

◁ 影像技术学 ▷

基于深度神经网络的高泛化性 MR 快速成像技术

余华君¹, 苗帧壮², 李瑞阳¹, 陈福军³, 初占飞², 郭红宇², 李英飒², 李怡², 梁晓云²

(1. 浙江医院放射科, 浙江 杭州 310013; 2. 东软医疗系统股份有限公司, 辽宁 沈阳 110167;

3. 辽宁省药品审评查验中心, 辽宁 沈阳 110003)

[摘要] **目的:** 提出一种基于深度神经网络(DNN)重建欠采样 MR 图像的技术并验证其临床价值。**方法:** DNN 模型的主体由残差卷积网络和保真网络两个模块构成, 能够适应不同尺寸和不同分辨率的输入图像且有效学习图像中的噪声分布。收集符合 MR 扫描适应症的志愿者共 150 例, K 空间满采图像和加速欠采样图像为一组随机扫描同一被试的头部、颈椎、腹部、盆腔和膝关节共 5 个部位的多组常规序列, 共计 2 437 组影像; 其中, 满采图像作为标签数据, 无需额外标注。**结果:** 将同部位不同序列及不同部位不同序列数据分别作为 DNN 模型的输入训练得到模型 1(当前序列除外的图像作为 DNN 模型输入)、模型 2(输入当前序列图像)、模型 3(当前部位图像除外)和模型 4(输入当前部位图像)的重建效果均很好(SSIM ≥ 0.93 , PSNR ≥ 37.22)。DNN 模型重建图像的采集时间平均减少 16.2%, 但 CNR 平均提升 8.5%, SNR 提升 7.7%以上。此外, DNN 重建图像具有同等甚至高于满采图像的质量。**结论:** DNN 模型可重建高质量 MR 图像且具备高泛化性, 帮助临床实现加速扫描。

[关键词] 神经网络; 磁共振成像**[中图分类号]** R338; R445.2**[文献标识码]** A**[文章编号]** 1008-1062(2024)01-0056-05

DOI:10.12117/jccmi.2024.01.012

A fast MR imaging technique with decent generalization performance based on deep neural networksYU Hua-jun¹, MIAO Zhen-zhuang², LI Rui-yang¹, CHEN Fu-jun³, CHU Zhan-fei²,GUO Hong-yu², LI Ying-sa², LI Yi², LIANG Xiao-yun²

(1. Department of Radiology, Zhejiang Hospital, Hangzhou 310013, China; 2. Neusoft Medical Systems Co., Ltd.,

Shenyang 110167, China; 3. Liaoning Center for Drug Evaluation and Inspection, Shenyang 110003, China)

Abstract: Objective: To propose a technique for reconstructing undersampled MR images based on deep neural network (DNN) and validate its clinical value. **Methods:** The main body of the DNN model consisted of two modules: residual convolutional network and fidelity network, which could adapt to input images of different sizes and resolutions and effectively learn the noise distribution in the images. A total of 150 volunteers who met the indications for MR scanning were included in this study. K-space full sampling images and accelerated undersampling images were a set of randomly scanned multiple routine sequences of the same subject's head, cervical spine, abdomen, pelvic cavity, and knee joint, totaling 2 437 sets of images. Among them, the fully captured images were used as labels without the need for additional annotation. **Results:** To evaluate the generalization of the DNN-based algorithm, four models were built and trained by changing the input images. The inputs of Model 1 employed all sequences(brain only) other than the current sequence as the output image, while the input of Model 2 was the opposite. The input of Model 3 employed all sequences of various parts(cervical spine, abdomen, pelvic cavity, and knee) other than the current part as the output image, while the inputs of Model 4 were the opposite. The reconstructed results of four models were all very good (SSIM ≥ 0.93 , PSNR ≥ 37.22). The average acquisition time was reduced by 16.2%, while the average contrast to noise ratio (CNR) was improved by 8.5%, and the signal to noise ratio (SNR) was improved by more than 7.7%. In addition, the DNN reconstructed images have the same or even higher quality than fully-sampled images. **Conclusion:** The DNN model can reconstruct high-quality MR images with excellent generalization, which can facilitate fast MR scanning in clinical practice.

Key words: Nerve Net; Magnetic Resonance Imaging

随着磁共振快速成像技术的不断发展, 半傅里叶技术^[1]、并行成像技术^[2]和压缩感知^[3]等技术已大幅提高了磁共振图像采集的效率。K 空间欠采样是

进一步提升 MR 图像采集速度的有效方案, 然而 K 空间欠采样会导致图像中出现混叠伪影, 丢失组织结构信息同时导致图像信噪比 (Signal to noise ra-

[收稿日期] 2023-07-26; **[修回日期]** 2023-08-08**[作者简介]** 余华君(1984-), 男, 浙江淳安人, 主治医师。E-mail: yuhuaunde@163.com**[通信作者]** 李怡, 东软医疗系统股份有限公司, 110167。E-mail: YiiLi9@163.com**[基金项目]** 国家重点研发计划“智能机器人”重点专项(2022YFB4702702)。

tio,SNR)降低^[4]。本研究提出一种基于深度神经网络(Deep neural networks,DNN)模型重建欠采样 MR 图像的技术,在实现快速成像的同时对于不同对比度图像具有良好的泛化性。

1 资料与方法

1.1 DNN 模型设计

DNN 模型的整体架构如图 1 所示,MR 硬件系统采集的多通道欠采样数据经传统多通道合并成像技术处理后作为模型的原始输入图像,模型主体由残差卷积网络(图 2)和保真网络(图 3)两个模块构成。残差卷积网络选择 Unet 结构^[5],用全卷积层替代全连接层,从而适应不同尺寸和不同分辨率的输入图像^[6];输出阶段采取残差相加的方式让网络专注

于学习噪声分布,降低网络和图像对比度的相关性,提高网络的收敛速度^[7]。残差卷积网络的输出和原始图像共同输入保真网络可充分利用原始图像信息,避免微小的扰动给深层网络带来巨大的波动^[8]。

1.2 数据采集

收集符合 MR 扫描适应症的志愿者共 150 例,年龄 20~65 岁。所有志愿者于 1.5T MR(NeuMR Rena 东软医疗系统股份有限公司,中国)随机选取 5 个目标部位包括头部、颈椎、腹部、盆腔和膝关节的不同序列和不同层面完成扫描。每个部位扫描序列详情见表 1,对应扫描参数见表 2。每个扫描序列采集一组图像包括 K 空间满采图像和随机加速欠采样图像。最终采集头部数据 768 组,共 45 224 层;颈椎数据 303 组,共 7 600 层;腹部数据 494 组,共




图 1 DNN 模型整体架构图。图 2 残差卷积神经网络示意。Conv 表示卷积层,pool 表示池化层,relu 表示非线性激活函数(Rectified Linear Unit),upsampling 表示上采样,add 表示相加。

Figure 1. The overall architecture of the DNN model. Figure 2. The illustration of the residual Un et, where Conv/pool/upsampling in legend refers to convolutional/pool/upsampling layer, and relu is the abbreviation of Rectified Linear Unit.

表 1 扫描部位及对应序列

部位	扫描序列
头部	T ₁ IR-TSE Tra,T ₂ TSE Sag,T ₂ TSE Tra,T ₂ FLAIR Tra,DWI
颈椎	T ₂ TSE Sag,T ₂ STIR Sag,T ₁ TSE Sag,T ₂ TSE Tra Stacks
腹部	B-FFE2D BH Cor,DFFE BH Tra,T ₂ TSE Gated Tra,T ₂ TSE FS Gated Tra,THRIVE BH Tra
盆腔	T ₂ TSE ROKAR FS Sag,T ₂ TSE Tra,T ₂ STIR Tra,T ₁ TSE Tra,T ₂ STIR Cor
膝关节	T ₁ TSE Sag,T ₂ TSE Sag,PD STIR Sag,T ₂ TSE Tra,T ₂ STIR Cor

表 2 各扫描部位对应扫描参数

部位	视场角(mm ²)	层厚(mm)	矩阵	采集线圈
头部	(200~240)×(200~240)	6	≥256×192	AIM 神经血管线圈
颈椎	(180~260)×(180~260)	3	≥320×224(矢状面) ≥256×224(轴面)	AIM 脊柱线圈+AIM 躯干线圈
腹部	(300~400)×(300~400)	7	≥256×224	AIM 脊柱线圈+AIM 躯干线圈+AIM 通用柔性线圈中号
盆腔	(200~400)×(200~400)	5	≥256×224	AIM 脊柱线圈+AIM 通用柔性线圈中号
膝关节	(160~200)×(160~200)	4	≥256×224	专用膝关节线圈




图 3 保真网络。Figure 3. Details of the fidelity neural network.

16 972 层;盆腔数据 397 组,共 8 580 层,膝关节数据 475 组,共 9 956 层。所有患者在检查前均签署知情同意书。

1.3 DNN 模型训练和评估指标

将 K 空间满采数据进行不同比例的欠采样并重建生成欠采重建图像(加速比为 1.5~3 倍),欠采样图像和对应的满采图像被视为一组训练数据,其中满采图像作为模型训练的标签数据,无需额外手

动标注。DNN 模型输入为二维图像,所有数据按照 8:2 随机划分训练集(52 556 层)和测试集(15 976 层),初始学习率为 0.000 1。

模型评估采用峰值信噪比 (Peak signal to noise ratio,PSNR)和结构相似性 (Structural similarity index measure,SSIM)两种指标完成。PSNR 是使

$$L(\hat{x}, x) = \lambda * \|x - \hat{x}\|_1 - \text{ssim}(x, \hat{x}) \quad \text{SSIM}(X, Y) = \ell(X, Y) \cdot h(X, Y) \cdot s(X, Y)$$

$$\ell(X, Y) = \frac{2\mu_X\mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1} \quad h(X, Y) = \frac{2\sigma_X\sigma_Y + C_2}{\sigma_X^2 + \sigma_Y^2 + C_2} \quad s(X, Y) = \frac{\sigma_{XY} + C_3}{\sigma_X\sigma_Y + C_3}$$

1.4 模型泛化性验证

不同磁共振加权图像的图像特征和图像 SNR 不同。为了使得神经网络性能可以兼容不同对比度图像,我们根据头部临床常用平扫序列设计泛化性实验,以验证神经网络的泛化性能。

基于头部的 4 种扫描序列包括 T₁ IR-TSE Tra、T₂ FLAIR Tra、T₂ TSE Sag 和 T₂ TSE Tra 数据设计实验 1:改变 DNN 模型的输入数据分别训练模型 1 (排除当前序列后使用其他三种序列数据训练得到)和模型 2(只用当前序列数据训练得到),比较模型 1 和 2 重建得到的图像质量验证 DNN 模型针对不同序列数据的泛化性。

基于颈椎、腹部、盆腔和膝关节共 4 个部位的数据设计实验 2:改变 DNN 模型的输入数据分别训练模型 3 (排除当前部位后使用其他三个部位数据训练得到)和模型 4(只用当前部位数据训练得到),比较模型 3 和 4 重建得到的图像质量验证 DNN 模型针对不同扫描部位数据的泛化性。

1.5 图像质量客观评价

从测试集中取出 30 例患者,分别手动勾画 5 个部位对应的满采图像、加速欠采样图像和加速后经 DNN 模型重建的图像上两处大小为 4×4 的感兴趣区域(Region of interest,ROI)。头部序列勾画灰质和白质区域,颈椎序列勾画脊髓和脑脊液(或椎间盘)区域,腹部序列勾画肝实质和肝血管区域,盆腔序列勾画前列腺(或子宫肌层)和膀胱(或结合带)区域,膝关节序列勾画骨质和肌肉区域。分别基于上述两处 ROI 计算图像的 SNR 和对比度噪声比(Contrast to noise ratio,CNR),计算公式如下^[12]:

$$\text{SNR}=\text{avg}(\text{ROI})/\text{std}(\text{ROI}_{\text{background}})$$

$$\text{CNR}=(\text{avg}(\text{ROI}_1)-\text{avg}(\text{ROI}_2))/\text{std}(\text{ROI}_{\text{background}})$$

1.6 图像质量主观评价

从测试集中取出 11 例患者头部检查常用的 4 种序列(T₁ IR-TSE Tra、T₂ FLAIR Tra、T₂ TSE Sag 和 T₂ TSE Tra),每个序列采集对应的满采图像(平

用最广泛的客观评价图像质量的量化指标,PSNR 值越大表示图像失真越少^[9-10];SSIM 是常用的衡量两幅图像相似度的量化指标,可从亮度、对比度和结构三方面评价图像的相似性,其取值范围是[0,1],SSIM 值越大表示图像失真越少^[11]。模型训练的损失函数为:

均次数(Average,AV)=2)、加速欠采样(AV=1 且敏感度编码成像(Sensitivity encoding,SENSE)=1.5 倍)图像和 DNN 模型重建图像(AV=1,SENSE=1.5 且 AI 后处理)。所有图像经匿名化处理后随机分配给 4 位影像科医生(年资均为 5 年以上),根据李克特量表完成评分,最终得分值是所有医生打分的均值。

评价标准:图像质量优秀(可用于诊断),计 5 分;图像质量良好(可用于诊断),计 4 分;图像质量可接受(可用于诊断但有轻微问题),计 3 分;图像质量差(不可用于诊断),计 2 分;图像质量非常差(不可用于诊断),计 1 分^[13]。

2 结果

2.1 模型泛化性

4 种头部常规扫描序列分别有 1 000 层图像,按照 8:2 划分训练集和测试集。通过更换 DNN 模型输入的方式针对每种序列分别训练 2 个模型。模型 1 的输入采用其他序列各 800 层图像;模型 2 的输入采用当前序列的 800 层图像。实验结果见表 3,重建后的图像质量均优于原始欠采样图像,且模型 1 和 2 的表现相近。

表 3 DNN 模型泛化性评估(SSIM/PSNR):扫描序列

	模型输入的 欠采样图像	模型 1 重建图像	模型 2 重建图像
T ₁ IR-TSE Tra	0.83/36.27	0.97/42.76	0.97/43.08
T ₂ FLAIR Tra	0.81/35.75	0.97/42.33	0.97/42.75
T ₂ TSE Sag	0.89/38.09	0.97/41.02	0.98/41.10
T ₂ TSE Tra	0.82/35.56	0.97/40.19	0.97/40.59

注:SSIM 计算以满采图像为参考,模型 1 指排除当前序列后使用其他三种序列数据训练得到的模型,模型 2 指只用当前序列数据训练得到的模型。

4 个扫描部位的序列分别包括 1 000 层图像,按照 8:2 划分训练集和测试集。通过更换 DNN 模型输入的方式针对每种序列分别训练 2 个模型。模型 3

的输入采用其他部位各 800 层图像；模型 4 的输入采用当前部位的 800 层图像。实验结果见表 4,重建后的图像质量均优于原始欠采样图像,且模型 3 和 4 的表现相近。

2.2 图像质量客观评价

满采且经 DNN 模型重建的图像具有和满采图像相同的采样时间,但 CNR 平均提升 21.4%,SNR 提升 18.1%和 18.6%;和满采图像相比,加速后经 DNN 模型重建的图像采集时间平均减少 16.2%,但 CNR 平均提升 8.5%,SNR 提升 7.7%和 9.4%。

2.3 临床评价图像质量

图 4 展示了 4 种序列对应的满采图像(AV=2)、加速欠采样(AV=1 且 SENSE=1.5)图像和 DNN 模型重建图像(AV=1,SENSE=1.5 且经 DNN 模型重建)。DNN 模型重建技术可在加速欠采样扫描的情况下,提供接近甚至优于满采图像的质量(李克特评分结果为:T₁ IR-TSE Tra,4.20 vs 4.18;T₂ TSE Sag,4.30 vs 4.18;T₂ TSE Tra,4.39 vs 3.89;T₂ FLAIR

Tra,3.84 vs 3.80)(图 5)。

3 讨论

传统并行成像技术和压缩感知技术在高加速倍数下均会遇到图像残余伪影或图像信噪比过低等问题。本研究提出了一种基于多对比度图像训练的 DNN 模型,可通过提高图像 SNR 的方式提高欠采样 MR 重建图像质量,并经过定量指标和临床质量评价证明具有良好的泛化性。模型由残差卷积神经网络和保真网络两大模块构成,可以适应不同尺寸且不同分辨率的输入图像,准确学习噪声分布的同时最大限度恢复图像细节。经 DNN 模型重建的加速欠采样图像的采集时间平均减少 16.2%,但 CNR 平均提升 8.5%,SNR 提升 7.7%和 9.4%。由 4 名高年资影像医师盲测的李克特量表评分结果也证明了 DNN 模型重建图像优于满采图像。此外,模型表现出很好的泛化性,当输出图像部位/序列不同的图像作为输入图像训练得到的模型依旧展现出很好的重




图 4 头部常规序列对应的满采图像(AV=2)、加速欠采样(AV=1 且 SENSE=1.5)图像和 DNN 模型重建图像(AV=1,SENSE=1.5)。图 4a:T₁ IR-TSE Tra,图 4b:T₂ TSE Tra,图 4c:T₂ TSE-Sag,图 4d:T₂ FLAIR Tra。

Figure 4. Fully sampled image (AV=2), under-sampled image reconstructed by iterative method (AV=1 and SENSE=1.5), DNN model reestablish imaging (AV=1, SENSE=1.5) of brain conventional sequence of MRI. Figure 4a:T₁ IR-TSE Tra, Figure 4b:T₂ TSE Tra, Figure 4c:T₂ TSE Sag, Figure 4d:T₂ FLAIR Tra.

表 4 DNN 模型泛化性评估(SSIM/PSNR):扫描部位

	模型输入的 欠采样图像	模型 3 重建图像	模型 4 重建图像
颈椎	0.88/34.50	0.93/37.25	0.94/37.22
腹部	0.89/37.35	0.94/37.66	0.94/37.75
盆腔	0.85/35.67	0.95/37.50	0.96/37.54
膝关节	0.91/37.97	0.94/39.59	0.95/40.34

注:SSIM 计算以满采图像为参考,模型 3 指排除当前部位后使用其他三个部位数据训练得到的模型,模型 4 指只用当前部位数据训练得到的模型。

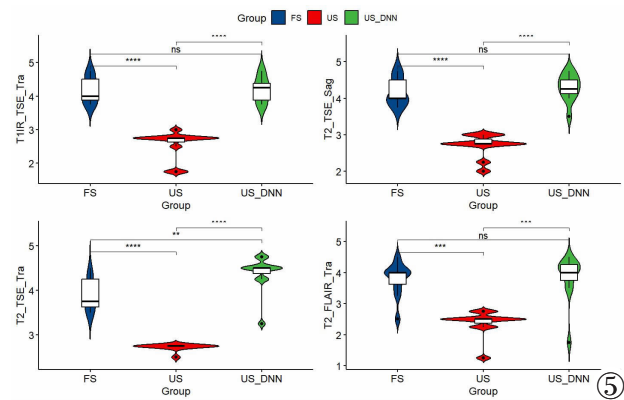


图 5 4 位临床医生根据李克特量表评分 4 种头部常规序列(T₁ IR-TSE Tra,T₂ TSE-Sag,T₂ TSE Tra 和 T₂ FLAIR Tra)的 K 空间满采图像(AV=2)、加速欠采样图像(AV=1,SENSE=1.5)和 DNN 模型重建图像(AV=1,SENSE=1.5)的结果对比。

Figure 5. The Likert scores provided by four neuroradiologists were compared for four conventional head sequences(T₁ IR-TSE Tra, T₂ TSE-Sag, T₂ TSE Tra, and T₂ FLAIR Tra), based on K-space full sampling images(AV=2), accelerated under-sampled images (AV=1, SENSE=1.5), and DNN model reconstruction images (AV=1, SENSE=1.5).

建效果,SSIM 在 0.93 以上,PSNR 在 37.22 以上。

在本研究中,残差卷积神经网络选择 Unet 结构为基础,其编码-解码结构可从多尺度、多分辨率的维度提取噪声特征,从而使 DNN 模型可很好地应对不同尺寸不同分辨率的输入图像,表现出良好的泛化能力^[5]。输出阶段采取残差相加的方式可以让网络专注于学习噪声,降低网络和图像对比度的相关性,提高网络的收敛速度^[7]。此外,网络中不含全连接层,而是全由卷积层组成,可适应任意尺寸输入^[6]。网络之间共享网络权重大大降低了对训练数据的需求,降低了过度拟合的风险,显著减少了重建算法对训练图像分布的依赖和计算时对显存容量的占用。

特别地,本研究增加了与残差卷积网络相连接的保真网络,保证了真实图像可以更多参与到网络的参数学习中,增加输出图像与真实采集图像的相关性,避免微小的扰动给深层网络带来巨大的波动^[8]。为了避免梯度消失以及网络深度过大时参数学习能力的下降,在每个网络的输出阶段都设置损失函数对该阶段的网络参数训练进行约束。

众所周知,MR 图像具有高分辨率和多对比度等优点,可准确反映人体内部组织情况,在疾病的临床诊断中具有不可替代的作用。然而,扫描时间长一直是 MR 成像技术的痛点^[14]。本文提出的 DNN 模型可完美重建采集倍数为 1.5~3 倍之间、不同序列(T_1 IR-TSE Tra, T_2 TSE Sag, T_2 TSE Tra 和 T_2 FLAIR 等)和不同采集部位(头部、颈椎、腹部、盆腔和膝关节)的欠采样 MR 图像。研究结果表明,本文提出的基于数据驱动的神经网络模型为快速磁共振扫描提供了一种可行的方法,在保证图像质量的同时具备较高的泛化性。

最后,本研究也存在一些局限性,包括:随机使用加速采集倍数在 1.5~3 倍之间的 MR 影像,其中,加速比的上限设定较低,且没有对比计算不同加速采集倍数下 DNN 模型重建图像的质量。此外,参与数据收集的志愿者均无基础疾病,缺乏针对患者数据的实验结果。

[参考文献]

[1]Xiao L, Liu Y, Yi Z, et al. Partial Fourier reconstruction of

- complex MR images using complex-valued convolutional neural networks[J]. *Magn Reson Med*, 2022, 87(2): 999-1014.
- [2]Hamilton J, Franson D, Seiberlich N. Recent advances in parallel imaging for MRI[J]. *Prog Nucl Magn Reson Spectrosc*, 2017, 101(2): 71-95.
- [3]Gumeler E, Parlak S, Yazici G, et al. Single shot echo planar imaging(ssEPI) vs single shot turbo spin echo(ssTSE) DWI of the orbit in patients with ocular melanoma [J]. *Br J Radiol*, 2021, 94(1118): 20200825.
- [4]Eo T, Jun Y, Kim T, et al. KIKI-net: cross-domain convolutional neural networks for reconstructing undersampled magnetic resonance images[J]. *Magn Reson Med*, 2018, 80(5): 2188-2201.
- [5]Han Y, Ye JC. Framing U-Net via Deep Convolutional Framelets: Application to Sparse-View CT [J]. *IEEE Trans Med Imaging*, 2018, 37(6): 1418-1429.
- [6]Shelhamer E, Long J, Darrell T. Fully Convolutional Networks for Semantic Segmentation [J]. *IEEE Trans Pattern Anal Mach Intell*, 2017, 39(4): 640-651.
- [7]Zhang K, Zuo W, Chen Y, et al. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising [J]. *IEEE Trans Image Process*, 2017, 26(7): 3142-3155.
- [8]Aggarwal HK, Mani MP, Jacob M. MoDL: Model Based Deep Learning Architecture for Inverse Problems [J]. *IEEE Trans Med Imaging*, 2019, 38(2): 394-405.
- [9]Zhou L, Liu H, Zou YX, et al. Clinical validation of an AI-based motion correction reconstruction algorithm in cerebral CT[J]. *Eur Radiol*, 2022, 32(12): 8550-8559.
- [10]Vadrevu S, Manikandan MS. Use of zero-frequency resonator for automatically detecting systolic peaks of photoplethysmogram signal[J]. *Health Technol Lett*, 2019, 6(3): 53-58.
- [11]You SH, Cho Y, Kim B, et al. Synthetic Time of Flight Magnetic Resonance Angiography Generation Model Based on Cycle-Consistent Generative Adversarial Network Using PETRA-MRA in the Patients With Treated Intracranial Aneurysm [J]. *J Magn Reson Imaging*, 2022, 56(5): 1513-1528.
- [12]Pirastru A, Chen Y, Pelizzari L, et al. Quantitative MRI using Strategically Acquired Gradient Echo (STAGE): optimization for 1.5 T scanners and T1 relaxation map validation[J]. *Eur Radiol*, 2021, 31(7): 4504-4513.
- [13]Tanenbaum LN, Tsiouris AJ, Johnson AN, et al. Synthetic MRI for Clinical Neuroimaging: Results of the Magnetic Resonance Image Compilation (MAGiC) Prospective, Multicenter, Multireader Trial[J]. *Am J Neuroradiol*, 2017, 38(6): 1103-1110.
- [14]Munoz C, Fotaki A, Botnar RM, et al. Latest Advances in Image Acceleration: All Dimensions are Fair Game[J]. *J Magn Reson Imaging*, 2023, 57(2): 387-402.