

# 基于 DAWGAN-GP 的磁共振图像重构方法研究

袁子晗<sup>1</sup>, 蒋明峰<sup>1</sup>, 李 杨<sup>1</sup>, 支明豪<sup>1</sup>, 朱志军<sup>2</sup>

(1. 浙江理工大学信息学院, 浙江杭州 310018; 2. 解放军第一一七医院心血管内科, 浙江杭州 310013)

**摘要:** 本文提出了一种基于改进 Wasserstein 生成式对抗网络 (De-aliasing Wasserstein Generative Adversarial Network with Gradient Penalty, DAWGAN-GP) 的磁共振图像重构算法, 该方法利用 Wasserstein 生成式对抗网络代替传统的生成式对抗网络, 并结合梯度惩罚的方法提高训练速度, 解决 WGAN 收敛缓慢问题. 此外, 为了更好的重构效果, 我们将感知损失, 像素损失和频域损失引入至损失函数中进行网络训练. 实验结果表明, 对比现有的基于深度学习的磁共振图像重构算法, 基于 DAWGAN-GP 的磁共振图像重构方法具有更好的重构效果, 可获得更高的峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 和更好的结构相似性 (Structural Similarity Index Measure, SSIM).

**关键词:** 磁共振; 图像重构; Wasserstein 生成式对抗网络; 感知损失

中图分类号: TP302

文献标识码: A

文章编号: 0372-2112 (2020)10-1883-08

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2020.10.002

## Research of MRI Reconstruction Method by Using De-aliasing Wasserstein Generative Adversarial Networks with Gradient Penalty

YUAN Zi-han<sup>1</sup>, JIANG Ming-feng<sup>1</sup>, LI Yang<sup>1</sup>, ZHI Ming-hao<sup>1</sup>, ZHU Zhi-jun<sup>2</sup>

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

2. Department of Cardiology, The 117th Hospital of PLA, Hangzhou, Zhejiang 310013, China)

**Abstract:** In this paper, we propose an improved Wasserstein generative adversarial network (WGAN), de-aliasing Wasserstein generative adversarial network with Gradient Penalty (DAWGAN-GP), for magnetic resonance imaging (MRI) reconstruction. This method uses WGAN to replace the traditional GAN, and combined the gradient penalty to improve the training speed and to solve the slow convergence problem of WGAN. In addition, for better preservation of the fine structures in the reconstructed images, we incorporate perceptual loss, pixel loss and frequency loss into the loss function for training the network. Compared with other state-of-the-art deep learning methods for MR images reconstruction, DAWGAN-GP method outperforms all other methods and can provide superior reconstruction with improved peak signal to noise ratio (PSNR) and better structural similarity index measure (SSIM).

**Key words:** magnetic resonance imaging (MRI); image reconstruction; WGAN-GP; perceptual loss

## 1 引言

磁共振成像 (Magnetic Resonance Imaging, MRI) 在医学上是一种常见的影像成像方法, 可以无创的成像内部组织结构, 其成像过程是先在频域中进行信号采集, 再将采集的信号变换到时域完成成像, 其拥有成像分辨率高、无辐射等优点. 但扫描时间过长, 一些危重病人往往难以忍受长时间保持固定姿势的疼痛, 且成像精度易受到生理性运动的影响, 产生运动伪影. 因此, 如何提高磁共振图像成像速度及图像重构质量是研究与

应用的关键所在. 目前最常用的技术主要分为: (1) 基于压缩感知的磁共振成像方法<sup>[1,2]</sup>, 如基于伪极坐标傅里叶变换方法<sup>[3]</sup>, 基于加权 Schatten p 范数最小化的磁共振图像重构方法<sup>[4]</sup>和基于组的特征值分解和估计<sup>[5]</sup>等方法; (2) 基于并行成像的磁共振成像方法, 如 k-t Sparse SENSE<sup>[6]</sup>, iGRASP<sup>[7]</sup>和基于联合稀疏编码<sup>[8]</sup>等方法; (3) 基于字典学习的磁共振重构方法, 如基于非参数贝叶斯字典学习<sup>[9]</sup>和基于几何方向快速多级字典学习<sup>[10]</sup>等方法. 尽管如此, 由于压缩感知主要是寻求不同的稀疏方法进行重构, 而稀疏变换并不能完全捕捉到

收稿日期: 2019-06-17; 修回日期: 2020-05-13; 责任编辑: 李勇锋

基金项目: 国家自然科学基金 (No. 61672466); 浙江省自然科学基金-数理医学学会联合基金重点项目 (No. LSZ19F010001); 浙江省科技厅重点研发项目 (No. 2020C03060)

细节特征,并且多次迭代也会导致图像重构时间过长,时效性较差.而字典学习的计算复杂性较大,忽略了训练集元素之间的相邻关系,这些不足都限制了技术的应用.

最近,深度学习<sup>[11]</sup>(Deep Learning)在超分辨率重建,图像识别和动作识别<sup>[12]</sup>等问题上都取得了不错的成绩.对于磁共振图像重构问题,深度神经网络主要是学习欠采样图像和全采样图像之间的映射关系.对图像处理的卷积操作也可以有效地提取图像特征,避免因细节特征不清晰而造成重构效果差.当模型训练结束,在网络中输入欠采样图像就会输出接近全采样的重构图像,这可以极大地减少磁共振成像时耗费的扫描时间,极大地加快磁共振图像重构时间,从而进一步提高磁共振成像精度.

将深度学习应用于磁共振图像重构的时间并不长,2016年Wang<sup>[13]</sup>首次将卷积神经网络(Convolutional Neural Networks, CNN)应用于磁共振图像重构中,其训练出一个离线CNN模型用于构建欠采样零填充图像与全采样图像之间的映射关系. Yang<sup>[14]</sup>为了改进神经网络的计算速度,将传统的交替方向乘子算法<sup>[15]</sup>(Alternating Direction Method of Multipliers, ADMM)与神经网络相结合,提出一种新型网络结构ADMM-Net.为了提高网络重构图像的质量, Yang<sup>[16]</sup>将生成式对抗网络<sup>[17]</sup>(Generative Adversarial Networks, GAN)应用于MRI重构中,并提出DAGAN网络模型.这几种基于深度学习的方法都能有效

地重构出接近全采样的磁共振图像,且图像重构效果往往比使用传统方法重构出的图像效果要好.

Wasserstein GAN<sup>[18]</sup>是原始GAN的一种变形,其彻底解决GAN训练不稳定的问题,并确保生成样本的多样性.但WGAN对权重进行裁剪时过于简单直接,这会引入新的问题,亦即梯度爆炸. Gulrajani<sup>[19]</sup>提出对权重采用梯度惩罚的方法以代替直接裁剪,从而可以避免训练时梯度爆炸问题.

本文中,我们提出一种基于改进Wasserstein生成式对抗网络(De-aliasing Wasserstein Generative Adversarial Network with Gradient Penalty, DAWGAN-GP)的磁共振图像重构算法,网络架构分为生成器G和判别器D,如图1所示.生成器借鉴残差网络的思想,级联三个带跳跃连接的U-net网络架构,分别由带四个卷积层与四个反卷积层的U-net,带六个卷积层与六个反卷积层的U-net和带八个卷积层与八个反卷积层的U-net组成.判别器采用去掉sigmoid激活的CNN网络架构,其目标转为计算生成器生成的图像与原图之间的Wasserstein距离,并采用梯度惩罚的方法优化训练过程,生成器目标为最小化Wasserstein距离,因而通过对抗使得模型学习到更多信息.此外,为提高图像重构的质量,将感知损失<sup>[20]</sup>,像素损失和频域损失作为生成器的组合损失函数,并采用Adam优化算法对其优化.实验验证,本文提出的DAWGAN-GP方法对磁共振欠采样图像有更好的重构效果.

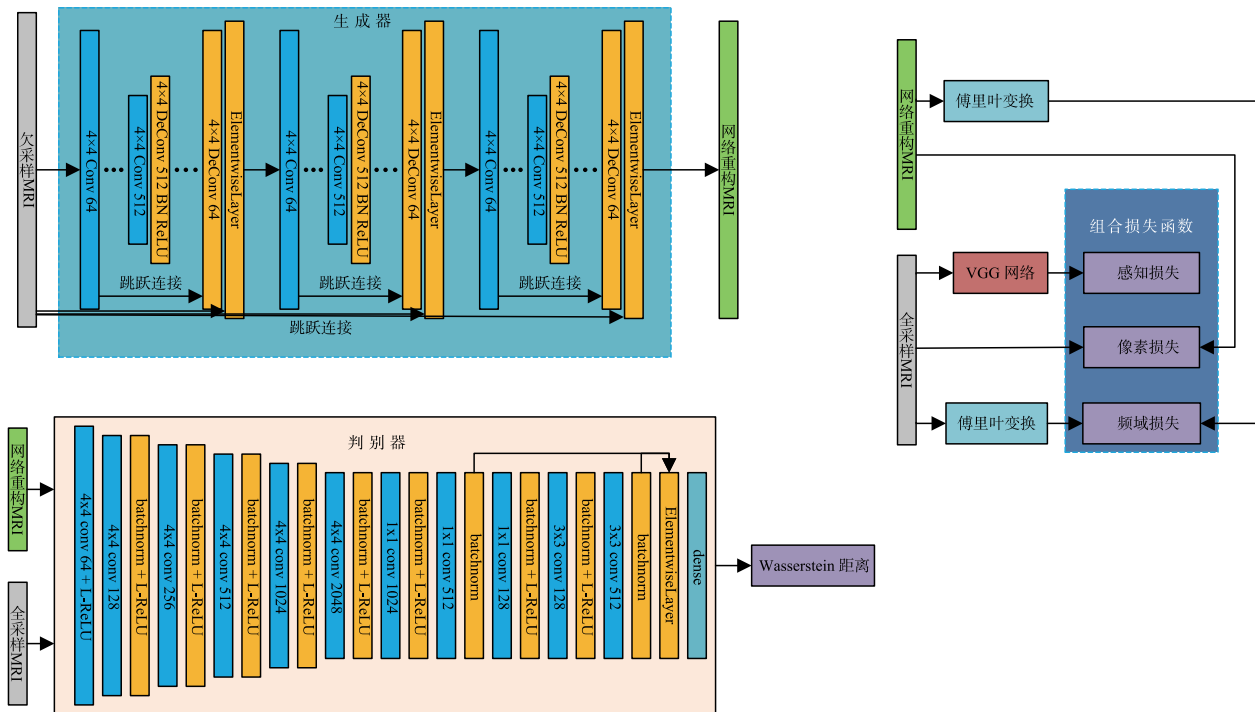


图1 基于改进Wasserstein生成式对抗网络网络结构图

## 2 基于 DAWGAN-GP 的磁共振图像重构算法

### 2.1 改进 Wasserstein 生成式对抗网络

在原始 GAN 中,生成器不断学习训练样本的真实概率分布,并将所输入的随机噪声不断拟合,判别器则是用来区分是生成的概率分布还是真实概率分布.在数学上可以理解为一个极小极大博弈过程,而最终目标是达到纳什均衡,使生成器估计到真实数据样本分布.在磁共振重构问题中,我们假设全采样图像为真实概率分布  $\mathbf{X}$ ,欠采样零填充图像为随机噪声  $\mathbf{Z}$ ,即生成的图像无限接近于原图:

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

其中  $E$  代表数学期望,  $P_{\text{data}}(\mathbf{X})$  代表真实数据概率分布.

当生成器固定参数且  $P_G$  代表生成器生成的概率分布时,最优的判别器就可以表示为:

$$D^* = \frac{P_{\text{data}}}{P_{\text{data}} + P_G} \quad \text{s. t. } P_{\text{data}} = P_G \quad (2)$$

从而可知,当判别器最优时极小极大博弈问题就转化为一个最小化问题:

$$\min_G L(D^*, G) = \text{JSD}(P_{\text{data}} \| P_G) - \log(2) \quad (3)$$

如式(3)所示,在原始 GAN 中使用 JSD<sup>[21]</sup> (Jensen-Shannon Divergence, JSD) 来衡量生成数据与原始数据之间的散度,这会导致判别器训练的越好,生成器梯度消失问题就越严重,网络训练不稳定.而 WGAN 则使用 Wasserstein 距离(又叫 Earth-Mover 距离)来反映  $P_G$  和  $P_{\text{data}}$  之间的距离, Wasserstein 距离是平滑的,从而可以有效避免梯度消失问题的发生,并提高训练稳定性.

$$W(P_{\text{data}}, P_G) = \inf_{\gamma \sim \prod(P_{\text{data}}, P_G)} E_{(X, Z)} [\| \mathbf{X} - \mathbf{Z} \|] \quad (4)$$

WGAN 虽然可以解决网络在训练时梯度消失问题,但在对权重进行裁剪时过于简单直接,这会导致另一个极端问题,亦即梯度爆炸. WGAN-GP 是对 WGAN 的一种改进,通过改进连续性约束,采用梯度惩罚的方法把权重缩减到一个很小的范围内,以达到加速模型收敛速度和解决梯度爆炸的目的.综上,本文采用 WGAN-GP 网络结构对欠采样磁共振图像进行重构,理论公式如式(5)所示:

$$\min_G \max_D L_{\text{WGAN}}(D, G) = -E_{\mathbf{X}} [D(\mathbf{X})] + E_{\mathbf{Z}} [D(G(\mathbf{Z}))] + \lambda E_{\hat{\mathbf{X}}} [(\| \nabla_{\hat{\mathbf{X}}} D(\hat{\mathbf{X}}) \|_2 - 1)^2] \quad (5)$$

其中公式前两项用于计算 Wasserstein 距离,同时也是 WGAN 的理论公式.第三项是用于修正的梯度惩罚项,  $\hat{\mathbf{X}}$  是对欠采样图像和全采样图像进行均匀采样的映射

对,  $\lambda$  为梯度惩罚项参数.

### 2.2 组合损失函数

损失函数是用来估量模型生成或拟合的值与真实值之间的差距,即表示模型重构出的 MRI 与全采样 MRI 之间的差距,损失函数越小,证明模型鲁棒性越强.为提高模型重构质量,我们提出将感知损失(perceptual loss)、像素损失(pixel loss)、频域损失(frequency loss)和对抗损失(adversarial loss)作为生成器的组合损失函数,采用更多的评价标准以提高图像重构质量.

像素损失  $L_{\text{pixel}}$  和频域损失  $L_{\text{frequency}}$  如下所示:

$$\min_G L_{\text{pixel}}(G) = \frac{1}{2} \| \mathbf{X}_t - \mathbf{X}_u \|_2^2 \quad (6)$$

$$\min_G L_{\text{frequency}}(G) = \frac{1}{2} \| \hat{\mathbf{Y}}_t - \hat{\mathbf{Y}}_u \|_2^2 \quad (7)$$

其中  $\mathbf{X}_t$  和  $\mathbf{X}_u$  分别代表全采样 MRI 和网络重构 MRI,  $\hat{\mathbf{Y}}_t$  和  $\hat{\mathbf{Y}}_u$  分别代表其对应的频域信息.

感知损失  $L_{\text{perceptual}}$  和对抗损失  $L_{\text{adversarial}}$  如下所示:

$$\min_G L_{\text{perceptual}}(G) = \frac{1}{2} \| f_{\text{perceptual}}(\mathbf{X}_t) - f_{\text{perceptual}}(\mathbf{X}_u) \|_2^2 \quad (8)$$

$$\min_G L_{\text{adversarial}}(G) = E(D(G(\mathbf{X}_u))) \quad (9)$$

组合损失函数  $L_{\text{combine}}$  可以表示为:

$$L_{\text{combine}} = \alpha L_{\text{pixel}} + \beta L_{\text{frequency}} + \delta L_{\text{perceptual}} + L_{\text{adversarial}} \quad (10)$$

## 3 实验及结果分析

实验采用 TeslaV100-SXM2 GPU 和 MICCAI 2013 grand challenge 公开数据集\*对模型进行训练和测试.随机选取 100 个三维样本做训练,其中 70 个样本做训练集(15800 张二维 MRI),30 个样本做验证集(6700 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 DAWGAN-GP 模型的性能.第一次是随机选取 30 个样本做测试集(5200 张二维 MRI 图像)进行测试并计算平均定量指标,第二次是从测试集中选取一张特征较明显的二维 MRI 进行测试.

实验采用两种不同的采样模式,符合一维高斯分布的采样模式和符合二维高斯的采样模式,如图 2 所示.采用 10%,20% 和 30% 三种不同采样率来评价不同方法的图像重构性能,所选采样率分别对应加速因子是 10 倍、5 倍和 3.3 倍.

对于实验超参数,我们将网络初始学习率设为 0.0001,学习率衰减因子设为 0.5,并每 5 个 epoch 更新一次.组合损失函数中的  $\alpha$ ,  $\beta$  和  $\delta$  分别设置为 15, 0.1 和 0.0025.为保证网络达到真正的收敛,我们规定当前 epoch 的归一化均方误差(Normalized Mean Square Error,

\* <https://www.synapse.org/#!/Synapse:syn3193805/wiki/217780>




图2 两种不同采样模式

NMSE) 小于接下来 10 个 epoch 时, 网络停止训练并保存当前模型为最优模型。

### 3.1 评价标准

实验采用峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 和结构相似性 (Structural Similarity Index Measure, SSIM) 两种评价标准来评价重构图像:

$$PSNR = 10 \times \log_{10} \left( \frac{255^2}{M \times N \sum_{i=1}^M \sum_{j=1}^N (y(i,j) - x(i,j))^2} \right) \quad (11)$$

其中  $x$  代表全采样图像,  $y$  代表欠采样重构图,  $i$  和  $j$  分别代表像素点的坐标位置,  $M \times N$  代表图像的大小。

$$SSIM = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (12)$$

其中  $\mu_x$  和  $\mu_y$  分别代表图像  $x$  和  $y$  的均值,  $\sigma_x$  和  $\sigma_y$  分别代表图像  $x$  和  $y$  的方差,  $\sigma_{xy}$  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。

### 3.2 基于 DAWGAN-GP 的磁共振图像重构结果

在实验中, 我们将对比实验与本实验的参数均设置最优值, 以便进行最佳重构性能比较。图 3, 图 4 分别展示一张特征较明显的二维 MRI 在不同采样模式下采 10% 频域信息并通过不同算法重构出的效果图。由于视觉上观察效果差距可能不大, 我们选择一张特征较为明显的二维 MRI 并对特定区域进行放大, 观察重构细节。通过实验结果对比可发现, 基于 DAWGAN-GP 的重构算法在细节方面有较为清晰的纹理结构, 如图 3, 图 4 所示。图 3, 图 4 提供不同方法的重构 MRI 与全采样 MRI 的残差图, 可以看出本论文提出方法具有更好的重构效果, 残差图误差值更小 (黑色为零误差)。表 1 所示为 5200 张二维 MRI 在一维高斯采样和二维高斯采样模式下, 通过不同算法重构出 MRI 的 PSNR 和 SSIM 两项定量指标的均值与方差。由于本实验采用数据是由三维 MRI 进行切片而来, 每张二维 MRI 结构存在较大的差异性, 故导致重构质量的不稳定, PSNR 存在较大的方差。表 1 结果表明 DAWGAN-GP 重构 MRI 的 PSNR 和 SSIM 平均值均明显高于其他方法, 但 PSNR 方差波动与其它算法的实验结果相差不大, 在同一采样率下 DAWGAN-GP 重构 MRI 的 SSIM 方差波动与其他算法相比有所减小。

由此可见, 在两种欠采样模式下 DAWGAN-GP 重构算法不管是在整体重构质量的量化指标还是在微观细节上图像重构视觉效果都优于其他重构方法, 该方法重构的 MRI 也更接近于全采样重构的 MRI。

表 1 不同算法下的 5200 张 MRI 重构质量平均值  $\pm$  方差 (PSNR/SSIM)

15800 images	Pixel-GAN		DAGAN		DAWGAN		DAWGAN-GP	
mask :1d Gaussian	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR
sample rate:10%	0.9363 $\pm$ 7.1807e-04	32.4700 $\pm$ 16.7086	0.9478 $\pm$ 4.4e-04	33.4711 $\pm$ <b>13.7840</b>	0.9700 $\pm$ 2.1551e-04	36.0302 $\pm$ 18.0622	<b>0.9724 <math>\pm</math></b> <b>1.8010e-04</b>	<b>36.4709 <math>\pm</math></b> 18.0549
sample rate:20%	0.9663 $\pm$ 1.1183e-04	37.0970 $\pm$ <b>14.0154</b>	0.9827 $\pm$ 5.5528e-05	39.6682 $\pm$ 17.6735	0.9906 $\pm$ 2.0525e-05	41.8865 $\pm$ 16.1775	<b>0.9923 <math>\pm</math></b> <b>1.3876e-05</b>	<b>42.6244 <math>\pm</math></b> 14.7777
sample rate:30%	0.9849 $\pm$ 4.0113e-05	39.7230 $\pm$ 15.4347	0.9854 $\pm$ 4.3986e-05	40.3395 $\pm$ 19.9671	0.9920 $\pm$ <b>1.4130e-05</b>	42.4669 $\pm$ <b>13.7906</b>	<b>0.9932 <math>\pm</math></b> 1.5925e-05	<b>42.8379 <math>\pm</math></b> 14.1086
mask :2d Gaussian	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR
sample rate:10%	0.9676 $\pm$ 1.7218e-04	37.4224 $\pm$ <b>18.5150</b>	0.9803 $\pm$ 1.0505e-04	39.5367 $\pm$ 23.8227	0.9876 $\pm$ 4.7438e-05	41.2353 $\pm$ 20.5399	<b>0.9893 <math>\pm</math></b> <b>3.4624e-05</b>	<b>41.8183 <math>\pm</math></b> 18.7702
sample rate:20%	0.9815 $\pm$ 4.4790e-05	40.5581 $\pm$ <b>15.0559</b>	0.9874 $\pm$ 5.0697e-05	41.5351 $\pm$ 23.6452	0.9891 $\pm$ 2.4193e-05	42.7260 $\pm$ 18.7412	<b>0.9922 <math>\pm</math></b> <b>1.9441e-05</b>	<b>43.2279 <math>\pm</math></b> 17.7346
sample rate:30%	0.9892 $\pm$ 3.9434e-05	42.4237 $\pm$ 28.1427	0.9929 $\pm$ 1.755e-05	44.0110 $\pm$ 23.1779	0.9941 $\pm$ 1.0709e-05	44.4851 $\pm$ 15.8162	<b>0.9952 <math>\pm</math></b> <b>1.0358e-05</b>	<b>44.6999 <math>\pm</math></b> <b>15.7907</b>

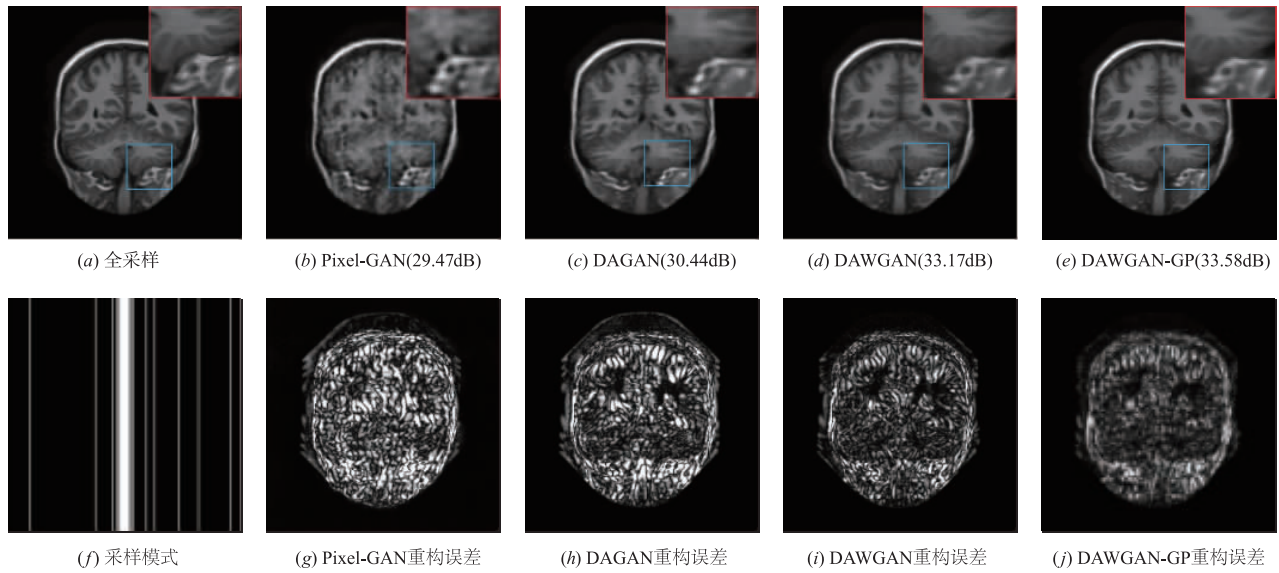


图3 在10%一维高斯采样模式下不同算法的二维MRI重构图

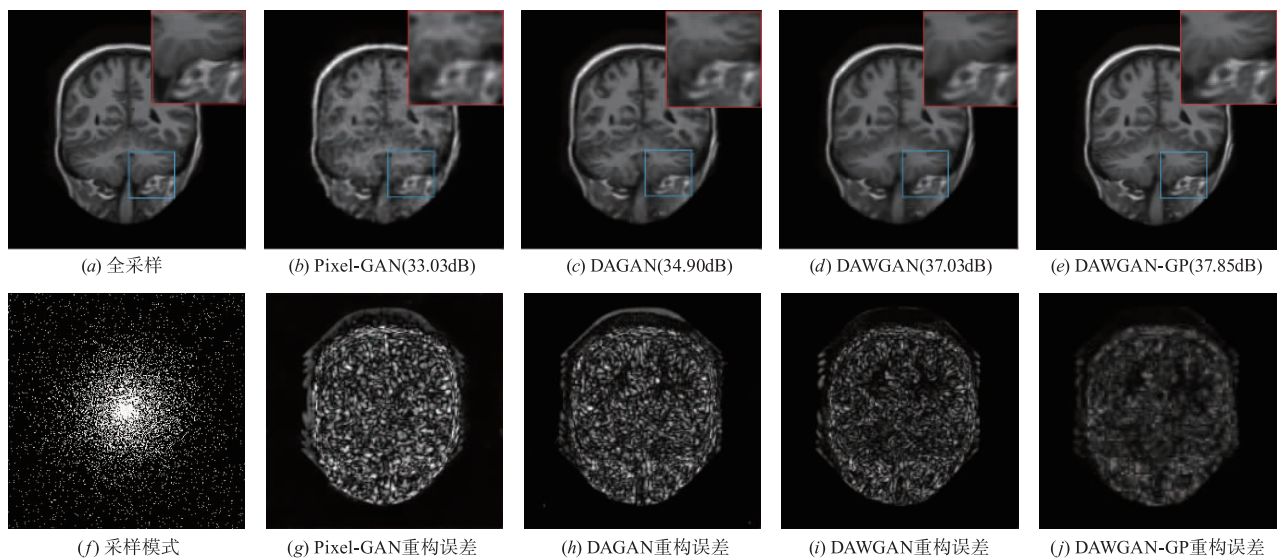


图4 在10%二维高斯采样模式下不同算法的二维MRI重构图

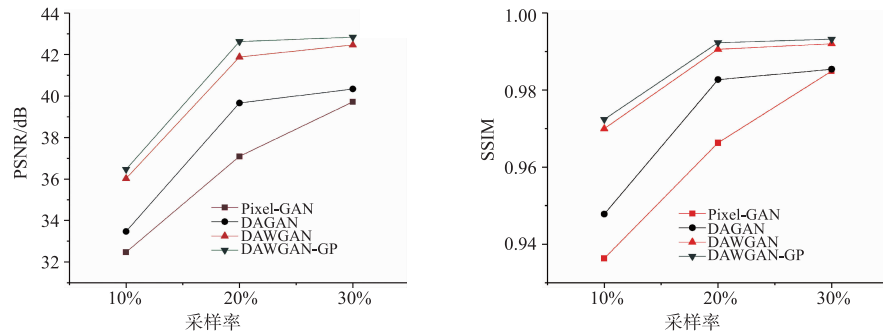
### 3.3 不同加速因子下重构性能的比较

图5和图6分别表示在一维高斯采样和二维高斯采样模式下, Pixel-GAN, DAGAN, DAWGAN和DAWGAN-GP四种重构算法在不同的加速因子下的PSNR和SSIM.从图5和图6中可以看出,随着采样率的减少,所有算法的重构质量下降,但不论在哪种采样模式和采样率下,DAWGAN-GP算法重构的磁共振图像都具有更高的PSNR和SSIM值,这表明该方法在任何重构条件下都具有适用性.从图5和图6的实验结果可以发现重构算法在相同采样率下,二维高斯采样模式往往比一维高斯采样重构效果更好,其原因与磁共振欠采样原理有关,二维采样模式能够在K空间中采集到更

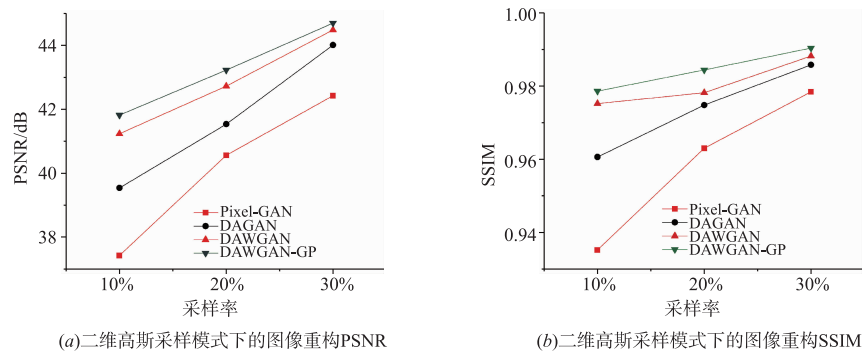
多的低频信息,而低频信息又是重构过程的关键.

### 3.4 梯度惩罚对网络训练的影响

基于DAWGAN-GP的磁共振图像重构方法的性能主要取决于梯度惩罚对网络的影响,我们将讨论梯度惩罚对图像重构质量的影响. WGAN在实验过程中虽效果优于原始GAN,但仍存在收敛速度慢,训练时梯度消失或爆炸等问题.这是因为WGAN在处理Lipschitz限制条件时直接采用了权重裁剪的方法,尽可能让所有参数走极端,要么取最大值要么取最小值.这虽然能够使得判别器的所有参数有界,但极端的参数经过多次迭代也很容易出现梯度消失或者梯度爆炸现象,导致网络无法进行学习.



(a)一维高斯采样模式下的图像重构PSNR (b)一维高斯采样模式下的图像重构SSIM  
图5 不同采样率在一维高斯采样模式下的图像重构质量



(a)二维高斯采样模式下的图像重构PSNR (b)二维高斯采样模式下的图像重构SSIM  
图6 不同采样率在二维高斯采样模式下的图像重构质量

Lipschitz 限制是要求判别器的梯度不超过常数  $K$ , 而 WGAN-GP 就是设置一个额外的梯度惩罚项来实现梯度与  $K$  之间的联系. 实验结果表明, 梯度惩罚能显著提高模型重构图像的能力, 使重构的磁共振图像能够收敛得到更高的 PSNR 和更小的 NMSE, 如图 7 ~ 8 所示.




图7 在10%一维高斯采样模式下梯度惩罚对图像PSNR的影响

针对 DAWGAN 收敛缓慢问题, 将进一步分析结合梯度惩罚方法的 DAWGAN-GP 是否能有效提高模型训练的收敛速度. 在 10% 一维高斯采样模式下对 DAWGAN 和 DAWGAN-GP 两种方法的生成器损失收敛速度进行比较, 如图 9 所示. 相比于 DAWGAN 方法, DAWGAN-GP 收敛速度更快, 在经过初始 5 轮迭代后, 就可以获得更小的生成器损失目标函数; 随后, DAWGAN-

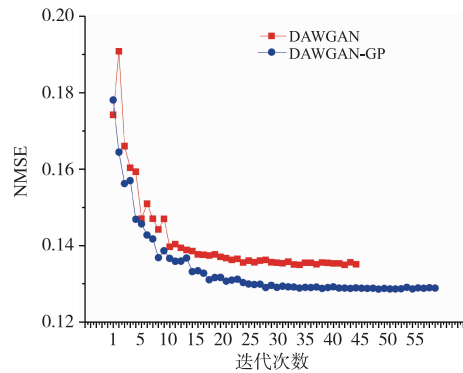


图8 在10%一维高斯采样模式下梯度惩罚对图像NMSE的影响

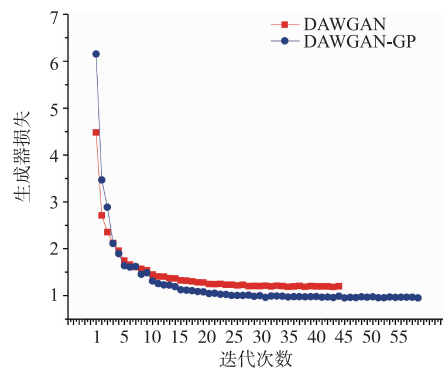


图9 在10%一维高斯采样模式下不同方法的收敛性分析  
GP 进一步加速收敛至更小的损失函数值. 通过实验结

果表明,结合梯度惩罚的 DAWGAN-GP 方法可有效解决 DAWGAN 收敛缓慢问题,在训练时收敛速度快,可以快速收敛到更好的目标函数值,实现重构更高质量的磁共振图像.

#### 4 结论

本论文提出了一种基于改进 Wasserstein 生成式对抗网络的磁共振图像重构方法,该方法利用 Wasserstein 生成式对抗网络代替传统的生成式对抗网络,并结合梯度惩罚的方法提高训练速度.同时,该算法结合了感知损失,像素损失和频域损失,采用多个评价标准以确保在宏观和微观上都有更好地重构效果.实验结果表明,相比现有基于深度学习的磁共振重构算法,本文提出的算法可以有效地提高 MRI 重构精度,减少磁共振图像重构误差,避免信息丢失.在未来的工作中,我们会引入更加复杂的网络结构进行优化模型,并将其应用于三维动态磁共振成像研究中.

#### 参考文献

- [1] Donoho D L. Compressed sensing [J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289 - 1306.
- [2] Lustig M, Donoho D L, Santos J M, et al. Compressed sensing MRI [J]. IEEE Signal Processing Magazine, 2008, 25(2): 72 - 82.
- [3] Yang Y, Liu F, Li M, et al. Pseudo-polar Fourier transform based compressed sensing MRI [J]. IEEE Transactions on Biomedical Engineering, 2017, 64(4): 816 - 825.
- [4] 蒋明峰, 陆亮, 吴龙, 等. 基于加权 Schatten  $p$  范数最小化的磁共振图像重构方法研究 [J]. 电子学报, 2019, 47(4): 784 - 790.  
JIANG Ming-feng, LU Liang, WU Long, et al. The research of MRI reconstruction method by using weighted Schatten  $P$ -norm minimization [J]. Acta Electronica Sinica, 2019, 47(4): 784 - 790. (in Chinese)
- [5] Liu S, Cao J, Wu G, et al. CS-MRI reconstruction via group-based Eigenvalue decomposition and estimation [J]. Neurocomputing, 2018, 283: 166 - 180.
- [6] Feng L, Srichai M B, Lim R P, et al. Highly accelerated real-time cardiac cine MRI using  $k$ - $t$  sparse-sense [J]. Magnetic Resonance in Medicine, 2013, 70(1): 64 - 74.
- [7] Feng L, Grimm R, Block K T, et al. Golden-angle radial sparse parallel MRI: Combination of compressed sensing, parallel imaging, and golden-angle radial sampling for fast and flexible dynamic volumetric MRI [J]. Magnetic Resonance in Medicine, 2015, 72(3): 707 - 717.
- [8] Wang S, Tan S, Gao Y, et al. Learning joint-sparse codes for calibration-free parallel MR imaging (LINDBERG) [J]. IEEE Transactions on Medical Imaging, 2018, 37(1): 251 - 261.
- [9] Huang Y, Paisley J, Lin Q, et al. Bayesian nonparametric dictionary learning for compressed sensing MRI [J]. IEEE Transactions on Image Processing, 2013, 23(12): 5007 - 5019.
- [10] Zhan Z, Cai J F, Guo D, et al. Fast multi-class dictionaries learning with geometrical directions in MRI reconstruction [J]. IEEE Transactions on Biomedical Engineering, 2016, 63(9): 1850 - 1861.
- [11] Lecun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436 - 444.
- [12] 罗会兰, 童康, 孔繁胜. 基于深度学习的视频中人体动作识别进展综述 [J]. 电子学报, 2019, 47(5): 1162 - 1173.  
LUO Hui-lan, TONG Kang, KONG Fan-sheng. The progress of human action recognition in videos based on deep learning: a review [J]. Acta Electronica Sinica, 2019, 47(5): 1162 - 1173. (in Chinese)
- [13] Wang S, Su Z, Ying L, et al. Accelerating magnetic resonance imaging via deep learning [A]. Proceedings of the IEEE International Symposium on Biomedical Imaging [C]. Piscataway: IEEE, 2016. 514 - 517.
- [14] Yan Y, Huibin L, Zongben X, et al. Deep ADMM-Net for compressive sensing MRI [A]. Proceedings of the Advances in Neural Information Processing Systems [C]. New York: NIPS, 2016. 10 - 18.
- [15] Boyd S, Parikh N, Chu E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers [J]. Foundations and Trends in Machine Learning, 2011, 3(1): 1 - 122.
- [16] Yang G, Yu S, Dong H, et al. DAGAN: Deep de-aliasing generative adversarial networks for fast compressed sensing MRI reconstruction [J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1310 - 1321.
- [17] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [A]. Proceedings of the Advances in Neural Information Processing Systems [C]. New York: NIPS, 2014. 2672 - 2680.
- [18] Arjovsky M, Chintala S, Bottou L. Wasserstein GAN [A]. Proceedings of the International Conference on Machine Learning [C]. New York, 2017. 214 - 223.
- [19] Gulrajani I, Ahmed F, Arjovsky M, et al. Improved training of Wasserstein GANs [A]. Proceedings of the Advances in Neural Information Processing Systems [C]. New York: NIPS, 2017. 5767 - 5777.
- [20] Johnson J, Alahi A, Fei-Fei L. Perceptual losses for real-time style transfer and super-resolution [A]. Proceedings of the European Conference on Computer Vision [C]. Berlin, 2016. 694 - 711.
- [21] Arjovsky M, Bottou L. Towards principled methods for

training generative adversarial networks [A]. Proceedings of the International Conference on Learning Representa-


tions [C]. Toulon, 2017. 1 - 17.

### 作者简介



**蒋明峰** 男, 1977 年生于江西丰城, 现为浙江理工大学信息学院教授、硕士生导师, 主要研究方向为计算机医学图像处理、生物医学信号处理.

E-mail: m. jiang@zstu. edu. cn



**袁子晗** 男, 1995 年生于河南濮阳, 现为浙江理工大学信息学院硕士研究生, 主要研究方向为医学图像处理.

E-mail: 1192128469@qq. com