基于生成对抗网络和域一致性的 MRI 运动伪影校正方法

曾宪华*, 纪聪辉, 董倩

重庆邮电大学图像认知重庆市重点实验室, 重庆 400065

* 通信作者. E-mail: zengxh@cqupt.edu.cn

收稿日期: 2021-04-02; 修回日期: 2021-06-23; 接受日期: 2021-07-12; 网络出版日期: 2022-05-11

国家自然科学基金 (批准号: 62076044)、重庆市自然科学基金重点项目 (批准号: cstc2019jcyj-zdxmX0011) 和重庆市研究生科研创新项目 (批准号: CYS21308) 资助

摘要 在临床诊断中, 磁共振成像 (magnetic resonance imaging, MRI) 运动伪影是一个常见的问题, 运动伪影的存在会影响医生的诊断, 虽然重新采集 MRI 可以避免这一问题, 但这会提高医院和患者的经济成本和时间成本, 因此, 运动伪影的校正具备实用研究价值. 现有的研究主要关注于空域的运动伪影校正或者 K 空间的运动伪影校正, 缺乏对 K 空间和空域之间数据一致性的保持. 为了解决这一问题, 本文基于生成对抗网络提出了保持 K 空间和空域之间数据一致性的 MRI 运动伪影校正模型. 该模型通过频域生成器对 K 空间数据进行初步校正, 然后通过空域生成器对空域中的数据进行精细校正, 在优化阶段则采用域间数据一致性损失来保持 K 空间和空域之间的数据一致性. 在公开脑部 MRI 数据集 ADNI, ABIDE, OASIS 和 Brain 上的实验结果表明, 本文提出的模型相较于其他方法分别在 PSNR, SSIM 以及 RMSE 上最高提升了 3.4%, 3.07% 和 15.57%.

关键词 运动伪影校正, 生成对抗网络, 数据一致性, 深度学习, 医学图像

1 引言

运动伪影一直是磁共振成像中的一个常见问题, 其产生会影响医生的诊断. 轻微的运动伪影可能只会产生一些噪声, 但严重的运动伪影可能会导致患者在成像图片上的生理结构发生改变. 当然, 重新采集可能得到无运动伪影的 MRI, 但也会带来额外的时间成本和金钱成本^[1]. 目前, 运动伪影校正方法主要包括前瞻性校正和回溯性校正^[2]. 前瞻性校正^[3~5]通常需要额外的设备获取实时信息来校正运动伪影, 例如通过导航器、相邻采集序列或其他信息的反馈调整磁共振采集的参数以保持采集数据和患者之间的相对静止. 而为了与磁共振采集过程兼容^[2], 通常需对导航器坐标进行精确校准, 导航器采样速度也要尽可能快. 因此, 相较于无导航器的回溯性校正方法, 前瞻性校正方法需要更多时

引用格式: 曾宪华, 纪聪辉, 董倩. 基于生成对抗网络和域一致性的 MRI 运动伪影校正方法. 中国科学: 信息科学, 2022, 52: 822–836, doi: 10.1360/SSI-2021-0114
Zeng X H, Ji C H, Dong Q. Motion artifact correction of MRI based on a generative adversarial network and domain consistency (in Chinese). Sci Sin Inform, 2022, 52: 822–836, doi: 10.1360/SSI-2021-0114

间来生成 MRI. 此外, 大多数前瞻性校正方法要求导航器的跟踪装置安装在患者身体上, 这也给患者带来了一些不适^[6].

回溯性校正^[7~10]不需要对患者进行物理约束和额外的检查时间, 因此能给患者带来最好的检查体验. 为了去除 MRI 中的运动伪影, Loktyushin 等^[7]提出一种迭代搜索运动轨迹的方法, 采用空间梯度熵来优化模型, 生成了较为清晰的图像. Cheng 等^[8]通过最小化局部梯度熵度量实现了一个自动聚焦算法. 此外, 为了在估计运动参数时限制搜索空间的大小, 他们还在数据采集的过程中对运动进行监测. Samsonov 等^[9]提出了一种新的基于迭代的方法来进行运动伪影的去除, 该方法不会受限于运动模型的构建, 在任意运动模型中都能较好地运动伪影进行校正. Jang 等^[10]提出了基于 FBP 的运动补偿重建模型用于头部运动伪影去除, 使用迭代非线性优化算法和 L-BFGS 估算头部运动参数, 并根据估计的运动参数实现图像的迭代重建. 可以看到, 传统的运动伪影校正方法都需要迭代地搜索运动轨迹或者直接对图像进行迭代优化, 这会耗费大量的计算时间和计算资源, 所以很难适用于大规模的运动伪影校正.

为了应对上述缺陷, 研究人员开始关注基于深度学习的 MRI 运动伪影回溯校正模型. 深度学习模型能够实现端到端的训练, 且测试时间相较于传统回溯校正方法较快, 尤其是近年来生成对抗网络^[11]的快速发展, 图像修复领域已取得了极大的进展. 但是当前基于深度学习的 MRI 运动伪影校正方法往往只针对 K 空间或者空域中的数据进行优化, 未考虑到 K 空间和空域之间的数据一致性, 这使得运动校正后的 MRI 在不同的空间中不能够保证数据一致性, 也就无法保证模型结果的可靠性.

为了解决上述问题, 本文提出了一种多域级联的 MRI 运动伪影校正模型. 该模型同时对 K 空间和空域中的数据进行运动伪影校正, 并且通过域间数据一致性损失保持 K 空间和空域之间的数据一致性. 模型整体框架采用生成对抗网络, 生成器采用了带有跳层连接^[12]和残差块^[13]的卷积神经网络, 判别器则采用了带有梯度惩罚项的 Wasserstein-1 距离^[14]进行优化. 本文使用了公开数据集 ADNI¹⁾, ABIDE²⁾, OASIS³⁾ 和 Brain⁴⁾ 对模型进行评估, 并且通过下文实验可知, 本文所提出的模型在客观评价指标和主观评价上都具备一定的优势.

本文作出的主要贡献如下:

(1) 提出了一种多域级联生成器: 通过频域生成器进行运动伪影的初步校正, 通过空域生成器进行运动伪影的精细校正.

(2) 通过域一致性损失保持 K 空间和空域之间的数据一致性.

(3) 和目前的最新方法相比, 本文提出的模型在客观评价指标上达到了最佳效果.

本文的组织如下: 第 2 节介绍有关生成对抗网络和 MRI 运动伪影校正的相关工作, 第 3 节介绍本文提出的 MRI 运动伪影校正模型, 并给出详细的训练算法, 第 4 节描述实验数据集、实验中的细节以及对实验结果的分析, 第 5 节对全文进行总结和展望.

2 相关工作

2.1 生成对抗网络

生成对抗网络 (GAN) 是一种基于博弈论的深度学习框架, 由生成器和判别器组成, 通过对抗来学

1) <http://adni.loni.usc.edu>.

2) http://fcon_1000.projects.nitrc.org/indi/abide.

3) <https://www.oasis-brains.org>.

4) <http://www.med.harvard.edu/AANLIB>.

习数据集的样本分布. 生成器通过接收随机噪声生成可迷惑判别器的假样本, 判别器则试图区分真假样本.

原始的 GAN 训练过程不稳定, 容易出现梯度消失、梯度爆炸、模式坍塌等问题. Arjovsky 等^[15]认为这是 JS 散度 (Jensen-Shannon divergence) 不能回传梯度, 以及 KL 散度的优化方向与 JS 散度相反造成的, 因此他们提出了 WGAN, 采用推土机 (earth-mover distance) 距离代替 JS 散度来计算生成样本分布和真实样本分布间的距离, 并通过权重裁剪使判别器满足 Lipschitz 连续. 改进后的 WGAN 解决了 GAN 训练时梯度不稳定的问题, 同时也初步解决了模式坍塌的问题, 并且在训练过程中也不需要精心设计生成器和判别器之间的迭代平衡策略. WGAN 中的目标函数如式 (1) 所示:

$$\min_G \max_D V(D, G) = \mathbb{E}_{\tilde{x} \sim \mathbb{P}_g} [D(\tilde{x})] - \mathbb{E}_{x \sim \mathbb{P}_r} [D(x)], \quad (1)$$

其中, $\tilde{x} = G(z)$, z 是输入生成器的随机噪声, $\mathbb{P}_g$ 是生成样本分布, $\mathbb{P}_r$ 是真实样本分布, D 是判别器.

在 WGAN 中, 通过权重裁剪实现了 Lipschitz 连续, 但是权重裁剪需要人工设置权重裁剪的阈值, 如果阈值设置得不合适很容易造成梯度消失或者梯度爆炸, 因此 Gulrajani 等^[14]在 WGAN 的基础上引入了梯度惩罚项并提出 WGAN-GP. 如式 (2) 所示, WGAN-GP 中判别器的损失函数仅仅在 WGAN 的基础上增加了梯度惩罚项.

$$\min_G \max_D V(D, G) = \mathbb{E}_{\tilde{x} \sim \mathbb{P}_g} [D(\tilde{x})] + \mathbb{E}_{x \sim \mathbb{P}_r} [D(x)] + \lambda \mathbb{E}_{\hat{x} \sim \mathbb{P}_{\hat{x}}} \left[(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1)^2 \right], \quad (2)$$

其中, $\hat{x}$ 是生成样本和真实样本插值的结果, $\nabla_{\hat{x}} D(\hat{x})$ 是判别器输入为 $\hat{x}$ 时的梯度. 这一改进使得生成对抗网络稳定性得到了极大提升, 也促使生成对抗网络应用于不同领域, 如图像超分辨率^[16]、风格迁移^[17]、跨模态变换^[18, 19]、图像去模糊^[20]等. 基于此, 本文模型整体框架也选择使用 WGAN-GP.

2.2 基于深度学习的运动伪影校正

在基于深度学习的运动伪影校正方法中, Oksuz 等^[21]为了修复 MRI 心脏采集过程中由于采集设备心电图门控不正确导致的运动伪影, 提出了一种基于深度学习模型使用对抗训练直接从 K 空间数据重建 MRI 来校正运动伪影的方法, 在网络结构中引入了判别器以指导生成器的训练. Armanious 等^[22]提出了一种基于生成对抗网络的运动伪影去除框架, 同时对刚性伪影和非刚性伪影进行校正, 并通过一个深度特征提取器构造了额外的感知损失和风格损失以指导生成器的优化. Küstner 等^[23]分别基于变分自编码器和生成对抗网络提出了两种运动伪影去除模型, 并证明了生成对抗网络对于生成更加接近真实的无运动伪影图像的可行性. Usman 等^[24]提出了一种新的基于生成对抗网络的共轭梯度传感重建框架用于对多轴磁共振成像中的运动进行校正, 该方法首先使用共轭梯度传感技术从被运动破坏的 K 空间数据重建图像, 然后使用基于生成对抗网络的框架校正运动伪影, 并且在计算速度上取得了极大的提升. Duffy 等^[25]提出了一种基于生成对抗网络的运动伪影校正方法, 该方法通过卷积神经网络直接学习有运动伪影图像和无运动伪影图像间的映射关系, 并且 Duffy 等还探究了 L-1 损失和对抗损失对运动伪影校正模型的影响. Sommer 等^[26]使用多尺度全卷积神经网络进行 MRI 运动伪影校正, 该模型通过接收不同尺度的图像输入, 使用 3 个级联的卷积神经网络进行运动估计, 以最终得到的运动估计图进行运动伪影的校正.

上述方法都是通过 K 空间或者空域数据训练深度神经网络的, 但其模型产生的结果不能保证 K 空间和空域之间数据的一致性. 受此启发, 本文提出了基于生成对抗网络的多域融合 MRI 运动伪影校正模型, 以保持不同空间下的数据一致性, 从而提高运动伪影校正的性能和可靠性.

图 1 (网络版彩图) 基于生成对抗网络和域一致性保持的 MRI 运动伪影校正模型整体架构

Figure 1 (Color online) The overview of motion artifact correction model of MRI based on GAN and domain consistency

3 基于生成对抗网络和域一致性的 MRI 运动伪影校正模型

本文提出的基于生成对抗网络和域一致性的 MRI 运动伪影校正模型如图 1 所示. 该模型主要包括 3 个部分, 分别是生成器 Generator、判别器 Discriminator 和特征提取器 VGGM. 其中, 生成器 Generator 采用了级联的生成器结构, 其由频域生成器 G_f 、空域生成器 G_s 以及域转换层 DT layer 组成, 复卷积网络 G_f 对 K 空间数据进行运动伪影初步校正, 深度跳层残差网络 G_s 对空域数据进行运动伪影精细校正, 两者共同实现了由粗到细的跨域运动伪影校正, 判别器 Discriminator 采用了 WGAN-GP 中的判别器结构, VGGM 则是使用 MRI 数据集预训练的 VGG-19. 当输入为带有运动伪影的 MRI 图像 x 时, 整体生成器可通过式 (3) 表示:

$$G(\theta_G, x) = G_s(\theta_s, T'(G_f(\theta_f, T(x)))) \quad (3)$$

其中 $\theta_G = \theta_f + \theta_s$ 表示生成器 G 的参数, θ_f 表示频域生成器 G_f 的参数, θ_s 表示空域生成器 G_s 的参数, $T(\cdot)$ 和 $T'(\cdot)$ 分别代表对空域数据和 K 空间数据的转换, 它们是一个互逆的过程.

3.1 生成器网络设计

对于频域生成器 G_f , 本文采用了 DeepcomplexMRI 中相同的网络结构^[27], 其结构如图 2 所示.

本文引入的复卷积网络 G_f 是一个使用了复卷积核的卷积神经网络, 其输入是存在运动伪影的重构 K 空间数据 f_{c2r}^{ma} , 输出是去除运动伪影后的重构 K 空间数据 f_{c2r}^f . f_{c2r}^{ma} 的转换过程如式 (4) 所示:

$$f_{c2r}^{ma} = \text{concat}(f_{real}^{ma}, f_{imag}^{ma}) \quad (4)$$

图 2 (网络版彩图) 频域生成器模型结构

Figure 2 (Color online) The architecture of frequency domain generator

图 3 (网络版彩图) 空域生成器模型结构

Figure 3 (Color online) The architecture of spatial domain generator

其中 $f^{\text{ma}} = T(I^{\text{ma}})$, $f_{\text{real}}^{\text{ma}}$ 和 $f_{\text{imag}}^{\text{ma}}$ 分别代表了 f^{ma} 的实部和虚部, $\text{concat}(\cdot)$ 则在矩阵的最后一个维度上进行拼接.

复卷积核卷积的过程如式 (5) 所示:

$$\begin{aligned} K^* f^{\text{ma}} &= (K_{\text{real}} + jK_{\text{imag}}) (f_{\text{real}}^{\text{ma}} + jf_{\text{imag}}^{\text{ma}}) \\ &= (K_{\text{real}} * f_{\text{real}}^{\text{ma}} - K_{\text{imag}} * f_{\text{imag}}^{\text{ma}}) \\ &\quad + j(K_{\text{real}} * f_{\text{imag}}^{\text{ma}} + K_{\text{imag}} * f_{\text{real}}^{\text{ma}}), \end{aligned} \quad (5)$$

其中 $K = K_{\text{real}} + jK_{\text{imag}}$ 为复卷积核, $f^{\text{ma}} = f_{\text{real}}^{\text{ma}} + jf_{\text{imag}}^{\text{ma}}$ 为频域生成器第 1 层卷积层的输入. 通过这种复卷积方式, 初步保证了 K 空间中实部和虚部之间数据的相关性. 同时, 因为复卷积网络并不是真正地对复数矩阵卷积, 而是对复数矩阵重构的实数矩阵进行卷积, 所以神经网络可能无法准确学习到复数部分和虚数部分之间的关系, 因此复卷积网络的输入 $f_{\text{c2r}}^{\text{ma}}$ 在每个级联块之后都会与当前块的输出进行残差连接, 以强化实部和虚部之间的相关性. 每个级联块都是由一个复卷积网络和一个数据一致性层组成, 其中复卷积网络包括 5 层复卷积层, 每层都采用了 3×3 的复卷积核, 并且除最后一层外都使用 ReLU 激活函数进行激活, 并且每层的输出通道数均为 64, 在整个卷积网络中特征图的宽高均和输入数据的宽高保持一致. 数据一致性层中采用了残差连接的方式来使重构后的 K 空间数据和重构之前的 K 空间数据保持数据一致性.

对于空域生成器 G_s , 如图 3 所示, 除了第 1 层卷积层和最后一层卷积层之外, 还包括两个下采样模块、两个上采样模块和 9 个残差模块, 对于每个下采样模块, 其都包括一个卷积层、一个实例归一化层和一个 ReLU 激活函数. 对于上采样模块, 除了使用转置卷积层代替卷积层外, 其他结构均与下

采样模块相同. 下采样模块和上采样模块在网络结构上是对称的, 上采样模块通过跳层连接将高级特征和下采样模块的低级特征在数据的最后一维拼接起来. 与 U-Net 不同的是, 该模型不裁剪低级特征, 而是直接将其与高级特征拼接起来. 其中, 残差模块用于更好地提取图像的高级特征, 不会改变特征的维数, 且每个残差模块都由两个卷积层、两个实例归一化层和一个 ReLU 激活函数组成. 在网络的输入输出层还采用了全局残差连接, 这在图像修复任务中取得了很好的效果.

3.2 K 空间和空域之间数据一致性的保持

尽管使用了 G_f 和 G_s 两个模型分别对频域数据和空域数据进行由粗到细的运动伪影去除, 但是在模型优化的过程中采用串行的方式进行优化, 因此这两个生成器之间并不一定能够保持域间的数据一致性. 本文模型的提出是为了使频域和空域数据保持跨域数据一致性, 但是单独针对空域生成器的结果进行优化明显和这一目的相悖. 为了解决这一问题, 受 DoDuNet^[28] 启发, 本文引入了 Domain Transform 层, 通过该结构实现了由 G_f 和 G_s 组成的级联网络, 并且通过域间一致性损失保持了 K 空间和空域之间的数据一致性.

3.3 损失函数

在训练过程中, 本文所提的双级联生成器的损失函数如式 (6) 所示:

$$L_G = L_{G_s} + \alpha L_{G_f} + \beta L_{LO} + \gamma L_{Percept} + \lambda L_{DC} + \mu L_{Adv}. \quad (6)$$

生成器的总体损失 L_G 包括像素级损失和对抗损失. 其中像素级损失主要包括均方差损失 (mean square error, MSE)、平均绝对误差损失 (mean absolute error, MAE) 和感知损失. 对抗损失则和 WGAN-GP 中提出的对抗损失一致. 在本文的实验中, 超参数 $\alpha, \beta, \gamma, \lambda, \mu$ 分别设置为 1, 1, 1×10^{-6} , 1 和 1×10^{-3} .

目前, 许多图像处理任务都通过对抗训练取得了很好的效果. 本文提出的模型通过对抗损失约束生成器生成无运动伪影的图像, 并使判别器无法正确区分无运动伪影的图像与真实图像. 对抗性损失的定义如式 (7) 所示:

$$L_{Adv} = - \sum_{n=1}^N D(G(I_n^{ma})), \quad (7)$$

其中 I_n^{ma} 表示输入生成器的原始 MRI 图像, G 和 D 分别表示整体生成器和判别器.

内容损失在图像处理任务中更为常见, 特别是对于条件生成对抗网络 (cGAN), 它可以带来很大的改进, 因此, 使用配对数据集进行训练是一种常用的方法. 基于图像像素的 MSE, MAE 损失和感知损失都是内容损失, MSE 损失因其对离群点不敏感, 训练过程较为稳定的特性而广为使用, 但对于图像增强任务, MSE 会使生成的图像变得模糊或者对比度异常. Johnson 等^[29] 证实, 与 MSE 损失相比, 感知损失可以产生更清晰的图像. 但在本文的实验中, 感知损失并不能够使模型获得比 MSE 损失更好的性能, 通过把这两个损失结合起来, 反而能够得到更优的结果, 所以本文提出的模型在训练过程中使用了感知损失来进一步校正 MRI 中的运动伪影. 感知损失的定义如式 (8) 所示:

$$L_{Percept} = \frac{1}{C_i W_i H_i} \sum_{n=1}^N \sum_{x=1}^{W_i} \sum_{y=1}^{H_i} \sum_{z=1}^{C_i} \left\| \varphi_i(I_n^o)_{x,y,z} - \varphi_i(G(I_n^{ma}))_{x,y,z} \right\|_F^2, \quad (8)$$

其中, N 表示图像的个数, I_n^o 是没有运动伪影的标签图像, C_i, W_i 和 H_i 分别是 VGGM 的第 i 层输出特征图的通道数、宽度和高度. φ_i 是 VGGM 的第 i 层及其之前的所有网络层, x, y 和 z 分别代表特征图中的坐标点. VGGM 是一个只用于特征提取的基于 VGG-19 的预训练模型.

L_{G_f} 表示频域生成器的重建损失, 本文采用输入和输出之间的平均绝对误差来计算. L_{G_s} 表示空域生成器的重建损失. L_{G_f} 和 L_{G_s} 的定义如式 (9) 所示.

$$\begin{aligned} L_{G_f} &= \sum_{n=1}^N \|G_f(\theta_f, T(I_n^{\text{ma}})) - T(I_n^o)\|_1, \\ L_{G_s} &= \sum_{n=1}^N \|G_s(\theta_s, T'(G_f(\theta_f, T(I_n^{\text{ma}})))) - I_n^o\|_F^2, \end{aligned} \quad (9)$$

其中, 空域生成器的损失 L_{G_s} 计算的是生成去伪影图像 I_n^f 和真实标签图像 I_n^o 间的像素均方误差.

为了保持频域数据和空域数据之间的数据一致性, 本文引入了域间一致性损失 L_{DC} . 域间一致性损失的定义如下:

$$L_{\text{DC}} = \sum_{n=1}^N \|T'(f_n^f) - I_n^o\|_F^2, \quad (10)$$

其中 f_n^f 是频域生成器修复后的 K 空间数据.

本文所使用的局部优化损失在所有的空域数据之间构造, 该损失能够约束模型保持生成样本和真实样本之间的局部数据一致性, 其定义如式 (11) 所示.

$$\begin{aligned} L_{\text{LO}} &= \sum_{n=1}^N \|(T'(f_n^f) - I_n^o) \otimes \text{kernel}\|_F^2 \\ &\quad + \sum_{n=1}^N \|(G_s(\theta_s, T'(G_f(\theta_f, T(I_n^{\text{ma}})))) - I_n^o) \otimes \text{kernel}\|_F^2, \end{aligned} \quad (11)$$

其中 kernel 被简单地设计成一个 3×3 的值为 1 的矩阵.

3.4 算法总结与分析

算法 1 详细介绍了模型的训练过程. 本模型训练完之后直接将带有运动伪影的 MRI 通过 DT 层转换之后即可输入到生成器 G 中进行测试.

为了定量分析本文提出的模型, 本小节还计算了测试阶段百万浮点运算量 (MFLOPs) 和模型的参数量以评估模型的计算效率和空间占比. 其中 MFLOPS 达到了 25.77, 参数量为 13016391.

4 实验结果与分析

为了验证本文方法的有效性, 本节在 4 个公开数据集中对比了不同方法之间的结果. 本节首先介绍了实验中所使用的数据集, 其次介绍了运动伪影数据集获取的具体方法, 然后介绍了实验中的一些具体细节、对比方法以及采用的评价指标, 通过主观观察和客观评价指标详细比较了本文所提出的方法与当前最好方法的结果, 最后通过消融实验证明了模型不同模块的有效性.

4.1 数据集

阿尔茨海默病 (alzheimer disease, AD) 神经影像学倡议 (ADNI) 包括 MRI 和 PET 图像, 它包括 4 个子数据集, 分别是 ADNI 1, ADNI 2, ADNI 3 和 ADNI GO. 本文实验选择了协议描述为 “MP-RAGE” 的图像作为原始数据集, 它包括 1167 个用于训练的 MRI 和 300 个用于测试的 MRI.

算法 1 MRI motion artifact correction model training algorithm based on GAN and domain consistency

Input: $\{(I_n^{\text{ma}}, I_n^o)\}_{n=1}^N \in \text{Set}$;

Main iteration: $I^f = G(\theta_G, I^{\text{ma}}) = G_s(\theta_s, T'(G_f(\theta_f, T(I^{\text{ma}}))))$;

- 1: **repeat**
- 2: **for all** $(I_n^{\text{ma}}, I_n^o) \in \text{Set}$ **do**
- 3: $f_n^{\text{ma}} \leftarrow T(I_n^{\text{ma}})$ {Transfer data from the spatial domain to K-space};
- 4: $f_{n_{c2r}}^{\text{ma}} \leftarrow \text{concat}(f_{n_{\text{real}}}^{\text{ma}}, f_{n_{\text{imag}}}^{\text{ma}})$ {Reconstruct complex number data in the K-space};
- 5: $f_{n_{c2r}}^f \leftarrow G_f(\theta_f, f_{n_{c2r}}^{\text{ma}})$ {Input the reconstructed data into the frequency domain generator};
- 6: $I_n^f \leftarrow G_s(\theta_s, T'(f_{n_{c2r}}^f))$ {Input the result of the frequency domain generator into the spatial domain generator};
- 7: $\hat{x} \leftarrow \epsilon I_n^o + (1 - \epsilon) I_n^f$ {Compute the interpolation between the final repair image and the label image};
- 8: $GP \leftarrow (\|\nabla_{\hat{x}} D_{\theta_D}(\hat{x})\|_2 - 1)^2$ {Compute the gradient penalty};
- 9: $L_{D_{\theta_D}} \leftarrow D_{\theta_D}(I_n^f) - D_{\theta_D}(I_n^o) + \alpha GP$ {Compute the loss of generator D };
- 10: $\theta_D \leftarrow \theta_D - \lambda \frac{\partial}{\partial \theta_D} L_D$ {Use Adam optimizer to update the parameters of D };
- 11: **for** $i=1$ to i **do**
- 12: $f_{n_{c2r}}^f \leftarrow G_f(\theta_f, f_{n_{c2r}}^{\text{ma}})$ {Input the reconstructed data into the frequency domain generator};
- 13: $I_n^f \leftarrow G_s(\theta_s, T'(f_{n_{c2r}}^f))$ {Input the result of the frequency domain generator into the spatial domain generator};
- 14: $L_{G_f} \leftarrow \sum_{n=1}^N \|G_f(\theta_f, T(I_n^{\text{ma}})) - T(I_n^o)\|_1$ {Compute the loss of the frequency domain generator G_f };
- 15: $L_{G_s} \leftarrow \sum_{n=1}^N \|G_s(\theta_s, T'(G_f(\theta_f, T(I_n^{\text{ma}})))) - I_n^o\|_F^2$ {Compute the loss of the spatial domain generator G_s };
- 16: $L_{\text{DC}} \leftarrow \sum_{n=1}^N \|T'(f_n^f) - I_n^o\|_F^2$ {Compute the data consistency loss between the K-space and the spatial domain};
- 17: $L_{\text{LO}} \leftarrow \sum_{n=1}^N \|(G_s(\theta_s, T'(G_f(\theta_f, T(I_n^{\text{ma}})))) - I_n^o) \otimes \text{kernel}\|_F^2 + \sum_{n=1}^N \|(T'(f_n^f) - I_n^o) \otimes \text{kernel}\|_F^2$ {Compute the local consistency loss};
- 18: $L_{\text{Percept}} \leftarrow \frac{1}{C_i W_i H_i} \sum_{n=1}^N \sum_{x=1}^{W_i} \sum_{y=1}^{H_i} \sum_{z=1}^{C_i} \|\varphi_i(I_n^o)_{x,y,z} - \varphi_i(G(I_n^{\text{ma}}))_{x,y,z}\|_F^2$ {Compute the perceptual loss};
- 19: $L_G \leftarrow L_{G_s} + \alpha L_{G_f} + \beta L_{\text{LO}} + \gamma L_{\text{Percept}} + \lambda L_{\text{DC}} - \mu \sum_{n=1}^N D_{\theta_D}(G_{\theta_G}(I_n^{\text{ma}}))$ {Compute the overall loss of generator G };
- 20: $\theta_G \leftarrow \theta_G - \lambda \frac{\partial}{\partial \theta_G} L_G$ {Use Adam optimizer to update the parameters of G };
- 21: **end for**
- 22: **end for**
- 23: **until** epoch = T ;

Output: θ_G ;

自闭症脑成像数据交换 (ABIDE) 是一个自闭症脑成像数据集, 主要用于研究儿童自闭症的早期诊断, 其包括 539 例 ASD 和 573 例正常对照组. 通过对数据集的观察和对图像质量控制指标的数值比较, 本小节从总数据集中选取了无运动伪影的图像作为训练集和测试集.

开放获取成像研究 (OASIS) 是一个旨在使科学界免费获得大脑神经成像数据集的项目, 已被用于假设驱动的数据分析、神经解剖学图谱的开发和分割算法的开发, 它包含 3 个不同的部分以应用于不同的任务. OASIS-1 由 416 个年龄在 18 ~ 96 岁之间的受试者的核磁共振图像组成. 对于每个受试者, 在数据集中都有单次扫描中获得的 3 ~ 4 个单独的 T1 加权 MRI 扫描, 受试者都是右撇子, 包括男性和女性, 其中 100 名年龄在 60 岁以上的受试者被临床诊断为极轻度至中度阿尔茨海默病.

Brain 是一个开放的大脑数据集, 该数据集中包含了正常大脑、脑血管疾病、肿瘤疾病、退行性疾病、炎症和传染性疾病的数据, 每个数据都是成对的 PET, SPECT, MRI 和 CT 扫描图像, 每个图像都有多张切片, 本文中使用了 33 名患者的 T1-MRI 切片数据.

4.2 运动伪影仿真

由于医学图像运动伪影数据的采集比较困难, 因此, 本文使用 Medley 等^[30]提出的方法, 通过破坏与图片对应的 K 空间数据模拟 MRI 中的运动伪影. 这种方法产生的运动伪影在临床检测中较为常

见, 其原理如下所示:

$$s'(k_x, k_y) = e^{-i\phi(k_x, k_y)} s(k_x, k_y), \quad (12)$$

其中 $s(k_x, k_y)$ 是原始的无运动伪影的 K 空间数据, $s'(k_x, k_y)$ 则是 K 空间被破坏后的带有运动伪影的 K 空间数据. k_x 和 k_y 分别代表不同相位编码方向上的 K 空间坐标. 其中 $\phi(k_x, k_y)$ 如下所示:

$$\phi(k_x, k_y) = 2\pi[k_x p(k_y) + k_y q(k_y)]. \quad (13)$$

其中, $p(k_y)$ 和 $q(k_y)$ 分别代表不同相移方向的运动函数.

在本文实验中, 仿真的运动伪影图像通过式 (14) 中参数获得.

$$p(k_y) = 1.4 \cos\left(\frac{\pi k_y}{5}\right), \quad q(k_y) = 1.4 \sin\left(\frac{\pi k_y}{5}\right). \quad (14)$$

4.3 实验配置

本文提出的模型是基于 tensorflow 深度学习框架实现的. 为保证实验的公平性和可靠性, 本文的所有实验在同一台服务器上进行, GPU 采用一张 tesla v100-sxm2gpu, 每次实验采用相同的初始化方案 10 次, 并对结果去除敏感值后得到其平均值. 由于不同数据集的尺寸不同, 在训练前会将其大小统一裁剪为 256×256 . 另外, 判别器卷积层之后使用了实例归一化, 因此模型的批样本数输入必须是 1. 在下采样模块后有 9 个残差模块, 每个残差模块的输入和输出总是保持相同的维数, 每个残差模块都包括两个卷积层、两个实例归一化层和 1 个 ReLU 激活函数. 上采样模块与下采样模块相反, 但在上采样模块, 跳层连接要求在上采样操作之前将低级特征和高级特征在最后一维拼接起来. 需要注意的是, 神经网络的输入和输出是残差连接, 残差连接是值的和, 而跳层连接是维数的串联. 另外, 在本文提出的模型中, 不需要在跳层连接中裁剪低级特征图. 最后的卷积层^[31]会将特征映射为输入的原始维数, 并使用 Tanh 激活函数进行激活.

验证所提出模型的优越性, FSGAN 模型将与以下 3 种不同主流网络结构的模型进行比较:

- (1) Pix2pix^[17] 是一种经典生成对抗网络, 它采用 U-Net 作为生成器.
- (2) SRN-Net^[32] 是一种由粗到细的 CNN, 它也用于自然图像去模糊.
- (3) DeepcomplexMRI^[27] 是一种用于 MRI 重建的复卷积网络, 它在目前 MRI 图像重建任务中达到了最优的结果. 本文采用的频域生成器即为 DeepcomplexMRI.

评价方式主要采用峰值信噪比 (root mean square error, PSNR)、结构相似性 (structural similarity, SSIM) 和均方根误差 (peak signal to noise ratio, RMSE). 其中 PSNR 和 SSIM 越大, RMSE 越小, 就说明两张图像的相似度越高.

4.4 医学运动伪影去除结果分析

为了更好地观察实验结果的细节, 如图 4 ~ 7 所示, 图中放大了被观察区域. 第 1 行图像的像素大小为 256×256 , 第 2 行图像是第 1 行的局部放大图像, 红色方框所标注的区域是重点观察区域. 按列从左到右依次是运动伪影图像 (Motion-Artifact)、Pix2pix 结果图像、SRN 结果图像、DeepcomplexMRI (DC-MRI) 结果图像、FSGAN-base 结果图像、FSGAN 结果图像和原始标签图像 (Original). 其中, FSGAN-base 是去除 FSGAN 中频域生成器后的模型, 其可以单独通过空域数据进行运动伪影的校正, 而 DC-MRI 则是单独通过频域进行运动伪影校正的.

本文首先在 ADNI 中训练总体模型. 如图 4 中第 2 行图片所示, 不同模型的结果纹理信息存在差异. Pix2pix 的结果在所有对比模型中, 图像纹理最为杂乱; 第 2 行图片中红色方框标注的区域

图 4 (网络版彩图) ADNI 数据集上的测试结果

Figure 4 (Color online) Testing results in ADNI

图 5 (网络版彩图) ABIDE 数据集上的测试结果

Figure 5 (Color online) Testing results in ABIDE

表明, SRN 的结果在该部分丢失了部分低像素值的纹理, 像素对比度更低, 这在 Original 中对应位置则表现为高对比度的图像纹理; DC-MRI 的结果则在红色方框标注区域残留了一定的运动伪影, 其相较于 Original 对应区域表现为像素值较低且出现不存在的图像纹理; FSGAN-base 和 FSGAN 的结果则与原始图像的外观最为相似. 但是从 FSGAN-base 中标注部分可以观察到, 与 Original 对比, FSGAN-base 的轮廓信息更加模糊, 对比度也更低. 而 FSGAN 与标签图像 Original 不存在明显的差异.

ABIDE 的结果如图 5 所示. 对于 Pix2pix, 虽然整体视觉上区别不明显, 但是可以看到标注部分的纹理结构信息相较于 Original 有较为明显的差异; 对于 SRN, 标注区域相较于原图可以观察到明显的运动伪影残留; 对于 DC-MRI, 其在标注区域具备较高的对比度, 而这和 Original 的对应区域中较低的对比度存在明显差别; FSGAN-base 在两处标注区域同样和 Original 存在一定的差别, 左侧标注区域存在和 SRN 同样的伪影残留, 右侧标注区域的图像纹理相较于 Original 过度平滑, 而 FSGAN 的结果和标签图像 Original 没有明显差别.

如图 6 所示, OASIS 中的实验结果很容易观察到不同模型结果的差异. Pix2pix 的结果纹理粗糙, 与 Original 差距较大; SRN 中标注区域的图像轮廓信息模糊, 无法清晰观察到边界信息; DC-MRI 中

图 6 (网络版彩图) OASIS 数据集上的测试结果

Figure 6 (Color online) Testing results in OASIS

图 7 (网络版彩图) Brain 数据集上的测试结果

Figure 7 (Color online) Testing results in Brain

的标注区域则出现了伪影残留, 即图像纹理相较于 Original 较暗且具备一定的结构信息, 而 Original 在对应部分的图像纹理则是连续平滑的; FSGAN-base 在标注区域同样存在过度平滑的问题, 图像的轮廓信息相较于 Original 较为模糊; FSGAN 的结果与 Original 同样没有明显区别。

图 7 展示了在 Brain 数据集上的运动伪影去除测试结果. 可以看到运动伪影造成图像上出现了不存在的黑色条形纹理. 从结果中可以清楚地观察到, Pix2pix, SRN, DC-MRI 和 FSGAN-base 中的标注区域仍然残留了明显的运动伪影, 而 FSGAN 仍然和标签图像 Original 保持了较高的相似度。

上述实验结果表明, 本文所提出的 FSGAN 模型相较于 DC-MRI 和 FSGAN-base 在图像纹理处理方面具有更加优秀的性能, 校正运动伪影后的图像和原图在图像细节和对比度上有极高的相似度, 可见 K 空间数据对空域生成器的运动伪影去除具有一定的辅助作用. 另外, 通过观察实验结果中 MRI 的颅脑边缘部分可以看出, 相较于 DC-MRI, FSGAN 在维持较高结构相似性的同时, 对于图像的噪声也有一定的平滑能力, 校正运动伪影后的 MRI 具备更低的噪声水平。

4.5 客观评价指标分析

在 4.4 小节的实验结果中, 我们认为在主观观察上 FSGAN 在对比方法中取得了最优的结果, 为更加直观准确地衡量不同模型的具体性能, 本文采用了客观评价指标 PSNR, SSIM 和 RMSE 对每个模型进行评价分析. 实验在相同条件下对所有模型都进行 10 次训练和测试, 并计算客观评价指标的平均值和标准偏差. 客观评价指标结果如表 1 和 2 所示, 表中分别对比了 Pix2pix, SRN, DC-MRI,

表 1 不同模型在 ADNI 和 ABIDE 上的客观评价指标结果

Table 1 Results on objective evaluation metrics of different models on ADNI and ABIDE

Method	ADNI			ABIDE		
	PSNR	SSIM	RMSE	PSNR	SSIM	RMSE
Pix2pix	32.977±0.050	0.937±0.001	5.888±0.051	33.726±0.287	0.949±0.002	5.352±0.174
SRN	33.449±0.208	0.942±0.008	5.564±0.123	35.562±0.253	0.965±0.002	4.360±0.118
DC-MRI	35.110±0.047	0.946±0.001	4.647±0.026	37.564±0.109	0.959±0.001	3.499±0.044
FSGAN-base	34.768±0.110	0.962±0.002	4.781±0.057	36.781±0.039	0.974±0.001	3.785±0.018
FSGAN	36.303±0.057	0.975±0.001	4.017±0.026	38.428±0.095	0.980±0.001	3.137±0.038

表 2 不同模型在 OASIS 和 Brain 上的客观评价指标结果

Table 2 Results on objective evaluation metrics of different models on OASIS and Brain

Method	OASIS			Brain		
	PSNR	SSIM	RMSE	PSNR	SSIM	RMSE
Pix2pix	36.067±0.090	0.947±0.003	4.063±0.042	33.136±0.188	0.953±0.018	5.715±0.122
SRN	37.694±0.119	0.967±0.002	3.398±0.043	35.341±0.356	0.974±0.003	4.468±0.170
DC-MRI	39.510±0.058	0.967±0.001	2.806±0.019	37.939±0.048	0.974±0.001	3.326±0.019
FSGAN-base	39.166±0.054	0.976±0.001	2.878±0.014	36.654±0.025	0.983±0.001	3.841±0.007
FSGAN	40.845±0.104	0.983±0.001	2.369±0.027	38.520±0.053	0.989±0.001	3.080±0.019

表 3 FSGAN 相较于 DC-MRI 的性能提升对比

Table 3 Comparison of performance between FSGAN and DC-MRI

Dataset	PSNR (%)	SSIM (%)	RMSE (%)
ADNI	3.40	3.07	13.56
ABIDE	2.30	2.19	10.35
OASIS	3.38	1.65	15.57
Brain	1.53	1.54	7.40

FSGAN-base 和 FSGAN 在 ADNI, ABIDE, OASIS 和 Brain 上的测试结果, 可以看到 FSGAN 在 4 个数据集上的 3 个评价指标均取得了最优结果, 并且 DC-MRI 均取得了次优结果. 为了更加直观地对比 FSGAN 相较于次优结果的提升, 表 3 详细对比了 FSGAN 相较于次优模型 DC-MRI 的提升率. 可以看到, FSGAN 在 PSNR, SSIM 和 RMSE 上相较于目前的最优方法 DC-MRI 最高分别提升了 3.4%, 3.07% 和 15.57%. 尤其是在 ADNI 数据集上的实验, FSGAN 的性能提升更为明显.

通过主观观察和客观评价指标的评估, 可以确定本文提出的 FSGAN 确实保证了校正后的 MRI 和原图的相似性, 使其具备更加真实的纹理和结构信息, 并且 PSNR 的提升也证实了 4.4 小节中的结论: FSGAN 对图像噪声有一定的平滑作用, 能够降低图像的噪声水平.

4.6 消融实验

本小节在 ABIDE 数据集上对我们提出的 FSGAN 进行了详细的消融实验以验证 FSGAN 中不同模块的有效性. 实验配置与上文中所描述的一致.

损失函数: 在 FSGAN 中, 我们引入了几种不同的损失函数对模型进行优化. 频域生成器损失和

表 4 损失函数的消融实验
Table 4 Ablation study of loss functions

Method	L_{G_f}	L_{G_s}	L_{DC}	L_{LO}	$L_{Percept}$	L_D	PSNR	SSIM	RMSE
FSGAN-f	✗	✓	✓	✓	✓	✓	37.039±0.539	0.971±0.006	3.702±0.239
FSGAN-s	✓	✗	✓	✓	✓	✓	36.579±0.205	0.958±0.002	3.856±0.110
FSGAN-dc	✓	✓	✗	✓	✓	✓	37.433±0.599	0.973±0.004	3.546±0.232
FSGAN-lo	✓	✓	✓	✗	✓	✓	36.778±0.043	0.959±0.016	3.811±0.011
FSGAN-p	✓	✓	✓	✓	✗	✓	38.141±0.095	0.980±0.001	3.244±0.038
FSGAN-d	✓	✓	✓	✓	✓	✗	37.871±0.095	0.979±0.001	3.316±0.030
FSGAN	✓	✓	✓	✓	✓	✓	38.428±0.095	0.980±0.001	3.137±0.038

表 5 FSGAN 中生成器结构的消融实验
Table 5 Ablation study of generator structures in FSGAN

Model in FSGAN		PSNR	SSIM	RMSE
G_f	G_s			
✓	✗	37.445±0.084	0.956±0.003	3.557±0.036
✗	✓	36.781±0.039	0.974±0.001	3.785±0.018
✓	✓	38.428±0.095	0.980±0.001	3.137±0.038

空域生成器损失作为重建损失指导生成器去除运动伪影, 同时, 域间一致性损失、局部一致性损失、感知损失以及对抗损失则进一步提高了去除运动伪影后的图像质量. 为了验证不同损失对 FSGAN 性能造成的影响, 我们首先对 FSGAN 中使用到的 6 种损失函数进行了消融实验. 如表 4 所示, 在同时使用所有损失函数时, 实验的客观评价指标达到最佳, 这证明了我们所提出模型各个模块的有效性.

模型结构: 进一步地, 为了验证频域生成器 G_f 和空域生成器 G_s 对 FSGAN 性能的影响, 我们对这两者进行了消融实验. 如表 5 所示, 我们分别对比了 G_f , G_s 和 $G_f + G_s$ 这 3 种生成器组合下的实验结果. 可以看到, 级联的生成器结构对运动伪影去除的结果起到了积极的作用, 因此客观评价指标取得了较大的提升.

5 总结

本文实现了一个 MRI 运动伪影回溯性校正方法. 针对目前基于深度学习的方法只对 K 空间或者空域数据进行运动伪影去除, 忽略了域间数据一致性的保持, 本文提出了一个级联生成器对抗网络, 分别通过频域生成器和空域生成器对 K 空间数据和空域数据进行运动伪影校正, 并且通过域间一致性损失保持 K 空间和空域之间的数据一致性, 实现了更高精度的 MRI 运动伪影校正. 在 4 个公开数据集 ADNI, ABIDE, OASIS 和 Brain 上的实验结果表明, 本文提出的方法相较于目前的最优方法具备更高的图像观测质量以及客观评价指标.

参考文献

1 Godenschweger F, Kägebein U, Stucht D, et al. Motion correction in MRI of the brain. Phys Med Biol, 2016, 61: 32–56

- 2 Zaitsev M, Maclaren J, Herbst M. Motion artifacts in MRI: a complex problem with many partial solutions. *J Magn Reson Imag*, 2015, 42: 887–901
- 3 van der Kouwe A J W, Benner T, Dale A M. Real-time rigid body motion correction and shimming using cloverleaf navigators. *Magn Reson Med*, 2006, 56: 1019–1032
- 4 Feinberg D A, Giese D, Bongers D A, et al. Hybrid ultrasound MRI for improved cardiac imaging and real-time respiration control. *Magn Reson Med*, 2010, 63: 290–296
- 5 Schulz J, Siegert T, Reimer E, et al. An embedded optical tracking system for motion-corrected magnetic resonance imaging at 7T. *Magn Reson Mater Phy*, 2012, 25: 443–453
- 6 Maclaren J, Herbst M, Speck O, et al. Prospective motion correction in brain imaging: a review. *Magn Reson Med*, 2013, 69: 621–636
- 7 Loktyushin A, Nickisch H, Pohmann R, et al. Blind retrospective motion correction of MR images. *Magn Reson Med*, 2013, 70: 1608–1618
- 8 Cheng J Y, Alley M T, Cunningham C H, et al. Nonrigid motion correction in 3D using autofocusing with localized linear translations. *Magn Reson Med*, 2012, 68: 1785–1797
- 9 Samsonov A A, Velikina J, Jung Y, et al. POCS-enhanced correction of motion artifacts in parallel MRI. *Magn Reson Med*, 2010, 63: 1104–1110
- 10 Jang S, Kim S, Kim M, et al. Head motion correction based on filtered backprojection in helical CT scanning. *IEEE Trans Med Imag*, 2020, 39: 1636–1645
- 11 Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets. In: *Proceedings of Advances in Neural Information Processing Systems*, Montreal, 2014. 2672–2680
- 12 Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation. In: *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*, Munich, 2015. 234–241
- 13 He K, Zhang X, Ren S, et al. Deep residual learning for image recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 2016. 770–778
- 14 Gulrajani I, Ahmed F, Arjovsky M, et al. Improved training of wasserstein GANs. In: *Proceedings of Advances in Neural Information Processing Systems*, Long Beach, 2017. 5769–5779
- 15 Arjovsky M, Chintala S, Bottou L. Wasserstein GAN. In: *Proceedings of the International Conference on Machine Learning*, Sydney, 2017. 214–223
- 16 Ledig C, Theis L, Huszar F, et al. Photo-realistic single image superresolution using a generative adversarial network. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 2017. 4681–4690
- 17 Isola P, Zhu J Y, Zhou T, et al. Image-to-image translation with conditional adversarial networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 2017. 1125–1134
- 18 Dai B, Fidler S, Urtasun R, et al. Towards diverse and natural image descriptions via a conditional GAN. In: *Proceedings of the IEEE International Conference on Computer Vision*, Venice, 2017. 2970–2979
- 19 Reed S, Akata Z, Yan X, et al. Generative adversarial text to image synthesis. In: *Proceedings of the International Conference on Machine Learning*, New York, 2016. 1060–1069
- 20 Kupyn O, Budzan V, Mykhailych M, et al. Deblurgan: blind motion deblurring using conditional adversarial networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake, 2018. 8183–8192
- 21 Oksuz I, Clough J, Bustin A, et al. Cardiac MR motion artefact correction from k-space using deep learning-based reconstruction. In: *Proceedings of the International Workshop on Machine Learning for Medical Image Reconstruction*, Granada, 2018. 21–29
- 22 Armanious K, Gatidis S, Nikolaou K, et al. Retrospective correction of rigid and non-rigid MR motion artifacts using GANs. In: *Proceedings of the IEEE International Symposium on Biomedical Imaging*, Venice, 2019. 1550–1554
- 23 Küstner T, Armanious K, Yang J, et al. Retrospective correction of motion-affected MR images using deep learning frameworks. *Magn Reson Med*, 2019, 82: 1527–1540
- 24 Usman M, Latif S, Asim M, et al. Retrospective motion correction in multishot MRI using generative adversarial network. *Sci Rep*, 2020, 10: 1–11
- 25 Duffy B A, Zhang W, Tang H, et al. Retrospective correction of motion artifact affected structural MRI images using deep learning of simulated motion. In: *Proceedings of Medical Imaging with Deep Learning*, Amsterdam, 2018

- 26 Sommer K, Saalbach A, Brosch T, et al. Correction of motion artifacts using a multiscale fully convolutional neural network. *Am J Neuroradiol*, 2020, 41: 416–423
- 27 Wang S, Cheng H, Ying L, et al. DeepcomplexMRI: exploiting deep residual network for fast parallel MR imaging with complex convolution. *Magn Reson Imag*, 2020, 68: 136–147
- 28 Lin W A, Liao H, Peng C, et al. Dudonet: dual domain network for CT metal artifact reduction. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Long Beach, 2019. 10512–10521
- 29 Johnson J, Alahi A, Li F-F. Perceptual losses for real-time style transfer and super-resolution. In: *Proceedings of the European Conference on Computer Vision*, Amsterdam, 2016. 694–711
- 30 Medley M, Yan H, Rosenfeld D. An improved algorithm for 2-D translational motion artifact correction. *IEEE Trans Med Imag*, 1991, 10: 548–553
- 31 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. In: *Proceedings of the International Conference on Learning Representations*, San Diego, 2015. 1–14
- 32 Tao X, Gao H, Shen X, et al. Scale-recurrent network for deep image deblurring. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake, 2018. 8174–8182

Motion artifact correction of MRI based on a generative adversarial network and domain consistency

Xianhua ZENG*, Conghui JI & Qian DONG

Chongqing Key Laboratory of Image Cognition, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

* Corresponding author. E-mail: zengxh@cqupt.edu.cn

Abstract In clinical diagnosis, magnetic resonance imaging (MRI) motion artifact is a common problem that will affect the doctor's diagnosis. Although the reacquisition of MRI can avoid this problem, it will bring extra economic and time cost to hospitals and patients. Therefore, the correction of motion artifacts has a practical research value. Existing studies mainly focus on correcting motion artifacts from the spatial domain or K-space, and ignore the data consistency between them. In order to solve this problem, a motion artifact correction model based on a generative adversarial network is proposed to maintain the data consistency between the K-space and spatial domain. In this model, K-space data are initially corrected by a frequency domain generator, and then spatial domain data are fine corrected by a spatial domain generator. In optimization phase, the data consistency loss between the K-space and spatial domain is used to maintain data consistency. In four public MRI datasets, ADNI, ABIDE, OASIS and Brain, the experimental results show that the performance of the proposed model has increased by 3.4%, 3.07% and 15.57% on PSNR, SSIM and RMSE, respectively.

Keywords motion artifact correction, generative adversarial network, data consistency, deep learning, medical image