

基于多尺度T1w图像注意力机制引导的定量磁化率重建

李飘然^{1,2}, 陶 泉^{1,2}, 欧阳丰盛³, 郭保亮³, 胡秋根³, 冯衍秋^{1,2,3}

南方医科大学¹生物医学工程学院,²图像处理广东省重点实验室与医学成像诊断技术广东省工程实验室, 广东 广州 510515;³南方医科大学第八附属医院(顺德第一人民医院)放射科, 广东 佛山 528308

摘要:目的 通过多尺度T1w图像注意力引导的深度学习网络,提高定量磁化率成像(QSM)的精度与结构一致性。方法 基于T1w图像的结构特性,本方法通过注意力模块引导网络关注组织边界和关键区域,以提高QSM成像中单方向重建的精度与结构保真度。实验将T1w-ADQSM、K空间截断法(TKD)、形态学约束偶极反演法(MEDI)和深度学习方法QSMnet进行比较,并使用定量参数高频误差范数(HFEN)、结构相似性指数(SSIM)、归一化均方根误差(NRMSE)和峰值信噪比(PSNR)进行图像质量的评估。结果 在健康志愿者中,T1w-ADQSM重建图像与TKD、MEDI、和QSMnet相比,峰值信噪比最高(43.12±1.19)、归一化均方根误差最小(51.98±3.65)。此外,T1w-ADQSM在4项定量指标上均优于QSMnet,且该差异具有统计学意义($P<0.05$)。基于多方向数据构建的COSMOS参考图的补充验证表明,T1w-ADQSM较QSMnet具有更好的结构一致性,其重建结果更接近COSMOS参考图。结论 本文提出的基于多尺度T1w图像注意力驱动的深度学习网络重建方法可以提高定量磁化率重建的精度和结构一致性。

关键词:定量磁化率成像;图像重建;深度学习

Quantitative susceptibility reconstruction guided by a multi-scale T1-weighted image attention mechanism

LI Piaoran^{1,2}, TAO Quan^{1,2}, OYANG Fusheng³, GUO Baoliang³, HU Qiugen³, FENG Yanqiu^{1,2,3}

¹School of Biomedical Engineering, ²Guangdong Provincial Key Laboratory of Medical Image Processing and Guangdong Provincial Engineering Laboratory for Medical Imaging and Diagnostic Technology, Southern Medical University, Guangzhou 510515, China;

³Department of Radiology, Eighth Affiliated Hospital of Southern Medical University (First People's Hospital of Shunde), Foshan 528308, China

Abstract: Objective To improve the accuracy and structural consistency of quantitative susceptibility mapping (QSM) reconstruction through a deep learning network guided by multi-scale T1-weighted image attention. **Methods** A multi-scale T1-weighted attention-driven deep QSM network (T1w-ADQSM) was proposed to enhance the precision and structural fidelity of single-orientation QSM reconstruction. The method incorporates structural features from T1-weighted images and employs an attention module to guide the network to focus on the anatomical boundaries and key regions. Experimental comparisons were conducted among T1w-ADQSM, truncated k-space division (TKD) method, morphology enabled dipole inversion (MEDI) and QSMnet. Quantitative evaluations were performed using the metrics including high-frequency error norm (HFEN), structural similarity index measure (SSIM), normalized root mean square error (NRMSE), and peak signal-to-noise ratio (PSNR). **Results** In healthy volunteers, T1w-ADQSM achieved the highest PSNR (43.12±1.19) and the lowest NRMSE (51.98±3.65) compared with TKD, MEDI, and QSMnet. T1w-ADQSM outperformed QSMnet across all the 4 quantitative metrics with statistically significant differences ($P<0.05$). Further validation based on the COSMOS reference reconstructed from multi-orientation data showed that T1w-ADQSM exhibited better structural consistency than QSMnet, and the reconstruction results were closer to the COSMOS reference. **Conclusion** The proposed multi-scale T1-weighted image attention-driven deep learning reconstruction method improves the accuracy and structural consistency of QSM.

Keywords: quantitative susceptibility mapping; image reconstruction; deep learning

定量磁化率成像(QSM)技术是一种磁共振定量成像技术。其中磁化率表征的是不同物质在主磁场中引起局部磁场的偏移,在人体中对这种磁场偏移敏感的主要物质有铁、钙、脂质等物质^[1-5]。QSM主要是利用不同组织具有不同的磁化特性,从而可以通过磁化率值的变化来判断组织病变,也能辅助诊断多发性硬化、帕金森

病和阿尔兹海默症^[6-12]。

在定量磁化率重建过程中,偶极子反演的病态问题是影响重建精度的主要因素,这一问题的有效求解,对获得可靠的磁化率图来说至关重要^[13, 14]。多方向采样磁化率重建方法(COSMOS)^[15]可以通过多方向采集多组相位数据,有效消除偶极核零锥引起的问题。但是这种采集方式耗时久,容易产生运动伪影,不利于临床进行常规扫描。为克服COSMOS方法的采集限制,后续的研究陆续发展了多种单方向QSM重建算法。K空间截断法(TKD)^[16]在频域进行偶极核反卷积并且在零锥域设置阈值截断,但是TKD方法阈值选择比较敏感,容易产生条纹伪影。迭代最小二乘QR分解算法

收稿日期:2026-02-25

基金项目:国家自然科学基金(82372079);广东省自然科学基金(2024A1515010014, 2023A1515110614)

Supported by National Natural Science Foundation of China (82372079).

作者简介:李飘然,在读硕士研究生,E-mail: 2446601298@qq.com

通信作者:冯衍秋,博士,教授,E-mail: force@163.com

(iLSQR)^[17]将磁化率反演问题转化为线性最小二乘求解,与TKD方法相比可以更好的抑制噪声和伪影。形态学约束偶极反演法(MEDI)^[18]通过在反演过程中引入基于结构图像的先验信息,来提高组织边界保真度。此外还有其他的正则化算法在精度和稳定性上优于早期的线性算法,但是计算代价高,且大多数对正则化参数敏感^[19-21]。

传统单方向算法的性能受制于模型假设和正则化参数的选择,而深度学习为QSM重建带来了新的机遇,可以进一步提升重建精度和计算效率。QSMnet方法^[22]在经典3D U-net框架下实现从局部场到磁化率图的映射,有效减少了条纹伪影和局部误差。DeepQSM方法^[23]则用更轻量化的三维卷积实现磁化率重建,为多序列跨场强重建提供可行路径。此外还有多种改进模型QSMnet+^[24]、QSMGAN^[25]和AutoQS^[26]等,都在一定程度上抑制了伪影并提高了磁化率重建精度。然而,现在的多数深度学习模型依赖局部场信息,缺乏对组织结构的有效约束,会导致边界模糊和局部误差^[27, 28]。

多模态MRI数据能够为病态反演问题提供额外的解刨约束,可提升磁化率求解过程的稳定性和几何保真度^[14, 29]。在这其中T1w图像具有高空间分辨率和良好的组织对比度,可以提供清晰的结构边缘信息^[18, 30]。因此,本文提出了一种基于多尺度T1w图像注意力引导的深度学习定量磁化率成像方法(T1w-ADQSM),在经典3D U-net结构中引入多尺度T1w图像构建多模态注意力模块,引导网络在磁化率反演过程中关注组织边界和关键区域。

1 材料和方法

1.1 数据准备和处理

本研究使用的数据集来源于Scientific Data期刊公开发表的SRMD数据集^[31],在其中选取12例健康志愿者的脑部多参数MRI扫描数据。T1w图像采集采用矢状面三维MPRAGE序列,扫描参数包括:磁场强度为3T,重复时间为2300 ms,回波时间为2.98 ms,反转时间为900 ms,翻转角度为9°,分辨率为各向同性1 mm³。QSM图像数据采用轴位三维MEGRE序列采集,主磁场强度为3T,重复时间为53ms,回波时间为9.42 ms,共采集5个回波,翻转角度为15°,空间分辨率为0.5 mm×0.5 mm×1.5 mm。研究中选取每位受试者多回波数据的第2个回波幅度图像,并采用iLSQR算法进行磁化率重建,获得对应的QSM图像,作为后续分析中的参考磁化率图。

另外,还使用SIEMENS磁共振扫描健康志愿者,得到了一组多方向QSM数据以及对应的T1w图像。T1w图像采集参数为磁场强度为3T,重复时间为2300 ms,回波时间为2.5 ms,反转时间为900 ms,翻转

角度为8°,分辨率为0.8×0.8×1 mm³,QSM数据扫描参数为场强为3T,翻转角度为15°,重复时间为50 ms,共采集5个回波分别为4.5、10.83、19.44、26.98、34.52 ms,分辨率为1 mm³的各向同性体素。对同一名志愿者多次改变头部相对于主磁场方向的取向,采集不同磁场方向的相位和幅度,使用COSMOS方法得到QSM图,用于对比本文提出的单方向重建算法^[15]。

1.2 T1w-ADQSM网络结构

传统的磁化率重建中,由于反卷积中的偶极核D(k)在偶极子接近54.7°时无线接近零,引起大量噪声从而产生条纹伪影。而T1w图像清晰的解剖结构对比度高,可以提供较好的组织边界,尤其是脑灰白质、基底节等区域^[18, 32]。Wang等^[30]提出了在U-net网络中加入对比注意力模块,利用T1w信息强化解剖边界,引导网络对于磁化率数据的学习。结果表明,磁化率数据和T1w数据的结合可以有效互补,显著提升灰质,核团等组织的可辨性。在这一方法的基础上,本文引入了多尺度T1w边缘图以增强结构先验,并在网络架构中加入注意力模块进行优化改进。

T1w-ADQSM的网络结构如图1所示。网络整体采用经典的3D U-net网络架构^[33]。以局部场图像为主要输入,并引入多尺度T1w图像作为结构先验输入。编码端由五个卷积模块组成,每个模块包含两层3×3×3卷积,通道数从32依次递增,下一层是上一层的两倍直至512,并在层间通过最大池化实现下采样。解码端对称设置,每一级先进行3×3×3上采样,通道依次从512减少至32,每一层解码过程中,经过编码器阶段的特征通过注意力机制AG模块进行处理后与解码器中的特征图拼接,再经过两层3×3×3卷积细化。最终通过1×1×1卷积层输出磁化率图像。

图1中的注意力模块和多尺度T1w数据处理过程如图2所示。首先,使用FSL工具包中的脑提取工具(BET)去除颅骨等非脑组织的脑图像(T1w_brain)及其对应的脑掩膜(T1w_brain_mask)。接着,对提取后的脑图像进行强度归一化处理,以降低成像参数差异所导致的灰度不一致性,得到标准化图像(T1w_norm)。随后,结合脑掩膜实施多尺度边缘检测^[34],提取脑组织边界等显著结构信息,生成边缘图像(T1w_edge)。在此基础上,通过将归一化图像与边缘图像进行加权融合,以增强解剖结构细节,获得融合图像(T1w_fused)。最后,借助3D Slicer软件,将T1w_edge, T1w_norm和T1w_fused图配准至对应的第2回波幅度图像上,得到3种类型的T1w图像。

T1w-ADQSM网络的损失函数有:物理模型损失函数、基于体素的损失函数(L1 loss)和基于边缘的损失函数。




图1 本文提出的T1w-ADQSM方法概述
Fig.1 Overview of the proposed T1w-ADQSM method.




图2 注意力机制模块AG示意图(A)和多尺度T1w图像生成示意图(B)
Fig.2 Generation of the attention gate (A) and multi-scale T1-weighted images (B).

$$\begin{aligned} L_{model} &= \|d^* \hat{x} - d^* x\|_1 & (1) \\ L_{L1} &= \|\hat{x} - x\|_1 & (2) \\ L_{grad} &= \|\nabla_x \hat{x} - \nabla_x x\|_1 + \|\nabla_y \hat{x} - \nabla_y x\|_1 + \|\nabla_z \hat{x} - \nabla_z x\|_1 & (3) \end{aligned}$$

其中, $\hat{x}$ 为网络预测的磁化率图, x 为输入的 ground truth, $*$ 代表卷积运算, d 代表偶极子。总损失函数定义为:

$$L_{total} = \lambda_1 L_{L1} + \lambda_2 L_{grad} + \lambda_3 L_{model} \quad (4)$$

其中的权重 λ_1 、 λ_2 、 λ_3 分别设置为: 1、0.1、0.5。使用 ADAM 优化器^[35] 进行网络权重的优化, 使用 Leaky

ReLU作为线性激活函数^[36],网络训练每个批次包含5个样本,学习率设置在 10^{-3} 量级,并在过程中根据验证集进行自适应调整。当模型在10轮迭代内趋于稳定,则降低参数更新步长,整个训练流程至第100轮训练为止。

1.3 T1w-ADQSM网络训练与测试

本实验一共选取12组志愿者数据,将数据随机划分为5例训练集,2例验证集和5例测试集。网络在NVIDIA GeForce RTX 4090 GPU上进行训练,将网络的输入切割为 $64 \times 64 \times 64$ 大小,一生成1680个patch。为了保证样本间的连续性,每个patch采用重叠滑动窗口的方式提取,沿x,y,z 3个方向的滑动步长分别为38、27和16个体素。在每个批次样本送入网络之前进行在线几何增强,以 $P=0.5$ 进行水平镜像,并以 $P=0.5$ 在切片平面随机执行 90° 的整数倍旋转,所有变换均同步作用与输入,标签和T1w数据以保持空间配准。上述增强操作用于增加训练样本的多样性,以缓解小样本条件下的过拟合风险并提高模型鲁棒性。

1.4 网络重建效果评估

在5例志愿者数据上分别使用QSMnet和T1w-ADQSM方法进行定量磁化率重建,并且使用TKD和MEDI方法进行非深度学习的重建。其中,QSMnet基于与本文方法相同的数据划分重新训练,并在该测试集上进行评估。由于数据本身是单方向采集,无法获得COSMOS参考结果。因此采用最小二乘法(iLSQR)作为基线方法进行对比,高频误差范数(HFEN)、结构相似性指数(SSIM)、归一化均方根误差(NRMSE)和峰值信噪比(PSNR)定量评价重建效果^[37]。

高频误差范数描述了预测值 $\hat{x}$ 和参考值 x 在经过高通滤波器H提取以后高频成分之间的差异:

$$HFEN = \frac{\sqrt{\sum_{i=1}^N \left((H*\hat{x})_i - (H*x)_i \right)^2}}{\sqrt{\sum_{i=1}^N \left((H*x)_i \right)^2}} \quad (5)$$

结构相似性指数描述了预测值 $\hat{x}$ 和参考值 x 在局部均值、方差及协方差层面上的结构相似性关系,其中 $\mu_x, \mu_{\hat{x}}$ 指的是 x 和 $\hat{x}$ 的局部均值, σ_x^2 和 $\sigma_{\hat{x}}^2$ 是指 x 和 $\hat{x}$ 的方差, σ_{xx} 代表协方差, C_1 和 C_2 为稳定常数:

$$SSIM = \frac{(2\mu_x\mu_{\hat{x}} + C_1)(2\sigma_{xx} + C_2)}{(\mu_x^2 + \mu_{\hat{x}}^2 + C_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + C_2)} \quad (6)$$

归一化均方根误差定义如下,N为用于计算的体素总数:

$$NRMSE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{x}_i - x_i)^2}}{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}} \quad (7)$$

峰值信噪比的计算中图像峰值 X_{max} 可取 $2^n - 1$,定义如下:

$$PSNR = 10 \log_{10} \left(\frac{(2^n - 1)^2}{\frac{1}{N} \sum_{i=1}^N (\hat{x}_i - x_i)^2} \right) \quad (8)$$

所有指标均忽略背景区域,只计算脑内组织。

2 结果

2.1 SRMD数据集的结果

与T1w_edge和T1w_norm图像相比,T1w_fused图像引导的重建结果在HFEN、NRMSE、PSNR和SSIM指标上表现更好(表1)。

表1 不同T1w数据输入的T1w-ADQSM的定量性能指标和标准差

Tab. 1 Means and standard deviation of the quantitative performance metrics for T1w-ADQSM with different T1w data types

Types	HFEN (%)	NRMSE (%)	PSNR	SSIM
T1w_norm	59.43±3.56	58.34±4.28	41.56±0.83	0.932±0.033
T1w_edge	58.21±1.67	59.31±3.43	39.82±1.06	0.928±0.024
T1w_fused	56.69±2.96	57.76±3.05	42.06±0.94	0.936±0.011

依次使用iLSQR、TKD、MEDI、QSMnet和T1w-ADQSM方法进行重建,并选取其中一例志愿者数据通过不同方法重建得到的磁化率图像和对应的差异图进行展示(图3)。与TKD和MEDI方法的重建结果相比,T1w-ADQSM方法具有更少的条纹伪影,与传统深度学习方法QSMnet相比,T1w-ADQSM方法得到了较好的磁化率值。图4是图3的局部放大图,T1w-ADQSM方法与非深度学习方法相比,在边缘部分保留了更多细节。此外T1w-ADQSM方法在尾状核、壳核等区域的表现整体偏差最小。

统计测试集的5例志愿者数据使用4种方法得到的定量指标,T1w-ADQSM方法得到了最好的峰值信噪比和结构相似度,与传统的深度学习方法QSMnet相比,T1w-ADQSM在4个量化指标上表现得都更好(表2)。

表2 4种重建方法的定量性能指标的均值和标准差,包括HFEN、NRMSE、PSNR和SSIM

Tab. 2 Means and standard deviation of the quantitative performance metrics

Methods	HFEN (%)	NRMSE (%)	PSNR	SSIM
MEDI	62.39±4.69	79.36±7.03	37.16±0.88	0.952±0.016
TKD	59.23±4.18	69.49±5.30	39.25±0.97	0.914±0.023
QSMnet	57.47±3.28	58.89±3.14	41.39±1.05	0.931±0.008
T1w-ADQSM	56.69±2.96	57.76±3.05	42.06±0.94	0.936±0.011




图3 使用基于非深度学习的偶极子反卷积方法(TKD和MEDI)和深度学习方法(QSMnet和T1w-ADQSM)的一例志愿者的单方向定量磁化率结果比较

Fig.3 Comparison of single-orientation QSM results from one volunteer using non-deep learning dipole deconvolution methods (TKD and MEDI) and deep learning-based methods (QSMnet and T1w-ADQSM). The yellow arrows in the figure indicate prominent differences between QSMnet and T1w-ADQSM.

2.2 COSMOS参考下的单方向QSM对比

图5是单方向QSM重建结果与对应的COSMOS结果对比图,从左到右依次为: COSMOS、QSMnet和T1w-ADQSM。与QSMnet相比,T1w-ADQSM方法表现出更好的结构一致性,其重建结果更加接近COSMOS参考图。

3 讨论

QSM重建误差主要来源于偶极子核在零锥面上的信息缺失以及组织边界处磁化率不连续所引起的局部场不稳定问题,因此本研究提出的基于多尺度T1w图像注意力引导的深度学习定量磁化率成像方法(T1w-ADQSM)主要解决的是QSM重建的条纹伪影和边界




图4 志愿者的定量磁化率结果(第1行)和对应的差异图(第2行)的轴向视图

Fig.4 Axial view of the QSM map (first row) and the corresponding difference maps (second row) of the subject in Fig.3. The last two rows show zoomed-in views. The red arrows indicate regions with obvious differences between QSMnet and T1w-ADQSM.

模糊问题。T1w-ADQSM方法通过注意力引导模块,引入T1w图像,提供清晰的组织结构特征,网络能够更加关注脑组织灰白质、深灰质核团等关键区域。结果表明,在健康志愿者数据上,T1w-ADQSM方法在定量指标PSNR、SSIM、NRMSE、HFEN上优于MEDI、TKD和QSMnet,而条纹伪影的减弱主要集中在组织边界及高磁化率梯度区域,说明T1w引导模块可能通过强化边界相关特征学习,间接缓解零锥面信息缺失带来的不稳定。在COSMOS参考下,T1w-ADQSM的重建结果在结构一致性上优于QSMnet方法,T1w-ADQSM在相同区域条纹明显减弱,组织边界更加平滑。

在本研究结果中,MEDI在深灰质边界处存在一定程度的平滑现象,这是由于MEDI方法利用幅度图作为形态稀疏性约束,使磁化率边缘与幅度图边缘一致,由于幅度图的梯度信息有限,结构先验容易受到影响。相对于非深度学习方法,深度学习方法可以显著提高重建速度并提升整体的质量。因此本文提出的T1w-ADQSM方法是指在QSMnet网络的基础上,在3D U net网络中

加入了T1w图像注意力模块,引导网络对组织边界和关键结构的学习,这使得T1w-ADQSM方法的表现优于QSMnet方法。而其他的深度学习方法,例如DeepQSM方法采用合成数据训练,和真实的生理结构存在差异;QSMGAN网络通过对抗损失提升重建效果,过程复杂不稳定,在未引入明确结构先验的情况下,边界区域仍可能存在一定程度的不稳定。这些深度学习方法未利用T1w或幅度图的外部结构信息,就导致了重建结果中灰白质及深灰质边界模糊。

T1w-ADQSM方法中,T1w引导模块的权重系数在多模态特征融合中起到调节作用,其大小直接影响结构信息对局部场特征学习的引导强度。权重过低会削弱结构先验的约束效果,而过高则可能导致磁化率估计受到过度形态化影响,从而影响网络的定量精度。实验结果表明,T1w引导模块的权重在中等范围(如0.3~0.5)时,网络在结构保真度与定量误差间取得最佳平衡。

本研究仍存在一定的局限性。本文仅采用12例数据进行训练、验证和测试,有限的数据规模可能影响模




图5 单方向QSM重建结果(QSMnet和T1w-ADQSM)与对应的COSMOS结果对比图

Fig. 5 Comparison of single-orientation QSM reconstructions (QSMnet and T1w-ADQSM) with the corresponding COSMOS results. In terms of reconstructed structural fidelity, T1w-ADQSM outperforms the QSMnet method (red arrows).

型泛化能力。尽管训练过程中采用了在线数据增强策略,其在更大规模和多中心数据上的适用性仍需进一步验证。由于数据条件的限制,实验目前仅在单方向QSM数据上进行,未能充分验证模型在多方向数据下的普适性。此外随着GPU显存需求显著增加,本研究采用了基于patch的分块策略进行网络训练,这在一定程度上限制了模型对全局空间信息的学习能力。未来还将探索其他类型图像在磁化率重建中的引导潜力,期望进一步提升网络的结构感知能力与重建精度。本文尚未对不同方法的推理时间进行系统比较。后续将进一步结合计算效率和临床流程适配性,对模型的实际部署潜力开展评估。

Declaration of interests: The authors declare no competing interests.

参考文献:

[1] Schweser F, Deistung A, Reichenbach JR. Foundations of MRI phase imaging and processing for Quantitative Susceptibility

Mapping (QSM)[J]. Z Für Med Phys, 2016, 26(1): 6-34.

[2] Wang Y, Liu T. Quantitative susceptibility mapping (QSM): Decoding MRI data for a tissue magnetic biomarker[J]. Magn Reson Med, 2015, 73(1): 82-101.

[3] Buelo CJ, Velikina J, Mao L, et al. Multicenter, multivendor validation of liver quantitative susceptibility mapping in patients with iron overload at 1.5 T and 3 T[J]. Magn Reson Med, 2025, 93(1): 330-40.

[4] 李明月, 高洁, 袁毓, 等. 铁代谢异常对高血压性脑出血的老年患者微创血肿清除术后神经功能的影响[J]. 中华老年心脑血管病杂志, 2025, 27(9): 1169-72.

[5] Schumacher K, Prince MR, Blumenfeld JD, et al. Quantitative susceptibility mapping for detection of kidney stones, hemorrhage differentiation, and cyst classification in ADPKD[J]. Abdom Radiol, 2024, 49(7): 2285-95.

[6] Sun HF, Klahr AC, Kate M, et al. Quantitative susceptibility mapping for following intracranial hemorrhage[J]. Radiology, 2018, 288(3): 830-9.

[7] Duyn J. MR susceptibility imaging[J]. J Magn Reson, 2013, 229: 198-207.

[8] Kim HG, Park S, Rhee HY, et al. Quantitative susceptibility

- mapping to evaluate the early stage of Alzheimer's disease[J]. *NeuroImage Clin*, 2017, 16: 429-38.
- [9] Voon CC, Wiltgen T, Wiestler B, et al. Quantitative susceptibility mapping in multiple sclerosis: a systematic review and meta-analysis[J]. *NeuroImage Clin*, 2024, 42: 103598.
- [10] Xie Y, Zhang Y, Wu SL, et al. Atrophy-independent and dependent iron and myelin changes in deep gray matter of multiple sclerosis: a longitudinal study using χ -separation imaging[J]. *Acad Radiol*, 2025, 32(2): 988-99.
- [11] 朱立科, 詹逸珺, 裴建. 定量磁化率成像在阿尔茨海默病脑铁沉积中的应用进展[J]. *放射学实践*, 2026, 41(3): 317-22.
- [12] Yang YQ, Yuan YT, Ren BX, et al. Deep learning-based diffusion MRI tractography: Integrating spatial and anatomical information[J]. *Neuroimage*, 2025, 317: 121314.
- [13] QSM Consensus Organization Committee, Bilgic B, Costagli M, et al. Recommended implementation of quantitative susceptibility mapping for clinical research in the brain: a consensus of the ISMRM electro-magnetic tissue properties study group[J]. *Magn Reson Med*, 2024, 91(5): 1834-62.
- [14] Li M, Chen C, Xiong Z, et al. Quantitative susceptibility mapping via deep neural networks with iterative reverse concatenations and recurrent modules[J]. *Med Phys*, 2025, 52(6): 4341-54.
- [15] Liu T, Spincemaille P, de Rochefort L, et al. Calculation of susceptibility through multiple orientation sampling (COSMOS): a method for conditioning the inverse problem from measured magnetic field map to susceptibility source image in MRI[J]. *Magn Reson Med*, 2009, 61(1): 196-204.
- [16] Shmueli K, de Zwart JA, van Gelderen P, et al. Magnetic susceptibility mapping of brain tissue *in vivo* using MRI phase data[J]. *Magn Reson Med*, 2009, 62(6): 1510-22.
- [17] Li W, Wang N, Yu F, et al. A method for estimating and removing streaking artifacts in quantitative susceptibility mapping[J]. *Neuroimage*, 2015, 108: 111-22.
- [18] Liu T, Liu J, de Rochefort L, et al. Morphology enabled dipole inversion (MEDI) from a single-angle acquisition: comparison with COSMOS in human brain imaging[J]. *Magn Reson Med*, 2011, 66(3): 777-83.
- [19] de Rochefort L, Liu T, Kressler B, et al. Quantitative susceptibility map reconstruction from MR phase data using Bayesian regularization: Validation and application to brain imaging[J]. *Magn Reson Med*, 2010, 63(1): 194-206.
- [20] Langkammer C, Bredies K, Poser BA, et al. Fast quantitative susceptibility mapping using 3D EPI and total generalized variation[J]. *NeuroImage*, 2015, 111: 622-30.
- [21] Liu Z, Spincemaille P, Yao YH, et al. MEDI+0: Morphology enabled dipole inversion with automatic uniform cerebrospinal fluid zero reference for quantitative susceptibility mapping[J]. *Magn Reson Med*, 2018, 79(5): 2795-803.
- [22] Yoon J, Gong EH, Chatnuntawech I, et al. Quantitative susceptibility mapping using deep neural network: QSMnet[J]. *Neuroimage*, 2018, 179: 199-206.
- [23] Bollmann S, Rasmussen KGB, Kristensen M, et al. DeepQSM: using deep learning to solve the dipole inversion for quantitative susceptibility mapping[J]. *NeuroImage*, 2019, 195: 373-83.
- [24] Jung W, Yoon J, Ji S, et al. Exploring linearity of deep neural network trained QSM: QSMnet+ [J]. *NeuroImage*, 2020, 211: 116619.
- [25] Chen YC, Jakary A, Avadiappan S, et al. QSMGAN: Improved Quantitative Susceptibility Mapping using 3D Generative Adversarial Networks with increased receptive field[J]. *NeuroImage*, 2020, 207: 116389.
- [26] Wei HJ, Cao S, Zhang YY, et al. Learning-based single-step quantitative susceptibility mapping reconstruction without brain extraction[J]. *Neuroimage*, 2019, 202: 116064.
- [27] Jung W, Bollmann S, Lee J. Overview of quantitative susceptibility mapping using deep learning: Current status, challenges and opportunities[J]. *NMR Biomed*, 2022, 35(4): e4292.
- [28] Zhang JW, Nguyen TD, Solomon E, et al. mcLARO: Multi-contrast learned acquisition and reconstruction optimization for simultaneous quantitative multi-parametric mapping[J]. *Magn Reson Med*, 2024, 91(1): 344-56.
- [29] Gao Y, Xiong Z, Shan SS, et al. Plug-and-Play latent feature editing for orientation-adaptive quantitative susceptibility mapping neural networks[J]. *Med Image Anal*, 2024, 94: 103160.
- [30] Wang YD, He NY, Zhang CY, et al. An automatic interpretable deep learning pipeline for accurate Parkinson's disease diagnosis using quantitative susceptibility mapping and T1-weighted images[J]. *Hum Brain Mapp*, 2023, 44(12): 4426-38.
- [31] Fiscione C, Sighinolfi G, Mannes DN, et al. Multiparametric MRI dataset for susceptibility-based radiomic feature extraction and analysis[J]. *Sci Data*, 2024, 11: 575.
- [32] Fischl B. FreeSurfer[J]. *NeuroImage*, 2012, 62(2): 774-81.
- [33] Chartsias A, Joyce T, Giuffrida MV, et al. Multimodal MR synthesis via modality-invariant latent representation[J]. *IEEE Trans Med Imaging*, 2018, 37(3): 803-14.
- [34] Brignoni-Pérez E, Dubner SE, Ben-Shachar M, et al. White matter properties underlying reading abilities differ in 8-year-old children born full term and preterm: a multi-modal approach[J]. *NeuroImage*, 2022, 256: 119240.
- [35] Kingma DP, Ba J. Adam: a method for stochastic optimization[EB/OL]. 2014: arXiv: 1412.6980. <https://arxiv.org/abs/1412.6980>
- [36] Glorot X, Bordes A, Bengio Y. Deep sparse rectifier neural networks [C]//International Conference on Artificial Intelligence and Statistics., 2011.
- [37] Langkammer C, Schweser F, Shmueli K, et al. Quantitative susceptibility mapping: Report from the 2016 reconstruction challenge[J]. *Magn Reson Med*, 2018, 79(3): 1661-73.

(编辑: 经 媛)