基于自注意力机制生成对抗网络的超分辨率磁共振图像重建

蒋明峰^{1*}, 支明豪¹, 李杨¹, 李铁强², 张鞠成³

1. 浙江理工大学信息学院, 杭州 310018

2. 中国计量大学信息工程学院, 杭州 310018

3. 浙江大学医学院附属第二医院, 杭州 310019

* 通信作者. E-mail: m.jiang@zstu.edu.cn

收稿日期: 2020-04-21; 修回日期: 2020-06-09; 接受日期: 2020-06-24; 网络出版日期: 2021-05-11

国家自然科学基金 (批准号: 61672466, 620115300130)、浙江省自然科学基金 – 数理医学学会联合基金重点项目 (批准号: LSZ19F010001)、浙江省科技厅重点研发项目 (批准号: 2020C03060)、浙江省科技厅公益项目 (批准号: 2015C31075) 和浙江省自然科学基金项目 (批准号: LY18D060009) 资助

摘要 高分辨率的磁共振图像可以提供细粒度的解剖信息, 但是获取数据需要较长的扫描时间. 本文提出了一种基于自注意力机制生成对抗网络的超分辨率磁共振图像重构方法 (SA-SR-GAN), 利用生成对抗网络从低分辨率磁共振图像生成高分辨率磁共振图像, 将自注意力机制集成到超分辨率生成对抗网络框架中, 用于计算输入特征的权重参数, 同时引入了谱归一化处理, 使判别器网络训练过程更加稳定. 本文使用 40 组 3D 磁共振图像 (每组图像包含 256 个切片) 训练网络, 并用 10 组图像进行测试. 实验结果表明, 所提出的超分辨率自注意力生成对抗网络方法生成的超分辨率的磁共振图像的 PSNR 和 SSIM 值高于同类比较方法.

关键词 磁共振图像, 超分辨率, 生成对抗网络, 自注意力, 谱归一化

1 引言

高分辨率磁共振图像可提供细粒度的解剖信息, 从而有助于临床诊断和准确的决策制定. 但是, 它不仅需要昂贵的设备, 而且需要更长的扫描时间, 这给数据采集带来了挑战^[1]. 超分辨率磁共振图像重建可以在无需升级硬件的情况下, 从单个或一组低分辨率图像生成高分辨率图像, 以提高图像细节的可见性^[2]. 目前, 图像超分辨率重建技术广泛应用于医学图像重建、视频监控和人脸识别等领域^[3]. 图像超分辨率重建和磁共振图像快速重建分别是计算机视觉和医学成像领域的两个热门话题^[4], 对于磁共振重建, 许多方法在提升信噪比和结构相似性的基础上, 已展现出强大的抑制噪声和伪影的能力^[5~7].

引用格式: 蒋明峰, 支明豪, 李杨, 等. 基于自注意力机制生成对抗网络的超分辨率磁共振图像重建. 中国科学: 信息科学, 2021, 51: 959–970, doi: 10.1360/SSI-2020-0100
Jiang M F, Zhi M H, Li Y, et al. Super-resolution reconstruction of MR image with self-attention based generate adversarial network algorithm (in Chinese). Sci Sin Inform, 2021, 51: 959–970, doi: 10.1360/SSI-2020-0100

通常, 在磁共振图像中实现图像超分辨率的方法主要有 3 种: 基于插值的方法^[8,9], 基于重建的方法^[10,11] 和基于机器学习的方法^[12,13]. 基于插值的方法假设可以通过使用多项式或具有平滑先验的插值函数将低分辨率图像中的区域扩展为相应的区域, 以生成超分辨率磁共振图像, 但这在不均匀区域中无法使用^[14]. 基于重建的方法可以正则化稀疏约束项解决超分辨重建过程中的优化问题. 但是, 当输入数据过于稀疏或模型略微不准确时, 此类方法无法获得最优解, 尤其是在高频区域^[15]. 这些缺陷使基于重建的超分辨率方法的效率随着放大倍数增大而变得缓慢, 并且在倍数大于 4 时重建效果不佳. 近来, 基于机器学习的方法, 特别是基于深度学习的超分辨率方法, 在提高自然图像超分辨率性能方面引起了广泛的关注^[16,17]. 最新算法依赖于数据驱动的深度神经网络来重建超分辨率所需的细节^[18,19], 直接从数据中自动学习输入和输出之间的映射关系^[20,21], 从而提高重建图像的信噪比和结构相似性.

生成对抗网络 (generative adversarial networks, GANs) 是由 Goodfellow 等^[22] 在 2014 年提出的一种基于深度神经网络的生成式模型, 通过无监督学习获得数据深度表征的方法, 利用反向传播算法不断更新生成网络和判别网络实现竞争性学习从而达到其训练目的^[23]. 大多数基于生成对抗网络的图像生成模型都是使用卷积层构建的^[24]. 卷积操作适用于处理局部邻域中的信息, 因此仅使用卷积层在建立图像的远程依存关系方面效率不高^[25~27], 使用小的卷积核很难学习图像之间的依赖关系^[28], 使用大的卷积核会增加卷积网络参数和降低计算效率^[29]. Zhang 等^[30] 针对图像生成任务提出了一个由注意力驱动, 具有长程依赖性的改进 GAN, 相比于传统的基于卷积网络的模型, 它可以从低分辨率图像中所有位置的细节线索来生成高分辨率细节特征, 而且判别器可以检查图像的远端部分中详细的特征是否彼此一致.

本文提出了一种基于自注意力生成对抗网络的超分辨率重建方法 SA-SR-GAN, 用于从低分辨率磁共振图像生成高分辨率磁共振图像. 由于自注意力机制产生的权重参数, 判别器可以更准确地对全局图像结构施加复杂的几何约束. 另外, 使用非局部模型将自注意力模块引入生成对抗网络框架, 以便生成器和判别器都可以有效地在空间区域之间建立关系依赖. 本文的贡献在于: (1) 提出基于自注意力生成对抗网络的超分辨率磁共振图像重建网络, 实现由低分辨率 2D 磁共振图像生成高分辨磁共振图像; (2) 结合自注意力机制的超分辨率生成对抗网络可提升超分辨率磁共振图像重建的精度; (3) 在判别器网络构建中, 利用谱归一化 (spectral normalization, SN) 能有效保证判别器网络的收敛性和训练稳定性.

2 基于 SA-SR-GAN 的磁共振图像超分辨率算法

2.1 自注意力超分辨率生成对抗网络

生成网络通过一系列上采样, 其中每个上采样都会使输入图像大小加倍, 最终通过卷积获得高分辨图像. 根据所需的缩放比例, 可以更改上采样的倍数. 在磁共振超分辨率重建问题中, 我们假设原图像为真实数据概率分布 x , 低分辨率图像为随机噪声 z , 即生成的图像无限接近于原图:

$$\min_G \max_D L(D, G) = E_{X \sim P_{\text{data}}(x)} [\log D(X)] + E_{z \sim P_z(z)} [\log(1 - D(G(z)))], \quad (1)$$

其中 E_X 代表原图像数据概率分布的数学期望, $P_{\text{data}}(x)$ 代表真实数据概率分布. E_z 代表生成器生成图像数据概率分布的数学期望, $P_z(z)$ 代表噪声数据概率分布.

生成器 G 的目的是欺骗判别器 D , 判别器目的为经过训练后以判别超分辨重建图像和真实图像.

图 1 (网络版彩图) 生成器 (a) 和判别器模型 (b)

Figure 1 (Color online) Generator model (a) and discriminator model (b)

G 生成的图像与真实图像非常相似, 因此很难用 D 进行区分, 从而实现超分辨率磁共振图像重建. 生成器和判别器的网络结构如图 1 所示.

(1) **生成器模型.** 生成器网络结构如图 1(a) 所示, 使用 16 个残差块, 每个残差块包含两个卷积层, 并使用 Swish 激活函数^[31], 使用两个子像素卷积层对图像进行上采样, 最后, 引入自注意力模块用于生成高分辨率图像.

(2) **判别器模型.** 判别器网络结构如图 1(b) 所示, 首先采取 8 层卷积层、批归一化处理和 Swish 函数激活结构的形式. 随后为 1×1 卷积模块, 最后加入自注意力模块, 输出结果为二分类, 即判别输入的高分辨率图像是真实高分辨率图像还是生成器生成图像.

(3) 自注意力模块. 该模块的作用是用自注意力特征图替换传统的卷积特征图. 对于卷积层之后输出的特征图, 经过 1×1 卷积结构的 3 个分支 $f(x)$, $g(x)$, $h(x)$, H 和 W 表示特征图的长和宽, C 表示通道数. 对 $f(x)$ 输出矩阵进行转置再与 $g(x)$ 输出矩阵相乘, 并乘以 Softmax 进行归一化, 以获得注意力特征图, 将注意力特征图与 $h(x)$ 输出矩阵相乘, 并通过 1×1 卷积, 然后将输出整合为自注意力特征图. 自注意力模块的结构如图 2 所示.

计算生成图像各个区域时,模型对不同位置的影响程度的公式如下所示:

$$s_{ij} = f(x_i)^T g(x_j), \quad \beta_{j,i} = \frac{\exp(s_{ij})}{\sum_{i=1}^N \exp(s_{ij})}, \quad (2)$$

其中 $\beta_{j,i}$ 表示在生成第 j 个区域时模型对第 i 个位置的影响程度, N 表示隐藏层中的特征数目.

自注意力层的输出 o 定义为

$$o_j = v \left(\sum_{i=1}^N \beta_{j,i} h(x_i) \right), \quad h(x_i) = W_h x_i, \quad v(x_i) = W_v x_i, \quad (3)$$

图 2 (网络版彩图) 自注意力模块

Figure 2 (Color online) Self-attention module of SA-SR-GAN

在上述公式中, W_h 和 W_v 是学习的权重矩阵, 为了实现 1×1 卷积. 此外, 我们还将注意力层的输出乘以比例系数, 然后加回输入特征图. 因此, 最终输出如下所示:

$$y_i = \gamma o_i + x_i, \quad (4)$$

其中 γ 是可学习的标量, 并且初始化为 0. 引入可学习的 γ 可以使网络首先依赖于本地邻域的信息, 然后逐渐学习为非本地信息分配更多的权重.

(4) 激活函数. ReLU 通常在深度学习中用作激活函数来加快卷积的计算, 但是当很大的梯度流过神经元时, 数据分布可能会被破坏, 从而导致某些神经元关闭而不激活任何数据. 2017 年, Google 提出了一个新的激活函数 Swish, 其公式如下:

$$J(x) = x \times \text{sigmoid}(x). \quad (5)$$

本文中所有激活函数均使用 Swish. 在不同数据集上, Swish 显示出比其他激活函数更好的性能.

(5) 损失函数. 损失函数 (LOSS) 用于估计模型生成或拟合的值与实际值之间的差异, 即重建的 MRI (magnetic resonance imaging) 图像与原始 MRI 图像之间的差异. 损失函数越小, 模型越好. 为了提高模型重构的质量, 本文使用内容损失和对抗损失作为生成器的组合损失函数. 损失函数公式如下所示:

$$l^{\text{SR}} = l_x^{\text{SR}} + 10^{-3} l_{\text{Gen}}^{\text{SR}}, \quad (6)$$

其中 l^{SR} 为总损失, l_x^{SR} 为内容损失, $l_{\text{Gen}}^{\text{SR}}$ 为对抗损失.

以往的内容损失函数都是基于像素差值的均方误差 (mean square error, MSE) 损失, 得到的图像往往过于平滑, 缺少高频细节特征, 而 MSE 对像素间差值敏感, 而像素间差值变化整体呈现给人们的感知并不一定发生变化. 本文采用了与人类感知更相关的 VGG 特征间的欧式距离作为内容损失, 如下所示:

$$l_x^{\text{SR}} = \frac{1}{W_{i,j} H_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} \left(\phi_{i,j} (I^{\text{HR}})_{x,y} - \phi_{i,j} (G_{\theta_G} (I^{\text{LR}}))_{x,y} \right)^2, \quad (7)$$

其中 $\phi_{i,j}$ 表示提取的为第 i 最大池化层前的第 j 卷积层的特征, $W_{i,j}$ 和 $H_{i,j}$ 为提取出的特征层的维度.

图 3 真实 MRI 高分辨率图像 (a) 和下采样低分辨率图像 (b)

Figure 3 The real high resolution MR image (a) and the downsampled low resolution MR image (b)

对抗损失函数就是生成器生成样本的平均判别器概率值, 公式如下所示:

$$l_{\text{Gen}}^{\text{SR}} = \sum_{n=1}^N -\log D_{\theta_D}(G_{\theta_G}(I^{\text{LR}})), \quad (8)$$

其中 $D_{\theta_D}(G_{\theta_G}(I^{\text{LR}}))$ 表示的是判别器将生成器生成的图像判断为原磁共振图像的概率。

(6) 谱归一化. Miyato 等^[32]提出将谱归一化 (SN) 应用于判别器网络, 以稳定 GAN 的训练, 并通过限制每一层的谱范数限制判别器的 Lipschitz 常数. 与其他归一化技术相比, 谱归一化不需要额外的超参数调整 (将所有权重层的谱范数设置为 1). 本文所提出的方法也加入了谱归一化, 减少了网络结构的计算成本, 同时使训练过程更加稳定。

2.2 实验数据与评价标准

实验对模型进行训练和测试所采用的数据集分别为 MICCAI 2013 grand challenge 公开数据集¹⁾, 以及卡罗林斯卡大学医院 (Karolinska University Hospital) 西门子 Prisma 3.0T 设备采集的临床实测数据集, 其参数为 T1, 恢复时间/重复时间 = 2.52 ms/1900 ms, 翻转角度 9°。大脑和心脏 MRI 图像随机选取 50 个样本做训练, 其中 40 个样本做训练集 (3200 张二维 MRI), 10 个样本做验证集 (960 张二维 MRI)。同时为保证测试公平性, 我们进行两次独立测试来验证所提出的 SA-SR-GAN 模型的性能: 第 1 次是随机选取 10 个样本做测试集 (960 张二维 MRI 图像) 进行测试并计算平均定量指标; 第 2 次是从测试集中选取一张特征较明显的二维 MRI 进行视觉方面重建效果测试。本论文实验采用 Pytorch 深度学习框架和 TeslaV100-SXM2 GPU 处理器。低分辨率图像是通过原始高分辨率图像双三次插值下采样后获得的, 如图 3 所示。本文将下采样后的图像作为网络的输入, 输出超分辨率后的图像与真实 MRI 图像进行对比。SA-SR-GAN 网络以 0.0001 的学习率进行了 100000 次更新迭代训练, 每经过 500 次训练保存并输出模型, 并对模型在数据集集中进行损失检测。

实验采用峰值信噪比 (peak signal-to-noise ratio, PSNR) 和结构相似性 (structural similarity index, SSIM) 两种评价标准来评价重构图像:

$$\text{PSNR} = 10 \times \log_{10} \left(\frac{255^2}{M \times N \sum_{i=1}^M \sum_{j=1}^N (y(i, j) - x(i, j))^2} \right), \quad (9)$$

1) <https://www.synapse.org/#!/Synapse:syn3193805/wiki/217780>.

图 4 (网络版彩图) 心脏 MRI 不同方法下重构超分辨率图像比较. (a) 真实 MRI 高分辨率图像, (b) SR-GAN, (c) SR-WGAN, (d) SA-SR-GAN, (e) SA-SR-GAN(SN)

Figure 4 (Color online) The reconstructed super resolution cardiac MR images by using different GAN based methods. (a) The real high resolution MR image, and the reconstructed super-resolution MRI using (b) SR-GAN, PSNR = 31.27, SSIM = 0.9947, (c) SR-WGAN, PSNR = 33.58, SSIM = 0.9953, (d) SA-SR-GAN, PSNR = 35.46, SSIM = 0.9962, (e) SA-SR-GAN(SN), PSNR = 36.16, SSIM = 0.9977

其中 x 代表真实高分辨率图像, y 代表重建超分辨率图, i 和 j 分别代表像素点的坐标位置, $M \times N$ 代表图像的大小.

$$\text{SSIM} = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}, \quad (10)$$

其中 μ_x 和 μ_y 分别代表图像 x 和 y 的均值, σ_x 和 σ_y 分别代表图像 x 和 y 的方差, σ_{xy} 代表图像 x 和 y 的协方差, C_1 和 C_2 代表用来维持稳定的常数值.

3 实验结果和分析

在实验中, 本文先参考原始 SR-GAN 的参数设置, 然后加入自注意力机制后对学习率、批大小等超参数进行调整, 进行多次实验, 把内容损失和对抗损失结合的组合损失函数达到最小值的实验参数作为最佳参数. 为了更好地比较各种方法重建超分辨率 MRI 图像的细微差别, 本文选择对二维 MRI 图像放大特定区域以便观察重构细节. 通过比较图 4~6 中的实验结果, 可以发现基于 SA-SR-GAN 的重建算法在细节上具有更清晰的纹理结构. 表 1~3 显示出了通过不同算法重构的 3200 个二维 MRI

图 5 (网络版彩图) 脑 MRI 不同方法下重构超分辨率图像比较. (a) 真实 MRI 高分辨率图像, (b) SR-GAN, (c) SR-WGAN, (d) SA-SR-GAN, (e) SA-SR-GAN(SN)

Figure 5 (Color online) The reconstructed super resolution brain MR images by using different GAN based methods. (a) The real high resolution MR image, and the reconstructed super-resolution MRI using (b) SR-GAN, PSNR = 31.68, SSIM = 0.9032, (c) SR-WGAN, PSNR = 32.33, SSIM = 0.9176, (d) SA-SR-GAN, PSNR = 33.27, SSIM = 0.9317, (e) SA-SR-GAN(SN), PSNR = 33.46, SSIM = 0.9429

的 PSNR 和 SSIM 的两个量化指标的平均值.

本文将 SA-SR-GAN 模型与 3 种同类 GAN 模型进行了比较. 2 倍、4 倍和 8 倍超分辨率重建后的图像放大细节在图 4~6 中列出, 可以看出 SA-SR-GAN 重构效果更好. 本文将自注意力模块与较大比例的高频纹理细节相结合, 在超分辨率重建后可以看到其他方法看不到的细节以及解剖结构的精细轮廓. 在某些边缘细节上, 本文提出的模型优于原始模型.

通过使用自注意力模块的超分辨率生成对抗网络, 本文比较了 2 倍、4 倍和 8 倍 3 种放大倍率下不同方法重建超分辨率 MRI 图像的 PSNR 和 SSIM 值, 其中表 1 比较了不同方法的心脏超分辨率 MRI 重构结果, 表 2 比较了不同方法的大脑超分辨率 MRI 重构结果, 表 3 比较了不同方法的临床数据超分辨率 MRI 重构结果. 从表 1~3 实验结果可以看出, 本文所提出的 SA-SR-GAN 可以有效提升重建质量, 而且 SA-SR-GAN(SN) 方法能够进一步改善超分辨率磁共振图像的重建质量.

加入自注意力机制与谱归一化处理后, 相比于原始 SR-GAN, 参数量略微提高, 参数量是通过 (卷积核长度 $\times$ 卷积核宽度 $\times$ 通道数) $\times$ 卷积核个数得到一层卷积的参数, 再把每一层参数相加得到模型总参数 [33], 如表 4 所示, 但迭代达到收敛所需的 epoch 有所下降, 从而减少了计算成本, 如图 7 所

图 6 (网络版彩图) 临床实测脑 MRI 超分辨率图像重构方法比较. (a) 真实 MRI 高分辨率图像, (b) SR-GAN, (c) SR-WGAN, (d) SA-SR-GAN, (e) SA-SR-GAN(SN)

Figure 6 (Color online) The reconstructed super resolution clinical brain MR images by using different GAN based methods. (a) The real high resolution MR image, and the reconstructed super-resolution MRI using (b) SR-GAN, PSNR = 29.52, SSIM = 0.9872, (c) SR-WGAN, PSNR = 29.87, SSIM = 0.9905, (d) SA-SR-GAN, PSNR = 30.17, SSIM = 0.9912, (e) SA-SR-GAN(SN), PSNR = 30.96, SSIM = 0.9931

表 1 心脏 MRI 超分辨率结果比较 (粗体标注为最佳结果)
Table 1 Average PSNR, SSIM under different methods (cardiac)

	SR-GAN		SR-WGAN		SA-SR-GAN		SA-SR-GAN(SN)	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
X2	33.73	0.9957	33.98	0.9968	35.66	0.9962	34.70	0.9965
X4	32.30	0.9946	33.22	0.9951	34.09	0.9959	37.58	0.9979
X8	31.35	0.9951	32.52	0.9943	33.45	0.9956	35.60	0.9962

示. 生成器和判别器使用谱归一化使得每个生成器更新过程中产生更少的判别器更新, 从而显著降低了训练的计算成本. 图 8 所示为 X4 倍超分辨率图像重构的训练过程损失值变化, 我们可以发现 SA-SR-GAN(SN) 方法的损失值呈单调下降, 而 SA-SR-GAN 方法呈波浪式下降, 表明结合谱归一化的 SA-SR-GAN(SN) 方法使训练变得更加稳定.

在本文研究中, 将自注意力机制集成到了生成对抗网络中, 使用自注意力机制来获取远程依赖关

表 2 大脑 MRI 超分辨率结果比较 (粗体标注为最佳结果)

Table 2 Average PSNR, SSIM under different methods (brain)

	SR-GAN		SR-WGAN		SA-SR-GAN		SA-SR-GAN(SN)	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
X2	43.35	0.9989	43.76	0.9990	43.97	0.9991	44.23	0.9993
X4	39.88	0.9955	40.37	0.9961	41.76	0.9970	42.76	0.9976
X8	30.83	0.8891	30.97	0.8902	31.02	0.8907	31.59	0.8922

表 3 临床 MRI 超分辨率结果比较 (粗体标注为最佳结果)

Table 3 Average PSNR, SSIM under different methods (clinical data)

	SR-GAN		SR-WGAN		SA-SR-GAN		SA-SR-GAN(SN)	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
X2	34.21	0.9963	35.43	0.9964	36.28	0.9966	37.72	0.9968
X4	28.89	0.9903	29.34	0.9908	30.13	0.9913	30.85	0.9920
X8	26.31	0.9722	27.67	0.9824	28.22	0.9842	28.71	0.9869

表 4 不同方法参数量比较

Table 4 Parameters by using different methods

Method	Parameters (M)
SR-GAN	1.55
SR-WGAN	1.57
SA-SR-GAN	1.58
SA-SR-GAN(SN)	1.60

图 7 (网络版彩图) 心脏在 4 倍超分辨率下与 PSNR 的收敛性函数

Figure 7 (Color online) The convergences of PSNR as a function of epoch for cardiac super resolution under factor 4

图 8 (网络版彩图) 不同方法 X4 倍重构 LOSS 值比较

Figure 8 (Color online) Comparison of LOSS under factor 4 and different methods

系, 实现超分辨率 MRI 重建. 与通过一系列卷积运算提供的渐进式传播相反, 自注意力机制计算任意两个位置之间的直接相互作用, 而与距离无关. 自注意力机制允许网络聚焦那些分散在不同位置, 却有结构关联的区域, 学习图像的上下文关系, 使生成的图像更具有全局一致性, 从而提升重建图像细节, 提高图像的分辨率. 表 1~3, 分析了本文方法与 3 种比较方法在 3 种放大倍数下重建超分辨率 MRI 图像的平均 PSNR 和 SSIM 值. 如表所示, 本文方法在不同放大倍数下可以使重建图像的平均 PSNR 提高约 2.8%~18.1%, SSIM 则提高约 0.15%~0.39%, 这表明 SA-SR-GAN 网络模型提高了图像的清晰度, 并且可以更准确地重建出具有更高 PSNR 和 SSIM 值的图像. 使用谱归一化使 SA-SR-GAN 方法更具鲁棒性, 训练过程使损失目标函数下降得更为稳定, 如图 8 所示, 并且可进一步提升超分辨率图像重建质量.

4 结论

本文提出了一种基于自注意力机制生成对抗网络的磁共振图像超分辨率重建的新方法, 通过将自注意力层附加到卷积层上, 演示了将自注意力机制集成到卷积神经网络中的可行性. 本文方法的核心之处在于将自注意力机制整合到 SR-GAN 框架中, 自注意力机制可确保在下一阶段中提高前一个阶段中产生的超分辨率图像的质量, 因此, 我们的方法能够针对高放大倍数 (大于或等于 4) 产生高质量的图像. 与原始 SR-GAN 框架相比, 本文方法获得的超分辨率图像具有更高的 PSNR 值和 SSIM 值, 图像细节更接近原始高分辨率图像, 所获得的超分辨率图像可以用于增加低维图像的尺寸和分辨率. 在未来的工作中, 我们会将本文所提出的 SA-SR-GAN(SN) 应用于从 3T 磁共振采集数据构建具有 7T 分辨率的磁共振图像, 实现可用于临床的超分辨率图像重建.

参考文献

- 1 Wang X Y, Li D. Application of generative countermeasure network in super-resolution image reconstruction. *J Frontiers Comput Sci Tech*, 2020, 14: 680–687 [汪鑫耘, 李丹. 生成式对抗网络在超分辨率图像重建中的应用. *计算机科学与探索*, 2020, 14: 680–687]
- 2 Zhang F Z, Cen Y G, Zhao R Z, et al. The algorithm of image super-resolution reconstruction via separable dictionaries. *Sci Sin Inform*, 2020, 50: 275–288 [张凤珍, 岑翼刚, 赵瑞珍, 等. 基于分离字典的图像超分辨率重建. *中国科学: 信息科学*, 2020, 50: 275–288]
- 3 Gholipour A, Estroff J A, Warfield S K. Robust super-resolution volume reconstruction from slice acquisitions: application to fetal brain MRI. *IEEE Trans Med Imag*, 2010, 29: 1739–1758
- 4 Zeng W, Peng J, Wang S, et al. A comparative study of CNN-based super-resolution methods in MRI reconstruction. In: *Proceedings of the 16th International Symposium on Biomedical Imaging, Venezia*, 2019. 1678–1682
- 5 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
- 6 Wang S, Ke Z, Cheng H, et al. DIMENSION: dynamic MR imaging with both k-space and spatial prior knowledge obtained via multi-supervised network training. 2019. ArXiv:1810.00302
- 7 Wang S, Tan S, Gao Y, et al. Learning joint-sparse codes for calibration-free parallel MR imaging. *IEEE Trans Med Imag*, 2018, 37: 251–261
- 8 Manjón J V, Coupé P, Buades A, et al. Non-local MRI upsampling. *Med Image Anal*, 2010, 14: 784–792
- 9 Jafari-Khouzani K. MRI upsampling using feature-based nonlocal means approach. *IEEE Trans Med Imaging*, 2014, 33: 1969–1985
- 10 Rueda A, Malpica N, Romero E. Single-image super-resolution of brain MR images using overcomplete dictionaries. *Med Image Anal*, 2013, 17: 113–132
- 11 Tourbier S, Bresson X, Hagmann P, et al. An efficient total variation algorithm for super-resolution in fetal brain MRI with adaptive regularization. *Neuroimage*, 2015, 118: 584–597

- 12 Dong C, Loy C C, He K, et al. Image super-resolution using deep convolutional networks. *IEEE Trans Pattern Anal Mach Intell*, 2016, 38: 295–307
- 13 Shi J, Li Z, Ying S, et al. Image super-resolution via wide residual networks with fixed skip connection. *IEEE Biomed Health Informat*, 2018, 23: 1129–1140
- 14 Mahmoudzadeh A P, Kashou N H. Interpolation-based super-resolution reconstruction: effects of slice thickness. *J Med Imag*, 2014, 1: 034007
- 15 Luo J, Mou Z, Qin B, et al. Fast single image super-resolution using estimated low-frequency k-space data in MRI. *Magn Reson Imaging*, 2017, 40: 1–11
- 16 Shi J, Liu Q, Wang C, et al. Super-resolution reconstruction of MR image with a novel residual learning network algorithm. *Phys Med Biol*, 2018, 63: 085011
- 17 Jog A, Carass A, Prince J L. Improving magnetic resonance resolution with supervised learning. In: *Proceedings of the 11th International Symposium on Biomedical Imaging*, Beijing, 2014. 987–990
- 18 Shi W, Caballero J, Huszár F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 2016. 1874–1883
- 19 Seeliger K, Güclü U, Ambrogioni L, et al. Generative adversarial networks for reconstructing natural images from brain activity. *Neuro Image*, 2018, 181: 775–785
- 20 Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 2017. 4700–4708
- 21 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 16th International Symposium on Biomedical Imaging*, Venezia, 2019. 1550–1554
- 22 Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets. In: *Proceedings of the Neural Information Processing Systems*, Montreal, 2014. 2672–2680
- 23 Jin W D, Yang P, Tang P. Double discriminator generative adversarial networks and their application in detecting nests built in catenary and semisupervised learning. *Sci Sin Inform*, 2018, 48: 888–902 [金炜东, 杨沛, 唐鹏. 双判别器生成对抗网络及其在接触网鸟巢检测与半监督学习中的应用. *中国科学: 信息科学*, 2018, 48: 888–902]
- 24 Quan T M, Nguyen-Duc T, Jeong W K. Compressed sensing MRI reconstruction using a generative adversarial network with a cyclic loss. *IEEE Trans Med Imag*, 2018, 37: 1488–1497
- 25 Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017. 4681–4690
- 26 Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 2017. 4700–4708
- 27 Gu J, Wang Z, Kuen J, et al. Recent advances in convolutional neural networks. *Pattern Recognition*, 2018, 77: 354–377
- 28 Latif S, Asim M, Usman M, et al. Automating motion correction in multishot MRI using generative adversarial networks. 2018. ArXiv: 1811.09750
- 29 Dong C, Loy C C, He K, et al. Learning a deep convolutional network for image super-resolution. In: *Proceedings of the European Conference on Computer Vision*, Switzerland, 2014. 184–199
- 30 Zhang H, Goodfellow I, Metaxas D, et al. Self-attention generative adversarial networks. 2018. ArXiv: 1805.08318
- 31 Ramachandran P, Zoph B, Le Q V. Searching for activation functions. 2017. ArXiv: 1710.05941
- 32 Miyato T, Kataoka T, Koyama M, et al. Spectral normalization for generative adversarial networks. 2018. ArXiv: 1802.05957
- 33 Iandola F N, Moskewicz M W, Ashraf K, et al. Firecaffe: near-linear acceleration of deep neural network training on compute clusters. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 2016. 2592–2600

Super-resolution reconstruction of MR image with self-attention based generate adversarial network algorithm

Mingfeng JIANG^{1*}, Minghao ZHI¹, Yang LI¹, Tieqiang LI² & Jucheng ZHANG³

1. School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China;

2. School of Information Engineering, China Jiliang University, Hangzhou 310018, China;

3. The Second Affiliated Hospital, School of Medicine, Zhejiang University, Hangzhou 310019, China

* Corresponding author. E-mail: m.jiang@zstu.edu.cn

Abstract Super-resolution (SR) MRI images can provide fine-grained anatomical information, however it takes a long time to acquire data. In order to accelerate the acquisition of MR images while maintaining high-quality images, extensive research has been performed on image reconstruction through the deep learning method. In this study, a reconstruction framework by using self-attention based super-resolution generative adversarial networks (SA-SR-GAN) is proposed to generate super resolution MR image from low resolution MR image. Moreover, the self-attention mechanism is integrated into super-resolution generative adversarial networks (SR-GAN) framework, which is used to calculate the weight parameters of the input features. At the same time, spectral normalization is added to make the discriminator network training process more stable. The network was trained with 40 3D images (each 3D image contains 256 slices) and tested with 10 images. The experimental results show that the PSNR and SSIM values of the super-resolution magnetic resonance image generated by the proposed SA-SR-GAN method are higher than the state-of-the-art reconstruction methods.

Keywords MR image, super resolution, generative adversarial network, self-attention, spectral normalization

Mingfeng JIANG received the B.S. and M.S. degrees in biomedical engineering from Chongqing University, China, in 2000 and 2003, respectively. And he received the Ph.D. degree in biomedical engineering from Zhejiang University, China, in 2008. From 2011 to 2012, he was a visiting scientist with Department of Electrical Engineering, University of Queensland, Australia. He is currently a professor with School of Information Science and Technology, Zhejiang Sci-Tech University, China. His research interests include biomedical signal processing, MR image reconstruction, and inverse ECG problem.

Minghao ZHI was born in 1995. Currently, he is a master candidate at Zhejiang Sci-Tech University. His research interest includes computer vision, and deep learning.

Yang LI received the B.E. degree from Northeastern University, China, in 2008, the M.E. degree from China Medical University, in 2011, and the Ph.D. degree from Shenyang Institute of Automation, Chinese Academy of Sciences, in 2018. He is currently a lecturer with School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou, China. His current research interests include medical image analysis, computer vision, and machine learning.

Tieqiang LI received the B.S. degree from Department of Chemical Engineering, Tianjin University of Science and Technology, Tianjin, China, in 1983. And he completed his Ph.D. degree from Faculty of Chemistry and Chemical Technology, the Royal Institute of Technology, Stockholm, Sweden, in 1997. He is currently a professor with College of Information Engineering, China Jiliang University. His current research interests include developing rapid data acquisition methods and novel post-processing techniques for MRI and exploring new imaging contrast mechanisms for neurological applications.