

基于隐式退化模型的磁共振图像超分辨重建网络

刘环宇¹, 郭海鹏¹, 刘晓东², 李晗¹, 李君宝¹

1. 哈尔滨工业大学计算学部信息对抗技术研究所, 黑龙江 哈尔滨 150080; 2. 哈尔滨工业大学电子与信息工程学院自动化测试研究所, 黑龙江 哈尔滨 150080

【摘要】对于使用算法提升磁共振(MR)图像分辨率的研究, 现有方法多停留在跨尺寸、同尺寸有监督的超分辨算法研究, 提出一种基于隐式退化映射模型的MR图像超分辨重建网络SG-Diffusion, 通过掩码自编码器隐式建模MR图像的退化过程, 减小实验构建数据集与实际场景下MR图像的域差距, 并基于隐式退化模型构建样本对, 训练得到基于自引导扩散模型的MR图像重建网络, 从而实现无监督同尺寸MR图像的空间分辨率提升。在fastMRI数据集的4倍加速采样脑部MR图像超分辨实验结果显示, 本文提出的基于隐式退化模型的MR图像超分辨重建网络能够有效提升退化MR图像的空间分辨率, 同时与基于显示退化模型的图像退化重建方法相比, 本文提出的SG-Diffusion方法具有更好的重建效果。

【关键词】脑部; 磁共振图像; 超分辨; 扩散模型

【中图分类号】R318; TP183

【文献标志码】A

【文章编号】1005-202X(2024)06-0690-12

Super-resolution reconstruction network based on implicit degradation model for magnetic resonance images

LIU Huanyu¹, GUO Haipeng¹, LIU Xiaodong², LI Han¹, LI Junbao¹

1. Information Countermeasure Technique Institute, Faculty of Computing, Harbin Institute of Technology, Harbin 150080, China;
2. Department of Automatic Test and Control, School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150080, China

Abstract: Given that the existing methods of enhancing the resolution of magnetic resonance (MR) images by algorithms mainly focus on cross-size and same-size supervised super-resolution algorithms, a super-resolution reconstruction network (SG-Diffusion) for MR images is proposed based on an implicit degradation mapping model. The degradation process of MR images is implicitly modeled through a masked autoencoder, which reduces the domain gap between the experimental constructed dataset and the actual MR images, and the sample pairs are generated based on implicit degradation model. After training, a MR image reconstruction network based on self-guided diffusion model is obtained to realize the spatial resolution enhancement of unsupervised same-size MR images. The results of super-resolution experiments of 4-fold accelerated sampling brain MR images on fastMRI dataset show that the MR image super-resolution reconstruction network based on implicit degradation model proposed in the study can effectively improve the spatial resolution of degraded MR images, and that compared with the image degradation reconstruction method based on the explicit degradation model, the proposed SG-Diffusion method achieves better reconstruction results.

Keywords: brain; magnetic resonance imaging; super-resolution; diffusion model

【收稿日期】2024-01-23

【基金项目】国家自然科学基金(62271166); 哈尔滨工业大学医工交叉基金(IR2021104)

【作者简介】刘环宇, 副研究员, 硕士生导师, 研究方向: 机器学习算法、嵌入式智能系统、基于机器学习的网络空间安全, E-mail: liuhuanyu@hit.edu.cn

【通信作者】李君宝, 博士, 博士生导师, 研究方向: 机器学习算法、人工智能安全、嵌入式智能系统、图像处理, E-mail: lijunbao@hit.edu.cn

前言

磁共振(Magnetic Resonance, MR)图像由于其出色的成像能力, 目前广泛应用于临床医疗, 在对病灶进行定位以及辅助医生诊断等过程中正在发挥越来越重要的作用^[1]。与电子计算机断层扫描和X射线成像技术相比, MR成像的优点在于软组织成像分辨率高, 以及成像过程无电离辐射, 对人体不产生损害^[2-3]。而MR成像的缺点在于成像时间长、伪影噪声较多等, 这就导致在成像时间、硬件设备等条件受

限的情况下,MR成像的分辨率较低。在此条件下,提高MR成像主磁场强度可以使更多的氢质子成像,进而极大程度提高MR成像分辨率。目前国内主流使用的MR成像设备磁场强度包括1.5T和3.0T两种,3.0T MR成像设备与1.5T设备相比,成像清晰度显著提高,但同时伴随着辐射时间和强度的增加,过量的辐射会导致人身体过热,如11.7T和21T超高频成像系统等更先进的高磁场强度成像设备还存在一定安全隐患,无法在临床应用^[4]。因此,考虑到使用提高磁场强度方法提高MR成像设备分辨率存在的安全隐患,临床中为获得更高分辨率的MR图像通常采用两种方法,即以并行成像为代表的硬件方法和各类超分辨重建算法^[5]。而硬件方法需要特殊的相位阵列线圈,往往伴随着更高的设备成本,并且无法直接应用于现有的MR成像设备,因此使用图像超分辨技术在不改变MR成像设备结构的基础上提升MR成像分辨率具有研究价值。目前对于从算法层面提升MR图像分辨率的研究主要包括两种:使用加速采样掩膜处理MR成像k空间数据得到欠采样MR图像,并重建全采样MR图像,以全采样MR图像加速重建研究,此类研究在MR成像时间固定的同时提高MR成像的空间分辨率^[6-7];使用k空间截断或空域截断获得低分辨率MR图像并重建原始MR图像,并以此MR图像进行超分辨重建研究,此类研究提升MR成像结果MR图像的分辨率^[8-9]。对提升MR图像分辨率的研究主要停留在有监督、跨尺寸的超分辨算法研究上,缺乏面向相同尺寸不同空间分辨率MR图像的空间分辨率提升方法。

同尺寸图像的空间分辨率提升问题可以描述为图像的退化过程建模及逆过程的实现,而现有的图像退化过程建模均基于显式图像退化模型,不具备泛化性,对于退化过程复杂的MR图像存在拟合能力不足的问题。针对现有提升MR图像空间分辨率方法存在的问题,本文开展MR图像真实退化映射模型研究,包括基于掩码自编码器(Masked AutoEncoder, MAE)的MR图像样本对生成方法以及基于自引导条件去噪扩散模型的低空间分辨率MR图像重建网络。本文的贡献如下:(1)提出基于MAE的MR图像隐式退化表征模型,更好地表征实际应用场景中复杂多变的MR图像退化过程;(2)提出基于自引导条件去噪扩散模型的低空间分辨率MR图像重建网络SG-Diffusion,是第一个用于同尺寸不同空间分辨率MR图像的无监督空间分辨率提升网络;(3)在4倍加速采样fastMRI数据集的脑部MR图像上的实验结果表明,本文提出的隐式退化表征以及图像重建网络SG-Diffusion具有良好的图像重建效果。

1 方法

1.1 现有图像退化建模及重建方法

在超分辨问题中,图像的退化过程通常使用显式表达:

$$y = (x \otimes k) \downarrow_s + n \quad (1)$$

其中, x 为高分辨率图像, y 为退化低分辨率图像, k 为模糊核, \downarrow_s 表示降采样, n 为高斯噪声,具体的退化流程图见图1。

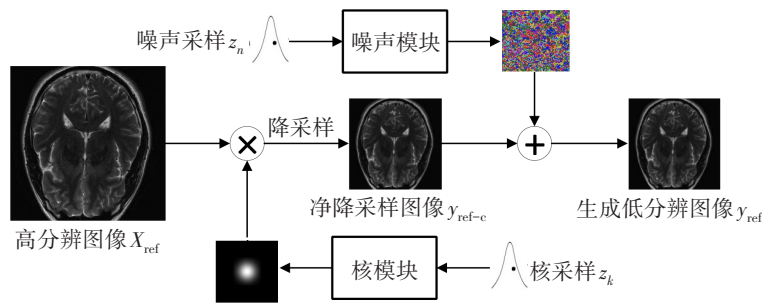


图1 超分辨问题图像退化流程图

Figure 1 Flowchart of super-resolution image degradation

在降采样因子 $s = 1$ 时,图像的退化过程不再包含降采样,在这样的显示退化建模前提下,退化过程中模糊核 k 和高斯噪声强度直接影响整个图像退化建模的性能,基于这样的退化模型对退化图像 y 进行重建,不涉及图像的物理分辨率变化,而是提升退化

图像 y 的空间分辨率。

对于模糊核的估计,整体问题的目标为满足:

$$\theta_k = \underset{k}{\operatorname{argmin}} \left(I_{\text{src}} * k - I_{\text{src}} + \left| 1 - \sum k_{i,j} \right| + \left| \sum k_{i,j} \cdot m_{i,j} \right| \right) \quad (2)$$

其中, $(I_{\text{src}} * k) - I_{\text{src}}$ 是使用内核 k 降质图像和具有理想

内核降质图像的误差最优化,鼓励退化图像保留源图像的重要低频信息, $|1 - \Sigma k_{i,j}|$ 和 $|\Sigma k_{i,j} \cdot m_{i,j}|$ 是对模糊核进行约束,使其更符合核分布的先验规律。通常对输入的源图像应用求解得到的模糊核完成图像的模糊处理,如式(3)所示:

$$I_D = I_{\text{HR}} \otimes k_i, i \in \{1, 2, \dots, m\} \quad (3)$$

其中, k_i 表示求解得到的模糊核, I_D 为得到的初步退化图像。在早期的图像复原任务中,通常将模糊核 k 固定,如使用高斯模糊核或其他固定大小模糊核^[10]处理原始图像后,添加一定强度的高斯噪声得到退化图像,此类方法如DPIR^[11]和Uformer^[12]使用端到端的训练方式训练网络,由于退化图像的生成模式单一,因此此类方法在处理同样模糊核和噪声强度的退化图像时能够表现出良好的性能,但此类方法显然与单图超分辨方法存在相同的问题,即实际退化图像是不存在参考模糊核和噪声强度的,当退化图像的退化过程不符合网络的先验预设时,网络的性能明显下降。因此在后续的研究中,多数的研究工作将重心转向盲模糊核估计方法,即不再假设退化图像的模糊核已知,在网络内部需对退化图像的模糊核进行估计,然后使用估计得到的模糊核逆处理退化图像,此类方法以迭代核校正方法IKC^[13]为代表。在IKC中,假设 $F(I^{LR}, k)$ 为以退化图像和模糊核信息为输入的超分辨预训练模型,在输入模糊核 k 符合 I^{LR} 的生成过程时,模型 F 的超分性能符合预期,而在输入模糊核 k' 不满足预设则超分结果出现伪影。因此IKC的核心思想在于寻找合适的模糊核 k 以使模型 F 生成符合预期的超分辨输出。

在IKC中,除了超分辨模型的训练,网络中还包含一个预测器 P (Predictor) 和一个矫正器 C (Corrector)用于使超分辨模型 F 的输入模糊核满足预期。其中预测器 P 直接从退化图像输入 I^{LR} 中估计模糊核 k ,该估计通过最小化L2损失获得:

$$\theta_p = \operatorname{argmin}_{\theta_p} \|k - P(I^{LR}; \theta_p)\|_2^2 \quad (4)$$

直接利用输入图像估计模糊核是十分困难的,因此IKC通过超分辨过程图像对模糊核 k 进行矫正,此过程通过矫正器 C 实现:

$$\theta_c = \operatorname{argmin}_{\theta_c} \|k - (C(I^{SR}; \theta_c) + k')\|_2^2 \quad (5)$$

在超分辨的每一个步骤中,矫正器 C 根据当前步骤的超分辨结果对模糊核输入 k 进行矫正,经过模糊核校正的超分辨模型 $F(I^{LR}, k^c)$ 又能够输出更好的超分辨结果。

通过循环对模糊核进行矫正,超分模型 $F(I^{LR}, k)$ 的过程伪影逐渐得到抑制,网络超分辨的视觉效果

随之逐渐提升。然而在IKC方法的实际训练中,依旧依赖现有模糊核生成退化图像,并以真实模糊核作为真值训练预测器 P 和矫正器 C 。在理想情况下,以足够多的模糊核训练得到的IKC网络能够从退化图像输入 I^{LR} 中准确估计模糊核 k ,并通过式(1)的逆过程对退化图像进行重建。在实际的图像退化中,图像的退化过程无法保证严格满足式(1)的显示建模假设,尤其是MR图像的成像过程往往受多种复杂退化因素影响,在实际退化过程不满足显式退化建模假设时,通过模糊核估计方法重建原始图像显然无法满足需要。

与显式退化过程建模相比,还有一类基于隐式退化建模的方法不再进行退化过程的建模,直接基于GAN网络结构,端到端的通过生成器得到输入退化图像的超分结果,并通过鉴别器减小生成超分结果图像和原始图像之间的分布差异,此类方法以DeblurGAN为代表^[14]。但GAN网络的训练经常伴随着众多的不确定性,因此本课题基于隐式退化建模方法展开研究,使用MAE^[15]初步隐式建模MR图像退化过程,并通过自引导条件去噪扩散模型^[16]对退化图像进行重建,通过这种方式提升同尺寸MR图像的空间分辨率。

1.2 基于扩散模型的图像隐式退化重建网络

对于给定输入-输出图像对数据集,记为 $D = \{x_i, y_i\}_{i=1}^N$,表示从未知分布 $p(x, y)$ 中抽取的样本。条件分布 $p(y|x)$ 是一个一对多映射,其中许多目标图像可能与单个源图像一致。本研究目的是通过将退化的源图像 x 映射到目标图像 $y \in \mathbf{R}^d$ 的随机迭代细化过程学习 $p(y|x)$ 的参数逼近。通过将条件去噪扩散模型适应于条件图像生成,可以实现这一过程。

定义一个正向马尔可夫扩散过程 q ,其通过 T 次迭代逐步向高分辨率图像 y_0 添加高斯噪声:

$$q(y_{1:T}|y_0) = \prod_{t=1}^T q(y_t|y_{t-1}) \quad (6)$$

$$q(y_t|y_{t-1}) = N(y_t | \sqrt{\alpha_t} y_{t-1}, (1 - \alpha_t) I) \quad (7)$$

其中,标量参数 α_t 是超参数,服从 $0 < \alpha_t < 1$,它决定每次迭代中添加噪声的方差。 y_{t-1} 以 $\sqrt{\alpha_t}$ 为因子衰减,以确保随机变量的方差在 $t \rightarrow \infty$ 时保持有界。在给定 y_0 的情况下,可以通过将中间步骤边缘化来描述 y_t 的分布:

$$q(y_t|y_0) = N(y_t | \sqrt{\gamma_t} y_0, (1 - \gamma_t) I) \quad (8)$$

其中, $\gamma_t = \prod_{i=1}^t \alpha_i$ 。此外,通过一些代数操作和补全平方,可以推导出给定 (y_0, y_t) 下 y_{t-1} 的后验分布为:

$$q(y_{t-1}|y_0, y_t) = N(y_{t-1}|\mu, \sigma^2 I) \quad (9)$$

$$\mu = \frac{\sqrt{\gamma_{t-1}}(1 - \alpha_t)}{1 - \gamma_t} y_0 + \frac{\sqrt{\alpha_t}(1 - \gamma_{t-1})}{1 - \gamma_t} y_t \quad (10)$$

$$\sigma^2 = \frac{(1 - \gamma_{t-1})(1 - \alpha_t)}{1 - \gamma_t} \quad (11)$$

当参数化反向过程和制定反向过程的数据对数似然的变分下界时,这种后验分布可以显著地为去噪模型提供指导。扩散模型推理的关键是去噪网络,在退化映射模型的研究部分中,本课题以源图像 x 形式的侧信息为条件,优化一个神经去噪模型 f_θ ,该模型将源图像 x 和有噪声的目标图像 \tilde{y} 作为输入,并以恢复无噪声目标图像 y_0 为目标。噪声目标图像的定义与正向扩散过程中不同阶段噪声图像的边缘分布保持一致:

$$\tilde{y} = \sqrt{\gamma} y_0 + \sqrt{1 - \gamma} \epsilon, \epsilon \sim N(0, I) \quad (12)$$

除源图像 x 和有噪声的目标图像 \tilde{y} 外,去噪模型 $f_\theta(x, \tilde{y}, \gamma)$ 将噪声方差 γ 的充分统计量作为输入,并经过训练预测噪声向量 ϵ 。因此,去噪模型通过对 γ 的调节来了解噪声的水平,训练 f_θ 的目标函数为:

$$E_{(x,y)} E_{\tilde{y}} f_\theta(x, \sqrt{\gamma} y_0 + \sqrt{1 - \gamma} \epsilon, \gamma) - \epsilon_p^p \quad (13)$$

其中, $\epsilon \sim N(0, I)$, (x, y) 从训练数据集中采样 $p \in \{1, 2\}$, $\gamma \sim p(\gamma)$ 。 γ 的分布对模型的质量和产生的输出有很大的影响。除了将 f_θ 的输出回归到 ϵ ,也可以将 f_θ 的输出回归到 y_0 。在已知 γ 和 \tilde{y} 的情况下, ϵ 和 y_0 可以确定相互推导。

退化映射模型的推断过程可以定义为逆向马尔可夫过程,它与正向扩散过程的方向相反,从高斯噪声 y_T 开始:

$$p_\theta(y_{0:T}|x) = p(y_T) \prod_{t=1}^T p_\theta(y_{t-1}|y_t, x) \quad (14)$$

$$p(y_T) = N(y_T|0, I) \quad (15)$$

$$p_\theta(y_{t-1}|y_t, x) = N(y_{t-1}|\mu_\theta(x, y_t, \gamma_t), \sigma_t^2 I) \quad (16)$$

根据各向同性高斯条件分布定义推理过程为 $p_\theta(y_{t-1}|y_t, x)$,这一过程是可学习的。如果将正向过程噪声方差步长设得尽可能小,即 $\alpha_{1:T} \approx 1$,则最优反向过程 $p_\theta(y_{t-1}|y_t, x)$ 近似高斯分布。因此在推理过程 $p_\theta(y_{t-1}|y_t, x)$ 中选择的高斯条件可以为真实的反向过程提供合理的拟合。同时, $1 - \gamma_t$ 应足够大,以使得 y_t 近似按照先验 $p(y_t) = N(y_t|0, I)$ 分布,使采样过程从纯高斯噪声开始。去噪模型 f_θ 在给定包含任意时刻 y_t 的噪声图像 \tilde{y} 的条件下估计 ϵ ,因此给定 y_T ,可以将 y_0 重新表示为:

$$\hat{y}_0 = \frac{1}{\sqrt{\gamma_t}} \left(y_t - \sqrt{1 - \gamma_t} f_\theta(x, y_t, \gamma_t) \right) \quad (17)$$

使用 $q(y_{t-1}|y_0, y_t)$ 的后验分布替换估计值 \hat{y}_0 ,以参数化 $p_\theta(y_{t-1}|y_t, x)$ 的均值为:

$$\mu_\theta(x, y_t, \gamma_t) = \frac{1}{\sqrt{\alpha_t}} \left(y_t - \frac{1 - \alpha_t}{\sqrt{1 - \gamma_t}} f_\theta(x, y_t, \gamma_t) \right) \quad (18)$$

并根据正向过程的方差,设置 $p_\theta(y_{t-1}|y_t, x)$ 的方差为 $1 - \alpha_t$ 。在完成参数化后,在扩散模型中,迭代细化的每一次迭代都采用以下形式:

$$y_{t-1} \leftarrow \frac{1}{\sqrt{\alpha_t}} \left(y_t - \frac{1 - \alpha_t}{\sqrt{1 - \gamma_t}} f_\theta(x, y_t, \gamma_t) \right) + \sqrt{1 - \alpha_t} \epsilon_t \quad (19)$$

其中, $\epsilon_t \sim N(0, I)$,这类似于朗之万动力学的一个步骤,即 f_θ 提供数据对数密度梯度的估计。

如果将正向扩散过程视为推理过程的固定近似后验,则可以在边际对数似然上推导出以下变分下界:

$$E_{(x,y_0)} \log p_\theta(y_0|x) \geq E_{x,y_0} E_{q(y_{1:T}|y_0)} \left[\log p(y_T) + \sum_{t=1}^T \log \frac{p_\theta(y_{t-1}|y_t, x)}{q(y_t|y_{t-1})} \right] \quad (20)$$

考虑到推理过程的特定参数化,负变分下界可以表示为以下简化损失,直到完成每个时间步骤的每个项的常数加权:

$$E_{x,y_0} \int \sum_{t=1}^T \frac{1}{T} \epsilon - \epsilon_\theta(x, \sqrt{\gamma_t} y_0 + \sqrt{1 - \gamma_t} \epsilon, \gamma_t)_2^2 \quad (21)$$

其中, $\epsilon \sim N(0, I)$ 。这个目标函数对应 $p(\gamma)$ 在均匀分布 $\{\gamma_1, \dots, \gamma_T\}$ 上的表征。

条件去噪扩散模型在 T 个细化步骤中生成目标图像 y_0 ,其从纯噪声图像 $y_T \sim N(0, I)$ 开始,迭代地细化输出图像以获得序列 $(y_{T-1}, y_{T-2}, \dots, y_0)$,并根据学习到的条件分布 $p_\theta(y_{t-1}|y_t, x)$ 使最终的输出满足 $y_0 \sim p(y|x)$,见图2。

中间图像在迭代细化链中的分布定义为正向扩散过程,该过程通过固定的马尔可夫链逐步向输出添加高斯噪声,记为 $q(y_t|y_{t-1})$,扩散模型的目标是通过以 x 为条件的反向马尔可夫链迭代地从噪声中恢复信号来反转高斯扩散过程,使用深度学习去噪模型 f_θ 学习反向链,该模型将源图像和有噪声的目标图像作为输入并估计噪声,对于条件去噪扩散模型在图像退化建模中的工作,可以认为条件 x 表示输入退化图像, y_0 表示 x 对应原始无退化图像,扩散模型的目的即为以 x 作为条件,扩散步骤 t 和对应退化图像 y_t




图2 正向扩散过程 q (从左到右)逐渐向目标图像添加高斯噪声,反向过程 p (从右向左)迭代地去噪目标图像,条件是源图像 x
Figure 2 During forward diffusion process q (from left to right), Gaussian noise is gradually added to the target image, and during reverse process p (from right to left), the noise is iteratively removed from the target image, provided that there is source image x

作为深度学习去噪模型 f_θ 的输入,训练一个迭代去噪器。在推理阶段,将真实退化图像作为网络输入的条件 x ,高斯噪声作为反向过程第一次迭代的输入,通过去噪器迭代去噪,最终得到的网络输出即为条件图像 x 的原始图像。所提出的深度学习去噪模型的训练部分伪代码如下所示:

Input: Degraded image x , Original image y_0

Output: Diffusion Denoising Model f_θ

repeat

Sample from $p(x, y)$ to get (x, y_0)

Sample from $p(y)$ to get γ

Generate initial random Gaussian noise $\epsilon \sim N(0, I)$

Perform random gradient descent:

$$\nabla_\theta f_\theta(x, \sqrt{\gamma} y_0 + \sqrt{1 - \gamma} \epsilon, \gamma) - \epsilon_p^p$$

until Diffusion Denoising Model f_θ converges

所提出的深度学习去噪模型的推理部分伪代码如下所示:

Input: Degraded image x

Output: Reconstructed image y_0

Sample y_t from Gaussian random noise

for $t=T, T-1, \dots, 1$ do

Sample $z \sim N(0, I)$ from Gaussian random noise

Iterate to compute the reverse process:

$$y_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left(y_t - \frac{1 - \alpha_t}{\sqrt{1 - \gamma_t}} f_\theta(x, y_t, \gamma_t) \right) + \sqrt{1 - \alpha_t} z$$

end

return inference image y_0

对于深度学习去噪模型 f_θ 的具体网络结构,常用的去噪模型网络采用U-Net^[17]结构,并在其中添加自注意力机制,以图像的输入尺寸 128×128 为例,网络采用的U-Net总体结构图如图3所示,网络的特征通道维数设置为128,由10组对称的残差组构成,每个残差组内包含3个残差模块。




图3 输入图像尺寸 128×128 条件下U-Net去噪模型 f_θ 网络结构

Figure 3 Network structure of U-Net denoising model f_θ with input image of 128×128

在训练过程中,图中的 x 对应退化图像, y_t 对应 x 的原始图像经 t 步骤正向过程得到的加噪图像,二者以级联方式作为U-Net的原始输入,噪声方差 γ 使用分段分布,即 $p(\gamma) = \sum_{t=1}^T \frac{1}{T} U(\gamma_{t-1}, \gamma_t)$ 。具体来说,在训练过程中首先根据时间序列 $t \sim \{0, \dots, T\}$ 对噪声序列进行采样 $\gamma \sim U(\gamma_{t-1}, \gamma_t)$ 。通常时间步数 T 设置为2000, y_t 是均匀间隔的,越大的 T 值往往会产生性能越优异的模型,但会伴随计算成本的提高。

2 基于自引导扩散模型的MR图像重建网络

2.1 基于MAE的伪样本对生成网络

基于DDPM的图像生成网络具有强大的隐式拟合能力,然而其训练过程是有监督的,即扩散模型的训练需要使用成对的不同分辨率图像,这对于MR图像来说是不可直接获取的,因此需要通过人为生成伪样本对的方法生成可供扩散模型学习的样本,因此本文采用MAE生成样本对。MAE是一种自编码方法,由编码器将输入信号映射到潜在的特征表示,再由解码器从潜在特征表示中重建原始信号,其采用非对称设计,即编码器仅观察部分输入,并采用解码器从潜在特征表示和掩码标记中重建完整原始信号。

MAE的编码器通过位置嵌入的线性投影将输入嵌入小块图像,并通过一系列Transformer^[18]块处理结果集,编码器的输入经过随机掩膜采样,最终编码器仅对一部分输入小块图像进行操作。MAE解码器的输入是完整的图像序列集,即通过填充将内容缺失的编码器输出补充到与原始图像维度一致的序列,并通过掩码标记每一个共享、学习过的向量,表示存在要预测的缺失图像块,通常MAE的编码器仅

在预训练期间执行图像重建任务。MAE网络通过预测每个掩码块所遮挡的像素值来重建输入图像,解码器输出中的每个元素都是一个代表小块图像的像素值向量,解码器的最后一层是线性投影,其输出通道数量等于图像小块中像素值的数量,并通过形状调整以重建图像。基于MAE的MR退化图像样本对生成网络结构示意图如图4所示。

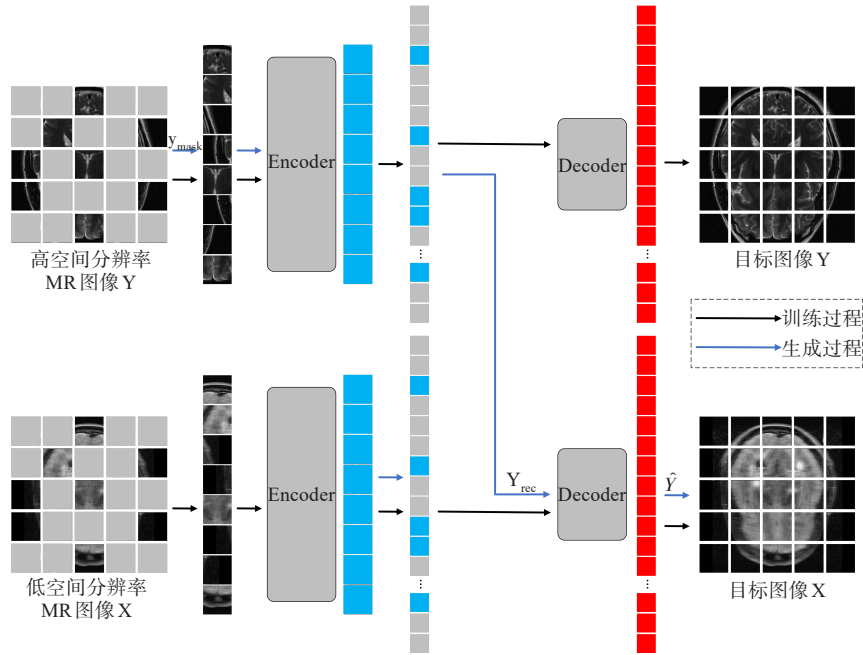


图4 基于MAE的MR退化图像样本对生成网络

Figure 4 MR degradation image sample pairs generation network based on masked autoencoder

2.2 基于自引导扩散模型的MR图像重建网络

使用MAE对低空间分辨率MR图像进行预训练,通过掩膜处理编码器输入,并通过解码器重建原始图像,将得到的MAE中的编码器取出作为低空间分辨率MR图像的特征提取网络,用于将低空间分辨率MR图像从图像样本空间映射到特征空间,该过程可以记为:

$$g_{\phi}(\cdot): R^{W \times H \times 3} \rightarrow R^{W \times H \times C} \quad (22)$$

其中, g 表示参数为 ϕ 的特征提取网络, C 表示特征空间维度。同时,另外使用MAE对高空间分辨率MR图像进行预训练,同样通过掩膜处理编码器输入,并通过解码器重建原始图像,将得到的MAE中的解码器取出,作为由特征空间映射到高空间分辨率MR图像样本生成网络,该过程可表示为:

$$f_{\phi}(\cdot): R^{W \times H \times C} \rightarrow R^{W \times H \times 3} \quad (23)$$

其中, f 表示参数为 ϕ 的样本生成网络,MR图像伪样本对的生成过程可以表示为:

$$\hat{y} = f_{\phi}(g_{\phi}(y)) \quad (24)$$

其中, y 表示原始高空间分辨率MR图像, \hat{y} 表示由低空间分辨率MR图像得到的MAE编码器和高分辨率MR图像得到的MAE解码器生成的伪退化MR图像样本。最终的样本对由具有空间像素对应关系的 y 和 \hat{y} 构成,用于引导训练基于条件去噪扩散模型的低空间分辨率MR图像重建网络。对于基于条件去噪扩散模型的MR图像退化重建网络训练过程,采用自引导训练策略,将生成的伪样本对仅用于扩散模型训练方向的引导,而非直接使用样本对训练扩散模型^[19]。

为了权衡条件扩散模型中的模式覆盖和样本保真度,使用标签条件对扩散模型的训练过程进行引导。通过在训练过程中随机丢弃引导信号,以实现在单个模型中的条件和无条件扩散模型组合,整个过程可以表示为:

$$\tilde{p}_{\theta}(y_i|x; t, \omega) = (1-\omega)p_{\theta}(y_i|x, t) + \omega p_{\theta}(y_i|x, t; f_{\phi}(g_{\phi}(x))) \quad (25)$$

其中, ω 表示引导强度, ω 越大, 扩散模型的训练方向与引导信号样本空间越对齐。

在基于真实退化映射模型的MR图像退化网络中, 引导信号表示由输入低空间分辨率样本 x 生成的伪样本 \hat{x} 。由此, 基于自引导条件去噪扩散模型的图像退化重建网络结构设计见图5。通过自监督策略预训练特征提取网络和样本生成网络 f_ϕ 、 g_ϕ , 然后对非配对MR图像样本集中的低分辨率MR图像进行特征提取, 并根据输入图像生成伪样本对, 将该伪样

本对作为扩散模型的自引导信号, 有选择地引导MR图像的退化重建过程, 以此提升MR图像的空间分辨率。扩散模型条件信息的引入通过将退化图像和原始高分辨率图像在通道上进行拼接作为输入, 因此在自引导策略下, 扩散模型以引导因子为概率随机将输入拼接图像替换为退化图像与其自身的拼接图像, 通过这种方式即可实现简单有效的自引导扩散模型训练。

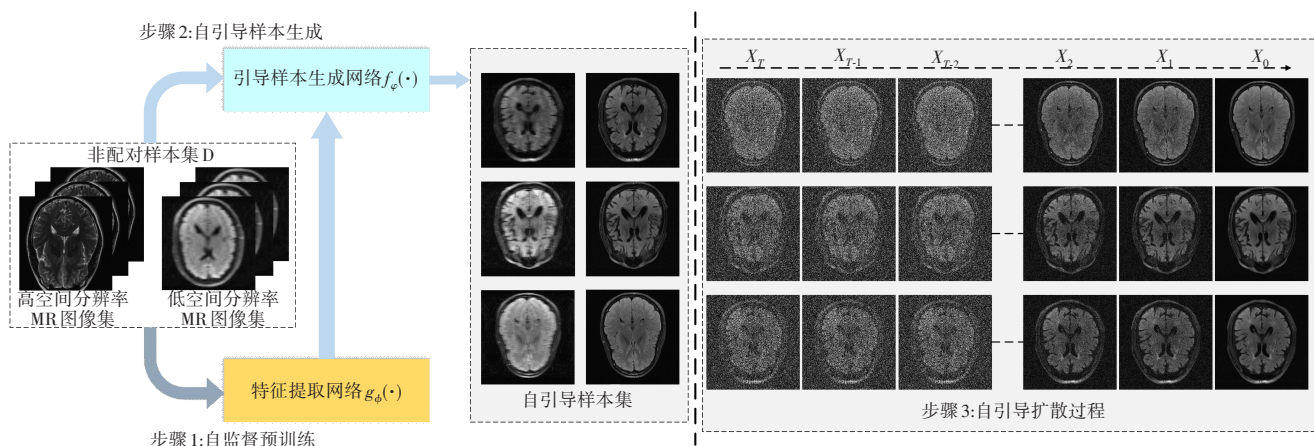


图5 基于自引导条件去噪扩散模型的图像退化重建网络结构

Figure 5 Image degradation reconstruction network structure based on self-guided conditional denoising diffusion model

3 结果与分析

基于真实退化映射模型的超分辨率算法应用场景为退化模式相对固定的两种采集条件下MR图像之间的映射过程, 二者之间不具备像素对应关系, 因此本课题在fastMRI数据集^[20]的x4加速采样脑部MR图像数据集上开展自引导样本生成网络的实验验证, 由于加速采样重建MR图像退化过程属于笛卡尔欠采样, 因此这一过程可以初步满足复杂退化条件。

3.1 实验设置与评价指标

本文的实验验证部分采用的硬件配置为: Core i9-12700H处理器和3080Ti显卡, 32 G内存。软件配置为: 采用Pytorch框架^[21]进行超分辨网络训练。评价指标方面, 本文使用峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)和结构相似性(Structral Similarity, SSIM)作为衡量网络超分辨性能的评价指标, 二者均为客观评价指标, 即给定包含明确对应关系的输入图像和原始图像, 计算二者的内容差异, 两项评价指标越大, 代表网络的超分辨性能越强。

对于给定的大小为 $M \times N$ 的原始图像 I 和退化图像 K , 二者的均方误差 (Mean-Square Error, MSE) 可

以定义为:

$$\text{MSE} = \frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} [I(i, j) - K(i, j)]^2 \quad (26)$$

利用原始图像和退化图像的均方误差就可以计算得到二者的PSNR:

$$\text{PSNR} = 10 \log_{10} \left(\frac{\text{MAX}_I^2}{\text{MSE}} \right) \quad (27)$$

其中, MAX_I^2 为图像最大像素值的平方。通常来讲, 图像的存储数据格式为 uint8, 即通过八位二进制数来表示一个像素点, 因此 MAX_I 应该等于像素的上限, 即:

$$\text{MAX}_I = 2^8 - 1 \quad (28)$$

针对三通道RGB图像, 通常通过分别计算三通道的PSNR后取平均的方式获得整幅图像的PSNR。图像的SSIM则通常基于输入样本 I 和退化样本 K 的亮度、对比度和结构进行计算:

$$l(I, K) = \frac{2\mu_I\mu_K + c_1}{\mu_I^2 + \mu_K^2 + c_1} \quad (29)$$

$$c(I, K) = \frac{2\sigma_I\sigma_K + c_2}{\sigma_I^2 + \sigma_K^2 + c_2} \quad (30)$$

$$s(I,K)=\frac{\sigma_{IK}+c_3}{\sigma_I\sigma_K+c_3}\tag{31}$$

其中, $l(I,K)$ 表示亮度, $c(I,K)$ 表示对比度, $s(I,K)$ 表示结构。 μ_I 和 μ_K 分别代表 I 和 K 的均值, σ_I^2 和 σ_K^2 分别代表 I 和 K 的方差, σ_{IK} 表示 I 和 K 的协方差。 $c_1=(k_1L)^2$, $c_2=(k_2L)^2$ 为两个常数, 避免计算过程中出现除零的情况, L 表示像素值范围, 即MAE计算中的 MAX_I , $k_1=0.01$, $k_2=0.03$ 为默认值。根据亮度对比度和结构, 两幅图像的SSIM可以表示为:

$$\text{SSIM}(I,K)=[l(I,K)]^{\alpha}[c(I,K)]^{\beta}[s(I,K)]^{\gamma}\tag{32}$$

通常将超参数 α 、 β 、 γ 均设定为1, 这样常用的

SSIM就可以表示为:

$$\text{SSIM}(I,K)=\frac{(2\mu_I\mu_K+c_1)(2\sigma_I\sigma_K+c_2)}{(\mu_I^2+\mu_K^2+c_1)(\sigma_I^2+\sigma_K^2+c_2)}\tag{33}$$

3.2 基于MAE的样本生成网络实验验证

本研究使用原始MR图像和欠采样MR图像分别作为网络输入进行MAE网络的预训练, 并以0.1为步长从0.05~0.75逐渐改变MAE的掩码率, 以此探究最适合用于构成自引导样本生成网络的MAE结构, 得到的实验结果见表1, 其中样本的构建效果使用PSNR、SSIM以及多核最大均值差异(MK-MMD)^[22]作为评价指标。

表1 使用不同掩码率的自引导样本生成网络性能
Table 1 Performance of self-guided sample generation networks using different mask rates

掩码率	0.05	0.15	0.25	0.35
	PSNR (dB)/SSIM/MK-MMD	PSNR (dB)/SSIM/MK-MMD	PSNR (dB)/SSIM/MK-MMD	PSNR (dB)/SSIM/MK-MMD
0.05	23.946/0.722/0.135	23.907/0.780/0.123	23.516/0.700/0.125	23.677/0.708/0.124
0.15	22.694/0.635/0.160	23.641/0.699/0.122	23.135/0.666/0.135	22.872/0.664/0.133
0.25	22.090/0.603/0.255	23.052/0.648/0.162	22.698/0.634/0.163	23.018/0.654/0.150
0.35	21.563/0.570/0.266	22.659/0.621/0.169	22.675/0.627/0.158	23.336/0.673/0.129
0.45	21.221/0.550/0.281	22.079/0.580/0.189	22.053/0.584/0.185	22.417/0.64/0.160
0.55	20.513/0.514/0.294	20.827/0.517/0.243	20.808/0.521/0.247	20.939/0.535/0.217
0.65	20.824/0.527/0.308	21.185/0.525/0.222	21.456/0.550/0.222	21.255/0.540/0.217
0.75	20.490/0.517/0.317	20.619/0.510/0.225	20.822/0.528/0.300	20.335/0.498/0.297

续表1

掩码率	0.45	0.55	0.65	0.75
	PSNR (dB)/SSIM/MK-MMD	PSNR (dB)/SSIM/MK-MMD	PSNR (dB)/SSIM/MK-MMD	PSNR (dB)/SSIM/MK-MMD
0.05	23.643/0.706/0.125	24.007/0.704/0.175	23.863/0.701/0.165	23.56/0.687/0.146
0.15	22.930/0.659/0.137	23.325/0.667/0.170	22.963/0.658/0.170	22.974/0.659/0.161
0.25	22.653/0.636/0.160	23.198/0.653/0.232	23.215/0.660/0.219	23.197/0.657/0.203
0.35	22.643/0.634/0.146	23.041/0.648/0.217	22.721/0.634/0.215	22.946/0.646/0.207
0.45	23.232/0.663/0.135	22.499/0.621/0.208	22.480/0.620/0.210	22.757/0.635/0.222
0.55	21.458/0.568/0.186	22.190/0.606/0.161	21.700/0.576/0.194	21.782/0.586/0.246
0.65	21.713/0.565/0.194	22.077/0.594/0.222	22.152/0.600/0.177	22.161/0.601/0.225
0.75	20.353/0.497/0.288	21.457/0.567/0.303	21.510/0.577/0.279	21.809/0.588/0.242

最大均值差异是迁移学习中常用的损失函数, 其提出两个假设:(1)若两随机变量分布的任意阶矩均相同, 那么认为两个分布一致;(2)若两个分布不同, 则使两个分布之间差异最大的矩可以用作衡量两个分布的标准。最大均值差异MMD通常可以用作两个相关但不同的随机变量分布之间的分布差异, MMD的计算方式可以定义为:

$$\text{MMD}[F,p,q]=\sup_{f\in F}(E_p[f(x)]-E_q[f(y)])\tag{34}$$

其中, $\sup(\cdot)$ 表示上界, $E_p(\cdot)$ 表示期望, $f(\cdot)$ 表示映射函数, F 表示函数域。 x 为源域随机变量, y 为目标域随机变量, 假设 x 和 y 分别服从分布 p 和 q , $f(x)$ 和 $f(y)$ 分别为源域随机变量 x 和目标域随机变量 y 经过映射 f 后的变量。在实现过程中, 映射函数 f 将随

机变量映射到高维空间,并在高维空间求解均值的差值,这个均值即为均值差异,均值差异的上界即为最大均值差异MMD。

多核最大均值差异 MK-MMD 基于 MMD 的思想,使用多个核函数构成一个总核函数代替 MMD 方法中的单一映射函数 f ,以确保测试能力和低测试误差。实践中,越低的 MK-MMD 指标意味着两个分布间的差异越小。由表 1 中实验结果可知,随着特征提取网络的掩码率升高,自引导样本生成网络性能急剧下降,因此应当选取较小掩码率的 MAE 编码器作为自引导样本生成网络的特征提取网络。

对于样本生成网络,掩码率的提高并不会使网

络性能急剧下滑,同时由于遮蔽了大部分输入图像,MAE 解码器能够关注于从稀疏特征空间恢复图像。因此最终采用 0.05~0.15 掩码率的 MAE 网络作为自引导样本生成网络,在 100 轮的微调后,生成的样本对用于后续引导扩散模型的训练。

图 6 展示了使用不同掩码率 MAE 网络作为自引导样本生成网络的视觉效果。可以明显观察到,随着掩码率的增加,样本生成网络生成的图像样本分布差异减小,但生成的图像具有明显网格效应,因此本文通过自引导策略训练扩散模型,以此减少由于网格效应带来的超分效果下降。




图 6 使用不同掩码率生成样本视觉效果

Figure 6 Visual effects of samples generated using different mask rates

3.3 MR 图像隐式退化重建网络实验验证

为了验证本文提出的基于自引导隐式退化映射模型的 MR 图像重建网络有效性,本文与其他图像退化重建网络进行对比,对比算法包括使用非盲图像复原方法(Uformer)^[12]以及使用核估计的盲图像复原方法(IKC)和不使用核估计的盲图像复原方法(DeblurGANv2)^[23]。

为了与各方法原始论文中训练参数保持一致,IKC 使用各向异性 21×21 高斯模糊核,并添加噪声强度 $\sigma = 15$ 的加性高斯噪声处理原始图像得到退化图像,并在测试阶段将真实退化图像作为输入,IKC 的迭代核估计次数 t 设置为 7;Uformer 模型由于采用端到端的形式直接对原始图像进行重建,因此直接使用 Uformer 在 Gopro^[24]数据集上的预训练模型,将真实退化图像作为输入评估 Uformer 的图像重建效果;DeblurGANv2 同样为端到端训练模型,但由于其采用无监督策略,因此直接使用非配对的 MR 图像退化数据集作为 DeblurGANv2 的训练数据集,并使用配对 MR 图像数据集作为输入评估 DeblurGANv2 的图像重建效果,训练过程使用 ADAM 优化器,学习率设置为 0.000 1,在 150 轮训练后线性下降为 0。

本文提出方法 SG-Diffusion 使用与 DeblurGANv2

相同的数据集进行训练,不同的是在自引导扩散模型训练之前,首先通过样本生成网络生成配对数据集,然后将此配对数据集作为自引导扩散模型的输入监督训练 SG-Diffusion 网络,这样既实现 SG-Diffusion 的监督训练,同时整个 MR 图像重建网络仍然基于无监督策略。在 SG-Diffusion 的训练过程中,自引导因子设置为 0.9,时间步设置为 2 000,噪声采样区间为 $[0.000\ 001, 0.01]$,训练 500 轮次与对比方法保持一致。在脑部 MR 图像加速采样数据集上进行实验验证,得到的结果见表 2。可以看到在不引入自引导策略,仅使用样本生成网络 MAE 的生成样本监督训练扩散模型时,网络的重建性能低于现有方法,而使用自引导策略则能够大幅度提升扩散模型的重建性能,并使整个图像重建网络在 PSNR 和 MK-MMD 指标上获得现有方法中的最优性能。图 7 展示了各方法的重建可视化结果,可以看到本文提出的 SG-Diffusion 方法在没有事先引入显式退化先验的条件下,能够明显去除退化图像中由于加速采样掩膜处理产生的干扰条纹,而其他基于显式建模的图像重建方法或端到端图像重建方法均没有对此类条纹的去除效果,部分方法(如 DeblurGANv2)甚至将干扰条纹放大。这足以证明所提方法能够良好地基于隐式退化建模对输入退化图像进行重建。

表 2 加速采样 MR 图像重建结果

Table 2 Accelerated sampling MR image reconstruction results

评价指标	Uformer	IKC	DeblurGANv2	SG-Diffusion	
				启用自引导	不启用自引导
PSNR/dB	23.861	23.753	22.349	24.117	22.054
SSIM	0.722	0.729	0.702	0.674	0.559
MK-MMD	0.091	0.113	0.243	0.026	0.136




图 7 本文提出的 SG-Diffusion 方法与其他方法可视化结果对比

Figure 7 Comparison of visualization results of the proposed SG-Diffusion method with other methods

在自引导扩散模型中,自引导因子 w 的值意味着扩散模型为条件概率模型训练的概率,越低的自引导因子意味着扩散模型条件训练越少,本文将自引导因子以 0.1 为步长逐渐改变自引导因子 w 的值,得到不同自引导因子下的 SG-Diffusion 模型重建性能如表 3 所示,可以看到,在自引导因子 $w=0.9$ 时,模型的重建性能最优。实际上,引导因子 $w=0.3$ 及 0.4 的扩散模型经过了约 1 000 轮次的迭代训练,可以看到 $w=0.3$ 时的模型同样具备良好的重建效果,因此可以认为,引导因子的下降会提升扩散模型的训练难度,而对网络的重建性能影响有限,因此在实际应用时应根据实际情况调整引导因子 w 的值以权衡训练难度和网络重建质量。

除此之外,上述的 MR 图像重建结果为使用 2 000 个时间步迭代采样的结果,在实际操作中,过多的时间步往往意味着过长的推理时间,因此本文探究 SG-Diffusion 方法在不同时间步迭代下的结果,如表 4 所示。当采样时间步大于 2 000,即可以为每幅图像分配更多推理时间时,SG-Diffusion 方法的重建性能较预设值的 2 000 时间步推理结果相比更优。而在推理时间不足时,减少推理时间步,通过 1 500 次迭代,取得的推理结果已经可以满足图像重建的性能需要。这意味着可以在保证网络重建性能的同时保留大幅度减少推理时间。

为了证明本文所提 MR 图像重建方法中,对图像退化过程进行隐式建模的重要性,本文还与一种先

表 3 自引导扩散模型SG-Diffusion随自引导因子 w 重建性能变化

Table 3 Variation of self-guided diffusion model (SG-Diffusion) performance with self-guided factor w

评价指标	自引导因子 w								
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
PSNR/dB	20.472	20.601	23.801	23.208	15.881	17.437	23.081	21.027	24.120
SSIM	0.520	0.537	0.669	0.628	0.259	0.340	0.614	0.498	0.674
MK-MMD	0.386	0.311	0.030	0.033	1.078	0.666	0.029	0.242	0.026

表 4 自引导扩散模型SG-Diffusion随推理时间步 t 变化

Table 4 Variation of self-guided diffusion model (SG-Diffusion) performance with inference time step t

评价指标	时间步 t					
	500	1 000	1 500	2 000	2 500	3 000
PSNR/dB	10.881	14.137	23.160	24.121	24.253	24.241
SSIM	0.055	0.126	0.617	0.674	0.676	0.675
MK-MMD	2.541	1.442	0.067	0.026	0.026	0.026

进图像去退化模型 BlindDPS^[25]进行对比,BlindDPS方法同样以条件概率扩散模型DDPM为基础对图像退化进行重建,区别在于BlindDPS方法仍然以显式

退化模型为基础,对于一个退化图像输入,BlindDPS方法同时使用两个不同的扩散模型对图像和模糊核进行去噪,并通过迭代获得最终的重建图像输出。使用BlindDPS方法获得的重建MR图像和本文SG-Diffusion方法获得的重建图像见图8,利用条件概率扩散模型DDPM进行图像推理,BlindDPS进行模糊核估计后应用显式退化模型即式(1)的逆过程对图像进行重建,得到的图像重建效果显然比本文所采用的隐式退化建模图像重建方法SG-Diffusion差,这进一步证明MR图像的退化过程与既有图像显式退化过程表达式不符,以及本文方法的有效性。




图 8 使用显式退化模型/隐式退化模型的扩散模型MR图像重建结果对比

Figure 8 Comparison of MR image reconstruction results of diffusion models using explicit/implicit degradation model

4 结 论

本文提出基于隐式图像退化建模的自引导扩散图像重建模型SG-Diffusion,用于对MR图像的退化过程进行隐式退化重建,进而提升MR图像的空间分辨率。SG-Diffusion方法使用MAE构成样本对生成网络,分别从非配对的原始图像和退化图像中提取特征并重建,将样本对生成网络的输出样本作为自引导扩散模型的输入,以此实现整个图像重建网络的无监督训练。在加速采样MR图像数据集上的实验结果表明,本文提出的SG-Diffusion方法能够良好提升MR图像的空间分辨率,并且与其他图像重建方法相比具有最优的图像重建性能。

【参考文献】

[1] 马超. 医学磁共振图像体数据三维分割研究[D]. 哈尔滨: 哈尔滨工业大学, 2019.
Ma C. Research on three dimensional segmentation of volumetric medical magnetic resonance images[D]. Harbin: Harbin Institute of Technology, 2019.

[2] 刘家奇. 基于深度网络的医学MRI超分辨率研究[D]. 哈尔滨: 哈尔滨工业大学, 2021.
Liu JQ. Research on medical MRI super-resolution algorithm based on deep network[D]. Harbin: Harbin Institute of Technology, 2021.

[3] 梁海兰. 乳腺MR图像三维超分辨率重建[D]. 天津: 天津大学, 2016.
Liang HL. Breast MR image 3D super-resolution reconstruction[D]. Tianjin: Tianjin University, 2016.

[4] Baker KB, Tkach JA, Nyenhuis JA, et al. Evaluation of specific absorption rate as a dosimeter of MRI-related implant heating[J]. J Magn Reson Imaging, 2004, 20(2): 315-320.

[5] Griswold MA, Jakob PM, Heidemann RM, et al. Generalized autocalibrating partially parallel acquisitions (GRAPPA)[J]. Magn Reson Med, 2002, 47(6): 1202-1210.

- [6] Montalt-Tordera J, Muthurangu V, Hauptmann A, et al. Machine learning in magnetic resonance imaging: image reconstruction[J]. *Phys Med*, 2021, 83: 79-87.
- [7] PLOS ONE Editors. Retraction: magnetic resonance imaging reconstruction algorithm under complex convolutional neural network in diagnosis and prognosis of cerebral infarction[J]. *PLoS One*, 2023, 18(8): e0290864.
- [8] Zhao M, Wei Y, Wong KK. A generative adversarial network technique for high-quality super-resolution reconstruction of cardiac magnetic resonance images[J]. *Magn Reson Imaging*, 2022, 85: 153-160.
- [9] Du WZ, Tian SH. Transformer and GAN-based super-resolution reconstruction network for medical images[J]. *Tsinghua Sci Technol*, 2024, 29(1): 197-206.
- [10] Levin A, Weiss Y, Durand F, et al. Understanding and evaluating blind deconvolution algorithms[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2009: 1964-1971.
- [11] Zhang K, Li YW, Zuo WM, et al. Plug-and-play image restoration with deep denoiser prior[J]. *IEEE Trans Pattern Anal Mach Intell*, 2022, 44(10): 6360-6376.
- [12] Wang ZD, Cun XD, Bao JM, et al. Uformer: a general U-shaped transformer for image restoration[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2022: 17662-17672.
- [13] Gu JJ, Lu HN, Zuo WM, et al. Blind super-resolution with iterative kernel correction[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2019: 1604-1613.
- [14] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. *Commun ACM*, 2020, 63(11): 139-144.
- [15] He KM, Chen XL, Xie SN, et al. Masked autoencoders are scalable vision learners[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2022: 15979-15988.
- [16] Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models[C]//Proceedings of the 34th International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2020: 6840-6851.
- [17] 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.
- [18] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017: 6000-6010.
- [19] Hu VT, Zhang DW, Asano YM, et al. Self-guided diffusion models[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2023: 18413-18422.
- [20] 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>.
- [21] Paszke A, Gross S, Massa F, et al. PyTorch: an imperative style, high-performance deep learning library [C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2019: 8026-8037.
- [22] Zhu XF, Thung KH, Adeli E, et al. Maximum mean discrepancy based multiple kernel learning for incomplete multimodality neuroimaging data [C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2017. Cham: Springer International Publishing, 2017: 72-80.
- [23] Kupyn O, Martyniuk T, Wu JR, et al. DeblurlGAN-v2: deblurring (orders-of-magnitude) faster and better [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2019: 8877-8886.
- [24] Nah S, Kim TH, Lee KM. Deep multi-scale convolutional neural network for dynamic scene deblurring[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 257-265.
- [25] Chung H, Kim J, Kim S, et al. Parallel diffusion models of operator and image for blind inverse problems [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2023: 6059-6069.

(编辑:陈丽霞)