

光电工程

Opto-Electronic Engineering

中文核心期刊 中国科技核心期刊
Scopus CSCD

联合分层语义网络与物理模型的MRI加速重建研究

张晓敏, 鲍玲鑫

引用本文:

张晓敏, 鲍玲鑫. 联合分层语义网络与物理模型的MRI加速重建研究[J]. 光电工程, 2025, 52(5): 250016.

Zhang X M, Bao L X. Integrating hierarchical semantic networks with physical models for MRI reconstruction[J]. *Opto-Electron Eng*, 2025, 52(5): 250016.

<https://doi.org/10.12086/oe.2025.250016>

收稿日期: 2025-01-20; 修改日期: 2025-03-11; 录用日期: 2025-03-12

相关论文

面向道路场景语义分割的移动窗口变换神经网络设计

杭昊, 黄影平, 张栩瑞, 罗鑫

光电工程 2024, 51(1): 230304 doi: 10.12086/oe.2024.230304

基于BiLevelNet的实时语义分割算法

吴马靖, 张永爱, 林珊玲, 林志贤, 林坚普

光电工程 2024, 51(5): 240030 doi: 10.12086/oe.2024.240030

基于多尺度特征增强的高效Transformer语义分割网络

张艳, 马春明, 刘树东, 孙叶美

光电工程 2024, 51(12): 240237 doi: 10.12086/oe.2024.240237

基于自适应双域注意力网络的遥感图像重建

吴菲, 陈嘉诚, 杨俊, 王万良, 李国庆

光电工程 2025, 52(4): 240297 doi: 10.12086/oe.2025.240297

更多相关论文见光电期刊集群网站 



光电工程
Opto-Electronic Engineering

<http://cn.ojournal.org/oe>



 OE_Journal



Website

联合分层语义网络与物理模型的 MRI 加速重建研究

张晓敏¹, 鲍玲鑫^{2*}

¹ 福建信息职业技术学院物联网与人工智能学院, 福建 福州 350003;


² 福建农林大学计算机与信息学院, 福建 福州 350003

摘要: 为缓解核磁共振成像 (MRI) 中的长时间采集困境, 大数据驱动下的算法与模型融合已成为实现高质量 MRI 重建的重要手段。然而, 现有方法多集中于视觉特征的提取, 忽视稳健重建所需的深层次语义信息。为此, 提出一种联合分层语义网络与物理模型网络的模型驱动架构, 旨在提升重建性能的同时维持计算效率。该架构包含四个关键模块: 上下文提取模块, 用于捕获丰富的上下文特征以降低背景干扰; 多尺度聚合模块, 通过整合多尺度信息保留粗细解剖细节; 语义图推理模块, 建模语义关系以增强组织区分度并抑制伪影; 双尺度注意力模块, 强化不同细节层级上的关键特征表达。这种层次化且语义感知的设计有效减少混叠伪影, 并显著提升图像保真度。实验结果表明, 在涵盖不同采样率的多样化数据集上, 所提方案在定量评估和视觉质量方面均优于现有方法。例如, 在 IXI 数据集四倍径向加速的实验中, 所提方法的峰值信噪比达到 48.15 dB, 平均领先最新的对比算法 1.00 dB, 同时实现更高的加速比并保持可靠的图像重建效果。

关键词: 核磁共振加速; 上下文信息; 模型驱动方法; 语义推理

中图分类号: TP391.4

文献标志码: A



张晓敏, 鲍玲鑫. 联合分层语义网络与物理模型的 MRI 加速重建研究 [J]. 光电工程, 2025, 52(5): 250016

Zhang X M, Bao L X. Integrating hierarchical semantic networks with physical models for MRI reconstruction[J]. *Opto-Electron Eng*, 2025, 52(5): 250016

Integrating hierarchical semantic networks with physical models for MRI reconstruction

Zhang Xiaomin¹, Bao Lingxin^{2*}

¹ The Internet of Things and Artificial Intelligence College, Fujian Polytechnic of Information Technology, Fuzhou, Fujian 350003, China;

² College of Computer and Information Sciences, Fujian Agriculture and Forestry University, Fuzhou, Fujian 350002, China

Abstract: To address the challenge of prolonged acquisition times in magnetic resonance imaging (MRI), data-driven algorithms and the model integration have emerged as crucial approaches for achieving high-quality MRI reconstruction. However, existing methods predominantly focus on visual feature extraction while neglecting deep semantic information critical for robust reconstruction. To bridge this gap, this study proposes a model-driven architecture that synergistically combines hierarchical semantic networks with physical model networks, aiming to

收稿日期: 2025-01-20; 修回日期: 2025-03-11; 录用日期: 2025-03-12

基金项目: 2023 年认知智能全国重点实验室课题 (COGOS-2023HE03); 福建省自然科学基金 (2023J01471); 智慧农林福建省高校重点实验室建设项目专项补助资金 (KJG23033A); 福建农林大学科技创新专项基金 (KFB23159)

*通信作者: 鲍玲鑫, bolingxmu@sina.com。

版权所有©2025 中国科学院光电技术研究所

enhance reconstruction performance while maintaining computational efficiency. The architecture comprises four core modules: a context extraction module to capture rich contextual features and mitigate background interference; a multi-scale aggregation module integrating multi-scale information to preserve coarse-to-fine anatomical details; a semantic graph reasoning module to model semantic relationships for improved tissue differentiation and artifact suppression; a dual-scale attention module to enhance critical feature representation across different detail levels. This hierarchical and semantic-aware design effectively reduces aliasing artifacts and significantly improves image fidelity. Experimental results demonstrate that the proposed method outperforms state-of-the-art approaches in both quantitative metrics and visual quality across diverse datasets with varying sampling rates. For instance, in $4\times$ radial acceleration experiments on the IXI dataset, our approach achieved a peak signal-to-noise ratio (PSNR) of 48.15 dB, surpassing the latest comparison algorithms by approximately 1.00 dB on average, while enabling higher acceleration rates and maintaining reliable reconstruction outcomes.

Keywords: MRI acceleration; contextual information; model-guided approaches; semantic reasoning

1 引言

在当今的大数据时代,数据的规模与复杂性正以前所未有的速度增长。光学相关技术呈现快速发展趋势^[1-3],其中磁共振成像(MRI)在现代生物医学科学领域中是一种关键的、非侵入且无辐射的成像模式,因其卓越的软组织对比度和出色的解剖成像能力而闻名。MRI通过利用强磁场和射频脉冲激发人体内的氢原子核,检测其弛豫过程中释放的信号,生成高分辨率的图像。这种成像方式不仅能够清晰地显示人体内部的解剖结构,还可以通过功能磁共振成像(fMRI)和扩散加权成像(DWI)等技术揭示组织的功能特性,为疾病的早期诊断、治疗规划和疗效评估提供了重要依据。例如,在神经系统疾病(如脑卒中、肿瘤和神经退行性疾病)的诊断中,MRI能够提供比其他成像模式(如CT或X射线)更为精细的软组织对比度,从而帮助医生更准确地定位病变区域。此外,在心血管疾病、骨关节疾病以及癌症的诊断和分期中,MRI也展现出了显著的优势。

尽管MRI具备上述诸多优势,其数据采集面临时间效率的核心挑战。由于信号采集需要逐点扫描k空间,这一过程通常耗时较长,尤其是在高分辨率成像或三维成像中,扫描时间可能长达数10 min甚至更久。这不仅增加了患者的不适感,还可能导致因患者运动引起的伪影,进而影响图像质量。此外,长时间的扫描限制了MRI在急诊和大规模筛查中的应用,凸显了提升MRI采集效率的重要性。为应对此问题,一种常见的策略是从稀疏采样的k空间数据中重构高质量图像,其中压缩感知(CS)成为关键技术^[4-7]。压缩感知旨在从成像系统获取的信号中重建图像,即便

存在噪声的情形下也能保持稳定。然而,位于k空间的大幅欠采样违背了奈奎斯特定理,可能在图像域中引入混叠伪影,这对开发有效的重建方法构成了重大挑战。

MRI的加速主要依赖于二维空间测量信号与原始信号之间的物理关联^[8-10]。核心难题在于从退化的测量中重构清晰的图像,这实质上是一个不适定问题。在传统方法中,通常会施加一个人工设计的先验作为正则化项,以引导求解过程并获得预期的解。例如,稀疏性是压缩感知领域中的经典先验,因其能够有效捕捉信号的稀疏特性而备受关注。在此基础上,全变分^[11]和低秩性^[12]等正则化方法被广泛研究,分别用于增强图像的局部平滑性和全局相关性。近年来,一些更为前沿的正则化方法逐渐涌现,如拉普拉斯正则化^[13]和曲率正则化^[14]等。尽管这些方法在特定应用场景中表现出色,但他们的实际设置往往依赖于经验选择,可能无法充分适应真实MRI数据的复杂性。此外,混合使用多种先验虽然可以在一定程度上缓解单一先验的局限性,但也会不可避免地增加模型选择难度并降低推理效率。

相比之下,基于深度学习的前沿方法通过数据驱动的方式,显著提升了MRI加速重建的性能。然而,现有方法仍面临一些挑战。首先,许多方法施加了过于刚性的结构约束,限制了特征学习的灵活性,导致其在复杂场景下的泛化能力不足^[6,15]。其次,现有模型往往未能充分抓取对准确重建极为重要的多尺度上下文信息,尤其在不同分辨率下整合层次信息的能力有限^[16]。这种缺陷使得模型在高欠采样条件下或重建不同解剖区域时表现欠佳。此外,当前的网络策略主要聚焦于提取浅层特征,忽略了丰富语义信息的整

合^[17]。这种语义意识的缺失削弱了网络对组织类型的区分能力和伪影的抑制能力, 导致图像保真度和诊断效用受损^[18-19]。最后, 由于未能捕捉到 MRI 数据中固有的复杂上下文关系和依赖性, 现有模型难以实现精准且可靠的重建^[20]。

综上所述, 尽管前沿模型在性能上优于传统方法, 但其在多尺度信息整合、语义信息建模以及上下文关系捕捉等方面仍有改进空间。为应对上述挑战, 提出了联合分层语义网络与物理模型的方法, 这是一种致力于在模型驱动方法中有效融合层次上下文信息的全新架构。借助多层次的层次结构来捕获原始信号空间里的全局和局部依赖关系, 保证重建的图像在不同解剖尺度上维持高保真度。通过在重建的多个阶段注入上下文信息, 所设计网络能够自适应地优化特征表示, 进而减轻混叠伪影并提升整体图像质量。

所提方法主要采用了四个关键模块: 上下文提取模块、尺度间聚合模块、语义图推理模块以及双尺度注意模块。这些模块协同运作, 整合语义信息和多尺度上下文特征, 使重建图像更精准和稳健。本文主要贡献可作如下概括:

1) 多尺度上下文整合。通过融合不同功能模块, 有效捕获多尺度上下文信息。此设计让网络能够精准重建复杂的解剖结构, 具备出色的精度。双尺度注意模块通过在粗细尺度上有选择性地突出关键特征, 增强了模型适应不同解剖区域的不同细节层级的能力。

2) 语义图推理。引入基于图的推理来构建模型并充分利用数据中的语义关系, 增强网络区分不同组织类型和抑制伪影的能力, 通过加深网络对空间和上下文依赖关系的理解, 生成更清晰且更具诊断价值的重建图像。

3) 语义网络优化算法整合。结合前沿的优化算法和富含语义信息的神经网络, 实现基于模型的推导和深度强大特征学习之间的平衡, 在维持可靠性的同时得到先进的重建结果。

2 相关工作

在 MRI 重建过程中, 模型驱动方案借助人工设计的先验条件, 例如稀疏性^[21]、全变分^[11]和低秩性^[22]取得了显著成果。尽管这些方法强化了局部和全局的数据特性, 但此类方法通常基于经验主义, 难以适应 MRI 的复杂实际分布。近期, 更为复杂的正则化, 例如拉普拉斯^[13]、流形^[23]和曲率^[14]被引入。尽管在

某些场景中表现出色, 这些手工设计的先验条件仍面临适应性方面的挑战。结合多个先验条件或许能缓解这一问题, 但也会使模型选择复杂化, 并降低推理效率。

基于深度学习 (DL) 的方案借助数据驱动的先验假定^[24], 极大地促进 MRI 加速领域的发展。U-Net^[25]、ResNet^[26-27]以及 Transformers^[28]等架构均实现了显著的性能提升。然而, 这些方法常常忽视了观测背后的物理机制, 尤其是退化算子, 致使结果的可解释性受限。在医疗情境中, 这种可解释性的缺失属于一个关键问题, 因为医疗可靠性的考量极为重要。

最近的研究日益聚焦于弥合模型驱动和数据驱动方法之间的差距^[29-30], 以充分利用两种范式的优势。相反, 数据驱动的深度学习模型在从大量数据集中学习复杂表征方面表现突出, 但缺乏必要的领域特定知识整合, 有可能影响其在临床环境中的泛化能力和可靠性。

目前已有各种各样的优化框架与高级模型驱动的方法依照 MRI 采样的物理原理, 提供了可解释性与稳健性, 着力于捕捉欠采样数据中存在的复杂高维模式。例如, Zhang 等^[31]引入了一种基于全变分 TV 的展开网络, 运用原始-对偶混合梯度算法与经典 CNN 网络来学习正则化。MICCAN^[32]引入了一种基于通道注意力机制的改进 U-Net 模型, 通过长跳跃连接和组合损失函数优化了高频率信息重建效果, 但在极低采样率下的性能仍有提升空间。与此同时, 深度展开网络逐渐成为主流解决方案, 如 MDUNet^[33]通过记忆增强机制在 k 域和图像域之间交替融合区域结构与全局信息, 展现了较强的特征表示能力, 而 GA-HQS^[34]则结合二阶梯度信息和多尺度注意力模块, 进一步增强了全局特征建模能力。Aggarwal 等^[29]开发出 MoDL 方法, 通过展开拟牛顿迭代过程并利用全采样数据训练正则化器来优化 MRI 重建。Pramanik 等^[16]运用 CNN 高效估算 k 空间湮灭关系, 提供了一种比传统结构低秩方法更快捷、更稳健的替代方案 (H-DSLR), 且无需校准步骤。Zhang 等^[19]借助残差网络评估了三种展开算法——交替最小化 (AM)、迭代收缩软阈值算法 (ISTA) 和交替方向乘子法 (ADMM) 的有效性, ADMM 的表现通常优于其他方法。Geng 等^[18]引入了一种 Transformer 以增强快速的基于 ISTA 的展开算法, 推动了全局依赖关系的学习。近期, Jiang 等^[34]将展开算法划分为两个关键阶段:

信息融合和图像校正, 允许独立设计模块以达成高泛化性。然而, 尽管这些方法各有优势, 但是他们普遍存在特征表示能力不足、信息融合机制不完善以及难以捕捉欠采样数据中复杂高维模式的问题, 尤其是当前展开方法通常在原始信号空间内运作, 限制了其捕捉复杂信号内在特征的能力。

3 方法介绍

3.1 基本模型

由原始信号 $\mathbf{Z} \in \mathbb{C}^{1 \times H \times W}$ 导出二维 k 空间测量 $\mathbf{Y} \in \mathbb{C}^{1 \times H \times W}$ 的数学公式为

$$\mathbf{Y} = \mathbf{F}_u \mathbf{Z} + \mathbf{N}, \quad (1)$$

式中: $\mathbf{N}$ 为测量 $\mathbf{Y}$ 中的噪声分量。在单通道 MRI 采集中, $\mathbf{F}_u$ 定义为 $\mathbf{M}\mathbf{f}$, 其中 $\mathbf{M}$ 是尺寸为 $H \times W$ 的二进制欠采样掩码, $\mathbf{f}$ 表示傅里叶变换, H 和 W 分别表示数据的高度和宽度。在多线圈 MRI 设置中, $\mathbf{F}_u$ 表示为 $\sum_{i=1}^{c_n} \mathbf{M}\mathbf{f}s_i$, 其中 s_i 表示第 i 个线圈的灵敏度, 对于 $i = 1, 2, \dots, c_n$ 。

3.2 问题描述

考虑直接从 $\mathbf{Y}$ 推断 $\mathbf{Z}$ 有一定难度, 为得到稳定的解, 必须引入某些先验约束。给定一些显式或隐式正则化^[21-22], 原本的不适定问题可以转化为适定问题, 进而获得可行解来处理重建问题。具体来说, 通过最小化以下能量函数可以实现具有多样特征的 $\mathbf{Z}$, 表达式为

$$\mathbf{Z} = \arg \min_{\mathbf{Z}} \underbrace{\frac{1}{2} \|\mathbf{Y} - \mathbf{F}_u \mathbf{Z}\|_F^2}_{\text{Data consistency}} + \underbrace{\lambda_1 \mathcal{R}_1(\mathbf{Z}) + \lambda_2 \mathcal{R}_2(\mathbf{Z})}_{\text{Regularization}}, \quad (2)$$

式中: λ_1 和 λ_2 为用于平衡不同组件的贡献; $\|\cdot\|_F^2$ 表示矩阵的范数平方, 用于衡量重建数据与观测数据之间的误差; $\mathcal{R}_1(\mathbf{Z})$ 和 $\mathcal{R}_2(\mathbf{Z})$ 为从互补模块中学习的两个隐式正则化。这些模块将解细化到所需水平。通过引入辅助变量 $\mathbf{B}$, 式 (2) 可以重新表述为一个约束问题, 表达式为

$$\begin{aligned} \min_{\mathbf{Z}, \mathbf{B}} \quad & \frac{1}{2} \|\mathbf{Y} - \mathbf{F}_u \mathcal{P}(\mathbf{Z})\|_F^2 + \lambda_1 \mathcal{R}_1(\mathbf{Z}) \\ & + \lambda_2 \mathcal{R}_2(\mathbf{B}), \text{ s.t. } \mathbf{B} = \mathbf{Z}, \end{aligned} \quad (3)$$

式中: $\mathcal{P}$ 表示一个预处理或投影算子。

3.3 优化方案

大多数一阶优化算法, 如 HQS^[35]、ISTA^[18] 和 ADMM^[19], 可用于解决式 (2) 或式 (3)。由于本文主要聚焦于语义挖掘, 采用经典 ADMM 作为基线优化

器。然后, 通过迭代执行以下子问题可以解决式 (3), 表达式为

$$\begin{cases} \mathbf{Z}^{(k+1)} = \arg \min_{\mathbf{Z}} \mathcal{J}(\mathbf{Z}) + \lambda_1 \mathcal{R}_1(\mathbf{Z}) \\ \mathbf{B}^{(k+1)} = \arg \min_{\mathbf{B}} \frac{\rho}{2} \|\mathbf{Z}^{(k+1)} - \mathbf{B} + \mathbf{U}^{(k)}\|_F^2 + \lambda_2 \mathcal{R}_2(\mathbf{B}) \\ \mathbf{U}^{(k+1)} = \mathbf{U}^{(k)} + \mathbf{Z}^{(k+1)} - \mathbf{B}^{(k+1)} \\ \mathcal{J}(\mathbf{Z}) = \frac{1}{2} \|\mathbf{Y} - \mathbf{F}_u \mathcal{P}(\mathbf{Z})\|_F^2 + \frac{\rho}{2} \|\mathbf{Z} - \mathbf{B}^{(k)} + \mathbf{Z}^{(k)}\|_F^2 \end{cases}, \quad (4)$$

式中: k 表示迭代步数; ρ 表示超参数; $\mathbf{U}$ 表示 ADMM 所需的拉格朗日变量。式 (4) 中的子问题 $\mathbf{Z}^{(k+1)}$ 和 $\mathbf{B}^{(k+1)}$ 应进一步简化以实现显式展开方案。通过使用近端梯度算法^[36], 详细信息如下:

1) 更新 $\mathbf{Z}$ 。通过组合前两项, $\mathbf{Z}$ 的更新可推导为

$$\min_{\mathbf{Z}} \frac{1}{2} \left\| \mathbf{Z} - \left(\mathbf{Z}^{(k)} - \eta^{(k)} \nabla g_1(\mathbf{Z}^{(k)}) \right) \right\|_F^2 + \eta^{(k)} \lambda_1 \mathcal{R}_1(\mathbf{Z}), \quad (5)$$

式中: $\eta^{(k)}$ 为步长超参数; ∇ 为一阶梯度。 $g_1(\mathbf{Z}) = (1/2) \|\mathbf{Y} - \mathbf{F}_u \mathcal{P}(\mathbf{Z})\|_F^2 + (\rho/2) \|\mathbf{Z} - \mathbf{B}^{(k)} + \mathbf{Z}^{(k)}\|_F^2$, 其一阶导数可以推导为

$$\nabla g_1(\mathbf{Z}^{(k)}) = \mathbf{F}_u^T (\mathbf{F}_u \mathcal{P}(\mathbf{Z}^{(k)}) - \mathbf{Y}) + \rho (\mathbf{Z}^{(k)} - \mathbf{B}^{(k)} + \mathbf{Z}^{(k)}). \quad (6)$$

此外, 通过采用与正则化 $\mathcal{R}(\mathbf{Z})$ 相符的近端算子, 从 $\mathbf{Z}^{(k)}$ 到 $\mathbf{Z}^{(k+1)}$ 的更新可写为

$$\mathbf{Z}^{(k+1)} = \text{prox}_{\eta^{(k)} \lambda_1} \left(\mathbf{Z}^{(k)} - \eta^{(k)} \nabla g_1(\mathbf{Z}^{(k)}) \right), \quad (7)$$

式中: $\text{prox}(\cdot)$ 为近端算子。

2) 更新 $\mathbf{B}$ 。根据式 (7) 输出的 $\mathbf{Z}^{(k+1)}$, $\mathbf{B}$ 的优化可以写为

$$\mathbf{B}^{(k+1)} = \arg \min_{\mathbf{B}} \frac{1}{2} \left\| \mathbf{B} - \left(\mathbf{Z}^{(k+1)} + \mathbf{U}^{(k)} \right) \right\|_F^2 + \frac{\lambda_2}{\rho} \mathcal{R}_2(\mathbf{B}), \quad (8)$$

通过重新选择近端算子, 可以借用类似于式 (7) 的操作来求解式 (8)。更新可写为

$$\mathbf{B}^{(k+1)} = \text{prox}_{\lambda_2/\rho} \left(\mathbf{Z}^{(k+1)} + \mathbf{U}^{(k)} \right). \quad (9)$$

注意, 式 (7) 中近端算子和式 (9) 中近端算子均采用一个简单的卷积模块 (Conv-BN-ReLU) 来实现, 以规避过于复杂的结构干扰语义提取模块。

3.4 网络模型概述

如图 1 所示, 所设计网络包含 6 个模块: 编码器、上下文提取模块、尺度间聚合模块、语义图推理模块、双尺度注意模块和解码器, 其中 $\oplus$ 为相加, $\odot$ 为特征串联, D^{1-5} 为解码器。

为提取全局上下文信息, 首先采用基于模型的推理流实现稳定可靠的重建。继而进行语义图推理, 精




图 1 算法流程示意图

Fig. 1 Schematic diagram of algorithm process

确识别重要信息。随后运用双尺度注意力来增强边缘细节。对于编码, 使用一个简单的 U-Net, 提供初始特征提取。编码器使用 CB1-CB2-CB3-CB4-CB5 结构提取不同特征, 其中 CB 为语义信息, 原始编码器对所有图像区域予以处理, 捕捉诸如 E^3 、 E^4 和 E^5 的高级特征。然而, 仅仅依靠单个层的特征图难以捕获重建完整组织以及排除无关组织所必需的细粒度细节。为化解这一局限, 本文引入了全局上下文增强块。另外, 提出了双尺度注意模块以应对边缘不确定性问题。此模块能够有效降低噪声, 细化边缘细节, 并生成增强的特征表示, 进而达成更精确且可靠的恢复。这些组件协同运作, 整合高级信息并对语义关系进行建模, 助推关键特征的精准提取。

3.5 多尺度上下文网络

有效捕捉空间上下文中的语义信息仍然是一项重大挑战。为应对此问题, 提出全局语义增强块, 旨在激活磁共振 (MR) 区域中的高级特征, 并促进空间和语义信息的无缝融合, 以实现卓越的重建效果。接下来将详细介绍其三个关键模块: 上下文提取模块、多尺度聚合模块和语义图推理模块。

1) 上下文提取模块: 目的在于捕捉图像的全局语义特征。如图 2 下侧所示, 输入始于高层编码器输出 $I \in \mathbb{R}^{C \times H \times W}$, 其中 C 表示特征通道数, 运用全局注意机制选择性地识别空间视觉特征, 生成语义流 $S \in \mathbb{R}^{C \times N}$, 其中 N 为中间通道数, 其表达式为

$$S = P_{\text{gather}}(I) = I_{\text{feat}} \cdot I_{\text{att}}^T, \quad (10)$$

式中: $P_{\text{gather}}(\cdot)$ 为全局注意操作; $\cdot$ 为矩阵乘法。公式

表达为

$$\begin{cases} I_{\text{feat}} = \varphi(I; W_{\varphi}), \\ I_{\text{att}} = \text{Softmax}(\theta(I; W_{\theta})) \end{cases} \quad (11)$$

这里, $I_{\text{feat}} \in \mathbb{R}^{C \times H \times W}$ 和 $I_{\text{att}}^T \in \mathbb{R}^{H \times W \times N}$ 是两个不同的 1×1 卷积层的输出, 其使用的卷积层分别表示为 φ 和 θ , W_{φ} 和 W_{θ} 是其中的参数。注意图 I_{att} 通过在空间维度 ($H \times W$) 上应用 Softmax 函数计算概率分布, 这与计算机视觉中广泛采用的做法一致。此过程确保了关键语义线索的高效和针对性提取。

注意图 I_{att} 在 N 个通道上编码多样化表示, 每个通道在空间域上独特地聚合了全局特征。然而, 不同尺度的高级特征之间的不一致性可能会影响具有多样尺寸变化的结构纹理的准确重建。为了解决这个问题, 语义流聚合了多尺度特征并减少了层之间的语义差距, 提高了具有不同结构复杂性的纹理的重建准确性。

2) 多尺度聚合模块: 为改进语义和结构信息, 结合了软注意机制, 将语义流与高级特征结合起来, 解决了缺乏全局语义线索的问题。如图 2 上侧所示, 输入特征 $G \in \mathbb{R}^{C \times kH \times kW}$ (其中 $k=2$) 表示从低分辨率图 I 获得的上采样特征图。通过 1×1 卷积和通道级 Softmax 操作, 多尺度间聚合模块将这些高级特征转换为尺寸为 $kH \times kW$ 的 N 维注意向量, kH 和 kW 分别表示高度和宽度的尺度因子。语义流 S 自适应地合并以生成语义描述符图 $F \in \mathbb{R}^{C \times kH \times kW}$, 其计算公式为

$$F = P_{\text{generate}}(S, G_{\text{att}}) = S \otimes G_{\text{att}}, \quad (12)$$

式中: $P_{\text{generate}}(\cdot)$ 表示生成语义描述符图的操作。由输入特征图 G 导出的注意图 G_{att} 定义为

$$\mathbf{G}_{\text{att}} = \text{Softmax}(\psi(\mathbf{G}; \mathbf{W}_{\psi})) \in \mathbb{R}^{N \times kH \times kW}, \quad (13)$$

式中: ψ 表示应用于 $\mathbf{G}$ 的通道级变换。语义描述符图 $\mathbf{F}$ 通过逐元素加法与原始特征图 $\mathbf{G}$ 结合, 形成初始融合输出。为强化这一输出, 应用 1×1 卷积, 生成丰富的语义特征表示 $\mathbf{M}_f$ 。融合过程的数学表达式为

$$\mathbf{M}_f = P_{\text{attention}}(\mathbf{E}_f, \mathbf{S}_f) = \mathbf{E}_f \otimes \text{Softmax}(\mathbf{E}_f^T \otimes \mathbf{S}_f), \quad (14)$$

式中: $P_{\text{attention}}(\cdot)$ 为通道注意机制; $\mathbf{S}_f$ 为语义特征; $\mathbf{E}_f$ 为通道特征。Softmax 函数通过计算通道上的概率分布生成注意力图。

为进一步细化上述重采样特征 $\mathbf{M}_f$, 语义图 $\mathbf{S}_f$ 被用于捕捉感兴趣区域内的关键语义细节, 同时过滤掉目标区域外的无关或干扰信息。通过对 $\mathbf{S}_f$ 应用 Sigmoid 函数, 并与 $\mathbf{M}_f$ 进行逐元素乘法来实现。此机制允许模型整合全局上下文信息, 丰富特征表示的细节。细化后的特征通过逐元素加法与 $\mathbf{S}_f$ 结合。多尺度聚合模块的最终输出通过卷积操作、批归一化和 ReLU 激活获得。这个过程的数学定义为

$$\mathbf{O} = P_{\text{refine}}(\mathbf{S}_f, \mathbf{M}_f) = \Psi(\mathbf{M}_f \odot \text{Sigmoid}(\mathbf{S}_f) \oplus \mathbf{S}_f; \mathbf{W}_{\Psi}), \quad (15)$$

式中: $P_{\text{refine}}(\cdot)$ 表示语义细化过程; $\mathbf{O}$ 表示模块的最终输出, $\mathbf{O} \in \mathbb{R}^{C \times kH \times kW}$ 。

3) 语义图推理模块: 提取深层语义信息对于提供准确捕捉和重建 MRI 数据中复杂细节的上下文线索

至关重要。然而, 许多现有方法^[15,37] 由于其感受野的限制和建模长程依赖关系的能力有限, 难以充分利用这种语义丰富性。相比之下, 图卷积网络利用图结构在建模 MRI 像素之间的关系方面表现出色, 使其能够有效捕捉长程上下文交互。为克服现有方法的局限性, 本文提出了一种增强的基于图卷积的模块, 称为语义图推理网络, 专门设计用于促进复杂语义信息的提取, 其操作流程如图 3 所示, $\mathbf{R}$ 为语义图推理模块输出的特征。受 Li 等^[38] 的启发, 由多尺度间聚合模块生成的特征图 $\mathbf{O}$ 被分割成每个 8 个像素的块。在每个块内, 具有相似特征的像素被映射到图 $\mathbf{K}$ 的顶点。对应于每个顶点的像素特征被聚合, 形成顶点特征 $\mathbf{V} \in \mathbb{R}^{64 \times (8 \times 8 \times 2)}$ 。每个顶点分配 8 个可学习的锚特征, 用于计算像素特征和锚特征之间的相似性, 从而确定不同图顶点的权重。然后使用这些顶点权重计算顶点信息。为了进一步建模顶点之间的关系, 构建了一个邻接矩阵 $\mathbf{H} \in \mathbb{R}^{128 \times 128}$, 其中每个元素 h_{ij} 表示顶点 v_i 和顶点 v_j 之间的边权重, i, j 为元素位置的索引, 取值范围为 1~128。此外, 保留了像素到顶点的分配, 生成了像素到顶点的分配矩阵 $\mathbf{Q}$ 。

为细化语义特征提取, 运用图卷积在图上展开图推理, 增强非线性激活函数和节点级注意机制。这些步骤使网络专注于特定顶点或区域, 增强其提取有意义语义信息能力。相应的数学表达式为




图 2 网络组成模块。(a) 多尺度聚合模块; (b) 上下文提取模块

Fig. 2 Network composition module. (a) Multi-scale aggregation module; (b) Context extraction module

$$V' = NA(BR(P_{\text{gconv}}(P_{\text{proj}}(\mathbf{O}), \mathbf{H}))), \quad (16)$$

式中: $P_{\text{proj}}(\cdot)$ 为图投影操作; $P_{\text{gconv}}(\cdot)$ 为图卷积; $BR(\cdot)$ 为批归一化结合激活函数; $NA(\cdot)$ 为节点级注意机制。最后, 通过跳跃连接将图卷积特征 V' 重投影, 以恢复原始特征维度并与 $\mathbf{O}$ 合并。这一过程生成了包含深层语义信息的丰富特征图 R^5 , 这对于精准 MRI 重建至关重要。

3.6 双尺度注意力模块

文献 [39] 强调低级特征包含详细粒度, 利于捕捉复杂局部纹理信息。然而, 粒度增加也会导致图像噪声增多。此问题在 MRI 中尤为明显, 背景和靶组织之间过渡区通常包含显著噪声, 给高损失重建带来挑战和不确定性。因此, 关键挑战在于有效利用边缘

和纹理信息, 同时减少边缘噪声的干扰。为解决这些挑战, 引入了双尺度注意力模块, 如图 4 所示。先将输入张量 T 沿空间维度分为两个部分, 即 T_1 和 T_g 。对于 T_1 , 先导出表示 $\{Q_1, K_1, V_1\} \in \mathbb{R}^{(HW-T) \times C}$, 其中 $T \ll HW$, 同时在空间维度上创建大小为 $\left(\frac{(HW-T)}{S^2} \times C\right)$ 的 $S \times S$ 局部块, Q 、 K 、 V 分别表示查询、键、值。随后, 对这些局部块分别施加自注意力, 并将他们连接生成输出 $T_{\text{LSA}} \in \mathbb{R}^{(HW-T) \times C}$ 。

对于 T_g , 先进行空间压缩以获得缩减表示, 记为 $Q_g \in \mathbb{R}^{T \times C}$ 。在此基础上, 再次应用自注意力, 并借助 K_1 和 V_1 , 导出初始的局部-全局耦合表示, 记为 $T_{\text{LGA}} \in \mathbb{R}^{T \times C}$ 。从 T_{LGA} 中, 进一步生成键值对 $\{K_g, V_g\} \in \mathbb{R}^{T \times C}$, 这些键值对与 Q_1 一起, 生成增强的局部-全局耦合表示 $T_{\text{PLGA}} \in \mathbb{R}^{(HW-T) \times C}$ 。最后, 将 T_{PLGA} 和 T_{LSA} 的组合特征




图 3 语义图推理模块示意图

Fig. 3 Schematic diagram of semantic graph reasoning module




图 4 双尺度注意力模块示意图

Fig. 4 Schematic diagram of dual-scale attention module

与 T_{LGA} 沿空间维度连接, 并与原始输入的跳跃连接结合, 生成最终输出。

4 实验结果分析

本节概述了在不同数据集上的一系列实验, 以评估所提出算法的性能。实验设置如下:

数据集: 本研究选择了两个公开 MRI 数据集, IXI 和 fastMRI, 以评估该方法的临床适用性。IXI 数据集包含 578 张尺寸为 256 pixel×256 pixel 的 T2 加权图像。fastMRI 数据集包括 588 卷脂肪抑制质子密度加权 (FSPD) 图像, 每卷分辨率为 320 pixel×320 pixel。两个数据集均按 7:1:2 的比例划分为训练、验证和测试集。为评估不同采样条件下的性能, 采用了三种类型的 k 空间欠采样掩码: 随机 1D 笛卡尔、等分 1D 笛卡尔和 2D 径向采样, 每种掩码均应用于 4×和 8×的加速因子。

实现细节: 所有实验均使用 PyTorch 框架在 NVIDIA GeForce RTX A6000 GPU 上进行。损失函数为 L1 损失, 优化器为 Adam, 超参数设置为 (0.9, 0.999), 训练轮数为 300 epochs, 初始学习率为 10^{-4} , 批量大小为 4。

评估指标: 使用峰值信噪比 (PSNR)、结构相似性指数 (SSIM) 和归一化均方根误差 (NRMSE) 对所提方法的性能进行定量评估。此外, 通过两个指标评估效率: 模型参数 (Param.) 和每秒浮点运算次数 (FLOPs)。

对比算法: 为了进行比较分析, 使用 4 种深度展开方法——MDUNet^[33]、GA-HQS^[34]、H-DSLR^[16] 和 PGIUN^[15], 以及 2 种基于深度学习的技术——U-Net^[40] 和 MICCAN^[32]。为了确保公平比较, 所有方法均按照其原始工作中的实验设置进行训练。

对于多通道 MRI 实验, 使用公开的脑数据集^[29], 该数据集由 5 名志愿者获取的完全采样的多线圈图像组成。4 名志愿者的数据用于训练, 而第 5 名志愿者的数据则分为验证和测试子集。训练、验证和测试数据集的尺寸分别为 $12 \times 360 \times 256 \times 232$ 、 $12 \times 100 \times 256 \times 232$ 和 $12 \times 64 \times 256 \times 232$ 。为了模拟欠采样, 对所有 12 个线圈的同一切片数据应用了 2D 笛卡尔伪随机采样掩码和 1D 等分掩码, 并基于每个切片的中心 k 空间区域, 使用 ESPIRiT 算法^[41] 生成线圈灵敏度图进行准确的灵敏度估计。

4.1 单线圈信号重建

表 1 总结了在单次评估中两个数据集的平均性能。结果表明, 所提方案在 IXI 数据集上表现出显著的性能优势。在 4×径向加速设置下, 实现了 48.15 dB 的 PSNR, 优于所有竞争方法。fastMRI 数据集被认为更具挑战性, 所提方案在所有场景中始终表现出强大的性能。在展开方法中, MDUNet、GA-HQS、H-DSLR 和 PGIUN 取得了具备竞争力的结果, 其中 PGIUN 因其优雅的精炼架构较为突出, 该架构有效地融合了传统算法和基于学习的策略。相较而言, U-Net 和 MICCAN 表现欠佳, 可能是在网络设计中缺少对数据一致性的强调。此外, 在图 5 中, 第一行和第二行分别展示了 IXI 数据集在随机 8 倍加速下的重建结果。总体而言, 所有算法均能够较好地恢复均匀的脑部组织, 尤其是在大面积的灰质和白质区域, 重建效果较为一致。然而, 可以从误差图观察到, 不同方法在细节区域, 如脑沟、脑室边缘以及局部细微结构的表现存在显著差异。这些区域的重建误差较大, 可能是在欠采样条件下高频信息的丢失以及算法对复杂解剖结构拟合能力的不足所致。此外, U-Net、MICCAN 在处理边界模糊和噪声抑制之间的权衡时表现欠佳, 进一步加剧了误差的累积。

所提方法能减小重建误差, 其独特之处在于语义模块的集成, 使其能够在保持相似参数量的同时实现更高的重建质量。具体而言, 在 IXI 4×径向采样条件下, 其 PSNR 分别超过 PGIUN 和 H-DSLR (1.07 dB 和 3.25 dB)。这一改进突显了语义模块在提取有意义信息以增强图像重建方面的有效性。同时, 展开方法 (如 H-DSLR 和 PGIUN) 严重依赖计算密集型操作, 导致 FLOPs 更高, 推理时间更长。相比之下, 所提方法在性能和效率之间取得了平衡, 以较低的计算开销实现了更优的结果。这种平衡使之成为高效且实际的 MRI 重建应用方法。

表 2 展示了不同对比方法的计算复杂度和运行时间, 可以看出所提方法在参数量、浮点运算次数和推理时间三个关键指标上展现出均衡且具有竞争力的性能。所提方法的参数量为 1.530 M, 低于 U-Net 的 7.756 M、GA-HQS 的 6.100 M 和 MICCAN 的 2.622 M。在计算复杂度方面, 所提方法的 FLOPs 为 86.3 G, 高于 U-Net 的 11.2 G 和 MICCAN 的 36.6 G, 但低于 GA-HQS 的 120.2 G 和 MDUNet 的 90.7 G, 表明其计算复杂度适中, 可较好平衡性能与计算开销。推理时

表 1 径向、随机、等分三种掩码在 4× 和 8× 加速率下的数值结果

Table 1 Numerical results under three kinds of masks: radial, random and equidistant, and acceleration rates of 4× and 8×

Dataset	Ratio	Mask	Metric	U-Net	MICCAN	MDUNet	GA-HQS	H-DSLR	PGIUN	Ours
IXI	4×	Radial	PSNR	34.04	41.62	45.87	45.28	45.30	47.08	48.15
			SSIM	0.971	0.990	0.992	0.993	0.993	0.995	0.996
		Random	PSNR	31.18	35.42	37.45	37.07	35.98	37.97	39.12
			SSIM	0.953	0.972	0.978	0.980	0.981	0.984	0.989
		Equispaced	PSNR	30.12	33.48	34.96	35.46	33.63	35.50	35.65
			SSIM	0.944	0.964	0.968	0.977	0.965	0.977	0.978
	8×	Radial	PSNR	29.74	32.82	35.48	34.13	34.50	36.26	36.42
			SSIM	0.934	0.958	0.977	0.968	0.971	0.980	0.981
		Random	PSNR	29.05	31.68	34.02	33.58	31.96	34.07	34.11
			SSIM	0.931	0.949	0.959	0.962	0.955	0.964	0.968
		Equispaced	PSNR	27.90	29.98	31.33	31.29	29.80	31.63	31.75
			SSIM	0.921	0.939	0.951	0.940	0.938	0.943	0.953
fastMRI	4×	Radial	PSNR	28.59	30.11	30.18	30.82	30.22	30.96	31.09
			SSIM	0.828	0.861	0.879	0.873	0.865	0.873	0.881
		Random	PSNR	27.86	29.03	30.09	39.98	29.01	30.01	30.15
			SSIM	0.810	0.830	0.843	0.848	0.831	0.849	0.851
		Equispaced	PSNR	27.16	28.11	28.53	28.51	28.23	28.53	28.62
			SSIM	0.779	0.795	0.809	0.807	0.786	0.803	0.826
	8×	Radial	PSNR	26.42	27.41	28.01	27.91	27.28	28.01	28.16
			SSIM	0.723	0.745	0.764	0.789	0.741	0.791	0.816
		Random	PSNR	26.38	27.26	27.65	27.79	27.04	27.75	27.81
			SSIM	0.754	0.771	0.739	0.781	0.762	0.792	0.803
		Equispaced	PSNR	26.21	26.96	27.31	27.33	26.84	27.29	27.34
			SSIM	0.743	0.745	0.747	0.767	0.752	0.768	0.783




图 5 IXI 数据集上使用随机掩膜进行 8× 加速下的重建结果

Fig. 5 Reconstruction results using random masking for 8× acceleration on the IXI dataset

间为 57 ms, 处于对比算法的中间层次。总体而言, 所提方法在保持较低参数数量的同时, 实现了适中的计算复杂度和推理时间, 体现了其在模型效率与性能优化方面的成功权衡, 具有一定的实用性和竞争力。

图 6 展示了在 IXI 数据集上应用随机掩膜策略进行 4 倍和 8 倍下采样时, 模型在验证集上的损失变化

趋势。从图 6 可以看出, 无论是 4 倍加速还是 8 倍加速的情况, 损失值都在训练的初期阶段迅速下降, 这一趋势反映了模型在初期快速学习到了数据中的重要特征。在大约 50 个 epoch 之后, 损失值的下降速度明显减缓并逐渐趋于稳定, 这表明模型已经有效地吸收了数据集中的大部分信息, 并达到了一个相对稳定

的收敛状态, 并且没有出现过拟合现象。

4.2 多线圈信号重建

当式 (1) 中的降解算子 F_u 从单线圈模式转换为多线圈模式时, 即 $F_u = Mf \Rightarrow F_u = \sum_{i=1}^c Mf s_i$ 时, 所提方法可以无缝适应多线圈任务。值得注意的是, U-Net、MoDL 和 H-DSLRL 等方法设计时考虑到多线圈重建。而 PGIUN 也可通过对其数据一致性组件进行

修改来扩展以处理多线圈数据结构。实验结果总结在表 3。

所提方法在所有条件下始终优于其他算法。在等分和随机掩码场景中, 所提方法表现出显著优势, 其 PSNR 超过次优方法 1.50 dB。这些结果验证了所提方法作为一种新颖的 MRI 重建范式的稳定性和可靠性, 突显了其在单线圈和多线圈加速中的强大潜力。

表 2 计算复杂度和运行时间分析结果

Table 2 Computational complexity and runtime analysis results

Method	Params./M	Flops/G	Inference/ms
U-Net	7.756	11.2	21
MICCAN	2.622	36.6	34
MDUNet	1.800	90.7	49
GA-HQS	6.100	120.2	63
H-DSLRL	1.650	85.3	44
PGIUN	1.250	74.8	53
Ours	1.530	86.3	57




图 6 在 IXI 数据集上使用随机掩膜进行 4 倍和 8 倍加速下的验证损失

Fig. 6 Validation loss using random masking for 4-fold and 8-fold acceleration on IXI dataset

表 3 多线圈重建实验结果

Table 3 Multi-coil reconstruction contrast results

Ratio	Mask	Method	PSNR/dB	SSIM	NRMSE
4×	Equispaced	U-Net	25.78	0.877	0.763
		H-DSLRL	31.54	0.942	0.212
		MoDL	29.12	0.919	0.304
		PGIUN	30.01	0.926	0.307
		Ours	32.70	0.958	0.190
6×	Random	U-Net	32.35	0.946	0.222
		H-DSLRL	40.84	0.986	0.073
		MoDL	39.63	0.977	0.081
		PGIUN	38.50	0.976	0.095
		Ours	41.35	0.990	0.062

表 4 模块消融实验结果
Table 4 Module ablation experiment results

No.	Contextual extraction	Multiscale aggregation	Semantic graph reasoning	Dual-scale attention	IXI		Complexity	
					PSNR/dB	SSIM	Param./M	FLOPs/G
1	√				30.01	0.901	4.20	55.30
2		√			30.25	0.912	5.10	66.12
3	√	√			31.10	0.921	6.50	72.45
4	√		√		31.95	0.931	6.80	80.32
5		√	√		32.50	0.940	7.15	85.20
6	√	√	√		33.75	0.950	7.85	95.00
7	√	√	√	√	35.65	0.976	8.17	102.12

4.3 消融实验

本小节进行了消融研究, 以评估模型不同组件的有效性。这些实验在单线圈框架内进行。

表 4 提供了详细的消融研究, 评估了上下文提取、多尺度聚合、语义图推理和双尺度注意力对重建性能的贡献。实验 1 仅包括上下文提取, 得到 PSNR=30.01 dB 和 SSIM=0.9005, 具有最低的计算复杂度 (参数量为 4.20 M, 55.30 GFLOPs)。这一结果突显了模型在提取上下文特征方面的能力, 同时也表明其单独操作时的局限性。实验 2 用多尺度聚合替换上下文提取, 取得轻微改进 (PSNR=30.25 dB, SSIM=0.9124), 这反映了多尺度聚合在多尺度信息提取方面的有效性。实验 3 结合上述两实验, 显著提高了性能 (PSNR=31.10 dB, SSIM=0.9208), 展示了融合上下文特征和多尺度聚合的互补作用。实验 4 将语义图推理与上下文提取结合, PSNR 为 31.95 dB, SSIM 为 0.9305。添加语义图推理提高了基于图的捕捉复杂语义关系的模型能力, 与没有语义推理的配置相比, 重建质量显著提高。实验 5 将多尺度聚合和语义图推理结合, 进一步提高了性能, PSNR 为 32.50 dB, SSIM 为 0.9401。此配置突显了多尺度聚合和语义推理在处理复杂结构方面的综合优势。实验 6 使用除语义图推理之外的组件, PSNR 为 33.73 dB, SSIM 为 0.9500。尽管此设置保持了相对较高的性能, 但省略语义图推理表明其关键作用, 因为双尺度注意力增强了对相关特征的关注, 同时减轻了重建过程中的噪声。实验 7 集成了所有组件, 实现了最佳重建性能, PSNR 为 35.65 dB, SSIM 为 0.9760, 计算成本最高 (参数量为 8.17 M, 102.12 GFLOPs)。完整配置利用了上下文提取、多尺度集成、语义推理和注意力机制, 可产生准确鲁棒的重建结果。这些结果验证了每个模块的基本贡献及其

协同效应, 通过实验的增量性能改进反映了集成这些组件以平衡重建质量和计算复杂度的价值。

5 结 论

本研究提出了一种用于快速 MRI 成像的联合分层语义网络与物理模型, 集成了语义信息以解决重建任务中的关键挑战。与传统方法结合深度学习和基于模型的方法不同, 利用四个关键模块 (上下文提取模块、多尺度间聚合模块、语义图推理模块和双尺度注意模块) 提高图像质量和计算效率。实验结果表明, 集成语义信息不仅提高了重建性能, 还使得在涉及复杂解剖结构和高加速比的场景中实现了更优的组织区分和伪影抑制。本研究强调语义感知架构在提升 MRI 重建效果的重要性。未来的工作将集中于优化语义特征的集成, 以进一步提高重建质量。此外, 还计划将框架扩展到更复杂和动态的场景, 如更高的加速因子和多样的采样模式, 以提高其在临床和实际应用中的鲁棒性和适用性。

利益冲突: 所有作者声明无利益冲突

参考文献

[1] Zhang Z J, Wang T Y, Xu X, et al. Effect of polarized laser illumination on imaging contrast of multilayer thin film structure[J]. *Opto-Electron Eng*, 2023, 50(7): 230089.
张子建, 王天义, 徐欣, 等. 偏振激光照明对多层薄膜结构成像对比度影响[J]. *光电工程*, 2023, 50(7): 230089.

[2] Zhang Z J, Xu X, Wang J X, et al. Review of the development of light sheet fluorescence microscopy[J]. *Opto-Electron Eng*, 2023, 50(5): 220045.
张子建, 徐欣, 王吉祥, 等. 光片荧光显微镜研究进展[J]. *光电工程*, 2023, 50(5): 220045.

[3] Abraham E, Zhou J X, Liu Z W. Speckle structured illumination endoscopy with enhanced resolution at wide field of view and depth of field[J]. *Opto-Electron Adv*, 2023, 6(7): 220163.

[4] Yan F H. The clinical application and development prospect of

- deep learning MRI reconstruction algorithm[J]. *Chin J Magn Reson Imaging*, 2023, **14**(5): 8–10.
- 严福华. 深度学习 MRI 重建算法的临床应用和发展前景[J]. *磁共振成像*, 2023, **14**(5): 8–10.
- [5] Lustig M, Donoho D, Pauly J M. Sparse MRI: the application of compressed sensing for rapid MR imaging[J]. *Magn Reson Med*, 2007, **58**(6): 1182–1195.
- [6] Liu J S, Qin C, Yaghoobi M. High-fidelity MRI reconstruction using adaptive spatial attention selection and deep data consistency prior[J]. *IEEE Trans Comput Imaging*, 2023, **9**: 298–313.
- [7] Sandino C M, Cheng J Y, Chen F Y, et al. Compressed sensing: from research to clinical practice with deep neural networks: shortening scan times for magnetic resonance imaging[J]. *IEEE Signal Process Mag*, 2020, **37**(1): 117–127.
- [8] Goujon A, Neumayer S, Bohra P, et al. A neural-network-based convex regularizer for inverse problems[J]. *IEEE Trans Comput Imaging*, 2023, **9**: 781–795.
- [9] Hou R Z, Li F, Zhang G X. Truncated residual based plug-and-play ADMM algorithm for MRI reconstruction[J]. *IEEE Trans Comput Imaging*, 2022, **8**: 96–108.
- [10] Xie J F, Zhang J, Zhang Y B, et al. PUERT: probabilistic under-sampling and explicable reconstruction network for CS-MRI[J]. *IEEE J Sel Top Signal Process*, 2022, **16**(4): 737–749.
- [11] Li P, Chen W G, Ng M K. Compressive total variation for image reconstruction and restoration[J]. *Comput Math Appl*, 2020, **80**(5): 874–893.
- [12] Xu H H, Jiang J W, Feng Y C, et al. Tensor completion via hybrid shallow-and-deep priors[J]. *Appl Intell*, 2023, **53**(13): 17093–17114.
- [13] Sandilya M, Nirmala S R. Compressed sensing MRI reconstruction using convolutional dictionary learning and Laplacian prior[M]//Senjyu T, Mahalle P, Perumal T, et al. *IOT with Smart Systems: Proceedings of ICTIS 2021, Volume 2*. Singapore: Springer, 2022: 661–669. https://doi.org/10.1007/978-981-16-3945-6_65.
- [14] Zhang X M, Ma J W, Zhang H. Curvature-regularized manifold for seismic data interpolation[J]. *Geophysics*, 2023, **88**(1): WA37–WA53.
- [15] Jiang J W, He Z H, Quan Y Q, et al. PGIUN: physics-guided implicit unrolling network for accelerated MRI[J]. *IEEE Trans Comput Imaging*, 2024, **10**: 1055–1068.
- [16] Pramanik A, Aggarwal H K, Jacob M. Deep generalization of structured low-rank algorithms (Deep-SLR)[J]. *IEEE Trans Med Imaging*, 2020, **39**(12): 4186–4197.
- [17] Chen Y W, He Y, Ye H, et al. Unified deep learning model for predicting fundus fluorescein angiography image from fundus structure image[J]. *J Innov Opt Health Sci*, 2024, **17**(3): 2450003.
- [18] Geng C H, Jiang M F, Fang X, et al. HFIST-Net: high-throughput fast iterative shrinkage thresholding network for accelerating MR image reconstruction[J]. *Comput Methods Programs Biomed*, 2023, **232**: 107440.
- [19] Zhang J, Zhang Z Y, Xie J F, et al. High-throughput deep unfolding network for compressive sensing MRI[J]. *IEEE J Sel Top Signal Process*, 2022, **16**(4): 750–761.
- [20] Arabi H, Zeng G D, Zheng G Y, et al. Novel adversarial semantic structure deep learning for MRI-guided attenuation correction in brain PET/MRI[J]. *Eur J Nucl Med Mol Imaging*, 2019, **46**(13): 2746–2759.
- [21] Panić M, Aelterman J, Crnojević V, et al. Sparse recovery in magnetic resonance imaging with a Markov random field prior[J]. *IEEE Trans Med Imaging*, 2017, **36**(10): 2104–2115.
- [22] Ke Z W, Huang W Q, Cui Z X, et al. Learned low-rank priors in dynamic MR imaging[J]. *IEEE Trans Med Imaging*, 2021, **40**(12): 3698–3710.
- [23] Abdullah S, Arif O, Mehmud T, et al. Compressed sensing MRI reconstruction using low dimensional manifold model[C]//*Proceedings of 2019 IEEE EMBS International Conference on Biomedical & Health Informatics*, 2019: 1–4. <https://doi.org/10.1109/BHI.2019.8834498>.
- [24] Wang J, Zong Y, He Y, et al. Domain adaptation-based automated detection of retinal diseases from optical coherence tomography images[J]. *Curr Eye Res*, 2023, **48**(9): 836–842.
- [25] Jethi A K, Murugesan B, Ram K, et al. Dual-Encoder-Unet for fast MRI reconstruction[C]//*Proceedings of 2020 IEEE 17th International Symposium on Biomedical Imaging Workshops*, 2020: 1–4. <https://doi.org/10.1109/ISBIWorkshops50223.2020.9153453>.
- [26] Lee D, Yoo J, Tak S, et al. Deep residual learning for accelerated MRI using magnitude and phase networks[J]. *IEEE Trans Biomed Eng*, 2018, **65**(9): 1985–1995.
- [27] Wang Z X, Wang Z W, Zhang Z Z, et al. PFONet: a progressive focus-oriented dual-domain reconstruction network for accelerated MRI[J]. *J Sichuan Univ (Nat Sci Ed)*, 2024, **61**(5): 053004.
王钟贤, 王志文, 张中洲, 等. PFONet: 一种用于加速 MRI 的渐进式聚焦导向双域重建网络[J]. *四川大学学报 (自然科学版)*, 2024, **61**(5): 053004.
- [28] Korkmaz Y, Yurt M, Dar S U H, et al. Deep MRI reconstruction with generative vision transformers[C]//*Proceedings of the 4th International Workshop Machine Learning for Medical Image Reconstruction*, 2021: 54–64. https://doi.org/10.1007/978-3-030-88552-6_6.
- [29] Aggarwal H K, Mani M P, Jacob M. MoDL: model-based deep learning architecture for inverse problems[J]. *IEEE Trans Med Imaging*, 2019, **38**(2): 394–405.
- [30] Yang G, Zhang L, Zhou M, et al. Model-guided multi-contrast deep unfolding network for MRI super-resolution reconstruction[C]//*Proceedings of the 30th ACM International Conference on Multimedia*, 2022: 3974–3982.
- [31] Zhang X H, Lian Q S, Yang Y C, et al. A deep unrolling network inspired by total variation for compressed sensing MRI[J]. *Digital Signal Process*, 2020, **107**: 102856.
- [32] Huang Q Y, Yang D, Wu P X, et al. MRI reconstruction via cascaded channel-wise attention network[C]//*Proceedings of 2019 IEEE 16th International Symposium on Biomedical Imaging*, 2019: 1622–1626. <https://doi.org/10.1109/ISBI.2019.8759423>.
- [33] Jiang J W, Wu J, Quan Y Q, et al. Memory-augmented dual-domain unfolding network for MRI reconstruction[C]//*Proceedings of the ICASSP 2024–2024 IEEE International Conference on Acoustics, Speech and Signal Processing*, 2024: 1651–1655. <https://doi.org/10.1109/ICASSP48485.2024.10446091>.
- [34] Jiang J W, Chen J C, Xu H H, et al. GA-HQS: MRI reconstruction via a generically accelerated unfolding approach[C]//*Proceedings of 2023 IEEE International Conference on Multimedia and Expo*, 2023: 186–191. <https://doi.org/10.1109/ICME55011.2023.00040>.
- [35] Xin B Y, Phan T, Axel L, et al. Learned half-quadratic splitting network for MR image reconstruction[C]//*Proceedings of the*

5th International Conference on Medical Imaging with Deep Learning, 2022: 1403–1412.

- [36] Beck A, Teboulle M. A fast iterative shrinkage-thresholding algorithm for linear inverse problems[J]. *SIAM J Imaging Sci*, 2009, 2(1): 183–202.
- [37] Chen J C, Jiang J W, Wu F, et al. Null space matters: range-null decomposition for consistent multi-contrast MRI reconstruction[C]//Proceedings of the 38th AAAI Conference on Artificial Intelligence, 2024: 1081–1090. <https://doi.org/10.1609/aaai.v38i2.27869>.
- [38] Li Y, Gupta A. Beyond grids: learning graph representations for visual recognition[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems, 2018:

9245–9255.

- [39] Cheng S, Wang Y Z, Huang H B, et al. NBNNet: noise basis learning for image denoising with subspace projection[C]//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 4896–4906. <https://doi.org/10.1109/CVPR46437.2021.00486>.
- [40] Zbontar J, Knoll F, Sriram A, et al. fastMRI: an open dataset and benchmarks for accelerated MRI[Z]. arXiv: 1811.08839, 2018. <https://doi.org/10.48550/arXiv.1811.08839>.
- [41] Uecker M, Lai P, Murphy M J, et al. ESPIRiT—an eigenvalue approach to autocalibrating parallel MRI: where SENSE meets GRAPPA[J]. *Magn Reson Med*, 2014, 71(3): 990–1001.

作者简介



张晓敏 (1978-), 女, 硕士, 副教授, CCF 会员, CCF 职业教育发展委员会执行委员, 研究方向为大数据技术、人工智能技术应用、软件工程等。

E-mail: xm_zhang1978@hotmail.com



【通信作者】鲍玲鑫 (1982-), 男, 博士, 教授, 研究方向为数理统计与机器学习。


E-mail: bolingxmu@sina.com



扫描二维码, 获取PDF全文

Integrating hierarchical semantic networks with physical models for MRI reconstruction

Zhang Xiaomin¹, Bao Lingxin^{2*}



Schematic diagram of the algorithm process

Overview: Magnetic resonance imaging (MRI) is a critical tool in biomedical research and clinical practice due to its exceptional soft tissue contrast and non-invasive, radiation-free imaging capabilities. However, its prolonged acquisition times (resulting from sequential k-space sampling) limit its efficiency in clinical workflows, patient comfort, and applicability in time-sensitive or large-scale screening scenarios. To address this challenge, undersampled k-space reconstruction techniques, particularly compressive sensing (CS), have been widely adopted. While CS leverages signal sparsity and prior knowledge to preserve image quality, aggressive undersampling often introduces aliasing artifacts, which complicates accurate reconstruction. Traditional model-driven methods, which rely on handcrafted priors (such as, sparsity, total variation, low-rank constraints), struggle to adapt to the complexity of real-world MRI data distributions. Meanwhile, deep learning approaches, despite their success in feature learning, often neglect physical degradation mechanisms. Additionally, they fail to capture semantic-level features necessary for distinguishing anatomical structures and suppressing artifacts.

Recent efforts aim to bridge model-driven and data-driven paradigms, but existing methods remain constrained by rigid feature representations, inadequate multi-scale context integration, and insufficient semantic reasoning. For example, the prior models prioritize shallow visual features over deeper anatomical semantics, limiting their ability to generalize across diverse tissue types and reconstruct high-fidelity images under extreme undersampling. To address these limitations, this paper proposes a physics-informed hierarchical semantic network (PHSN), an innovative framework that unifies physical signal principles with semantic-aware deep learning. The architecture integrates four core modules: 1) a context extraction module to capture spatial dependencies across scales; 2) a scale-aggregation module for hierarchical feature fusion; 3) a semantic graph reasoning module to model tissue-specific relationships and enhance artifact suppression via graph-based inference; 4) a dual-scale attention module to prioritize anatomical details at both coarse (global structure) and fine (local tissue) spatial levels. The overall framework is illustrated in Fig. 7.

By embedding physical k-space sampling constraints into hierarchical feature learning and explicitly modeling semantic relationships, PHSN achieves robust reconstruction under high acceleration factors (e.g., 8-fold) while preserving diagnostic image fidelity. Comprehensive experiments on diverse datasets (e.g., IXI) demonstrate that the proposed method outperforms state-of-the-art approaches in suppressing artifacts, maintaining anatomical accuracy, and balancing acceleration efficiency with clinical reliability. The framework's hierarchical design enables adaptive feature optimization across scales, effectively mitigating aliasing artifacts and improving visibility of complex anatomical structures. This study advances MRI reconstruction by integrating interpretable physics-based constraints with data-driven semantic understanding, offering a pathway toward faster, higher-quality imaging for clinical and research applications.

Zhang X M, Bao L X. Integrating hierarchical semantic networks with physical models for MRI reconstruction[J]. *Opto-Electron Eng*, 2025, 52(5): 250016; DOI: 10.12086/oe.2025.250016

Foundation item: 2023 Cognition and Intelligence National Key Laboratory Topic (COGOS-2023HE03), Natural Science Foundation of Fujian Province (2023J01471), Special Fund for Key Laboratory Construction Project of Fujian Province for Smart Agriculture and Forestry in Universities (KJG23033A), and Science and Technology Innovation Special Fund of Fujian Agricultural and Forestry University (KFB23159)

¹The Internet of Things and Artificial Intelligence College, Fujian Polytechnic of Information Technology, Fuzhou, Fujian 350003, China; ²College of Computer and Information Sciences, Fujian Agriculture and Forestry University, Fuzhou, Fujian 350002, China

* E-mail: bolingxmu@sina.com