的早期干预和治疗具有重要意义。Rubin等<sup>[20]</sup>将条件生成对抗网络(CGAN)应用于CT灌注图像到DWI图像转换任务,并验证了合成MR图像在缺血性病变分割任务中的有效性。具体而言,CGAN的生成器接受5个通道的输入,经过卷积和反卷积操作后生成单通道的MR图像。多模态输入包括CT平扫和4种灌注图像(CBF、CBV、MTT和Tmax),更丰富的特征信息有助于提高生成器对病变区域的识别和生成能力。生成结果的DSC,HD95分别达到了0.54±0.23和27.88±21.00 mm。利用合成MR图像,研究人员还开展了缺血性脑卒中病变部位的分割研究。结果表明,基于多模态输入约束的CGAN所生成的MR图像显著提高了FCN的分割精度和一致性(精确率=0.56±0.25,召回率=0.63±0.25),增强了病变区域的识别能力。Feng等<sup>[21]</sup>提出了一种结合放射组学特征的GAN模型合成MR图像,可以改进AIS病变区域的准确识别。通过利用放射组学特征作为生成对抗网络的中间监督,该方法显著提高了生成图像的真实感。研究首先在CT图像中检测病变候选区域,提取多种放射组学病变特征,并通过信息增益筛选出最具代表性的特征并可视觉化为特征图。再将特征图与CT图像作为生成网

络的联合输入,实现CT到MR的跨模态图像生成。引入病变特征相似度损失函数,确保生成的MR在病变特征上与真实MR高度一致,减少特征差异。实验结果表明,生成的MR在视觉上与真实MR高度相似,特别是在病灶区域的高亮显示方面效果显著优于对比算法(pix2pix、CycleGAN、RegGAN和MedGAN)。Hu等<sup>[22]</sup>提出了一种基于3D GAN的CT到MR图像合成模型,并评估其在检测疑似AIS患者脑损伤的可行性。研究收集了193名疑似AIS患者的头部非对比CT和随访FLAIR图像,随机分配到训练集( $n=140$ )和测试集( $n=53$ )。通过4级视觉评分、PSNR、SSIM指标以及人工判读病变表现,共同评估合成MR图像对于临床诊断的有效性。生成测试显示,92.5%(49/53)的合成MR图像报告了2~4级脑病变(与参考病变组织部分至完全重合),包含3例误报;PSNR和SSIM分别达到24.3 dB和0.857。人工判读病变测试显示,CT图像无法观察到的病变能够在合成MRI上被检测到,与CT相比合成MR图像导致患者检测的总体敏感性从38%增加到82%;特异性从67%下降至33%。总体而言,基于生成对抗网络的合成MR技术在AIS患者的检测中具有较高的灵敏度,但是检测精度仍需进一步优化以便在实际临床诊断中提供更可靠的支持。表2对近年来MR图像合成在AIS诊断方面的研究进行汇总。

### 2.3 合成MR图像辅助肿瘤自动分割

肿瘤放疗(Tumor Radiotherapy)是一种利用高能辐射摧毁或损伤肿瘤细胞的治疗方法,需要精确控制辐射剂量以最大限度地保护周围健康组织<sup>[23]</sup>。准确定位和分割肿瘤及危及器官(OARs)对于确保辐射剂量准确覆盖肿瘤并保护健康组织至关重要<sup>[24]</sup>。CT和MR在放射治疗计划中扮演着重要角色,各自具有独特的优势和局限性。定位CT图像常用于勾画放疗靶区和OARs,但其在软组织对比度方面的不足,使得MR成为重要的补充成像手段。MR图像的

表2 基于DL的MR图像生成用于AIS诊断  
Table 2 Deep learning-based magnetic resonance image synthesis for diagnosis of acute ischemic stroke

作者	研究年份	样本量	模型	结果
Rubin, et al. <sup>[20]</sup>	2021	---	CGAN+FCN	DSC: 0.54±0.23 HD95: (27.88±21.00) mm 精确率: 0.56±0.25 召回率: 0.63±0.25
Feng, et al. <sup>[21]</sup>	2022	103	GAN+放射组学病变特征	MAE: 0.034 PSNR: 70.803 dB SSIM: 0.783 R: 0.986 DSC: 0.869
Hu, et al. <sup>[22]</sup>	2022	193	3D GAN	PSNR: 24.30 dB SSIM: 0.857 PPV: 95% NPV: 10% F1分数: 0.88

PPV: 阳性预测值; NPV: 阴性预测值

高软组织对比度能够提供更详细的解剖和病理信息,从而显著提高放疗的精度<sup>[25-26]</sup>。在图像引导精准放疗治疗的背景下,以GAN、Unet为代表的DL技术在MR图像生成任务中的潜力备受关注。

近年来,DL实现肿瘤及侵犯组织的自动分割是研究热点。然而,专用的MR数据集不足是开发优秀DL自动分割(DL auto-segmentation, DLAS)模型困难的主要障碍<sup>[27]</sup>。Jiang等<sup>[28]</sup>提出了一种基于GAN架构的跨模态(CT-to-MR)数据增强方法,通过CT合成MR图像来训练用于肺肿瘤分割的U-net模型。引入肿瘤感知损失(Tumor-aware Loss, TAL),包括肿瘤形状损失(Tumor Shape Loss)和肿瘤位置损失(Tumor Location Loss)确保生成模型能够准确保留肿瘤的形状和位置特征。与真实结果对比表明,所提方法在合成MR图像上产生了最佳的肿瘤保留效果,KL散度达到0.069;另一方面,合成MR图像对于U-net的肿瘤分割效果改善明显[DSC=0.75±0.12、HD95=(9.36±6.00) mm]。证明合成MR图像结合少量真实的MR图像能够提高U-Net模型在肺肿瘤分割任务中的性能,克服了从小型数据集中开发稳健分割模型的局限性。类似的,前列腺癌放射治疗中基于CT图像的肿瘤分割往往存在体积高估的问题<sup>[29]</sup>,Lei等<sup>[30]</sup>提出了一种仅基于CT图像的前列腺分割策略。研究通过3D CycleGAN完成CT到MR图像的跨模态生成,再将获取的合成MR图像用于深度注意全卷积网络(Deep Attention Fully Convolution Network, DAFCN)的监督训练,以改善前列腺肿瘤的

分割准确性。DAFCN集成深度注意力机制和深度监督,以提取和区分代表前列腺和非前列腺边界的最相关特征,从而生成高分辨率的分割掩膜<sup>[31-32]</sup>。与CT相比,合成MR图像辅助的肿瘤分割精度明显改善,DSC从0.86提高至0.92,HD95从7.36 mm降至4.38 mm。为不需要MR采集的情况下获取多模态影像用于精准放疗提供了解决思路<sup>[33]</sup>。

在多器官分割研究中,Dai等<sup>[34]</sup>提出了一种合成MR图像辅助的掩膜评分区域卷积神经网络(MS-RCNN),用于头颈部多器官的自动分割。研究采用结合几何一致性损失(Geometric Consistency Loss, GCL)的预训练CycleGAN完成头颈部肿瘤CT到MR图像的无监督学习任务,然后利用从CT和合成MR图像中提取的多尺度特征共同学习分割目标器官。MS-RCNN的创新性有如下体现:(1)在传统的CycleGAN基础上引入了几何一致性损失,减少了生成图像与源图像之间的几何偏差;(2)设计了主干网络、区域建议网络(RPN)、区域卷积神经网络头(RCNN Head)和掩模头(Mask Head)等多个子网络共同完成头颈部OARs分割,并通过掩模评分头(Mask Scoring Head)生成每个掩模的置信度评分,评估分割效果;(3)在特征提取和分割的各个环节中引入注意力机制(Attention Gate, AG),动态选择和强调重要特征以突出关键区域和抑制不相关的背景信息,从而提高分割精度。在公共数据集的头颈部9个OARs分割任务中,所提方法的平均DSC和HD95分别达到了0.77和2.9 mm,比表现最优的对比算法提

高了6%和16%。证明所提的合成MR图像辅助深度学习框架在头颈放疗治疗计划中高精度自动勾画器官的可行性。Dong等<sup>[35]</sup>关注前列腺癌放疗中男性盆腔的多器官分割任务,提出了一种合成MR图像辅助的深度注意力U-net(Deep attention U-net, DAUnet)用于前列腺、膀胱和直肠等相邻器官的自动分割。DAUnet将注意力门(Attention Gates, AGs)和深度监督(Deep Supervision)策略与传统U-Net架构相结合,在不扩大感受野(Receptive Field)的情况下提高了模型捕获相关语义信息的能力。AGs用于U-Net的长跳跃连接,通过计算特征图的注意力权重增强重

要区域的特征来识别器官边界。深度监督在DAUnet解码器的中间层添加监督信号(手动标注的前列腺、膀胱和直肠等器官的实际轮廓),确保解码器能够在多个图像尺度上学习到更丰富的特征信息,增强多器官特征的区分能力。与CT相比,DAUnet使用合成MR图像辅助的分割精度更高,膀胱、前列腺和直肠的平均DSC和HD95分别达到了 $0.90\pm 0.03$ 和 $(8\pm 9.32)$  mm。表明MS-RCNN能够提供准确且一致的盆腔多器官分割,有望促进前列腺癌放射治疗计划的高效制定。表3对近年来MR图像合成在辅助肿瘤自动分割方面的研究进行汇总。

表3 基于DL的MR图像生成用于肿瘤自动分割

Table 3 Deep learning-based magnetic resonance image synthesis for automatic tumor segmentation

作者	研究年份	样本量	模型	结果
Jiang, et al. <sup>[28]</sup>	2019	81	GAN+U-net	KL 散度: 0.069
				DSC: $0.75\pm 0.12$
				HD95: $(9.36\pm 6.00)$ mm
Lei, et al. <sup>[30]</sup>	2020	103	CycleGAN+DAFCN	DSC: $0.92\pm 0.09$ HD95: $(4.38\pm 4.66)$ mm
Dai, et al. <sup>[34]</sup>	2021	118	CycleGAN+MS-RCNN	DSC: 0.77 HD95: 2.9 mm
Dong, et al. <sup>[35]</sup>	2019	140	3D CycleGAN+DAUnet	DSC: $0.90\pm 0.03$ HD95: $(8\pm 9.32)$ mm

### 3 总结与讨论

基于DL的CT到MR图像合成技术是医学图像生成的重要研究方向,能够在不便获取MR的情况下弥补CT图像的不足,满足不同的临床诊疗需求。本文主要综述了当前基于生成对抗网络(GAN)的MR图像合成技术的进展,重点分析了其在脊柱病变、AIS及肿瘤分割等领域的应用。然而,GAN网络及其变体(CycleGAN, CGAN)在生成高分辨率MR图像时易出现细节丢失和边界模糊的问题,导致生成的MR图像在关键结构上不够清晰。此外,由于高分辨率图像包含更多的细节信息,GAN模型在训练时面临更大的计算和内存需求,训练过程容易出现不稳定性和模式崩溃问题<sup>[36]</sup>。近年来,扩散模型(Diffusion Models, DM)在高分辨率图像生成任务中展现出更大的潜力,逐步添加噪声并去噪的机制允许模型在每个步骤逐步细化图像,更好地保留细节和边界特征,同时避免对抗学习机制固有的不稳定风险<sup>[37]</sup>。据本文所知,目前尚无学者就基于DM的合成MR图像开展研究,尤其在头颈或盆腔等解剖结构较为丰富的成像领域。因此,基于扩散模型的CT到

MR图像合成技术或将成为未来的研究重点。与此同时,如何在数据有限的情况下,通过引入多模态特征、注意力机制和深度监督等技术提升生成模型的泛化能力和鲁棒性,仍是值得探索的问题。

综上所述,随着深度学习技术的不断发展,未来CT到MR图像合成技术将在临床应用中发挥更大作用,为提高临床诊疗准确性、简化诊疗流程和降低诊疗成本方面提供更加可靠的支持。

### 【参考文献】

- [1] Otsuka H. Clinical imaging technology and the diagnosis in patient-centered interdisciplinary care [J]. J Med Invest, 2019, 66(1.2): 31-34.
- [2] Ruiz Santiago F, Láinez Ramos-Bossini AJ, Wáng YX, et al. The value of magnetic resonance imaging and computed tomography in the study of spinal disorders [J]. Quant Imaging Med Surg, 2022, 12(7): 3947-3986.
- [3] 董国亚, 宋立明, 李雅芬, 等. 基于深度学习的跨模态医学图像转换 [J]. 中国医学物理学杂志, 2020, 37(10): 1335-1339.  
Dong GY, Song LM, Li YF, et al. Cross-modality medical image synthesis based on deep learning [J]. Chinese Journal of Medical Physics, 2020, 37(10): 1335-1339.
- [4] Dayarathna S, Islam KT, Uribe S, et al. Deep learning based synthesis of MRI, CT and PET: review and analysis [J]. Med Image Anal, 2024, 92: 103046.
- [5] Sethi D, Bharti S, Prakash C. A comprehensive survey on gait analysis:

- history, parameters, approaches, pose estimation, and future work[J]. *Artif Intell Med*, 2022, 129: 102314.
- [6] Osorio F, Vallejos R, Barraza W, et al. Statistical estimation of the structural similarity index for image quality assessment[J]. *Signal Image Video Process*, 2022, 16(4): 1035-1042.
- [7] Oho E, Suzuki K, Yamazaki S. Highly reliable method to obtain a correlation coefficient unaffected by the SEM noise component for examining the degree of specimen damage due to electron beam irradiation[J]. *Scanning*, 2021, 2021: 2226577.
- [8] Yeung M, Rundo L, Nan Y, et al. Calibrating the dice loss to handle neural network overconfidence for biomedical image segmentation[J]. *J Digit Imaging*, 2023, 36(2): 739-752.
- [9] Ayaz A, Al Khalil Y, Amirrajab S, et al. Brain MR image simulation for deep learning based medical image analysis networks[J]. *Comput Methods Programs Biomed*, 2024, 248: 108115.
- [10] 谢达科, 韦琳, 唐运军, 等. CT联合MRI在腰椎间盘突出症患者中的诊断效果及诊断ROC效能研究[J]. *影像研究与医学应用*, 2021, 5(5): 52-53.  
Xie DK, Wei L, Tang YJ, et al. Study on the diagnostic effect and ROC performance of CT combined with MR in patients with lumbar disc herniation[J]. *Journal of Imaging Research and Medical Applications*, 2021, 5(5): 52-53.
- [11] Schwaiger BJ, Schneider C, Kronthaler S, et al. CT-like images based on T1 spoiled gradient-echo and ultra-short echo time MRI sequences for the assessment of vertebral fractures and degenerative bone changes of the spine[J]. *Eur Radiol*, 2021, 31(7): 4680-4689.
- [12] Zhang CR, Liu SH. The advancement of MRI in differentiating Modic type I degenerative changes from early spinal infections[J]. *Br J Radiol*, 2023, 96(1152): 20230551.
- [13] Jin CB, Kim H, Liu MJ, et al. DC2Anet: generating lumbar spine MR images from CT scan data based on semi-supervised learning[J]. *Appl Sci*, 2019, 9(12): 2521.
- [14] Lee JH, Han IH, Kim DH, et al. Spine computed tomography to magnetic resonance image synthesis using generative adversarial networks : a preliminary study[J]. *J Korean Neurosurg Soc*, 2020, 63(3): 386-396.
- [15] Hong KT, Cho Y, Kang CH, et al. Lumbar spine computed tomography to magnetic resonance imaging synthesis using generative adversarial network: visual turing test[J]. *Diagnostics (Basel)*, 2022, 12(2): 530.
- [16] Jayaraj RL, Azimullah S, Beiram R, et al. Neuroinflammation: friend and foe for ischemic stroke[J]. *J Neuroinflammation*, 2019, 16(1): 142.
- [17] Byrne D, Walsh JP, Sugrue G, et al. CT imaging of acute ischemic stroke[J]. *Can Assoc Radiol J*, 2020, 71(3): 266-280.
- [18] Manwani B, Rath S, Lee NS, et al. Early magnetic resonance imaging decreases hospital length of stay in patients with ischemic stroke[J]. *J Stroke Cerebrovasc Dis*, 2019, 28(2): 425-429.
- [19] 郭凯. MR弥散加权成像与CT灌注在急性缺血性脑卒中诊断中的应用价值[J]. *现代医药卫生*, 2020, 36(9): 1377-1379.  
Guo K. Application value of MR diffusion-weighted imaging and CT perfusion in the diagnosis of acute ischemic stroke[J]. *Journal of Modern Medicine & Health*, 2020, 36(9): 1377-1379.
- [20] Rubin J, Abulnaga SM. CT-To-MR conditional generative adversarial networks for ischemic stroke lesion segmentation[C]//2019 IEEE International Conference on Healthcare Informatics (ICHI). Piscataway, NJ, USA: IEEE, 2019: 1-7.
- [21] Feng EY, Qin PL, Chai R, et al. MRI generated from CT for acute ischemic stroke combining radiomics and generative adversarial networks[J]. *IEEE J Biomed Health Inform*, 2022, 26(12): 6047-6057.
- [22] Hu N, Zhang TW, Wu YF, et al. Detecting brain lesions in suspected acute ischemic stroke with CT-based synthetic MRI using generative adversarial networks[J]. *Ann Transl Med*, 2022, 10(2): 35.
- [23] Bonù ML, Pedersoli G, Balduzzi J, et al. Stereotactic radiotherapy for critically located pancreatic and biliary targets: a review on simultaneous integrated protection and other dose-painting strategies to minimize dose to critical organs at risk[J]. *Radiation*, 2023, 3(2): 98-109.
- [24] Jin DK, Guo DZ, Ge J, et al. Towards automated organs at risk and target volumes contouring: defining precision radiation therapy in the modern era[J]. *J Natl Cancer Cent*, 2022, 2(4): 306-313.
- [25] 蔡丰, 徐露, 徐洪波, 等. MRI与CT模拟定位技术在局部晚期鼻咽癌放射治疗中剂量学对比研究[J]. *生物医学工程与临床*, 2024, 28(1): 42-45.  
Cai F, Xu L, Xu HB, et al. Comparison of dosimetry between MRI and CT simulated localization techniques in radiotherapy for locally advanced nasopharyngeal carcinoma[J]. *Biomedical Engineering and Clinical Medicine*, 2024, 28(1): 42-45.
- [26] Young T, Dowling J, Rai R, et al. Clinical validation of MR imaging time reduction for substitute/synthetic CT generation for prostate MRI-only treatment planning[J]. *Phys Eng Sci Med*, 2023, 46(3): 1015-1021.
- [27] Li ZJ, Zhang W, Li BS, et al. Patient-specific daily updated deep learning auto-segmentation for MRI-guided adaptive radiotherapy[J]. *Radiother Oncol*, 2022, 17: 222-230.
- [28] Jiang J, Hu YC, Tyagi N, et al. Cross-modality (CT-MRI) prior augmented deep learning for robust lung tumor segmentation from small MR datasets[J]. *Med Phys*, 2019, 46(10): 4392-4404.
- [29] 胡玉兰, 徐海荣, 刘佳宾. CT与MRI融合图像在确定前列腺癌调强放疗靶区中的应用研究[J]. *实用医学杂志*, 2013, 29(11): 1770-1772.  
Hu YL, Xu HR, Liu JB. Application of CT-MRI fusion images in determining the target region in IMRT for prostate cancer[J]. *The Journal of Practical Medicine*, 2013, 29(11): 1770-1772.
- [30] Lei Y, Dong X, Tian Z, et al. CT prostate segmentation based on synthetic MRI-aided deep attention fully convolution network[J]. *Med Phys*, 2020, 47(2): 530-540.
- [31] Yang X, Lei Y, Wang T, et al. 3D prostate segmentation in MR image using 3D deeply supervised convolutional neural networks[J]. *Med Phys*, 2018, 45(6): 582-583.
- [32] Wang B, Lei Y, Tian SB, et al. Deeply supervised 3D fully convolutional networks with group dilated convolution for automatic MRI prostate segmentation[J]. *Med Phys*, 2019, 46(4): 1707-1718.
- [33] Savenije MH, Maspero M, Sikkes GG, et al. Clinical implementation of MRI-based organs-at-risk auto-segmentation with convolutional networks for prostate radiotherapy[J]. *Radiat Oncol*, 2020, 15(1): 104.
- [34] Dai XJ, Lei Y, Wang TH, et al. Automated delineation of head and neck organs at risk using synthetic MRI-aided mask scoring regional convolutional neural network[J]. *Med Phys*, 2021, 48(10): 5862-5873.
- [35] Dong X, Lei Y, Tian SB, et al. Synthetic MRI-aided multi-organ segmentation on male pelvic CT using cycle consistent deep attention network[J]. *Radiother Oncol*, 2019, 141: 192-199.
- [36] Skandarani Y, Jodoin PM, Lalonde A. GANs for medical image synthesis: an empirical study[J]. *J Imaging*, 2023, 9(3): 69.
- [37] Scoles A, Sionis G, Otero B, et al. High-resolution image generation using artificial intelligence and diffusion modelling[C]//2024 32nd Euromicro International Conference on Parallel, Distributed and Network-Based Processing (PDP). Piscataway, NJ, USA: IEEE, 2024: 272-276.

(编辑:薛泽玲)