

DOI:10.3969/j.issn.1005-202X.2026.03.003

医学影像物理

基于噪声自适应感知的低场MRI图像增强方法

刘琪¹, 胡宇韬², 杨淳沅², 陈阳^{1,2}

1. 南方医科大学生物医学工程学院, 广东 广州 510515; 2. 东南大学计算机科学与工程学院, 江苏 南京 211189

【摘要】目的:对低场核磁共振成像(MRI)设备采集的低信噪比、高噪声的MRI图像进行高效且鲁棒的质量提升。**方法:**针对缺乏一一对应的高场-低场MRI图像的问题,提出在高场MRI图像的K空间数据上进行加噪声和图像域欠采样的低场MRI图像模拟方法,获得用于训练的高场-低场MRI图像数据集。针对难以感知低场MRI图像中噪声强度的问题,提出带有噪声自适应感知分支的双路去噪增强网络,使用公开数据集IXI和fastMRI的数据构建用于训练的数据集,实现对低场图像噪声的有效感知以及对低场图像质量的显著增强。针对难以量化低场图像增强质量的问题,提出采用弗雷歇初始距离(FID)和学习型感知图像块相似度(LPIPS)评估增强后的低场MRI图像的图像质量方法,实现对低场MRI图像增强效果的科学评估。**结果:**在真实低场数据中,双路去噪增强网络表现出了最好的去噪以及细节保留效果。以IXI数据集进行训练,FID和LPIPS分别为0.4729和149.6493;以fastMRI数据集进行训练,FID和LPIPS分别为0.4734和148.4323。**结论:**基于噪声自适应的低场MRI图像增强方法能够较好地低场图像进行增强,能够有效推进低场MRI设备在临床上的应用。

【关键词】低场MRI; 图像增强; 深度学习; 双分支网络

【中图分类号】R318;R445.2

【文献标志码】A

【文章编号】1005-202X(2026)03-0293-07

Low-field MRI image enhancement method based on adaptive noise perception

LIU Qi¹, HU Yutao², YANG Chunfeng², CHEN Yang^{1,2}

1. School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China; 2. School of Computer Science and Engineering, Southeast University, Nanjing 211189, China

Abstract: Objective To achieve efficient and robust quality enhancement for low signal-to-noise ratio (SNR) and high-noise-level magnetic resonance imaging (MRI) images acquired by low-field MRI devices. **Methods** Given the lack of one-to-one paired high- and low-field MRI images, a simulation method was developed to generate low-field MR images by adding noise into the K-space data of high-field MRI images and performing undersampling in the image domain, thereby constructing a paired high- and low-field MRI image dataset for training. A dual-path denoising and enhancement network with an adaptive noise perception branch was introduced to tackle the difficulty in perceiving noise intensity in low-field MR images. Publicly available datasets IXI and fastMRI were used to establish training datasets for enabling effective noise perception and significant quality enhancement of low-field images. In addition, Fréchet inception distance (FID) and learned perceptual image patch similarity (LPIPS) were adopted to evaluate the quality of enhanced low-field MR images, which overcame the challenge of quantifying enhancement performance in low-field MRI images, and enabled a scientific assessment of the efficacy of low-field MRI image enhancement. **Results** On real low-field data, the dual-path denoising and enhancement network exhibited the best performance in both denoising and detail preservation. When trained on the IXI dataset, the FID and LPIPS values reached 0.4729 and 149.6493, respectively; when trained on the fastMRI dataset, the corresponding values were 0.4734 and 148.4323, respectively. **Conclusion** The low-field MRI image enhancement method based on adaptive noise perception can effectively enhance low-field images, which promotes the clinical application of low-field MRI devices.

Keywords: low-field magnetic resonance imaging; image enhancement; deep learning; dual-path network

【收稿日期】2025-08-19

【基金项目】国家杰出青年科学基金(T2225025)

【作者简介】刘琪, 硕士研究生, 研究方向: 人工智能医学影像、MRI图像处理, E-mail: 1208857531@qq.com

【通信作者】陈阳, 教授, 研究方向: 人工智能应用、计算机视觉、智能图像处理, E-mail: chenyang.list@seu.edu.cn

前言

核磁共振成像(MRI)凭借高分辨率、非接触式成像及多对比度优势,已成为推动医学、神经生物学与认知神经科学发展的核心诊断技术。自1977年问世

以来,以1.5T为代表的高场MRI设备虽长期作为临床标准^[1-2],但其高昂的购置与维护成本、复杂的电磁屏蔽要求,严重制约了广泛应用,尤其在欠发达地区,此类设备的普及度不高^[3]。在此背景下,低场MRI设备因成本低廉、屏蔽需求低、体积小巧的特性,成为空间受限场景(如基层医疗机构、移动诊疗)的研究热点^[4]。2018年以来,0.064T Hyperfine Swoop、0.55T Siemens Magnetom FreeMax等低场系统陆续推向市场^[5-7],进一步印证其医学应用潜力,但成像质量优化始终是制约其释放临床价值的核心技术瓶颈^[8-10]。低场MRI图像普遍存在噪声干扰严重、组织细节模糊、伪影明显等问题,难以满足临床诊断中对细微结构(如微小病灶、脑组织边缘)的精准识别需求。随着人工智能技术在医学影像处理领域的快速渗透,深度学习为突破低场MRI成像质量瓶颈提供新路径。研究者尝试通过卷积神经网络、Transformer、生成对抗网络等架构,构建端到端的噪声抑制与细节增强模型,以数据驱动方式学习低场图像到高场图像的映射关系,进而改善低场MRI图像的视觉质量与诊断价值。然而,当前相关技术仍处于持续优化与迭代阶段,要实现满足临床诊断标准的增强效果,需克服多重关键挑战。首先,低场与高场MRI设备的信号采集机制存在本质差异,高场设备依托强主磁场可获得更高的质子纵向弛豫(T_1)与横向弛豫(T_2)信号对比度,而低场设备信号强度弱且易受组织磁化率差异干扰,加之现有扫描模式无法确保两次扫描层面完全一致,导致“低场-高场配对图像缺失”,直接制约依赖大量精准配对数据的深度监督式训练方法的应用,使模型难以有效学习噪声与信号的区分规律。其次,低场MRI图像的噪声呈非高斯、空间异质分布特征,传统去噪算法在抑制噪声时易过度平滑关键细节,而现有深度学习方法因对噪声的感知能力不足,仍难以平衡噪声去除与细节保留的关系,影响后续诊断准确性。最后,过往研究多采用“高场图像模拟低场图像”的方式构建评估数据集,通过在图像域劣化高场图像模拟低场噪声,但人工模拟噪声与真实低场噪声在分布特征、强度异质性上差异显著,且真实噪声还受设备硬件、患者生理状态等复杂因素影响,导致模拟数据上的模型性能与真实临床场景效果偏差较大,峰值信噪比(PSNR)、结构相似性系数(SSIM)等像素级评估指标也无法反映图像的临床诊断相关性。

针对上述挑战,本研究从数据构建、网络设计与评估体系3方面提出解决方案。为解决配对图像缺失问题,研究从K空间入手,在高场K空间数据上添加随机复高斯噪声以拟合实际MRI图像采集过程中

的噪声,再对加噪后图像进行下采样,生成低场与高场MRI图像的配对数据。为平衡噪声去除与细节保留,设计双路去噪增强网络,通过噪声自适应感知分支多尺度学习噪声强度与分布,去噪主干分支提取图像整体信息,两分支借助卷积块实现信息融合,噪声感知分支的权重输出动态调整去噪滤波强度,去噪分支的特征反馈优化噪声感知准确性,最终输出高质量图像以支撑脑灰质体积测量、微小病灶检出等临床任务。为完善评估体系,研究与鑫高益医疗设备有限公司合作,采集大致一一对应的0.1T低场和1.5T高场头部MRI图像数据集,并采用学习型感知图像块相似度(LPIPS)^[11]和弗雷歌初始距离(FID)^[12]替代传统指标,从单图感知质量与图集分布一致性两个维度,科学衡量优化后图像与高场图像的接近程度,更客观验证方法在真实场景中的应用价值。

1 方法

1.1 基于MRI成像噪声原理的低场模拟方法

为充分挖掘深度学习监督训练的强表征能力,同时遵循MRI的物理原理,本研究构建基于MRI噪声原理的低场模拟方法,旨在充分释放深度学习监督训练的强表征能力。该框架以MRI的信号生成与传播规律为约束,通过K空间物理噪声污染、图像域空间分辨率匹配、噪声图像分离3步流程,从临床常用的1.5T脑部MRI数据中精准模拟0.1T低场成像效果,为后续双路去噪增强网络的监督训练提供兼具物理真实性与标签可靠性的配对数据。

MRI图像的噪声分布并非传统的高斯分布,而是由信号采集原理决定的莱斯分布,其本质是质子进动产生的相干信号与热噪声、电磁干扰等非相干噪声的叠加结果。当信号强度较高时(如脑白质区域),噪声近似高斯分布;当信号强度较低时(如脑脊液、图像背景区域),噪声呈现明显的莱斯分布特征。对于0.1T低场设备,由于主磁场强度仅为1.5T的1/15,质子磁化强度显著降低,导致信号强度低、信噪比远低于1.5T设备,莱斯噪声特性更为突出。为了拟合这一现象,本研究构建复合高斯噪声模型用于K空间污染,该模型基于MRI信号的复数域特性,通过在K空间的实部与虚部分量中分别注入噪声,以对应数据的幅度和相位信息,确保噪声传播过程符合傅里叶变换的物理规律。具体而言,对于高场的K空间数据 K_{hf} :

$$K_{\text{hf}}(u, v) = K_{\text{real}}(u, v) + j \cdot K_{\text{imag}}(u, v) \quad (1)$$

其中, (u, v) 表示K空间的二维坐标, K_{real} 和 K_{imag} 分别是实部和虚部, j 为虚数单位。为了拟合低场MRI图像的噪声分布,本研究在K空间的实部和虚部分量上

注入的噪声分别为 $N_{\text{real}}(u, v)$ 和 $N_{\text{imag}}(u, v)$, 二者均服从均值为0和标准差为 σ^2 的随机高斯分布, 污染后的K空间数据 K_{noisy} 表达式为:

$$K_{\text{noisy}}(u, v) = K_{\text{real}}(u, v) + N_{\text{real}}(u, v) + j \cdot (K_{\text{imag}}(u, v) + N_{\text{imag}}(u, v)) \quad (2)$$

该噪声注入方式的核心优势在于保留频域噪声的相干特性, 传统图像域加噪是在空间域直接叠加噪声, 会破坏信号的傅里叶相位相关性(如导致高频细节的相位失真), 而K空间物理噪声污染在K空间注入复高斯噪声, 可与原始K空间数据的幅度、相位信息自然融合, 更贴合MRI设备中信号从K空间采集到图像域重建的物理流程。在K空间加噪声之后, 通过离散逆傅里叶变换将频域数据转换到图像域:

$$I_{\text{noisy}}(x, y) = F^{-1}(K_{\text{noisy}}) \quad (3)$$

为了匹配低场MRI图像的空间分辨率限制, 本研究基于真实0.1T MRI数据的分辨率参数, 对 I_{noisy} 进行降采样处理, 得到最终的模拟低场图像 I_{lf} :

$$I_{\text{lf}} = \text{downsample}(I_{\text{noisy}}) \quad (4)$$

该步骤解决传统模拟方法中分辨率不匹配导致的解剖结构失真问题。为了给予双路去噪增强网络进一步的数据支撑, 本研究通过图像域信号分离获取模拟低场图像对应的噪声图像 I_{noise} , 为了避免分辨率不匹配的问题, 本研究根据未降采样的 $I_{\text{noisy}}(x, y)$ 和高场图像数据 I_{hf} 获得 I_{noise} :

$$I_{\text{noise}} = I_{\text{hf}}(x, y) - I_{\text{noisy}}(x, y) \quad (5)$$

该噪声图像不仅保留了模拟低场图像中噪声的空间分布特征(如背景区域噪声强度高、脑组织边缘噪声强度低), 还可作为噪声自适应感知分支的监督标签, 为网络提供精准的噪声感知监督信号。

1.2 双路去噪增强网络

利用第1.1小节中提出的基于MRI噪声原理的加噪声方法, 能够克服实际中难以获得的一一对应的高场-低场MRI图像这一问题。在具备充足训练数据的情况下, 本研究设计双路去噪增强网络用于低场图像的优化增强。双路去噪增强网络针对低场MRI图像优化中去噪易失细节、保细节难抑噪的固有矛盾, 将任务拆解为两个并行且互补的分支。去噪主干分支以恢复高频解剖细节为核心目标, 通过混合注意力机制捕捉图像的局部纹理与全局结构特征, 在抑制噪声的同时重点保留临床诊断所需的关键细节信息。噪声自适应感知分支则以精准预测噪声分布为核心目标, 通过对称编码-解码结构, 学习低场图像中噪声的空间异质性与强度差异, 为去噪主干提供噪声定位与强度指导。两分支通过末端的卷

积层实现信息交互融合, 最终输出兼顾去噪效果与细节完整性的增强图像。这种架构区别于传统单分支端到端去噪网络的核心优势在于将细节恢复与噪声感知解耦后分别优化, 避免单一分支在去噪强度与细节保留度之间的被动权衡, 显著提升网络对复杂噪声场景的适应性。

去噪主干分支采用浅层特征提取、深层特征强化、跨尺度特征聚合的3级结构, 核心在于引入混合注意力模组(RHAG), 通过窗口自注意力、通道注意力和空间注意力的组合实现对噪声与有效信号的精准区分。输入的低场MRI图像首先经过1个 3×3 卷积层, 将图像从像素空间映射至低维特征空间以提取边缘、纹理等浅层特征 F_{shallow} 。随后, F_{shallow} 逐步输入9个串联的混合注意力模组, 逐步学习得到为包含全局结构与局部细节的深层特征 F_{deep} 。最后, 通过1个 3×3 卷积层实现 F_{shallow} 与 F_{deep} 的跨尺度聚合, 并调整特征通道权重分配以突出细节恢复关键通道, 输出初步去噪后的细节特征图 F_{df} 。如图1d所示, 混合注意力模组由9个混合注意力机制块(HAB)、1个重叠交叉注意力块(OCAB)、1个 3×3 卷积层以及残差连接组成。如图1g所示, HAB采用类似swin transformer^[13]的结构, 引入通道注意力机制^[14]和空间注意力机制^[15]。其中, 滑动窗口注意力块将特征图划分为多个局部窗口计算自注意力权重以强化解剖结构关联性, 通道注意力层通过全局平均池化计算通道权重以激活细节相关通道, 空间注意力层通过逐通道池化融合生成空间权重图以定位细节密集区域, 三者协同扩大网络的感受野。如图1h所示, OCAB由一个重叠交叉注意力机制层、一个多层感知机(MLP)层以及两个层归一化和两段跳跃连接组成。重叠交叉注意力机制层将特征图划分为 5×5 且重叠50%的窗口, 通过跨窗口连接捕捉长距离解剖结构特征, MLP则实现特征非线性变换, 该设计避免细节信息碎片化, 并降低网络的参数量, 而残差连接可以缓解梯度消失问题。

噪声自适应感知分支以原始低场MRI图像 I_{lf} 为输入, 采用类似U-Net^[16]的对称编码-解码架构, 整体由编码器、中间注意力层、解码器及噪声重建层组成, 最终输出像素级预测噪声分布图 I_{pn} 。首先, 编码器采用两次下采样操作与编码单元特征强化相结合的结构, 通过降低空间分辨率、提升通道维度捕捉噪声全局分布。如图1e所示, 第1个编码单元由1个 3×3 卷积层、1个BN层、ReLU结构和1个最大池化层组成, 输出尺寸为输入的1/2、通道32的特征图 F_{e1} 以捕捉局部噪声强度。第2个编码单元结构相同但输出

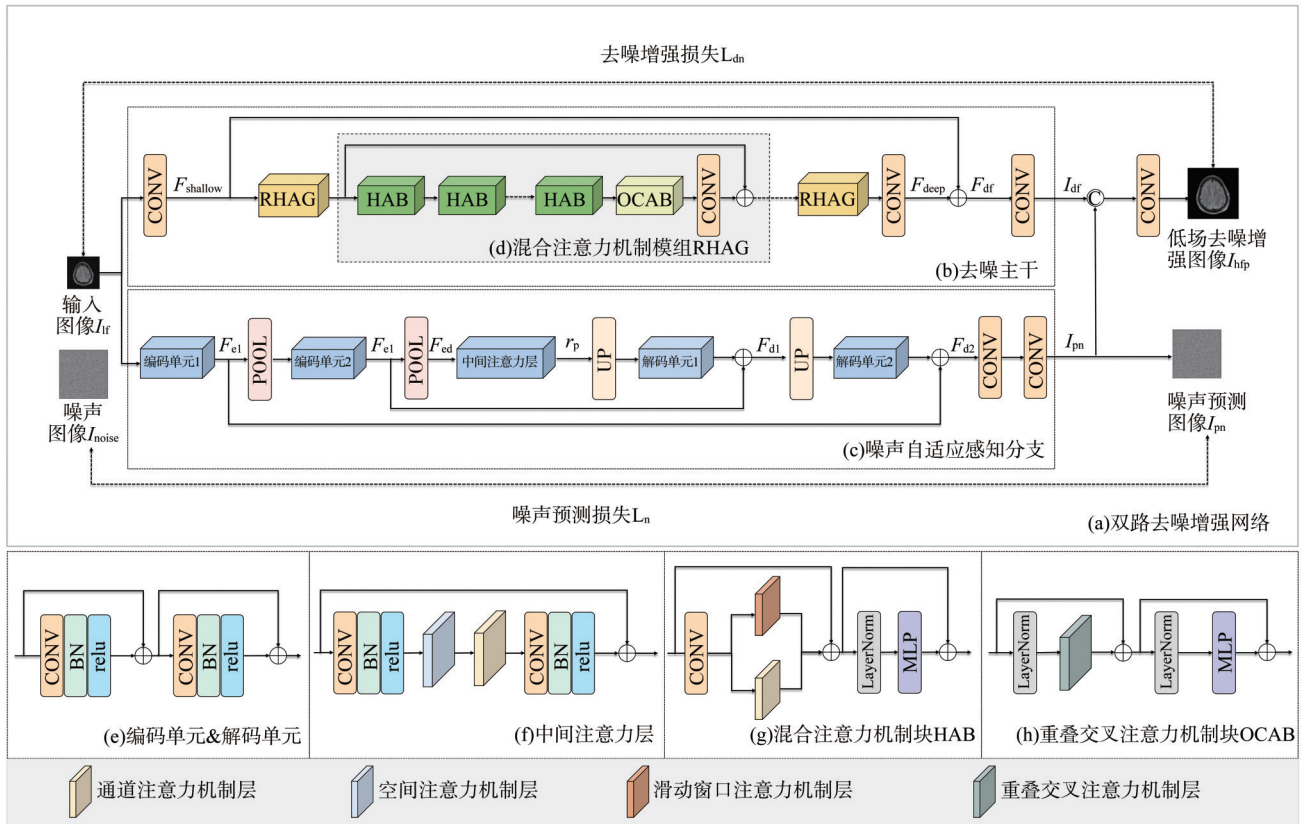


图 1 双路去噪增强网络的结构

Figure 1 Structure of the dual-path denoising and enhancement network

尺寸为输入的 1/4, 通道提升至 64 的 F_{e2} 以捕捉跨区域噪声差异, 最终编码器输出整合全局噪声信息的深层特征 F_{e2} 。其次, 为解决噪声分布不均的问题, 编码器与解码器间增设中间注意力层。如图 1f 所示, 中间注意力层由空间注意力与通道注意力串联组成。其中通道注意力对 F_{e2} 进行全局平均池化以计算通道噪声贡献权重, 激活组织与噪声差异相关通道; 空间注意力通过逐通道池化融合生成空间注意力图, 定位噪声密集区域, 最终输出包含不均匀噪声信息的潜在表示 r_p 。随后, 解码器采用与编码器对称的两次上采样操作与跳跃连接相结合的结构, 并且使用和编码单元架构相同的解码单元。第 1 个解码单元通过 2×2 卷积将尺寸翻倍, 经 3×3 卷积、BN 层、ReLU 处理后与 F_{e2} 跳跃连接输出通道 32、尺寸为输入的 1/2 F_{d1} ; 第 2 个解码单元同理恢复尺寸至输入大小, 与 F_{e1} 跳跃连接输出通道 32、尺寸与输入一致的 F_{d2} 。最后, 通过一个卷积层将 F_{d2} 通道压缩至 1, 得到反映各像素噪声强度的 I_{pn} 。

为实现噪声抑制与细节保留的动态平衡, 本研究设计自适应特征聚合模块, 通过 1 个 3×3 卷积层对去噪主干输出的细节特征图 F_{df} 与噪声感知分支输出的噪声分布图 I_{pn} 进行融合。首先将 F_{df} 通过 1×1 卷积

压缩至 1 个通道, 得到与 I_{pn} 维度一致的单通道细节图 I_{df} ; 随后聚合卷积层通过训练动态优化权重参数, 对于 I_{pn} 中像素值高的高噪声区域, 网络自动提升噪声抑制权重以降低 I_{pn} 对最终输出的贡献; 对于 I_{df} 中边缘梯度大的细节密集区域, 自动提升细节保留权重以增加 I_{df} 的贡献。最终聚合模块输出增强后的低场 MRI 图像 I_{hfp} , 其表达式可简化为:

$$I_{hfp} = \text{conv}(\text{concatenate}(I_{df}, I_{pn})) \quad (6)$$

该式直观体现网络融合噪声分布图与细节特征图, 最终实现噪声有效去除、细节完整保留的增强效果。

1.3 损失函数的构成

本研究提出方法的损失函数由两部分构成, 即噪声预测损失 L_n 和去噪增强损失 L_{dn} 。噪声预测损失 L_n 计算噪声预测分支预测的噪声 I_{pn} 和实际注入的复合噪声 I_{noise} 之间的 L1 损失:

$$L_n = \text{L1}(I_{pn}, I_{noise}) \quad (7)$$

图像去噪增强损失则计算最终模型输出的高质量干净图像 I_{hfp} 和真实的高场图像 I_{hf} 之间的 L1 损失:

$$L_{dn} = \text{L1}(I_{hfp}, I_{hf}) \quad (8)$$

最终完整的损失函数 L_{cn} 由这两个部分相加得到:

$$L_{cn} = L_n + L_{dn} \quad (9)$$

2 实验

2.1 实验数据集

本研究主要使用3个数据集,包括开源的fastMRI数据集^[17]、IXI数据集^[18],以及使用鑫高益公司的MRI设备采集的0.1T低场图像和相近扫描层面的1.5T高场脑部MRI图像数据集。训练阶段构建两组高场-低场MRI图像训练集,一组源自IXI数据集,含 T_1 、 T_2 加权序列脑部MRI图像各8000张;另一组取自fastMRI数据集,序列与图像数量同前。两组训练集的模拟低场图像,均通过第1.1小节基于MRI成像噪声原理的低场模拟方法生成,确保噪声分布与空间分辨率匹配真实低场设备特性。

每个训练集的测试含两类实验:一是模拟测试,采用与训练集同源的IXI、fastMRI数据集1.5T图像,经第1.1小节方法模拟为0.1T低场图像,形成IXI模拟测试集与fastMRI模拟测试集,提供严格配对数据以验证模型在可控噪声环境下的性能;二是真实测试,采用鑫高益0.1T MRI真实脑部数据,搭配同一被试在1.5T设备相近扫描层面图像,因临床扫描中被试体位变动、层厚/视野等参数差异,仅能实现相近解剖层面半配对,用于验证模型在真实临床低场环境的适用性。

针对两类测试特性,设计差异化评估指标体系:模拟测试采用PSNR(反映像素灰度保真度)与SSIM(衡量图像结构一致性),指标计算简便、结果直观,便于与现有低场去噪方法横向对比;真实测试创新性采用LPIPS与FID替代传统指标。LPIPS通过预训练AlexNet提取增强后0.1T图像与1.5T相近层面图像的深层感知特征,计算特征空间欧氏距离,贴合放射科医师主观评估逻辑,规避像素未对齐导致的偏差。而FID衡量增强后0.1T图像集与1.5T图像集的特征分布差异,确保增强图像整体结构一致。该双

指标体系突破传统PSNR、SSIM对严格空间对齐数据的依赖,解决真实场景中低场-高场图像难完全配对的评估难题,实验中通过计算各方法增强后图像的LPIPS与FID值,直观对比性能以验证模型临床价值。

2.2 实验环境与参数配置

本研究实验环境配置如下:CPU: Intel(R) Xeon (R) Platinum 6164 CPU @ 1.90 GHz; GPU: NVIDIA GeForce RTX 3090。实验使用PyTorch深度学习框架完成,在训练过程中Batch Size大小设置为2,最大训练迭代次数为500,初始学习率为0.001,使用Adam优化器训练网络参数。

3 结果与分析

以IXI数据集为训练集时,不同模型在真实测试和模拟测试上的表现,如表1所示。模拟测试中,双路去噪增强网络在fastMRI模拟数据集上的SSIM为0.9427,PSNR为31.8995 dB,高于对比方法中最优的SRFormer(PSNR为31.5407 dB,SSIM为0.9017)。在IXI模拟数据集上双路增强网络PSNR为32.2524 dB,SSIM为0.8996,两项指标均高于其他对比方法的最优结果。本文方法在两个模拟数据集的两项指标上实现了对现有对比方法的全面超越,说明在图像细节还原与噪声去除的协同效果上双路去噪增强网络具有明显优势,充分验证该网络在模拟低场MRI图像去噪增强任务中的可靠性。而在真实0.1T低场MRI数据集上,双路去噪增强网络同样展现出最优性能。以IXI数据集为训练集时,双路去噪增强网络的LPIPS为0.4729,FID为149.6493,这两项关键指标均显著优于各对比方法。上述结果表明,本文所提双路去噪增强网络以IXI数据集训练时,不仅在可控模拟场景中突破传统方法局限,更能应对真实临床低场环境。

表1 使用IXI数据集训练的不同模型性能对比

Table 1 Performance comparison of different models trained on the IXI dataset

方法	真实0.1T测试		模拟测试 (IXI)		模拟测试 (fastMRI)	
	LPIPS	FID	PSNR/dB	SSIM	PSNR/dB	SSIM
EDSR ^[19]	0.504 8	190.842 3	31.279 7	0.825 6	31.553 4	0.859 9
MPRNET ^[20]	0.514 6	299.560 3	31.647 9	0.871 2	31.714 3	0.885 5
SRFormer ^[21]	0.506 9	188.457 2	31.721 7	0.874 0	31.540 7	0.901 7
SWINIR ^[22]	0.508 6	186.480 8	31.709 7	0.832 2	31.244 3	0.882 3
HAT ^[23]	0.504 1	180.823 4	31.246 6	0.835 5	31.432 2	0.878 9
本文方法	0.472 9	149.649 3	32.252 4	0.899 6	31.899 5	0.942 7

为验证本研究双路去噪增强网络实际效果,图2展示该网络与各对比方法在IXI训练集上训练后,部分真实0.1T MRI图像上的增强结果。为清晰展示解剖细节的增强效果,图中以绿色框标注关键评估区域,并对标注区域进行放大处理,便于直观观察细节差异。从增强效果来看,双路去噪增强网络在不同噪声强度的成像序列中均展现出显著优势。在噪声较低的T₂ FSE加权序列中,对比方法如EDSR与MPRNET虽能抑制部分噪声,但存在脑回边缘模糊、脑沟间隙对比度不足的问题,难以满足临床诊断的需求。而双路去噪增强网络通过噪声自适应感知分支精准定位低强度噪声,结合去噪主干的混合注意力机制强化解剖结构特征,可

在完全抑制噪声的同时,使脑回的褶皱纹理更锐利、脑沟的灰度梯度更清晰,有效提升细微结构的可辨识度。在噪声较高的T₁加权序列中,对比方法的局限性更为明显。对比方法往往在抑制噪声的同时对小血管截面、脑回沟弱信号细节的恢复能力不足,使得最终的增强图像出现明显细节缺失,严重影响后续的临床诊断。而双路去噪增强网络通过噪声预测加细节恢复的双路协同机制,既去除了空间异质噪声,又完整保留小血管、脑灰白质交界等关键诊断信息,使增强后图像的解剖结构完整性与诊断可用性显著优于对比方法,为临床医师进行诊断等任务提供更可靠的图像支撑。

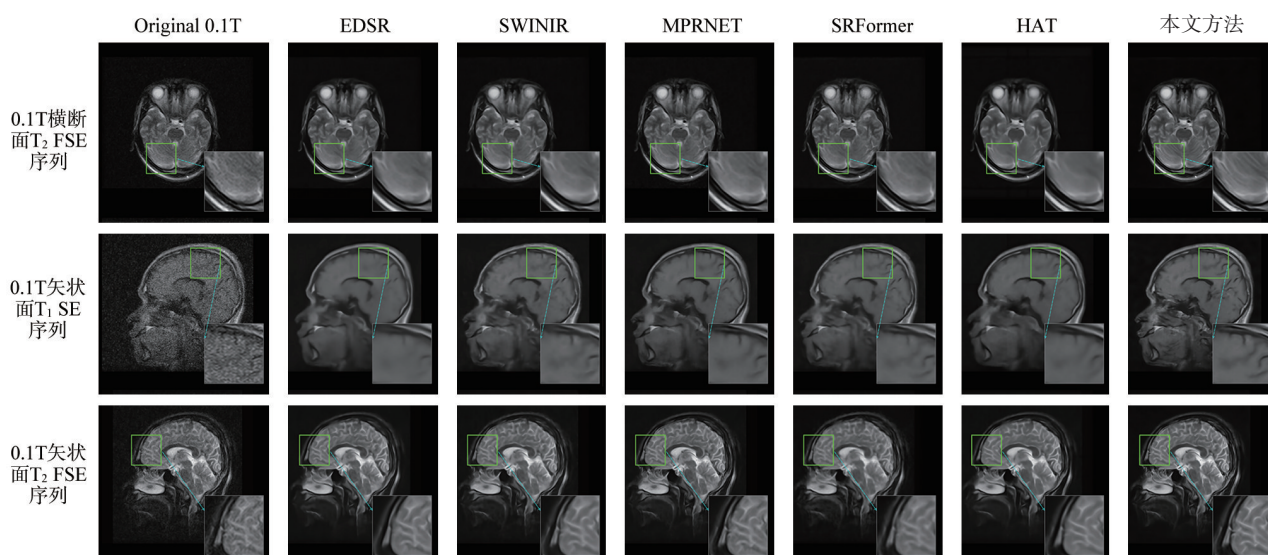


图2 各种方法在0.1T脑部MRI图像上的去噪增强结果

Figure 2 Denoising and enhancement results of various methods on 0.1T brain MRI images

本研究以fastMRI数据集为训练集时对3组不同测试集中低场MRI影像的增强效果,如表2所示。在模拟测试场景中,本文方法的性能显著优于EDSR、MPRNET、SRFormer等对比方法,且在同源与异源模拟数据上均保持领先。在与训练集同源的fastMRI模拟数据集上,本文方法的PSNR为31.877 0 dB,SSIM为0.943 3,其中SSIM指标高于对比方法中最优的MPRNET(0.930 6)。在与训练集异源的IXI模拟数据集上,本文方法仍实现性能突破,PSNR为32.157 7 dB,高于所有对比方法,SSIM为0.877 9,同样优于全部对比方法,证明其在跨数据集模拟场景下的良好适配性。在更贴近临床实际的真实0.1T低场数据集测试中,本文方法依旧表现突出,其LPIPS低至0.473 4,FID为148.432 3。相较于对比方法,本文方法的LPIPS和FID低于对比方法中最优的HAT(LPIPS为0.499 4,FID为172.360 0),充分说明本文

提出的网络可有效适配真实低场成像的噪声特性与结构特征,泛化能力满足临床应用需求。

综合上述实验结果可得出结论:无论以IXI数据集还是fastMRI数据集作为训练数据,本文提出的网络均能在模拟数据集到真实0.1T低场数据集的跨场景测试中保持稳定且优异的性能。这种跨数据集、跨成像条件的性能一致性,充分证明所提网络具有良好的泛化能力,能够有效克服不同数据集间的分布差异,为低场MRI设备的图像质量提升提供更具普适性的技术方案。

4 结论

本研究针对低场MRI图像增强领域中配对数据难获取、图像细节难保留、增强效果难量化3大关键痛点,提出基于噪声自适应感知的低场MRI图像增强方法,构建了系统性解决方案。首先,在配对数据获取方面,本研究提出基于MRI成像噪声原理的低场模拟方法。

表2 使用fastMRI数据集训练的不同模型性能对比

Table 2 Performance comparison of different models trained on the fastMRI dataset

方法	真实0.1T测试		模拟测试 (IXI)		模拟测试 (fastMRI)	
	LPIPS	FID	PSNR/dB	SSIM	PSNR/dB	SSIM
EDSR ^[19]	0.5149	186.2539	31.7250	0.8754	31.5267	0.8723
MPRNET ^[20]	0.5434	221.4443	31.4476	0.8729	31.7922	0.9306
SRFormer ^[21]	0.5082	193.6867	31.3355	0.8667	31.4287	0.8993
SWINIR ^[22]	0.5091	176.4170	31.5751	0.8568	31.0123	0.8733
HAT ^[23]	0.4994	172.3600	31.4261	0.8423	31.5321	0.8823
本文方法	0.4734	148.4323	32.1577	0.8779	31.8770	0.9433

该方法通过在高场MRI图像K空间注入随机高斯噪声并降采样,生成一一对应的高场-低场MRI图像数据集。基于MRI成像噪声原理的低场模拟方法贴合实际MRI成像特征,可获得与真实低场MRI图像噪声分布、分辨率一致的模拟低场图像,为深度学习监督训练提供数据支撑。其次,在图像细节保留方面,本研究设计双路去噪增强网络。该网络引入混合注意力机制,可自适应学习图像丰富表征,同时通过噪声自适应感知分支加去噪增强主干分支的双路结构,精准感知低场图像噪声强度信息,实现降噪与组织细节保留的协同优化。最后,在增强效果量化方面,本研究创新性地采用FID与LPIPS指标用于评估低场去噪增强方法的效果。FID、LPIPS可分别从图像集合的总体分布特征和单图感知分布层面量化增强后低场图像与对应高场图像的差异,实现真实场景下增强效果的精准评估。为验证方法的有效性,本研究构建多场景验证体系:模拟数据验证(fastMRI、IXI数据集)显示,本文方法PSNR、SSIM显著优于EDSR、MPRNET等对比方法;真实数据验证(0.1T和1.5T数据集)显示,LPIPS和FID同样优于全部对比方法^[19-23]。而在视觉上,本文方法可有效抑制噪声与伪影,保留脑灰白质边界、小血管纹理等细节。

综上所述,本研究围绕低场MRI图像质量痛点,针对现有方法3大关键问题展开系统性创新,形成从数据构建到模型设计再到效果评估的完整技术方案。本研究在模拟与真实场景下的实验表明,本文方法在低场去噪增强性能上显著优于对比方法,且评价指标科学适用,具备良好的临床应用潜力。

【参考文献】

- Geethanath S, Vaughan JT. Accessible magnetic resonance imaging: a review[J]. *J Magn Reson Imaging*, 2019, 49(7): e65-e77.
- Moser E, Laistler E, Schmitt F, et al. Ultra-high field NMR and MRI: the role of magnet technology to increase sensitivity and specificity[J]. *Front Phys*, 2017, 5: 00033.
- Marques JP, Simonis FF, Webb AG. Low-field MRI: an MR physics perspective[J]. *J Magn Reson Imaging*, 2019, 49(6): 1528-1542.
- Sarracanie M, Salameh N. Low-field MRI: how low can we go? A fresh view on an old debate[J]. *Front Phys*, 2020, 8: 00172.
- Snyder T, Vyas S, Scarpiello S, et al. Hyperfine swoops in for point of care imaging to help those suffering from subdural hematomas[J]. *Stroke: Vascular and Interventional Neurology*, 2024, 4: e12984-290.
- Arnold TC, Freeman CW, Litt B, et al. Low-field MRI: clinical promise and challenges[J]. *J Magn Reson Imaging*, 2023, 57(1): 25-44.
- Jalloul M, Miranda-Schaeubinger M, Noor AM, et al. MRI scarcity in low- and middle-income countries[J]. *NMR Biomed*, 2023, 36(12): e5022.
- Sheth KN, Mazurek MH, Yuen MM, et al. Assessment of brain injury using portable, low-field magnetic resonance imaging at the bedside of critically ill patients[J]. *JAMA Neurol*, 2021, 78(1): 41-47.
- Mazurek MH, Cahn BA, Yuen MM, et al. Portable, bedside, low-field magnetic resonance imaging for evaluation of intracerebral hemorrhage[J]. *Nat Commun*, 2021, 12(1): 5119.
- Yuen MM, Prabhat AM, Mazurek MH, et al. Portable, low-field magnetic resonance imaging enables highly accessible and dynamic bedside evaluation of ischemic stroke[J]. *Sci Adv*, 2022, 8(16): eabm3952.
- Zhang R, Isola P, Efros AA, et al. The unreasonable effectiveness of deep features as a perceptual metric[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 586-595.
- Heusel M, Ramsauer H, Unterthiner T, et al. GANs trained by a two time-scale update rule converge to a local nash equilibrium[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017: 6629-6640.
- Liu Z, Lin YT, Cao Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2021: 9992-10002.
- Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 7132-7141.
- Jaderberg M, Simonyan K, Zisserman A, et al. Spatial transformer networks[C]//Proceedings of the 29th International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2015: 2017-2025.
- Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Cham: Springer International Publishing, 2015: 234-241.
- Zbontar J, Knoll F, Sriram A, et al. fastMRI: an open dataset and benchmarks for accelerated MRI[EB/OL]. (2019-12-11). <https://arxiv.org/abs/1811.08839>.
- LSA Imperial College London, South Kensington Campus. IXI dataset [EB/OL]. [2025-03-06]. <https://brain-development.org/ixi-dataset/>.
- Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway, NJ, USA: IEEE, 2017: 1132-1140.
- Zamir SW, Arora A, Khan S, et al. Multi-stage progressive image restoration[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2021: 14816-14826.
- Zhou YP, Li Z, Guo CL, et al. SRFormer: permuted self-attention for single image Super-Resolution[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2023: 12734-12745.
- Liang JY, Cao JZ, Sun GL, et al. SwinIR: image restoration using Swin transformer[C]//2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). Piscataway, NJ, USA: IEEE, 2021: 1833-1844.
- Chen XY, Wang XT, Zhou JT, et al. Activating more pixels in image super-resolution transformer[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2023: 22367-22377.

(编辑:陈丽霞)