

基于双域并行编解码网络的磁共振图像重建

张登强*, 刘霄汉, 庞彦伟

天津大学电气自动化与信息工程学院, 天津 300072

摘要 磁共振成像具有出色的软组织对比度, 在很多诊断中具有其他方式不可比拟的优势, 是现代临床医学的重要观测手段之一。但磁共振成像扫描时间较长, 严重制约了诊断效率, 按照一定加速倍率通过部分扫描得到欠采样的 K 空间数据是减少扫描时间的重要途径。现有方法仅单独对 K 域或图像域进行重建, 或者通过串行连接的图像域和 K 域卷积对两域进行交替处理, 未能实现双域信息的融合, 导致重建性能较差。为了实现对高加速倍率欠采样 K 空间数据的高质量重建, 提出了一种同时处理图像域和 K 域数据的双域并行编解码结构。所提方法使用两个并行的编解码网络分别重建欠采样图像域和 K 域数据, 并将 K 域分支的特征通过傅里叶逆变换融合到图像域, 从而显著提高重建质量。实验结果表明, 对于不同加速倍率的前采样数据, 所提方法都优于其他基于 U-Net 的图像重建方法。所提方法有望成为一种高性能的高加速倍率磁共振欠采样数据重建方法, 可应用于临床磁共振重建。

关键词 图像处理; 磁共振成像; 欠采样重建; 编解码网络; 深度学习

中图分类号 TP391.41

文献标志码 A

DOI: 10.3788/LOP202259.1210014

Reconstruction of Magnetic Resonance Images Based on Dual-Domain Crossed Codec Network

Zhang Dengqiang*, Liu Xiaohan, Pang Yanwei

School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China

Abstract Magnetic resonance imaging (MRI) has outstanding soft-tissue contrast and provides unparalleled benefits in various diagnoses. It is an important way of observation in current clinical practice. The scanning period of an MRI, however, is long, which greatly limits the diagnostic efficiency. Obtaining undersampled K-space data through partial scanning at a specific acceleration magnification is a critical approach to save scanning time. Existing approaches only rebuild the K-domain or the image domain alone or alternately process the two domains through serially coupled image domain and K-domain convolution, resulting in poor reconstruction performance. A dual-domain parallel codec structure that processes image domain and K-domain data simultaneously is presented to provide high-quality reconstruction of undersampled K-space data at high acceleration rates. The proposed technique reconstructs the undersampled image domain and K-domain data using two parallel codec networks, respectively, then combines the features of the K-domain branch into the image domain using the inverse Fourier transform, considerably enhancing reconstruction quality. For presampling data with varying acceleration magnifications, experimental results reveal that the proposed method outperforms other U-Net-based image reconstruction methods. This proposed method is projected to develop into a high-performance, high-acceleration-magnification MRI undersampling data reconstruction method that can be used in clinical MRI reconstruction.

Key words image processing; magnetic resonance imaging; under-sampling reconstruction; codec network; deep learning

收稿日期: 2021-05-10; 修回日期: 2021-06-21; 录用日期: 2021-06-28

基金项目: 国家自然科学基金(61632018)

通信作者: *dengqiangzhang@tju.edu.com

1 引言

磁共振成像 (MRI) 是一种非侵入式的医学观测手段。由于良好的组织对比度^[1], MRI 成为自 X 射线发现以来医疗诊断领域最有力的诊断技术之一^[2]。但 MRI 受限于扫描速度, 通常一次磁共振成像需要 15 min 左右, 更长甚至达到 30 min^[3], 会给患者造成严重的不适, 此外过长的扫描时间导致患者通量过低, 检查成本也会居高不下^[4]。因此, 近年来关于提高磁共振成像速度的欠采样重建方法研究一直是磁共振成像的研究重点。

采用欠采样后的 K 域数据进行图像重建, 由于数据获取不满足奈奎斯特采样定理, 会产生伪影^[5]。传统的解决方法有两种。一种是并行成像^[6], 在采集过程中使用按照一定方式排列的接收线圈阵列进行数据采集, 获取采样数据后, 利用不同线圈间冗余的信息提高成像质量, 但该类方法仅能实现低加速倍率的重建。在该类方法中, 比较经典的算法有以下几种: 灵敏度编码 (SENSE)^[7] 通过不同线圈的空间灵敏度将不同线圈间的数据组合, 完成重建, 但是该算法对线圈的空间灵敏度有较高的依赖; 泛化自动校准部分并行采集 (GRAPPA)^[8] 直接在 K 空间对欠采样数据进行组合, 然后通过傅里叶逆变换完成图像重建, 但无法对非笛卡儿采样轨迹的数据进行重建。另一类是基于压缩感知 (CS) 理论^[9] 利用数据稀疏先验的重建, CS 通过使用适当的非线性恢复方案, 可从随机欠采样的 K 空间数据中获取具有稀疏表示的图像。但该算法需要消耗大量计算时间^[10]。

近年来, 受深度学习成功的启发^[11-13], 许多研究人员研究了针对磁共振成像欠采样重建问题的深度

学习方法, 并成功证明了该方法有显著的性能提升^[14-16]。Golkov 等^[17] 利用含有混叠伪影图像和全采样不含混叠伪影图像之间的映射关系, 构建了多层感知器来实现磁共振成像的加速重建, 但是该方法成像质量较低且加速倍率较低。Wang 等^[18] 利用深度卷积神经网络 (CNN) 学习零填充的磁共振图像与全采样磁共振图像之间的映射关系, 实现对欠采样数据的图像重建并去除混叠伪影。但是, 该方法未给出对重建结果的具体评价指标, 适用性受到严格的限制。Zhu 等^[19] 提出端到端的基于流形近似自动转换 (AUTOMAP) 的重建方法, AUTOMAP 可以直接实现端到端的恢复。但由于全连接需要大量的运算存储空间, 在现有计算设备上仅适用于小尺寸的图像。Zhou 等^[20] 在神经网络的基础上引入了 T1 先验, 在实现加速重建的同时提高了成像质量, 但是 T1 先验扫描需要额外的时间, 严重影响重建速度。Eo 等^[21] 提出交叉域卷积网络 KIKI-net, 在双域上进行交替卷积实现磁共振重建, 但是该方法仅是双域之间的交替卷积, 未能实现双域之间的特征融合。

鉴于现有深度学习方法未充分利用 K 域和时域的信息以及双域之间的联系, 导致重建结果在消除伪影和提高信噪比表现上比较差。本文提出一种充分利用双域信息的双域并行编解码网络 (DPC-Net), 对欠采样数据进行双域重建。

2 原理和方法

2.1 网络总体结构

图像域的编解码网络更倾向于图像去噪^[22], 未充分利用原始的 K 域信息, 极易导致网络生成的重建图像无法与原始 K 域信息匹配, 因此提出如图 1

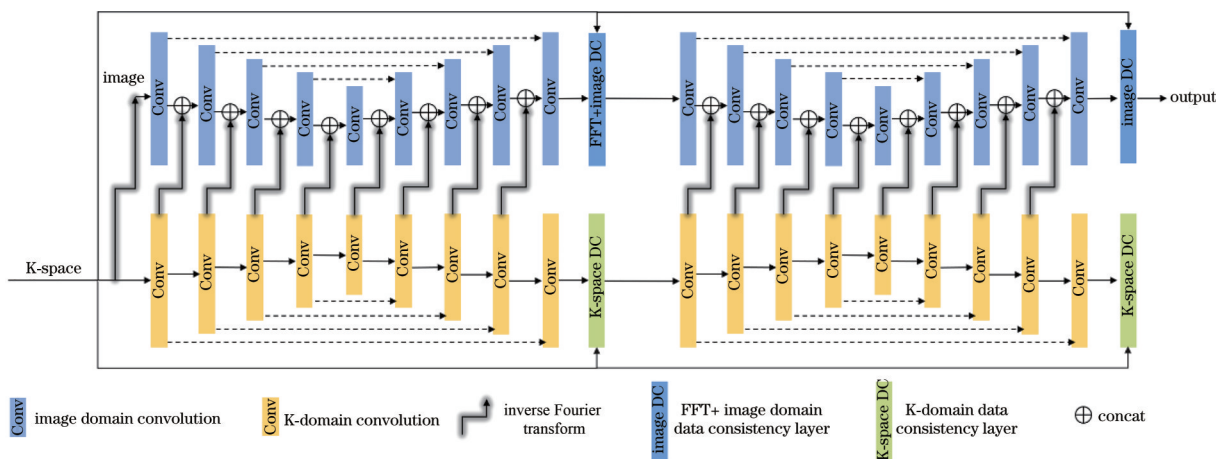


图 1 级联双域交叉编解码网络结构

Fig. 1 Cascaded dual-domain crossed encoding and decoding network structure

所示的 DPC-Net。DPC-Net 借鉴处理分割任务的 U-Net^[23],对图像重建与伪影去除进行了调整。该网络对双域信息进行编解码,实现了双域信息在特征层面的融合。对 K 域和图像域进行编解码并对两者进行特征融合可以更大程度地消除数据获取不满足奈奎斯特采样定理^[24]导致的伪影。此外,在设计级联时采用数据一致性层(DC)^[25]来实现对重建图像的改善并将改善后的信息反馈到 K 域,最后再进行成像。数据一致性表示为

$$y_{rec}(k) = \begin{cases} y_i(k), & k \notin \Omega \\ \frac{y_i(k) + \lambda y_u(k)}{1 + \lambda}, & k \in \Omega \end{cases}, \quad (1)$$

式中: y_i 为全采样 K 空间信息; y_u 为重建图像经傅里叶变换后而得的 K 域信息; k 为 K 域的元素; Ω 为采样掩码, λ 为参数; $y_{rec}(k)$ 为更新后的 K 域信息。

2.2 双域并行编解码网络(DPC-Net)

所提双域并行编解码网络由两部分构成:图像域编解码模块和 K 域编解码模块。图像域编解码模块由两个深层卷积网络组成,分别是编码器和解码器。编码器由 4 层卷积块组成,卷积块如图 2(a)

所示,每个卷积块含 2 个步长为 1 的 3×3 卷积,每次卷积后均连有实例归一化(IN)和整流线性单元(ReLU)激活函数。这些卷积块通过下采样连接,下采样操作由步长为 2 的最大下采样层(Maxpooling)组成,每个步长将每个空间尺寸减半。解码器由与编码器相似的块组成,解码器卷积块之间同样采用双线性上采样层连接,双线性上采样层使卷积块的分辨率依次加倍。解码器将两个输入连接到每个块中的第一个卷积:来自上一个块的上采样输出和来自具有相同分辨率的编码器的输出(图 1 中虚线水平箭头)。在输出端解码器的末尾,采用一系列 1×1 卷积,这些卷积在不更改空间分辨率的情况下将通道数减少到 1 个。

K 域编解码模块结构与图像域编解码模块类似,但是卷积块采用 2 个 3×3 的膨胀卷积,扩大感受野以适应 K 域卷积,如图 2(b)所示。

DPC-Net 采用 DC 将生成的图像域信息经傅里叶变换(FFT)过程变换到 K 域,并对变换得到的 K 域信息与原始输入的 K 域信息进行比对更新,最后通过傅里叶逆变换 IFFT 进行成像。K 域的 DC 则在 K 域编解码网络输出端直接比对更新 K 域信息。

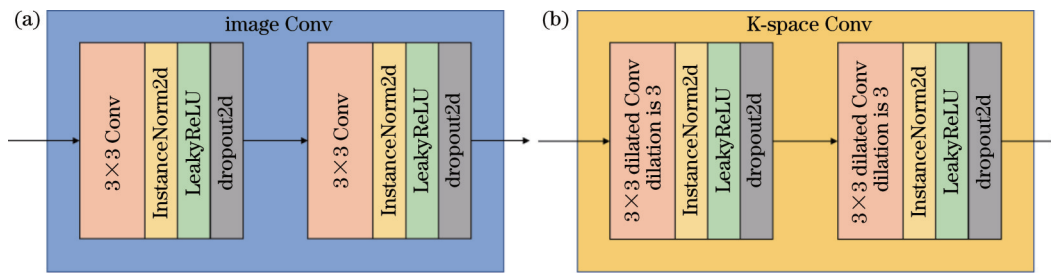


图 2 图像域及 K 域卷积结构。(a)图像域卷积;(b)K 域卷积

Fig. 2 Image-domain and K-domain convolution structures. (a) Image-domain convolution; (b) K-domain convolution

2.3 级联双域交叉编解码网络

双域级联有两种方式:双域并行级联和双域交叉级联。前一级双域交叉编解码网络完成重建之后,若图像域的输出是下一级网络的图像域的输

入,K 域的输出同样是下一级网络的 K 域输入,则称这样的级联方式为双域并行级联,如图 3(a)所示。若上一级的图像域输出经傅里叶变换变为 K 域,再作为下一级的 K 域编解码网络的输入,上一级的 K




图 3 双域级联方式。(a)并行级联;(b)交叉级联

Fig. 3 Dual domain cascaded modes. (a) Parallel cascade; (b) crossed cascade

域输出通过傅里叶逆变换变为图像域,再作为下一级的图像域编解码网络的输入,则称这种级联方式为交叉级联,如图 3(b)所示。通过实验证明,如图 3(a)所示的双域并行级联方式的重建效果更好。

2.4 复合损失函数

鉴于采用的双域编解码结构,图像域和 K 域在数据分布上有着明显的不同,所以在训练阶段图像域采用结构相似度(SSIM)损失函数,K 域采用 L1 损失函数,最终的损失函数由两者以一定的权重相加构成。复合损失函数定义为

$$L_{\text{loss}} = \alpha \|\hat{\mathbf{v}} - \mathbf{v}\|^2 - \beta \frac{(2\mu_{\hat{m}}\mu_m + c_1)(2\sigma_{\hat{m}m} + c_2)}{(\mu_{\hat{m}}^2 + \mu_m^2 + c_1)(\sigma_{\hat{m}}^2 + \sigma_m^2 + c_2)}, \quad (2)$$

式中: α 和 β 均为超参数,满足 $\alpha + \beta = 1$; $\hat{\mathbf{v}}$ 表示重建 K 域, \mathbf{v} 表示全采样 K 域真值; $\mu_{\hat{m}}$ 和 μ_m 分别表示欠采样重建像素块和全采样真值像素块的平均像素强度; $\sigma_{\hat{m}}^2$ 和 σ_m^2 是它们的方差, $\sigma_{\hat{m}m}$ 是 \hat{m} 与 m 之间的协方差; c_1 和 c_2 是两个用于稳定除法的变量,其中 $c_1 = (k_1 M)^2$ 和 $c_2 = (k_2 M)^2$ 。对于 SSIM,选择 7×7 的窗口,取 $k_1 = 0.01$, $k_2 = 0.03$,并将全采样真值的最大值定义为 $M = \max(\mathbf{v})$ 。

3 分析与讨论

3.1 实验环境与数据集

本实验环境如下:CPU Intel Core i7-10700K CPU 3.80 GHz,GPU NVIDIA RTX2080Ti(11 GB) X1,Ubuntu18.04 操作系统,Pytorch 深度学习框架,语言环境为 Python3.7。

采用 FaceBook 与纽约大学联合制作的 FastMRI 公开数据集^[17]中的 Single-coil(Knee)。本数据集训练集含有 973 卷,共计 41877 切片。验证集共 199 卷,共计 7135 切片。训练集原始 K 空间的数据分辨率为 640×384 ,转换到图像域后以中心裁剪的方式将图像裁剪为 320×320 。欠采样数据采用原始信息加掩码(Mask)的方式生成,欠采样 K 空间数据包括一部分连续的低频部分,其余高频部分按照加速倍数随机均匀选取。当加速度倍数等于 4 时,完全采样的低频区域占有所有 K 空间线的 8%,当加速度倍数等于 8 时,完全采样的低频区域占有所有 K 空间线的 4%。所提方法采用随机遮挡的掩码,遮挡过后的 K 域空间如图 4(a)所示,其所对应的全采样 K 空间如图 4(b)所示。实验均在训练集上进行训练,在验证集上进行测试。




图 4 4 倍欠采样与全采样 K 域数据可视化对比。(a)欠采样 K 空间;(b)全采样 K 空间

Fig. 4 Comparison of 4-fold under-sampled and full-sampled K-domain data visualization. (a) Under-sampled K-space; (b) full-sampled K-space

3.2 评价指标

从归一化均方误差(NMSE)、峰值信噪比(PSNR)、结构相似度(SSIM)三个方面对重建结果进行了客观评价。欠采样重建图像与全采样真值图像之间的误差采用归一化均方误差来描述。结构相似度通过利用附近像素之间的相互依赖性来度量两个图像之间的相似性。SSIM本质上可以评估图像中对象的结构属性,可以通过使用滑动窗口在不同的图像位置进行计算获得。对于 SSIM,选择 7×7 的窗口。峰值信噪比表示最大可能图像强度的能量与失真噪声的功率之间的比值。

3.3 超参设置

为了充分利用双域信息以及后续进行数据一致性处理,没有对原始 K 域信息进行裁剪。所提方法使用 RMSprop 优化函数,初始学习率设为 0.001,每次训练 50 epochs,前 40 epochs 的学习率均为 0.001,后 10 epochs 学习率变为初始学习率的 0.1,即 0.0001。

3.4 实验结果分析

所提双域特征融合编解码网络有两种级联方式:交叉级联和并行级联。在两级级联情况下,通过实验证明并行级联方式的重建性能更好,实验结果如表 1 所示。所以在后续的级联重建实验中,都采取如图 3(a)所示的并行级联方式。

损失函数采用复合损失函数,在只有一级双域

表 1 两种级联方式的性能对比

Table 1 Performance comparison of two cascaded methods

Objective indicator	DPC-Net (dual-domain parallel)	DPC-Net (dual-domain crossover)
NMSE	0.0330	0.0325
SSIM	0.7363	0.7268
PSNR /dB	32.16	31.37

特征融合编解码网络的情况下,通过实验证明,当 $\alpha = 0.2, \beta = 0.8$, 即结构相似度损失系数为 0.8, K 域 1 范数损失系数为 0.2 时,重建效果最佳,结构相似度损失对重建结果影响更大,如表 2 所示。

表 2 损失函数权重在重建中的性能对比

Table 2 Performance comparison of loss function weights in reconstruction

Condition	NMSE	SSIM	PSNR /dB
$\alpha = 0.1, \beta = 0.9$	0.0338	0.7310	31.83
$\alpha = 0.2, \beta = 0.8$	0.0330	0.7363	32.16
$\alpha = 0.3, \beta = 0.7$	0.0341	0.7287	32.02
$\alpha = 0.4, \beta = 0.6$	0.0348	0.7213	31.78
$\alpha = 0.5, \beta = 0.5$	0.0352	0.7189	31.01

对 DPC-Net 与 U-Net 的重建结果进行对比实验。为了验证 DPC-Net 每次级联都有一定的收益,在进行对比实验时将 U-Net 级联相应的次数。实验结果如表 3 所示,当级联次数达到 6 次时重建性能达到最佳,并且前 6 级联每次级联都带来性能的提升。DPC-Net 每次级联性能总优于 U-Net 的级联。

在 2 倍、4 倍、8 倍欠采样重建的任务中,DPC-Net 结构均实现了较为优秀的重建表现。如表 4 所示,在不同加速倍率下,DFC-Net 均实现了相比 U-Net 的高质量重建。与 KIKI-Net 的重建结果相比,所提方法在均方根误差、结构相似度及峰值信噪比上均有一定的提升。

表 3 级联双域特征编解码网络重建结果的客观指标

Table 3 Objective indicators of reconstruction results of cascaded dual-domain codec network

Number of cascades	NMSE		SSIM		PSNR /dB	
	U-Net	DPC-Net	U-Net	DPC-Net	U-Net	DPC-Net
1	0.0357	0.0350	0.7271	0.7363	32.15	32.16
2	0.0351	0.0341	0.7298	0.7417	32.23	32.33
3	0.0348	0.0340	0.7354	0.7440	32.67	32.36
4	0.0342	0.0338	0.7435	0.7460	33.03	32.44
5	0.0347	0.0326	0.7426	0.7498	32.78	32.98
6	0.0349	0.0318	0.7417	0.7532	32.53	33.16
7	0.0352	0.0324	0.7387	0.7520	32.47	33.02

表 4 不同加速倍率下不同网络的重建性能表现

Table 4 Reconstruction performance of different networks under different acceleration magnifications

Parameter	Network	2-fold	4-fold	8-fold
NMSE	Zero filled	0.0323	0.0522	0.1091
	U-Net	0.0234	0.0349	0.0604
	KIKI-Net	0.0231	0.0326	0.0602
	DPC-Net	0.0221	0.0318	0.0601
SSIM	Zero filled	0.7820	0.6559	0.548
	U-Net	0.826	0.741	0.623
	KIKI-Net	0.831	0.748	0.634
	DPC-Net	0.845	0.753	0.648
PSNR /dB	Zero filled	31.76	29.59	21.63
	U-Net	34.60	32.53	27.5
	KIKI-Net	34.98	33.01	27.9
	DPC-Net	35.04	33.16	28.8

所提级联双域特征融合编解码网络重建的欠采样磁共振图像如图 5 所示,图 5(a)为 4 倍欠采样零填充图像,图 5(b)为 U-Net 重建的欠采样磁共振图像,图 5(c)为 DPC-Net 重建的欠采样磁共振图像,图 5(d)为 KIKI-Net 重建的欠采样磁共振图像,

图 5(e)为全采样真值。由图 5 可知,所提算法可以有效去除混叠伪影的同时实现 4 倍欠采样加速重建,并且重建结果优于经典神经网络 U-Net 的重建结果。图 6 为对应的重建误差。由图 6 可知,对比零填充磁共振图像和 U-Net 错误差图,所提算法对

细节的恢复具有显著的优势,同时有效消除了欠采样导致的伪影,重建图像更加清晰。




图 5 欠采样磁共振重建结果。(a) 4 倍欠采样零填充磁共振图像;(b) U-Net 重建的磁共振图像;(c) DPC-Net 重建的磁共振图像;(d) KIKI-Net 重建的磁共振图像;(e) 全采样真值

Fig. 5 Reconstruction results of under-sampled MRI. (a) $4\times$ under-sampled zero-filled magnetic resonance images; (b) magnetic resonance images reconstructed by U-Net; (c) magnetic resonance images reconstructed by DPC-Net; (d) magnetic resonance images reconstructed by KIKI-Net; (e) full-sampled true value




图 6 重建误差。(a) 4 倍欠采样零填充磁共振图像误差;(b) U-Net 的重建误差;(c) DPC-Net 的重建误差;(d) KIKI-Net 的重建误差

Fig. 6 Reconstruction error. (a) $4\times$ under-sampled zero filled MRI error; (b) reconstruction error of U-Net; (c) reconstruction error of DPC-Net; (d) reconstruction error of KIKI-Net

4 结 论

欠采样条件下的磁共振加速重建研究越来越成为磁共振研究的重点,但是传统磁共振成像加速倍率较低,很难消除采样不满足奈奎斯特采样定理导致的伪影。针对这些问题,提出一种双域并行编解码网络(DPC-Net),实现最高可达 8 倍的加速且具有较高成像质量的磁共振重建。对比仅在图像域进行重建的 U-Net, DPC-Net 具有更好的重建效

果。在单线圈膝盖欠采样磁共振重建任务中, DPC-Net 实现了 2 倍、4 倍、8 倍的加速重建同时还保证了较高的结构相似度,并消除了采样不满足奈奎斯特采样定理导致的伪影。在主观评价方面,通过欠采样重建,得到的磁共振图像细节丰富、对比度高、视觉效果良好。相比传统算法,所提方法的图像重建质量更高,所得图像的边缘、轮廓以及纹理等都更加清晰。在客观指标上,如表 4 所示,在 4 倍欠采样重建任务中,所提算法重建图像的客观指标与零填

充图像的客观指标相比,SSIM 提升 9.7 个百分点,PSNR 提升 3.57 dB,NMSE 下降 2.04 个百分点。这些结果表明了所提算法的有效性。与交叉域卷积神经网络 KIKI-Net 相比,DPC-Net 也有更优的重建表现。

在后续的研究中,将进一步探索更高倍率的加速重建,如 10 倍的加速重建。此外,随着并行扫描技术的成熟,可进一步研究多线圈欠采样重建问题,并在多线圈欠采样上实现更高加速倍率、更高性能的重建。

参 考 文 献

- [1] Zhang Z Z, Romero A, Muckley M J, et al. Reducing uncertainty in undersampled MRI reconstruction with active acquisition[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 2049-2053.
- [2] Hashemi R H, Bradley W G, Lisanti C J. MRI 基础[M]. 尹建忠,译. 2 版. 天津: 天津科技翻译出版公司, 2004.
Hashemi R H, Bradley W G, Lisanti C J. MRI: the basic[M]. Yin J Z, Transl. 2nd ed. Tianjin: Tianjin Science & Technology Translation & Publishing Corp, 2004.
- [3] Pineda L, Basu S, Romero A, et al. Active MR k-space sampling with reinforcement learning[M]//Martel A L, Abolmaesumi P, Stoyanov D, et al. Medical image computing and computer assisted intervention-MICCAI 2020. Lecture notes in computer science. Cham: Springer, 2020, 12262: 23-33.
- [4] Zbontar J, Knoll F, Sriram A, et al. fastMRI: an open dataset and benchmarks for accelerated MRI [EB/OL]. (2018-11-21) [2021-06-01]. <https://arxiv.org/abs/1811.08839>.
- [5] 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, 2017, 37(2): 491-503.
- [6] Deshmane A, Gulani V, Griswold M A, et al. Parallel MR imaging[J]. Journal of Magnetic Resonance Imaging, 2012, 36(1): 55-72.
- [7] Pruessmann K P, Weiger M, Scheidegger M B, et al. SENSE: sensitivity encoding for fast MRI[J]. Magnetic Resonance in Medicine, 1999, 42(5): 952-962.
- [8] 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.
- [9] 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.
- [10] 王一达, 宋阳, 谢海滨, 等. 卷积神经网络重建欠采样的磁共振图像[J]. 磁共振成像, 2018, 9(6): 453-459.
Wang Y D, Song Y, Xie H B, et al. Reconstruction of under-sampled magnetic resonance image based on convolutional neural network[J]. Chinese Journal of Magnetic Resonance Imaging, 2018, 9(6): 453-459.
- [11] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [12] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [13] 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.
- [14] Liang D, Cheng J, Ke Z W, et al. Deep MRI reconstruction: unrolled optimization algorithms meet neural networks[EB/OL]. (2019-07-26) [2021-05-01]. <http://arxiv.org/abs/1907.11711>.
- [15] Chaudhari A S, Fang Z N, Kogan F, et al. Super-resolution musculoskeletal MRI using deep learning [J]. Magnetic Resonance in Medicine, 2018, 80(5): 2139-2154.
- [16] Wu Y, Ma Y J, Liu J, et al. Self-attention convolutional neural network for improved MR image reconstruction[J]. Information Sciences, 2019, 490: 317-328.
- [17] Golkov V, Dosovitskiy A, Sperl J I, et al. Q-space deep learning: twelve-fold shorter and model-free diffusion MRI scans[J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1344-1351.
- [18] Wang S S, Cheng H T, Ying L 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.
- [19] Zhu B, Liu J Z, Cauley S F, et al. Image reconstruction by domain-transform manifold learning [J]. Nature, 2018, 555(7697): 487-492.

- [20] Zhou B, Zhou S K. DuDoRNet: learning a dual-domain recurrent network for fast MRI reconstruction with deep T1 prior[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 4272-4281.
- [21] Eo T, Jun Y, Kim T, et al. KIKI-net: cross-domain convolutional neural networks for reconstructing undersampled magnetic resonance images[J]. *Magnetic Resonance in Medicine*, 2018, 80(5): 2188-2201.
- [22] Mao X J, Shen C H, Yang Y B. Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections[EB/OL]. (2016-03-30) [2021-05-01]. <https://arxiv.org/abs/1603.09056>.
- [23] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. *Medical image computing and computer-assisted intervention-MICCAI 2015*. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [24] 杨文举. 奈奎斯特欠采样和信号的重构算法研究[D]. 北京: 北京理工大学, 2016: 3-4.
- Yang W J. Research on reconstruction algorithm of under Nyquist sampling and signal[D]. Beijing: Beijing Institute of Technology, 2016: 3-4.
- [25] Schlemper J, Caballero J, Hajnal J V, et al. A deep cascade of convolutional neural networks for MR image reconstruction[M]//Niethammer M, Styner M, Aylward S, et al. *Information processing in medical imaging*. Lecture notes in computer science. Cham: Springer, 2017, 10265: 647-658.