DOI：10.12287/j.issn.2096-8965.20250305

基于深度学习的脑部MR图像生成合成CT图像研究进展

杨智慧[1,2]，李好[1,2]，李丰森[1,2]*

［1.甘肃中医药大学医学信息工程学院，甘肃 兰州 730000；
2.甘肃省人民医院（甘肃中医药大学第一临床医学院），甘肃 兰州 730000］

【摘要】放射治疗是治疗恶性肿瘤的重要手段，精准放射治疗计划通常需要联合使用计算机断层扫描（CT）和磁共振成像（MRI）。由于CT扫描中的电离辐射问题及获取多模态影像的复杂性，研究者开始探索合成CT（sCT）图像的方法。本文概述了影像技术在脑肿瘤放射治疗中的应用背景，讨论了基于脑部MRI图像生成sCT图像的传统方法、深度学习的新兴方法以及不同深度学习架构在该领域的应用，探讨了sCT图像在脑部肿瘤放射治疗中的应用前景及发展方向，为放射治疗提供新的思路。

【关键词】合成CT；磁共振成像；深度学习

中图分类号：R445，R319　　**文献标识码：**A　　**文章编号：**2096-8965（2025）03-0029-10

Advances in generating sCT images from brain MR images based on deep learning

Yang Zhihui[1,2], Li Hao[1,2], Li Fengsen[1,2]*

[1. School of Medical Information Engineering, Gansu University of Chinese Medicine, Lanzhou 730000, Gansu, China;
2. Gansu Provincial Hospital (First Clinical Medical School, Gansu University of Chinese Medicine), Lanzhou 730000, Gansu, China]

【Abstract】Radiotherapy is a crucial modality in the treatment of malignant tumors. Precision radiotherapy planning typically requires the integration of computed tomography (CT) and magnetic resonance imaging (MRI). However, concerns over ionizing radiation from CT scans and the complexity of acquiring multimodal imaging have driven researchers to explore methods for generating synthetic CT (sCT) images. This article outlines the application of imaging technologies in radiotherapy for brain tumors. It discusses traditional approaches for generating sCT images from brain MR images, emerging deep learning-based methods, and the application of different deep learning architectures in this domain. The potential applications and future prospects of sCT images in radiotherapy for brain tumors are explored, thereby offering new insights for radiotherapy.

【Keywords】Synthetic CT; Magnetic resonance imaging; Deep learning

收稿日期：2025-01-13；**修回日期：**2025-04-29

基金项目：甘肃省自然科学基金项目（21JR7RA631）

通信作者：李丰森（1967-），男，甘肃靖远人，硕士研究生导师，主要从事医学信息工程研究，E-mail: 1641673807@qq.com

0 引言

放射治疗作为治疗恶性肿瘤的重要手段之一，在临床上被广泛应用[1-2]。为了制定精准放射治疗计划，医生通常需要联合使用计算机断层扫描（Computed Tomography，CT）和磁共振成像（Magnetic Resonance Imaging，MRI）两种影像技术，以发挥各自的优势。这两种影像模式各具优势：CT图像具有高空间分辨率，尤其在骨骼结构的显示和肿瘤定位方面表现出色，因此广泛应用于肿瘤的精确定位和剂量计算。MRI图像则以其优异的软组织对比度[3]和多平面图像采集能力[4]著称，能够清晰显示脑部组织及病变区域，被认为是诊断脑部肿瘤的首选方法之一[5]。

然而，CT图像也存在着不可忽视的局限性。其中最明显的问题是患者需暴露于电离辐射，多次或长时间接受CT扫描可能增加癌症的发生风险[6]。此外，CT在软组织对比度上较为有限，且缺乏特异性的分子信息[4]。与CT不同，MRI通过反映质子弛豫时间和分布密度，无法直接获得人体组织衰减系数图[7]。

另一方面，多模态影像采集虽然能够为临床决策提供更全面的解剖信息，但也需要更多时间进行影像获取和配准，延长了治疗计划的制定时间，且增加了操作的成本。因此，MRI-only放射治疗计划[8]被提出，将MRI单独用于放射治疗逐渐成为研究热点[9]。但是需要解决MRI缺乏电子密度信息这一问题。

在此背景下，生成合成CT（synthetic CT，sCT），又称伪CT（pseudo CT，pCT）图像，成为一种具有潜力的解决方案。通过使用仅有的MRI数据生成sCT图像，具有以下优势：（1）减少患者暴露于电离辐射的风险，简化多模态成像流程，并避免CT和MRI配准导致的系统性误差[10]；（2）改善肌肉骨骼疾病的表征能力，并显著提升诊断准确性[3]。该方法不仅有效降低了放射治疗相关的风险，还能够在紧急情况下大幅缩短图像采集时间，从而提升临床工作的效率[11]。研究[12]表明，基于sCT的放射治疗计划可以实现与基于CT的放射治疗计划等效的剂量分布和患者治疗定位，已成功地应用于20例神经胶质瘤患者，符合剂量学和治疗设置标准[1]。随着深度学习技术的迅速发展，基于深度学习的sCT图像生成方法备受关注，尤其是在脑部MRI图像生成sCT图像的研究中，取得了显著进展。

1 国内外sCT研究现状

在sCT图像生成的研究中，不同的技术方法各有其特点和适用场景。早期的sCT生成方法之一是体积密度赋值法，为不同的解剖结构分配预设的体积密度值[13]，涉及将单一亨氏单位（Hounsfield Unit，HU）值应用于整个体积[14]。该方法在临床实践中表现出差异化表现：Chin等[15]在头颈部研究中采用分阶段密度赋值策略（全水→水+骨骼→水+骨骼+空气），证实骨骼密度赋值对剂量准确性影响最大（计划靶区覆盖差异从16.1%降至1.6%），但未显影的金属植入物导致局部剂量高估达65%，凸显解剖结构的局限性；Kim等[16]在前列腺癌中对比发现，基于本地CT平均骨骼密度（300 HU）的赋值较文献值（491 HU）更优，前者γ通过率（94.0%）较后者（90.4%）显著提升，证实密度本地化校准的重要性；Hsu等[17]针对腹部放射治疗，通过CT模拟MRI-only放射治疗场景，采用基于人群HU值的多组织分类策略（3~10类），发现10类细分时计划靶区剂量偏低0.1%，而简化至3类时差异增大，偏低0.4%，揭示了腹部剂量计算对组织异质性敏感的特性。这些研究表明，体积密度赋值法在骨骼结构等较为稳定的区域表现较好，尤其是在骨组织和部分软组织的CT替代中展现了良好的计算效率。尽管体积密度赋值法简单高效，但它需要依赖人工勾画解剖结构，不仅耗时，且精确性取决于操作水平[13]，甚至在复杂解剖区域或伪影干扰下可能失效[15-16]，同时忽略了组织的不均匀性[18-19]。

随着对sCT生成需求的增加，体素转换法逐渐成为更常用的技术。该方法通常利用统计学习法从标准、特殊或混合MRI序列中提取图像中的MRI和CT特征，建立MRI体素信号强度与HU值的映射函数[10]，从而使MRI图像能够准确映射到sCT图像。Johansson等[20]通过高斯混合回归模型融合多序列MRI（包括T2加权和双回波超短回波时间序列），在头部sCT生成中实现了体素级映射，其全局平均绝对误差（Mean Absolute Error，MAE）为137 HU，但骨–软组织界面仍存在局部偏差。Edmund等[21]进一步验证了统计回归方法的优势，发现随机森林和高斯混合模型在脑部sCT的几何精度和剂量一致性上显著优于传统阈值分割法。针对盆腔解剖的复杂性，Liu等[22]提出结合模糊*C*均值分类与骨盆形状先验约束的方法，利用单一T1 Dixon序列MRI生成sCT，通过排除空气干扰和优化骨掩模，将计划靶区剂量差异控制在0.3 Gy以内。体素转换法的最大优势在于其细节处理能力，

能够更精确地捕捉复杂解剖结构的特征。在脑部肿瘤影像处理领域，该方法的效果尤为显著。然而，该方法高度依赖于大量标注数据和经验模型，且特征提取易受主观因素影响[10]。

另一种广泛应用于sCT生成的技术是基于图谱的方法。该方法涉及将采集的MRI图像与配准的CT-MRI图谱库进行比较，通过将采集的患者MRI与预先建立的MRI图谱进行复杂、非刚性配准，并将变形矩阵应用于相应的CT对，进而生成sCT图像[14]。Demol等[23]提出基于局部加权投票的图谱融合方法，通过计算目标MRI与图谱MRI的局部图像块相似度权重，实现多图谱CT的加权融合，在颅内立体定向治疗中实现平均剂量差异<2%。Arabi等[24]在此基础上引入骨骼增强策略，通过相位一致性特征和骨骼距离变换优化骨组织映射，显著提升骨骼区域HU值的准确性。Ahunbay等[25]提出基于患者自身CT的单图谱方法，通过刚性约束骨骼变换和MRI阈值空气修正，实现全自动化sCT生成，其MAE（16.6~25.9 HU）显著优于传统体素分类方法（44.2~66.7 HU）。基于图谱的方法具有全自动化的特点，并且能够使用经典的MRI序列[13]。在大规模的CT-MRI配对数据集上，基于图谱的方法表现出良好的稳定性。然而，其对图谱的依赖性使得当患者的解剖结构与图谱存在较大差异时缺乏鲁棒性，并且需要许多经过密集计算的成对配准图谱[13]。此方法难以处理个体差异较大的病例，无法准确反映患者的真实解剖结构。

近年来，深度学习技术的发展为sCT生成带来了新的机遇。基于深度学习的方法，尤其是卷积神经网络（Convolutional Neural Network，CNN）和生成对抗网络（Generative Adversarial Network，GAN），已经在sCT图像生成中取得了显著进展。这些深度学习方法通过大量标注数据的训练，能够捕捉复杂的非线性映射关系，生成高质量的sCT图像。与传统方法相比，深度学习的最大优势在于其灵活性和适应性。例如，CNN和GAN能够自动学习MRI与CT之间的复杂映射关系，生成的图像质量较高，且能够适应不同的解剖结构变化[5]。然而，深度学习方法也面临挑战。首先，这类方法对大规模标注数据的依赖较强，在数据量不足时可能无法充分训练模型。其次，模型计算复杂度高，训练过程耗时且对计算资源需求较大[11]。尽管如此，基于深度学习的sCT生成方法在处理复杂的脑部解剖结构时已展现出巨大的潜力[6]。

2 MRI图像生成sCT图像的算法

深度学习方法在医学影像生成领域取得显著的进展，其中CNN、GAN和变分自编码器（Variational Autoencoder，VAE）是最为常用的深度学习架构。通过学习MRI图像的特征，能够生成与CT图像高度相似的sCT图像。每种架构都有其独特的优势和挑战，且在不同的研究和应用场景中发挥着重要作用。图1展示了文献中用于医学图像生成的深度学习网络的简要发展历程。

2.1 架构介绍

2.1.1 CNN及其变体

CNN通过多层卷积操作能够有效提取图像中的局部特征和全局特征，已成为图像处理领域的重要工具。在sCT图像生成中，CNN被广泛应用于从MRI图像中提取多尺度特征，并进行体素级别的映射。CNN的特点在于其能够学习到图像中的空间特征，并通过不断的卷积和下采样操作，逐渐提取到更加抽象的特征，最终实现MRI到sCT的转换。然而，标准CNN在处理复杂三维数据时计算复杂度高，易出现梯度消失问题，导致深层网络的训练效果受限。

为解决这一问题，He等[26]提出了残差网络（Residual Network，ResNet），该网络通过跳跃连接有效解决了深层网络中的梯度消失问题。在sCT生成任务中，ResNet在较深的卷积层中表现出色，

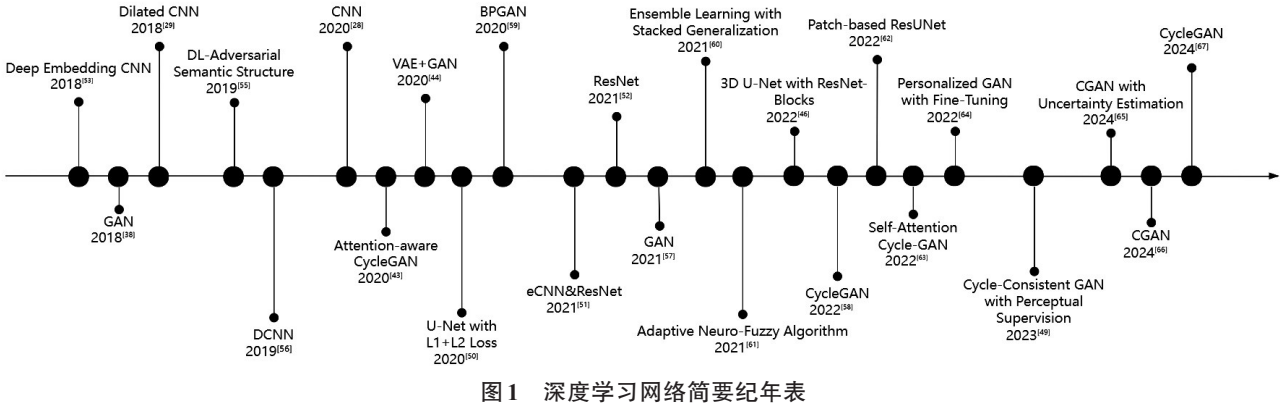


图1 深度学习网络简要纪年表

Figure 1 Brief chronological timeline of deep learning networks

能够捕捉到更复杂的图像特征。尽管ResNet改善了深层卷积中的训练瓶颈问题，但其计算复杂度较高的问题依然存在，尤其是在处理高维数据时，需要大量的计算资源。为进一步提升网络的计算效率，Huang等[27]提出了密集连接卷积网络（Densely Connected Convolutional Network，DenseNet），通过层间的密集连接减少了网络中的冗余参数，并显著提高了计算效率。在MRI图像生成sCT图像的任务中，DenseNet不仅缩短了训练时间，还显著提高了生成图像的质量。然而，DenseNet在处理大规模三维数据时，依然面临内存占用较高的问题，限制了其在某些临床场景中的应用。

在具体应用中，Alvarez等[28]通过系统评估关键参数对基于CNN的sCT生成质量的影响，包括训练集大小、MRI序列选择、标准化方法等，并比较了HighResNet和3D U-Net的效果，结果显示，使用较大训练集和适当预处理能提高sCT质量，且剂量学指标表现良好。Dinkla等[29]的研究表明，基于扩张卷积神经网络的sCT生成方法在脑部肿瘤放射治疗计划中表现出显著效果，生成的sCT在剂量计算中显示出高精度，体部轮廓内的MAE为（67±11）HU，靶区剂量差异仅偏低0.13%±0.39%，验证了MRI-only放射治疗计划的可行性。该进展为临床应用提供了重要基础，使得MRI图像生成sCT图像成为可能，由此促进了U-Net网络的应用[24,30-36]。然而，该法生成的sCT图像的精度严重依赖于MRI与CT的图像配准精度。

2.1.2 GAN及其变体

GAN是近年来图像生成领域中的重要技术，最早由Goodfellow等[37]在2014年提出。GAN由两个神经网络组成，分别是生成器和判别器，二者通过对抗性训练不断提升生成图像的质量。生成器的任务是生成与真实图像相似的合成图像，而判别器的任务则是判断输入的图像是真实的还是合成的。在sCT生成领域，GAN尤其适合处理复杂的解剖结构，其对抗性训练机制能够有效提升图像的细节还原和真实感[38]。

Mirza等[39]在2014年提出条件GAN（Conditional Generative Adversarial Network，CGAN），该模型允许在输入端加入条件信息，如病灶位置或标签，使得生成器能够根据特定条件生成更具针对性的图像。在从MRI图像生成sCT图像的任务中，CGAN通过加入病灶或解剖区域的标签，有效提升了生成图像的结构多样性和细节质量。然而，CGAN的主要问题在于，其对输入条件的依赖性较大，输入信息的质量直接影响了最终生成图像的质量。若条件信息不准确，生成图像可能偏离真实影像。

为了降低对输入条件的依赖，Isola等[40]提出了像素到像素生成对抗网络（Pix2Pix Generative Adversarial Network，Pix2Pix GAN），该模型使用成对的图像进行训练，直接学习从输入图像到目标图像的像素映射关系。该方法在MRI图像生成sCT图像中表现出色，特别是在有充足配对数据的情况下，生成图像的细节精度得到显著提升。然而，Pix2Pix GAN需要大量的配对训练数据，在实际临床中，获取如此大规模的配对数据往往存在困难。

针对配对数据需求高这一问题，Zhu等[41]提出了无监督的循环生成对抗网络（Cycle-Consistent Generative Adversarial Network，CycleGAN），该模型能够在没有配对数据的情况下训练，通过学习逆向映射提高生成图像的稳定性。CycleGAN的前向循环中，生成器G以MRI图作为输入，输出则为生成的sCT图，将判别器D用于区分生成的sCT图与CT图。将生成器G的输出作为生成器F的输入，F输出相应的伪MRI图。将生成器F输出的伪MRI图与输入生成器G的MRI图对比，以构成前向循环的循环一致性[2]。CycleGAN在MRI图像生成sCT图像的任务中表现优异，特别是在数据有限的场景下，依然能够生成高质量的sCT图像，极大地扩展了GAN的应用范围。然而，CycleGAN对输入数据的噪声较为敏感，噪声较大的MRI图像可能会导致生成图像中出现伪影。

Emami等[38]提出了一种基于GAN的新型方法，利用T1加权MRI生成脑部sCT，采用ResNet作为生成器并结合对抗训练策略，结果显示，GAN生成的sCT在定量指标和视觉细节保留上均优于传统CNN方法，尤其在骨骼边界和异常解剖区域能够高精度还原结构特征。该方法仅需单序列MRI输入，测试时间约5.7 s，为实时MRI-only放射治疗计划提供了高效解决方案。同时，GAN的生成能力使得它在处理高噪声的MRI图像时表现优异，从而减少了图像中伪影和噪声的影响。尽管如此，GAN的训练过程具有一定的不稳定性，容易出现模式崩溃问题，这也是未来研究中需要解决的技术挑战。

2.1.3 VAE及其结合模型

VAE是另一种生成模型，由Kingma等[42]提出，它通过学习潜在空间中的概率分布生成图像。与GAN不同，VAE通过最大化对数似然估计，将输入图像压缩到一个潜在空间中，并在该空间中生成与输入数据分布相似的新图像。在sCT生成中，

VAE的优势体现在其生成图像的稳定性，以及潜在空间表示的结构化特性，在一定程度上解决了GAN训练不稳定的问题。

Kearney等[43]提出的注意力感知循环一致性生成对抗网络首次将VAE与CycleGAN结合，通过注意力机制优化判别器的特征选择能力，显著改善了传统CycleGAN在MRI-to-CT转换中的收敛问题，其性能优于传统CycleGAN，但其生成图像仍存在局部细节模糊的局限，尤其在处理复杂解剖结构时表现受限。

针对生成图像质量优化问题，Yang等[44]提出的条件自编码生成对抗网络实现了进一步突破。该模型通过深度融合VAE的重构能力与GAN的细节生成优势，在编码器—解码器架构中引入分类器引导的对抗训练，有效解决了传统VAE生成图像模糊的问题。实验显示其sCT生成质量显著提升，MAE较传统FCN方法降低23.6%，同时，为多模态配准奠定了高质量数据基础。这种双重架构不仅保留了VAE的稳定性，还通过对抗训练增强了骨骼等细微结构的生成能力。

值得关注的是，条件自编码生成对抗网络的创新应用场景拓展了生成模型的价值。通过将生成的sCT作为中介，研究者成功将复杂的多模态MRI-CT配准转化为单模态sCT-CT配准，利用局部相位差分的形变场计算方法，使配准精度提升15%以上，同时修复异常MRI图像。这种“生成—配准”协同框架突破了传统多模态配准对解剖对齐的依赖，为解决医学图像跨模态融合难题提供了新范式。两代研究的演进体现了从单一生成任务到多任务协同优化的技术发展路径，为后续研究提供了架构融合与临床应用结合的重要参考。

2.1.4 其他深度学习模型

除了CNN、GAN和VAE，其他深度学习模型如3D U-Net也逐渐在sCT图像生成中得到应用。3D U-Net通过结合卷积和上采样操作，能够高效处理大规模三维医学影像数据，并支持多模态数据整合，是生成高分辨率图像的有力工具[45]。Zimmermann等[46]的研究进一步探索了3D U-Net的应用潜力，通过使用3D U-Net架构结合ResNet块，开发了一种不依赖特定MRI序列的深度学习模型，用于生成质子治疗中的sCT图像。该模型对47例脑膜瘤患者数据进行训练和验证，展现了出色的性能，其MAE在不同组织类型中分别为79.8/216.3 HU（T1序列）、71.1/186.1 HU（T2序列）和82.9/236.4 HU（T1CM序列），结构相似性（Structural Similarity Index，SSIM）达到0.95~0.98。此外，剂量参数的一致性分析表明，目标结构的剂量差异在1%以内，斑点差异图显示98%的斑点位置差异小于1 cm。该项研究的创新之处在于能够处理多种MRI序列，显著增强模型的泛化能力，但局限性在于数据集规模相对较小，且主要针对脑膜瘤患者，其在更广泛的临床应用中的有效性仍需进一步验证。

2.2 不同架构的性能比较

在sCT图像生成过程中，不同深度学习架构的表现各有千秋。CNN及其变体（如ResNet和DenseNet）通过增强网络深度和减少参数量，提高了图像生成的质量和效率，但在处理大规模三维数据时，仍面临计算资源占用较高的问题。GAN及其变体（如CGAN、Pix2Pix GAN和CycleGAN）通过引入卷积层、条件信息和无监督学习，逐步解决了生成图像不稳定、多样性不足和配对数据需求高的问题。然而，GAN类模型的训练过程依然存在不稳定性和噪声敏感性问题。VAE及其结合模型，通过对潜在空间的优化，提升了生成图像的清晰度和训练效率，但其计算复杂性依然较高。

通过对比CNN、GAN、VAE等模型的性能，研究人员能够评估不同架构的优势与局限。常用的性能评估指标包括MAE、SSIM和峰值信噪比（Peak Signal-to-Noise Ratio，PSNR）。表1总结了不同模型生成sCT的性能。表2是不同模型在同一数据集SynthRAD2023[47]上的性能对比，各个团队所采用的模型参考了SynthRAD2023挑战报告[48]。

3 MRI图像生成sCT图像的前沿进展

MRI图像生成sCT图像技术的发展历程，体现了从早期的CNN到GAN，再到个性化建模和不确定性感知方法的逐步演进。早期，Dinkla等[29]利用Dilated CNN生成脑部sCT图像，尽管在放射治疗剂量规划中表现良好，但在骨组织的估计上仍存在不足。Xiang等[53]针对该问题引入了深度嵌入卷积神经网络，显著提高了骨组织和软组织的估计精度，然而复杂的网络结构导致计算效率较低。

Liu等[54]引入GAN，显著提升了sCT生成的质量，特别是在PET/MRI成像中的衰减校正中表现优异。尽管如此，GAN模型在训练过程中易出现模式崩溃，导致生成图像的多样性不足。为解决该问题，Arabi等[55]提出了语义结构GAN，通过优化生成器和鉴别器的架构，有效减少了伪影并提升了骨组织的估计精度，但在软组织的估计方面仍然存在改进空间。

为同时提升骨组织和软组织的估计精度，

表1　不同模型生成sCT性能总结

Table 1　Summary of sCT performance generated by different models

作者	模型	数据集	部位	评价指标［MAE(HU)，PSNR（dB）］
Alvarez等[28]	3D CNN	402例脑肿瘤患者	脑部	MAE（78±2）
Dinkla等[29]	Dilated CNN	52例颅内放射治疗患者	脑部	MAE（67±11）
Emami等[38]	GAN（ResNet生成器）、CNN	15例脑癌患者	脑部	GAN：MAE（89.3±10.3）、SSIM（0.83±0.03）、PSNR（26.6±1.2）；CNN：MAE（102.4±11.1）
Kearney等[43]	A-CycleGAN（结合VAE）	60例训练/验证，30例测试	头颈/脑部	MAE（19.61, 95%*CI*: 18.83~20.39）、SSIM（0.778, 95%*CI*: 0.758~0.798）、PSNR（62.35, 95%*CI*: 61.80~62.90）
Zimmermann等[46]	3D U-Net（含ResNet块）	47例脑膜瘤患者	脑部	MAE（T1: 79.8/216.3，T2: 71.1/186.1，T1CM: 82.9/236.4）、SSIM（0.95~0.98）
Gu等[49]	改进CycleGAN（含感知监督）	25例（3 416张MRI-CT图像）	脑部	MAE（0.147）、PSNR（19.27）
Li等[50]	CycleGAN、Pix2Pix、U-Net	未明确患者数	脑部	U-Net：MAE（74.19）、SSIM（0.944 0）、PSNR（32.44）
Bahrami等[51]	eCNN、U-Net、GAN、V-Net、ResNet	20例男性骨盆（MRI-CT）	骨盆	eCNN：MAE（26.03±8.85）ResNet：PSNR（29.38±1.75）
Gholamiankhah等[52]	ResNet、GAN	86例脑部患者	脑部	ResNet：MAE（114.1±27.5）；GAN：MAE（-10.9±147.0）、SSIM/PSNR（与ResNet相近但略低）

表2　不同方法在同一数据集上的性能对比

Table 2　Performance comparison of different methods on the same dataset

团队	模型	MAE（HU）	PSNR（dB）	SSIM
SMU-MedVision	Transformer	58.827 2±13.406 3	29.605 6±1.788 7	0.885 1±0.028 8
Jetta_Pang	CNN	65.733 5±13.753 3	28.383 2±1.684 0	0.868 8±0.031 9
FAYIU	Transformer	61.717 5±13.323 7	28.826 8±1.612 9	0.876 1±0.030 2
iu_mia	CNN	62.826 9±13.771 9	28.700 8±1.585 1	0.873 0±0.029 3
ShantouBME	CNN	67.536 7±14.175 0	28.049 1±1.545 3	0.863 2±0.031 4
PSICPT_AI4PT	CNN	78.002 4±27.439 5	27.548 5±2.162 2	0.839 4±0.049 4
SubtleCT	CNN	66.527 4±14.630 6	28.509 9±1.678 4	0.868 5±0.029 4
mriG	CNN	82.010 6±17.775 0	26.379 5±1.526 8	0.841 7±0.035 0
Breizh-CT	GAN	93.569 2±19.010 1	25.857 1±1.431 4	0.805 9±0.032 1
SKJP	CNN	88.419 6±26.885 4	26.440 8±2.033 9	0.814 8±0.043 0
X-MAN	GAN	117.881 1±45.075 1	25.636 3±2.200 7	0.773 8±0.096 9

Spadea等[56]采用深度卷积神经网络融合多模态数据，有效提高了sCT图像的空间分辨率。然而，该方法对骨组织的估计仍存在局限。Bourbonne等[57]进一步评估了GAN生成的sCT在脑部立体定向放射治疗中的剂量学准确性，虽然剂量差异有所减少，但骨骼HU值估计仍不够精确。

针对不同扫描仪数据异质性的问题，Jabbarpour等[58]引入CycleGAN，通过无监督学习应对数据多样性，尤其在脑部和盆腔放射治疗中表现出色。但CycleGAN在处理软组织时的细节保留仍有不足。Alvarez等[28]提出基于剂量驱动的深度学习方法，通过优化sCT的质量评估，有效提升了软组织区域的预测精度，尽管其在复杂解剖结构（如颅骨）的估计上仍然存在不足。

Xu等[59]提出了双向生成对抗网络，通过双向CT到MRI预测模型显著提升了骨组织和软组织的估计精度，但依然需要大规模数据集增强泛化能力。Boukellouz等[60]提出的基于patch的多模态特征提取模型，利用集成学习技术进一步优化了sCT图像的生成，但细节还原和分辨率问题仍然存在。随

后，Yousefi Moteghaed等[61]通过多模态MRI图像生成sCT图像，减少了对配对数据的依赖，优化了放射治疗剂量学规划。尽管其在软组织的估计中表现较好，但在处理复杂解剖结构时，特别是颅骨区域，依然有改进空间。为应对这一问题，Eshraghi Boroojeni等[62]开发了高分辨率sCT生成模型，特别适用于小儿颅骨成像，在高噪声MRI数据的处理上有所突破，但在图像细节保留方面仍然存在不足。与此同时，Wang等[63]采用了自注意力CycleGAN框架，在儿童脑肿瘤质子治疗中生成了高质量的sCT图像，提升了治疗计划的灵活性和准确性。

Ma等[64]引入个性化建模，通过每日MRI扫描生成与患者解剖结构动态变化相匹配的更加精准的sCT图像，尤其在脑部放射治疗中展现出色表现。然而，该方法对计算资源需求较大。为进一步增强模型的鲁棒性，Li等[65]提出了不确定性感知的贝叶斯GAN模型，能够在质子治疗计划中生成更精确的sCT图像，并通过不确定性预测增强了网络误差的应对能力，尽管该模型在计算资源消耗上依然较高。

在技术优化的基础上，Tan等[66]通过像素到像素框架为神经外科手术规划开发了适用于颅骨和脑组织的sCT生成方法，尽管该方法在处理复杂病理（如脑膜瘤的钙化区域）时表现良好，但仍需在MRI伪影抑制方面行进一步优化。为了增强放射治疗计划的鲁棒性，Bird等[67]研究了多部位sCT生成技术，展示了深度学习模型在盆腔、脑部和头颈部癌症放射治疗计划中的广泛应用。然而，由于数据集的异质性，模型在骨组织细节的估计上仍需优化。

4 总结与展望

近年来，随着深度学习技术的迅猛发展，基于MRI图像生成sCT图像的技术在医学影像领域取得了显著进展。这些进展主要体现在sCT图像生成的准确性和临床适用性上，特别是在放射治疗中的应用。

早期的研究通过CNN实现了基础的MRI图像到sCT图像的转换，但由于在骨组织和软组织的估计上的局限性，模型的临床应用受到了限制。随着GAN的引入，sCT图像的生成质量得到了显著提升，特别是在处理多模态影像数据方面表现优异。无监督学习方法（如CycleGAN）的应用进一步扩展了sCT生成技术的适用范围，减少了对配对数据集的需求，提升了模型的鲁棒性。近期研究[64-65]中，个性化建模和不确定性感知模型的引入进一步优化了在个体化放射治疗计划中的应用。

尽管取得了这些进展，sCT生成技术依然面临多项挑战。数据集的规模和多样性不足限制了模型的泛化能力，尤其是在处理复杂的解剖结构和极端情况时，生成图像的精度仍有待提高。此外，骨组织与软组织之间的密度转换和多模态数据融合技术仍需进一步优化。

为推进sCT生成技术的临床转化，未来研究应重点关注以下方向：构建更大规模的多中心数据集，并结合不同扫描仪、不同解剖区域的异质性数据，以扩大训练数据集的规模与多样性，提升模型的适用性和鲁棒性；进一步优化模型在骨组织和软组织之间的密度转换，特别是在复杂解剖结构中的应用，以提高骨组织和软组织的估计精度。整合不同成像模态之间的信息时，需进一步优化特征提取和匹配算法。同时，优化计算资源需求也是未来研究的重要方向之一，未来的研究可以通过模型压缩、稀疏化技术以及高效的并行计算，降低计算资源的需求，使得这些先进技术能够更快地转化为实际临床应用；随着个性化治疗的需求日益增长，未来的研究可以进一步结合不确定性建模方法，为不同患者的治疗计划提供更为精准和可靠的sCT图像。

未来，通过这些努力，MRI图像生成sCT图像技术有望在放射治疗和其他医学影像领域中得到更广泛的应用，从而进一步推动精准医学的发展。

参考文献

[1] LERNER M, MEDIN J, JAMTHEIM GUSTAFSSON C, et al. Prospective clinical feasibility study for MRI-only brain radiotherapy[J]. Frontiers in Oncology, 2021, 11: 812643.

[2] 奚谦逸, 张钒, 李奇轩, 等. 循环生成对抗网络基于颅脑MR图生成伪CT图模型[J]. 中国医学影像技术, 2023, 39(2): 264-269.

[3] FRITZ J. Automated and radiation-free generation of synthetic CT from MRI data: Does AI help to cross the finish line?[J]. Radiology, 2021, 298(2): 350-352.

[4] DARYANANI A, TURKBEY B. Recent advancements in CT and MR imaging of prostate cancer[J]. Seminars in Nuclear Medicine, 2022, 52(3): 365-373.

[5] RANJBARZADEH R, BAGHERIAN KASGARI A, JAFARZADEH GHOUSHCHI S, et al. Brain tumor segmentation based on deep learning and an attention mechanism using MRI multi-modalities brain images[J]. Scientific Reports, 2021, 11(1): 10930.

[6] CURRIE G, HAWK K E, ROHREN E, et al. Machine

learning and deep learning in medical imaging: Intelligent imaging[J]. Journal of Medical Imaging and Radiation Sciences, 2019, 50(4): 477-487.

[7] 陈扬洋, 钱鹏江, 赵开发, 等. 基于mDixon序列下腹部MRI数据的sCT生成方法[J]. 计算机工程, 2019, 45(7): 273-281.

[8] OWRANGI A M, GREER P B, GLIDE-HURST C K. MRI-only treatment planning: Benefits and challenges[J]. Physics in Medicine and Biology, 2018, 63(5): 05TR01.

[9] 菅影超, 付东山, 王伟. 基于MRI的合成CT生成方法综述[J]. 中国生物医学工程学报, 2020, 39(4): 485-492.

[10] 毛玲丽, 吴秉志, 吴香奕, 等. MRI-only放射治疗方案中基于深度学习生成伪CT最新进展[J]. 中国医学影像技术, 2022, 38(4): 619-623.

[11] TALO M, BALOGLU U B, YILDIRIM Ö, et al. Application of deep transfer learning for automated brain abnormality classification using MR images[J]. Cognitive Systems Research, 2019, 54: 176-188.

[12] LERNER M, MEDIN J, JAMTHEIM GUSTAFSSON C, et al. Clinical validation of a commercially available deep learning software for synthetic CT generation for brain[J]. Radiation Oncology, 2021, 16(1): 66.

[13] LARGENT A, BARATEAU A, NUNES J C, et al. Pseudo-CT generation for MRI-only radiation therapy treatment planning: Comparison among patch-based, atlas-based, and bulk density methods[J]. International Journal of Radiation Oncology, Biology, Physics, 2019, 103(2): 479-490.

[14] O'CONNOR L M, CHOI J H, DOWLING J A, et al. Comparison of synthetic computed tomography generation methods, incorporating male and female anatomical differences, for magnetic resonance imaging-only definitive pelvic radiotherapy[J]. Frontiers in Oncology, 2022, 12: 822687.

[15] CHIN A L, LIN A, ANAMALAYIL S, et al. Feasibility and limitations of bulk density assignment in MRI for head and neck IMRT treatment planning[J]. Journal of Applied Clinical Medical Physics, 2014, 15(5): 4851.

[16] KIM J, GARBARINO K, SCHULTZ L, et al. Dosimetric evaluation of synthetic CT relative to bulk density assignment-based magnetic resonance-only approaches for prostate radiotherapy[J]. Radiation Oncology, 2015, 10: 239.

[17] HSU S H, ZAWISZA I, O'GRADY K, et al. Towards abdominal MRI-based treatment planning using population-based Hounsfield units for bulk density assignment[J]. Physics in Medicine and Biology, 2018, 63(15): 155003.

[18] TYAGI N. Challenges and requirements[M]. MRI for Radiotherapy. Cham: Springer International Publishing, 2019: 119-129.

[19] JOHNSTONE E, WYATT J J, HENRY A M, et al. Systematic review of synthetic computed tomography generation methodologies for use in magnetic resonance imaging-only radiation therapy[J]. International Journal of Radiation Oncology, Biology, Physics, 2018, 100(1): 199-217.

[20] JOHANSSON A, KARLSSON M, NYHOLM T. CT substitute derived from MRI sequences with ultrashort echo time[J]. Medical Physics, 2011, 38(5): 2708-2714.

[21] EDMUND J M, KJER H M, VAN LEEMPUT K, et al. A voxel-based investigation for MRI-only radiotherapy of the brain using ultra short echo times[J]. Physics in Medicine and Biology, 2014, 59(23): 7501-7519.

[22] LIU L, JOLLY S, CAO Y, et al. Female pelvic synthetic CT generation based on joint intensity and shape analysis [J]. Physics in medicine and Biology, 2017, 62(8): 2935-2949.

[23] DEMOL B, BOYDEV C, KORHONEN J, et al. Dosimetric characterization of MRI-only treatment planning for brain tumors in atlas-based pseudo-CT images generated from standard T1-weighted MR images[J]. Medical Physics, 2016, 43(12): 6557.

[24] ARABI H, DOWLING J A, BURGOS N, et al. Comparative study of algorithms for synthetic CT generation from MRI: Consequences for MRI-guided radiation planning in the pelvic region[J]. Medical Physics, 2018, 45(11): 5218-5233.

[25] AHUNBAY E E, THAPA R, CHEN X, et al. A technique to rapidly generate synthetic computed tomography for magnetic resonance imaging-guided online adaptive replanning: An exploratory study[J]. International Journal of Radiation Oncology, Biology, Physics, 2019, 103(5): 1261-1270.

[26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016[C]. Las Vegas: IEEE, 2016.

[27] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017[C]. Honolulu: IEEE, 2017.

[28] ALVAREZ ANDRES E, FIDON L, VAKALOPOULOU M, et al. Dosimetry-driven quality measure of brain pseudo computed tomography generated from deep learning for MRI-only radiation therapy treatment planning[J]. International Journal of Radiation Oncology, Biology, Physics, 2020, 108(3): 813-823.

[29] DINKLA A M, WOLTERINK J M, MASPERO M, et al. MR-only brain radiation therapy: Dosimetric evaluation of synthetic CTs generated by a dilated convolutional neural network[J]. International Journal of Radiation Oncology, Biology, Physics, 2018, 102(4): 801-812.

[30] CHEN S, QIN A, ZHOU D, et al. Technical Note: U-net-generated synthetic CT images for magnetic resonance

imaging-only prostate intensity-modulated radiation therapy treatment planning[J]. Medical Physics, 2018, 45(12): 5659-5665.

[31] DINKLA A M, FLORKOW M C, MASPERO M, et al. Dosimetric evaluation of synthetic CT for head and neck radiotherapy generated by a patch - based three - dimensional convolutional neural network[J]. Medical Physics, 2019, 46(9): 4095-4104.

[32] FU J, YANG Y, SINGHRAO K, et al. Deep learning approaches using 2D and 3D convolutional neural networks for generating male pelvic synthetic computed tomography from magnetic resonance imaging[J]. Medical Physics, 2019, 46(9): 3788-3798.

[33] NEPPL S, LANDRY G, KURZ C, et al. Evaluation of proton and photon dose distributions recalculated on 2D and 3D Unet-generated pseudoCTs from T1-weighted MR head scans[J]. Acta Oncologica, 2019, 58(10): 1429-1434.

[34] WANG Y, LIU C, ZHANG X, et al. Synthetic CT generation based on T2 weighted MRI of nasopharyngeal carcinoma (NPC) using a deep convolutional neural network (DCNN) [J]. Frontiers in Oncology, 2019, 9: 1333.

[35] GUPTA D, KIM M, VINEBERG K A, et al. Generation of synthetic CT images from MRI for treatment planning and patient positioning using a 3-channel U-Net trained on sagittal images[J]. Frontiers in Oncology, 2019, 9: 964.

[36] 杨国亮, 赖振东, 喻丁玲. 一种改进UNet++网络用于检测黑色素瘤皮肤病变[J]. 中国医学影像技术, 2020, 36 (12): 1877-1881.

[37] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets. International Conference on Weural Information Processing Systems, 2014[C]. MIT Press, 2014.

[38] EMAMI H, DONG M, NEJAD-DAVARANI S P, et al. Generating synthetic CTs from magnetic resonance images using generative adversarial networks[J]. Medical Physics, 2018.

[39] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J]. Computer Science, 2014:2672-2680.

[40] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-Image translation with conditional adversarial networks. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017[C]. Honolulu: IEEE, 2017.

[41] ZHU J-Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks. IEEE International Conference on Computer Vision (ICCV), 2017[C]. Venice: IEEE, 2017.

[42] KINGMA D P, WELLING M. Auto-encoding variational bayes[Z]. CoRR, 2013, abs/1312.6114.

[43] KEARNEY V, ZIEMER B P, PERRY A, et al. Attention-aware discrimination for MR-to-CT image translation using cycle-consistent generative adversarial networks[J]. Radiology Artificial Intelligence, 2020, 2(2): e190027.

[44] YANG H, QIAN P, FAN C. An indirect multimodal image registration and completion method guided by image synthesis[J]. Computational and Mathematical Methods in Medicine, 2020, 2020: 2684851.

[45] ÇIÇEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: Learning dense volumetric segmentation from sparse annotation[Z]. CoRR, 2016, abs/1606.06650.

[46] ZIMMERMANN L, KNÄUSL B, STOCK M, et al. An MRI sequence independent convolutional neural network for synthetic head CT generation in proton therapy[J]. Zeitschrift Fur Medizinische Physik, 2022, 32(2): 218-227.

[47] THUMMERER A, VAN DER BIJL E, GALAPON A Jr, et al. SynthRAD2023 grand challenge dataset: Generating synthetic CT for radiotherapy[J]. Medical Physics, 2023, 50(7): 4664-4674.

[48] HUIJBEN E M C, TERPSTRA M L, GALAPON A Jr, et al. Generating synthetic computed tomography for radiotherapy: SynthRAD2023 challenge report[J]. Medical Image Analysis, 2024, 97: 103276.

[49] GU X, ZHANG Y, ZENG W, et al. Cross-modality image translation: CT image synthesis of MR brain images using multi generative network with perceptual supervision[J]. Computer Methods and Programs in Biomedicine, 2023, 237: 107571.

[50] LI W, LI Y, QIN W, et al. Magnetic resonance image (MRI) synthesis from brain computed tomography (CT) images based on deep learning methods for magnetic resonance (MR) - guided radiotherapy[J]. Quantitative Imaging in Medicine and Surgery, 2020, 10(6): 1223-1236.

[51] BAHRAMI A, KARIMIAN A, ARABI H. Comparison of different deep learning architectures for synthetic CT generation from MR images[J]. Physica Medica, 2021, 90: 99-107.

[52] GHOLAMIANKHAH F, MOSTAFAPOUR S, ARABI H. Deep learning-based synthetic CT generation from MR images: Comparison of generative adversarial and residual neural networks[J]. International Journal of Radiation Research, 2021, 20(1): 121-130.

[53] XIANG L, WANG Q, NIE D, et al. Deep embedding convolutional neural network for synthesizing CT image from T1-Weighted MR image[J]. Medical Image Analysis, 2018, 47: 31-44.

[54] LIU F, JANG H, KIJOWSKI R, et al. Deep learning MR imaging-based attenuation correction for PET / MR imaging[J]. Radiology, 2018, 286(2): 676-684.

[55] ARABI H, ZENG G, ZHENG G, et al. Novel adversarial semantic structure deep learning for MRI-guided attenuation correction in brain PET / MRI[J]. European Journal of Nuclear Medicine and Molecular Imaging, 2019, 46(13): 2746-2759.

[56] SPADEA M F, PILEGGI G, ZAFFINO P, et al. Deep convolution neural network (DCNN) multiplane approach to synthetic CT generation from MR images—application in brain proton therapy[J]. International Journal of Radiation Oncology, Biology, Physics, 2019, 105(3): 495-503.

[57] BOURBONNE V, JAOUEN V, HOGNON C, et al. Dosimetric validation of a GAN-based pseudo-CT generation for MRI-only stereotactic brain radiotherapy[J]. Cancers, 2021, 13(5): 1082.

[58] JABBARPOUR A, MAHDAVI S R, VAFAEI SADR A, et al. Unsupervised pseudo CT generation using heterogenous multicentric CT/MR images and CycleGAN: Dosimetric assessment for 3D conformal radiotherapy[J]. Computers in Biology and Medicine, 2022, 143: 105277.

[59] XU L, ZENG X, ZHANG H, et al. BPGAN: Bidirectional CT-to-MRI prediction using multi-generative multi-adversarial nets with spectral normalization and localization [J]. Neural Networks, 2020, 128: 82-96.

[60] BOUKELLOUZ W, MOUSSAOUI A. Magnetic resonance-driven pseudo CT image using patch-based multi-modal feature extraction and ensemble learning with stacked generalisation[J]. Journal of King Saud University-Computer and Information Sciences, 2021, 33(8): 999-1007.

[61] YOUSEFI MOTEGHAED N, MOSTAAR A, AZADEH P. Generating pseudo-computerized tomography (P-CT) scan images from magnetic resonance imaging (MRI) images using machine learning algorithms based on fuzzy theory for radiotherapy treatment planning[J]. Medical Physics, 2021, 48(11): 7016-7027.

[62] ESHRAGHI BOROOJENI P, CHEN Y, COMMEAN P K, et al. Deep-learning synthesized pseudo-CT for MR high-resolution pediatric cranial bone imaging (MR-HiPCB) [J]. Magnetic Resonance in Medicine, 2022, 88(5): 2285-2297.

[63] WANG C, UH J, MERCHANT T E, et al. Facilitating MR-guided adaptive proton therapy in children using deep learning-based synthetic CT[J]. International Journal of Particle Therapy, 2022, 8(3): 11-20.

[64] MA X, CHEN X, WANG Y, et al. Personalized modeling to improve pseudo-computed tomography images for magnetic resonance imaging-guided adaptive radiation therapy[J]. International Journal of Radiation Oncology, Biology, Physics, 2022, 113(4): 885-892.

[65] LI X, BELLOTTI R, MEIER G, et al. Uncertainty-aware MR-based CT synthesis for robust proton therapy planning of brain tumour[J]. Radiotherapy and Oncology, 2024, 191: 110056.

[66] TAN Y, PATEL R V, WANG Z, et al. Generation and applications of synthetic computed tomography images for neurosurgical planning[J]. Journal of Neurosurgery, 2024, 141(3): 742-751.

[67] BIRD D, SPEIGHT R, ANDERSSON S, et al. Deep learning MRI-only synthetic-CT generation for pelvis, brain and head and neck cancers[J]. Radiotherapy and Oncology, 2024, 191: 110052.

（上接第28页）

apoptosis by increasing oxidative stress in proximal tubular epithelial cells[J]. Endocrinology, 2011, 152(8): 3135-3142.

[69] OH Y. The insulin-like growth factor system in chronic kidney disease: Pathophysiology and therapeutic opportunities[J]. Kidney Research and Clinical Practice, 2012, 31 (1): 26-37.

[70] AGHANOORI M-R, AGARWAL P, GAUVIN E, et al. CEBPβ regulation of endogenous IGF-1 in adult sensory neurons can be mobilized to overcome diabetes-induced deficits in bioenergetics and axonal outgrowth[J]. Cellular and Molecular Life Sciences, 2022, 79(4): 193.

[71] LIU C, LIU S, WANG S, et al. IGF-1 via PI3K/Akt/S6K signaling pathway protects DRG neurons with high glucose-induced toxicity[J]. Open Life Sciences, 2019, 14 (1): 502-514.

[72] 张松涛, 王萍, 郭慧 . 2型糖尿病患者超敏c反应蛋白、胰岛素样生长因子-1及低密度脂蛋白与周围神经传导速度的相关性[J]. 广州医科大学学报, 2022, 50(4): 46-50.

[73] RESANOVIĆ I, GLUVIĆ Z, ZARIĆ B, et al. Effect of hyperbaric oxygen therapy on fatty acid composition and insulin-like growth factor binding protein 1 in adult type 1 diabetes mellitus patients: A pilot study[J]. Canadian Journal of Diabetes, 2020, 44(1): 22-29.

[74] American Diabetes Association Standards of medical care in diabetes-2015 abridged for primary care providers[J]. Clinical Diabetes, 2015, 33(2): 97-111.

[75] WANG H, ZHANG H, CAO F, et al. Protection of insulin-like growth factor 1 on experimental peripheral neuropathy in diabetic mice[J]. Molecular Medicine Reports, 2018, 18(5): 4577-4586.

[76] ISHII D N. Implication of insulin-like growth factors in the pathogenesis of diabetic neuropathy[J]. Brain Research Reviews, 1995, 20(1): 47-67.

[77] SULLIVAN K A, KIM B, FELDMAN E L. Insulin-like growth factors in the peripheral nervous system[J]. Endocrinology, 2008, 149(12): 5963-5971.

[78] KANEKO H, NAMIHIRA M, YAMAMOTO S, et al. Oral administration of cyclic glycyl-proline facilitates task learning in a rat stroke model[J]. Behavioural Brain Research, 2022, 417: 113561.