

DOI:10.3969/j.issn.1005-202X.2023.01.006

医学影像物理

基于频域约束和交叉融合特征网络的磁共振图像超分辨率重建算法

李嘉丽, 王国中, 赵海武

上海工程技术大学电子电气工程学院人工智能产业研究院, 上海 201620

【摘要】磁共振(MR)图像常用于临床医学诊断,获得高分辨率MR图像有利于进行医学分析。目前主流的基于参考的图像超分辨率重建算法重建的图像,其视觉效果取得了明显的提升,但仍存在明显的伪影问题。针对该问题,提出频域约束和交叉融合特征网络(FCCF)模型,即引入频域损失函数作为约束条件,并构建一种多分辨率特征融合机制,通过交叉融合不同分辨率的图像特征来提高生成图像的质量,使重建结果具有更清晰的细节,没有明显的伪影。在合成和真实的MR图像数据集上分别用PSNR和SSIM指标进行评估,实验结果明显优于现有的超分辨率重建方法。

【关键词】磁共振成像;超分辨率重建;频域约束;深度学习

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2023)01-0031-08

Magnetic resonance image super-resolution reconstruction based on frequency-domain constraints and cross-fusion feature

LI Jiali, WANG Guozhong, ZHAO Haiwu

Artificial Intelligence Industry Institute, School of Electrical and Electronic Engineering, Shanghai University of Engineering Science, Shanghai 201620, China

Abstract: Magnetic resonance (MR) images are often used in clinical medical diagnosis, and high-resolution MR images are of high medical diagnostic value and can be recovered from low-resolution MR images using super-resolution reconstruction algorithms. The mainstream reference-based image super-resolution reconstruction algorithm can obtain fine image details, but still inevitably produces some artifacts. To address this problem, a frequency-domain constraints and cross-fusion feature (FCCF) model is proposed. The model introduces the frequency-domain loss function as a constraint and constructs a cross-fusion feature integration mechanism module to improve the quality of the generated images by cross-fusing image features of different resolutions, so that the reconstruction results have clearer details and no obvious artifacts. The experiment results show that the proposed method outperforms the existing super-resolution reconstruction algorithms when they are evaluated on synthetic and actual MR image data sets using peak signal-to-noise ratio and structural similarity.

Keywords: magnetic resonance imaging; super-resolution reconstruction; frequency domain constraint; deep learning

前言

高分辨率磁共振(Magnetic Resonance, MR)图像能提供更多的图像细节信息,被广泛用于临床诊断和定量分析。然而通过医疗检测手段获取高分辨率的MR图像需要对身体组织进行长时间的稳定扫描,实现难度高,具有局限性^[1]。超分辨率重建算法通过运用数字图像处理等知识可以从低分辨率(Low

Resolution, LR)图像中恢复出高分辨率(High Resolution, HR)图像,利用超分辨重建算法提高MRI影像的分辨率,不会给病人带来额外的伤害^[2],而且费用低廉,便于临床应用^[3]。

基于匹配加速和空间自适应的超分辨率算法(Matching Acceleration and Spatial Adaptation for Reference-Based Image Super-Resolution, MASA)是一种将高分辨率图像的纹理信息用于迁移和参考的图像超分辨率算法^[4],它最大程度地利用了参考图像的信息,可以有效地搜索与迁移高分辨率的纹理特征到低分辨率图像中,解决重建图像纹理模糊和纹理失真的问题。快速傅里叶变换是信号处理领域的一个强大工具,常用来实现图像降噪,它在深度学习相关的研究中也显示出巨大的潜力。本文利用快速傅里叶变换对MASA

【收稿日期】2022-07-22

【基金项目】国家重点研发计划(2019YFB1802702)

【作者简介】李嘉丽,硕士研究生,研究方向:深度学习,图像超分辨率重建, E-mail: 986437829@qq.com

【通信作者】王国中,博士,教授,研究方向:数字音视频信息处理、智能信息处理, E-mail: wanggz@sues.edu.cn

进行频域损失约束,使重建出的MR图像具有更精细的轮廓细节及更少的伪影。同时,为了进一步提升模型对参考图像信息的提取和利用,本文构建了一个多分辨率交叉融合特征机制来替换MASA中原有的空间自适应特征融合模块,使得提取出的图像特征能够多尺度交叉融合,增强网络的特征表达能力。实验结果证明,与只利用图像空间信息的传统超分辨率重建方法以及MASA相比^[5-12],本文提出的方法可以更好地利用MR图像丰富的频域信息,使得网络可以提取到更充足的图像特征和结构信息,重建出的MR图像质量有较大幅度的提升。

1 相关工作

1.1 图像超分辨率重建算法

图像超分辨率重建算法主要可以分为3种类型,即基于插值的超分辨率重建方法^[5-8],基于重构的超分辨率重建方法^[9-12]和基于学习的重建算法^[4,13-19]。基于插值的方法通过插值算法插值得到目标高分辨率图像,该方法具有复杂度低、计算量小、实时性好的特点,然而其适应能力较差且场景处理简单,对灰度变化大的场景容易造成边缘模糊、高频细节缺失等问题。基于重构的方法利用先验知识重建出目标高分辨率图像,能很好地抑制噪声并保留图像边缘信息,与插值算法相比,重建出的图像质量更高。缺点是其图像重构的速度较慢,算法复杂性高,对先验信息的依赖性较强。

基于学习的超分辨率重建方法利用训练集中的LR图像及与其对应的HR图像之间的关系来估计输入LR图像丢失的高频细节,只需要少量信息就能够重建出高质量的MR图像。其有两个主要的类别,即单图像超分辨率重建(Single Image Super-Resolution, SISR)方法和基于参考的图像超分辨率重建(Reference-based Image Super-Resolution, RefSR)方法^[13-14]。SISR方法旨在从单一的LR图像重建一个HR图像,基于卷积神经网络(CNN)模型和生成对抗网络(GAN)模型的SISR方法虽然能够重建出具有精细细节的高质量图像^[15-16],但随之带来更多的噪声和伪影,影响手术诊断和决策。RefSR方法旨在从高分辨的参考图像中学习到更丰富的纹理细节,参考图像可以从视频中的相邻帧、不同视点的图像中选择。近年来,大量研究证明了RefSR的优越性能。2018年,Wang等^[17]提出了增强型超分辨率重建生成对抗网络(Enhanced Super-Resolution Generative Adversarial Network, ESRGAN)模型,通过引入密集残差块结构提高了生成效果和量化指标;Zhang等^[18]提出了一种深度残差通道注意网络(Image Super-

Resolution Using Very Deep Residual Channel Attention Networks, RCAN),整个结构通过运用多个跳跃连接,让低频信息绕过网络,使主干网络只学习到高频信息,增强了网络的表达能力。2020年,Yang等^[19]提出了一种新颖的用于图像超分辨率的纹理转换网络(Learning Texture Transformer Network for Image Super-Resolution, TTSR),该网络通过引入一张参考图像来指导整个超分辨率过程,将超分辨率重建问题由较为困难的纹理恢复与生成转化为了相对简单的纹理搜索与迁移,使得图像重建结果在指标以及视觉效果上有了显著的提升。2021年,Lu等^[4]提出了MASA网络,该模型通过两个空间自适应模块学习LR图像和参考图像之间的分布差异,并以空间自适应的方式将参考图像的特征分布重新映射到LR图像的特征分布,这种由粗到细的对应匹配方案显著降低了计算成本。同时,由于感知损失函数的引入,图像结构得以保留,重建出的图像细节更丰富且更接近真实图像。

2 频域约束和交叉融合特征网络(Frequency-domain Constraints and Cross-fusion Feature, FCCF)模型

针对现有超分辨率重建方法存在的伪影和噪声问题,本文在MASA网络的基础上增加HR图像作为网络输入,以新增一个频率损失函数作为约束,同时根据MR图像空间域的特性,去除原有的融合模块,替换为多分辨率交叉融合特征机制(Cross-Fusion Feature Integration, CFFI)模块,构成本文的FCCF模型。原MASA网络由3个模块组成:编码器(Encode, ENCD)、匹配和提取模块(Match & Extraction Module, MEM)以及融合模块。FCCF模型保留了MASA的ENCD、MEM模块,同本文提出的CFFI模块一同构成纹理特征提取及融合模块(Texture Extraction and Fusion Module, TEFM)。本文提出的FCCF模型共由3个部分组成,分别为网络输入部分,TEFM部分和损失函数部分,算法框架如图1所示。

2.1 网络输入

FCCF模型的输入部分由4张图像构成,分别是分辨率为120 pixel×120 pixel的LR图像、参考图像(Ref)、四倍双三次上采样的LR图像(LR↑)及分辨率为480 pixel×480 pixel的HR图像。HR图像为通过欠采样模型生成LR图像之前的原始高清图像,HR图像与LR图像一一对应。参考图像从原始高清图像数据集中选取,确保其与HR图像具有相似纹理,以提高重建效果。

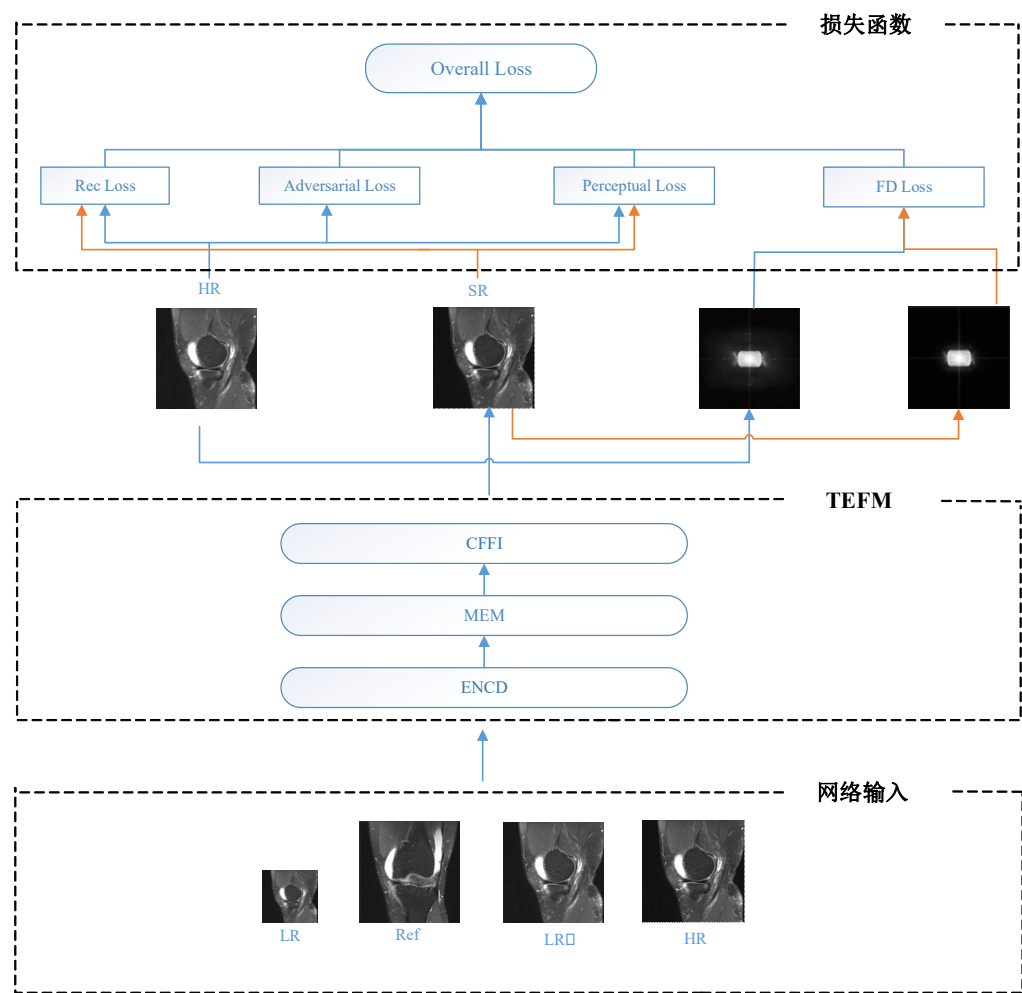


图1 FCCF算法框架图

Figure 1 FCCF algorithm framework

2.2 TEFM

在TEFM中,首先由ENCD提取参考图像特征,与LR图像一起进入MEM执行从粗到细的对应匹配和特征提取,并输出1倍(1×),2倍(2×),4倍(4×)3种不同倍率放大后的的特征图(LR Feature Map),接着进入CFFI中执行多分辨率特征融合操作。

MASA提出的特征融合机制主要针对参考图像和LR图像中的颜色和亮度分布不一致性问题,因此对MR图像的处理不具有泛化性。为了进一步提升模型对MR图像信息的提取和利用,本文去除了原有MASA网络的融合模块,并提出CFFI,通过将不同粒度的图像信息渗透到不同分辨率层级的方式增强网络的特征表达能力,从而提高生成图像的质量。CFFI模块如图2所示。图2中,RBs表示一组步长为1的残差块,用于解决梯度消失和梯度爆炸问题。在整个多分辨率特征融合过程中,总共会进行两次交叉融合操作。第一次交叉融合操作通过上下采样完成对1×和2×两种分辨率图像的特征融合。第二次交叉融合操作完成对1×,2×和4×3种分辨率图像的特

征融合。其中特征融合按照通道维度通过级联操作完成。3种分辨率图像的特征更新及前向传播由一组步长为1的残差块完成。最终会生成3个多分辨率特征融合后的图片,将这3个图片通过上采样的方式固定于4倍放大后的特征图分辨率,得到网络输出超分辨率(SR)图像。这种在不同分辨率的参考图像上进行信息渗透的模块,实现了更强大的特征表示,进一步提高了FCCF模型的性能。

2.3 损失函数

本文损失函数由重建损失,对抗训练损失,感知损失以及频域损失4个损失函数组成。其中重建损失,对抗训练损失,感知损失可以用于提高重建图像的主观视觉质量,保留LR图像的空间结构。为了保留参考图像的高频细节,充分利用其纹理信息,本文在此基础上提出频域损失函数,将MASA功能模块输出的SR图像与HR图像通过快速傅里叶变换转入频率域,计算其频域损失,同时将参考图像特征与LR特征融合,使得LR图像和参考图像的高频细节得到了增强和聚合,从而产生了更具代表性的图像特征。

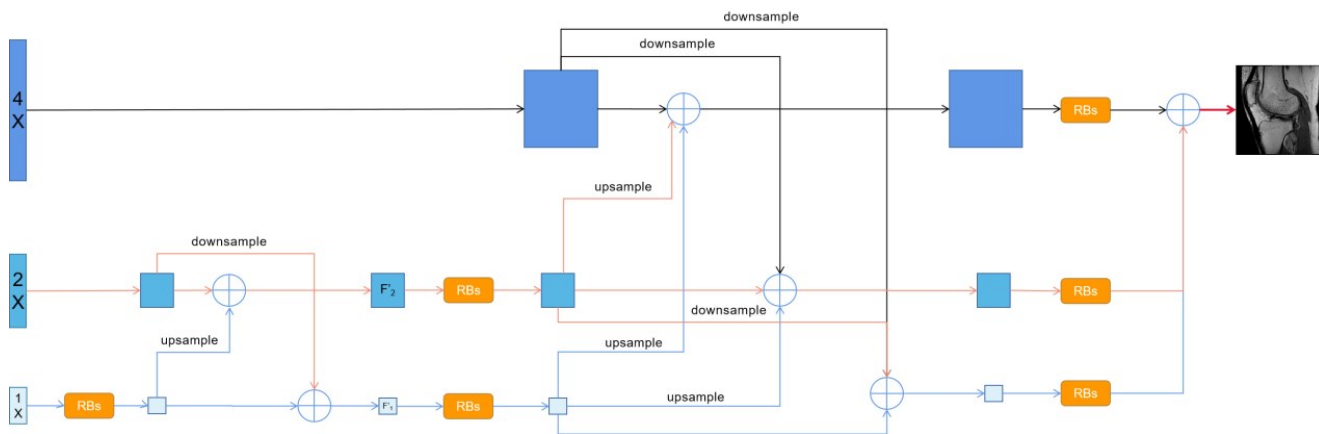


图2 多分辨率交叉特征融合机制模块

Figure 2 Cross-fusion feature integration mechanism module

2.3.1 频域损失函数 为了从数据集中学习更多的纹理细节,减少超分辨率重建时产生的伪影,同时保留MR图像的高频细节,本文建立了一个像素级的频域损失函数(Frequency Domain loss),以确保网络能从频域模式中进行学习。为了便于优化,频域损失函数采用了更稳健,更容易收敛的L1范数,公式如下:

$$S_{HR} = f_{\text{rft}}(I_{HR}), S_{SR} = f_{\text{rft}}(I_{SR}) \quad (2)$$

$$L_{\text{fd}} = (S_{HR} - S_{SR})_1 \quad (3)$$

其中, I_{HR} 和 I_{SR} 分别是HR图像和经过MASA部分生成的SR图像, S_{HR} 和 S_{SR} 是其经过快速傅里叶变换后的频域图像。 L_{fd} 表示频域损失函数, f_{rft} 表示实数到复数的离散傅里叶变换函数。本文使用PyTorch内置的快速傅里叶变换函数(实复离散傅里叶变换)来提高计算效率,无需将张量转换为其他数据类型,训练时间复杂度没有显著增加。

2.3.2 总体损失 FCCF模型总体损失的公式如下:

$$L_{\text{overall}} = \lambda_{\text{rec}} L1_{\text{rec}} + \lambda_{\text{fd}} L1_{\text{fd}} + \lambda_{\text{adv}} L1_{\text{adv}} + \lambda_{\text{per}} L1_{\text{per}} \quad (4)$$

其中: $L1_{\text{rec}}$ 为基于L1范数的重建损失, $L1_{\text{adv}}$ 是使用Relativistic GANs的对抗性损失, $L1_{\text{per}}$ 包括正常感知损失和纹理损失的感知损失。本文增加了频域损失 L_{fd} 进行约束, λ_{rec} 、 λ_{fd} 、 λ_{adv} 、 λ_{per} 是经过反向传播优化后的损失函数的权重系数。

3 实验结果与分析

为了验证本文提出的FCCF模型的有效性,本文进行了大量实验对比与评估。除了定性评估实验效果图,本文还基于评价指标峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)及结构相似性(Structural Similarity, SSIM)对不同算法的结果进行了定量评估^[22-23]。

3.1 数据集

本文基于两个MR数据集来进行实验评估,一个

是真实的膝盖MR图像数据集,一个是合成的脑部MR图像数据集,分别命名为Dataset I, Dataset II。

(1)Dataset I。Dataset I来自于真实MR数据集。该数据集采集自临床MR扫描仪Discovery MR750,并使用12通道(117次扫描)或32通道线圈(50次扫描)采集数据集。采集参数为TR=6.3 ms、TE=2.6 ms、TI=650 ms(93次)和TR=7.4 ms、TE=3.1 ms、TI=400 ms(74次),层厚170~180层,视野256 mm×218 mm。本文从中选取了13 000张无运动伪影干扰的清晰膝关节MR图像构成本数据集。

(2)Dataset II。Dataset II来自BrainWeb提供的一套模拟数据库^[24],该数据库包含由MRI模拟器产生的一组模拟的正常人脑部和膝部MR图像,已被广泛用于评估图像处理算法的性能。其中,本文选择了部分无噪声添加的轴向切片图像T₁加权图像(编号为31~130),并将这组数据标记为Dataset II。

3.2 实验方法

由于MR图像的特殊性,进行实验前需要对数据集进行预处理。首先将DICOM文件转换为3通道图像文件,并去除没有成功转换或不满足实验条件的图像。接着对输入的图像进行滑动裁剪,得到大小均为480 pixel×480 pixel的图片,将其作为HR图像。最后再对HR图像使用双三次插值法进行下采样,得到120 pixel×120 pixel的LR图像,完成数据预处理操作。

FCCF网络训练的超参数包括:初始学习率为 1×10^{-4} ;最大训练迭代次数为400 000,在训练迭代到50 000、100 000、200 000、300 000次时,将学习率依次下降减半;batch_size为9,优化器为ADAM。硬件平台配置如表1所示。实验使用的是UBUNTU操作系统,对于Dataset I花费的训练时间为10 h左右,对于Dataset II花费的训练时间约为12 h左右。

表 1 硬件平台配置表
Table 1 Hardware platform configuration

项目名称	具体配置
操作系统	UBUNTU 18.0.45
驱动版本	440.33.01
CUDA 版本	10.2
GPU	NVIDIA-SMI 440.33.01
显存	32510 MiB
深度学习框架	Pytorch 1.81

3.3 实验结果与分析

本文分别基于 Dataset I 和 Dataset II 数据集对 FCCF 模型,传统超分辨率重建算法以及先进的基

于学习的方法进行了实验对比。测试时统一输入 120 pixel×120 pixel 的 LR 图像,各模型输出的图像分辨率均为放大 4 倍后的 480 pixel×480 pixel。

3.3.1 定性评估 为了验证 FCCF 的有效性,在 Dataset I 上使用不同超分辨率算法进行重建(Bicubic、ESRGAN、RCAN、TTSR、MASA、FCCF)。重建结果如图 3 所示。图 4 展示了将生成图像使用二维快速傅里叶变换转换到频域后的图像。

图 4 中,频域图像的白色中心区域表示图像包含更多的高频信息。与原始真实图像相比,经过 Bicubic 模型重建出的图像最为模糊且图像高频信息损失严重。ESRGAN、RCAN 模型重建出的图片虽然在清晰度有所提高,然而重建出的高频细节十分有




图 3 Dataset I 上不同超分辨率算法重建结果示意图
Figure 3 Results of the super-resolution reconstruction on Dataset I




图 4 频率域中超分辨率重建结果示意图
Figure 4 Results of the super-resolution reconstruction in the frequency domain

限。TTSR 模型生成的图像具有丰富的高频细节,并能在空间域中展示出清晰的纹理,但伪影问题严重。MASA 模型可以生成精细的高频细节,但边缘部分还是存在着模糊重影。FCCF 模型重建出的图像没有明显的噪声和伪影,在 SSIM 和 PSNR 值上获取了最优值,同时整体效果清晰,细节也较为丰富,整体

视觉感受与原始真实图像更加接近。

本文进一步在 Dataset II 上对以上方法进行了定性评估,图 5 给出了这些方法的超分辨率重建结果,图 6 展示了将超分辨率重建结果转换到频域后的图像。

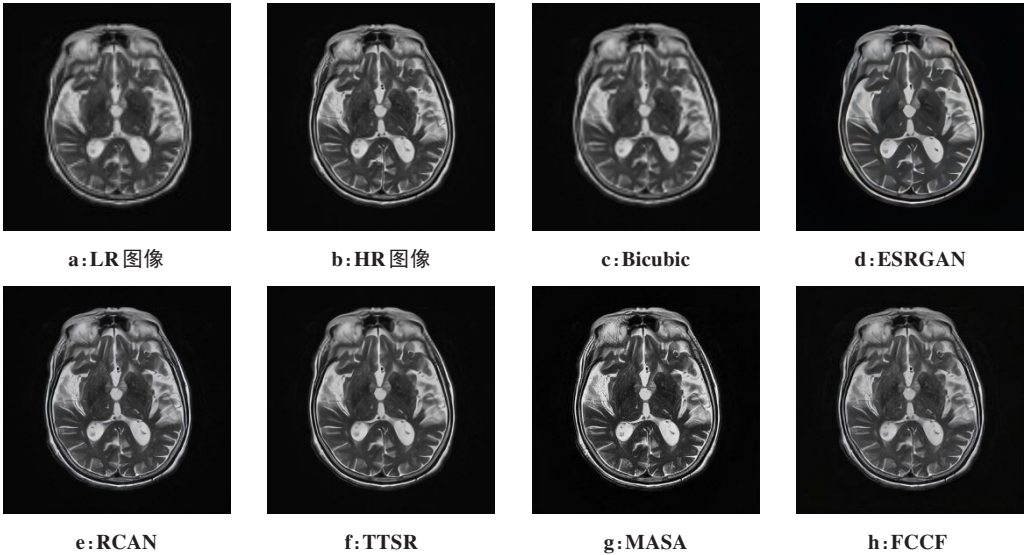


图 5 Dataset II 上超分辨率重建结果示意图
Figure 5 Results of the super-resolution reconstruction on Dataset II




图 6 频率域中超分辨率重建结果示意图
Figure 6 Results of the super-resolution reconstruction in the frequency domain

3.3.2 定量评估 表 2 列出了不同超分辨率算法分别在 Dataset I 和 Dataset II 上进行四倍超分辨率重建的客观评价结果。从表 2 中可以看出,本文提出的 FCCF 模型在 PSNR 和 SSIM 指标上具有最佳的结果,这验证 FCCF 模型的有效性和通用性。

3.4 消融实验

为了进一步验证频域损失函数的有效性,本文设置了 FCCF-Rec 模型进行对比实验。该模型权重系数分布比例与 FCCF 相同,仅仅将重建损失 L_{rec} 的权重系数从 1 增加到 1.01,同时去除频域损失函数,其余损失函数的权重系数和训练参数都采用相同的设置。本文将 SR 图像重建结果显示在图 7 中,频域

表 2 在 Dataset I 及 Dataset II 上使用不同方法进行超分辨率重建后的 PSNR/SSIM 结果
Table 2 PSNR/SSIM of super-resolution reconstruction on Dataset I and Dataset II using different methods

数据库		Bicubic ^[25]	ESRGAN ^[18]	RCAN ^[18]	TTSR ^[19]	MASA ^[4]	FCCF
Dataset I	PSNR/dB	26.55	27.69	28.69	27.51	28.93	30.97
	SSIM	0.885 3	0.902 3	0.922 3	0.900 1	0.929 1	0.943 0
Dataset II	PSNR/dB	30.54	31.91	33.91	32.65	34.30	36.51
	SSIM	0.906 0	0.924 1	0.954 1	0.950 1	0.952 4	0.967 3

图如图 8 所示,PSNR/SSIM 值如表 3 所示。从图 7 及表 3 中可以看出,如果没有引入频域损失,单独增加重建损失的权重系数,不仅无法改善 FCCF 在 MR 图像上超分辨率重建结果,同时还出现了伪影问题。FCCF 的重建结果在 PSNR 及 SSIM 评价指标上有最优的表现,同时频域图像也与 HR 图像有最高的相似度。




图 7 Dataset II 上超分辨率重建结果示意图
Figure 7 Results of the super-resolution reconstruction on Dataset II




图 8 频率域中超分辨率重建结果示意图
Figure 8 Results of the super-resolution reconstruction in the frequency domain

表 3 在 Dataset II 进行频域损失的消融研究
PSNR/SSIM 结果

模型	PSNR/dB	SSIM
MASA ^[4]	28.32	0.905 3
FCCF-Rec	28.51	0.935 6
FCCF	28.82	0.948 3

4 结束语

本文提出了一种增加频域损失函数为约束的多

分辨率交叉融合特征的超分辨率重建方法。该算法在残差结构内部通过跨尺度模块,利用 MR 图像内部信息辅助重建图像中大量的细节区域,能使图像看起来更加真实自然,纹理细节更加清晰。同时利用快速傅里叶变换进行频域损失约束,使重建出的核磁共振图像具有更精细的轮廓细节及更少的伪影。与传统的超分辨率重建算法及先进的深度学习方法进行比较,FCCF 模型在 PSNR 和 SSIM 上表现优异,重建出的图像细节丰富、纹理清晰,符合临床诊断需求,验证了本文算法在重建超分辨率医学 MRI 影像的高效与准确性。

【参考文献】

- [1] 曹阳, 肖能, 胡石腾, 等. 磁共振3D-ASL定量评估儿童病毒性脑炎脑灌注特征[J]. 中国医学物理学杂志, 2022, 39(4): 475-478.
Cao Y, Xiao N, Hu ST, et al. Magnetic resonance 3D-ASL for quantitative assessment of cerebral perfusion characteristics in children with viral encephalitis [J]. Chinese Journal of Medical Physics, 2022, 39(4): 475-478.
- [2] 白雪冬, 仇恒志, 王胜林, 等. 磁共振波谱多体素及单体素在诊断低级别胶质瘤急性和亚急性期脑梗死及病毒性脑炎中的诊断价值分析[J]. 河北医学, 2020, 26(10): 1702-1706.
Bai XD, Chou HZ, Wang SL, et al. Analysis on value of multivoxel and monovoxel of 1H-MRS in the diagnosis of low-grade glioma acute and subacute cerebral infarction and viral encephalitis [J]. Hebei Medicine, 2020, 26(10): 1702-1706.
- [3] 刘芳华, 阮若林, 倪浩, 等. 双正则化参数法超分辨率重建核磁共振图像[J]. 核电子学与探测技术, 2016, 36(9): 948-952.
Liu FH, Ruan RL, Ni H, et al. MRI Super-resolution reconstruction via double regularization parameters [J]. Nuclear Electronics & Detection Technology, 2016, 36(9): 948-952.
- [4] Lu LY, Li WB, Tao X, et al. MASA-SR: matching acceleration and spatial adaptation for reference-based image super-resolution [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 6368-6377.
- [5] Wang LZ, Liu W, Xu LN. Approximating Catmull-Clark subdivision surfaces with bicubic Bezier patches on GPU [J]. J Comput Appl, 2010, 30(2): 37-39.
- [6] Ji LL, Zhang R, Han HJ, et al. Image magnification based on bicubic approximation with edge as constraint [J]. Applied Sciences, 2020, 10(5): 1685.
- [7] 卢紫微, 吴成东. 基于重建方法的图像超分辨率技术发展现状分析与方向预测[J]. 辽宁石油化工大学学报, 2014, 34(2): 69-73.
Lu ZW, Wu CD. Current status analysis and future directions prediction for Image super-resolution technique based on reconstructing approach [J]. Journal of Liaoning Petrochemical University, 2014, 34(2): 69-73.
- [8] Thapa D, Raahemifar K, William R, et al. A performance comparison among different super-resolution techniques [J]. Computers and Electrical Engineering, 2016, 54: 313-329.
- [9] Nasrollahi K, Moeslund TB. Super-resolution: a comprehensive survey. [J]. Mach Vis Appl, 2014, 25(6): 1423-1468.
- [10] Elham K, Kaveh K, Shahram J. A survey on super-resolution methods for image reconstruction [J]. Int J Comput Appl, 2014, 90(3): 32-39.
- [11] Lin ZC, He JF, Tang XO, et al. Limits of learning-based superresolution algorithms [J]. Int J Comput Vision, 2008, 80(3): 406-420.
- [12] Li K, Yang SH, Dong RT, et al. Survey of single image super-resolution reconstruction [J]. IET Image Processing, 2020, 14(11). Doi: 10.1049/iet-ipr.2019.1438
- [13] Yang W, Zhang X, Tian Y, et al. Deep learning for single image super-resolution: a brief review [J]. IEEE Trans Multimedia, 2019, 21(12): 3106-3121.
- [14] Yue HJ, Shen S, Yang JY, et al. Reference image guided super-resolution via progressive channel attention networks [J]. Journal of Computer Science and Technology, 2020, 35(3): 551-563.
- [15] Huang YH, Shi LL, Lu YC. Research on module-level fault diagnosis of avionics system based on residual convolutional neural network [C]//Conference Proceedings of 2021 4th International Conference on Algorithms, Computing and Artificial Intelligence (ACAI 2021), 2021: 676-682.
- [16] Chen YZ, Yang XH, Wei ZH, et al. Generative adversarial networks in medical image augmentation: a review [J]. Comput Biol Med, 2022, 144: 105382.
- [17] Wang XT, Yu K, Wu SX, et al. ESRGAN: enhanced super-resolution generative adversarial networks [J]. arXiv preprint arXiv: 1809.00219v2, 2018.
- [18] Zhang Y, Li K, Li K, et al. Image super-resolution using very deep residual channel attention networks [C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 286-301.
- [19] Yang FZ, Yang H, Fu JL, et al. Learning texture transformer network for image super-resolution [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2020.
- [20] Wu L, Zhang S, Zhang T. MRI-Based image signal-to-noise ratio enhancement with different receiving gains in K-space [J]. Sensors, 2021, 21(16): 5296.
- [21] Kim BS, Jin Y, Lee J, et al. High-efficiency super-resolution FMCW radar algorithm based on FFT estimation [J]. Sensors, 2021, 21(12): 4018.
- [22] Adegboye MA, Lukman A. Performance evaluation of multiple transform watermarking system for privacy protection of medical data using PSNR and NC [J]. Acta Inform, 2019, 18(4): 44-51.
- [23] Bakurov I, Buzzelli M, Schettini R, et al. Structural similarity index (SSIM) revisited: a data-driven approach [J]. Expert Syst Appl, 2022, 189: 116087.1-116087.19.
- [24] Cocosco CA, Kollokian V, Kwan RK, et al. Brain web: online interface to a 3D MRI simulated brain database [J]. Neuroimag, 1997, 5: S425.
- [25] Khomchenko A, Sidenko I. Piecewise planar method of bicubic interpolation [J]. Comput Sci Eng, 2020, 1(1): 29-37.

(编辑: 薛泽玲)