

基于深度学习的欠采样磁共振图像重建研究综述

程 航¹, 蔡 昕¹, 姜小平², 杨 光³, 贾守强⁴, 聂生东¹

(1.上海理工大学健康科学与工程学院, 上海 200093;

2.上海康达卡勒幅医疗科技有限公司, 上海 200444;

3.华东师范大学物理与电子科学学院, 上海 200062;

4.山东第一医科大学附属济南人民医院影像科, 山东 济南 271100)

✉ 2909994580@qq.com; cxsmic@163.com; xp_jiang@msn.com; gyang@phy.ecnu.edu.cn; jshqlw@163.com; nsd4647@163.com



摘 要: 针对加速磁共振成像(Magnetic Resonance Imaging, MRI)中, 传统算法对压缩感知欠采样磁共振(Magnetic Resonance, MR)图像重建质量欠佳的问题, 以基于深度学习的欠采样 MR 图像重建算法为研究对象, 系统性地概述图像重建算法中模型驱动与数据驱动方法的工作原理, 分析各自的特性与优点、缺点, 对重建方法进行对比讨论, 并列举了部分算法在数据集上的表现。结果表明, 大部分算法在数据集上的结构相似性指标 (Structure Similarity Index Measure, SSIM) 为 0.87—0.96。依据重建方法现存的不足与当前的研究趋势, 提出 3 种 MR 图像重建算法未来的发展方向。

关键词: MRI; 欠采样图像重建; 深度学习; 模型驱动; 数据驱动

中图分类号: TP391.4 **文献标识码:** A

Overview of Under-sampled Magnetic Resonance Image Reconstruction Based on Deep Learning

CHENG Hang¹, CAI Xin¹, JIANG Xiaoping², YANG Guang³, JIA Shouqiang⁴, NIE Shengdong¹

(1.School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;

2.Shanghai Kangda Colorful Medical Technology Co., Ltd., Shanghai 200444, China;

3. School of Physics and Electronic Science, East China Normal University, Shanghai 200062, China;

4.Department of Imaging, Jinan People's Hospital Affiliated to Shandong First Medical University, Jinan 271100, China)

✉ 2909994580@qq.com; cxsmic@163.com; xp_jiang@msn.com; gyang@phy.ecnu.edu.cn; jshqlw@163.com; nsd4647@163.com

Abstract: Traditional algorithms perform poorly on reconstructing compressed sensing under-sampled Magnetic Resonance (MR) images in accelerated Magnetic Resonance Imaging (MRI). In order to solve this problem, taking under-sampled MR Image reconstruction algorithm based on deep learning as the research object, this paper proposes to systematically summarize the working principles of model-driven and data-driven methods in image reconstruction algorithms, and analyze their characteristics, advantages and disadvantages. The reconstruction methods are compared and discussed, and performance of some algorithms on the dataset is listed. The results show that most algorithms have a Structure Similarity Index Measure (SSIM) of 0.87-0.96 on the dataset. The future development directions of the three MR image reconstruction algorithms are proposed based on the existing shortcomings of the reconstruction methods and current research trends.

Keywords: MRI; under-sampled image reconstruction; deep learning; model-driven; data-driven

1 引言(Introduction)

磁共振成像(Magnetic Resonance Imaging, MRI)能够提供对比度丰富、分辨率高的图像, 并且具有无创、无电离辐

射等特点, 被广泛应用于临床诊断中。受物理因素的限制, MRI 扫描时间较长, 因此需对该过程进行加速。常用的加速策略有两种: ①并行成像(Parallel Image, PI)^[1], 使用多组

线圈同时采集信号；②压缩感知(Compressed Sensing, CS)^[2]，只采集部分数据点，从而减少采样时间。通常，PI在不严重损失图像质量的情况下，加速因子为2或3，而CS能以更大的加速因子降采k空间(傅里叶空间)的信号。因此，基于CS降采样的MRI(CS-MRI)重建技术成为近年来磁共振(Magnetic Resonance, MR)图像重建方法领域的热点研究内容之一。

随着深度学习技术在图像处理领域大放异彩，为MR重建提供了新的工具，主流重建方法大致分为两类：模型驱动(Model-Driven)与数据驱动(Data-Driven)。模型驱动是以特定的优化方程为基础，通过数学推导，使优化方程变形为适合组成深度网络的形式，并结合人工神经网络(Artificial Neural Network, ANN)形成的一类重建方法。数据驱动则是完全使用ANN，如卷积神经网络(Convolutional Neural Network, CNN^[3])、对抗生成网络(Generative Adversarial Network, GAN^[4])等进行重建的一类方法。本文主要介绍基于模型驱动与数据驱动的欠采样磁共振成像重建算法，阐述它们各自的特点、发展情况及应用场景，并对MR图像重建技术未来的发展方向进行展望。

2 数据驱动的重建方法(Data-driven reconstruction method)

随着深度学习将各类ANN引入人们的视野，基于数据驱动，也称端到端(End-to-End, E2E)^[5]的重建方法应运而生。数据驱动方法主要流程如图1所示：首先，对MR图像进行预处理，如灰度标准化等；其次，构建适用特定任务的神经网络，使用训练集进行网络训练，使用验证集与测试集评估网络的性能；最后，对网络的输出进行后处理，提升结果图像的质量。




图1 基于数据驱动的MR图像重建流程图

Fig. 1 Flowchart of data-driven-based MR image reconstruction

2.1 基于CNN的重建方法

CNN通过多层卷积操作提取图像中的信息，将信息整合得到最后的输出。WANG等^[3]使用一个3层的CNN重建降采样的MR图像，该网络采用k空间填零重建后的图像作为预训练的CNN输入，最终生成全采样图像。然而，这样的训练方法存在数据不稳定的问题，即输出的数据可能因为输入数据的微小变动而发生大幅度改变，这不符合实际情况。为此，深度级联神经网络(Deep Cascade CNN)^[6-7]提出一种新的操作：数据一致性(Data Consistency, DC)，该操作能有效防止网络由于过拟合等因素导致重建结果对应的k空间与真实

k空间在数值上的不连续问题。针对Cartesian采样的DC操作较为成熟，而针对non-Cartesian采样的DC操作还存在诸多挑战。为此，CHEN等^[8]提出4种不同的用于non-Cartesian采样的DC操作，并以U形网络^[9](U-Net)为重建网络进行了测试。结果显示，相比不使用DC的重建图像(NRMSE = 0.169)，使用conjugate gradient DC能获得误差最小的重建图像(NRMSE = 0.117)。GAN等^[10]在使用CNN重建的基础上，在网络中加入另一个独立的CNN用于图像配准，以降低扫描过程中患者的运动对图像质量的损害。

U-Net^[9]的编码-解码连接方式能提升深层卷积核的视野，为深层网络提供更多上下文信息用于推断。此外，U-Net中的跳跃连接使编码特征与解码特征融合，充分利用数据的全局特征，提高了重建图像的质量。王一达等^[11]使用基础U-Net作为网络，并利用数据扩增技术获得包含100万张2D MR图像的训练集，最终重建图像的SSIM达到0.93。EO等^[12]提出KIKI-net用于图像域与k空间的双域卷积，弥补了以往单域重建工作中，对另一域数据利用不充分的缺陷。张登强等^[13]提出的双域并行编解码网络(DPC-Net)，使用2个U-Net进行双域重建。相较于KIKI-net，DPC-Net中用于重建k空间的U-Net会将每一层特征图经过逆傅里叶变换后与用于重建图像域U-Net的对应层特征图相加，实现了双域间的特征融合。

残差(Residual)结构由卷积层与残差连接组合而成，残差连接将卷积层的输入与输出相加，能有效提高网络的抗干扰能力。DUAN等^[14]将残差结构与密集连接思想结合的网络模块(Residual Dense Block, RDB)进行级联，设计出用于重建肺形态学测量的扩散加权磁共振成像(DW-MRI)的新网络，并从统计学的角度证明，金标准图像与重建图像之间没有显著性差异。WU等^[15]提出的T-Net，将残差结构与层级化的网络结构结合。层级结构提高了特征图的稀疏性并扩大了感受野，而残差结构补偿了层级结构运算中的细节损失。

2.2 基于GAN的重建方法

YANG等^[4]使用U-Net代替CNN作为GAN的生成器，以获得更丰富的重建细节。同时，使用VGG作为特征提取器，以生成器生成的图像与真实图像之间为输入，将输出作为判别器损失函数值的一部分。BELOV等^[16]利用GAN与CNN结合进行了一系列实验。他们将输入图像的长和宽各缩小一倍，对缩小图像的k空间进行降采样，并使用超分辨率GAN(SRGAN^[17])与U-Net的不同组合形式，对图像进行重建与提升分辨率。结果发现，先使用SRGAN提升分辨率，再使用U-Net去伪影，对图像质量的提升效果最好。LIU等^[18]将注意力机制引入以U-Net作为GAN的生成器，使网络依据数据自适应地选取更有价值的信息。LV等^[19]在生成器中融合了正则化操作，并在图像域与k空间都运用增加了pixel-wise的混合损失函数。LI等^[20]在以U-Net为生成器的

GAN 中加入了基于空间与通道的注意力机制。空间注意力机制先获取该层所有特征图的均值特征图,在均值特征图学习应关注的特征,便于准确定位有效信息。基于通道的注意力机制获取通道维的全局平均池化,便于重建图像的细节部分。

综上,基于数据驱动的重建方法,利用不同类型的 ANN 对 MR 图像进行重建。这些方法的性能主要取决于网络自身结构与训练数据量。网络自身结构旨在整合网络各层次特征,提升重建效果,如上述的跳跃连接及残差连接。数据量越大,意味着可学习的样本越多,网络的性能就越稳定,泛化能力也越强。此外,基于 GAN 的重建方法,设置判别器损失函数也十分重要。不同的损失函数具有不同的特性,例如 l_2 损失能够保存图像的主要结构; l_1 损失能丢弃一些低强度噪声,提升分辨率^[21]。因此,选择适用于特定任务的一个或多个损失函数组合能够提升网络的性能表现。然而,数据驱动方法也存在如下不足:①训练数据都是有偏差的,导致模型也存在偏差,难以泛化;②数据驱动加重了 ANN 的“黑箱”特性,网络具体获取了哪些特征更难判断。

3 模型驱动的重建方法(Model-driven reconstruction method)

模型驱动的重建方法,也称优化展开(Unrolled Optimization, UO),是传统重建算法与 ANN 和深度学习思想结合的方法。传统重建算法存在耗时长、精度低等缺陷且难以在高降采率图像上获得较好的重建结果。模型驱动方法可避免复杂的人为操作,如正则函数、稀疏函数的选择等,并且对于输入与输出之间强大的非线性映射能力,更适用于处理复杂的医学图像。模型驱动方法有 3 个关键因素:数学模型、优化方法和深度网络。数学模型是 UO 的基石,从理论上建立输入数据到输出数据之间的映射关系。优化方法是网络内参数更新的具体过程,如梯度下降法(Gradient Descent, GD)、交替乘法(Alternating Direction Method of Multiplier, ADMM)等。深度网络是优化方法展开的结果。UO 使用带有自由参数的网络模块代替传统优化方法中的方程,再将些网络模块组合成一个完整的重建步骤。通过重建步骤间的级联操作形成深度网络。这样的网络具有清晰的数学结构,因此可以根据先验知识,对网络中的特定部分进行修改。模型驱动方法的主要流程如图 2 所示。




图 2 基于模型驱动的 MR 图像重建流程图

Fig. 2 Flowchart of model-driven-based MR image reconstruction

3.1 单输入单输出型重建模型

单输入单输出(Single In Single Out, SISO)的重建模型所需的输入数据为单线圈的 MR 图像。获取这类图像通常需要将多线圈的 k 空间数据做傅里叶逆变换得到每个通道对应的图像域数据,再进行通道合并获得。这样处理的优点在于输入输出数据简单、直观,劣势在于丢失了线圈之间的信息。

受 ADMM 的启发,YANG 等^[22]以 ADMM 为优化方法,设计出 Generic-ADMM-CSNet(简称 ADMM-CSNet)。ADMM-CSNet 让稀疏变换和输入数据解耦,使网络能够对 MR 图像外的自然图像进行处理。此外,ADMM-CSNet 能够处理复数格式的输入数据。本文使用磁场强度为 3 T 的 MRI 扫描仪获取的脑部数据与胸部数据作为测试集证明 ADMM-CSNet 的重建图像质量更高。但是,ADMM-CSNet 存在只处理单线圈数据,而不能处理多线圈数据的缺陷。

迭代阈值收缩网络(ISTA-Net^[23])是以迭代阈值收缩算法(Iterative Shrinkage Thresholding Algorithm, ISTA)为优化方法,创新地使用了一个能在训练过程中显式地学习稀疏变换的 CNN 模块。ISTA-Net^[23]将残差结构与 ISTA-Net 融合,增强了原网络的稳定性。此外,ISTA-Net⁺在不同层之间进行参数共享,在完全共享参数的条件下,网络参数比完全不共享参数低一个数量级,而 PSNR 仅降低 0.83。ISTA-Net⁺⁺^[24]提出动态展开策略(Dynamic Unfolding Strategy, DUS),将采样率也作为输入数据的一部分,通过网络内的卷积层获取输入的降采样图像与降采样率之间的关系,实现了同一网络重建不同降采样率的图像。

3.2 多输入多输出型重建模型

在实际采样过程中,往往采用多线圈进行采样,而线圈之间的信号存在一定冗余,有效利用这些冗余信号能够让我们以更大的加速因子进行降采。多输入多输出(Multi In Multi Out, MIMO)的重建模型以不同线圈信号作为输入,弥补了 SISO 中损失的线圈间特征。

HAMMERNIK 等^[25]以梯度下降法(Gradient Descent, GD)作为优化方法,设计出能用于重建多通道数据的变分网络(Variational Net, VN)。VN 中通过传统方法计算得到的敏感度图,需要使用 k 空间的 ACS(Auto Calibration Signal),即全采的低频信号。这导致 k 空间中心区域采集的信号增多,采样时间加长。为此,SRIRAM 等^[26]提出了一种改进的 VN:端到端的变分网络(End-to-End VarNet)。他们使用一个独立的 U-Net 从训练过程中学习敏感度图,使网络只需获取少量 ACS 数据,也能准确计算出敏感度图,从而提高了降采率。AGGARWAL 等^[27]提供了结合了深度学习先验信息的模型驱动方法的系统性设计过程。此外,重建步骤间的权重共享能使收敛性与网络复杂度解耦,避免在网络中增加重建步骤时,同步增加网络参数量导致过拟合。AGGARWAL 等^[28]提出的基于模型的联合深度学习方法(J-MoDL)将采样矩阵作为可学习的参数,与重建过程一起训练,并指出网络可能会由于优

化问题的高度非凸性而陷入局部最小值，而 SGD 能有效地找到较优解。

综上，基于优化展开的方法将传统优化方法与 CNN 结合，使网络依据训练数据学习传统方法中需要人为设定的函数，减轻人为交互的负担与不确定性。对部分优化展开方法的总结如表 1 所示。基于优化展开方法存在如下问题：①大部分工作针对实数图像开展。直接从 MR 仪器上获取的数据通常为多通道的复数数据，实数数据只保留了原始复数数据的幅值信息，损失了相位信息。②这类算法都依托于特定的优化方法，导致对重建方法的改进会受到原有方程形式的限制，改进空间有限。③基于二维与三维网络的工作较多，而基于四维网络的工作较少。KÜSTNER 等^[29]在三维重建网络的基础上，增加时间维度，实现对高维数据的重建。由于增加了一个维度的信息，数据的冗余度增大，因此可以使用更高的降采率，进一步缩短了采样的时间，更容易满足实时重建对速度的要求。

表 1 5 种优化展开方法总结

Tab.1 Summary of five unrolled optimization methods

UO 方法	优化方法	测试集	降采率/%	PSNR	SSIM	特点
ADMM-CSNet ^[22]	ADMM	脑、胸部图像	30	34.42	0.87	单通道数据
ISTA-Net ^{++[23]}	ISTA	Set11	30	33.82	—	单通道数据
ISTA-Net ^{++[24]}	ISTA	Set11	30	34.86	—	单通道数据
VN ^[25]	GD	膝盖冠状面	25	—	0.92	多通道数据
E2E VarNet ^[26]	GD	脑部图像	25	40.00	0.93	多通道数据、融合敏感度图
J-MoDL ^[28]	GD	膝、脑部图像	25	41.28	0.96	多通道数据、采样矩阵可学习

4 挑战与未来工作(Challenges and prospects for future work)

随着 MR 数据集的扩充与高性能网络架构的提出，基于深度学习的重建算法显现出比传统方法更大的潜力，但仍存在值得深入研究的问题。

(1)网络设计。UO 的优势在于具有清晰的数学结构，能使网络迅速收敛，并达到较高的重建效果；缺点在于网络体积较大，学习能力较弱。E2E 则与此相反，它的网络体积小，训练速度快，学习能力的强弱与所使用的网络紧密相关；但这类网络必须要经过长时间的迭代才能达到一定的精度，未来如果能在此基础上加入一些先验知识，就能在保持网络学习能力的同时，减少网络的训练时间。如今，越来越多的实验将二者的特性更为紧密地结合在一起，因此混合式重建模型将更具潜力。

(2)并行成像的压缩感知混合(PI-CS)。随着网络与硬件技术的不断发展，研究人员可以使用性能更强的网络在更大的数据集上更快地训练所需的模型。对于单一的 CS 或 PI 任务而言，已有很多工作能够实现在 4 倍、8 倍乃至更高的加速因子下完成 MRI 重建任务。为了实现更高速的采样，就需要在单次扫描中创造更多的信息冗余，而 PI 正好能满足要求。已有文献对 PI + CS 这样的混合加速模式进行探索^[25-26,30]，因此 PI-CS 的降采样模式势必会成为未来的研究热点。

(3)多模态。在 MRI 重建领域另一个值得关注的点是多模态或多对比度重建。使用特定序列进行成像，能在一次扫描中获得多种对比度的输出，使图像中信息的集中度不同，为重建带来更丰富的信息^[31]。目前的重建工作大多在单一对比度的数据上表现良好，但缺少在其他对比度数据集上的泛化能力。解决该问题的通常做法是迁移学习，将已训练好的模型在新数据集上再次训练，但会增加时间成本。对模型使用多模态数据进行训练能增强模型泛化能力，使模型预先适应不同模态的图像，节省使用迁移学习所带来的额外开销。此外，ISAT-Net⁺⁺提出的 DUS，将不同的 CS 采样率作为网络的一项输入，使最终训练完成的网络可以适应不同 CS 采样率的 MR 图像，相似的方法也可以用来训练能适应不同模态图像的模式。

5 结论(Conclusion)

本文主要介绍了深度学习技术在磁共振图像重建领域中的两种具体应用，即模型驱动与数据驱动。无论是模型驱动还是数据驱动，都越来越紧密地同深度学习结合起来，以实现更高的采样倍率以及更优的重建效果，但仍有问题亟待解决。未来，应继续深入挖掘深度学习的优势，并将这些优势同 MR 图像重建任务结合起来，进一步提升重建图像质量，为 MR 图像降采样技术实现更好的临床应用而不断努力。

参考文献(References)

- [1] GRISWOLD M A, JAKOB P M, NITTKA M, et al. Partially parallel imaging with localized sensitivities (PILS)[J]. Magnetic Resonance in Medicine, 2000, 44:602-609.
- [2] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4):1289-1306.
- [3] WANG S, SU Z, YING L, et al. Accelerating magnetic resonance imaging via deep learning[C]// IEEE. 2016 IEEE International Symposium on Biomedical Imaging (ISBI). Prague, Czech Republic: IEEE, 2016:514-517.
- [4] YANG G, YU S, DONG H, et al. DAGAN: Deep de-aliasing generative adversarial networks for fast compressed sensing MRI reconstruction[J]. IEEE Transaction on Medical Imaging, 2018, 37(6):1310-1321.
- [5] CHEN Y, SCHONLIEB C B, LIO P, et al. AI-based reconstruction for fast MRI—a systematic review and meta-analysis[J]. Institute of Electrical and Electronics Engineers (IEEE), 2022, 110(2):224-245.

- [6] SCHLEMPER J, CABALLERO J, HAJNAL J V, et al. A deep cascade of convolutional neural networks for dynamic MR image reconstruction[J]. *IEEE Transaction on Medical Imaging*, 2018, 37(2):491-503.
- [7] 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.
- [8] CHEN Z, CHEN Y, XIE Y, et al. Data-consistent non-cartesian deep subspace learning for efficient dynamic MR image reconstruction[C]// *IEEE. 2022 IEEE International Symposium on Biomedical Imaging (ISBI)*. Kolkata, INDIA: IEEE, 2022:1-5.
- [9] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[J/OL]. (2015-05-18)[2023-03-01]. <https://arxiv.org/abs/1505.04597>.
- [10] GAN W, SUN Y, ELDENIZ C, et al. Deep image reconstruction using unregistered measurements without groundtruth[C]// *IEEE. 2021 IEEE International Symposium on Biomedical Imaging (ISBI)*. Nice, FRANCE: IEEE, 2021:1531-1534.
- [11] 王一达, 宋阳, 谢海滨, 等. 卷积神经网络重建欠采的磁共振图像[J]. *磁共振成像*, 2018, 9(6):453-459.
- [12] 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.
- [13] 张登强, 刘霄汉, 庞彦伟. 基于双域并行编解码网络的磁共振图像重建[J]. *激光与光电子学进展*, 2022, 59(12):172-179.
- [14] DUAN C, DENG H, XIAO S, et al. Accelerate gas diffusion weighted MRI for lung morphometry with deep learning[J]. *European Radiology*, 2022, 32(1):702-713.
- [15] WU Y, MA Y, CAPALDI D P, et al. Incorporating prior knowledge via volumetric deep residual network to optimize the reconstruction of sparsely sampled MRI[J]. *Magnetic Resonance Imaging*, 2020, 66:93-103.
- [16] BELOV A, STADELMANN J, KASTRYULIN S, et al. Towards ultrafast MRI via extreme k-space undersampling and superresolution[C]// *BRUIJNE M D. International Conference on Medical Image Computing and Computer-Assisted Intervention(MICCAI)* 2021. Berlin, GERMANY: Springer, 2021:254-264.
- [17] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]// *IEEE. Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)*, Honolulu, HI, USA, 2017: 4681-4690.
- [18] LIU J, YAGHOUBI M. Fine-grained MRI reconstruction using attentive selection generative adversarial networks[C]// *IEEE. 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. New York, USA: IEEE, 2021:1155-1159.
- [19] LV J, WANG C, YANG G. PIC-GAN: a parallel imaging coupled generative adversarial network for accelerated multi-channel MRI reconstruction[J]. *Diagnostics*, 2021, 11(1):61-75.
- [20] LI G, LV J, WANG C. A modified generative adversarial network using spatial and channel-wise attention for CS-MRI reconstruction[J]. *IEEE Access*, 2021, 9:83185-83198.
- [21] MARDANI M, GONG E, CHENG J Y, et al. Deep generative adversarial neural networks for compressive sensing MRI[J]. *IEEE Transactions on Medical Imaging*, 2018, 38(1):167-179.
- [22] YANG Y, SUN J, LI H, et al. ADMM-CSNet: a deep learning approach for image compressive sensing[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(3):521-538.
- [23] ZHANG J, GHANEM B. ISTA-Net: interpretable optimization-inspired deep network for image compressive sensing[C]// *IEEE. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, UT: IEEE, 2018:1828-1837.
- [24] YOU D, XIE J, ZHANG J. ISTA-Net+ : flexible deep unfolding network for compressive sensing[C]// *IEEE. 2021 IEEE International Conference on Multimedia and Expo (ICME)*. Shenzhen, China: IEEE, 2021:1-6.
- [25] 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.
- [26] SRIRAM A, ZBONTAR J, MURRELL T, et al. End-to-end variational networks for accelerated MRI reconstruction[J/OL]. (2020-04-15)[2023-03-01]. <https://arxiv.org/abs/2004.06688>.
- [27] AGGARWAL H K, MANI M P, JACOB M. MoDL: Model-based deep learning architecture for inverse problems[J]. *IEEE Transactions on Medical Imaging*, 2018, 38(2):394-405.
- [28] AGGARWAL H K, JACOB M. J-MoDL: Joint model-based deep learning for optimized sampling and reconstruction[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2020, 14(6):1151-1162.
- [29] KÜSTNER T, FUIN N, HAMMERNIK K, et al. CINENet: deep learning-based 3D cardiac CINE MRI reconstruction with multi-coil complex-valued 4D spatio-temporal convolutions[J]. *Scientific Reports*, 2020, 10(1):1-13.
- [30] SANDINO C M, LAI P, VASANAWALA S S, et al. Accelerating cardiac cine MRI using a deep learning-based ESPIRiT reconstruction[J]. *Magnetic Resonance in Medicine*, 2021, 85(1):152-167.
- [31] JOHNSON P M, RECHT M P, KNOLL F. Improving the speed of MRI with artificial intelligence[J]. *Seminars in Musculoskeletal Radiology*, 2020, 24(1):12-20.

作者简介:

程 航(1998-), 男, 硕士生. 研究领域: 磁共振图像重建.
蔡 昕(1989-), 男, 博士生. 研究领域: 磁共振图像重建.
姜小平(1981-), 男, 硕士, 工程师. 研究领域: 磁共振序列开发.
杨 光(1968-), 男, 博士, 副教授. 研究领域: 智能医学影像处理.
贾守强(1973-), 男, 博士, 主任医师. 研究领域: 神经影像学.
聂生东(1962-), 男, 博士, 教授. 研究领域: 智能医学影像处理.