

# 压缩感知磁共振成像双域三边复数GAN模型

王玉露<sup>1</sup>, 吴敏<sup>2</sup>, 詹天明<sup>3</sup>, 孙玉宝<sup>1\*</sup>

(1. 南京信息工程大学计算机学院, 江苏南京 210044; 2. 中国人民解放军东部战区总医院医学工程科, 江苏南京 210016; 3. 南京审计大学计算机学院, 江苏南京 211815)

**摘要:** 压缩感知磁共振成像 (Compressed Sensing Magnetic Resonance Imaging, CS-MRI) 通过减少频域  $k$ -空间采样数据量来加速成像过程, 其核心科学问题在于如何从欠采样的、不完备的  $k$ -空间数据中高效地重建出原高质量的核磁共振成像 (Magnetic Resonance Imaging, MRI) 图像。近年来, 基于深度神经网络的重建方法取得了重要进展, 有效推动了重建图像质量的持续提升。然而, 现有的深度重建网络大多采用实数网络模型, 而原始  $k$ -空间采样数据为复数信息, 实数网络模型不利于充分捕获复数采样所蕴含的图像细节和结构特征, 这直接影响了重建质量的进一步提升。同时, 现有重建网络通常缺乏频域  $k$ -空间与图像域之间的交互约束机制, 双域特征学习存在不足。针对这些问题, 本文创新性地提出了一种双域三边复数生成对抗网络 (Dual-domain Tri-edge Complex Generative Adversarial Network, Dual-Tri-CGAN) 重建模型。该模型主要包含空间生成器和图像域生成器两个生成器, 它们共同构成了双域生成器框架, 并采用实数判别器对生成结果进行评估。双域生成器均采用多尺度编解码架构, 能够有效捕捉不同尺度的图像特征。此外, 双域生成器通过残差连接实现多尺度特征的有效融合, 增强了特征表示能力。为进一步提升双域生成器的协同生成能力, 本文采用了三边对抗博弈学习模式。该模式不仅包含双域生成器与判别器间的常规对抗训练, 还引入了双域子生成器间的对抗机制。在损失函数设计方面, 除常规对抗损失外, 本文专门设计了一种新颖的相似性对抗损失函数。该损失函数通过约束两个生成器输出间的一致性, 促使它们在对抗训练中相互促进、协同优化, 提升 MRI 重建图像质量。在实验验证方面, 本文使用公开的 IXI Brain (Information eXtraction from Images Brain) 数据集对模型性能进行系统测试。实验结果表明, 相较于现有的生成对抗网络 (Generative Adversarial Network, GAN) 重建模型, DualTri-CGAN 能够更好地处理  $k$ -空间复采样数据, 避免因实部与虚部分离处理而引入重建误差。同时, 得益于所提出的双域生成器框架和三边对抗博弈学习模式, 该模型有效提升了重建图像的峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 和结构相似性指数 (Structural Similarity Index Measure, SSIM), 在 10% 低采样率条件下, DualTri-CGAN 仍然能够有效恢复 MRI 图像的边缘结构和纹理细节, 展现出良好的重建性能和鲁棒性。

**关键词:** 核磁共振成像 (MRI) 压缩感知重建; 复数生成对抗网络 (GAN); 双域生成器; 三边对抗学习

**基金项目:** 国家自然科学基金 (No.92470126, No.62276139); 江苏省重大研究计划 (No.BG2024042); 江苏省青蓝工程 (No.R2024Q06)

中图分类号: TP391.41; TP751

文献标识码: A

文章编号: 0372-2112(2026)01-0381-14

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250371

## Dual-Domain Tripartite Complex GAN for Compressed Sensing MRI Reconstruction

WANG Yulu<sup>1</sup>, WU Min<sup>2</sup>, ZHAN Tianming<sup>3</sup>, SUN Yubao<sup>1\*</sup>

(1. School of Computer Science, Nanjing University of Information Science and Technology, Nanjing, Jiangsu 210044, China;

2. Department of Medical Engineering, General Hospital of Eastern Theater Command, Chinese People's Liberation Army, Nanjing, Jiangsu 210016, China; 3. School of Computer Science, Nanjing Audit University, Nanjing, Jiangsu 211815, China)

**Abstract:** Compressed sensing magnetic resonance imaging (CS-MRI) accelerates image acquisition by substantially reducing the amount of data sampled in the frequency domain ( $k$ -space). The core scientific challenge lies in the high-fidelity reconstruction of MRI images from such incomplete, under sampled  $k$ -space data. While deep neural network-based reconstruction methods have recently driven significant progress and continuously improved output quality, a key limitation remains: most existing deep models employ real-valued network architectures. This creates a critical mismatch, as the raw data from magnetic resonance imaging (MRI) scanners is inherently complex-valued, containing both magnitude and phase information. Real-valued networks typically process this data by separating or discarding its complex components, which hinders the full exploitation of the detailed structural features inherent in complex  $k$ -space signals, thereby limiting further

gains in reconstruction fidelity. Furthermore, prevailing reconstruction networks often operate within a single domain (image or  $k$ -space) or use simple sequential processing, lacking a sophisticated interactive mechanism that explicitly enforces consistency between the frequency and image domains. This leads to insufficient and sub-optimal dual-domain feature learning, leaving potential performance improvements unrealized. To address these issues, this paper proposes an innovative dual-domain, three-party complex-valued generative adversarial network named the dual-domain tri-edge complex generative adversarial network (DualTri-CGAN) reconstruction model. Its core architecture features two principal generators: a  $k$ -space generator and an image-domain generator, forming a comprehensive dual-domain generation framework. This framework is paired with a real-valued discriminator that evaluates the authenticity of the generated outputs. Both generators are built on a multi-scale encoder-decoder structure, enabling effective extraction and utilization of image features across different scales, from local textures to global anatomy. Additionally, residual connections are integrated within the generators to effectively fuse multi-scale features, significantly enhancing overall feature representation. A pivotal innovation is the introduction of a three-party adversarial learning paradigm. This advanced scheme goes beyond the conventional adversarial game between the generators and the discriminator by incorporating a novel, direct adversarial mechanism between the two sub-generators, fostering a competitive yet collaborative dynamic. For the loss function, alongside standard adversarial losses, a novel similarity adversarial loss is designed. This specialized loss explicitly enforces consistency and alignment between the outputs of the two generators, compelling them to mutually inform, regularize, and optimize each other during adversarial training. This results in superior collaborative performance and, ultimately, higher-quality MRI reconstructions. For experimental validation, the proposed DualTri-CGAN model was systematically evaluated on the public information extraction from images brain (IXI Brain) dataset. Results demonstrate that, compared to existing state-of-the-art generative adversarial network (GAN)-based models, DualTri-CGAN exhibits superior native handling of complex-valued  $k$ -space data. This approach effectively avoids the reconstruction errors and information loss typically arising from the separate processing of real and imaginary components in real-valued networks. Moreover, the synergistic benefits of the dual-domain generator framework and the three-party adversarial learning strategy collectively lead to measurable improvements in key image quality metrics, namely higher peak signal-to-noise ratio (PSNR) and structural similarity index (SSIM). Notably, even under a stringent 10% sampling rate, DualTri-CGAN maintains a robust capability to accurately recover fine edge details and nuanced textures in MRI images. These findings underscore the model's excellent reconstruction performance, generalization ability, and strong robustness, marking a promising advancement for fast, high-quality CS-MRI.

**Keywords:** magnetic resonance imaging (MRI) compressed sensing reconstruction; complex-valued generative adversarial network (GAN); dual-domain generator; tripartite adversarial learning

**Foundation Item(s):** National Natural Science Foundation of China (No.92470126, No.62276139); Major Research Plan of Jiangsu Province (No.BG2024042); Jiangsu Provincial Qinglan Project (No.R2024Q06)

## 0 引言

核磁共振成像 (Magnetic Resonance Imaging, MRI) 是现代临床医学诊断中使用最广泛的成像技术之一。但 MRI 需在频域  $k$ -空间进行稠密扫描, 因此存在成像时间过长的问题。同时, 在扫描时要求患者保持静止状态, 患者的动作和生理运动 (如心脏搏动和呼吸运动) 会导致运动伪影。为此, 如何加速 MRI 并消除成像伪影是需解决的关键问题<sup>[1]</sup>。并行成像技术从硬件设备方面加快 MRI 扫描速度, 其采用多个独立的接收器通道, 每个通道对邻近接收线圈的组织最敏感。基于多通道获取的原始数据, 可使用敏感度编码 (SENSitivity Encoding, SENSE) 技术以及广义的自校准 (GeneRALized Autocalibrating Partially Parallel Acquisitions, GRAPPA) 方法完成数据融合<sup>[2]</sup>。然而, 并行成像效率受限于接收线圈的数量和排列方式, 且在一定程度上增加了设备成本。除硬件方面的改进外, 减少

观测数据量, 采用软件算法从少量采集信号中重建完整数据是目前更高效的方法。

压缩感知理论指出, 对于具有稀疏性或可压缩性的信号, 在采样率低于奈奎斯特采样率的条件下, 仍可通过压缩采样实现对原始信号的高质量重建<sup>[3]</sup>。压缩感知磁共振成像技术 (Compressed Sensing Magnetic Resonance Imaging, CS-MRI) 即基于该理论构建, 通过在  $k$ -空间进行欠采样以降低扫描时间, 并进一步通过求解非线性优化问题实现对理想 MRI 图像的重建<sup>[4]</sup>。早期的 CS-MRI 重建方法主要采用稀疏性正则化重建模型, 如离散傅里叶变换、离散余弦变换以及全变分等固定稀疏表示方式。然而, 固定的稀疏基表达能力有限, 难以有效刻画图像中复杂的结构特征和细节信息。自适应学习稀疏变换字典能够更有效地表征图像的局部特征, 但额外的字典训练和稀疏编码会降低重建速度。针对非线性重建模型的优化求解

问题,部分学者提出了共轭梯度法、迭代阈值收缩(Iterative Shrinkage-Thresholding Algorithm, ISTA)<sup>[5]</sup>、交替方向乘法(Alternating Direction Method of Multipliers, ADMM)<sup>[6]</sup>等重建算法。然而,这类迭代优化方法通常存在计算复杂度较高、重建过程耗时较长的问题。

近年来,深度学习在计算机视觉领域取得了显著进展,并在 CS-MRI 成像问题中得到了广泛应用,通过端到端的数据驱动方式学习重建映射<sup>[7]</sup>。基于卷积神经网络的 CS-MRI 重建方法通过多尺度局部特征提取与分层抽象,直接学习图像空间与  $k$ -空间的非线性映射关系,实现端到端快速重建,有效提升了高频细节恢复与伪影抑制能力<sup>[8-9]</sup>。此外,生成对抗网络(Generative Adversarial Network, GAN)通过生成器与判别器的竞争互动,有利于自动学习数据的关键特征,在 CS-MRI 问题中也得到广泛应用<sup>[10-11]</sup>,进一步提升了图像重建质量。同时,对抗网络能够生成高质量的合成图像,有效扩充训练数据,从而增强重建模型的泛化能力。鉴于 MRI 的  $k$ -空间采样数据属于复值信号,而复值卷积神经网络(Complex Convolutional Neural Networks, CCNNs)可直接对复数数据进行处理,能够同步利用信号的振幅与相位信息,进而更全面地挖掘并捕获 MRI 信号的内在特征。Wang 等人<sup>[12]</sup>提出了一种用于 MRI 重建的复数卷积残差(Deep complex MRI, DeepcomplexMRI)网络,该网络能够自动学习跨通道的图像相关性,提高重建图像质量。Cole 等人<sup>[13]</sup>的研究表明,与具有相同可训练参数数量的实值卷积相比,CCNNs 具有更优的重建结果。Dong 等人<sup>[14]</sup>提出了一种基于 CCNNs 的自适应字典学习算法,在线学习复数域字典,提高 MRI 重建性能。然而,现有基于复值卷积网络的重建模型大多将实数域方法直接应用于分离的实部与虚部通道,难以实现幅值与相位信息的有效耦合建模。在学习机制方面,多数复数网络缺乏对抗学习策略,且频域  $k$ -空间与图像域之间缺乏有效的交互约束机制,重建图像质量与细节恢复能力方面仍有待进一步提升。

针对上述问题,本文提出了一种双域三边复数生成对抗网络(Dual-domain Tri-edge Complex Generative Adversarial Network, DualTri-CGAN)模型,主要由生成器与判别器两大核心模块构成。其中,生成器由复数  $k$ -空间生成器和实数图像域生成器两部分组成,分别预测潜在的全采样  $k$ -空间和全采样 MRI 图像,两者的输出均输入至同一实数判别器中。 $k$ -空间生成器的输出在输入判别器前需进行逆傅里叶变换。图像域生成器采用实数卷积构建,在一定程度上避免了全复数操作带来的不稳定问题。此外,本文提出了一种新

的基于反馈机制的训练算法,设计了新的相似性对抗损失函数,引入双域子生成器间的对抗,提升重建图像质量。在多对比度、多采集部位 MRI 数据集上的实验结果表明,本文模型能够有效提升重建质量。本文工作的创新点总结如下。

(1) 构建了双域三边复数 GAN 模型,包括  $k$ -空间和图像域双生成器,同步优化复数域数据保真度和空间域结构相似性,并通过相似性对抗损失函数实现双域特征互补,充分学习双域特征。

(2) 设计了三边对抗博弈学习策略,在传统生成器-判别器对抗的基础上,引入  $k$ -空间子生成器与图像域子生成器的跨域竞争机制,并设计了动态阈值,通过判别器准确率自适应调节生成器训练强度,提升了训练过程的稳定性。

(3) 在 IXI Brain (Information eXtraction from Images Brain) 数据集上的实验结果表明,本模型可有效提升重建图像的峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)和结构相似性指数(Structural Similarity Index Measure, SSIM),在低采样率(10%)条件下,仍能够恢复 MRI 图像的边缘结构与纹理细节。

## 1 相关工作

依据所使用的模型不同,目前的 CS-MRI 重建方法可分为两类:一类是基于稀疏变换和字典学习的稀疏性正则化重建方法,另一类是基于深度学习的深度神经网络模型。

### 1.1 稀疏性正则化重建方法

该类方法利用 MRI 图像的稀疏先验作为正则约束构建重建模型,其核心在于稀疏变换的设计。Huang 等人<sup>[15]</sup>将全变差(Total Variation, TV)与小波变换相结合,在保持图像边缘信息的同时,可有效抑制噪声和伪影。Qu 等人<sup>[16]</sup>提出了一种基于图像块的非局部算子并行采集(Parallel Acquisition with Nonlocal Operators, PANO)方法,用于对相似图像块进行稀疏表示建模。Zhang 等人<sup>[17]</sup>提出了一种基于低秩先验约束方法,利用核范数约束矩阵空间的稀疏性,进一步提高了重建质量。

上述方法主要使用固定变换基表示 MRI 图像,而字典学习方法则使用数据集自适应学习表示基进行表示。Ravishankar 等人<sup>[18]</sup>从欠采样的  $k$ -空间数据自适应地学习图像块的稀疏变换字典,能够有效捕获 MRI 图像的局部结构细节。Song 等人<sup>[19]</sup>提出了一种基于耦合字典学习的多对比度 MRI 重建(Coupled Dictionary Learning MRI, CDLMRI)方法,利用参考对比度图像来辅助目标对比度图像重建,分别学习两组字典,并通过耦合稀疏编码进行联合重建。Li 等人<sup>[20]</sup>

融合高维深度字典学习和化学位移模型来实现体成像。

## 1.2 基于深度学习的重建方法

该类方法利用深度网络学习从欠采样  $k$ -空间数据到目标 MRI 图像的参数化重建映射,核心在于重建网络结构的设计。Xie 等人<sup>[21]</sup>提出一种基于深度卷积神经网络(Convolutional Neural Network, CNN)的 CS-MRI 重建方法,验证了深度学习在 CS-MRI 重建中的有效性。同年,Ouchi 等人<sup>[22]</sup>将深度残差网络(Residual Network, ResNet)用于重建。Aggarwal 等人<sup>[23]</sup>则探索了将深度学习与传统优化算法相结合的方法,通过引入数据一致性层,提高了重建图像的保真度。Wu 等人<sup>[24]</sup>设计了一种轻量级的 CNN 模型,用于在资源受限的环境下实现快速的 MRI 图像重建。Kim 等人<sup>[25]</sup>将深度网络用于并行 MRI 重建,通过利用多通道数据的冗余信息,提高了重建图像的分辨率和信噪比。Mardani 等人<sup>[26]</sup>提出了一种基于深度残差 GAN 的 CS-MRI 重建方法。Yang 等人<sup>[10]</sup>则探索了条件 GAN 在 CS-MRI 重建中的应用,通过结合图像域和频域损失函数,实现了对重建图像质量的有效提升。Liu 等人<sup>[27]</sup>提出了一种基于双分支 GAN 的 CS-MRI 重建方法,通过引入双分支解码器结构,有效解决了传统 GAN 在重建过程中可能出现的伪影问题。Cheng 等人<sup>[28]</sup>引入 Wasserstein 距离作为损失函数,提升了 GAN 模型的训练稳定性。

考虑到  $k$ -空间采样数据为复值信号,研究者们将 CCNNs 用于 MRI 压缩感知重建。Vasudeva 等人<sup>[29]</sup>提出了一种轻量级的 CCNNs,实现了在保持重建质量的同时大幅降低计算复杂度。Hossain 等人<sup>[30]</sup>进一步融合复数卷积与注意力机制,提出了基于注意力的复数网络(Attention-based Complex-valued Network, AttentionComplexNet)模型,该模型能够自适应地关注 MRI 图像中的重要特征,提高了重建的精度和鲁棒性。Asiyabi 等人<sup>[31]</sup>提出了一种基于复数卷积和变分自编码器(Variational Auto-Encoder, VAE)的重建方法,增强了重建图像的多样性和逼真度。Deveshwar 等人<sup>[32]</sup>提出了一种基于复数卷积的多线圈联合重建网络,该网络通过同时处理多个线圈的数据,实现了对 MRI 图像的协同重建。张晓华等人<sup>[33]</sup>提出了一个融合复数卷积、复数 Transformer 及小波变换的轻量级混合网络,有效结合了局部特征提取与全局依赖建模的优势,但该模型结构复杂度较高,且对小波基函数选择与计算效率的平衡仍需进一步优化。Li 等人<sup>[34]</sup>提出的分割生成对抗网络(SEgmentation Generative Adversarial Network, SEGAN)将图像质量评估指标 SSIM 转化为 GAN 的对抗性约束,直接针对结构伪影进行惩罚。Zhao 等人<sup>[35]</sup>提出的 Swin Transformer 生成对抗网

络(Swin transformer Generative Adversarial Network, SwinGAN)则将 Swin Transformer 作为 GAN 的生成器骨干,并设计了频域-图像域双级联生成的流水线,实现了从  $k$ -空间到图像的端到端优化。Noor 等人<sup>[36]</sup>提出的 Dlgan(Dense Laplacian generative adversarial network)采用“分而治之”策略,通过多个特化子网络来提升整体模型的泛化性能和特定组织的重建保真度。

$k$ -空间复采样数据中的相位信息反映了原子核周围的电子云分布和分子结构等信息。例如,在脑部成像中,不同组织的分子结构和电子云分布不同,导致其相位信息存在差异,利用这些差异可更清晰地区分不同的组织类型,如区分灰质、白质和脑脊液等,从而为疾病的诊断提供更丰富的信息。然而,现有基于复值卷积网络的重建模型多将实数域方法直接应用于分离的实部与虚部通道,难以实现幅值与相位信息的有效耦合建模。在学习机制方面,多数复数网络缺乏对抗学习策略,且频域  $k$ -空间与图像域之间缺乏有效的交互约束机制,重建图像质量与细节恢复能力方面仍有待进一步提升。为此,本文提出 DaulTriCGAN,使用新颖的训练方式和合理设计的损失函数,能够重建超高质量的 MRI 图像。下面将详细介绍本文提出的网络架构。

## 2 双域三边复数 GAN 重建模型

### 2.1 模型整体架构

本文的双域三边复数 GAN 模型(DaulTri-GAN)由复数  $k$ -空间域、实数图像域生成器以及实数域判别器构成。 $k$ -空间生成器依据输入的欠采样频域空间数据  $\mathbf{k}$ ,重建稠密的频域  $k$ -空间数据  $\hat{\mathbf{k}}$ 。实数域生成器将由欠采样数据  $\mathbf{k}$  进行逆快速傅里叶变换获取的欠采样图像域数据  $\mathbf{x}$  作为输入,预测重建图像  $\hat{\mathbf{x}}$ 。二者随后输入到实数判别器中进行判别。本文将  $k$ -空间生产器和图像域生成器分别表示为  $G_{k\text{-space}}$  和  $G_{\text{imag}}$ ,判别器记为  $D$ ,全采样的  $k$ -空间数据记为  $\tilde{\mathbf{k}}$ ,高质量全采样真实图像记为  $\tilde{\mathbf{x}}$ 。DaulTri-GAN 的整体处理流程可以用如下的公式描述:

$$G_{k\text{-space}}(\mathbf{k}) = \hat{\mathbf{k}} \quad (1)$$

$$\mathbf{x} = \text{iFFT}(\mathbf{k}), G_{\text{imag}}(\mathbf{x}) = \hat{\mathbf{x}} \quad (2)$$

$$D(\text{iFFT}(\hat{\mathbf{k}}), \hat{\mathbf{x}}) = \text{true/false} \quad (3)$$

$$D(\hat{\mathbf{x}}, \tilde{\mathbf{x}}) = \text{true/false} \quad (4)$$

其中, iFFT 代表快速逆傅里叶变换(inverse Fast Fourier Transform, FFT)操作。

如图 1 所示,  $k$ -空间生成器  $G_{k\text{-space}}$  与图像域生成器  $G_{\text{imag}}$  均采用多尺度编解码架构,不同之处在于  $G_{k\text{-space}}$  为复数域编解码网络。为了保持  $G_{k\text{-space}}$  与

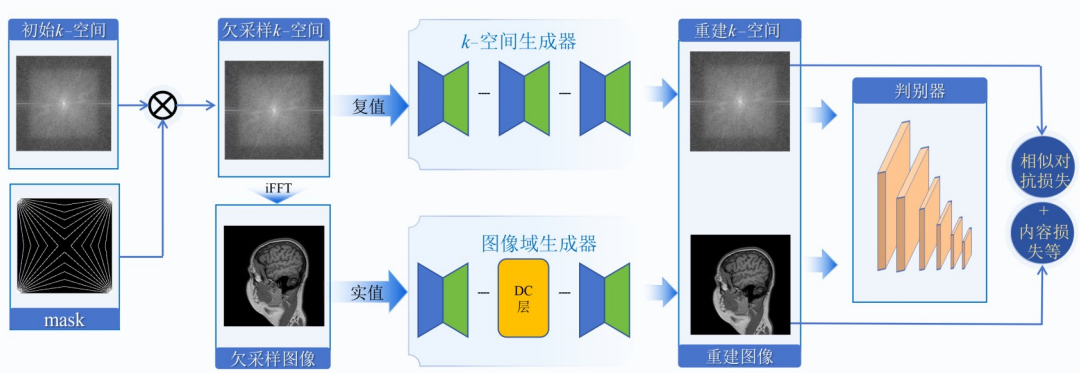


图1 DaulTri-CGAN模型整体架构

Figure 1 Overall architecture of the DaulTri-CGAN network

$G_{\text{imag}}$  公平竞争,将  $G_{k\text{-space}}$  各卷积层核数减少至实数域的一半以平衡参数量,二者通过跨域协同实现对抗学习优化。 $k$ -空间生成器输出稠密的复值频域  $k$ -空间数据,需经 iFFT 转换后输入判别器。实数域生成器则直接输出单通道重建图像。实数判别器通过卷积下采样、全连接层和 Sigmoid 激活函数评估幅值图像的视觉合理性。

### 2.2 $k$ -空间生成器

$k$ -空间生成器使用复卷积直接处理复值采样数

据,其编码阶段提取多层次特征,解码阶段通过跨层连接实现高精度重建。如图2所示, $k$ -空间编码器由4个复卷积块串联构成,通过4次步长为2的下采样逐级降低空间分辨率,并同步倍增特征通道数。编码器最低分辨率特征经瓶颈层处理后输入解码器。解码器对应采用4个逆复卷积块,通过转置卷积进行4次2倍上采样并折半通道数。编解码器通过残差连接实现跨尺度特征融合,解码器输入由上层输出和与编码器同尺度特征图逐像素相加获得,确保多级上下文信息的高效整合。

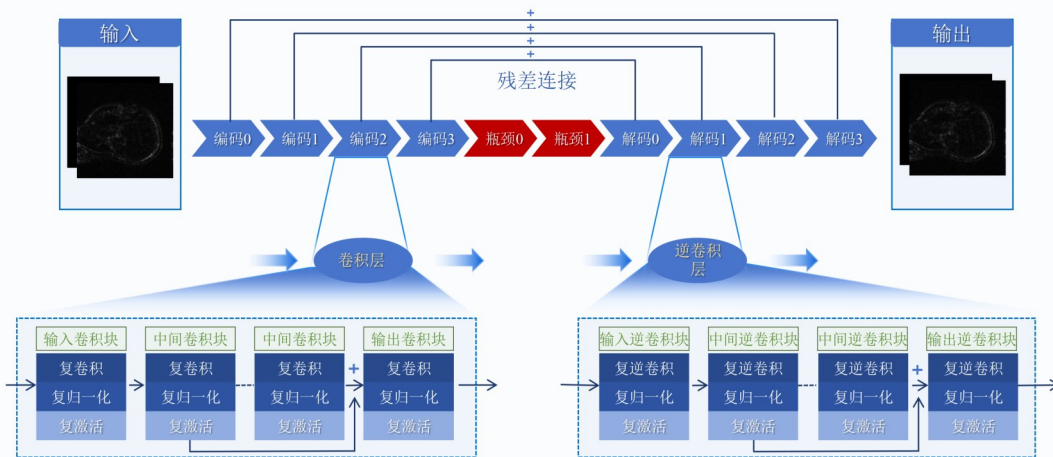


图2  $k$ -空间生成器

Figure 2  $k$ -space generator

如图2所示,编码器卷积层中的卷积块包括复卷积、复归一化以及复激活函数处理。复卷积通过可学习核提取局部特征(如边缘/纹理),批归一化层标准化数据分布以抑制内部协变量偏移,激活函数设置为修正线性单元(Rectified Linear Unit, ReLU)扩展的复数变体复数型修正线性单元(Complex-valued Rectified Linear Unit, CReLU),为网络注入非线性建模能力。复数卷积操作按照复数的乘法规则进行,定义为

$$(f_{\text{real}} + jf_{\text{imag}}) * (I_{\text{real}} + jI_{\text{imag}}) = (f_{\text{real}} * I_{\text{real}} - f_{\text{imag}} * I_{\text{imag}}) + j(f_{\text{real}} * I_{\text{imag}} + f_{\text{imag}} * I_{\text{real}}) \quad (5)$$

其中,  $f_{\text{real}} + jf_{\text{imag}}$  表示复卷积核;  $I_{\text{real}} + jI_{\text{imag}}$  表示复值输入数据。不同于分离的实部或虚部卷积运算,式(5)定义的卷积复数卷积能够同时捕获所输入  $k$ -空间数据实部和虚部的相关性,保留振幅与相位信息,在处理MRI等复数数据时具有优势。复卷积核需分别设置实部和虚部权重,在相同网络架构下参数量将为实

数网络的2倍。输出特征图的实部和虚部通道数与复数卷积核的数量相同,可通过双通道并行处理。

### 2.3 图像域生成器

图像域生成器  $G_{\text{imag}}$  处理实值数据,其网络结构与  $k$ -空间生成器相同,均采用多尺度编解码器结构。 $G_{\text{imag}}$  通过将复卷积块替换为实卷积块,并加倍卷积核的数量来实现。为约束各解码器重建图像的  $k$ -空间采样点数值与初始采样数据保持一致,将在每个解码器输出的结果之上强制进行  $k$ -空间数据一致性操作。

$$\mathbf{F}_L^{\text{dc}}(p) = \begin{cases} \mathbf{F}_L^{\text{ge}}(p); & \text{mask}_p = 0 \\ \frac{\mathbf{F}_L^{\text{ge}}(p) + \lambda \hat{\mathbf{k}}_p}{1 + \lambda}; & \text{mask}_p \neq 0 \end{cases} \quad (6)$$

其中,  $\mathbf{F}$  表示对图像域数据进行 FFT;  $L$  表示解码器序号;  $\mathbf{F}_L^{\text{dc}}$  中上标 dc 表示  $L$  个解码器输出并经过数据一致性处理的  $k$ -空间数据;  $p$  表示  $k$ -空间中像素点的索引坐标;  $\mathbf{F}_L^{\text{ge}}$  中上标 ge 表示  $L$ -th 层 U-Net 生成的  $k$ -空间;  $\lambda$  表示一个加权参数,设置为无穷大,这意味着若  $k$ -空间位置被采样,则将使用该位置的原始采样值;  $\text{mask}$  表示欠采样  $k$ -空间时使用的掩码,  $\text{mask}_p = 0$  意味着索引  $p$  对应的  $k$ -空间位置没有被采样。该层不包含任何可训练参数,仅为一个简单的数学映射操作,因此不会增加网络的负担。

### 2.4 实数判别器

判别器采用实数卷积神经网络搭建,其整体结构设计遵循空间分辨率逐步降低、特征通道逐步增加的原则,从而实现深层次的特征提取。具体而言,判别器由多层实数卷积层堆叠而成,每两个卷积层之间通过最大池化层进行下采样操作。当每次进行下采样时,下采样因子均设为2,确保空间分辨率按照固定比例逐步降低。在第一次下采样时,输出特征通道数初始化为32。随着网络深度的增加,每次下采样后的输出特征通道数均会在上一层基础上加倍,从而使网络能够逐步捕捉从低级到高级的图像特征。

经5次下采样操作后,最终通过一个全连接层将高维特征映射为单一标量值,并通过 sigmoid 激活函数将输出值压缩至  $[0, 1]$ ,从而得到对输入图像真实性的预测概率值。该输出值将直接用于计算 GAN 中的对抗损失,作为判别器判断图像真伪的核心依据。

## 3 网络参数学习

本文网络模型的损失函数包含三部分,分别是判别器损失、 $k$ -空间生成器损失和图像域生成器损失。下面将详细介绍各个损失函数的计算方式。

### 3.1 判别器损失

判别器损失  $\text{loss}_D$  通过交叉熵来衡量判别器区分真假数据的能力。在此过程中,真实样本应输出接近

1 的概率,而生成样本应输出接近 0 的概率。判别器的损失由两部分组成,分别对应真实数据被正确识别的误差和生成数据被错误判定为真实数据的误差。为了优化判别能力,判别器通过最大化整体损失(即最小化负损失)进行优化,从而促使生成器生成更逼真的数据。其计算式为

$$\text{loss}_D = \min_G \max_D E_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})} \left[ \ln D(\mathbf{x}) + E_{\mathbf{z} \sim p_{\text{G}}(\mathbf{z})} \left[ \ln(1 - D(G(\mathbf{z}))) \right] \right] \quad (7)$$

其中,  $G$  表示生成器,对应本文的  $k$ -空间生成器  $G_{k\text{-space}}$  或者图像域生成器  $G_{\text{imag}}$ ;  $D$  表示判别器;  $E$  表示求数学期望操作;  $\mathbf{x}$  表示真实样本;  $\mathbf{z}$  表示输入数据;  $G(\mathbf{z})$  表示由生成器生成的虚假样本。

### 3.2 $k$ -空间生成器损失

$k$ -空间生成器的总损失函数  $\text{loss}_{\text{total}_k}$  包括4项,具体计算方式为

$$\text{loss}_{\text{total}_k} = \zeta_1 \text{loss}_{\text{ssimDG}_k} + \zeta_2 \text{loss}_k + \zeta_3 \text{loss}_{k_{2\text{img}}} + \zeta_4 \text{loss}_{k_{\text{vgg}}} \quad (8)$$

其中,  $\zeta_1 \sim \zeta_4$  表示各个损失项的权重系数;  $\text{loss}_{\text{ssimDG}_k}$  为相似性对抗损失函数;  $\text{loss}_k$ 、 $\text{loss}_{k_{2\text{img}}}$  和  $\text{loss}_{k_{\text{vgg}}}$  为内容损失函数。

相似性对抗损失通过量化生成器输出与真值之间的结构差异,推动生成器在对抗博弈中提升重建精度。SSIM 能够从亮度、对比度、结构相似性等感知维度度量重建图像质量,且其取值范围与判别器输出的概率范围  $([0, 1])$  相一致。为此,本文基于 SSIM 构建相似性对抗损失函数为

$$\text{loss}_{\text{ssimDG}_k} = \ln \left( \text{SSIM} \left( \text{iFFT} \left( G_{k\text{-space}}(\mathbf{k}), \tilde{\mathbf{x}} \right) \right) + \ln \left( 1 - \frac{\text{SSIM} \left( G_{\text{imag}}(\mathbf{x}), \tilde{\mathbf{x}} \right)}{\text{SSIM} \left( \text{iFFT} \left( G_{k\text{-space}}(\mathbf{k}), \tilde{\mathbf{x}} \right) \right) + \zeta} \right) \right) \quad (9)$$

其中,  $\text{iFFT} \left( G_{k\text{-space}}(\mathbf{k}) \right)$  表示对  $k$ -空间生成器重建的稠密数据进行逆快速傅里叶变换获得的幅值图像;  $\zeta$  表示一个较小的常数,防止分母为0。

为了优化  $\text{loss}_{\text{ssimDG}_k}$ , 网络将倾向于通过学习使得对数函数中的分母越接近1、对数值越接近0。每次经优化和调整参数后,  $k$ -空间和图像域生成器的能力均会有所精进,对数中的分子不断增大,为使真数的值维持接近于1,分母也应不断增大。因此分子(图像域生成器的重建效果度量)越高,分母( $k$ -空间生成器的重建效果度量)随之增高,体现了双域子生成器的竞争对抗关系。

内容损失函数由三部分组成,包括  $k$ -空间 MSE 损失  $\text{loss}_k$ 、图像域 MSE 损失  $\text{loss}_{k_{2\text{img}}}$  和 VGG 感知损失  $\text{loss}_{k_{\text{vgg}}}$ 。

$k$ -空间 MSE 损失  $\text{loss}_k$  计算为

$$\text{loss}_k = \text{MSE}(\hat{\mathbf{k}}_r, \tilde{\mathbf{k}}_r) + \text{MSE}(\hat{\mathbf{k}}_j, \tilde{\mathbf{k}}_j) \quad (10)$$

其中,  $\hat{\mathbf{k}}_r$  和  $\tilde{\mathbf{k}}_r$  分别表示输出  $k$ -空间和真实  $k$ -空间的实部;  $\hat{\mathbf{k}}_j$  和  $\tilde{\mathbf{k}}_j$  分别表示二者的虚部。

图像域 MSE 损失  $\text{loss}_{k_{2\text{imag}}}$ , 利用  $\mathbf{k}_{2\text{imag}}$  和  $\tilde{\mathbf{x}}$  进行 MSE 损失计算,  $\mathbf{k}_{2\text{imag}}$  表示  $\hat{\mathbf{k}}$  经过 iFFT 后得到的图像域数据。

此外, 本文发现多数现有模型的训练过程仅采用  $L_p$  损失函数, 从而导致重建的结果过于平滑, 边缘模糊不够锐利, 为了改善这一问题, 本文引入 VGG 感知损失  $\text{loss}_{k_{\text{vgg}}}$ , 利用  $f_{\text{vgg}}(\mathbf{k}_{2\text{imag}})$  和  $f_{\text{vgg}}(\tilde{\mathbf{x}})$  进行 MSE 损失计算,  $f_{\text{vgg}}$  表示在 ImageNet 上预训练的 VGG16 的第四个卷积层,  $f_{\text{vgg}}(\tilde{\mathbf{x}})$  代表对真实图像域数据进行编码嵌入。感知损失可指导网络向着视觉感知更好的重建方向进行, 包括更清晰的纹理、更锐利的边缘和更精细的结构。

### 3.3 图像域生成器损失

图像域生成器的总损失函数  $\text{loss}_{\text{total}_i}$  包含相似性对抗损失函数  $\text{loss}_{\text{ssimDG}_i}$ 、内容损失函数 (包括  $\text{loss}_i$ ,  $\text{loss}_{i_{2k\text{-space}}}$  和  $\text{loss}_{i_{\text{vgg}}}$ ) 以及  $k$ -空间数据一致性损失函数  $\text{loss}_{\text{dc}}$ , 计算表达式为

$$\text{loss}_{\text{total}_i} = \eta_1 \text{loss}_{\text{ssimDG}_i} + \eta_2 \text{loss}_i + \eta_3 \text{loss}_{i_{2k\text{-space}}} + \eta_4 \text{loss}_{i_{\text{vgg}}} + \eta_5 \text{loss}_{\text{dc}} \quad (11)$$

其中,  $\eta_1 \sim \eta_5$  表示表示各个损失项的权重系数。

相似性对抗损失的计算方式为

$$\text{loss}_{\text{ssimDG}_i} = \ln \left( \text{SSIM} \left( G_{\text{imag}}(\mathbf{x}), \tilde{\mathbf{x}} \right) \right) + \ln \left( 1 - \frac{\text{SSIM} \left( \text{iFFT} \left( G_{k\text{-space}}(\mathbf{k}), \tilde{\mathbf{x}} \right) \right)}{\text{SSIM} \left( G_{\text{imag}}(\mathbf{x}), \tilde{\mathbf{x}} \right) + \zeta} \right) \quad (12)$$

其中,  $\text{loss}_{\text{ssimDG}_i}$  的设计思想和式 (9) 一致, 但由于图像域生成器直接输出空域数据, 因此未进行逆傅里叶变换。

内容损失包括图像域 MSE 损失  $\text{loss}_i$ 、 $k$ -空间 MSE 损失  $\text{loss}_{i_{2k\text{-space}}}$  和 VGG 感知损失  $\text{loss}_{i_{\text{vgg}}}$ 。图像域 MSE 损失  $\text{loss}_i$  利用  $\hat{\mathbf{x}}$  和  $\tilde{\mathbf{x}}$  进行 MSE 损失计算。 $k$ -空间 MSE 损失  $\text{loss}_{i_{2k\text{-space}}}$  计算式为

$$\text{loss}_{i_{2k\text{-space}}} = \text{MSE}(i_{2k\text{-space}_r}, \hat{\mathbf{k}}_r) + \text{MSE}(i_{2k\text{-space}_j}, \hat{\mathbf{k}}_j) \quad (13)$$

其中,  $i_{2k\text{-space}_r}$  和  $i_{2k\text{-space}_j}$  分别表示图像域数据经过傅里叶变换后的实部和虚部数据。

VGG 感知损失  $\text{loss}_{i_{\text{vgg}}}$ , 利用  $f_{\text{vgg}}(\hat{\mathbf{x}})$  和  $f_{\text{vgg}}(\tilde{\mathbf{x}})$  进行 MSE 损失计算,  $f_{\text{vgg}}(\hat{\mathbf{x}})$  表示对图像域生成器输出的图像域数据进行编码嵌入。

将图像域生成器生成的图像经过逆傅里叶变换

获取的  $k$ -空间施加与原全采样相同的欠采样掩码得到欠采样  $k$ -空间  $\hat{\mathbf{k}}_{\text{un}}$ , 通过 MAE 计算其与全采样  $k$ -空间  $\mathbf{k}$  的距离, 即数据一致性损失  $\text{loss}_{\text{dc}}$ , 定义为

$$\text{loss}_{\text{dc}} = \frac{1}{n} \sum_{h=1}^n |\hat{\mathbf{k}}_{\text{un}_h} - \mathbf{k}_h| \quad (14)$$

其中,  $n$  表示图像的像素总数;  $h$  表示像素点索引。

### 3.4 三边对抗博弈学习算法

针对上述损失函数, 本文构建了三边对抗博弈学习训练算法。算法首先初始化网络并训练判别器以建立能力基准, 然后以分组迭代的方式优先训练两个生成器, 使其协同进步以欺骗判别器, 同时引入一个根据判别器准确率计算的动态阈值来监控训练状态, 以此调整生成器与判别器的训练轮数, 从而维持三者间竞争博弈的平衡, 实现整体性能的协同优化。

首先, 在初始化权重下, 获取双域子生成器生成假样本, 然后固定生成器, 将假样本和真样本混合输入到判别器中训练一个 epoch, 根据输出结果计算判别器的初始判别准确率, 记录该值 ( $t_0$ )。从第二个 epoch 开始, 以 10 次迭代为一组训练, 优先训练生成器 (本文采取先训练  $k$ -空间子生成器, 再训练图像域生成器的方式) 一个组次。定义阈值  $t$ , 其计算方式定义为

$$t = t_0 + 0.8 \times \frac{\text{trained\_group}}{\text{total\_group}/3} \quad (15)$$

其中,  $\text{trained\_group}$  表示判别器已训练组次;  $\text{total\_group}$  表示组次总数。3 是一个固定的参数, 来源于本文认为三个组件获得训练的次数是平均的假设。

双域子生成器训练完后, 分别将来自不同子生成器的生成样本与相同数量的真实样本混合, 如算法 1 所示, 输入到判别器中进行判别。为了更直观地展示三边对抗博弈学习算法下训练过程的动态平衡, 本文构建了训练方式真值表, 如表 1 所示, 其中训练组件包括  $k$ -空间生成器、图像域生成器和判别器, 根据对应的条件选择其中一个组件进行训练。分别计算判别器对  $k$ -空间生成器和图像域生成器输出的假数据样本的分类准确率  $a_{k\text{-space}}$  和  $a_{\text{imag}}$  和阈值  $t$  比较, 对比结果共有五种, 以编号 ①~⑤区分。①  $a_{k\text{-space}} < t$  &  $a_{\text{imag}} < t$ ; ②  $a_{k\text{-space}} < t$  &  $a_{\text{imag}} > t$ ; ③  $a_{k\text{-space}} > t$  &  $a_{\text{imag}} < t$ ; ④  $a_{k\text{-space}} > t$  &  $a_{\text{imag}} > t$  &  $\text{avg\_ind} = (\tilde{\mathbf{x}}, \mathbf{y}_{k\text{-space}}) < \text{avg\_ind}(\tilde{\mathbf{x}}, \mathbf{y}_{\text{imag}})$ ; ⑤  $a_{k\text{-space}} > t$  &  $a_{\text{imag}} > t$  &  $\text{avg\_ind} = (\tilde{\mathbf{x}}, \mathbf{y}_{k\text{-space}}) > \text{avg\_ind}(\tilde{\mathbf{x}}, \mathbf{y}_{\text{imag}})$ 。如表 1 所示, 其中“√”表示被选中训练的组件。①表示判别器的判别能力不足, 会继续训练判别器。当判别器的准确率较高时, 意味着子生成器的“欺骗”能力较弱, 即生成能力偏弱, ②和③反映了这种情况。④和⑤需要选择训练  $\text{avg\_ind}$  更低的子

生成器,具体判别式为

$$\text{avg\_ind}(x_1, x_2) = \frac{1}{s} \sum_{v=1}^s (\text{PSNR}(x_1, x_2) + \text{SSIM}(x_1, x_2) - \text{RMSE}(x_1, x_2)) \quad (16)$$

其中, avg\_ind 表示 PSNR、SSIM 和 RMSE 平均度量指标;  $v$  表示图像像素索引;  $s$  表示一个组次中图像的总数;  $x_1$  和  $x_2$  分别表示参与计算的两个输入图像。

值得注意的是,随着判别器训练的进行,  $t$  也会随之提高,为了避免一直陷入①的情况,本文通过设置判断连续训练 10 个组次的判别器后,若仍处于①的情况,则将  $t$  从当前值回退至 10 个组次之前并重复上述过程,直至其中一个子生成器得到训练的方式来解。算法 1 中对训练组件的选择和表 1 给出的判定规则一致。注意到,为了公平地衡量双域子生成器的生成能力,判别器的参数会保留为一个断点,即当判别来自不同子生成器的样本时,判别器初始的权重参数是一致的。在两次更新完判别器的权重后,对判别器的参数取均值,作为下次训练判别器的权重。

算法 1 三边对抗博弈学习训练算法

输入:真实样本集  $X$ ,总训练组次  $T$

输出:优化生成器  $G_{k\text{-space}}^*$ 、 $G_{\text{imag}}^*$ ,判别器  $D^*$

1.  $a_{k\text{-space}} = t_0, a_{\text{imag}} = t_0$
2. FOR 步数 in 1,2,...,  $T$
3. IF  $a_{k\text{-space}} < t_0$  and  $a_{\text{imag}} < t_0$  //训练判别器  $D$
4. ELIF  $a_{k\text{-space}} < t_0$  //训练图像域生成器  $G_{\text{imag}}$
5. ELIF  $a_{\text{imag}} < t_0$  //训练  $k$ -空间生成器  $G_{k\text{-space}}$
6. ELSE
7. IF  $\text{avg\_ind}(\tilde{x}_{k\text{-space}}, x) > \text{avg\_ind}(\tilde{x}_{\text{imag}}, x)$  THEN
8.  $\tilde{X}_{k\text{-space}} \leftarrow G_{k\text{-space}}()$ ,  $\text{flag}_{k\text{-space}} = 1$  //训练  $k$ -空间生成器  $G_{k\text{-space}}$
9. ELSE
10.  $\tilde{X}_{\text{imag}} \leftarrow G_{\text{imag}}()$ ,  $\text{flag}_{\text{imag}} = 1$  //训练图像域生成器  $G_{\text{imag}}$
11. END IF
12. END IF
13. END FOR

表 1 训练方式真值表

Table 1 Training method truth table

条件编号	训练组件	①	②	③	④	⑤
训练组件选择	$k$ -空间生成器			√	√	
	图像域生成器		√			√
	判别器	√				

## 4 实验结果与分析

本节通过设计对比实验验证所提出模型的有效性,包括多样采样模式以及极低采样率(如 10%)下的重建结果对比,分析各模型的重建质量,并通过消融

实验分析复数卷积、网络深度及损失函数对重建性能的影响。

### 4.1 数据集与参数设置


本文使用 IXI-brain MRI 数据集进行网络模型训练和测试。IXI-brain 数据集采集自哈默史密斯医院的飞利浦 3T 系统、盖伊医院使用的飞利浦 1.5T 系统和精神病学研究所的使用 GE 1.5T 系统共 3 种扫描仪,在 NIfTI-1 数据文件中分别使用“HH”“Guys”和“IOP”嵌入的文件名加以区分。在对比试验中,本文也据此将数据集按场强分成两类(1.5T 和 3T),并独立训练,从而验证模型对不同场强的泛化性。除此之外,本文使用了 2 种对比度的 IXI-brain MRI 图像,分别是 T2 和 PD,并进行场强划分,形成 4 种不同组合的训练数据。消融实验部分采取混合场强数据进行验证。本论文中实验使用 2 张 Tesla T4 显卡进行网络模型训练与测试。

### 4.2 对比实验

为全面对比本文的模型和多个基于 GAN 的 CS-MRI 重建模型(SEGAN、Recon-GLGAN、SARA-GAN、SwinGAN 和 Dlgan)的性能差异,本次对比实验共设置了 2 种采样模式,采样率 10% 的笛卡尔采样和采样率 10% 的径向采样。图 3 和图 4 展示了各模型在 4 组数据集和 2 种采样条件下的 MRI 重建图像,表 2 给出了各模型重建图像的定量指标结果。

由表 2 可知,本文模型在不同对比度、场强的数据集和不同的采样模式下均取得了令人满意的结果,这表明本方法能够更精准地恢复原始图像的细节信息,有效抑制重建过程中产生的噪声和伪影。从定性实验结果分析,SEGAN 的重建结果整体模糊,灰质与白质区域对比度较低,背景区域出现明显的噪声斑点,难以分辨细微结构。Recon-GLGAN 在 10% 欠采样条件下,皮层沟回和脑室等精细结构的边界出现锯齿状伪影,海马体等关键区域的轮廓模糊不清。在 SARA-GAN 重建图像中,灰白质交界处的相位连续性较差,出现不自然的过渡带,影响解剖结构的真实性。SwinGAN 在重建时过度抑制噪声导致脑脊液区域细节丢失,同时皮层表面出现网格状伪影,破坏了脑部表面的自然曲率。Dlgan 重建的丘脑、基底神经节等深部结构位置出现系统性偏移,与真实解剖位置存在明显偏差,影响临床诊断准确性。在 IXI-brain 数据集上的定性和定量分析结果证明,本文的模型对于 MRI 图像重建的效果优于同类模型。

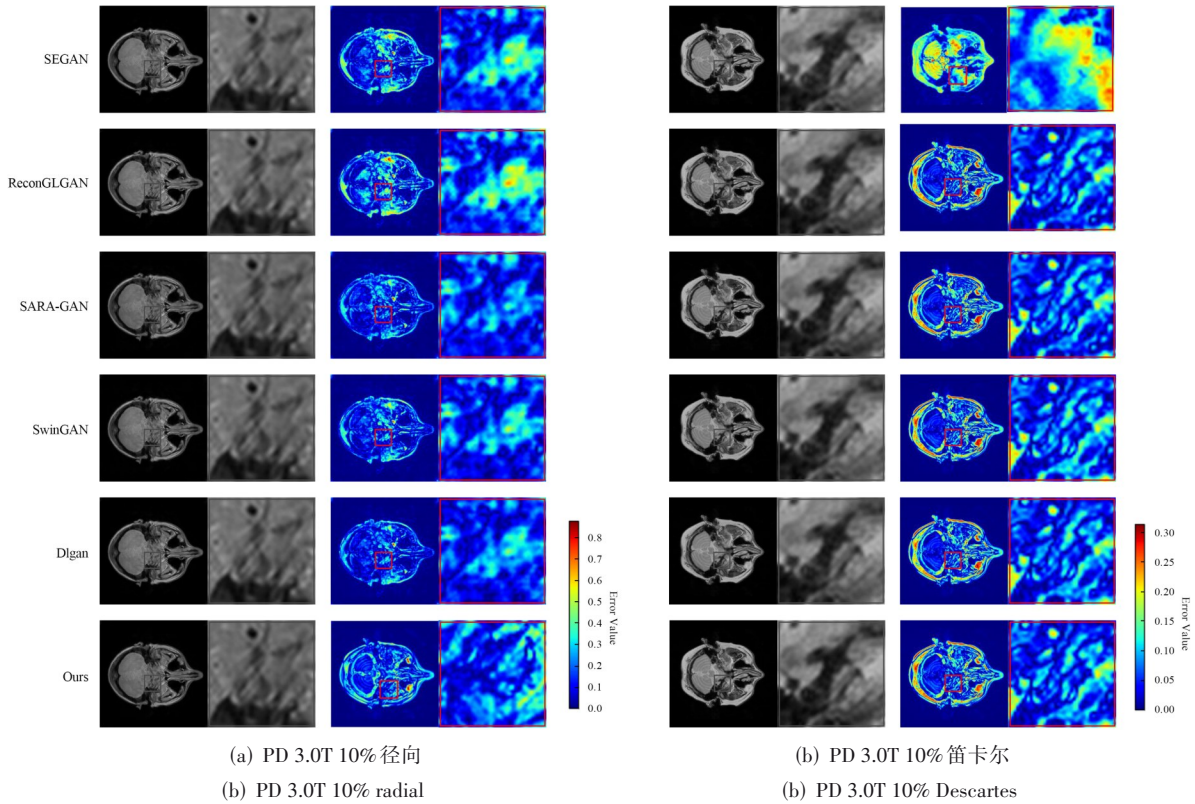
为了验证不同模型的重建效率,表 3 给出了本文模型与对比模型的浮点运算次数(Floating-point Operations, FLOPs)、模型参数量以及单张图像的推理时间。由表 3 可知,本文模型在保持较低计算复杂度的



(a) T2 1.5T 10% 径向 (b) T2 1.5T 10% 笛卡尔  
(a) T2 1.5T 10% radial (b) T2 1.5T 10% Descartes

图3 对比模型的T2对比度的MRI重建图像

Figure 3 MRI reconstructed image of T2 contrast of the comparison model



(a) PD 3.0T 10% 径向 (b) PD 3.0T 10% 笛卡尔  
(a) PD 3.0T 10% radial (b) PD 3.0T 10% Descartes

图4 对比模型的PD对比度的MRI重建图像

Figure 4 MRI reconstructed image of PD contrast in comparison model

表2 采样率10%下各模型重建图像的定量指标

Table 2 Quantitative metrics of reconstructed images by various models at a sampling rate of 10%

模型	指标	PSNR $\uparrow$		SSIM $\uparrow$		RMSE $\downarrow$	
	数据集	Cartesian	Radial	Cartesian	Radial	Cartesian	Radial
SEGAN	T2 1.5T	35.12 $\pm$ 2.1	35.31 $\pm$ 2.5	0.785 $\pm$ 0.05	0.813 $\pm$ 0.06	7.75 $\pm$ 0.48	7.10 $\pm$ 0.50
	T2 3.0T	34.98 $\pm$ 1.9	35.60 $\pm$ 1.5	0.794 $\pm$ 0.02	0.827 $\pm$ 0.04	7.54 $\pm$ 0.48	6.99 $\pm$ 0.49
	PD 1.5T	33.06 $\pm$ 3.2	35.72 $\pm$ 3.0	0.796 $\pm$ 0.03	0.832 $\pm$ 0.04	7.66 $\pm$ 0.48	7.08 $\pm$ 0.49
	PD 3.0T	33.72 $\pm$ 1.5	35.84 $\pm$ 2.8	0.803 $\pm$ 0.06	0.826 $\pm$ 0.03	7.73 $\pm$ 0.50	6.84 $\pm$ 0.49
Recon-GLGAN	T2 1.5T	35.77 $\pm$ 2.1	36.01 $\pm$ 1.3	0.807 $\pm$ 0.04	0.801 $\pm$ 0.03	7.36 $\pm$ 0.48	6.93 $\pm$ 0.36
	T2 3.0T	35.15 $\pm$ 1.3	36.12 $\pm$ 2.6	0.815 $\pm$ 0.05	0.830 $\pm$ 0.05	6.94 $\pm$ 0.48	6.39 $\pm$ 0.41
	PD 1.5T	35.18 $\pm$ 3.4	35.12 $\pm$ 2.1	0.817 $\pm$ 0.04	0.836 $\pm$ 0.03	6.94 $\pm$ 0.48	5.85 $\pm$ 0.39
	PD 3.0T	35.22 $\pm$ 2.8	36.46 $\pm$ 1.7	0.819 $\pm$ 0.02	0.879 $\pm$ 0.02	7.11 $\pm$ 0.49	5.19 $\pm$ 0.42
SARA-GAN	T2 1.5T	35.25 $\pm$ 1.6	36.41 $\pm$ 3.4	0.799 $\pm$ 0.02	0.886 $\pm$ 0.03	6.78 $\pm$ 0.49	6.08 $\pm$ 0.23
	T2 3.0T	35.87 $\pm$ 1.9	37.03 $\pm$ 1.5	0.854 $\pm$ 0.02	0.855 $\pm$ 0.05	6.04 $\pm$ 0.48	4.94 $\pm$ 0.18
	PD 1.5T	6.15 $\pm$ 1.8	37.07 $\pm$ 2.9	0.827 $\pm$ 0.04	0.873 $\pm$ 0.06	6.07 $\pm$ 0.48	5.22 $\pm$ 0.33
	PD 3.0T	35.96 $\pm$ 3.5	37.85 $\pm$ 3.0	0.832 $\pm$ 0.04	0.848 $\pm$ 0.06	5.79 $\pm$ 0.49	5.02 $\pm$ 0.31
SwinGAN	T2 1.5T	35.92 $\pm$ 2.4	37.58 $\pm$ 3.2	0.817 $\pm$ 0.04	0.833 $\pm$ 0.06	5.61 $\pm$ 0.49	4.64 $\pm$ 0.39
	T2 3.0T	36.32 $\pm$ 3.3	37.87 $\pm$ 2.2	0.899 $\pm$ 0.02	0.896 $\pm$ 0.03	6.09 $\pm$ 0.32	4.31 $\pm$ 0.26
	PD 1.5T	37.12 $\pm$ 3.2	37.74 $\pm$ 2.3	0.906 $\pm$ 0.03	0.894 $\pm$ 0.02	5.25 $\pm$ 0.44	4.05 $\pm$ 0.31
	PD 3.0T	36.69 $\pm$ 1.6	38.14 $\pm$ 2.4	0.920 $\pm$ 0.05	0.906 $\pm$ 0.03	5.29 $\pm$ 0.46	4.09 $\pm$ 0.43
DlGAN	T2 1.5T	37.18 $\pm$ 3.0	38.27 $\pm$ 2.8	0.918 $\pm$ 0.06	0.891 $\pm$ 0.03	5.63 $\pm$ 0.50	3.92 $\pm$ 0.34
	T2 3.0T	37.58 $\pm$ 3.2	38.45 $\pm$ 3.4	0.911 $\pm$ 0.03	0.928 $\pm$ 0.06	5.04 $\pm$ 0.38	3.76 $\pm$ 0.42
	PD 1.5T	36.87 $\pm$ 2.8	37.83 $\pm$ 1.9	0.932 $\pm$ 0.04	0.895 $\pm$ 0.05	4.99 $\pm$ 0.47	3.85 $\pm$ 0.36
	PD 3.0T	35.98 $\pm$ 2.1	38.21 $\pm$ 2.6	0.896 $\pm$ 0.03	0.919 $\pm$ 0.02	5.02 $\pm$ 0.41	3.79 $\pm$ 0.35
Ours	T2 1.5T	36.18 $\pm$ 3.0	38.58 $\pm$ 3.3	0.873 $\pm$ 0.06	0.889 $\pm$ 0.02	4.43 $\pm$ 0.37	3.64 $\pm$ 0.46
	T2 3.0T	38.74 $\pm$ 2.4	37.81 $\pm$ 2.7	0.922 $\pm$ 0.04	0.914 $\pm$ 0.02	4.18 $\pm$ 0.48	3.52 $\pm$ 0.42
	PD 1.5T	38.87 $\pm$ 2.3	38.61 $\pm$ 2.8	0.953 $\pm$ 0.06	0.944 $\pm$ 0.02	3.52 $\pm$ 0.42	3.33 $\pm$ 0.27
	PD 3.0T	38.09 $\pm$ 1.7	39.05 $\pm$ 3.2	0.962 $\pm$ 0.04	0.964 $\pm$ 0.02	3.72 $\pm$ 0.40	3.66 $\pm$ 0.25

表3 各网络各模型复杂度与推理时间

Table 3 Complexity and inference time of different network models

模型	GFLOPs	Inference time/ ms	Params/M
SEGAN	2.6	6.2	3.5
Recon-GLGAN	3.2	8.9	10.0
SARA-GAN	3.8	8.4	12.0
SwinGAN	18.0	12.5	100.0
DlGAN	2.8	7.1	4.0
Ours	<b>2.1</b>	<b>5.4</b>	<b>3.8</b>

注:加粗字体表示结果最优,下同。

同时,实现了更快的处理速度,可为资源受限环境下的MRI图像高效重建应用提供技术支撑。

### 4.3 消融实验

为了验证本文模型 DaulTri-CGAN 中  $k$ -空间生成器、相似性对抗损失函数等模块对重建性能提升的有效性,本文设置了5种消融方法:(1)将  $k$ -空间生成器替换为等参数量的实数网络(Real Convolutional, Real-Conv);(2)不使用相似性对抗损失函数(Normalized

Structural SIMilarity loss, NoSSIMloss);(3)将双域子生成器的级联深度从8减少为5(Depth5);(4)不使用动态阈值(No Dynamic Threshold, NoDynThres)方法;(5)不同的复数激活函数(Complex Activation Function, ComActFunc)。DaulTri-CGAN 使用的 CReLU 被替换成了模值修正线性单元(Modulus Rectified linear unit, ModRelu)和基于幅度的修正线性单元(Magnitude-based Relu, ZRelu)进行实验,在表4中分别表示为 ModRelu 和 ZRelu。

消融实验使用完整的 IXI-T2 (Information eXtraction from Images-T2-weighted) 数据集(未进行场强划分)进行测试。各消融模型的定性和定量实验结果分别如图5和表4所示,其中实数模型增加了1倍的卷积核数以保证其参数量和复数模型基本一致。实验结果表明,在相同的参数量下,实数模型的重建质量劣于复数模型,说明复数卷积和复数激活函数在处理MRI等复数数据时具有更强的表征能力。其性能优势主要来源于复数卷积在相位保持方面优于实数卷积。本文进一步可视化了实数模型和复数模型重建

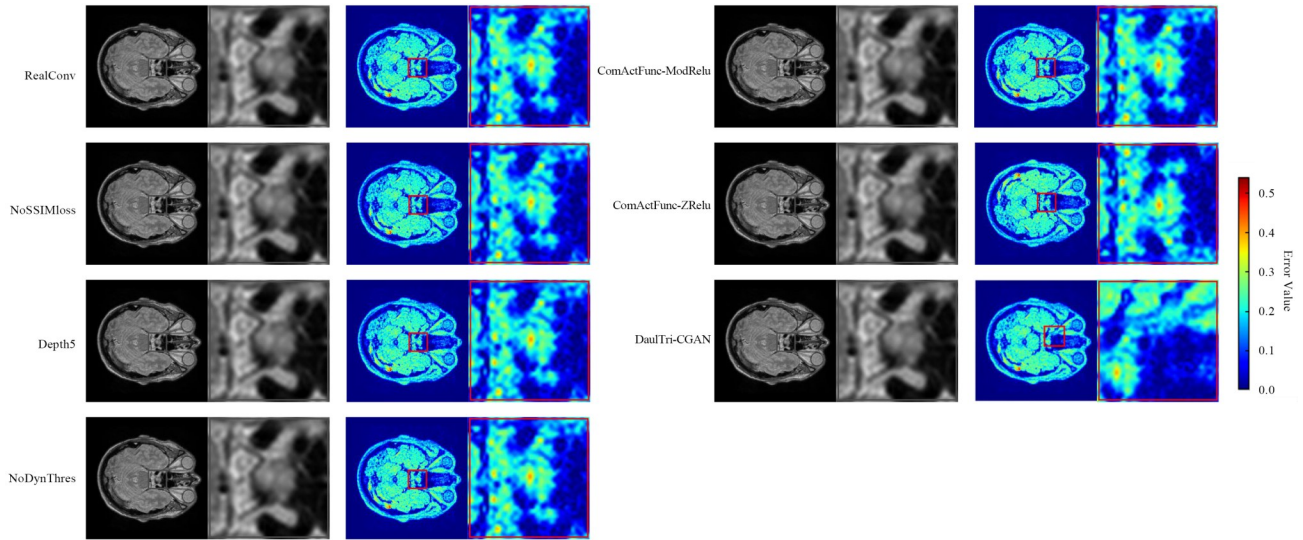


图 5 消融定性实验结果

Figure 5 Ablation qualitative experimental results

表 4 消融模型定量结果对比

Table 4 Comparison of quantitative results of ablation models

模型	PSNR $\uparrow$	SSIM $\uparrow$	RMSE $\downarrow$	GFLOPs	Infer time/ms	Params/M
RealConv	37.65 $\pm$ 2.5	0.936 $\pm$ 0.04	3.88 $\pm$ 0.29	2.3	5.2	3.9
NoSSIMloss	36.89 $\pm$ 3.1	0.901 $\pm$ 0.02	4.05 $\pm$ 0.34	2.1	5.2	3.8
Depth5	37.22 $\pm$ 2.8	0.936 $\pm$ 0.03	3.63 $\pm$ 0.19	<b>1.9</b>	<b>4.9</b>	<b>3.7</b>
NoDynThres	38.12 $\pm$ 2.2	0.945 $\pm$ 0.02	3.72 $\pm$ 0.22	2.0	5.0	3.8
ModRelu	38.55 $\pm$ 4.1	0.929 $\pm$ 0.04	3.78 $\pm$ 0.26	2.1	5.3	3.8
ZRelu	37.99 $\pm$ 3.8	0.933 $\pm$ 0.05	3.66 $\pm$ 0.31	2.1	5.3	3.8
Ours	<b>38.92<math>\pm</math>2.9</b>	<b>0.979<math>\pm</math>0.03</b>	<b>3.11<math>\pm</math>0.20</b>	2.1	5.3	3.8

的相位在图像域的表现。为了直观展示, 本文将从频域分离出的相位信息经逆傅里叶变换到图像域, 并与对应全采样相位数据做误差热力图, 可视化结果如图 6 所示, 同时计算了量化指标, 相位重建的量化结果也显示复数卷积模型在所有指标上均优于实数卷积模型, 表现出更高的 PSNR 和 SSIM 值, 以及更低的 RMSE 值。去除相似性损失项的模型, 尤其在 SSIM 的

表现上呈现出骤降趋势, 说明本文提出的相似性损失函数对提升重建图像的 SSIM 起到关键的优化作用。降低级联深度的模型, 通过增加网络宽度保持参数量基本一致, 实验结果表明, 该消融模型虽然能够优化推理效率, 满足实时性要求, 但由此导致的重建图像质量显著下降, 限制了该模型在需要高保真度输出场景下的实际应用价值。未配置动态阈值的模型在训

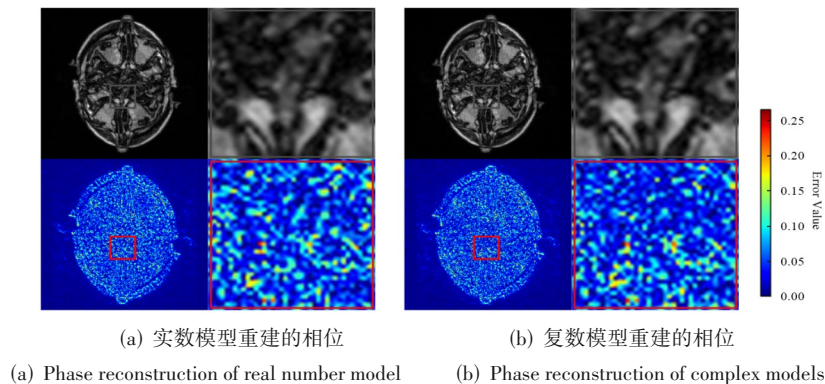


图 6 实数模型与复数模型相位重建结果对比

Figure 6 Comparison of phase reconstruction results using real-complex model

练过程中出现了明显的稳定性下降,这种不稳定性直接导致了在同等训练周期下的性能减损,其最终结果未能达到动态阈值基准模型水平。当使用 ModReLU 与 ZReLU 激活函数时,模型性能均未超越原始的 CReLU 配置,从而验证了 CReLU 激活函数的有效性。

## 5 结论

本研究提出了一种 DualTri-CGAN 的新型 CS-MRI 重建方法,有效解决了传统 MRI 成像中采样速率受限和重建图像质量一般的瓶颈问题。该模型融合了 GAN 的核心原理并进行关键创新,其整体架构由专门的  $k$ -空间生成器、图像域生成器及配套的实值判别器共同构成。DualTri-CGAN 最具突破性的设计在于其独特的多对抗训练机制,不仅实现了双域子生成器与判别器之间的经典对抗博弈,还创新性地引入了双域生成器间的对抗环节,形成三位一体的博弈架构,这一设计充分借鉴了博弈论中的多主体竞争策略。值得注意的是,两个关键组件均采用优化的 U-Net 架构,并通过精心设计的残差连接实现了多尺度特征的有效融合,有效缓解了深度网络训练中的梯度弥散问题。特别地,为增强模型性能,本研究设计了一种创新的损失函数,该函数促使双域生成器在相互竞争与协同中持续提升重建质量,最终输出高度接近真实情况的优质 MRI 图像。大量实验验证表明,与现有基于 GAN 的 CS-MRI 方法相比,本模型在重建精度方面具有显著优势,而全面的消融实验结果则确凿证明了模型中各创新设计要素的不可或缺性。后续研究中拟进一步对模型的迁移性进行深入分析,例如将框架移植到 CT 图像或者 3D 成像领域,在后处理阶段,进行病灶区域的检测和识别等。

## 参考文献

- [1] 蒋明峰, 陆亮, 吴龙, 等. 基于加权 Schatten  $p$  范数最小化的磁共振图像重构方法研究[J]. 电子学报, 2019, 47(4): 784-790.  
Jiang Mingfeng, Lu Liang, Wu Long, et al. The research of MRI reconstruction method by using weighted Schatten  $P$ -norm minimization[J]. Acta Electronica Sinica, 2019, 47(4): 784-790. (in Chinese)
- [2] Hamilton J, Franson D, Seiberlich N. Recent advances in parallel imaging for MRI[J]. Progress in Nuclear Magnetic Resonance Spectroscopy, 2017, 101: 71-95.
- [3] 焦李成, 杨淑媛, 刘芳, 等. 压缩感知回顾与展望[J]. 电子学报, 2011, 39(7): 1651-1662.  
Jiao Licheng, Yang Shuyuan, Liu Fang, et al. Development and prospect of compressive sensing[J]. Acta Electronica Sinica, 2011, 39(7): 1651-1662. (in Chinese)
- [4] Lustig M, Donoho D, Pauly J M. Sparse MRI: The application of compressed sensing for rapid MR imaging[J]. Magnetic Resonance in Medicine, 2007, 58(6): 1182-1195.
- [5] Daubechies I, Defrise M, De Mol C. An iterative thresholding algorithm for linear inverse problems with a sparsity constraint[J]. Communications on Pure and Applied Mathematics, 2004, 57(11): 1413-1457.
- [6] Yang J F, Zhang Y. Alternating direction algorithms for  $\ell_1$ -problems in compressive sensing[J]. SIAM Journal on Scientific Computing, 2011, 33(1): 250-278.
- [7] 董浩, 李劭辉, 阚诺文, 等. 基于深度压缩感知的联合信源信道编码方法研究[J]. 电子学报, 2025, 53(7): 2178-2192.  
Dong Hao, Li Shaohui, Kan Nuowen, et al. Research on joint source-channel coding method based on deep compressive sensing[J]. Acta Electronica Sinica, 2025, 53(7): 2178-2192. (in Chinese)
- [8] Sandino C M, Cheng J Y, Chen F Y, et al. Compressed sensing: From research to clinical practice with deep neural networks: Shortening scan times for magnetic resonance imaging[J]. IEEE Signal Processing Magazine, 2020, 37(1): 117-127.
- [9] Shi W Z, Jiang F, Liu S H, et al. Image compressed sensing using convolutional neural network[J]. IEEE Transactions on Image Processing, 2020, 29: 375-388.
- [10] Yang G, Yu S M, Dong H, et al. DAGAN: Deep de-aliasing generative adversarial networks for fast compressed sensing MRI reconstruction[J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1310-1321.
- [11] Quan T M, Nguyen-Duc T, Jeong W K. Compressed sensing MRI reconstruction using a generative adversarial network with a cyclic loss[J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1488-1497.
- [12] Wang S S, Cheng H T, Ying L, et al. Deep complexMRI: Exploiting deep residual network for fast parallel MR imaging with complex convolution[J]. Magnetic Resonance Imaging, 2020, 68: 136-147.
- [13] Cole E, Cheng J, Pauly J, et al. Analysis of deep complex-valued convolutional neural networks for MRI reconstruction and phase-focused applications[J]. Magnetic Resonance in Medicine, 2021, 86(2): 1093-1109.
- [14] Iqbal A, Nait-Meziane M, Seghouane A K, et al. Adaptive complex-valued dictionary learning: Application to fMRI data analysis[J]. Signal Processing, 2020, 166: 107263.
- [15] Huang J P, Wang L H, Zhu Y M. Compressed sensing

- MRI reconstruction with multiple sparsity constraints on radial sampling[J]. *Mathematical Problems in Engineering*, 2019, 2019: 3694604.
- [16] Qu X B, Hou Y K, Lam F, et al. Magnetic resonance image reconstruction from undersampled measurements using a patch-based nonlocal operator[J]. *Medical Image Analysis*, 2014, 18(6): 843-856.
- [17] Zhang C Y, Arefin T M, Nakarmi U, et al. Acceleration of three-dimensional diffusion magnetic resonance imaging using a kernel low-rank compressed sensing method[J]. *NeuroImage*, 2020, 210: 116584.
- [18] Ravishankar S, Bresler Y. MR image reconstruction from highly undersampled k-space data by dictionary learning[J]. *IEEE Transactions on Medical Imaging*, 2011, 30(5): 1028-1041.
- [19] Song P F, Weizman L, Mota J F C, et al. Coupled dictionary learning for multi-contrast MRI reconstruction[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(3): 621-633.
- [20] Li S, Wang Z J, Ding Z K, et al. Accelerated four-dimensional free-breathing whole-liver water-fat magnetic resonance imaging with deep dictionary learning and chemical shift modeling[J]. *Quantitative Imaging in Medicine and Surgery*, 2024, 14(4): 2884-2903.
- [21] Xie Y T, Li Q Z. A review of deep learning methods for compressed sensing image reconstruction and its medical applications[J]. *Electronics*, 2022, 11(4): 586.
- [22] Ouchi S, Ito S. Reconstruction of compressed-sensing MR imaging using deep residual learning in the image domain[J]. *Magnetic Resonance in Medical Sciences*, 2021, 20(2): 190-203.
- [23] Aggarwal H K, Mani M P, Jacob M. MoDL: Model-based deep learning architecture for inverse problems[J]. *IEEE Transactions on Medical Imaging*, 2019, 38(2): 394-405.
- [24] Wu K, Xia Y, Ravikumar N, et al. Compressed sensing using a deep adaptive perceptual generative adversarial network for MRI reconstruction from undersampled K-space data[J]. *Biomedical Signal Processing and Control*, 2024, 96: 106560.
- [25] Kim M, Lee S M, Park C, et al. Deep learning-enhanced parallel imaging and simultaneous multislice acceleration reconstruction in knee MRI[J]. *Investigative Radiology*, 2022, 57(12): 826-833.
- [26] Mardani M, Gong E, Cheng J Y, et al. Deep generative adversarial networks for compressed sensing automates MRI[PP/OL]. V1.arXiv (2017-05-31)[2025-05-10]. <https://arxiv.org/abs/1706.00051>.
- [27] Liu X Z, Du H W, Xu J Z, et al. DBGAN: A dual-branch generative adversarial network for undersampled MRI reconstruction[J]. *Magnetic Resonance Imaging*, 2022, 89: 77-91.
- [28] Cheng J Y, Chen F, Sandino C, et al. Compressed sensing: From research to clinical practice with data-driven learning[PP/OL]. V1.arXiv (2019-03-19)[2025-05-10]. <https://arxiv.org/abs/1903.07824>.
- [29] Vasudeva B, Deora P, Bhattacharya S, et al. Compressed sensing MRI reconstruction with co-VeGAN: Complex-valued generative adversarial network[C]//2022 IEEE/CVF Winter Conference on Applications of Computer Vision. Piscataway: IEEE, 2022: 1779-1788.
- [30] Hossain M B, Kwon K C, Shinde R K, et al. A hybrid residual attention convolutional neural network for compressed sensing magnetic resonance image reconstruction[J]. *Diagnostics*, 2023, 13(7): 1306.
- [31] Asiyabi R M, Dacu M, Anghel A, et al. Complex-valued autoencoder-based neural data compression for SAR raw data[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2025, 19(3): 572-582.
- [32] Deveshwar N, Rajagopal A, Sahin S, et al. Synthesizing complex-valued multicoil MRI data from magnitude-only images[J]. *Bioengineering*, 2023, 10(3): 358.
- [33] 张晓华, 练秋生. 基于小波域的复数卷积和复数 Transformer 的轻量级 MR 图像重建方法[J]. *电子学报*, 2025, 53(4): 1221-1231.  
Zhang Xiaohua, Lian Qiusheng. Lightweight MR image reconstruction network based on wavelet domain complex convolution and complex transformer[J]. *Acta Electronica Sinica*, 2025, 53(4): 1221-1231. (in Chinese)
- [34] Li Z N, Zhang T, Wan P, et al. SEGAN: Structure-enhanced generative adversarial network for compressed sensing MRI reconstruction[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, 33(1): 1012-1019.
- [35] Zhao X, Yang T J, Li B J, et al. SwinGAN: A dual-domain Swin Transformer-based generative adversarial network for MRI reconstruction[J]. *Computers in Biology and Medicine*, 2023, 153: 106513.
- [36] Noor R, Wahid A, Bazai S U, et al. DLGAN: Undersampled MRI reconstruction using Deep Learning based Generative Adversarial Network[J]. *Biomedical Signal Processing and Control*, 2024, 93: 106218.

## 作者简介



**王玉露** 女,1999年2月出生于安徽省滁州市。工学硕士,2025年于南京信息工程大学获得硕士学位,现为江苏金恒信息科技股份有限公司 AI 工程师。主要研究方向为医学图像重建。

E-mail: wang00002014@163.com



**吴敏** 女,1973年3月出生于江苏省南通市。现为东部战区总医院医学工程科副教授。主要研究方向为医学图像分析、MRI 压缩感知成像等。

E-mail: njzywm@163.com



**詹天明** 男,1984年10月出生于江苏省高邮市。现为南京审计大学计算机学院/智能审计学院教授、硕士生导师。主要研究方向为模式识别与图像处理。

Email: ztm@nau.edu.cn



**孙玉宝** 男,1983年9月出生于江苏省连云港市。现为南京信息工程大学计算机学院教授、博士生导师。主要研究方向为智能计算成像和三维场景重建。主持国家自然科学基金项目4项,获江苏省科学技术奖1项,在国内外发表学术论文60余篇。

E-mail: sunyb@nuist.edu.cn