

DOI:10.11918/202309074

基于双域 N2N 和注意力的无监督磁共振成像重建

段继忠, 陈盛毅

(昆明理工大学 信息工程与自动化学院, 昆明 650504)

摘要: 为解决目前大部分重建磁共振成像(MRI)的深度学习方法依赖于大量完全采样的数据集进行训练的问题,提出一种包含注意力机制的无监督双域 N2N 网络(DN2NA)进行并行 MRI 重建,提出的 DN2NA 网络不需要额外的训练数据,即可直接对欠采样的 k 空间数据进行重建。具体而言,在 N2N 网络中加入复数卷积和通道注意力机制,构建一个基础无监督网络 N2NA,同时加入两个物理先验提高频域(k 空间)N2NA 网络的性能,再将频域 N2NA 网络与图像域 N2NA 网络级联成双域网络 DN2NA,这种组合方法充分结合了频域和图像域网络的优势。由于在实际应用场景中没有真实数据作为参考,还采用了一种提前停止方法来避免过拟合和提高稳定性。在膝盖和大脑共 3 个数据集上进行的实验表明,相比现有的无监督网络 IUNN 和 KUNN, DN2NA 网络拥有更高的 PSNR 值和 SSIM 值以及更低的 HFEN 值和 STD 值,这表明 DN2NA 网络重建质量更好,多次重复重建结果也更稳定。与有监督网络 MICCAN 相比, DN2NA 网络也展现了相似或者更优的性能。

关键词: 磁共振成像;深度学习;无监督网络;零样本;提取停止准则

中图分类号: TP391

文献标志码: A

文章编号: 0367-6234(2025)10-0143-11

Unsupervised magnetic resonance imaging reconstruction based on dual-domain N2N and attention mechanisms

DUAN Jizhong, CHEN Shengyi

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

Abstract: To address the reliance of most deep learning methods for magnetic resonance (MR) imaging (MRI) reconstruction on extensive fully-sampled datasets for training, this study proposes an unsupervised dual-domain N2N network with attention mechanisms (DN2NA) for parallel MRI reconstruction. The proposed DN2NA network can directly reconstruct undersampled k-space data without requiring additional training data. Specifically, we integrate complex-valued convolution and channel attention mechanism into the N2N framework to construct a baseline unsupervised network N2NA. Two physical priors are incorporated to enhance the performance of the frequency-domain (k-space) N2NA network, which is then cascaded with an image-domain N2NA network to form the dual-domain DN2NA architecture. This combination effectively leverages the complementary advantages of frequency-domain and image-domain networks. Given the absence of ground-truth references in practical scenarios, an early-stopping strategy is adopted to prevent overfitting and improve stability. Experiments conducted on three knee and brain datasets demonstrate that DN2NA achieves higher PSNR and SSIM, along with lower HFEN and STD compared to existing unsupervised networks (IUNN and KUNN), indicating superior reconstruction quality and stability in repeated reconstructions. Furthermore, DN2NA exhibits comparable or better performance than the supervised network MICCAN.

Keywords: magnetic resonance imaging; deep learning; unsupervised neural network; zero-shot; early stopping criterion

磁共振成像(magnetic resonance imaging, MRI)因其无创、无电离辐射、软组织对比度高等优点,成为一种应用广泛的医学成像技术。然而,采集 MR 信号的速度受到成像对象心理上的限制或者成像设备物理上的约束。因此,如何加快 MR 信号的采集

速度是当前研究热点。欠采样和并行成像是提高 MRI 采集速度的有效方法。根据压缩感知(compressed sensing, CS)理论^[1-3],由于 MR 图像具有稀疏性,可以利用非线性优化方法从高度欠采样的 k 空间数据中重建 MR 图像。并行成像利用多个

收稿日期: 2023-09-28; 录用日期: 2023-12-13; 网络首发日期: 2024-06-24

网络首发地址: <https://link.cnki.net/urlid/23.1235.t.20240622.1018.009>

基金项目: 国家自然科学基金(61861023); 云南省基础研究计划(202301AT070452)

作者简介: 段继忠(1984—),男,副教授,硕士生导师

通信作者: 段继忠, duanjz@kust.edu.cn

阵列接收器的空间灵敏度来加快 MRI 的采集^[4-6]。

随着深度学习在计算机视觉领域展现出极强的能力,一些研究人员提出使用深度学习模型从欠采样 k 空间数据重建并行 MR 图像。具体来说, Hammernik 等^[7]从全采样的多线圈 k 空间数据中训练了一个用于并行 MRI 重建的变分网络。Aggarwal 等^[8]提出了一种基于深度学习先验的重构框架,该框架包含数据一致性 (data consistency, DC) 并学习卷积神经网络 (convolution neural network, CNN) 来捕获图像的冗余信息。Sriram 等^[9]提出了一种用于并行 MRI 重建的端到端变分网络 (VarNet)。Lu 等^[10]设计了一种受稀疏迭代重构启发的网络结构,并且使用了残差结构。由于 MR 图像和 k 空间数据本质上是复值的^[11], Wang 等^[12]提出了复值 CNN 模型 deepcomplex 进行并行 MRI 重建。Feng 等^[13]基于 deepcomplex 提出了一种将 MR 数据分为高频和低频分量处理的双阶卷积网络 DONet。Huang 等^[14]提出了 MICCAN 网络,该模型将注意力机制应用到了 U-Net 中。Lehtinen 等^[15]提出了 Noise2Noise (N2N) 网络,从有噪声的图像中去除噪声,从欠采样 k 空间数据中重建 MR 图像。

这些基于深度学习的方法依赖于完全采样的 MR 数据的大型数据库来训练 CNN。然而,在某些情况下,获取完全采样的 k 空间数据很困难,有时甚至不可行。Yaman 等^[16]提出了一种通过欠采样数据进行物理引导深度学习重建的自监督学习方法 (SSDU),该方法将可用的欠采样测量值划分为两个不相交的集合,一个用于数据一致性,另一个用于定义训练损失。SSDU 只需要欠采样的 k 空间数据集就能训练。Peng 等^[17]提出了一种新的 Hankel- k -space 生成模型 (Hankel- k -space generative model, HKGM),该模型仅从一个完全采样的 k 空间数据学习并生成样本。此外,一些研究人员提出了在没有任何外部训练数据集的情况下重建 MRI 的方法。Darestani 等^[18]提出了一种基于深度解码器变体的图像域未训练神经网络 (image domain untrained neural network, IUNN),用于加速 MRI 重建。Cui 等^[19]提出了一种 k 空间未训练神经网络 (k -space interpolation with untrained neural network, KUNN),用于频域的 MRI 重构,该网络采用三重结构,由 3 个物理先验 (变换稀疏性、线圈灵敏度平滑性和相位平滑性) 驱动。由于 KUNN 和 IUNN 使用随机的低维变量作为输入,并直接选择固定的轮次进行训练,无法保证稳定的重构。Yaman^[20]提出了一种称为 zero-shot SSDU (ZS-SSDU) 的方法,该方法不依赖于任何外部训练数据集,但该方法需要显式使用线圈灵敏度信息,该信息通常需要全采样的自校准信

号 (auto-calibration signal, ACS) 进行估计,这会造成加速比的降低。

为了提高无监督网络性能,提出一种基于双域 N2N 网络和注意力机制的零样本无监督 MR 图像重建网络 (DN2NA),所提出的网络无需任何外部训练数据集即可进行并行 MRI 重建。具体地,在编码器-解码器形式的 N2N 网络中加入了复数卷积和通道注意力机制,设计了 N2NA 网络。对于在频域进行重建的 k 空间 N2NA (k -space domain N2N with attention mechanism, KN2NA) 网络,额外加入了相位平滑和线圈灵敏度平滑两个物理先验来提高重建性能。将带有物理先验的 k 空间 N2NA 网络 (k -space N2N with attention mechanism and physical prior, KN2NAP) 的重建结果输入到图像域 N2NA 网络 (image domain N2N with attention mechanism, IN2NA) 进行下一步的重建,设计了频域-图像域形式的双域网络 DN2NA。同时在 DN2NA 模型中加入提前停止准则,使 DN2NA 网络在过拟合时可自动停止,从而提升网络的稳定性。

1 模型与方法

1.1 DN2NA

并行磁共振成像模型可以表示为

$$y_i = \mathbf{R}\hat{\mathbf{x}}_i + \mathbf{n}_i \quad (1)$$

式中: $\hat{\mathbf{x}}_i = \mathbf{F}\mathbf{x}_i \in \mathbf{C}^N$, $\hat{\mathbf{x}} = [\hat{\mathbf{x}}_1, \dots, \hat{\mathbf{x}}_C] \in \mathbf{C}^{N \times C}$ 为全采样的多线圈 k 空间数据, $\mathbf{x}_i = \mathbf{S}_i\mathbf{z} \in \mathbf{C}^N$, $\mathbf{x} = [\mathbf{x}_1, \dots, \mathbf{x}_C] \in \mathbf{C}^{N \times C}$ 为多线圈图像, $\mathbf{z} \in \mathbf{C}^N$ 为待重建目标图像, $N = n \times n$, $\mathbf{y}_i \in \mathbf{C}^M$ 为第 i 个线圈欠采样 k 空间数据, $\mathbf{y} = [\mathbf{y}_1, \dots, \mathbf{y}_C] \in \mathbf{C}^{M \times C}$ 为多线圈 k 空间数据, \mathbf{F} 为傅里叶变换, 对角矩阵 \mathbf{S}_i 为第 i 个线圈灵敏度信息, \mathbf{n}_i 表示第 i 个线圈的噪声, $\mathbf{R} \in \mathbf{R}^{M \times N}$ 表示单线圈欠采样矩阵, 其行由 $N \times N$ 的单位矩阵 \mathbf{I}_N 的行构成, 将 \mathbf{I}_N 的这些行编号组成 \mathbf{R} 的下标集合 R_{ind} , M 表示单个线圈欠采样 k 空间数据的数量。

对于带有物理先验的 KN2NA 网络 (即 KN2NAP), 采用虚拟共轭线圈 (virtual conjugate coils, VCC) 技术^[21]将其并入相位先验中, 于是重建模型可写成:

$$\min_{z, \mathcal{S}, \varphi} \sum_{i=1}^C \|\mathbf{RFS}_i\mathbf{z} - \mathbf{y}_i\|^2 + \sum_{i=1}^C \|\overline{\mathbf{R}}\mathbf{F}(\mathbf{S}_i^* \mathbf{z} e^{-j2\varphi}) - \mathbf{y}'_i\|^2 \quad (2)$$

式中: $\mathbf{y}' = \overline{\mathbf{y}}^*$, $(\cdot)^*$ 表示复数的共轭, $\overline{\mathbf{y}}$ 表示 \mathbf{y} 的翻转, 使得 $\overline{\mathbf{y}}(i) = \mathbf{y}(-i)$ 。

利用卷积定理, 以上最优化问题可以转换为如下形式:

$$\min_{z, S, \varphi} \sum_{i=1}^C \| \mathbf{R}(\hat{z} \otimes \hat{S}_i) - \mathbf{y}_i \|_2^2 + \sum_{i=1}^C \| \bar{\mathbf{R}}(\hat{z} \otimes e^{-j2\varphi} \otimes \hat{S}_i^*) - \mathbf{y}'_i \|_2^2 \quad (3)$$

式中: \otimes 表示卷积; \hat{z} 通过 KN2NA 网络实现, 即 $\hat{z} = \text{KN2NA}_\theta(\mathbf{Y})$; θ 为 KN2NA 网络的参数。N2NA 网络的结构如图 1 所示, 在 KN2NA 网络中 $\chi = 2$ 。




图 1 加入了通道注意力和复数卷积的 N2N 网络 (N2NA) 结构

Fig. 1 Architecture of N2N network with channel attention and complex convolution (N2NA)

同时, 考虑到 MRI 的相位 φ 和线圈灵敏度 S_i 在图像域具有平滑特性, 从而在 k 空间域具有紧支撑先验, 与 KUNN^[19] 类似, 使用具有小尺寸输出的基于解码器结构的 UNN 网络生成 $\eta = \{\hat{S}_i\} = \text{UNN}_\varepsilon(\mathbf{p})$

和 $\zeta = e^{-j2\varphi} = \text{UNN}_\delta(\mathbf{q})$, 其中, \mathbf{p}, \mathbf{q} 是大小为 $[1, 2, 3, 3]$ 的低维随机变量, ε, δ 为 UNN 网络的参数, UNN 网络结构如图 2 所示。




图 2 UNN 网络的结构

Fig. 2 Structure of the UNN network

于是 KN2NAP 优化问题可以转化成如下紧凑形式:

$$\min_{\theta, \varepsilon, \delta} L(\mathbf{Y}, \mathbf{p}, \mathbf{q}) = \| \check{\mathbf{R}} \Psi_{\theta, \varepsilon, \delta}(\mathbf{Y}, \mathbf{p}, \mathbf{q}) - \mathbf{Y} \|_F^2 \quad (4)$$

其中, $\Psi_{\theta, \varepsilon, \delta}(\mathbf{Y}, \mathbf{p}, \mathbf{q}) = [\text{KN2NA}_\theta(\mathbf{Y}) \otimes \text{UNN}_\varepsilon(\mathbf{p}), \text{KN2NA}_\theta(\mathbf{Y}) \otimes \text{UNN}_\delta(\mathbf{q}) \otimes \text{UNN}_\varepsilon^*(\mathbf{p})]$ 表示 KN2NAP 网络重建得到的多线圈 k 空间数据, $\mathbf{Y} = [\mathbf{y}, \mathbf{y}'] \in \mathbf{C}^{N \times 2C}$, $\mathbf{y}' = \bar{\mathbf{y}}^*$, $\check{\mathbf{R}}([\mathbf{y}, \mathbf{y}']) = [\mathbf{R}\mathbf{y}_1, \dots, \mathbf{R}\mathbf{y}_c, \bar{\mathbf{R}}\mathbf{y}'_1, \dots, \bar{\mathbf{R}}\mathbf{y}'_c]$ 。

频域网络 KN2NPA 和图像域网络 IN2NA 级联成双域网络 DN2NA, 具体地, KN2NAP 网络的重建结果作为 IN2NA 网络的输入进行进一步的重建。双域网络 DN2NA 的优化问题写成如下形式:

$$\min_{\sigma, \theta, \varepsilon, \delta} L(\mathbf{Y}, \mathbf{p}, \mathbf{q}) =$$

$$\| \check{\mathbf{R}} \mathbf{F}(\text{IN2NA}_\sigma(\mathbf{F}^{-1}(\text{DC}(\Psi_{\theta, \varepsilon, \delta}(\mathbf{Y}, \mathbf{p}, \mathbf{q})))) - \mathbf{Y} \|_F^2 \quad (5)$$

其中, $\text{DC}(\cdot)$ 表示 DC 操作 (定义见第 1.5 节), σ 为 IN2NA 网络的参数, N2NA 网络结构如图 1 所示, 在 IN2NA 网络中 $\chi = 4C$ 。

双域网络 DN2NA 的结构如图 3 所示。欠采样的 k 空间数据在经 KN2NAP 网络重建后进行 DC 操作, 再通过傅里叶反变换将重建的频域数据转化为图像域数据。图像域数据通过 IN2NA 网络进一步重建后, 经傅里叶变换得到频域数据, 再与原始的欠

采样 k 空间数据计算训练损失和验证损失,其中,训练损失用来训练网络参数,验证损失用来判断网络的提前停止。在网络判断停止后,整个 DN2NA 网

络重建的频域数据(即 k 空间数据)再进行 DC 操作、傅里叶反变换和平方和的平方根(square root of sum of squares, SOS)操作即可得到图像域的输出。

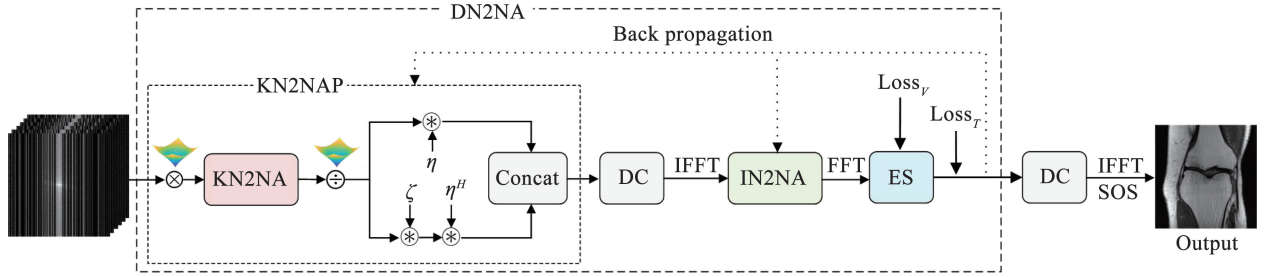


图 3 DN2NA 网络的结构

Fig. 3 Structure of the KN2N network

1.2 提前停止准则(ES)

在实际应用中,由于无监督网络没有可用的真实图像信息,网络无法根据峰值信噪比(peak signal to noise ratio, PSNR)判断什么时候停止训练。尽管损失函数(loss function)会随着网络的训练持续下降,但当达到临界点之后,网络开始过拟合(即重建质量开始降低)。之前的工作^[18-19]直接选择固定的迭代次数,但是在临床应用中,采集到的 MR 数据是多变且未知的,使用固定的迭代次数不能保证稳定的重建质量,也会浪费计算资源。在 ZS-SSDU^[20]一文中,作者将采样轨迹划分为 training mask, loss mask, validation mask 共 3 部分,其中, validation mask 用来判断网络是否过拟合。受此启发,将原始 mask 进行划分,选择一个区域用于判断过拟合,从而使我们的网络可以自己判断什么时候停止。

将下标集 R_{ind} 分为不相交的两部分 T_{ind} 和 V_{ind} , 即

$$\begin{cases} T_{ind} \cup V_{ind} = R_{ind} \\ T_{ind} \cap V_{ind} = \emptyset \end{cases} \quad (6)$$

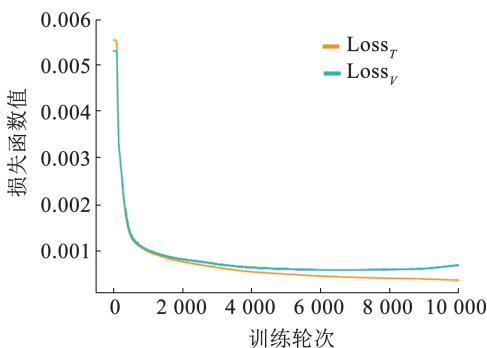
T 、 V 分别表示由下标集 T_{ind} 、 V_{ind} 指定的欠采样矩阵, T 用于训练, V 用于验证。这时, KN2NAP 网络的输入由 Y 变为 $\check{T}Y$ (因为利用 T 对 y 进行了重新采样), 再分别计算两部分的损失:

$$Loss_T = \|\check{T}\Psi_{\theta, \epsilon, \delta}(Y, p, q) - \check{T}Y\|_F^2 \quad (7)$$

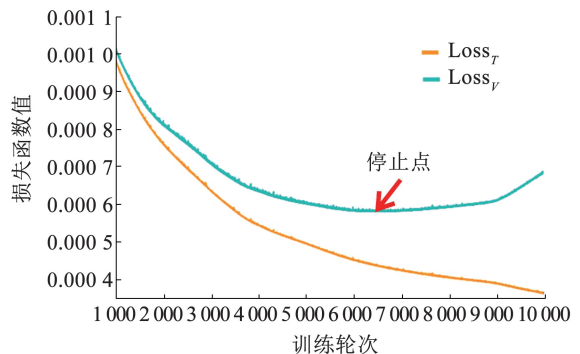
$$Loss_V = \|\check{V}\Psi_{\theta, \epsilon, \delta}(Y, p, q) - \check{V}Y\|_F^2 \quad (8)$$

$Loss_T$ 为训练的损失函数, 用于优化网络、更新网络的参数, $Loss_V$ 用于判断网络是否过拟合。当 $Loss_V$ 由下降转为上升时, 网络过拟合, 停止训练, 保存网络的重建输出。其中, 验证区域占全部采样区域的比例为 $|V_{ind}|/|R_{ind}| = 0.1$ 。

如图 4 所示, 通过判断验证损失是否上升来寻找网络的停止点, 可以看出, 训练损失随着 epoch 的增加一直降低, 但验证损失在达到最低点后开始上升。可以认为此时网络已经学习到了一组较好的参数, 如果继续学习, 网络可能会过拟合, 继而降低图像重建的质量。



(a) 全景图



(b) 局部放大图

图 4 DN2NA 网络在加速倍率为 3 的 RADU 采样模式下的的大脑数据的训练损失和验证损失

Fig. 4 Training and validation loss of DN2NA on brain data with RADU at AF = 3

1.3 通道注意力机制

在多线圈数据中, 受线圈灵敏度的影响, 每个线圈包含的数据并不相同。在神经网络中多线圈数据

将按照多通道数据进行处理。通道注意力机制通过平均池化来量化多通道数据中单个通道拥有的信息量, 并通过卷积-激活-卷积的形式来调整所有通

道之间的权重。通道注意力机制可以为包含更多信息的通道赋予更大的权重, 更大的权重意味着在训练的过程中会更多地对这部分进行优化, 使重建图的质量得到提升。通道注意力机制模块的结构见图 5。




图 5 通道注意力机制结构

Fig. 5 Structure of the channel attention mechanism

1.4 复数卷积

在 MRI 重建中, 大多方法都是将 MR 数据的实部和虚部分开, 分别使用实值卷积处理实部和虚部。为了避免信息丢失, Wang 等^[12] 提出使用复数卷积来处理复值输入。复数数据 $V = V_r + jV_i$ 和具有复数权重的卷积核 $K = K_r + jK_i$ 进行复数卷积的过程可以表示为

$$K \otimes V = (K_r \otimes V_r - K_i \otimes V_i) + j(K_r \otimes V_i + K_i \otimes V_r) \quad (9)$$

其中, K_r, K_i, V_r, V_i 均为实数矩阵。

复数卷积被应用到了 KN2NAP 和 IN2NA 中。在 2.4 节设计了消融实验, 来证明通道注意力机制和复数卷积的加入对 N2N 网络造成的影响。

1.5 数据一致性 (DC) 操作

如图 3 所示, KN2NAP 网络的最后一步是进行 k 空间数据的数据一致性 (DC) 操作, IN2NA 网络在频域进行训练损失和验证损失的计算后也会进行 DC 操作。设 DC 操作前的数据为 $\hat{x} \in \mathbf{C}^{2NC}$, 则 DC 操作后变成

$$\tilde{x} = \text{DC}(\hat{x}) = \tilde{R}_c^T \tilde{R}_c \hat{x} + \tilde{R}^T Y \quad (10)$$

\tilde{R}_c 为 k 空间数据中未采样的点。将 \tilde{x} 进行傅里叶反变换之后, 即 $x = F^{-1} \tilde{x}$, 再对前 C 个线圈 (由于使用了 VCC 技术, 后 C 个线圈为虚拟线圈, 不予考虑) 通过 SOS 操作可以组合成单线圈幅度图像 X, 即

$$X = \text{SOS}(x) = \sqrt{\sum_{i=1}^C |x_i|^2} \quad (11)$$

2 实验及结果分析

2.1 实验数据

2.1.1 膝盖数据

膝盖数据选择的是公开数据集 NYULH Radiology-Reconstruction-Data^[7], 该数据集使用临床 3T 系统 (Siemens Magnetom Skyra) 对不同的成像受试者进行膝盖部位全采样, 该数据集由 5 个 2D 涡轮自旋回波 (turbo spin-echo, TSE) 序列组成。每个

序列包含 20 位不同成像受试者的数据。本实验选择冠状面质子密度加权序列, 序列参数: 重复时间 (repetition time, TR) 为 2 750 ms, 回波时间 (echo time, TE) 为 27 ms, 平面分辨率为 $0.49 \times 0.36 \text{ mm}^2$ 。在对比的有监督网络中, 选取其中 14 个成像受试者的数据作为训练集, 3 个成像受试者的数据作为验证集, 3 个成像受试者的数据为测试集。每个成像受试者选择中间的 20 个切片, 并将数据裁剪或填充为 320×320 , 每个切片为 15 通道, 即每个实验样本大小为 $320 \times 320 \times 15$ 。对于无监督网络, 随机选取测试集中的一个数据进行重建, 无需额外的训练集。

2.1.2 SIAT 大脑数据

SIAT 大脑数据由中国科学院深圳先进技术研究院提供。该数据集使用 3T 系统 (SIEMENS MAGNETOM Trio Tim) 对 500 名受试者进行大脑部位全采样, 全采样的二维复值 MR 数据从 T2 加权的 3D 涡轮自旋回波序列中获取。参数如下: 平面分辨率为 $220 \times 220 \text{ mm}^2$, 回波时间 TE 为 149 ms, 重复时间 TR 为 2 500 ms, 线圈数为 12。在对比的有监督网络中, 选择 340 个成像受试者的数据作为训练集, 80 个成像受试者的数据作为验证集, 80 个成像受试者的数据作为测试集, 将数据裁剪为 256×256 , 即每个实验样本大小为 $256 \times 256 \times 12$ 。对于无监督网络, 随机选取测试集中的一个数据进行重建, 无需额外的训练集。

2.1.3 NYUfastMRI 大脑数据

NYU fastMRI^[22] 数据集由纽约大学和 Langone 健康中心提供, 该数据集是在 3T 西门子扫描仪上使用 20 通道接收线圈和 2D 涡轮自旋回波序列获得的。参数如下: 平面分辨率为 $220 \times 220 \text{ mm}^2$, 回波时间 TE 为 113 ms, 重复时间 TR 为 6 000 ms。选择其中的多线圈大脑数据进行实验。在对比的有监督网络中, 选取 70 个成像受试者的数据作为训练集, 20 个成像受试者的数据为验证集, 20 个成像受试者的数据为测试集。每个成像受试者选择前 4 个切片, 并将数据裁剪为 384×384 , 每个切片 20 个通道, 即每个实验样本大小为 $384 \times 384 \times 20$ 。对于无监督网络, 随机选取测试集中的一个数据进行重建, 无需额外的训练集。

2.2 实验设置

为了评估提出的 DN2NA 网络的性能, 选择了不同的采样轨迹进行欠采样模拟。选择的欠采样掩码为: 一维随机欠采样 (one-dimensional random undersampling pattern, 1DRU), 二维泊松圆盘欠采样 (two-dimensional Poisson-disc undersampling pattern, 2DPU), 二维随机欠采样 (two-dimensional random

undersampling pattern, 2DRU) 和伪径向欠采样 (pseudo radial undersampling pattern, RADU)。选用了经典的未训练网络 IUNN 和最新的在 k 空间重建的未训练网络 KUNN 进行对比,以探究 DN2NA 网络与其他无监督网络之间的性能差异。此外,选用了带有通道注意力机制的有监督网络 MICCAN 进行对比,以探究 DN2NA 网络与有监督网络之间的性能差异。

选择峰值信噪比 (peak signal to noise ratio, PSNR)、结构相似性 (structural similarity, SSIM) 和高频误差范数 (high frequency error norm, HFEN) 作为评价指标。其中,PSNR 和 SSIM 的数值越高代表重建质量越好, HFEN 的数值越低代表重建质量越好。需要强调的是,对无监督的网络均进行 10 次重复实验,每个评价指标都是取 10 次结果的平均值。额外加入了 10 次重建结果的 PSNR 值的标准差 (standard deviation, STD) 作为评价无监督网络稳定性的指标,STD 越低代表重建的质量越稳定。选择 ADAM 优化器对损失函数式进行优化,参数设置为 $\beta_1 = 0.9, \beta_2 = 0.999$,学习率为 1×10^{-4} 。实验在配

置为 Intel Core i9-12900K @ 3.2 GHz CPU, NVIDIA RTX 3090 (24 GB 显存) GPU, 64 GB 内存, 64 位 Ubuntu 20.04 操作系统的服务器上完成。

2.3 实验结果

在膝盖数据集、SIAT 大脑数据集和 NYU fastMRI 大脑数据集上进行了实验。表 1~3 给出了所有网络在不同的采样模式以及不同加速因子下的膝盖数据大脑数据重建图像的评价指标。最好的结果标记为红色,第二好的结果标记为蓝色。

图 6~10 可视化地展示了 4 种网络 (MICCAN^[14]、IUNN^[18]、KUNN^[19]、DN2NA) 的重建结果。每组图有 3 列,第 1 列为 4 种不同网络的重建图,左下角为局部放大图,右下角为重建图的评价指标;第 2 列为误差图,左下角为局部放大图,右下角为色标;第 3 列为方差图,右下角为色标,其中,只有无监督网络有方差图。

从图 6 的误差图可以看出,不同于 MICCAN 和 KUNN 重建结果有大块高误差区域, DN2NA 和 IUNN 的误差值更小,同时,与 IUNN 相比, DN2NA 误差的区域更少,拥有更加丰富的细节。




图 6 膝盖数据在加速倍率为 3 的 2DPU 模式下 4 种网络的重建结果对比

Fig. 6 Comparison of reconstruction results for four different networks on knee data using 2DPU with acceleration factor of 3

由图 7 可以看出, MICCAN 出现了明显的条状伪影,表现不佳。与 IUNN 和 KUNN 相比, DN2NA 在关节连接处重建误差更小。

由图 8 的误差图可以看出, DN2NA 的重建误差比对比网络小得多。

由图 9 可以看出, IUNN 和 MICCAN 都没有提供好的重建结果,而 KUNN 和 DN2NA 表现更好。但是 KUNN 网络的重建图出现了两块明显的误差区域,这两个区域亮度较低,在实际场景中会影响医

生的判断。同时观察方差图可以看出, KUNN 在其他几次重建中仍然出现了明显误差区域。 DN2NA 在此场景下展现了更多的细节。

由图 10 可以看出, MICCAN 在平坦区域重建误差更小 (SSIM 值更大),而在大脑沟回和头骨等细节区域的重建误差非常大,这种情况对于临床诊断来说十分不利。相比之下, DN2NA 在大脑沟回和头骨等细节区域的重建误差明显减小,表现出更高的 PSNR 值和更低的 HFEN 值。

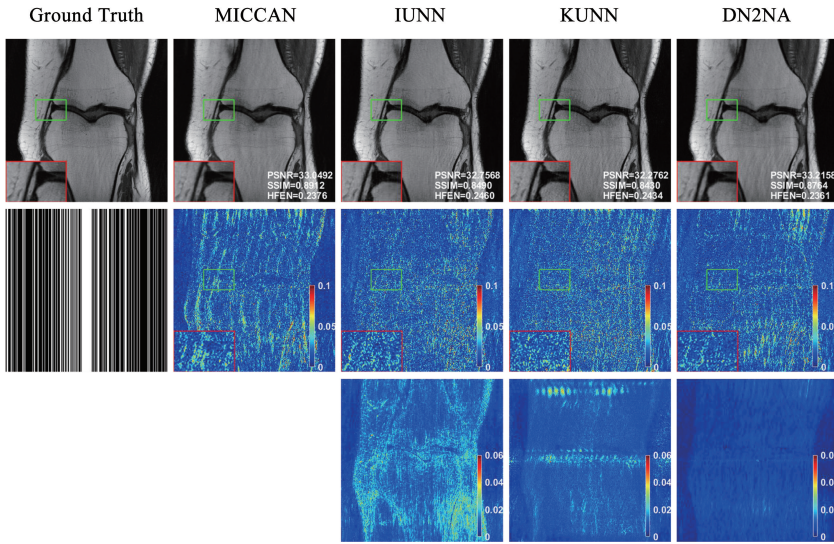


图 7 膝盖数据在加速倍率为 3 的 1DRU 模式下 4 种网络的重建结果对比

Fig. 7 Comparison of reconstruction results for four different networks on knee data using 1DRU with acceleration factor of 3

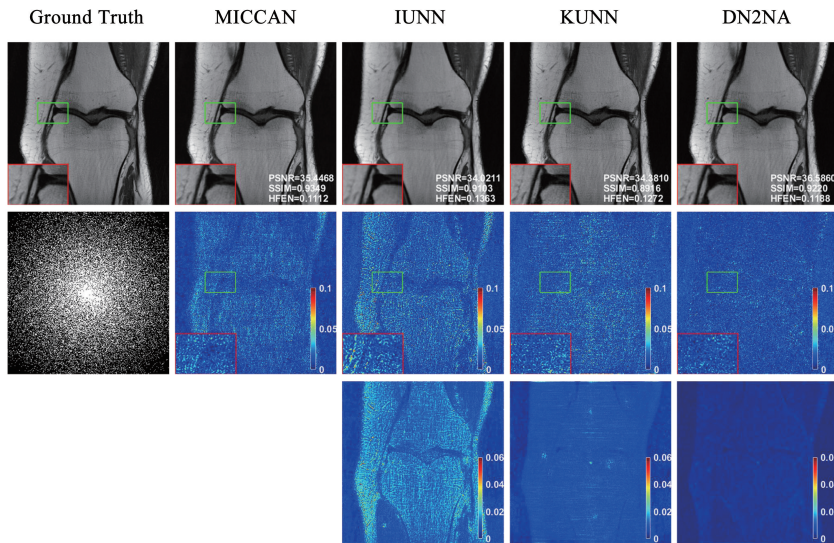


图 8 膝盖数据在加速倍率为 3 的 2DRU 模式下 4 种网络的重建结果对比

Fig. 8 Comparison of reconstruction results for four different networks on knee data using 2DRU with acceleration factor of 3

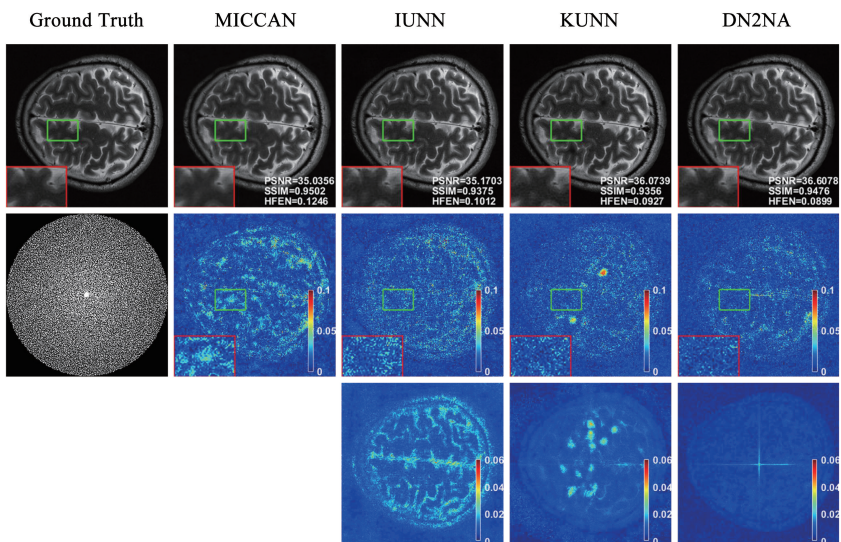


图 9 SIAT 大脑数据在加速倍率为 3 的 2DPU 模式下 4 种网络的重建结果对比

Fig. 9 Comparison of reconstruction results for four different networks on SIAT brain data using 2DPU with acceleration factor of 3

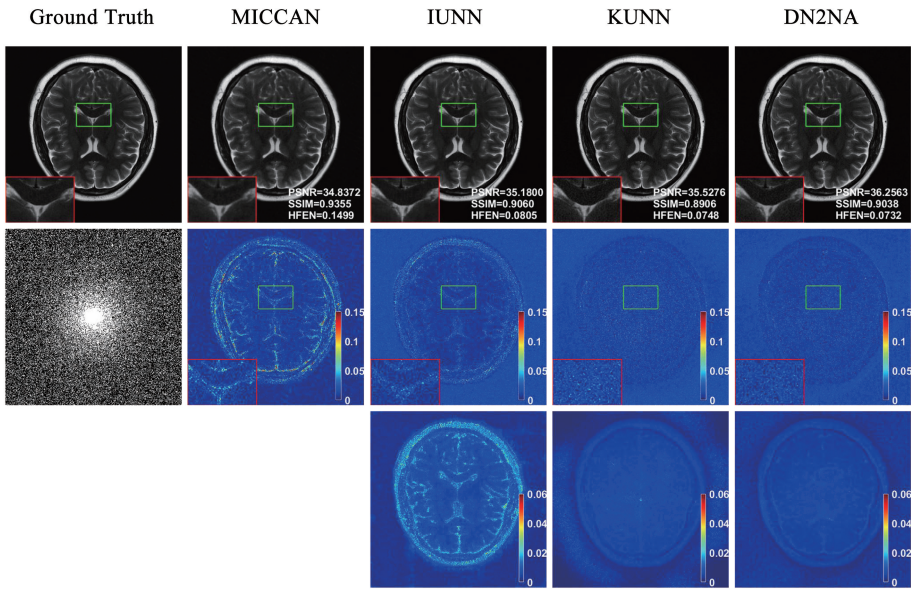


图 10 NYU fastMRI 大脑数据在加速倍率为 3 的 2DRU 模式下 4 种网络的重建结果对比

Fig. 10 Comparison of reconstruction results for four different networks on NYU fastMRI brain data using 2DRU with acceleration factor of 3

从表 1 所有欠采样模式重建结果的评价指标可以看出, DN2NA 不仅提供了优于 IUNN 和 KUNN 的重建结果, 而且展现了与有监督网络 MICCAN 相近的性能, 在部分场景下 DN2NA 甚至拥有好于 MICCAN 的性能。从表 2 可以看出, DN2NA 依然展现了优于 IUNN 和 KUNN 的性能, 在 PSNR 值接近

时, DN2NA 的重建结果具有更高的 SSIM 值。从表 3 可以看出, 在不同欠采样模式下, DN2NA 均能提供最高的 PSNR 值和较低的 HFEN 值。观察表 1 ~ 3 可以看出, 在大部分场景中 DN2NA 的 STD 值都是最低的, 说明拥有提前停止准则的 DN2NA 能提供更加稳定的重建结果。

表 1 4 种不同网络在膝盖数据重建结果的评价指标

Tab. 1 Evaluation metrics for knee reconstruction results of four different networks

掩码	方法	AF = 3				AF = 5			
		PSNR ↑	STD ↓	SSIM ↑	HFEN ↓	PSNR ↑	STD ↓	SSIM ↑	HFEN ↓
2DPU	IUNN	34.338 7	0.751 0	0.909 4	0.161 8	31.052 7	1.056 2	0.841 4	0.263 8
	KUNN	31.718 9	0.490 1	0.912 0	0.156 7	29.971 6	0.997 4	0.848 2	0.208 8
	DN2NA	35.415 5	0.331 7	0.931 7	0.132 9	33.770 3	0.141 6	0.882 5	0.183 6
	MICCAN	34.257 5	—	0.928 2	0.159 6	30.576 8	—	0.880 0	0.202 4
2DRU	IUNN	34.420 1	1.069 9	0.903 2	0.131 8	32.910 0	0.760 9	0.865 6	0.177 9
	KUNN	34.351 5	0.601 4	0.891 5	0.119 8	32.232 8	0.469 8	0.830 4	0.183 0
	DN2NA	36.574 6	0.037 3	0.921 6	0.118 6	34.216 4	0.119 0	0.882 8	0.149 5
	MICCAN	35.446 8	—	0.934 9	0.111 2	35.177 0	—	0.905 8	0.150 6
RADU	IUNN	34.205 2	1.285 8	0.899 7	0.129 2	31.739 0	0.812 2	0.847 8	0.232 4
	KUNN	35.209 0	0.437 2	0.896 1	0.097 0	32.550 2	0.478 4	0.825 5	0.196 3
	DN2NA	36.630 0	0.059 5	0.918 6	0.092 8	33.389 6	0.153 7	0.868 5	0.169 8
	MICCAN	37.056 5	—	0.937 4	0.091 2	35.359 3	—	0.897 5	0.157 9
1DRU	IUNN	32.890 1	0.380 2	0.860 3	0.243 4	31.134 7	0.461 9	0.818 6	0.336 5
	KUNN	32.284 6	0.320 5	0.843 4	0.245 3	30.312 3	1.332 0	0.792 8	0.356 3
	DN2NA	33.155 7	0.073 2	0.876 9	0.234 9	31.229 2	0.056 4	0.819 7	0.350 7
	MICCAN	33.049 2	—	0.891 2	0.237 6	30.916 4	—	0.857 7	0.314 2

表 2 4 种不同网络在 SIAT 大脑数据重建结果的评价指标

Tab. 2 Evaluation metrics for brain reconstruction results on SIAT dataset across four different networks

掩码	方法	AF = 3				AF = 5			
		PSNR \uparrow	STD \downarrow	SSIM \uparrow	HFEN \downarrow	PSNR \uparrow	STD \downarrow	SSIM \uparrow	HFEN \downarrow
2DPU	IUNN	35.260 8	1.060 8	0.933 4	0.100 7	32.937 0	0.880 2	0.902 5	0.131 1
	KUNN	35.982 8	0.604 2	0.934 4	0.091 3	33.379 3	0.757 8	0.901 1	0.120 1
	DN2NA	36.578 2	0.138 4	0.947 0	0.090 5	33.867 3	0.160 1	0.924 6	0.131 6
	MICCAN	35.035 6	—	0.950 2	0.124 6	32.418 7	—	0.938 3	0.163 1
2DRU	IUNN	35.206 6	1.393 3	0.925 8	0.085 2	32.776 4	0.680 7	0.874 2	0.093 2
	KUNN	35.225 3	0.154 7	0.918 0	0.077 7	33.140 8	0.259 1	0.873 7	0.100 4
	DN2NA	35.592 3	0.345 5	0.940 9	0.078 2	33.795 6	0.184 0	0.901 7	0.099 2
	MICCAN	37.116 7	—	0.964 8	0.083 7	35.029 2	—	0.951 0	0.122 3
RADU	IUNN	35.667 0	2.161 9	0.923 8	0.084 7	31.689 2	0.682 0	0.874 1	0.116 4
	KUNN	35.871 3	0.142 5	0.917 8	0.066 4	31.322 2	0.687 5	0.866 2	0.129 5
	DN2NA	36.793 4	0.269 1	0.942 1	0.068 2	31.982 7	0.225 0	0.907 4	0.130 2
	MICCAN	38.097 1	—	0.965 4	0.075 1	32.776 9	—	0.929 4	0.153 2
1DRU	IUNN	31.918 7	1.616	0.915 2	0.169 1	29.296 7	0.818 3	0.860 6	0.298 6
	KUNN	31.812 7	1.134	0.895 3	0.167 4	28.904 5	1.418 4	0.837 1	0.300 8
	DN2NA	32.338 3	0.341 7	0.918 8	0.166 1	29.304 2	0.384 0	0.850 0	0.328 0
	MICCAN	28.721 4	—	0.921 8	0.231 2	27.926 3	—	0.883 3	0.362 4

表 3 4 种不同网络在 NYU fastMRI 大脑数据重建结果的评价指标

Tab. 3 Evaluation metrics for brain reconstruction results on NYU fastMRI dataset across four different networks

掩码	方法	AF = 3				AF = 5			
		PSNR \uparrow	STD \downarrow	SSIM \uparrow	HFEN \downarrow	PSNR \uparrow	STD \downarrow	SSIM \uparrow	HFEN \downarrow
2DPU	IUNN	35.781 3	0.392 2	0.910 4	0.073 2	28.137 9	0.317 3	0.832 4	0.142 7
	KUNN	36.017 5	0.108 3	0.918 2	0.068 8	33.553 3	0.315 9	0.849 4	0.094 6
	DN2NA	36.767 6	0.120 1	0.934 4	0.068 4	34.180 0	0.236 5	0.900 1	0.092 8
	MICCAN	27.956 5	—	0.822 0	0.275 0	25.241 0	—	0.741 8	0.4074
2DRU	IUNN	35.403 7	0.403 4	0.899 9	0.075 1	33.105 5	0.557 0	0.838 3	0.105 4
	KUNN	35.602 2	0.125 5	0.891 0	0.074 1	32.777 3	0.148 3	0.816 8	0.097 3
	DN2NA	36.233 2	0.098 0	0.902 8	0.073 6	33.669 5	0.074 7	0.845 6	0.097 0
	MICCAN	34.837 2	—	0.935 5	0.149 9	32.881 0	—	0.919 1	0.194 0
RADU	IUNN	35.482 5	0.594 2	0.901 5	0.069 9	32.938 5	0.263 8	0.828 7	0.099 9
	KUNN	35.523 1	0.088 9	0.891 7	0.062 0	31.934 6	0.233 9	0.818 5	0.096 8
	DN2NA	36.305 4	0.099 2	0.905 8	0.063 4	33.107 9	0.223 4	0.840 6	0.091 8
	MICCAN	34.973 4	—	0.940 0	0.133 1	32.710 5	—	0.918 2	0.205 1
1DRU	IUNN	33.555 3	0.294 6	0.876 0	0.123 2	31.592 3	0.426 1	0.814 9	0.140 7
	KUNN	32.867 3	0.331 2	0.854 8	0.127 4	31.486 2	0.553 4	0.809 7	0.153 9
	DN2NA	33.585 2	0.076 2	0.869 6	0.122 9	32.031 9	0.097 9	0.826 5	0.149 7
	MICCAN	28.697 0	—	0.862 7	0.308 0	27.973 6	—	0.859 3	0.353 0

2.4 消融实验

为了验证所提出的改进,设计了 3 组详尽的消融实验。

2.4.1 KN2NAP 网络的消融实验

对在频域工作的 KN2N 网络加入了复数卷积和通道注意力机制,同时加入了相位平滑和线圈灵敏

度平滑两个物理先验。对加入的部分设计了如下几组消融实验。线圈灵敏度平滑先验 (coil sensitivity smoothness) 用 S 表示, 相位平滑先验 (phase smoothness) 用 P 表示, 复数卷积 (complex convolution) 用 C 表示, 通道注意力机制 (channel attention mechanism) 用 A 表示。所有组别的重建结果见表 4, 其中, 最好的结果标记为红色。

表 4 KN2NAP 网络消融实验的结果

Tab. 4 Results of ablation experiments for KN2NAP network

方法	PSNR	SSIM	HFEN
KN2N	19.467 1	0.748 6	0.479 6
KN2N + S	29.338 1	0.917 2	0.178 1
KN2N + P	29.425 1	0.917 1	0.178 8
KN2N + S + P (KN2NP)	31.022 4	0.913 8	0.163 2
KN2N + C	24.174 2	0.817 3	0.390 7
KN2N + A	23.510 2	0.808 0	0.406 9
KN2N + C + A (KN2NA)	29.548 6	0.894 1	0.248 3
KN2N + C + A + S + P (KN2NAP)	31.741 7	0.929 8	0.152 2

从表 4 可以看出, 所提出的改进都带来了效果的提升, 单独加入线圈灵敏度先验和相位先验都能带来可观的提升, 通道注意力机制和复数卷积的组合也带来了较多的提升。组合所有的改进因素, 可以得到最好的效果。

2.4.2 IN2NA 网络的消融实验

与在频域工作的 KN2NAP 网络相同的是, 对在图像域工作的 IN2N 网络中加入了复数卷积和通道注意力机制。对 IN2NA 网络设计了如下几组消融实验。复数卷积 (complex convolution) 用 C 表示, 通道注意力机制 (channel attention mechanism) 用 A 表示。上述所有组别的重建结果见表 5, 其中, 最好的结果标记为红色。

表 5 IN2NA 网络消融实验的结果

Tab. 5 Results of ablation experiments for IN2NA network

方法	PSNR	SSIM	HFEN
IN2N	29.747 3	0.902 2	0.246 9
IN2N + C	33.172 9	0.904 8	0.235 0
IN2N + A	33.351 4	0.905 6	0.228 1
IN2N + C + A (IN2NA)	34.663 0	0.930 9	0.135 7

观察表 5 可以看出, 复数卷积和通道注意力机制都带来了效果的提升, 其中, 通道注意力机制带来的提升更多, 同时加入复数卷积和通道注意力机制可以得到最好的效果。

2.4.3 DN2NA 网络的消融实验

选择将 KN2NAP 网络和 IN2NA 网络结合起来,

组成双域的 DN2NA 网络进一步提升网络的性能, 设计了如下消融实验验证双域网络的优势: a) 单独的 KN2NAP 网络, b) 单独的 IN2NA 网络, c) IN2NA 网络重建的结果由 KN2NAP 网络进一步重建, d) KN2NAP 网络的重建结果由 IN2NA 网络进一步重建。上述所有组别的重建结果见表 6, 其中, 最好的结果标记为红色。

表 6 DN2NA 网络消融实验的结果

Tab. 6 Results of ablation experiments for DN2NA network

方法	PSNR	SSIM	HFEN
KN2NAP	31.741 7	0.929 8	0.152 2
IN2NA	34.663 0	0.930 9	0.135 7
IN2NA→KN2NAP	31.039 7	0.925 8	0.167 8
KN2NAP→IN2NA (DN2NA)	35.738 1	0.931 7	0.134 0

从表 6 可以看出, 使用频域网络 - 图像域网络形式的双域网络拥有最好的性能。

3 结 论

1) 提出了一种包含注意力机制的双域 N2N 网络 (DN2NA) 进行并行 MRI 重建, 所提出的 DN2NA 网络不需要额外的训练数据, 即可直接对欠采样的 k 空间 MR 数据进行重建。

2) DN2NA 网络结合了频域和图像域网络的优势; 在 DN2NA 网络中使用的复数卷积可以更好地处理复数 MR 数据; DN2NA 网络中的通道注意力机制在对单个多线圈欠采样数据进行训练时, 可以调整每个通道之间的比例, 带来了显著的效果提升。

3) 在膝盖和大脑共 3 个数据集上进行的实验表明, DN2NA 优于现有的无监督方法 IUNN 和 KUNN, 这不仅体现在更好的重建指标, 也体现在更稳定的重建性能。

4) 与有监督网络 MICCAN 相比, DN2NA 展示了与其相似的性能, 在部分场景下 DN2NA 的表现甚至优于 MICCAN。

5) DN2NA 网络也存在一些不足。DN2NA 作为无监督网络, 相比有监督网络 MICCAN 在重建速度上存在劣势, MICCAN 网络虽然训练时间很长, 但是网络训练好之后重建 MR 图像 (测试) 只需要几秒, 提高无监督网络的重建速度是下一步的研究方向。在之后的工作中, 会继续探究双域网络的形式, 充分结合频域网络与图像域网络的优势, 同时会尝试更多种类的注意力机制, 以期获得更好的重建性能。

参考文献

- Information Theory, 2006, 52(4): 1289. DOI: 10.1109/TIT.2006.871582
- [2] CANDÈS 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. DOI: 10.1109/TIT.2005.862083
- [3] LUSTIG M, DONOHO D L, SANTOS J M, et al. Compressed sensing MRI[J]. IEEE Signal Processing Magazine, 2008, 25(2): 72. DOI: 10.1109/MSP.2007.914728
- [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. DOI: 10.1002/(SICI)1522-2594(199911)42:5<952::AID-MRM16>3.0.CO;2-S
- [5] 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. DOI: 10.1002/mrm.10171
- [6] 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. DOI: 10.1002/mrm.22428
- [7] 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. DOI: 10.1002/mrm.26977
- [8] 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. DOI: 10.1109/TMI.2018.2865356
- [9] SRIRAM A, ZBONTAR J, MURRELL T, et al. End-to-end variational networks for accelerated MRI reconstruction [C]// Medical Image Computing and Computer Assisted Intervention (MICCAI 2020). Cornell; Cornell University, 2020; 64. DOI: 10.1007/978-3-030-59713-9_7
- [10] LU Tiejuan, ZHANG Xinlin, HUANG Yihui, et al. pFISTA-SENSE-ResNet for parallel MRI reconstruction [J]. Journal of Magnetic Resonance, 2020, 318: 106790. DOI: 10.1016/j.jmr.2020.106790
- [11] DEDMARI M A, CONJETI S, ESTRADA S, et al. Complex fully convolutional neural networks for MR image reconstruction [C]// International Workshop on Machine Learning for Medical Image Reconstruction. Cornell; Cornell University, 2018; 30. DOI: 10.1007/978-3-030-00129-2_4
- [12] WANG Shanshan, CHENG Huitao, YING L, et al. DeepcomplexMRI: exploiting deep residual network for fast parallel MR imaging with complex convolution[J]. Magnetic Resonance Imaging, 2020, 68: 136. DOI: 10.1016/j.mri.2020.02.002
- [13] FENG Chunmei, YANG Zhanyuan, FU Huazhu, et al. DONet: dual-octave network for fast MR image reconstruction [J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(3): 3965. DOI: 10.1109/TNNLS.2021.3090303
- [14] HUANG Qiaoying, YANG Dong, WU Pengxiang, et al. MRI reconstruction via cascaded channel-wise attention network [C]// 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019). Venice, Italy; IEEE, 2019; 1622. DOI: 10.1109/ISBI.2019.8759423
- [15] LEHTINEN J, MUNKBERG J, HASSELGREN J, et al. Noise2Noise: learning image restoration without clean data [C]// International Conference on Machine Learning 2018 (ICML). Stockholm, Sweden; PMLR, 2018; 2965
- [16] YAMAN B, HOSSEINI S A H, MOELLER S, et al. Self-supervised learning of physics-guided reconstruction neural networks without fully sampled reference data [J]. Magnetic Resonance in Medicine, 2020, 84(6): 3172. DOI: 10.1002/mrm.28378
- [17] PENG Hong, JIANG Chen, CHENG Jing, et al. One-shot generative prior in hankel-k-space for parallel imaging reconstruction [J]. IEEE Transactions on Medical Imaging, 2023, 42: 3431. DOI: 10.1109/TMI.2023.3288219
- [18] DARESTANI M Z, HECKEL R. Accelerated MRI with un-trained neural networks [J]. IEEE Transactions on Computational Imaging, 2021(7): 724. DOI: 10.1109/TCI.2021.3097596
- [19] CUI Zhuoxu, JIA Sen, CAO Chentao, et al. K-UNN: k-space interpolation with untrained neural network [J]. Medical Image Analysis, 2023, 88: 102877. DOI: 10.1016/j.media.2023.102877
- [20] YAMAN B. Zero-shot self-supervised learning for MRI reconstruction [C]// International Conference on Learning Representations. Cornell; Cornell University, 2022
- [21] BLAIMER M, GUTBERLET M, KELLMAN P, et al. Virtual coil concept for improved parallel MRI employing conjugate symmetric signals [J]. Magnetic Resonance in Medicine, 2009, 61(1): 93. DOI: 10.1002/mrm.21652
- [22] KNOLL F, ZBONTAR J, SRIRAM A, et al. fastMRI: a publicly available raw k-space and DICOM dataset of knee images for accelerated MR image reconstruction using machine learning [J]. Radiology, 2020, 2(1): e190007. DOI: 10.1148/ryai.2020190007

(编辑 刘彤)