

基于多尺度特征融合预处理与深度稀疏网络的并行磁共振成像重建

薛磊, 段继忠

(昆明理工大学信息工程与自动化学院, 昆明 650504)

摘要: 磁共振成像 (Magnetic resonance imaging, MRI) 在医学诊断中具有关键作用, 但过长的扫描时间可能会导致患者不适或产生运动伪影。并行成像技术和压缩感知理论表明, 可通过对 k 空间数据进行欠采样从而提高扫描速度, 其中并行 MRI 是一种通过利用多个接收线圈同时采集多个数据通道来加速成像过程的技术。深度学习凭借其强大的特征提取和模式识别能力, 在欠采样 MRI 重建中展现出巨大的潜力。为克服现有技术的局限性 (如需要自动校准信号、重建不稳定等), 提出了一种创新的重建方法, 旨在从欠采样的 k 空间数据中高效、准确地重建高质量的并行磁共振图像。该方法的核心骨架为深度稀疏网络, 该网络通过将求解稀疏模型的迭代收缩阈值算法的迭代过程展开, 转化为深度神经网络框架内的一系列可训练层。另外, 还引入基于多尺度特征融合的自适应预处理模块, 通过融合普通卷积与异型卷积核, 进一步提升网络的稀疏表示能力。实验结果表明, 相较于其他先进方法, 本文提出的方法在多个数据集上均表现出更优的重建性能, 包括更高的峰值信噪比和结构相似性指数, 以及更低的高频误差范数。

关键词: 并行磁共振成像重建; 深度学习; 卷积神经网络; 深度稀疏网络; 多尺度特征融合

中图分类号: TP391

文献标志码: A

Parallel Magnetic Resonance Imaging Reconstruction Based on Multi-scale Feature Fusion Preprocessing and Deep Sparse Networks

XUE Lei, DUAN Jizhong

(Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650504, China)

Abstract: Magnetic resonance imaging (MRI) plays a crucial role in medical diagnosis, but prolonged scanning times can cause patients discomfort and motion artifacts. Parallel imaging techniques and compressed sensing theory indicate that undersampling k-space data can enhance the scanning speed, where parallel MRI accelerates the imaging process by utilizing multiple receiving coils to simultaneously acquire data from multiple channels. Leveraging its powerful feature extraction and pattern recognition capabilities, deep learning demonstrates great potential in undersampled MRI reconstruction. To overcome the limitations of existing technologies (e.g., the need for automatic calibration signals, reconstruction instability), this paper proposes an innovative reconstruction method aimed at efficiently and accurately

基金项目: 云南省基础研究计划项目 (202301AT070452)。

收稿日期: 2024-09-04; 修订日期: 2024-11-16

reconstructing high-quality parallel MRI images from undersampled k-space data. The core framework of this method is a deep sparse network that unfolds the iterative process of the iterative shrinkage-thresholding algorithm (ISTA) for solving sparse models into a series of trainable layers within a deep neural network framework. Additionally, this paper introduces an adaptive preprocessing module based on multi-scale feature fusion, which further enhances the sparse representation capability of the network by integrating standard convolutions with heterogeneous convolutional kernels. Experimental results demonstrate that, compared to other advanced methods, the proposed method exhibits superior reconstruction performance across multiple datasets, including higher peak signal-to-noise ratio (PSNR) and structural similarity (SSIM), as well as lower high-frequency error norms.

Key words: parallel magnetic resonance imaging reconstruction; deep learning; convolutional neural network (CNN); deep sparse network; multi-scale feature fusion

引言

磁共振成像(Magnetic resonance imaging, MRI)作为一种先进的医学成像技术,自问世以来便因其非侵入性、无电离辐射以及对软组织的高分辨率成像能力,在临床诊断中占据了举足轻重的地位。它广泛应用于全身各部位的检查,为医生提供了丰富的解剖学、生理学及病理学信息,极大地提高了医学诊断的准确性和精确度。然而,尽管MRI技术具有诸多优势,但其较长的扫描时间始终是一个亟待解决的问题。这一难题不仅限制了MRI技术在临床实践中的更广泛应用,尤其是在紧急成像场景中,还降低了患者的舒适度,甚至可能导致运动伪影,进而影响诊断效果。为了克服这一难题,科研人员不断探索新的技术手段,旨在在不影响成像质量的前提下,显著提升MRI扫描速度,其中,压缩感知(Compressed sensing, CS)^[1-3]和并行成像技术^[4-9]已成为加速MRI扫描的两大主流方向。CS理论利用图像在特定变换域中的稀疏特性,成功实现了从欠采样k空间数据(该数据量少于奈奎斯特采样定理所要求的k空间数据量)中重建出高质量的MRI图像;另一方面,并行成像技术则通过利用多通道线圈阵列间灵敏度的差异,减少梯度编码的步数(即实现欠采样),从而显著缩短成像时间。

在并行MRI重建领域,传统的技术(如SENSE^[4-5])、自动校准方法(如GRAPPA^[6]和SPIRiT^[7])以及基于结构化低秩矩阵补全的无标定技术(如SAKE^[8]和P-LORAKS^[9]),虽然在一定程度上加速了重建过程,但仍面临诸多挑战。这些方法在确定最优重建参数时难度较大,重建过程耗时较长,且重建质量往往难以达到最优。此外,这些方法大多依赖于复杂的数学模型和额外的正则化项^[10-17],其性能受到多种因素的影响,如噪声水平、数据一致性等。为了应对这些挑战,近年来,深度学习方法凭借其强大的特征提取和学习能力^[18],被逐渐引入到并行MRI重建领域,并取得了显著的成效。一些研究尝试将传统模型与深度学习相结合,如将SENSE模型与深度学习网络结合,利用自动校准信号(Automatic calibration signal, ACS)估计的线圈灵敏度信息进行重建。Hammernik等^[19]提出的变分网络、Sriram等^[20]的E2EvarNet、Ramzi等^[21]的XPDNet、Aggarwal等^[22]的MoDL方法以及Lu等^[23]的pFISTA-SENSE-ResNet等,均展示了深度学习在提升重建性能方面的潜力。然而,这些方法仍依赖于额外的ACS来对灵敏度信息进行准确的估计,这极大地增加了图像重建前期的工作量,并且在复杂情况下存在灵敏度信息难以估计导致重建质量不稳定的问题。

另一些研究则直接利用深度学习网络从欠采样(通过采集少于传统奈奎斯特采样定理所要求的k空间数据量,以加速成像过程)的k空间数据中学习重建映射。这些研究,如Huang等^[24]的MICCAN、Wang等^[25]提出的残差复数卷积神经网络(Convolutional neural network, CNN)进行并行MRI重建的

Deepcomplex模型以及Feng等^[26]的DONet方法等。这些方法通过端到端的训练方式实现了对图像和线圈灵敏度的联合重建,显著提高了重建质量和速度,但在处理高度欠采样的数据时,仍面临重建质量不稳定的问题。

此外,受结构化低秩矩阵补全启发的深度学习方法,如Pramanik等^[27]的Deep-SLR和Wang等^[28]的ODLS等,通过训练基于CNN的滤波器组来加速重建过程,并实现了对图像稀疏性的有效捕捉。然而,这些方法在处理复杂图像结构时,无法充分提取和利用多尺度特征信息,导致重建结果中存在伪影或细节丢失。

为克服现有技术的局限性,本文创新性地提出了一种基于多尺度特征融合预处理与深度稀疏网络的并行磁共振成像重建方法,命名为DASC-Net。该方法的核心骨架为深度稀疏网络,该网络通过将求解稀疏模型的迭代收缩阈值算法(Iterative shrinkage-thresholding algorithm, ISTA)的迭代过程展开,转化为深度神经网络框架内的一系列可训练层。这一转化策略旨在有效地学习数据的稀疏表示,进而提升图像重建的性能。尤为重要的是,此方法无需依赖ACS来估计灵敏度信息,即可实现高质量图像的重建。为进一步提升深度稀疏网络的稀疏表示能力,本文引入基于多尺度特征融合的自适应预处理模块。通过融合普通卷积与具有横向和纵向的奇异卷积核,该模块能够捕捉长距离的横向和纵向联系,确保从多个视角和尺度全面捕捉图像细节,不仅减少了伪影的产生,还成功保留了图像中的关键细节信息,使得重建结果更加真实细腻。在一系列广泛采用的公开数据集上进行了详尽的实验验证,结果表明,相较于其他最先进的重建方法,本文提出的基于多尺度特征融合预处理与深度稀疏网络的DASC-Net方法在多个性能指标上均展现出了更为优异且稳定的重建能力,包括更高的峰值信噪比和结构相似性指数,以及更低的高频误差范数。

1 问题表述

并行磁共振成像模型可表述为

$$Y = PFSx \quad (1)$$

式中: $x \in \mathbb{C}^N$ 表示待重建的目标图像, $N = H \times W$ 为图像的像素总点数, W 和 H 分别代表图像的列数和行数; $Y = [Y_1^T, Y_2^T, \dots, Y_c^T, \dots, Y_C^T]^T \in \mathbb{C}^{MC}$ 表示欠采样多线圈 k 空间数据, $Y_c \in \mathbb{C}^M$ 表示第 c 个线圈的欠采样 k 空间数据, M 表示单个线圈的欠采样数据点数, C 为接收线圈的个数; $S = [S_1^T, S_2^T, \dots, S_c^T, \dots, S_C^T]^T \in \mathbb{C}^{NC \times N}$ 为灵敏度算子,对角矩阵 $S_c \in \mathbb{C}^{N \times N}$ 表示第 c 个线圈的灵敏度信息; $F = I_C \otimes f \in \mathbb{C}^{NC \times NC}$ 表示逐线圈二维傅里叶变换算子,“ $\otimes$ ”表示Kronecker乘积, I_C 为 $C \times C$ 的单位矩阵, $f = U_w \otimes U_H \in \mathbb{C}^{N \times N}$ 表示二维傅立叶变换算子, $U_H \in \mathbb{C}^{H \times H}$ 和 $U_w \in \mathbb{C}^{W \times W}$ 分别为 H 点和 W 点离散傅里叶变换矩阵; $P = I_C \otimes L \in \mathbb{C}^{MC \times NC}$ 表示多线圈 k 空间数据的欠采样算子, L 表示单个线圈 k 空间数据的欠采样矩阵。

根据压缩感知理论,磁共振图像在某个变换 Ψ 有稀疏表示,即大部分变换系数为零或接近于零。因此,可以采用最优化方法,通过求解具有 L_1 范数的最优化问题,来实现对图像 x 的重建,于是得到基于SENSE的重建模型的表述,即

$$x = \arg \min_x \frac{1}{2} \|PFSx - Y\|_2^2 + \lambda \|\Psi x\|_1 \quad (2)$$

但该模型需要显式利用线圈灵敏度信息,然而在实际中灵敏度信息难以准确地获取,于是可以直接对多线圈图像进行重建,重建模型为

$$X = \arg \min_X \frac{1}{2} \|PFx - Y\|_2^2 + \lambda \|\Psi X\|_1 \quad (3)$$

式中 $X \in \mathbb{C}^{NC}$ 为待重建的多线圈图像。

重建完成后,对重建得到的多线圈数据 X 通过平方和的平方根 (Square root of sum of squares, SOS) 运算合成幅值图像。

2 问题求解

优化问题式(3)可利用 ISTA 求解,通过不断地对目标函数进行梯度下降和软阈值操作,从而找到稀疏解。具体而言,通过迭代求解如下子问题,重建问题式(3)可以得以解决。

$$r^{(k)} = \Gamma^{(k)}(X^{(k-1)}) = X^{(k-1)} - \rho(PF)^H(PFX^{(k-1)} - Y) \quad (4)$$

$$X^{(k)} = \arg \min_X \frac{1}{2} \|X - r^{(k)}\|_2^2 + \rho\lambda \|\Psi X\|_1 \quad (5)$$

式中: ρ 为步长参数, λ 为正则化参数, $\Gamma(\cdot)$ 表示数据一致性操作, k 表示第 k 个重建阶段。

当稀疏变换 Ψ 为正交变换时,问题式(5)的解为

$$X^{(k)} = \Psi^H \text{soft}(\Psi r^{(k)}, \rho\lambda) \quad (6)$$

式中 $\text{soft}(\cdot)$ 表示软阈值运算,定义为

$$\text{soft}(x, \lambda_1) = \frac{x}{|x|} \max(|x| - \lambda_1, 0) \quad (7)$$

为了得到更好的稀疏表示从而提高重建质量,受 Zhang 等^[29]提出的 ISTA-Net+ 的启发,也采用基于 CNN 的非线性稀疏变换矩阵 Φ 和 $\tilde{\Phi}$ 分别代替传统设计的稀疏变换 Ψ 和 Ψ^H ,故式(6)可重新表述为

$$X^{(k)} = r^{(k)} + C(\tilde{\Phi}^{(k)} \text{soft}(\Phi^{(k)} C(r^{(k)}), \eta^{(k)} \lambda^{(k)})) \quad (8)$$

式中: η 为可学习的步长参数, λ 为可学习的正则化参数, $C(\cdot)$ 为 3×3 的卷积操作。

在此基础上,为了提高网络的重建性能,引入一个深度自适应稀疏预处理 (Deep adaptive preprocessing, DAP) 网络。假设输入为 X , DAP 可表示为

$$X_R = R(X) \quad (9)$$

该模块在保证收敛速度的前提下,可明显提高网络的重建性能。

综上所述,所提出的迭代优化过程可以表述为

$$\begin{cases} X_R^{(k-1)} = R^{(k)}(X^{(k-1)}) \\ r^{(k)} = \Gamma^{(k)}(X_R^{(k-1)}) = X_R^{(k-1)} - \eta^{(k)}(PF)^H(PFX_R^{(k-1)} - Y) \\ X^{(k)} = r^{(k)} + C(\tilde{\Phi}^{(k)} \text{soft}(\Phi^{(k)} C(r^{(k)}), \eta^{(k)} \lambda^{(k)})) \end{cases} \quad (10)$$

需要说明的是,在推导的过程中,使用了向量化的表示方法,因此,式(10)第2个公式的输入参数均应转化为向量形式,而其输出向量应转化为矩阵形式。根据式(10)所示的优化过程,得到整体展开深度稀疏网络的结构如图1所示,图中 $X^{(k-1)} \in \mathbb{C}^{C \times H \times W}$ 为第 k 个重建阶段的输入多线圈图像, $X^{(k)} \in \mathbb{C}^{C \times H \times W}$ 为第 k 个重建阶段的输出多线圈图像。以下为各个模块的详细介绍。

2.1 非线性稀疏正反变换子网络

Φ 和 $\tilde{\Phi}$ 网络模块用于执行稀疏正变换和稀疏反变换,以实现图像的压缩和重建。 $\tilde{\Phi}$ 网络模块和 Φ 网络模块如图1(d)所示,可分别表示为

$$\Phi(\cdot) = A_2(A_1(\cdot)) \quad (11)$$

$$\tilde{\Phi}(\cdot) = A_2(A_1(\cdot)) \quad (12)$$

式中: $A(\cdot) = \text{ReLU}(C(\cdot))$, $C(\cdot)$ 表示与 3×3 卷积核进行的卷积运算, ReLU 是模块在网络模型训练过程




图1 所提方法的网络结构图

Fig.1 Network structure diagram of the proposed method

中所使用的激活函数,作用是通过去除负值,增强模型的非线性表达能力和梯度传播,促进更快、更稳定的收敛^[30]。

2.2 自适应稀疏预处理网络

自适应稀疏预处理网络用于对输入数据进行个性化预处理,旨在从图像中提取和增强关键信息,融合多尺度特征,以降低重建过程中的噪声和失真,从而提高最终的重建图像质量。图1(c)展示了自适应稀疏预处理网络(即 $R(\cdot)$)的结构,可表示为

$$R(X) = X + C(J(C(X))) \quad (13)$$

式中操作 $J(\cdot)$ 包含4个相同的多尺度特征融合(Multi-scale feature fusion, MSFF)模块。 $J(\cdot)$ 和MSFF模块可分别表述为

$$J(X) = \text{MSFF}_4(\text{MSFF}_3(\text{MSFF}_2(\text{MSFF}_1(X)))) \quad (14)$$

$$\text{MSFF}(X) = X + C(\text{Concat}(A_{R,1}(X), A_{R,2}(X), A_{R,3}(X))) \quad i = 1, 2, 3, 4 \quad (15)$$

式中 $A_{R,1}(\cdot)$ 、 $A_{R,2}(\cdot)$ 和 $A_{R,3}(\cdot)$ 分别表示卷积核大小为 7×7 、 3×11 和 11×3 的卷积与ReLU激活函数的组合操作。MSFF模块的网络结构如图1(b)所示。

2.3 损失函数的设置

所提网络的损失函数由两部分组成。受深监督思想^[31]的启发,提出了深监督加权损失加权(Loss₁),该损失由每个重建阶段的重建图像与真实图像间差值的 L_1 范数的加权和组成;另一部分损失(Loss₂)由稀疏正反变换网络模块 Φ 、 $\tilde{\Phi}$ 之间的约束 $\Phi \cdot \tilde{\Phi} = I$ 组成,该约束确保学习到的稀疏变换是一个可逆变换。综上所述,整体网络损失函数为

$$\text{Loss} = \text{Loss}_1 + \text{Loss}_2 = \beta_1 \frac{1}{N_T N_P} \sum_{i=1}^{N_T} \sum_{k=1}^{N_P} k \|x_i^k - x_i^{\text{true}}\|_1 + \beta_2 \frac{1}{N_T N_P} \sum_{i=1}^{N_T} \sum_{k=1}^{N_P} \|\tilde{\Phi}^{(k)}(\Phi^{(k)}(Z_i)) - Z_i\|_2^2 \quad (16)$$

式中 N_T 为训练集的大小; N_P 为重建的阶段数; x_i^{true} 为第 i 个全采样幅度图像; x_i^k 为第 k 个重建阶段的第 i 个重建幅度图像; $\Phi^{(k)}$ 、 $\tilde{\Phi}^{(k)}$ 分别表示第 k 次迭代时的稀疏正、反变换网络; β_1 、 β_2 分别为第1、2项损失的权重,设置为 $\beta_1 = 0.1$, $\beta_2 = 0.01$ 。

3 实验及结果分析

3.1 实验数据

实验使用公开数据集 NYULH Radiology-Reconstruction-Data^[19]进行膝盖部位图像重建的训练和测试。该数据集由来自不同病理、性别、年龄和体重指数的病人在 3T Siemens Magnetom Skyra 磁共振扫描仪下进行的膝盖扫描数据组成。

数据集囊括了冠状面和矢状面两种质子密度加权序列,每个序列均采集了来自 20 位不同病人的图像。为了进行实验,随机选择了 14 位病人的数据作为训练集,3 位病人的数据作为验证集,另外 3 位病人的数据作为测试集。每位病人选取中间 20 个切片。为了减少噪声影响,从每位病人的数据中选取了中间部分切片,并将图像裁剪为 320×320 大小。每个切片的采集都使用了 15 个线圈。因此每种序列的训练集包含 280 张图片,验证集包含 60 张图片,测试集包含 60 张图片,并且所有数据均为真实复数 k 空间数据。

冠状面质子密度加权序列(CoronalPD)的参数为:TR=2 750 ms,TE=27 ms,TF=4,平面内分辨率为 $0.49 \times 0.44 \text{ mm}^2$,切片厚度为 3 mm,35~42 个切片,5 名女性,15 名男性,年龄为 15~76 岁,BMI 为 20.46~32.94。

矢状面质子密度加权序列(SagittalPD)的参数为:TR=2 800 ms,TE=27 ms,TF=4,平面内分辨率为 $0.46 \times 0.36 \text{ mm}^2$,切片厚度为 3 mm,31~38 个切片,11 名女性,9 名男性,年龄为 15~94 岁,BMI 为 18.69~35.15。

3.2 实验实施细节

为了评估不同算法的重建性能,实验采用 3 种不同的欠采样模式进行欠采样,分别为一维笛卡尔均匀欠采样(1DUU)、一维笛卡尔变密度欠采样(1DRU)和二维随机欠采样(2DRU)。对于一维欠采样模式,加速因子(Acceleration factor, AF)分别为 3 和 5,对应的欠采样率分别为 33.3% 和 20%。由于二维欠采样模式在两个方向上进行欠采样,和一维欠采样模式(只在一个方向进行欠采样)相比会更容易重构出高质量的图像,因此为了证明所提方法的优越性,加大了二维欠采样模式下图像重构的难度,AF 分别取 5 和 10,对应的欠采样率分别为 20% 和 10%。

实验中将 Batch size 设置为 1,重建阶段总数设置为 10。使用 Adam 优化器来优化模型,学习率设置为 0.000 1。除特别说明外,网络中所使用的卷积均为卷积核大小为 3×3 、步长为 1 的“same”卷积。训练过程中选择验证损失最小的模型作为测试的最佳模型。实验在配置为 Intel Core i9-12900K@3.2 GHz CPU,64 GB 内存,NVIDIA RTX 3090(24 GB 显存),64 位 Ubuntu 20.04 操作系统的服务器上完成,所有代码均使用 PyTorch 1.12 平台实现。

峰值信噪比(Peak signal-to-noise ratio, PSNR)^[32]和结构相似性指数(Structural similarity, SSIM)在评估 MRI 并行成像重构质量时具有互补性。PSNR 侧重于像素级误差的量化,而 SSIM 则关注于图像结构信息的保留。将这两个指标结合使用,可以全面而准确地评估重建图像的质量,确保重建图像既在像素级上具有较高的保真度,又在结构信息上得到有效保留。因此,为了评估重建质量,本文使用 PSNR 和 SSIM 作为评价指标,数值越高,则表示重建质量越好。此外,为更加全面地评估重建质量,还添加了高频误差范数(High-frequency error norm, HFEN)^[33]这一评价指标。该评价指标专注于衡量重建图像与原始图像在高频细节上的差异,能够准确反映重建图像边缘和纹理信息的保真度,HFEN 的数值越低,表示重建质量越好。

对于全采样参考图像 $\hat{x}$ 和重建图像 x ,PSNR 定义为

$$\text{PSNR} = 10 \lg \frac{\max^2}{\text{MSE}} \quad (17)$$

式中:MSE表示 x 与 $\hat{x}$ 之间的均方误差,max为 $\hat{x}$ 的最大像素值。

SSIM定义为

$$\text{SSIM} = \frac{(2u_x u_{\hat{x}} + c_1)(2\sigma_{x\hat{x}} + c_2)}{(u_x^2 + u_{\hat{x}}^2 + c_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + c_1)}$$

(18)

式中: u_x 与 $u_{\hat{x}}$ 分别表示 x 与 $\hat{x}$ 的均值; σ_x^2 与 $\sigma_{\hat{x}}^2$ 分别表示 x 与 $\hat{x}$ 的方差; $\sigma_{x\hat{x}}$ 表示 x 与 $\hat{x}$ 的协方差; c_1 和 c_2 为常数,其中 $c_1=0.01,c_2=0.03$ 。

HFEN定义为

$$\text{HFEN} = \frac{\|\text{filter}(\hat{x}) - \text{filter}(x)\|_2}{\|\text{filter}(x)\|_2}$$

(19)

式中 filter($\bullet$)表示一个拉普拉斯高斯滤波器,用于捕捉图像边缘。

3.3 实验结果

将提出的方法 DASC-Net 与传统重建算法 L1SPIRiT^[12] 以及 6 种深度学习方法 (MICCAN^[24], ISTA-Net+^[29], Deep-SLR^[27], Deepcomplex^[25], DONet^[26], CGPD-CSNet^[34]) 进行了比较。实验中使用了两个不同序列的膝盖数据集,并在不同的采样模式和加速因子下评估了这些方法的平均 PSNR、SSIM 以及 HFEN。实验结果总结在表 1 和表 2 中,其中粗体标注表示每种对比方法在各个采样模式和加速因子下的最优 PSNR、SSIM 以及 HFEN 值。

表 1 不同欠采样模式下 CoronalPD 比较方法的定量比较

Table 1 Quantitative comparison of comparison methods on CoronalPD under different undersampling modes									
欠采样 模式	评价指数	方法							
		L1SPIRiT	MICCAN	ISTA-Net+	Deep-SLR	Deepcomplex	DONet	CGPD-CSNet	DASC-Net
3× 1DRU	PSNR/dB	34.14	34.51	35.56	32.99	35.59	35.80	36.09	37.24
	SSIM	0.894	0.908	0.918	0.873	0.910	0.913	0.928	0.937
	HFEN	0.037 3	0.032 7	0.025 3	0.420 0	0.031 1	0.0300	0.0238	0.017 5
5× 1DRU	PSNR/dB	31.07	32.33	33.52	31.48	33.04	33.60	33.89	35.25
	SSIM	0.826	0.861	0.881	0.826	0.856	0.864	0.889	0.909
	HFEN	0.055 4	0.040 6	0.030 5	0.046 1	0.039 7	0.0370	0.029 2	0.021 5
3× 1DUU	PSNR/dB	31.68	31.70	33.12	30.49	32.71	33.31	33.95	35.25
	SSIM	0.849	0.864	0.886	0.841	0.866	0.878	0.901	0.915
	HFEN	0.055 9	0.052 1	0.041 7	0.062 4	0.049 4	0.0446	0.037 3	0.028 5
5× 1DUU	PSNR/dB	27.91	29.97	30.35	28.32	29.61	30.69	30.69	32.81
	SSIM	0.745	0.814	0.826	0.762	0.792	0.814	0.839	0.875
	HFEN	0.090 4	0.061 6	0.059 3	0.789 0	0.071 5	0.0593	0.056 9	0.038 6
5× 2DRU	PSNR/dB	36.18	36.67	37.48	35.49	37.25	37.50	38.14	38.71
	SSIM	0.910	0.922	0.933	0.904	0.916	0.913	0.944	0.946
	HFEN	0.021 6	0.019 8	0.013 7	0.023 3	0.022 7	0.0227	0.009 7	0.006 4
10× 2DRU	PSNR/dB	29.20	34.43	35.19	33.16	34.87	35.00	35.52	36.20
	SSIM	0.805	0.890	0.904	0.857	0.867	0.869	0.910	0.915
	HFEN	0.071 2	0.024 4	0.016 9	0.033 1	0.029 6	0.0297	0.016 3	0.011 8

表2 不同欠采样模式下SagittalPD比较方法的定量比较

Table 2 Quantitative comparison of comparison methods on SagittalPD under different undersampling modes

欠采样 模式	评价指标	方法							
		L1SPIRiT	MICCAN	ISTA-Net+	Deep-SLR	Deepcomplex	DONet	CGPD-CSNet	DASC-Net
3× 1DRU	PSNR/dB	34.84	34.51	36.98	35.78	36.89	37.31	37.87	38.81
	SSIM	0.899	0.900	0.930	0.909	0.920	0.922	0.941	0.949
	HFEN	0.035 2	0.035 4	0.022 5	0.028 7	0.025 9	0.0242	0.019 7	0.013 9
5× 1DRU	PSNR/dB	31.69	32.50	34.82	33.44	34.34	34.93	35.49	36.26
	SSIM	0.828	0.854	0.895	0.856	0.867	0.873	0.907	0.918
	HFEN	0.051 1	0.043 1	0.028 5	0.038 8	0.035 5	0.0326	0.026 8	0.020 6
3× 1DUU	PSNR/dB	33.06	33.71	35.02	34.24	35.22	35.74	36.10	37.49
	SSIM	0.870	0.889	0.908	0.886	0.900	0.902	0.924	0.937
	HFEN	0.048 6	0.420 0	0.034 4	0.406 0	0.035 5	0.0331	0.030 1	0.021 6
5× 1DUU	PSNR/dB	28.68	29.56	31.00	30.15	30.77	31.71	32.01	33.25
	SSIM	0.747	0.780	0.819	0.782	0.794	0.811	0.847	0.873
	HFEN	0.082 9	0.070 2	0.058 2	0.069 4	0.064 1	0.0547	0.052 1	0.041 2
5× 2DRU	PSNR/dB	37.19	37.87	38.91	37.69	38.43	38.43	39.40	39.96
	SSIM	0.921	0.937	0.945	0.945	0.926	0.926	0.952	0.956
	HFEN	0.017 2	0.013 5	0.009 5	0.017 7	0.018 6	0.0189	0.010 6	0.006 1
10× 2DRU	PSNR/dB	29.91	35.15	36.54	35.30	36.02	36.20	36.75	37.46
	SSIM	0.817	0.899	0.917	0.883	0.863	0.881	0.922	0.931
	HFEN	0.062 7	0.025 7	0.017 4	0.024 4	0.025 1	0.0247	0.017 1	0.011 9

结果显示,在所有采样模式和AF下,DASC-Net相比其他方法均取得了明显的PSNR和SSIM提升,以及更低的HFEN,尤其是在一维采样模式(如1DRU和1DUU)下,其提升效果更加显著。可以观察到,在CoronalPD的1DUU采样模式下AF=5时,相较于其他方法,提出的DASC-Net的平均PSNR分别提升了4.90、2.84、2.46、4.49、3.20、2.12和2.12 dB,并且SSIM相较于其他方法也均有较大的提升。

为了比较各算法重建结果的视觉效果,选择两个序列中具有代表性的切片,图2~7分别展示了不同模型在1DUU(AF=5)、1DRU(AF=5)和2DRU(AF=10)下的重建图像与重建误差图。从图中可以观察到,在两种序列数据集下的所有欠采样模式中,L1SPIRiT、MICCAN、ISTA-Net+、Deep-SLR、Deep-complex、DONet、CGPD-CSNet方法均产生了较严重的伪影,具有较大的重建误差,而本文所提出的DASC-Net方法能更有效地抑制这些伪影,得到了更清晰且接近真实图像的重建结果,重建误差更小。




图2 使用5倍1DUU对CoronalPD进行欠采样时各算法的重建图像和误差图对比
Fig.2 Comparison of reconstructed images and error maps of various algorithms on CoronalPD under 5×1DUU




图3 使用5倍1DRU对CoronalPD进行欠采样时各算法的重建图像和误差图对比


Fig.3 Comparison of reconstructed images and error maps of various algorithms on CoronalPD under $5 \times 1\text{DRU}$ 

图4 使用10倍2DRU对CoronalPD进行欠采样时各算法的重建图像和误差图对比


Fig.4 Comparison of reconstructed images and error maps of various algorithms on CoronalPD under $10 \times 2\text{DRU}$ 

图5 使用5倍1DUU对SagittalPD进行欠采样时各算法的重建图像和误差图对比


Fig.5 Comparison of reconstructed images and error maps of various algorithms on SagittalPD under $5 \times 1\text{DUU}$ 

图6 使用5倍1DRU对SagittalPD进行欠采样时各算法的重建图像和误差图对比

Fig.6 Comparison of reconstructed images and error maps of various algorithms on SagittalPD under $5 \times 1\text{DRU}$




图7 使用10倍2DRU对SagittalPD进行欠采样时各算法的重建图像和误差图对比

Fig.7 Comparison of reconstructed images and error maps of various algorithms on SagittalPD under $10\times 2\text{DRU}$

为了验证所提出的DASC-Net算法与其他比较方法在欠采样场景下重建图像的PSNR值是否存在统计显著性差异,进行了 t -test检验。由于篇幅限制,本文仅针对最核心的重建指标PSNR进行了检验。显著性检验实验涉及两个数据集:CoronalPD和SagittalPD。在每种数据集的3种欠采样模式下,对所提方法DASC-Net与其他7种对比方法的PSNR值进行了 t -test检验。检验结果如表3和表4所示,表中列出的数值代表DASC-Net与每种对比方法 t -test检验的 P 值结果。从结果中可以看出,在所有欠采样模式下,DASC-Net方法与其他方法的PSNR值的 t -test检验 P 值均小于0.05,这表明DASC-Net方法与其他方法在重建PSNR值上存在统计显著性差异。

表3 CoronalPD下PSNR的 t -test检验 P 值结果

Table 3 t -test P -value results of PSNR under CoronalPD

方法	CoronalPD		
	1DRU	1DUU	2DRU
L1-SPIRiT	8.003 71e-34	1.781 08e-37	4.251 87e-25
MICCAN	3.623 5e-33	1.119 78e-37	3.995 28e-12
ISTA-Net+	1.942 94e-14	8.400 95e-17	1.638 28e-05
Deep-SLR	8.363 02e-42	5.107 99e-37	6.205 74e-26
Deepcomplex	1.090 63e-15	1.161 88e-20	2.029 31e-05
DONet	1.772 2e-11	1.049 72e-14	0.000 393 861
CGPD-CSNet	6.120 32e-08	1.408 34e-08	0.016 822 2

表4 SagittalPD下PSNR的 t -test检验 P 值结果

Table 4 t -test P -value results of PSNR under SagittalPD

方法	SagittalPD		
	1DRU	1DUU	2DRU
L1-SPIRiT	1.876 84e-32	1.095 19e-24	2.133 47e-28
MICCAN	2.788 07e-34	2.380 04e-20	5.184 52e-14
ISTA-Net+	1.475 46e-08	5.255 1e-10	0.000 270 199
Deep-SLR	2.239 51e-23	1.220 09e-16	1.991 82e-15
Deepcomplex	4.509 71e-11	8.180 81e-10	1.580 71e-08
DONet	4.292 59e-07	6.186 54e-06	5.392 24e-08
CGPD-CSNet	0.002 740 95	0.000 442 56	0.020 606 5

3.4 消融实验

为了验证本文所提出的深监督加权损失对重建性能的影响,在 CoronalPD 的 3 倍 1DRU 模式下进行消融实验,实验结果在表 5 中列出,其中 Base_Net 表示没有 DAP 和 MSFF 的基本网络,使用深监督加权损失;Base_Net w/o deep loss 表示在 Base_Net 的基础上将深监督加权损失替换成常用的 L_1 范数损失,定义为

$$\text{Loss} = \frac{1}{N_T} \sum_{i=1}^{N_T} \left\| \mathbf{x}_i^{N_P} - \mathbf{x}_i^{\text{true}} \right\|_1 + \beta_2 \frac{1}{N_T N_P} \sum_{i=1}^{N_T} \sum_{k=1}^{N_P} \left\| \tilde{\Phi}^{(k)}(\Phi^{(k)}(Z_i)) - Z_i \right\|_2^2 \quad (20)$$

从表 5 可以看出,相比常规 L_1 范数损失,使用深监督加权损失重建的 PSNR 提高了 0.37 dB,这验证了提出的深监督加权损失的有效性。

为了验证本文所提出的 DAP 和 MSFF 对重建性能的影响,在 CoronalPD 的 3 倍 1DRU 模式下进行消融实验,实验结果如表 6 所示,其中 Base_Net+DAP 表示基本网络上加上 DAP 但不包含 MSFF,Base_Net+DAP+MSFF 表示基本网络上加上 DAP 和 MSFF。从表 6 可以看出,在基本网络上加上 DAP,重建的 PSNR 提高了 0.55 dB,再加上 MSFF,PSNR 进一步提高了 0.76 dB,验证了提出的 DAP 和 MSFF 的有效性。

此外,为了评估在 DASC-Net 中不同重建阶段数对重建性能的影响,在 CoronalPD 的 3 倍 1DRU 欠采样模式下进行实验,重建阶段数从 2 变化到 14,间隔为 2,实验结果如图 8 所示。从图中可以看到,随着重建阶段数的增加,重建图像的 PSNR 呈增长趋势,但重建阶段数过大也会造成 PSNR 的下降。基于这一观察,重建阶段数为 10 被确定为最优设置,因此本文在所有实验中都固定网络的重建阶段数为 10。

在重建单张图像时,DASC-Net 与其他方法的计算成本、参数量和单张 RTX3090 GPU 上的推理时间如表 7 所示(除了 L1SPIRiT 在 CPU 上运行)。由于传统算法 L1SPIRiT 的参数量与深度学习方法相比过于太小,此处便不再展示,仅提供该方法的推理速度,可以看到深度学习方法的推理速度明显优于传统算法,可以在较短时间内完成重建。

表 5 深监督加权损失消融实验结果

Table 5 Experimental results of deep supervised weighted loss ablation

方法	1DRU (AF=3)		
	PSNR/dB	SSIM	HFEN
Base_Net w/o deep loss	35.56	0.918	0.025 3
Base_Net	35.93	0.925	0.024 1

表 6 不同模块消融实验结果

Table 6 Results of ablation experiments on different modules

方法	1DRU (AF=3)		
	PSNR	SSIM	HFEN
Base_Net	35.93	0.925	0.024 1
Base_Net+DAP	36.48	0.932	0.022 5
Base_Net+DAP+MSFF	37.24	0.937	0.017 5




图 8 重建阶段数消融结果

Fig.8 Ablation results of number of reconstruction stages

表7 不同方法的计算成本、参数量和推理时间对比

Table 7 Comparison of computational cost, params, and inference time for different methods

方法	计算成本	参数量/ 10^6	推理时间/s
L1SPIRiT	—	—	372.058
MICCAN	143.884	5.334	0.098
ISTA-Net+	81.75	0.598	0.026
Deepcomplex	148.636	1.454	0.027
CGPD-CSNet	520.004	5.867	0.097
DASC-Net	917.754	7.622	0.198

为了验证训练过程是否存在过拟合,图9展示了训练和验证损失曲线。可以看出,在两个数据集上训练损失和验证损失均呈较为一致的下降趋势,说明了训练过程正常,并未出现过拟合等异常情况。




图9 训练和验证损失曲线

Fig.9 Training and validation loss curves

4 结束语

本文提出了一种基于自适应稀疏预处理和多尺度特征融合的并行MR图像重建方法,旨在提高并行MR图像的重建质量。该方法通过深度展开迭代网络结构,将优化算法拆解为多个网络层,以学习更有效的稀疏表示,从而提升压缩感知性能。此外,本文还创新性地引入了一个自适应稀疏预处理模块。该模块通过自适应地对输入图像进行稀疏预处理,提升图像的稀疏表示能力,有效减少了重构过程中的噪声和失真。同时,该模块还设计了多尺度特征融合机制,并融合具有横向和纵向奇异值卷积核的卷积操作,进一步增强了网络的能力,使之能够捕捉图像中长距离的细节并自适应地融合不同尺度的特征,从而全面地重建了MRI图像并减少了伪影。在多个数据集上的实验结果证明,该方法相较于其他现有方法能够获得更高的峰值信噪比和结构相似性指数及更低的高频误差范数,充分展示了其在并行MR图像重建方面的优越性和有效性。

参考文献:

[1] CANDLES E J, ROMBERG J, TAO T. Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information[J]. IEEE Transactions on Information Theory, 2006, 52(2): 489-509.

[2] DONOHO D L. For most large underdetermined systems of linear equations the minimal ℓ_1 -norm solution is also the sparsest

- solution[J]. *Communications on Pure and Applied Mathematics*, 2006, 59: 907-934.
- [3] 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.
 - [4] 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.
 - [5] PRUESSMANN K P, WEIGER M, BÖRNERT P, et al. Advances in sensitivity encoding with arbitrary k-space trajectories [J]. *Magnetic Resonance in Medicine*, 2001, 46(4): 638-651.
 - [6] GRISWOLD M A, JAKOB P M, HEIDEMANN R M, et al. Generalized autocalibrating partially parallel acquisitions (GRAPPA)[J]. *Magnetic Resonance in Medicine*, 2002, 47(6): 1202-1210.
 - [7] LUSTIG M, PAULY J M. SPIRiT: Iterative self-consistent parallel imaging reconstruction from arbitrary k-space[J]. *Magnetic Resonance in Medicine*, 2010, 64(2): 457-471.
 - [8] SHIN P J, LARSON P E Z, OHLIGER M A, et al. Calibrationless parallel imaging reconstruction based on structured low-rank matrix completion[J]. *Magnetic Resonance in Medicine*, 2014, 72(4): 959-970.
 - [9] HALDAR J P, ZHUO J. P-LORAKS: Low-rank modeling of local k-space neighborhoods with parallel imaging data[J]. *Magnetic Resonance in Medicine*, 2016, 75(4): 1499-1514.
 - [10] VASANAWALA S S, ALLEY M T, HARGREAVES B A, et al. Improved pediatric MR imaging with compressed sensing [J]. *Radiology*, 2010, 256(2): 607-616.
 - [11] MURPHY M, ALLEY M, DEMMEL J, et al. Fast L_1 -SPIRiT compressed sensing parallel imaging MRI: Scalable parallel implementation and clinically feasible runtime[J]. *IEEE Transactions on Medical Imaging*, 2012, 31(6): 1250-1262.
 - [12] WELLER D S, RAMANI S, FESSLER J A. Augmented Lagrangian with variable splitting for faster non-cartesian L_1 -SPIRiT MR image reconstruction[J]. *IEEE Transactions on Medical Imaging*, 2014, 33(2): 351-361.
 - [13] DUAN J, BAO Z, LIU Y. Eigenvector-based SPIRiT parallel MR imaging reconstruction based on ℓ_p pseudo-norm joint total variation[J]. *Magnetic Resonance Imaging*, 2019, 58: 108-115.
 - [14] ZHANG X, DI GUO, HUANG Y, et al. Image reconstruction with low-rankness and self-consistency of k-space data in parallel MRI[J]. *Medical Image Analysis*, 2020, 63: 101687.
 - [15] ZHANG X, LU H, DI GUO, et al. A guaranteed convergence analysis for the projected fast iterative soft-thresholding algorithm in parallel MRI[J]. *Medical Image Analysis*, 2021, 69: 101987.
 - [16] DUAN J, LIU Y, WANG J. Accelerated SPIRiT parallel MR image reconstruction based on joint sparsity and sparsifying transform learning[J]. *IEEE Transactions on Computational Imaging*, 2023, 9: 276-288.
 - [17] DUAN J, LIU C, LIU Y, Et al. Adaptive transform learning and joint sparsity based PLORAKS parallel magnetic resonance image reconstruction[J]. *IEEE Access*, 2020, 8: 212315-212326.
 - [18] 黄裕青, 李华锋, 原铭, 等. 基于卷积神经网络梯度和纹理补偿的单幅图像超分辨率重建[J]. *数据采集与处理*, 2023, 38(5): 1112-1124.
 - HUANG Yuqing, LI Huafeng, YUAN Ming, et al. Super-resolution reconstruction of single image based on convolutional neural network gradient and texture compensation[J]. *Journal of Data Acquisition and Processing*, 2023, 38(5): 1112-1124.
 - [19] 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.
 - [20] SRIRAM A, ZBONTAR J, MURRELL T, et al. End-to-end variational networks for accelerated MRI reconstruction[C]// *Proceedings of Medical Image Computing and Computer Assisted Intervention (MICCAI)*. Lima, Peru: Springer International Publishing, 2020: 64-73.
 - [21] RAMZI Z, CIUCIU P, STARCK J. XPDNet for MRI reconstruction: An application to the fastMRI 2020 brain challenge[EB/OL]. (2020-10-15). <https://doi.org/10.48550/arXiv.2010.07290>.
 - [22] 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.
 - [23] LU T, ZHANG X, HUANG Y, et al. pFISTA-SENSE-ResNet for parallel MRI reconstruction[J]. *Journal of Magnetic Resonance*, 2020, 318: 106790.

- [24] HUANG Q, YANG D, WU P, Et al. MRI reconstruction via cascaded channel-wise attention network[C]//Proceedings of 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019). Venice, Italy: IEEE, 2019: 8-11.
- [25] WANG S, CHENG H, YING L, et al. DeepcomplexMRI: Exploiting deep residual network for fast parallel MR imaging with complex convolution[J]. Magnetic Resonance Imaging, 2020, 68: 136-147.
- [26] FENG C, YANG Z, FU H, et al. DONet: Dual-octave network for fast MR image reconstruction[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021. DOI: 10.1109/TNNLS. 2021, 3090303.
- [27] PRAMANIK A, AGGARWAL H K, JACOB M. Deep generalization of structured low-rank algorithms (Deep-SLR)[J]. IEEE Transactions on Medical Imaging, 2020, 39(12): 4186-4197.
- [28] WANG Z, QIAN C, GUO D, et al. One-dimensional deep low-rank and sparse network for accelerated MRI[J]. IEEE Transactions on Medical Imaging, 2023, 42(1): 79-90.
- [29] ZHANG J, GHANEM B. ISTA-Net: Interpretable optimization-inspired deep network for image compressive sensing[C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City: IEEE, 2018: 1828-1837.
- [30] XU L, CHOY C, LI Y. Deep sparse rectifier neural networks for speech denoising[C]//Proceedings of 2016 IEEE International Workshop on Acoustic Signal Enhancement (IWAENC). Xi'an, China: IEEE, 2016: 1-5.
- [31] WANG L, LEE C, TU Z, et al. Training deeper convolutional networks with deep supervision[EB/OL]. (2015-05-11). <https://doi.org/10.48550/arXiv.1505.02496>.
- [32] FESSLER J A. Optimization methods for magnetic resonance image reconstruction: Key models and optimization algorithms[J]. IEEE Signal Processing Magazine, 2020, 37(1): 33-40.
- [33] 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.
- [34] FAN X, YANG Y, CHEN K, et al. An interpretable MRI reconstruction network with two-grid-cycle correction and geometric prior distillation[J]. Biomedical Signal Processing and Control, 2023, 84: 104821.

作者简介:



薛磊(1999-),男,硕士研究生,研究方向:图像处理、磁共振成像重构算法,E-mail: 2556305312@qq.com。



段继忠(1984-),通信作者,男,博士,副教授,硕士生导师,研究方向:医学图像处理、人工智能以及GPU优化等,E-mail:duanjz@kust.edu.cn。

(编辑:王静)