

基于语义对比生成对抗网络的高倍欠采 MRI 重建

马凤飞¹ 蔺素珍¹ 刘峰² 王丽芳¹ 李大威¹¹ 中北大学大数据学院 太原 030051² 昆士兰大学信息技术与电子工程学院 布里斯班 QLD 4072

(751812591@qq.com)

摘要 利用数据的稀疏性从随机欠采样的 K 空间重建图像,是解决磁共振成像(Magnetic Resonance Imaging, MRI)因采集时间过长而应用受限问题的主要手段。然而,现有的方法重建高倍欠采图像时纹理细节丢失严重。针对这一问题,借鉴生成对抗网络的对抗学习思想,文中提出一种基于语义对比生成对抗网络的高倍欠采 MRI 重建方法(Semantic-Contrast Generative Adversarial Network, SC-GAN)。该方法由连续的两部分组成。第一部分将笛卡尔高倍随机欠采样 MRI 图像输入基于 U-NET 的生成器,与鉴别器不断博弈对抗生成初步重建图像,以此构建重建子网;另一部分是语义对比子网,通过 VGG-16 比较初步重建图像与全采样图像的语义信息,比较结果反馈给第一部分进行参数调优,直到生成最佳的重建图像。实验结果表明,在加速因子高达 7(14%)时,获得了主客观评价结果均较好的重建图像。与先进的重建方法相比,所提方法的内存损耗更低、收敛速度更快且纹理细节更丰富,可为下一代 MRI 机器的研发提供算法支持。

关键词: MRI 重建;高倍欠采图像;生成对抗网络;语义对比;稀疏性;深度学习

中图分类号 TP391

Semantic-contrast Generative Adversarial Network Based Highly Undersampled MRI Reconstruction

MA Feng-fei¹, LIN Su-zhen¹, LIU Feng², WANG Li-fang¹ and LI Da-wei¹¹ School of Data Science and Technology, North University of China, Taiyuan 030051, China² School of Information Technology and Electrical Engineering, The University of Queensland, Brisbane QLD 4072, Australia

Abstract Exploiting the sparse nature of data to reconstruct image from randomly undersampled K-space is the main method to solve the problem of limited application of magnetic resonance imaging(MRI) due to long acquisition time. However, the loss of textures is serious when the existing methods are used to reconstruct the highly undersampled MRI. Aiming at this problem, referring to the adversarial learning idea of generative adversarial networks(GAN), a novel method for highly undersampled MRI reconstruction based on semantic-contrast generative adversarial network(SC-GAN) is proposed. This method consists of two successive parts. In the first part, the MRI image with Cartesian highly random undersampled is input into the U-NET-based generator to compete with the discriminator for generating the initial reconstructed image, so as to construct the reconstruction subnet. The other part is the semantic contrast subnet, which compares the semantic information between the initial reconstructed image and its fully-sampled image with VGG-16 network. Comparison results are fed back to the first part for parameter adjustment until the best reconstructed image is generated. Experimental results show that the excellent reconstructed results are verified by subjective and objective evaluation when the acceleration factor is up to 7(14%). Compared with the state-of-art methods, the proposed SC-GAN has lower memory consumption, faster convergence speed and more textures, and can provide algorithm support for the development of next-generation MRI machines.

Keywords MRI reconstruction, Highly undersampled images, Generative adversarial network, Semantic contrast, Sparsity, Deep learning

来稿日期:2020-06-08 返修日期:2020-09-15 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:山西省应用基础研究项目(201701D121062);山西省自然科学基金(201901D111152);中北大学第十六届研究生科技立项资助项目(20191635)

This work was supported by the Applied Basic Research Project of Shanxi Province, China(201701D121062), Natural Science Foundation of Shanxi Province, China(201901D111152) and 16th Graduate Science and Technology Project of North University of China(20191635).

通信作者:蔺素珍(lsz@nuc.edu.cn)

1 引言

作为一种可重复、非侵入和定量的组织测量方式, MRI 因其良好的软组织分辨力已经成为重大疾病诊疗的重要手段。不过,其固有的信号采集时间过长问题也给应用造成了一些困难^[1]。一方面,数据采集时间过长不仅会给患者带来不适,而且不可避免的患者身体移动(如心脏搏动和肠胃蠕动等)也增加了图像中存在较重伪影的可能性,从而造成误诊或漏诊;另一方面,较低的检查效率且昂贵的检查费用限制了其进一步的推广和使用。为缓解患者不适并提高 MRI 效率,近二十年来,在加速采集信号的情况下提高图像保真度一直是 MRI 领域的研究重点。

MRI 加速成像方法主要有两大类:一类是并行成像,该方法利用多个独立接收器通道且每个独立通道对离该线圈最近的组织最敏感的特性^[2],获得原始数据,然后使用灵敏度编码(Sensitivity Encoding, SENSE)技术或泛化自校正部分并行获取(GeneRalized Autocalibrating Partial Parallel Acquisition, GRAPPA)等技术^[3]进行重建。然而,并行成像的加速因子受到接收器线圈数量和位置的限制,会引入成像假象并增加 MRI 扫描仪的制造成本^[4]。另一类是信号欠采样+图像重建^[5]。该类方法先利用压缩感知(Compressed Sensing, CS)理论在 K 空间进行 MRI 信号欠采样^[6-7],再基于小波变换^[8]、离散余弦变换^[9]和有限差分(Total Variation, TV)模型^[10]重建图像(后文称之为传统 CS 方法)。该类方法经济实惠,在欠采样率小于 5(20%) (本文称之为低倍欠采样)时效果较好,因此现有 3T 以下机器多采用该类方法。但是,3T 及以上的新一代 MRI 成像机至少需要 5 倍及以上的加速,受低水平稀疏性制约,传统 CS 方法即使在低倍欠采样下也不能有效去除伪影和恢复图像细节。因此,高倍欠采样 MRI 图像重建已成为制约研制下一代 MRI 成像机的瓶颈。

最近,随着深度学习在计算机视觉方面的一系列突破^[11-12], Wang 等^[13]设计并训练了卷积神经网络(Convolutional Neural Networks, CNN)来学习零填充 MRI 图像和全采样 MRI 图像之间的映射关系,虽取得了初步成功,但尚未对其适用性进行定量评估; Lee 等^[14]将 CNN 与并行成像结合,通过从失真图像中估计混叠伪影来重建图像,但重建结果存在明显伪影。为去除图像伪影, Qin 等^[15]加深网络层数并借助 MRI 时间序列的相关性,设计了卷积递归神经网络,实现了动态心脏 MRI 图像重建,但需要较长的迭代重建时间。Ke 等^[16]利用残差加速网络学习,开发了频域预测网络和空间域密集残差网络,使跨域学习成为可能,但重建图像的细节不够清晰。Yang 等^[7]将生成对抗网络(Generative Adversarial Network, GAN)用于 CS-MRI 重建,通过构建基于 U-NET 的生成器并整合频域信息重建了清晰的 MRI 图像,但纹理细节信息缺失明显。为此, Quan 等^[17]在生成器中堆叠两个 U-NET 以增加网络深度,结合循环损失重建 MRI 的结果尚可,但内存损耗较大。总的来说,这些基于深度学习的 CS 方法在 MRI 低倍欠采样时较之传统 CS 方法都有不同程度的改进,但随着欠采样率的提高,尤其是达到 5 倍以上时,即使是在现有 3T 机上,重建图像也会明显缺失纹理细节信

息,更勿论高倍欠采和 3T 及以上 MRI 成像机。因此,探索高倍速采下 MRI 图像的重建新方法势在必行。

GAN 是一种灵活的网络模型,通过生成器和鉴别器的博弈对抗完成训练,但存在训练困难、模式崩溃等问题^[18-19]。U-NET 由一个捕捉语义的收缩路径和一个精准定位的对称扩展路径构成,扩展路径和收缩路径相互联系,具有局部感知能力强、训练时间较短、结构简单、参数较少和对训练数据要求较低等优点^[20]。我们采用 U-NET 作为 GAN 的生成器,并在 GAN 的基础上额外构建一个语义对比子网对 GAN 进行参数调优,在 GAN 和语义对比子网两阶段的对抗下,促使生成器生成特征更加明显、纹理细节更加丰富的图像。本文的主要贡献概括如下:

- (1) 借鉴 GAN 的对抗学习思想,设计语义对比子网,以增强图像语义特征一致性,有效提高了网络学习能力并加速收敛。
- (2) 为了充分利用不同尺度的高频信息,构建基于 U-NET 的重建子网,以捕获更多的纹理细节。
- (3) 级联重建子网和语义对比子网,进行两阶段对抗,并提出了基于语义对比生成对抗网络的 MRI 重建模型(SC-GAN)。
- (4) 为网络配置了合理的综合损失函数,进一步约束图像特征一致性,提高模型的准确率。

2 重建方法

2.1 网络总体结构

本文所提重建方法如图 1 所示,其将 MRI 重建任务分解为两部分。第一部分是基于 GAN 的重建子网,用于生成初始重建图像。其中, G 是由改进的 U-NET 构成的生成器, D 是由标准卷积层构成的鉴别器;第二部分是语义对比子网,这一部分基于重建图像和完全采样图像应具有相同语义特征的思想构建,用于增强重建图像的纹理细节。

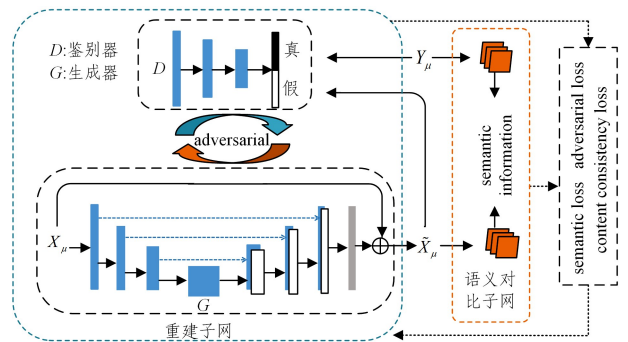


图 1 网络总体框架图

Fig. 1 General framework of the proposed network

2.2 重建子网

重建子网用于从有混叠伪影的零填充图像 X_μ 中提取图像结构特征和纹理细节信息,并去除伪影,最后通过生成器和鉴别器的不断博弈对抗达到平衡,生成初始重建图像 \tilde{X}_μ 。其中,零填充图像 X_μ 由全采样图像 Y_μ 经过笛卡尔随机欠采样得到,具体实现方法如下:

$$X_\mu = SY_\mu \quad (1)$$

$$S = F^{-1} \circ Z \circ M \circ F \quad (2)$$

$$\tilde{X}_\mu = f_{net}(X_\mu) \quad (3)$$

其中, S 表示欠采样操作, F^{-1} 和 F 分别表示傅里叶逆变换和傅里叶正变换, M 表示欠采样算子, Z 表示零填充操作, \circ 表示操作符, $\mu = 1, 2, \dots, U$ 代表样本数量, f_{net} 表示基于 U-NET 的生成函数。

2.3 语义对比子网

为了使重建图像有更加丰富的纹理细节,受重建图像应获得与完全采样图像相同语义信息的启发,本文在重建子网




图2 语义对比子网的结构图

Fig. 2 Structure of semantic-contrast subnet

该子网类似于 GAN 的鉴别器,但是没有 GAN 的交叉训练过程,只是在预训练的网络上进行微调来避免耗时的训练过程和过拟合。通过对比 \tilde{X}_μ 和 Y_μ 的语义信息,损失函数和反向传播促使生成器弥补上一阶段重建子网生成图像中缺失的纹理细节信息,确保最终的重建图像与全采样图像具有相同的语义特征,从而抑制网络优化过程中引入高频伪像,有效重建图像的纹理细节信息。

2.4 损失函数

本文最大化判别器损失,使其最大程度地识别重建图像和全采样图像;同时,最小化生成器损失,使其尽量生成更加逼真的重建图像。最终的训练目标是让判别器无法区分重建图像和完全采样图像。公式化描述如下:

$$L_D = E_{Y_\mu} [\log_{10}(D(Y_\mu))] + E_{X_\mu} [\log_{10}(1 - D(G(X_\mu)))] \quad (4)$$

其中, E_{Y_μ} 表示全采样数据的期望, E_{X_μ} 表示欠采样数据的期望。为了提高重建图像的质量,除了对抗损失 L_{adv} 外,增加了数据一致性损失和语义损失 $L_{semantic}$ 。数据一致性损失由重建图像和全采样图像在图像域和频域的像素级均方差 L_{img} , L_{freq} 联合实现,具体如下:

$$L_G = \epsilon L_{adv} + \beta L_{img} + \delta L_{freq} + \gamma L_{semantic} \quad (5)$$

$$L_{adv} = E_{X_\mu} [\log_{10}(1 - D(G(X_\mu)))] \quad (6)$$

$$L_{img} = \|Y_\mu - \tilde{X}_\mu\|_2^2 \quad (7)$$

$$L_{freq} = \|f_{fft}(Y_\mu) - f_{fft}(\tilde{X}_\mu)\|_2^2 \quad (8)$$

$$L_{semantic} = \|f_{semantic}(Y_\mu) - f_{semantic}(\tilde{X}_\mu)\|_2^2 \quad (9)$$

3 实验与分析

3.1 数据集及实验设置

数据集采用 Facebook 人工智能研究中心 (FAIR) 和纽约大学医学院高级成像创新与研究中心 (CAI2R) 分享的 Fast MRI 数据集。我们随机选用 17000 幅带有或不带有脂肪抑制的冠状 PD 加权的膝部全采样 MRI 图像,欠采样图像经笛

的基础上设计一个附加子网,称作语义对比子网。该子网类似于 GAN 的对抗结构,可进一步促进图像纹理细节的提取并约束图像语义一致性。

由于 VGG-16^[21] 结构简单,泛化性能较好且精度高^[18],采用预训练的 VGG-16 模型进行微调作为语义对比子网的网络架构,如图 2 所示。首先将初始重建图像 \tilde{X}_μ 和全采样图像 Y_μ 作为语义对比子网的输入,经过 4 次池化提取语义特征。然后,通过比较二者的语义相似性获得反馈,并对重建子网进行参数调优。

卡尔欠采样得到。其中,70%作为训练集,30%作为验证集,另选 50 幅图像作为测试集,图像分辨率为 256×256 。

模型初始学习率为 0.0001,每 5 个迭代衰减率为 0.5, $\epsilon = 1, \beta = 15, \delta = 0.1, \gamma = 0.002$,最小批次为 25,使用 Adam Optimizer 优化。本实验以及其他重建方法的硬件平台为:英伟达 (NVIDIA) Tesla M40 GPU 服务器,Inter(R) Core(TM) i5-4590 CPU @3.30 GHz,Python 3.5.0。

3.2 实验影响因素分析

3.2.1 语义对比子网的影响

本文训练了没有增加语义对比子网的模型 No semantic,测试的平均指标如表 1 所列,可以看出,增加语义对比子网后各项指标明显改善,充分验证了语义对比子网的有效性。

表 1 欠采样率为 14% 时影响因素分析

Table 1 Influencing factor analysis with undersampling

Metrics	rate of 14%		
	SC-GAN	No semantic	No consistency
PSNR	29.838	27.735	28.082
SSIM	0.879	0.819	0.838
NMSE	0.127	0.148	0.142

3.2.2 数据一致性损失函数的影响

本文仅设置数据一致性损失为唯一可变因素,训练模型 No consistency,如表 1 所列为测试集的平均指标(黑体表示最好值)。可见,增加数据一致性损失函数后,各项指标均有所提升。

3.2.3 重建结果比较分析

本文将重建结果与其他先进的深度学习方法 DA-GAN^[7],RefineGAN^[17],MDN^[22] 进行比较,从测试集中随机选取 3 幅图像可视化,如图 3 所示(红色框截取局部图并放大 1.5 倍以凸显图像细节)。第 1—第 6 列依次为全采样图像 (Full)、零填充的 7 倍欠采样图像 (ZF)、DAGAN、RefineGAN、MDN 和本文方法 SC-GAN 的结果。可见,SC-GAN 的纹理细节更丰富且指标更高。

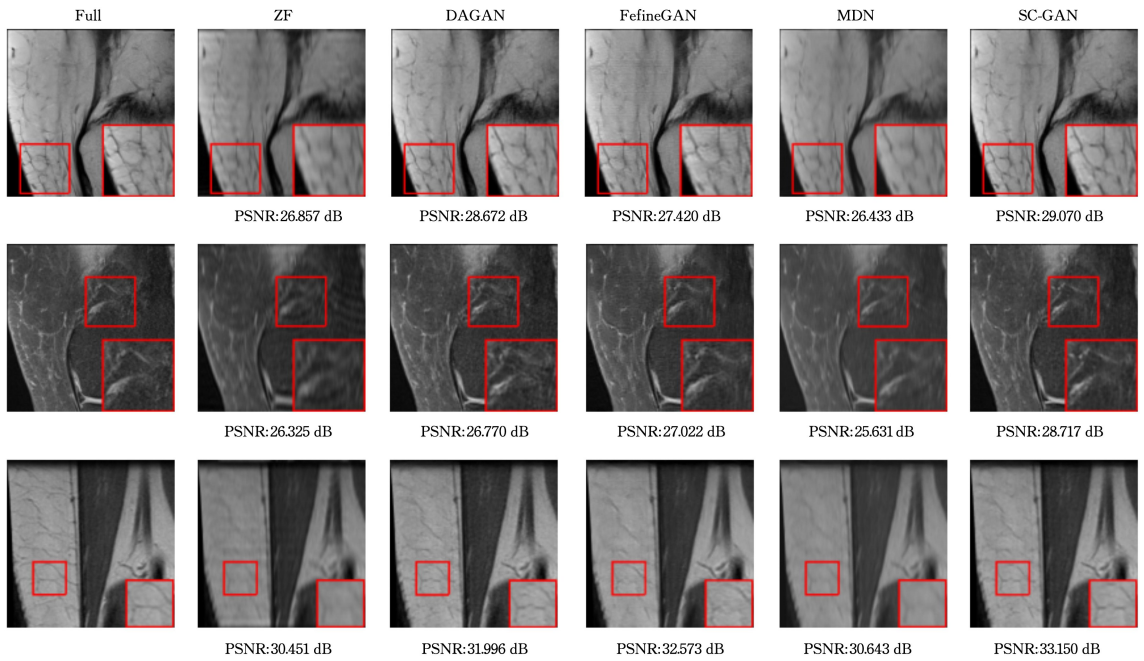


图3 欠采样率为14%不同方法的重建结果可视化(电子版为彩色)

Fig. 3 Visualization of reconstruction results by different methods with undersampling rate of 14%

表2列出了不同方法在不同采样率下的定量比较结果的平均指标,其中黑体表示最优值。可以看出,所有算法在可视化和客观度量方面都比零填充图像有明显的改进。在我们选取的数据集上,MDN可以消除大部分伪影并有效去除噪声,但对于恢复图像细节并不理想,RefineGAN获得了更好的去混叠效果,但是重构细节明显平滑模糊,这两种方法在7倍

(14%)欠采样下重建图像细节不清晰。DAGAN和SC-GAN在恢复图像细节方面是最好的,但是DAGAN存在过拟合现象,本文的SC-GAN用更好的定量指标重建了更逼近全采样图像的结果,细节更丰富,内存损耗(Memory-loss)更低。此外,图4给出了不同方法的收敛曲线,其中,SC-GAN的损失和误差都稳定下降且收敛更快。

表2 不同方法的定量比较

Table 2 Quantitative comparison of different methods

Method	14%			30%			Memory-loss
	PSNR	SSIM	NMSE	PSNR	SSIM	NMSE	
ZF	28.583±2.648	0.871±0.051	0.143±0.050	30.477±2.649	0.900±0.041	0.115±0.041	—
DAGAN	29.534±2.842	0.869±0.055	0.132±0.055	32.042±2.882	0.910±0.040	0.100±0.043	10 873 MiB
RefineGAN	29.529±2.728	0.873±0.049	0.131±0.050	32.017±2.824	0.908±0.038	0.100±0.041	11 002 MiB
MDN	27.474±2.839	0.841±0.044	0.159±0.049	31.014±2.618	0.889±0.032	0.099±0.045	10 870 MiB
SA-GAN	29.838±2.714	0.879±0.050	0.127±0.052	32.137±2.892	0.911±0.040	0.099±0.043	8 406 MiB

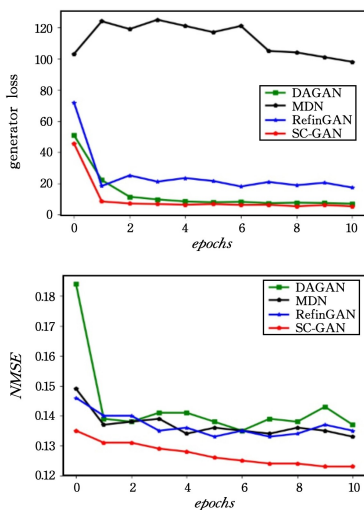


图4 不同方法的收敛分析

Fig. 4 Convergence analysis of different methods

结束语 本文提出一种基于语义对比生成对抗网络的高倍欠采样MRI重建方法(SC-GAN)。针对高倍欠采样MRI重建时纹理细节缺失严重的问题,将重建任务分解为两部分:第一部分是基于GAN的重建子网,用于生成初步重建图像;第二部分为类似于鉴别器的语义对比子网,通过比较初步重建图像和全采样图像的语义相似性获得反馈,并对重建子网进行参数调优,抑制高频伪影,对图像特征一致性进行约束,进一步促进生成器生成更加丰富逼真的纹理细节。经过两阶段对抗,该方法有效提高了网络学习能力并加速收敛。大量实验结果表明,SC-GAN在加速因子为7时,不仅可以有效去除混叠伪影并重建逼真的图像,而且在内存损耗和收敛速度方面明显优于其他先进方法,可为下一代MRI机器研发提供算法支持。

在未来,我们计划对SC-GAN进行深入的分析改进以提高重建精度,进一步处理动态MRI。

参 考 文 献

- [1] SCHLEMPER J, CABALLERO J, HAJNAL J V, et al. A Deep Cascade of Convolutional Neural Networks for Dynamic MR Image Reconstruction[J]. *IEEE transactions on medical imaging*, 2018, 37(2):491-503.
- [2] DESHMANE A, GULANI V, GRISWOLD M A, et al. Parallel MR imaging[J]. *Journal of Magnetic Resonance Imaging*, 2012, 36(1):55-72.
- [3] UECKER M, LAI P, MURPHY M J, et al. ESPIRiT—an eigenvalue approach to autocalibrating parallel MRI where SENSE meets GRAPPA[J]. *Magnetic Resonance in Medicine*, 2014, 71(3):990-1001.
- [4] HAMMERNIK K, KLATZER T, KOBLER E, et al. Learning a variational network for reconstruction of accelerated MRI data[J]. *Magnetic Resonance in Medicine*, 2018, 79(6):3055-3071.
- [5] WU Y, MA Y, LIU J, et al. Self-attention convolutional neural network for improved MR image reconstruction[J]. *Information Sciences*, 2019, 490:317-328.
- [6] SENOUF O, VEDULA S, WEISS T, et al. Self-supervised learning of inverse problem solvers in medical imaging[J]. *arXiv:1905.09325*, 2019.
- [7] YANG G, YU S, 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.
- [8] HUANG J, ZHANG S, METAXAS D. Efficient MR image reconstruction for compressed MR imaging[J]. *Medical Image Analysis*, 2011, 15(5):670-679.
- [9] WANG Y, YING L. Undersampled dynamic magnetic resonance imaging using kernel principal component analysis[C]// 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE, 2014:1533-1536.
- [10] YANG J, ZHANG Y, YIN W. A fast alternating direction method for TVL1-L2 signal reconstruction from partial Fourier data[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2010, 4(2):288-297.
- [11] YAO H, DAI F, ZHANG S, et al. Dr2-net: Deep residual reconstruction network for image compressive sensing[J]. *Neurocomputing*, 2019, 359:483-493.
- [12] LIU Y H, LIU S Y, FU F X. Optimization of Compressed Sensing Reconstruction Algorithms Based on Convolutional Neural Network[J]. *Computer Science*, 2020, 47(3):143-148.
- [13] WANG S, SU Z, YING L, et al. Accelerating magnetic resonance imaging via deep learning[C]// 2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI). IEEE, 2016:514-517.
- [14] LEE D, YOO J, YE J C. Deep artifact learning for compressed sensing and parallel MRI[J]. *arXiv:1703.01120*, 2017.
- [15] QIN C, SCHLEMPER J, CABALLERO J, et al. Convolutional recurrent neural networks for dynamic MR image reconstruction[J]. *IEEE Transactions on Medical Imaging*, 2018, 38(1):280-290.
- [16] KE Z, WANG S, CHENG H, et al. CRDN: Cascaded Residual Dense Networks for Dynamic MR Imaging with Edge-enhanced Loss Constraint[J]. *arXiv:1901.06111*, 2019.
- [17] 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.
- [18] YANG X L, LIN S Z. Method for multi-band image feature-level fusion based on the attention mechanism[J]. *Journal of Xidian University*, 2020, 47(1):120-127.
- [19] ZHENG Z, HU Q H, LIU Q S, et al. Quantizing Weights and Activations in Generative Adversarial Networks[J]. *Computer Science*, 2020, 47(5):144-148.
- [20] TONG G, LI Y, CHEN H, et al. Improved U-NET network for pulmonary nodules segmentation[J]. *Optik*, 2018, 174:460-469.
- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. *arXiv:1409.1556*, 2014.
- [22] DAI Y, ZHUANG P. Compressed Sensing MRI via a Multi-scale Dilated Residual Convolution Network[J]. *arXiv:1906.05251*, 2019.



MA Feng-fei, born in 1991, postgraduate, is a member of China Computer Federation. Her main research interests include image processing and MRI reconstruction.



LIN Su-zhen, born in 1966, Ph.D, professor, master supervisor, is a member of China Computer Federation. Her main research interests include image processing and information fusion.