

基于参考驱动深度图像先验与去噪正则化的多先验约束欠采样磁共振图像重建*

赵地¹⁾²⁾ 劳欢¹⁾ 白凤波^{1)†} 徐晨¹⁾

1) (广西民族大学人工智能学院, 南宁 530006)

2) (广西混杂计算与集成电路设计分析重点实验室, 南宁 530006)

(2026 年 2 月 4 日收到; 2026 年 5 月 5 日收到修改稿)

磁共振成像 (magnetic resonance imaging, MRI) 因数据采集时间较长, 限制了其在动态成像与介入式手术等临床场景中的应用. 压缩感知理论通过欠采样 k 空间数据缩短 MRI 扫描时间, 但重建质量高度依赖有效的先验约束. 近年来, 深度学习类方法在 MR 图像重建中表现优异, 其性能通常依赖于大规模高质量临床训练数据集, 而实践中临床数据的获取通常面临显著困难. 为此, 本文提出一种基于参考驱动深度图像先验 (deep image prior, DIP) 与去噪正则化 (regularization by denoising, RED) 的多先验约束欠采样 MR 图像重建方法. 该方法不依赖大规模预训练数据, 仅由单幅参考图像驱动, 构建一个两阶段重建框架: 首先利用结构相似的参考图像训练 RED 中去噪引擎, 将结构先验引入 RED 正则化; 随后将该参考图像进一步用于引导基于 DIP 的重建过程, 并结合 k 空间数据一致性约束、小波域结构相似性约束及 RED 正则化, 构建多先验协同优化模型, 实现从欠采样数据中高质量重建目标 MR 图像. 实验结果表明, 本文方法在视觉评价与定量指标上均优于现有同类方法, 能够更精确地重建组织细节与边缘, 为欠采样 MRI 重建提供了一种低数据依赖的高效技术路径.

关键词: 磁共振成像, 深度图像先验, 去噪正则化, 多先验约束

DOI: 10.7498/aps.75.20260203

CSTR: 32037.14.aps.75.20260203

1 引言

磁共振成像 (magnetic resonance imaging, MRI) 是一种重要的生物医学成像手段, 具备无电离辐射、卓越的软组织对比度、非侵入性及高空间分辨率等临床优势, 能够提供功能、结构与解剖等多维度信息, 广泛应用于疾病诊断与评估. 然而, 传统 MRI 数据采集时间较长, 限制了其在动态成像、介入式手术及急诊诊断等临床场景中的应用. 针对此问题, 压缩感知 (compressed sensing, CS) 理论^[1] 被引入 MRI 领域, 通过实施亚奈奎斯特采

样, 实现对 k 空间数据的欠采样采集^[2], 从而显著缩短扫描时间. 欠采样重建本质上属于高度欠定的逆问题, 通常需要引入图像先验知识以构建数学约束, 并借助优化算法进行求解. 随着 CS 理论的发展, 基于固定稀疏变换^[2-4] 或自适应稀疏表示^[5,6] 的稀疏性先验已得到广泛研究与应用. 此外, 参考驱动方法通过引入高分辨率参考图像, 利用图像间的结构相似性增强稀疏表示能力, 进一步提升了重建质量^[7-9]. 基于联合子空间采样理论、支撑信息^[10] 与结构化稀疏^[11,12] 等结构化先验也被整合至重建模型中, 以提升算法的鲁棒性与精确度.

近年来, 深度学习被广泛用于求解医学成像逆

* 广西民族大学引进人才科研启动项目 (批准号: 2023KJQD27)、广西自然科学基金 (批准号: 2021GXNSFBA220056) 和广西重点研发计划 (批准号: 桂科 FN2504240031) 资助的课题.

† 通信作者. E-mail: baif@gxmzu.edu.cn

问题^[13], 并在 MR 图像分割、去噪、分类以及快速成像等领域取得了显著成果. 基于数据驱动与模型驱动的深度学习方法^[14–16]各具特色: 数据驱动方法通常通过学习从欠采样 k 空间或图像域到全采样域的映射实现重建^[17–19]; 而模型驱动方法则从成像物理模型出发, 结合深度网络进行迭代优化求解^[20–23]. 尽管这些方法性能优越, 但其效果依然显著依赖基于大规模高质量临床数据集的预训练过程. 而受限于患者隐私保护政策及设备兼容性等因素, 获取充足的高分辨率 MR 训练数据面临现实挑战.

Ulyanov 等^[24]提出的深度图像先验 (deep image prior, DIP) 框架作为逆问题求解与深度学习交叉领域的重要进展, 显著降低了对大规模标注数据的依赖. DIP 将深度神经网络本身作为一种隐式正则化, 而非依赖监督学习进行参数训练^[25]. 该框架假设待重建图像应可由网络结构自然表征, 从而无需设计显式正则化项, 仅需将随机噪声输入网络即可运行. DIP 已在图像去噪、超分辨率、图像修复^[25–27]、压缩感知重建^[28]及医学成像^[29–31]等任务中展现出优异性能.

为进一步提升 DIP 的重建能力, 有研究提出在隐式正则化基础上引入显式正则化机制^[32,33]. 其中, 基于图像去噪的成像先验受到广泛关注^[32]. 去噪正则化 (regularization by denoising, RED)^[34]利用通用去噪器构建具有解析梯度的显式正则项. Mataev 等^[25]将 RED 思想融入 DIP 框架, 提出基于去噪正则化的深度图像先验 (DeepRED). 研究显示, 结合先进去噪算法的 RED 可在多种成像逆问题中取得优良性能^[25,34–36]. 类似地, 采用预训练的去噪卷积神经网络 (convolutional neural network, CNN) 作为成像先验的 RED 方法也被证实具有良好适用性^[37,38]. 然而, 由于全采样的真实 MR 数据难以获取, 训练高性能的去噪先验模型仍面临挑战.

为克服高质量、快速 MRI 对临床训练数据的依赖性, 本文提出一种结合参考驱动 DIP 与 RED 正则化的多先验约束欠采样 MR 图像重建方法. 该方法基于 DIP 框架, 无需依赖大规模预训练数据, 仅利用单幅参考图像构建约束优化问题, 通过求解最优网络参数实现目标 MR 图像的欠采样重建. 本文充分考虑了参考图像与目标图像间的结构相似性, 以参考图像同时驱动 RED 去噪引擎的训

练与 DIP 学习过程; 并进一步约束 k 空间数据一致性与小波域结构相似性, 构建融合 RED 正则化与多先验信息的欠采样重建模型. 整个流程包括去噪引擎训练与多先验约束重建两个阶段, 最终实现从欠采样数据中高质量重建目标 MR 图像. 实验结果表明, 本文方法在视觉评价与定量指标上均优于现有同类方法, 能够更精确地重建组织细节与边缘结构, 具有良好的临床适用潜力.

本研究的主要贡献为:

1) 提出一种仅需单幅参考图像驱动的重建策略, 无需依赖大规模高质量训练数据集进行预训练. 该方法有效克服了临床 MR 数据获取难的瓶颈问题, 具备较高的实际应用价值.

2) 设计了参考图像驱动的完整重建流程, 利用单幅参考图像同时引导 RED 去噪引擎的训练及目标图像的 DIP 重建过程, 引入结构化先验以提升学习效率与重建质量.

3) 构建了融合多域先验约束的重建模型, 结合 k 空间数据一致性、小波域结构相似性以及 RED 正则化, 实现多源先验信息的协同优化, 进一步提升重建性能.

2 方法

2.1 重建问题描述

基于 DIP 框架的欠采样 MR 图像重建问题可表述为

$$\hat{\theta} = \underset{\theta}{\operatorname{argmin}} \| \mathbf{y} - \mathbf{F}_U \mathbf{f}(\theta | \mathbf{z}) \|_2^2. \quad (1)$$

则待重建的目标 MR 图像 $\mathbf{I}_t \in \mathbb{C}^{N \times N}$ 可由 (2) 式得到:

$$\hat{\mathbf{I}}_t = \mathbf{f}(\hat{\theta} | \mathbf{z}), \quad (2)$$

其中 $\hat{\mathbf{I}}_t$ 表示重建的目标 MR 图像; $\mathbf{F}_U$ 为傅里叶降采样算子; $\mathbf{y} \in \mathbb{C}^{M \times 1}$ 是目标图像 $\mathbf{I}_t$ 根据欠采样模板 $\mathbf{U}$ 获取的 k 空间测量数据, $M \ll N$; $\mathbf{f}(\theta | \mathbf{z})$ 为未经训练的深度神经网络, 其以 θ 为网络参数, 以随机噪声 $\mathbf{z}$ 为网络输入; $\|\cdot\|_2$ 表示 l_2 范数. (1) 式所示的优化问题通过约束输出与 k 空间数据的一致性, 旨在实现深度网络输出与测量数据之间的最佳匹配. 基于 DIP 框架, 网络无需预训练, 其参数随机初始化后, 通过反复迭代求解 (1) 式所示的最优化问题获得最优网络参数.

2.2 重建方法

本文提出一种基于参考驱动 DIP 与 RED 正则化的多先验约束欠采样 MR 图像重建方法, 该方法无需预训练, 不依赖数据集, 仅利用与待重建目标图像结构相似的单幅参考图像, 即可由欠采样数据实现 MR 图像的加速重建. 本文方法的执行过程总览如图 1 所示, 可分解为两个阶段: 1) 基于参考驱动 DIP 的去噪引擎训练; 2) 基于参考驱动 DIP 与 RED 正则化的多先验约束重建.

本文方法由单幅已知参考图像驱动, 其与待重建的目标图像具有相似的解剖结构. 引入参考图像具有双重驱动作用: 一方面, 利用其训练 CNN 作为 RED 中的去噪引擎, 将结构相似性先验引入 RED 正则化; 另一方面, 将其作为网络输入, 为目标图像的重建提供结构化先验信息. 故而, 基于 (1) 式, 提出融合 RED 正则化和多先验约束的欠采样 MR 图像重建模型:

$$\begin{aligned} \arg\min_{\theta, I} & \frac{1}{2} \|y - F_U f(\theta | I_r)\|_2^2 + \frac{\alpha}{2} \|y - F_U f(\theta | I_r)\|_1 \\ & + \frac{\beta}{2} \|\Psi[I_r - f(\theta | I_r)]\|_1 + \frac{\lambda}{2} I^T [I - D(\Theta | I)] \\ \text{s.t. } & I = f(\theta | I_r), \end{aligned} \quad (3)$$

式中, I_r 为选取的高分辨率参考图像, 其与目标图像具有相似的解剖结构; Ψ 代表小波变换; $\|\cdot\|_1$ 表示 l_1 范数. $D(\Theta | I)$ 表示以 I 为输入、 Θ 为参数的卷积神经网络, 本文方法将其训练后用于 RED 正则化中的去噪引擎. 正则化参数 $\alpha, \beta, \lambda > 0$.

(3) 式中, 第一项为数据保真项, 用于约束网络输出与 k 空间采样数据的一致性. 第二项使用对异常值更具鲁棒性的 l_1 范数, 进一步约束 k 空间 (尤其是中心区域) 的数据误差. 第三项基于参考图像与目标图像之间的结构相似性, 约束二者之间差异图像的小波域稀疏性.

最后一项为 RED 正则化项 [25]. 在逆问题求解中, RED 具有显著优势. 一是其梯度可通过显式表达式直接计算, 从而避免了对去噪函数本身进行求导; 二是 RED 正则化项是凸泛函. 随着即插即用方法 [39,40] 的发展, 去噪引擎得以灵活嵌入各类迭代求解框架中. 这类框架通常由数据一致性子问题, 及关联去噪子问题的正则项组成. 因此, 众多高效去噪算法被广泛应用于重建任务中 [34,41]. 得益于神经网络日益强大的去噪能力, 越来越多的研究证实神经网络可作为有效的去噪先验, 并以多种形式嵌入迭代优化流程中 [20,32,41]. 故而, 本文选择 CNN 作为去噪引擎.

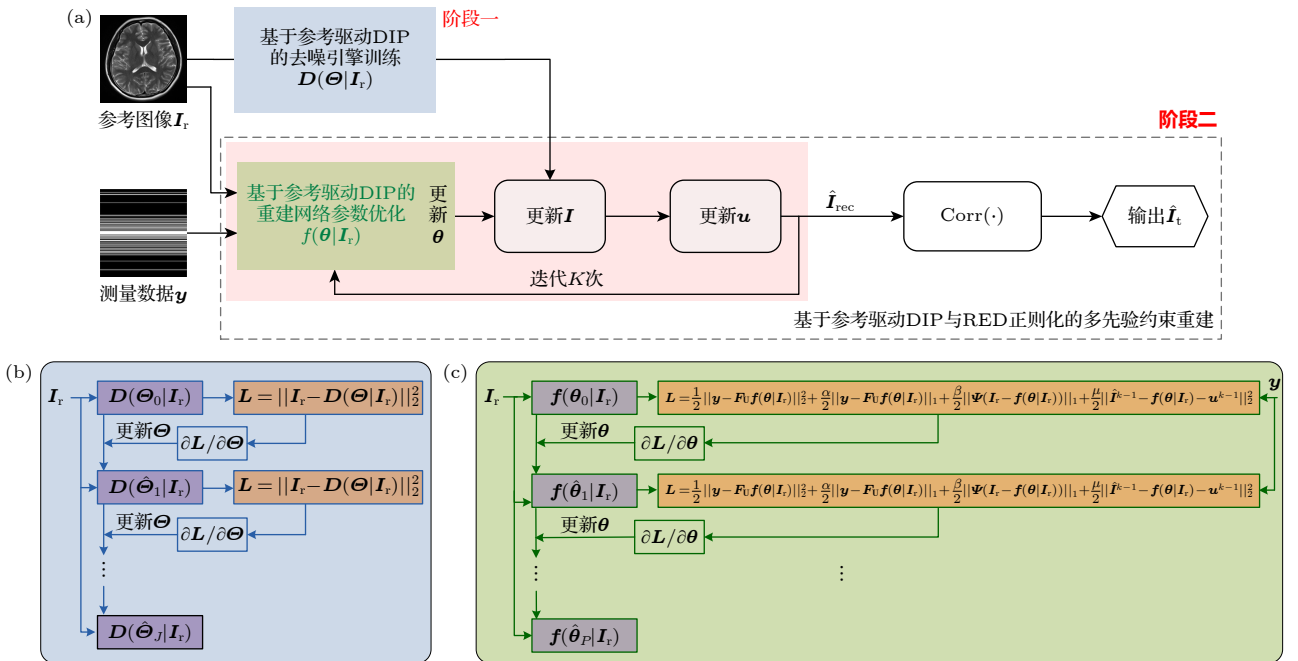


图 1 本文方法的执行过程总览 (a) 本文方法总览图; (b) 基于参考驱动 DIP 的去噪引擎训练流程; (c) 基于参考驱动 DIP 的重建网络参数训练流程

Fig. 1. Overview of the execution process of the proposed method: (a) Overall framework of the proposed method; (b) training of the denoising engine based on reference-driven DIP; (c) training of reconstruction network parameters based on reference-driven DIP.

2.2.1 基于参考驱动 DIP 的去噪引擎训练

在实际应用场景 (如序列成像、动态成像等) 中, 参考图像与目标 MR 图像通常采集自同一场景, 并具有相似的成像参数, 因而二者结构特征高度相似. 基于此, 本文考虑利用参考图像训练去噪引擎, 并将训练得到的去噪引擎用于目标图像重建的正则化约束. 此策略既实现了不依赖于大规模数据集的去噪引擎训练, 又可将参考图像与目标图像的结构相似性先验引入 RED 正则化, 为后续重建提供有效先验信息.

具体实现上, 本文方法以参考图像为驱动 (作为网络输入), 在 DIP 框架下通过迭代优化求解去噪引擎 $D(\cdot)$ 的网络参数:

$$\hat{\Theta} = \operatorname{argmin}_{\Theta} \|I_r - D(\Theta | I_r)\|_2^2, \quad (4)$$

式中, 参考图像来源于实际采集, 其本身即为含有噪声的真实存在. 故而, (4) 式所描述的优化问题可视为一个基于 DIP 框架的参考图像去噪过程^[24]. 由此, 本文方法仅需单幅参考图像即可完成 RED 正则化中去噪引擎的训练.

2.2.2 基于参考驱动 DIP 与 RED 正则化的多先验约束重建

1) 重建网络参数优化

使用增广拉格朗日法, 可将 (3) 式中的约束条件转化为惩罚项, 故而得到如 (5) 式所示的无约束优化问题:

$$\begin{aligned} \operatorname{argmin}_{\theta, I} & \frac{1}{2} \|y - F_U f(\theta | I_r)\|_2^2 + \frac{\alpha}{2} \|y - F_U f(\theta | I_r)\|_1 \\ & + \frac{\beta}{2} \|\Psi[I_r - f(\theta | I_r)]\|_1 + \frac{\lambda}{2} I^T [I - D(\Theta | I)] \\ & + \frac{\mu}{2} \|I - f(\theta | I_r) - u\|_2^2, \end{aligned} \quad (5)$$

其中 u 表示拉格朗日乘子向量, μ 为惩罚系数.

为求解 (5) 式中的目标函数, 采用乘子交替方向法 (alternating direction method of multipliers, ADMM)^[42], 分解为以下子问题:

$$\begin{aligned} \hat{\theta}^k &= \operatorname{argmin}_{\theta} \frac{1}{2} \|y - F_U f(\theta | I_r)\|_2^2 \\ &+ \frac{\alpha}{2} \|y - F_U f(\theta | I_r)\|_1 \\ &+ \frac{\beta}{2} \|\Psi(I_r - f(\theta | I_r))\|_1 \\ &+ \frac{\mu}{2} \|\hat{I}^{k-1} - f(\theta | I_r) - u^{k-1}\|_2^2, \end{aligned} \quad (6)$$

$$\begin{aligned} \hat{I}^k &= \operatorname{argmin}_I \frac{\lambda}{2} I^T [I - D(\hat{\Theta} | I)] \\ &+ \frac{\mu}{2} \|I - f(\hat{\theta}^k | I_r) - u^{k-1}\|_2^2, \end{aligned} \quad (7)$$

$$u^k = u^{k-1} - \hat{I}^k + f(\hat{\theta}^k | I_r), \quad (8)$$

其中 k 表示 ADMM 中的迭代索引.

子问题一 求解网络参数 $\hat{\theta}^k$. (6) 式所示的优化问题中, 第一项与传统 DIP 一致, 而后三项则通过额外引入正则化进一步修正优化过程, 增强稳定性与鲁棒性.

子问题二 求解 $\hat{I}^k$. 可以观察到, (7) 式是一个经典的 RED 目标函数^[34], 其本质是对图像进行去噪处理. 存在两种可选求解方案: 一种是定点迭代策略, 另一种是最速下降法^[25]. 本文采用定点迭代策略, 令 (7) 式对 I 的导数为零.

由于 RED 正则项的梯度满足梯度规则, 故有

$$\frac{\partial}{\partial I} \left\{ \frac{1}{2} I^T [I - D(\hat{\Theta} | I)] \right\} = I - D(\Theta | I), \quad (9)$$

分配索引, 进一步得到

$$\lambda [I^k - D(\hat{\Theta} | I^{k-1})] + \mu [I^k - f(\hat{\theta}^k | I_r) - u^{k-1}] = 0. \quad (10)$$

从而可得更新公式如下:

$$\hat{I}^k = \frac{1}{\lambda + \mu} \left\{ \lambda D(\hat{\Theta} | \hat{I}^{k-1}) + \mu [f(\hat{\theta}^k | I_r) + u^{k-1}] \right\}. \quad (11)$$

子问题三 依 (8) 式更新 u^k .

2) MR 图像重建

经过 K 轮 ADMM 迭代更新后 (设 K 表示最大迭代次数), 可获得最优网络参数为 $\hat{\theta}^K$ 的重建网络及其输出结果, 输出的重建 MR 图像表示为

$$\hat{I}_{\text{rec}} = f(\hat{\theta}^K | I_r). \quad (12)$$

进一步使用数据校正算子 $\text{Corr}(\cdot)$ 提升重建精度, 可得到 k 空间校正数据 y_{cor} :

$$y_{\text{cor}} = \text{Corr}(\hat{I}_{\text{rec}}) = (F \hat{I}_{\text{rec}})_{\bar{U}} \cup y, \quad (13)$$

式中, F 表示傅里叶变换, y 是根据欠采样掩模 U 获取的 k 空间测量数据, $\bar{U}$ 表示 U 的补集. 遵循 (13) 式所述的数据校正策略, 所有预先采样获取的测量数据均被保留以维持 k 空间的数据一致性, 从而将重建误差严格限制于未采样的 k 空间数据. 然后, 对 y_{cor} 执行逆傅里叶变换 F^{-1} , 得到目标 MR 图像的最终重建结果:

$$\hat{I}_t = F^{-1} y_{\text{cor}}. \quad (14)$$

本文方法的算法流程总结如下:

Algorithm 1 本文方法的算法流程.

输入

I_r - 选取的参考MR图像; y - k 空间测量数据; J - 去噪引擎网络参数的最大迭代更新次数; K - ADMM最大迭代次数; P - ADMM中重建网络参数的最大迭代更新次数; μ - ADMM惩罚系数; α, β, λ - 正则化参数

输出

目标MR图像的重建结果 $\hat{I}_t$

- 1) 初始化: $u^0 = 0$, $I^0 = F_U^{-1}y$, 随机化去噪引擎网络参数 Θ^0 和重建网络参数 θ^0 .
- 2) **基于参考驱动DIP的去噪引擎训练:**
- 3) 采用Adam和反向传播算法对(4)式进行 J 次迭代求解.
- 4) **基于参考驱动DIP与RED正则化的多先验约束重建:**
- 5) **for** $k = 1: K$ **do**
- 6) 更新 $\hat{\theta}^k$: 采用Adam和反向传播算法对如(6)式所示的子问题进行 P 次迭代求解.
- 7) 更新 $\hat{I}^k$: 通过计算式(11)求解(7)式所示的子问题.
- 8) 更新 u^k : 由(8)式确定拉格朗日乘子向量.
- 9) **end for**
- 10) 重建网络输出 $\hat{I}_{rec} = f(\hat{\theta}^K | I_r)$.
- 11) 根据(13)式进行 k 空间数据校正.
- 12) 执行(14)式得到重建图像.

2.3 网络结构

本文采用 U-net 作为去噪引擎 $D(\cdot)$ 和重建网络 $f(\cdot)$, 与传统 DIP^[24] 采用相同的网络架构, 详见图 2 所示. 该网络基于编码器-解码器架构, 采用带有跳跃连接的“沙漏”形结构. 编码路径 (左侧) 与

解码路径 (右侧) 通过跳跃连接实现链接, 从而整合不同尺度下的特征信息. 该网络重复使用卷积层 (Conv)、批量归一化层 (BN)、泄漏整流线性单元层 (LeakyReLU)、下采样操作和双线性插值上采样操作. 设 L 表示网络的最大深度, 将 $n_d[i]$, $n_u[i]$ 和 $n_s[i]$ 记作深度为第 i 层的下采样、上采样和跳跃连接的滤波器数量, $k_d[i]$, $k_u[i]$ 和 $k_s[i]$ 分别表示对应的卷积核尺寸.

3 实验与分析

3.1 实验设置

3.1.1 数据获取

为评价所提出方法的重建性能, 本文选取三组 MR 数据开展实验. 第一组数据 (Group One) 与第二组数据 (Group Two) 均来自纽约大学 fastMRI 数据库 (<https://fastmri.med.nyu.edu>)^[43,44]. Group One 包含 1 幅参考图像与 20 幅待重建的目标图像, 均选自 fastMRI 单线圈膝关节验证数据集 (文件编号 1001096). 图 3 展示了该组数据中的部分 MR 图像. Group Two 同样选自 fastMRI 单线圈膝关节验证数据集, 具体来源文件编号为 1000153. 随机选取 7 幅图像, 其中一幅作为参考图像, 用于重建其余 6 幅 MR 图像. 如图 3 所示, 图 3(a) 为参考 MR 图像, 图 3(b)–(g) 为待重建的 6 幅目标图像, 分别记为 knee 1—knee 6. 第三组数据 (Group




图 2 本文方法采用的网络架构^[24]

Fig. 2. Network architecture^[24] used in the proposed method.




图 3 实验数据. Group One: 部分 MR 图像展示, 第一幅为参考图像, 其余为 6 幅待重建图像. Group Two: (a) 参考图像和待重建的目标图像 (b) knee 1—(g) knee 6. Group Three: (h) 参考图像, 待重建的目标图像 (i) Brain 1 和 (j) Brain 2

Fig. 3. MR scans used in reconstruction experiments. Group One: Partial display of MR images, with the first being the reference image and the remaining six being the target images for reconstruction. Group Two: (a) The reference image, and the target images (b) knee 1—(g) knee 6. Group Three: (h) The reference image, and the target images (i) Brain 1 and (j) Brain 2.




图 4 降采样模板 (a) 笛卡尔采样模板; (b) 变密度采样模板; (c) 径向采样模板

Fig. 4. Undersampling masks used in the experiments: (a) Cartesian mask; (b) variable density mask; (c) radial mask.

Three) 为来自 3T Siemens MRI 扫描仪的活体脑部 MR 数据. Group Three 包含一幅参考图像 (图 3(h)) 及两幅目标图像 (Brain 1 与 Brain 2, 参见图 3(i) 和图 3(j)). 该组图像源自同一患者的脑部扫描序列, 尺寸为 256×256 . 成像参数如下: 梯度回波 (GRE) 序列, 重复时间 (TR) = 250 ms, 回波时间 (TE) = 2.5 ms, 翻转角 = 70° , 层厚 5.0 mm.

为探究不同欠采样方案对重建性能的影响, 本文采用三种不同类型的欠采样模板完成实验: 笛卡尔采样模板、变密度采样模板以及径向采样模板 (如图 4 所示).

3.1.2 实验参数设置

本文设定网络最大深度 $L = 6$, $n_u = [32; 32; 64; 128; 128; 128]$, $n_d = [32; 32; 64; 128; 128; 128]$, $n_s = [16; 16; 16; 16; 16; 16]$, $k_d = k_u = [3; 3; 3; 3; 3; 3]$,

以及 $k_s = [1; 1; 1; 1; 1; 1]$. 初始学习率设定为 $LR = 0.001$, 随后迭代按照 $0.92 \times LR$ 更新. 设定正则化参数 $\alpha = 10^{-4}$, $\beta = 10^{-6}$, $\lambda = 10^{-6}$, ADMM 惩罚系数 $\mu = 10^{-4}$. 采用 Haar 小波, 分解层数设置为 6. 去噪网络参数更新的最大迭代次数 J 设定为 2000 次, ADMM 的迭代次数为 $K = 30$ 和 $P = 100$.

本文实验在 Ubuntu 16.04 LTS (64 位) 操作系统上实现, 平台配置为 Intel Core i9-7920X 2.9 GHz CPU 和 Nvidia GeForce GTX 1080Ti GPU, 11 GB RAM; 运行环境为 PyTorch, CUDA, CUDNN.

3.1.3 对比方法与评价指标

实验中, 为评估本文提出方法的重建性能, 将零填充重建、约束小波域稀疏性的 CS 重建 (简称

CS-L1W)、传统 DIP 重建、以参考图像作为网络输入的 DIP 重建 (简称 DIP+Ref), 以及基于 DIP 框架且约束目标图像小波域稀疏性的参考驱动方法 (简称 DIP-RWS)^[45] 作为对比方法. 为确保公平比较, 各重建方法均采用相同的欠采样模板, 且本文方法中的去噪引擎 $D(\cdot)$ 和重建网络 $f(\cdot)$ 均采用与传统 DIP 相同的网络架构. 为了量化比较重建性能, 本文采用了三种广泛使用的评价指标: 峰值信噪比 (peak signal to noise ratio, PSNR)、相对误差 (RelErr) 和结构相似性指数 (structural similarity index, SSIM)^[46], 定义分别如下:

$$\text{PSNR} = 10 \lg \frac{NN(\text{MAX}_x)^2}{\sum_{i=1}^N \sum_{j=1}^N [\hat{x}(i, j) - x(i, j)]^2}, \quad (15)$$

$$\text{RelErr} = \frac{\|\hat{x} - x\|_2}{\|x\|_2}, \quad (16)$$

$$\text{SSIM} = \frac{(2\mu_x \mu_{\hat{x}} + c_1)(2\sigma_{x\hat{x}} + c_2)}{(\mu_x^2 + \mu_{\hat{x}}^2 + c_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + c_2)}, \quad (17)$$

式中, 真实图像 x 与重建图像 $\hat{x}$ 具有相同尺寸, 均为 $N \times N$; MAX_x 表示 x 中的最大值; μ_x , $\mu_{\hat{x}}$ 分别代表 x 与 $\hat{x}$ 的均值, σ_x , $\sigma_{\hat{x}}$ 为其标准差; $\sigma_{x\hat{x}}$ 表示 x 与 $\hat{x}$ 的互协方差; c_1 和 c_2 取值分别为 0.01 与 0.03.

3.2 实验结果与分析

3.2.1 不同采样率下的重建性能比较

首先采用笛卡尔采样模板, 在不同采样率下进

行重建实验. 表 1、表 2 和表 3 展示了本文方法与零填充重建、CS-L1W、传统 DIP、以参考图像作为输入的 DIP+Ref 及 DIP-RWS 方法在不同采样率下三种评价指标的数值结果. 其中, 表 1 展示的各项指标数值为 Group One 中 20 幅目标图像重建结果的平均数值. 考虑到训练过程中固有的随机性 (即本文方法和 DIP+Ref、DIP-RWS 中网络参数的随机初始化, 以及传统 DIP 中网络参数和网络输入的随机初始化), 实验通过完成 10 次运行并取数据平均值获得数值结果. 表 1—表 3 表明, 在相同采样数据量下, 本文方法在三组 MR 数据集中均获得了最高的 SSIM 和 PSNR 值, 以及最低的相对误差, 从而验证了本文方法能够获得更精确的重建结果.

表 1 笛卡尔采样模板下, 不同重建方法基于 Group One 膝关节扫描数据的定量指标评估

Table 1. Quantitative metric evaluations for the knee reconstructions in Group One according to the different methods under the Cartesian undersampled masks.

重建方法	采样率 = 20%			采样率 = 30%		
	RelErr /%	PSNR /dB	SSIM	RelErr /%	PSNR /dB	SSIM
零填充	8.19	32.79	0.9016	7.65	33.26	0.9163
CS-L1W	7.77	33.17	0.9190	7.26	33.77	0.9307
DIP	7.98	32.94	0.9361	7.37	33.63	0.9465
DIP+Ref	7.37	33.56	0.9446	6.85	34.26	0.9520
DIP-RWS	7.04	34.01	0.9517	6.30	34.94	0.9630
本文方法	6.62	34.36	0.9555	5.87	35.61	0.9653

表 2 笛卡尔采样模板下, 不同重建方法基于 Group Two 膝关节扫描数据的定量指标评估

Table 2. Quantitative metric evaluations for the knee reconstructions in Group Two according to the different methods under the Cartesian undersampled masks.

目标图像	重建方法	采样率 = 20%			采样率 = 30%		
		RelErr/%	PSNR/dB	SSIM	RelErr/%	PSNR/dB	SSIM
knee 1	零填充	8.59	31.65	0.9024	7.81	32.47	0.9153
	CS-L1W	7.46	32.86	0.9208	6.52	34.03	0.9373
	DIP	8.38	31.86	0.9217	8.10	32.05	0.9273
	DIP+Ref	7.51	32.81	0.9325	7.17	33.21	0.9391
	DIP-RWS	7.22	31.15	0.9432	6.39	34.21	0.9556
	本文方法	6.96	33.47	0.9460	6.08	34.64	0.9583
knee 2	零填充	8.31	32.35	0.9053	7.77	32.93	0.9167
	CS-L1W	7.23	33.56	0.9256	6.57	34.38	0.9396
	DIP	8.05	32.62	0.9287	7.45	33.29	0.9400
	DIP+Ref	7.34	33.42	0.9396	7.24	33.54	0.9423
	DIP-RWS	6.98	33.92	0.9436	6.78	34.11	0.9459
	本文方法	6.68	34.24	0.9511	5.75	35.55	0.9623

表 2 (续) 笛卡尔采样模板下, 不同重建方法基于 Group Two 膝关节扫描数据的定量指标评估
Table 2 (continued). Quantitative metric evaluations for the knee reconstructions in Group Two according to the different methods under the Cartesian undersampled masks.

目标图像	重建方法	采样率 = 20%			采样率 = 30%		
		RelErr/%	PSNR/dB	SSIM	RelErr/%	PSNR/dB	SSIM
knee 3	零填充	9.03	31.64	0.8910	8.32	32.35	0.9058
	CS-L1W	7.91	32.79	0.9187	7.14	33.67	0.9344
	DIP	8.84	31.82	0.9190	7.97	32.72	0.9355
	DIP+Ref	7.46	33.30	0.9393	7.17	33.64	0.9447
	DIP-RWS	6.97	33.88	0.9494	6.22	34.86	0.9587
	本文方法	6.78	34.12	0.9503	5.92	35.30	0.9616
knee 4	零填充	8.86	31.17	0.8856	8.25	31.79	0.8968
	CS-L1W	8.36	31.67	0.9026	7.60	32.50	0.9203
	DIP	9.18	30.79	0.9031	8.59	31.44	0.9218
	DIP+Ref	7.72	32.37	0.9335	7.39	32.75	0.9388
	DIP-RWS	7.42	32.71	0.9372	6.24	34.22	0.9576
	本文方法	6.94	33.29	0.9455	5.82	34.83	0.9609
knee 5	零填充	8.12	32.22	0.8976	7.64	32.75	0.9077
	CS-L1W	7.67	32.72	0.9135	6.91	33.62	0.9296
	DIP	8.64	31.69	0.9222	8.03	32.33	0.9336
	DIP+Ref	7.61	32.79	0.9369	6.88	33.66	0.9476
	DIP-RWS	7.32	33.13	0.9395	6.45	34.22	0.9568
	本文方法	6.54	34.10	0.9515	6.10	34.71	0.9613
knee 6	零填充	7.75	32.41	0.8959	7.31	32.92	0.9061
	CS-L1W	7.34	32.88	0.9141	6.50	33.94	0.9304
	DIP	7.99	32.08	0.9321	7.50	32.67	0.9429
	DIP+Ref	7.29	32.94	0.9419	6.82	33.52	0.9495
	DIP-RWS	6.80	33.54	0.9496	5.94	34.72	0.9621
	本文方法	6.38	34.10	0.9544	5.60	35.23	0.9653

表 3 笛卡尔采样模板下, 不同重建方法基于 Group Three 脑部扫描数据的定量指标评估
Table 3. Quantitative metric evaluations for the brain reconstructions in Group Three according to the different methods under the Cartesian undersampled masks.


采样率	重建方法	Brain 1			Brain 2		
		RelErr/%	PSNR/dB	SSIM	RelErr/%	PSNR/dB	SSIM
15%	零填充	24.78	19.88	0.6428	21.97	20.65	0.6799
	CS-L1W	23.10	20.48	0.6506	19.54	21.67	0.6917
	DIP	16.87	23.22	0.8002	11.30	26.43	0.8511
	DIP+Ref	12.39	25.90	0.8740	9.91	27.56	0.9047
	DIP-RWS	8.49	29.17	0.9247	10.79	26.83	0.9095
	本文方法	7.94	29.76	0.9298	5.37	32.88	0.9558
20%	零填充	10.98	26.94	0.7513	12.20	25.76	0.7584
	CS-L1W	8.38	29.29	0.8358	8.62	28.77	0.8466
	DIP	6.05	32.12	0.9506	8.28	29.13	0.9213
	DIP+Ref	4.56	34.58	0.9687	3.76	35.98	0.9738
	DIP-RWS	4.49	34.70	0.9718	3.66	36.22	0.9790
	本文方法	4.28	35.12	0.9755	3.32	37.06	0.9826

表 3 (续) 笛卡尔采样模板下, 不同重建方法基于 Group Three 脑部扫描数据的定量指标评估
Table 3 (continued). Quantitative metric evaluations for the brain reconstructions in Group Three according to the different methods under the Cartesian undersampled masks.

采样率	重建方法	Brain 1			Brain 2		
		RelErr/%	PSNR/dB	SSIM	RelErr/%	PSNR/dB	SSIM
25%	零填充	7.50	30.26	0.7803	8.42	28.98	0.7869
	CS-L1W	5.95	32.26	0.8535	5.72	32.33	0.8683
	DIP	4.51	34.67	0.9664	3.30	37.11	0.9793
	DIP+Ref	3.71	36.35	0.9759	3.14	37.56	0.9839
	DIP-RWS	3.67	36.47	0.9782	2.92	38.19	0.9844
	本文方法	3.20	37.65	0.9840	2.59	39.23	0.9874
30%	零填充	7.46	30.30	0.8045	8.13	29.29	0.8189
	CS-L1W	5.53	32.90	0.8799	4.92	33.65	0.9104
	DIP	4.30	35.09	0.9653	4.03	35.38	0.9726
	DIP+Ref	3.64	36.52	0.9794	2.94	38.12	0.9762
	DIP-RWS	3.36	37.23	0.9812	2.54	39.39	0.9871
	本文方法	3.02	38.16	0.9846	2.39	39.92	0.9881
35%	零填充	7.07	30.76	0.8540	7.65	29.81	0.8511
	CS-L1W	5.24	33.37	0.9349	4.50	34.42	0.9493
	DIP	3.95	35.82	0.9773	3.53	36.52	0.9743
	DIP+Ref	3.48	36.92	0.9820	2.85	38.39	0.9807
	DIP-RWS	3.31	37.36	0.9821	2.34	40.10	0.9900
	本文方法	2.82	38.75	0.9875	2.17	40.74	0.9905

图 5 展示了本文方法与对比方法对 Group Two 中膝关节扫描 knee 1—6 的重建结果. 可以看出, CS-L1W, DIP 和 DIP+Ref 显著优于零填充重建, 而 DIP-RWS 方法将目标图像的小波域稀疏性作

为显式先验引入学习及重建流程, 故而在重建精度上取得了进一步的提升. 然而, 对比方法在细节和精细结构处均仍存在重建模糊 (如黄色箭头所示). 相比之下, 本文方法在重建结构细节方面展现出更明显






图 5 采用笛卡尔采样模板对 Group Two 膝关节扫描数据的重建结果对比. 第 1, 3, 5, 7, 9, 11 行分别显示目标图像的真实值以及采用不同方法 (零填充, CS-L1W, DIP, DIP+Ref, DIP-RWS 和本文方法) 的重建结果. 第 2, 4, 6, 8, 10, 12 行呈现对应的局部放大图像. 黄色箭头标注了被重建还原的细微结构特征. 其中, knee 1 采用 20% 采样, 其余均为 30% 采样

Fig. 5. Visual comparison of reconstruction results for knee scans in Group Two under Cartesian undersampled masks. Rows 1, 3, 5, 7, 9 and 11 display the ground truth of the target images along with reconstruction results obtained using different methods (zero-filling, CS-L1W, DIP, DIP+Ref, DIP-RWS and the proposed method). Rows 2, 4, 6, 8, 10 and 12 present the corresponding zoomed-in local views. Yellow arrows emphasize restored subtle details. Knee 1 is sampled at 20%, while all other cases are sampled at 30%.

的优势, 图示结果证明了其在保留细微特征方面的潜力. 图 6 和图 7 分别展示了 Brain 1 和 Brain 2 的重建结果. 本文方法在保持脑部 MR 图像结构细节和纹理特征方面同样表现出显著优势, 特别是在放大区域更为明显. 同时, 可由误差图像看出, 本文方法的重建结果误差更小, 更接近目标

MR 图像.

3.2.2 不同采样模板下的重建性能比较

为评估本文方法在不同欠采样模板下的重建性能, 本部分进一步使用径向采样模板与变密度采样模板进行实验. 表 4 展示了 Brain 1 和 Brain 2 在两种采样模板下重建结果的 SSIM, PSNR 和




图 6 35% 采样率下采用笛卡尔采样模板对 Brain 1 的重建结果对比. 第 1 行为目标图像及不同方法 (零填充, CS-L1W, DIP, DIP+Ref, DIP-RWS 与本文方法) 的重建结果; 第 2 行显示对应的误差图; 第 3 行为局部放大图像

Fig. 6. Visual comparisons for Brain 1 reconstructions at the 35% sampling rate with the Cartesian undersampled mask. Row 1 display the ground truth of the target images along with reconstruction results obtained using different methods (zero-filling, CS-L1W, DIP, DIP+Ref, DIP-RWS and the proposed method). Row 2 shows the corresponding error images, and row 3 shows corresponding zoomed-in local views.




图 7 25% 采样率下采用笛卡尔采样模板对 Brain 2 的重建结果对比. 第 1 行为目标图像及不同方法 (零填充, CS-L1W, DIP, DIP+Ref, DIP-RWS 与本文方法) 的重建结果; 第 2 行显示对应的误差图; 第 3 行为局部放大图像

Fig. 7. Visual comparisons for Brain 2 reconstructions at the 25% sampling rate with the Cartesian undersampled mask. Row 1 display the ground truth of the target images along with reconstruction results obtained using different methods (zero-filling, CS-L1W, DIP, DIP+Ref, DIP-RWS and the proposed method). Row 2 shows the corresponding error images, and row 3 shows corresponding zoomed-in local views.

RelErr 指标对比, 由数据可知, 本文方法在两种欠采样模板下均获得了最佳量化性能. 图 8 和图 9 呈现了径向模板与变密度模板下多种方法的视觉结

果对比. 根据对应的误差图与局部放大图可知, 本文方法显然具有更优的重建性能, 能保留更完整的结构细节与特征信息.

表 4 变密度采样模板和径向采样模板下, 不同重建方法基于 Group Three 脑部扫描数据的定量指标评估
Table 4. Quantitative metric evaluations for the brain reconstructions in Group Three according to the different methods under variable density and radial undersampled masks.

目标图像	采样模板 (采样率)	重建方法	RelErr/%	PSNR/dB	SSIM	目标图像	采样模板 (采样率)	重建方法	RelErr/%	PSNR/dB	SSIM
Brain 1	径向采样模板 (20%)	零填充	8.34	29.34	0.8491	Brain 2	径向采样模板 (20%)	零填充	8.58	28.82	0.8386
		CS-L1W	6.51	31.48	0.9115			CS-L1W	6.02	31.90	0.9265
		DIP	6.18	31.93	0.9539			DIP	6.48	31.26	0.9500
		DIP+Ref	4.28	35.14	0.9778			DIP+Ref	2.79	38.56	0.9866
		DIP-RWS	3.64	36.54	0.9812			DIP-RWS	2.55	39.37	0.9887
		本文方法	3.45	36.99	0.9825			本文方法	2.26	40.42	0.9910
	变密度采样模板 (30%)	零填充	9.01	28.66	0.8353		变密度采样模板 (30%)	零填充	9.32	28.10	0.8155
		CS-L1W	6.18	31.94	0.9158			CS-L1W	5.21	33.16	0.9334
		DIP	4.38	34.92	0.9713			DIP	3.26	37.21	0.9803
		DIP+Ref	3.75	36.29	0.9784			DIP+Ref	2.75	40.27	0.9857
		DIP-RWS	3.26	37.48	0.9818			DIP-RWS	2.49	39.56	0.9873
		本文方法	3.04	38.09	0.9841			本文方法	2.08	41.14	0.9907




图 8 30% 采样率下采用变密度采样模板对 Brain 1 的重建结果对比. 第 1 行为目标图像及不同方法 (零填充, CS-L1W, DIP, DIP+Ref, DIP-RWS 与本文方法) 的重建结果; 第 2 行显示对应的误差图; 第 3 行为局部放大图像, 黄色箭头标注重建结果的细微结构

Fig. 8. Visual comparisons for Brain 1 reconstructions at the 30% sampling rate with the variable density undersampled mask. Row 1 display the ground truth of the target images along with reconstruction results obtained using different methods (zero-filling, CS-L1W, DIP, DIP+Ref, DIP-RWS and the proposed method). Row 2 shows the corresponding error images, and row 3 shows corresponding zoomed-in local views. The yellow arrows emphasize restored subtle details.

3.2.3 收敛性能分析

本文方法的收敛性分析将从两个方面展开: 一是基于参考驱动 DIP 的去噪引擎训练策略; 二是结合参考驱动 DIP 与 RED 正则化的多先验约束重建方案.

首先, 针对提出的去噪引擎训练策略进行收敛

性验证. 图 10(a) 呈现了 (4) 式中损失值随迭代次数增加而逐渐衰减的趋势. 该平滑下降曲线表明, 本文采用的参考图像驱动训练机制能够以合理的计算成本高效收敛, 获得令人满意的解.

其次, 通过实验进一步探讨基于参考驱动 DIP 与 RED 正则化的多先验约束重建方案的收敛性.




图9 20%采样率下采用径向采样模板对Brain 2的重建结果对比. 第1行为目标图像及不同方法(零填充, CS-L1W, DIP, DIP+Ref, DIP-RWS与本文方法)的重建结果; 第2行显示对应的误差图; 第3行为局部放大图像

Fig. 9. Visual comparisons for Brain 2 reconstructions at the 20% sampling rate with the radial undersampled mask. Row 1 display the ground truth of the target images along with reconstruction results obtained using different methods (zero-filling, CS-L1W, DIP, DIP+Ref, DIP-RWS and the proposed method). Row 2 shows the corresponding error images, and row 3 shows corresponding zoomed-in local views.




图10 本文提出的去噪引擎训练策略与重建方案的收敛曲线 (a) 参考驱动的去噪引擎在训练过程中的损失衰减曲线; (b) 基于参考驱动DIP与RED正则化的多先验约束重建结果的PSNR; (c) RelErr数值随迭代次数的变化曲线(未经数据校正)

Fig. 10. Convergence behavior of the proposed denoising engine training strategy and reconstruction scheme: (a) Loss decay curves of the reference-driven denoising engine during training; (b) PSNR and (c) RelErr values of the multi-prior constrained reconstruction based on reference-driven DIP and RED regularization, showing their variation with iteration numbers (without data correction).

图10(b)和图10(c)展示了相对误差(RelErr)与峰值信噪比(PSNR)在迭代过程中的变化情况(未经过数据校正). 随着ADMM迭代的推进, 重建结果趋于稳定, 相对误差逐步降至较低水平, PSNR亦同步提升至较高数值. 尽管曲线在迭代过程中存在轻微波动, 整体仍呈现出明确的收敛趋势.

4 讨论

4.1 消融性研究

本部分通过实验验证并分析本文方法中各项创新要素对提升重建性能的贡献. 以DIP框架为

基准, 依次增加参考图像(Ref)、去噪正则化(RED)、 k 空间 l_1 约束($k-l_1$)、目标图像与参考图像差异的小波域稀疏性(WaveSpar)以及 k 空间数据校正(Corr), 评估其对重建性能的影响.

基于Brain 1扫描数据的消融性实验结果如表5所列. 表中重建性能评价数值指标表明, 在参考图像、RED正则化、 k 空间和小波域先验信息以及数据校正的综合使用下, 本文方法在相对误差、PSNR和SSIM指标上均表现最佳. 移除任一要素都会导致重建质量下降, 这充分证明了本文所提重建方法中的这些核心要素对提升重建性能的重要价值.

表 5 消融实验的 RelErr, PSNR 与 SSIM 指标评估

Table 5. Quantitative evaluations on metrics of RelErr, PSNR and SSIM for ablation study.

采样模板(采样率)	DIP	Ref	RED	$k-l_1$	WaveSpar	Corr	RelErr/%	PSNR/dB	SSIM
径向采样模板(20%)	✓						6.18	31.93	0.9539
	✓	✓					4.28	35.14	0.9778
	✓		✓				6.06	32.10	0.9527
	✓	✓	✓				3.83	36.10	0.9801
	✓	✓	✓	✓			3.79	36.17	0.9799
	✓	✓	✓		✓		3.71	36.36	0.9810
	✓	✓	✓	✓	✓		3.64	36.53	0.9816
	✓	✓	✓	✓	✓	✓	3.45	36.99	0.9825
变密度采样模板(15%)	✓						7.17	30.64	0.9245
	✓	✓					5.39	33.12	0.9637
	✓		✓				6.55	31.43	0.9458
	✓	✓	✓				5.19	33.45	0.9622
	✓	✓	✓	✓			5.01	33.75	0.9649
	✓	✓	✓		✓		4.97	33.82	0.9657
	✓	✓	✓	✓	✓		4.77	34.18	0.9677
	✓	✓	✓	✓	✓	✓	4.60	34.49	0.9691




图 11 不同采样率下本文方法重建的 RelErr 与各参数的变化关系

Fig. 11. RelErr values vs. parameters for the reconstruction of our proposed method under different sampling rates.

4.2 参数评价

本部分评估了本文方法对正则化参数 (α, β, λ) 以及 ADMM 惩罚系数 μ 的敏感性. 选取 knee 6 和 Brain 1 作为测试数据, 并分别采用笛卡尔和变密度降采样模板进行重建实验. 实验中每次仅改变

一个参数, 其余参数固定不变. 图 11 展示了相对误差 (RelErr) 随各参数变化的折线图. 可以看出, 在大多数情况下, 本文所选的参数组合对应的误差最小; 各参数在不同取值下, RelErr 的差异并不显著, 表明本文方法在参数设置方面具有良好的鲁棒性.

4.3 去噪引擎分析

本部分从去噪引擎训练的迭代次数、噪声鲁棒性两个方面进行实验验证及分析。

迭代次数 本文中去噪引擎的训练基于传统DIP框架, 将其视为参考图像的去噪过程, 训练是否终止由迭代次数控制. 图12展示了不同迭代次数设置下, Group One数据集的去噪引擎训练性能.

由图12可知, 迭代次数设置为2000, 2500, 3000, 4000及5000次时, (4)式的损失值都能快速稳定收敛, 且去噪引擎的输出图像均具有良好的图像质量. 图12中第3列数据展示了相应的最终重建结果(选取Group One中一幅目标图像), 可以看出, 不同的去噪引擎训练迭代次数对最终重建结果的影响并不明显. 故而兼顾计算效率, 本文方法选定迭代次数为2000.




图12 不同迭代次数设置下的去噪引擎训练性能

Fig. 12. Denoising engine training performance with different iteration numbers.

噪声鲁棒性 本文实验所用数据均来自实际采集, 故图像本身含有噪声. 本部分为讨论去噪引擎的噪声鲁棒性, 对参考图像进一步增加噪声. 以 Group One 及 Group Three 数据集的参考图像为对象, 分别对其添加不同强度的频域噪声 (方差 σ^2 为 0.001 和 0.0001), 图 13 左侧部分展示了不同噪声水平下, 去噪引擎在迭代过程中输出的图像视觉效果. 可以看出, 在增加频域噪声情况下, 随着迭代进行, 输出图像越来越清晰并愈加接近参考图像. $\sigma^2 = 0.001$ 情况下, 输出图像仍有些许噪声. 图 13 右侧部分还展示了相应噪声水平下的最终重建得到的目标图像及评价指标数值. 可以看出, 本文方法依然可以获得与前述实验部分相当接近的重建精度, 意味着本文提出的去噪引擎训练方案对噪声具有一定程度的鲁棒性.

4.4 局限性

本文方法的一个主要局限在于, 尚未建立参考图像与目标图像之间的相似性度量与重建性能之间的量化关系. 缺乏这一理论指导, 使得参考图像的选择在当前仍依赖于经验判断. 尽管如此, 现有实验结果仍可表明, 本文方法对参考图像与目标图

像之间的相似性差异具有较高的容忍度. 从图 5 至图 9 的重建结果可以看出, 即使参考与目标图像在结构上存在一定差异, 方法仍能获得可接受的重建效果. 此外, 传统 DIP 方法在采用随机噪声作为输入时仍能实现一定程度的重建, 这进一步印证了深度图像先验本身对输入差异的不敏感性. 消融实验同时表明, 引入参考图像的结构相似性先验能够显著提升重建性能, 说明参考信息虽非严格必要, 但对高质量重建具有重要促进作用.

为进一步探究本文方法在更极端情况下的鲁棒性, 本部分补充了存在显著对比度及结构差异情况下的重建实验: 使用 T2 加权图像作为参考, 重建 T1 加权目标图像 (Brain 1 和 Brain 2). 所选取的参考图像成像参数为: T2 加权, TSE 序列, 翻转角 = 120° , TR/TE = 4000/91 ms, 层厚 = 5.0 mm. 如图 14 所示, 在笛卡尔 25% 和 35% 采样率下, 本文方法仍能获得边缘、细节及纹理保持良好的重建结果, 定量指标同样验证了其有效性. 这表明, 本文方法能够适应明显的结构及对比度差异, 具备向不同模态间重建扩展的潜力.

综上所述, 尽管参考图像与目标图像间相似性的量化关系尚待建立, 但现有实验证据表明该方法对相似性差异具有较强鲁棒性. 未来工作将重点探




图 13 参考图像添加频域噪声 ($\sigma^2 = 0.001/0.0001$) 条件下, 去噪引擎输出及相应的重建结果. 第 1 行与第 3 行: 左侧为 Group Three 数据集中参考图像训练去噪引擎的各次迭代输出结果, 右侧为该数据集中目标图像 Brain 2 的重建结果; 第 2 行与第 4 行: 左侧为 Group One 数据集中参考图像训练去噪引擎的各次迭代输出结果, 右侧为该数据集中一幅目标图像的重建结果

Fig. 13. Denoising engine outputs and corresponding reconstruction results under frequency-domain noise ($\sigma^2 = 0.001/0.0001$) addition to the reference image. Rows 1 and 3: Left panel-denoising engine outputs at various iterations trained on the reference image from Group Three; Right panel-reconstruction results of the target image Brain 2 from the same dataset. Rows 2 and 4: Left panel-denoising engine outputs at various iterations trained on the reference image from Group One; Right panel-reconstruction results of one target image from the same dataset.




图 14 本文方法在参考图像与目标图像间存在显著对比度及结构差异情况下的重建结果

Fig. 14. Reconstructions of our proposed method when there are contrast and structural differences between the reference image and the target image.

究解剖结构相似性与重建精度之间的定量关系, 并将样本拓展至其他解剖区域 (如腹部、心脏等), 以进一步验证本文方法的泛化能力.

本文方法的另一局限在于其重建耗时相较于传统 DIP 方法显著增加. 这主要源于引入去噪引擎所需的额外训练过程. 表 6 显示了笛卡尔采样模板下, 采样率分别为 20% 和 30% 时, 本文方法与对比方法的计算时间. 虽在重建时间方面, 本文方法没有显示出优势, 但是其不依赖于预训练及数据集, 并在重建精度上的显著提升, 使得其依然具有

应用价值及吸引力. 在实际应用场景 (如序列成像、动态成像等) 中, 鉴于图像序列通常具有高度相似性, 可考虑实施单次去噪引擎训练, 并用于处理多幅序列图像, 从而有效提升整体重建效率. 此外, 随着后续硬件升级和未来硬件技术的进步, 图像重建过程的计算效率有望获得进一步提升.

5 结 论

本文提出了一种基于参考驱动 DIP 与 RED 正则化的多先验约束重建方法, 通过创新算法设计提升了欠采样 MR 图像的重建质量. 该方法显著削弱了对大规模预训练数据的依赖, 构建了一个以单幅参考图像为核心驱动的两阶段重建框架: 第一阶段, 利用参考图像训练 RED 去噪引擎, 将图像结构先验引入至 RED 正则化; 第二阶段, 同一参考图像进一步引导基于 DIP 的重建过程, 并与已训练的去噪引擎协同优化, 从而在整体流程中实现结构先验的一致性与高效利用. 此外, 本文方法构建了一个集成 k 空间数据一致性、小波域结构相似性与 RED 正则化的多域协同优化模型, 从多维度对重建过程施加约束, 保障了重建结果的保真度与鲁棒性. 实验结果表明, 相较于传统 CS 及同类重建方法, 本文方法在多项定量指标上均表现出显著优势, 特别是在图像细节还原与边缘结构保持方面

表 6 笛卡尔采样下不同重建方法的计算时间
Table 6. Computational time for different reconstruction methods under the Cartesian under-sampled mask.

待重建MR图像	重建方法	计算时间	
		20%	30%
knee 1	CS-L1W	31 s	27 s
	DIP	2 min 39 s	2 min 44 s
	DIP+ref	2 min 39 s	2 min 45 s
	DIP-RWS	1 min 36 s	1 min 35 s
	本文方法	5 min 55 s	5 min 56 s
Brain 1	CS-L1W	27 s	26 s
	DIP	2 min 48 s	2 min 42 s
	DIP+ref	2 min 42 s	2 min 43 s
	DIP-RWS	1 min 37 s	1 min 36 s
	本文方法	5 min 47 s	5 min 49 s

性能优异. 本文提出的参考驱动策略与多先验融合机制, 共同提升了先验信息引入的准确性与有效性, 为克服临床 MR 数据获取困难、实现高质量快速重建提供了一条具有潜力的技术路径.

参考文献

- [1] Davenport M A, Duarte M F, Eldar Y C, Kutyniok G 2012 *Compressed Sensing: Theory and Applications* (Cambridge: Cambridge University Press) pp1–64
- [2] Lustig M, Donoho D L, Pauly J M 2007 *Magn. Reson. Med.* **58** 1182
- [3] Ophir B, Lustig M, Elad M 2011 *IEEE J. Sel. Top. Sign. Process.* **5** 1014
- [4] Qu X B, Guo D, Ning B D, Hou Y K, Lin Y L, Cai S H, Chen Z 2012 *Magn. Reson. Imaging* **30** 964
- [5] Zhan Z F, Cai J F, Guo D, Liu Y S, Chen Z, Qu X B 2016 *IEEE Trans. Biomed. Eng.* **63** 1850
- [6] Liu Q G, Wang S S, Ying L, Peng X, Zhu Y J, Liang D 2013 *IEEE Trans. Image Process.* **22** 4652
- [7] Du H Q, Lam F 2012 *Magn. Reson. Imaging* **30** 954
- [8] Lam F, Haldar J P, Liang Z P 2011 *Proceedings of IEEE International Symposium on Biomedical Imaging* Chicago, March 30–April 2, 2011 p73
- [9] Weizman L, Eldar Y C, Ben B D 2016 *Med. Phys.* **43** 5357
- [10] Han Y, Du H Q, Gao X Z, Mei W B 2017 *IET Image Process.* **11** 155
- [11] Stojnic M, Parvaresh F, Hassibi B 2009 *IEEE Trans. Signal Process.* **57** 3075
- [12] Usman M, Prieto C, Schaeffter T, Batchelor P G 2011 *Magn. Reson. Med.* **66** 1163
- [13] Xiang P C, Cai C B, Wang J C, Cai S H, Chen Z 2022 *Acta Phys. Sin.* **71** 058702 (in Chinese) [向鹏程, 蔡聪波, 王杰超, 蔡淑惠, 陈忠 2022 物理学报 **71** 058702]
- [14] Wang S S, Xiao T H, Liu Q G, Zheng H R 2021 *Biomed. Signal Process. Control* **68** 102579
- [15] Liang D, Cheng J, Ke Z W, Ying L 2020 *IEEE Signal Process. Mag.* **37** 141
- [16] Wang S S, Wu R Y, Jia S, Diakite A, Li C, Liu Q G, Zheng H R, Ying L 2024 *Magn. Reson. Med.* **92** 496
- [17] Schlemper J, Caballero J, Hajnal J V, Price A, Rueckert D 2018 *IEEE Trans. Med. Imaging* **37** 491
- [18] Wang S S, Su Z H, Ying L, Peng X, Liang D 2016 *IEEE 13th International Symposium on Biomedical Imaging (ISBI)* Prague, Czech Republic, April 13–16, 2016 p514
- [19] Akakaya M, Moeller S, Weingärtner S, Uğurbil K 2019 *Magn. Reson. Med.* **81** 439
- [20] Aggarwal H K, Mani M P, Jacob M 2019 *IEEE Trans. Med. Imaging* **38** 394
- [21] Yang Y, Sun J, Li H B, Xu Z B 2016 *Proceedings of the 30th International Conference on Neural Information Processing Systems* Barcelona, December 5–10, 2016 p10
- [22] Zhang X H, Lian Q S, Yang Y C, Su Y M 2020 *Digit. Signal Process.* **107** 102856
- [23] Zhang M H, Li M T, Zhou J J, Zhu Y J, Wang S S, Liang D, Chen Y, Liu Q G 2020 *Med. Image Anal.* **64** 101717
- [24] Ulyanov D, Vedaldi A, Lempitsky V 2018 *Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, June 18–23, 2018 p9446
- [25] Mataev G, Elad M, Milanfar P 2019 *arXiv: 1903.10176 [cs.CV]*
- [26] Sagel A, Roumy A, Guillemot C 2020 *Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Barcelona, Spain, May 4–8, 2020 p2513
- [27] Hashimoto F, Ohba H, Ote K, Teramoto A, Tsukada H 2019 *IEEE Access* **7** 96594
- [28] Veen D V, Jalal A, Soltanolkotabi M, Price E, Vishwanath S, Dimakis A G 2018 *arXiv: 1806.06438 [stat.ML]*
- [29] Baguer D O, Leuschner J, Schmidt M 2020 *Inverse Prob.* **36** 094004
- [30] Yoo J, Jin K H, Gupta H, Yerly J, Stuber M, Unser M 2021 *IEEE Trans. Med. Imaging* **40** 3337
- [31] Siedler T M, Jakob P M, Herold V 2024 *Magn. Reson. Med.* **92** 3
- [32] Liu J M, Sun Y, Eldeniz C, Gan W, Kamilov U S 2020 *IEEE J. Sel. Top. Sign. Process.* **14** 1088
- [33] Song G, Sun Y, Liu J, Wang Z, Kamilov U S 2020 *IEEE Signal Process. Lett.* **27** 451
- [34] Romano Y, Elad M, Milanfar P 2017 *SIAM J. Imaging Sci.* **10** 1804
- [35] Reehorst E T, Schniter P 2019 *IEEE Trans. Comput. Imaging* **5** 52
- [36] Sun H, Peng L, Zhang H, He Y, Cao S, Lu L 2021 *IEEE Access* **9** 52378
- [37] Sun Y, Liu J, Kamilov U S 2019 *Proceedings of Advances in Neural Information Processing Systems (NeurIPS)*, Vancouver, BC, Canada, December 8–14, 2019 p380
- [38] Wu Z, Sun Y, Liu J, Kamilov U S 2019 *Proceedings of IEEE International Conference on Computer Vision Workshops*, Seoul, Korea (South), October 27–28, 2019 p3887
- [39] Sun Y, Wohlberg B, Kamilov U S 2019 *IEEE Trans. Comput. Imaging* **5** 395
- [40] Ryu E K, Liu J, Wang S, Chen X, Wang Z, Yin W 2019 *Proceedings of 36th International Conference on Machine Learning (ICML)* Long Beach, CA, USA, June 9–15, 2019 p5546
- [41] Huang P, Zhang C, Zhang X, Li X, Dong L, Ying L 2024 *IEEE Trans. Med. Imaging* **43** 1203
- [42] Boyd S, Parikh N, Chu E, Peleato B, Eckstein J 2010 *Found. Trends Mach. Le.* **3** 1
- [43] Zbontar J, Knoll F, Sriram A, et al. 2018 *arXiv: 1811.08839 [cs.CV]*
- [44] Knoll F, Zbontar J, Sriram A, Muckley M, Bruno M, Defazio A, Parente M, Geras K, Katsnelson J, Chandarana H 2020 *Radiol- Artif Intell* **2** e190007
- [45] Zhao D, Huang Y H, Zhao F, Qin B Y, Zheng J C 2021 *Comput. Math. Methods Med.* **2021** 8865582
- [46] Wang Z, Bovik A C, Sheikh H R, Simoncelli E P 2004 *IEEE Trans. Image Process.* **13** 600

Multi-prior constrained reconstruction for undersampled magnetic resonance imaging using reference-driven deep image prior and regularization by denoising^{*}

ZHAO Di¹⁾²⁾ LAO Huan¹⁾ BAI Fengbo^{1)†} XU Chen¹⁾

1) (*School of Artificial Intelligence, Guangxi Minzu University, Nanning 530006, China*)

2) (*Guangxi Key Laboratory of Hybrid Computation and IC Design Analysis, Nanning 530006, China*)

(Received 4 February 2026; revised manuscript received 5 May 2026)

Abstract

Magnetic Resonance Imaging (MRI) has limited applications in clinical scenarios, particularly in dynamic imaging and interventional surgery, due to its long data collection time. Compressed sensing (CS) theory can shorten MRI scan time by undersampling k -space data, but the reconstruction quality is highly dependent on effective prior constraints. In recent years, deep learning methods have shown excellent performance in MR image reconstruction; however, their performance usually depends on large-scale, high-quality clinical training datasets, while obtaining clinical data is often difficult in practice. To address this challenge, we propose a multi-prior constrained reconstruction method for undersampled MRI using reference-driven deep image prior (DIP) and regularization by denoising (RED). A key advantage of our method is its independence from large pre-trained datasets; instead, the entire reconstruction is guided by only a single reference image, offering a low-data-dependency pathway for undersampled MRI reconstruction.

The proposed method capitalizes on the structural similarity between the reference and target images, constructing a two-stage process core-driven by a single reference image. In the first stage, the denoising engine within the RED is trained using the reference image, thereby embedding structural priors into the RED regularization. In the second stage, the same reference image guides the DIP-based reconstruction. A multi-prior collaborative optimization model is designed by combining k -space data consistency constraints, wavelet domain structural similarity constraints, and RED regularization. By optimizing the network parameters in this model, high-quality reconstruction from undersampled data is achieved. This design allows the same reference image to drive both the RED denoising engine training and the DIP-based learning, ensuring consistent and efficient utilization of structural priors throughout the workflow. The integration of multi-domain priors, which span k -space, wavelet, and image domains, enables collaborative optimization from multiple dimensions and thus further enhances reconstruction performance.

Experimental results show that the proposed method surpasses existing comparable techniques in both visual assessment and quantitative metrics, more accurately recovering tissue details and edge structures. Importantly, it substantially reduces reliance on large-scale pre-training data. Through the reference-driven strategy and multi-prior fusion mechanism, this method jointly improves the accuracy and effectiveness of prior incorporation, ensuring reconstruction fidelity and robustness. In summary, this work presents a promising technical pathway to overcome the challenges of clinical MR data acquisition and achieve high-quality reconstruction.

Keywords: magnetic resonance imaging, deep image prior, regularization by denoising, multi-prior constrained

DOI: [10.7498/aps.75.20260203](https://doi.org/10.7498/aps.75.20260203)

CSTR: [32037.14.aps.75.20260203](https://cstr.cn/32037.14.aps.75.20260203)

^{*} Project supported by the Scientific Research Start-up Project for Introduced Talents of Guangxi Minzu University, China (Grant No. 2023KJQD27), the Guangxi Natural Science Foundation, China (Grant No. 2021GXNSFBA220056), and the Guangxi Key Research and Development Program, China (Grant No. FN2504240031).

[†] Corresponding author. E-mail: baif@gxmzu.edu.cn

基于参考驱动深度图像先验与去噪正则化的多先验约束欠采样磁共振图像重建

赵地 劳欢 白凤波 徐晨

Multi-prior constrained reconstruction for undersampled magnetic resonance imaging using reference-driven deep image prior and regularization by denoising

ZHAO Di LAO Huan BAI Fengbo XU Chen

引用信息 Citation: *Acta Physica Sinica*, 75, 180302 (2026) DOI: 10.7498/aps.75.20260203

CSTR: 32037.14.aps.75.20260203

在线阅读 View online: <https://doi.org/10.7498/aps.75.20260203>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

您可能感兴趣的其他文章

Articles you may be interested in

基于支撑先验与深度图像先验的无预训练磁共振图像重建方法

Undersampled magnetic resonance image reconstruction based on support prior and deep image prior without pre-training

物理学报. 2022, 71(5): 058701 <https://doi.org/10.7498/aps.71.20211761>

基于深度神经网络的时空编码磁共振成像超分辨率重建方法

Super-resolved reconstruction method for spatiotemporally encoded magnetic resonance imaging based on deep neural network

物理学报. 2022, 71(5): 058702 <https://doi.org/10.7498/aps.71.20211754>

近零场磁共振与超极化技术

Near-zero-field nuclear magnetic resonance and hyperpolarization technology

物理学报. 2025, 74(21): 218701 <https://doi.org/10.7498/aps.74.20250771>

水分子跨细胞膜交换的磁共振测量技术研究进展

Research progress of magnetic resonance measurements of transcytolemmal water exchange

物理学报. 2025, 74(11): 118702 <https://doi.org/10.7498/aps.74.20250325>

基于偏振的暗通道先验去雾

Polarization-based research on a priori defogging of dark channel

物理学报. 2022, 71(14): 144202 <https://doi.org/10.7498/aps.71.20220332>

超高场磁共振成像的现状和展望

Current status and perspectives of ultrahigh-field magnetic resonance imaging

物理学报. 2025, 74(7): 078701 <https://doi.org/10.7498/aps.74.20241759>