

# 基于残差通道注意力网络的医学图像 超分辨率重建方法

刘可文<sup>1,2</sup>, 马圆<sup>1,2</sup>, 熊红霞<sup>3\*</sup>, 严泽军<sup>4</sup>, 周志军<sup>5</sup>, 刘朝阳<sup>6</sup>, 房攀攀<sup>1,2</sup>, 李小军<sup>1,2</sup>, 陈亚雷<sup>1,2</sup>

<sup>1</sup> 武汉理工大学信息工程学院, 湖北 武汉 430070;

<sup>2</sup> 武汉理工大学宽带无线通信和传感器网络湖北省重点实验室, 湖北 武汉 430070;

<sup>3</sup> 武汉理工大学土木工程与建筑学院, 湖北 武汉 430070;

<sup>4</sup> 宁波市第一医院泌尿外科泌尿系疾病转化医学研究宁波市重点实验室, 浙江 宁波 315010;

<sup>5</sup> 湖北省天门市第一人民医院泌尿外科, 湖北 天门 431700;

<sup>6</sup> 中国科学院武汉物理与数学研究所波谱与原子分子物理国家重点实验室, 湖北 武汉 430071

**摘要** 针对医学图像超分辨率重建过程中高频信息缺失导致的模糊问题, 提出了一种基于残差通道注意力网络的医学图像超分辨率方法。提出的方法在残差网络的基本单元上去除了批规范化层以稳定训练; 去掉缩放层、添加通道注意力块, 使神经网络更加关注含有丰富高频信息的通道; 使用亚像素卷积层进行上采样操作得到最终输出的高分辨率图像。实验结果表明, 提出的方法相比主流的图像超分辨率方法在客观评价指标如峰值信噪比和结构相似性上有显著提升, 得到的医学图像纹理细节丰富, 视觉体验较好。

**关键词** 图像处理; 医学图像处理; 图像超分辨率; 残差网络; 通道注意力机制; 亚像素卷积

中图分类号 TP183

文献标志码 A

doi: 10.3788/LOP57.021014

## Medical-Image Super-Resolution Reconstruction Method Based on Residual Channel Attention Network

Liu Kewen<sup>1,2</sup>, Ma Yuan<sup>1,2</sup>, Xiong Hongxia<sup>3\*</sup>, Yan Zejun<sup>4</sup>,  
Zhou Zhijun<sup>5</sup>, Liu Chaoyang<sup>6</sup>, Fang Panpan<sup>1,2</sup>, Li Xiaojun<sup>1,2</sup>, Chen Yalei<sup>1,2</sup>

<sup>1</sup> School of Information Engineering, Wuhan University of Technology, Wuhan, Hubei 430070, China;

<sup>2</sup> Hubei Key Laboratory of Broadband Wireless Communication and Sensor Networks, Wuhan University of Technology, Wuhan, Hubei 430070, China;

<sup>3</sup> School of Civil Engineering & Architecture, Wuhan University of Technology, Wuhan, Hubei 430070, China;

<sup>4</sup> Department of Urology, Ningbo First Hospital, Key Laboratory of Translational Medicine of Urological Diseases in Ningbo, Ningbo, Zhejiang 315010, China;

<sup>5</sup> Department of Urology, the First People's Hospital of Tianmen, Tianmen, Hubei 431700, China;

<sup>6</sup> State Key Laboratory of Magnetic Resonance and Atomic Molecular Physics, Wuhan Institute of Physics and Mathematics, Chinese Academy of Sciences, Wuhan, Hubei 430071, China

**Abstract** To resolve the fuzzy problem caused by the lack of high-frequency information in the super-resolution reconstruction of medical images, this study proposes a medical-image super-resolution reconstruction method based on a residual channel attention network. The proposed method removes the batch normalization layer from the basic unit of the residual network (ResNet) to stabilize its training. Furthermore, it removes the scaling layer and adds a channel-attention block that focuses the ResNet on channels with abundant high-frequency details. The feature maps are subsampled using a sub-pixel convolution layer, obtaining the final high-resolution images. Experimental results

收稿日期: 2019-06-04; 修回日期: 2019-07-03; 录用日期: 2019-07-11

基金项目: 国家重点研发计划(2018YFC0115000)

\* E-mail: xionghongxia@whut.edu.cn

show that the proposed method significantly improves objective evaluation indexes such as the peak signal-to-noise ratio and structural similarity index compared with mainstream image super-resolution methods. The obtained medical images are sufficiently detailed with high visual quality.

**Key words** image processing; medical image processing; image super-resolution; residual network; channel attention; sub-pixel convolution

**OCIS codes** 100.2000; 100.6640; 100.3008

## 1 引言

随着人工智能技术的快速发展,图像超分辨率(SR)<sup>[1-3]</sup>方法在医学影像、计算机辅助诊断、卫星遥感等领域得到了大量的应用<sup>[4-6]</sup>,成为了医学图像处理和计算机视觉领域的研究热点。将低分辨率的医学图像进行超分辨率重建,得到的高清医学图像能使医生更清楚地看到生物组织结构及其早期病变,为医生对疾病的诊断和治疗提供辅助及支持<sup>[7-11]</sup>。

根据实现原理的不同,可以将图像超分辨率方法分为基于插值、基于重建以及基于学习的方法<sup>[12]</sup>。基于插值的方法例如双三次插值法,作为一种非迭代的空域算法,具有计算高效的特点,但很容易在边缘细节处理上丢失高频细节信息。基于重建的方法如迭代反投影法<sup>[13]</sup>,利用复杂的先验信息约束解空间,和基于插值的算法相比,重建效果有一定改善,但根据先验建立的成像模型很难确定,输入的低分辨率图像尺寸较小时,能有效用于建模的先验信息较少,超分辨率效果比较差。基于学习的方法分为基于压缩感知<sup>[14]</sup>和基于深度学习<sup>[15]</sup>的方法。压缩感知指利用信号的稀疏性来寻找欠定线性系统的稀疏解,从较少的采样样本中还原信号,相比 Nyquist 采样定理,能更高效地采样信号<sup>[14]</sup>。Yang 等<sup>[14]</sup>首次将压缩感知理论引入到图像超分辨率领域,提出了基于稀疏表示的方法,该方法同时学习高分辨率字典和低分辨率字典,使高分辨率及相应的低分辨率图像块在各自的字典下有着相同的稀疏编码。Dong 等<sup>[15]</sup>首先提出基于卷积神经网络(CNN)的简单网络模型 SRCNN(Super-Resolution CNN),该方法分为特征提取、非线性映射、上采样重建三个阶段,实现低、高分辨率图像之间的端到端映射,基于卷积神经网络的方法不再是显性地学习外部字典,而是隐性地学习网络中间各层的卷积核参数,这种方法有着比传统方法更好的泛化能力及表达高层次特征的能力。Kim 等<sup>[16]</sup>提出的 VDSR(very deep super-resolution algorithm)在 SRCNN 的基础上将网络层数扩展到 20 层,同时引入了全局跳连结构,学习低、高分辨率图像之间的残差,改善了梯度消失

与网络退化问题。SRCNN 和 VDSR 都需要先将输入的低分辨率图像插值放大,再对放大的图像进行卷积运算,而 Shi 等<sup>[17]</sup>提出的亚像素卷积方法 ESPCN(Efficient sub-pixel CNN)和 Dong 等<sup>[18]</sup>提出的 FSRCNN(Fast-SRCNN)则是直接在低分辨率图像上进行卷积运算,在图像的最后一层对图像的大小进行变换,重建效率更高。He 等<sup>[19]</sup>提出的残差网络(ResNet)通过搭建多个残差块组成深度网络,改善了随着网络加深带来的梯度消失、网络退化等问题。Ledig 等<sup>[20]</sup>结合 ResNet 提出了 SRResNet(Super-resolution ResNet),SRResNet 中引入了丰富的全局和局部跳连结构,使得大量的低频信息可以直接被跳连结构传输到网络顶层,这样的结构使整个网络具有了梯度消失减轻、特征传播加强的优点。Lim 等<sup>[21]</sup>提出的 EDSR(Enhanced super-resolution algorithm)在 ResNet 的基础上去除了批规范化层以稳定训练,使用了更多的卷积核,引入残差学习来改善深层网络训练困难的问题。

注意力机制旨在使神经网络更加关注具有更多高频信息的区域或通道,根据关注点的不同,注意力机制可分为空间注意力机制与通道注意力机制。Hu 等<sup>[22]</sup>提出的通道注意力块可以自适应地给不同通道赋不同的权值,放大含有丰富高频信息的通道的权重,缩小含有大量冗余低频信息的通道的权重,这样的结构可以加速网络收敛、进一步提升网络性能。

针对医学图像超分辨率重建过程中缺失高频信息导致的模糊问题,本文提出了一种基于残差通道注意力网络的医学图像超分辨率重建方法。基础网络结构设计为残差神经网络,引入了全局跳连结构,学习低、高分辨率图像之间的残差,同时在网络的基本单元内添加了局部跳连结构,改善了梯度消失与网络退化问题;去除网络的基本单元中 ResNet 原有的批规范化层以避免损失高频纹理细节信息;在每个基本单元的最后添加通道注意力机制块,使神经网络更加关注含有丰富高频信息的特征图通道,加速网络收敛,进一步提升网络的性能;在网络顶层的上采样部分,采用亚像素卷积得到最终输出的高分辨率图像。将本文提出的方法应用于模糊肺癌

CT 图像超分辨率重建和模糊前列腺癌 MRI (Magnetic Resonance Imaging) 图像超分辨率重建, 实验结果表明, 执行该方法得到的超分辨率放大两倍时的 CT、MRI 图像具有较好的图像锐度, 依然保留了较多的纹理细节。该方法除了可应用于 CT、MRI 图像, 也可将网络结构迁移应用于 X 射线图像和正电子发射计算机断层扫描图像超分辨率重建, 具有较好的普适性。

## 2 相关理论

### 2.1 残差学习

残差学习的基本单元如图 1 所示。

残差学习的特点是在原始卷积神经网络的基础上增加跳连结构, 使原始输入可以直接通过跳连结构传输到网络的顶层, 从而使原始学习  $\varphi(x)$  的任务转换为学习输入与输出之间的残差  $F(x)$ , 相比直接学习  $\varphi(x)$ , 学习  $F(x)$  更容易。在图像超分辨率中, 输入与输出图像具有一定程度的相似性, 残差特征图比较稀疏, 这意味着残差神经网络在前向传播时不需要携带大量的记忆。在反向传播时, 网络




图 1 残差学习的基本单元

Fig. 1 Basic unit of residual learning

顶层的梯度信息可以通过跳连结构直接传输到网络底层, 可以有效缓解梯度消失与网络退化问题。残差学习的网络结构使训练深层的网络更容易, 因此可以通过增加网络层数进一步提升网络的性能。

鉴于残差神经网络具有改善梯度消失和网络退化的能力, 本文方法基于残差神经网络结构设计。

### 2.2 通道注意力机制

在网络中添加通道注意力块可以使网络在训练中更加关注含有丰富高频信息的通道, 加速网络收敛, 进一步提升网络性能。通道注意力机制块如图 2 所示。




图 2 通道注意力机制块

Fig. 2 Channel-attention mechanism block

输入、输出特征图的维度均为  $H \times W \times C$ ,  $H$  为特征图的高度,  $W$  为特征图的宽度,  $C$  为特征图的通道数; Conv 为卷积操作, ReLU 与 Sigmoid 为两种不同的激活函数<sup>[23]</sup>,  $\otimes$  为 Hadamard 乘积<sup>[24]</sup>。输入维度为  $H \times W \times C$  的特征图, 经过全局池化 (Global pooling) 获取逐通道统计  $\mathbf{z} \in \mathbf{R}^C$ ,  $\mathbf{z}$  的第  $c$  个元素为

$$z_c = H_{GP}(x_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j), \quad (1)$$

式中:  $x_c$  为输入特征图的第  $c$  个通道;  $x_c(i, j)$  指第  $c$  个通道内位置为  $(i, j)$  的图像像素值;  $H_{GP}(\cdot)$  为全局池化。经过全局池化得到的逐通道统计可以看作一系列的描述符 (descriptor), 用于描述各个通道。一系列描述符经过级联的两次卷积、激活, 得到的经过缩放的描述符为

$$\mathbf{s} = f[\mathbf{W}_U \delta(\mathbf{W}_D \mathbf{z})], \quad (2)$$

式中:  $\mathbf{W}_D$  为第一层卷积的权值, 第一层卷积完成因子为 16 的描述符降维, 生成大小为  $1 \times 1 \times C/16$  的描述符;  $\delta(\cdot)$  为 ReLU 激活;  $\mathbf{W}_U$  为第二次卷积的权值, 第二次卷积完成因子为 16 的描述符升维, 将其恢复为大小为  $1 \times 1 \times C$  的描述符;  $f(\cdot)$  为 Sigmoid 激活函数。将经过缩放的描述符  $\mathbf{s}$  与原输入进行逐通道 Hadamard 相乘, 得到通过通道注意力块的特征表示。

鉴于添加的通道注意力块具有加速网络收敛、进一步提升网络性能的能力, 本文提出的方法在基于残差神经网络的结构基础上引入了通道注意力机制。

## 3 基于残差通道注意力的网络结构

### 3.1 网络结构

基于深度残差通道注意力的网络结构的基本单




图 3 基于深度残差通道注意力的网络结构。(a)基本单元;(b)网络结构

Fig. 3 Network structure based on deep residual channel attention. (a) Basic unit; (b) network structure

元如图 3(a)所示,其中 $\oplus$ 为逐像素相加。基本单元由级联的卷积、激活、卷积、通道注意力块组成,基本单元内添加了局部跳连结构(Local skip connection),用于改善梯度消失与网络退化问题。具体来说,输入基本单元的特征图,先进行卷积操作,获得更深层次的特征表示,卷积层的参数设置为 $3 \times 3 \times 256 \times 256$ ,即 256 个大小为 $3 \times 3$ 的卷积核,每个卷积核的通道数为 256,卷积操作的步长为 1,在边缘使用补零(Zero padding)操作,用以保持输入输出特征图的尺寸一致。卷积得到的特征图再经过通道注意力块(channel-attention block),再输出至级联的下一级基本单元提取更深层次的特征。

网络的整体示意图如图 3(b)所示,其中 sub-pixel conv 为亚像素卷积层。整体网络结构由三部分:特征提取、非线性映射和亚像素卷积上采样组成。特征提取由卷积层组成,卷积核参数设置为 $3 \times 3 \times 256$ ,即 256 个大小为 $3 \times 3$ 的卷积核,每个卷积核的通道数为 3。非线性映射阶段由 32 个级联的残差基本单元组成,基本单元内添加了局部跳连结构,同时引入全局跳连结构(global skip connection)直接将网络顶层和底层连接起来,学习残差,改善梯度消失和网络退化问题,降低训练深层

网络的难度;最后使用亚像素卷积层(sub-pixel convolution)和卷积完成上采样,得到最终输出的高分辨率图像。

### 3.2 损失函数

参考文献[25],采用均方误差  $L_{MSE}$  衡量得到高分辨率图像和真实高分辨图像的相似程度,用于指导网络训练。 $L_{MSE}$  为

$$L_{MSE} = \frac{1}{n \times H \times W \times C} \sum_{v=1}^n \sum_i^W \sum_j^H \sum_k^C (I_{v,i,j,k}^{HR} - I_{v,i,j,k}^{SR})^2, \quad (3)$$

式中: $I^{HR}$ 为真实的高分辨率图像; $I^{SR}$ 为经过超分辨率得到的高分辨率图像; $H \times W$ 为特征图的尺寸; $C$ 为特征图的通道数; $n$ 为小批量(mini-batch)学习样本的大小; $I_{v,i,j,k}$ 为第  $v$  张图像的第  $k$  个通道的位置  $(i, j)$  处的像素值。网络训练的目标是极小化均方误差  $L_{MSE}$ ,  $L_{MSE}$  的值越小,真实高分辨率图像与生成的高分辨率图像的差异越小,超分辨率的精度越高。

### 3.3 实验参数设置与训练过程

首先对训练数据进行预处理,对输入图像进行

表1 实验环境参数

Hardware configuration	Parameter
CPU	Intel Xeon E3-1231 V3
RAM	16G
GPU	1070Ti
GPU Memory	8G
Development Framework	Pytorch1.1

研究将完成单帧图像超分辨率所需的时间也作为参考的客观评价指标之一。

参考文献[21]的具体计算方式:首先将得到的高分辨率图像与真实的高分辨率图像进行裁剪,去掉图像边缘数量为放大因子的像素点;然后将图像由RGB色彩空间转换为YCbCr色彩空间<sup>[29]</sup>,取出Y通道图像,只在Y通道上计算客观指标。MSE的计算公式为

$$R_{MSE} = \frac{1}{W \times H} \sum_{i=1}^W \sum_{j=1}^H (I_{i,j}^{HR} - I_{i,j}^{SR})^2, \quad (4)$$

式中: $I^{HR}$ 为真实的高分辨率图像; $I^{SR}$ 为执行超分辨率得到的高分辨率图像; $I_{i,j}$ 为图像位置 $(i,j)$ 处的像素值。MSE的值越小,说明超分辨率得到的图像质量越好。SNR的计算公式为

$$R_{SNR} = 10 \lg \frac{(I_{i,j}^{HR})^2}{(I_{i,j}^{HR} - I_{i,j}^{SR})^2}. \quad (5)$$

SNR的值越大,超分辨率得到的图像质量越好。

PSNR的计算公式为

$$R_{PSNR} = 10 \lg \left( \frac{255^2}{R_{MSE}} \right). \quad (6)$$

PSNR的值越大,超分辨率得到的图像质量越好。

SSIM的计算公式为

$$R_{SSIM}(x, y) = \frac{2u_x u_y + C_1}{u_x^2 + u_y^2 + C_1} \times \frac{2\sigma_x \sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \times \frac{\sigma_{xy} + C_3}{\sigma_x \sigma_y + C_3}, \quad (7)$$

式中: $u, \sigma$ 分别为两幅图像的像素均值和方差; $C_1, C_2, C_3$ 为防止分母为0的常数。SSIM的取值范围为 $[0, 1]$ ,数值越接近1,表明对比的两幅图像越相似。

将各个测试集上每张医学影像对应得到的MSE、SNR、PSNR和SSIM数据平均化,得到各方法在各个测试集上的平均客观评价结果。各超分辨率方法的评价指标值如表2所示。

从表2各超分辨率方法的实验数据可以看出,所提方法的客观评价结果显著优于对照方法。以在肺部CT图像测试集上的表现为例,此方法在

裁剪,裁剪为大小为 $96 \text{ pixel} \times 96 \text{ pixel}$ 的子图,使用Matlab的`imresize`函数对裁剪得到的子图进行双三次下采样操作,得到对应的下采样两倍的低分辨率图像,即 $96 \text{ pixel} \times 96 \text{ pixel}$ 的图像经下采样两倍得到 $48 \text{ pixel} \times 48 \text{ pixel}$ 的图像,使用了数据增强如旋转、镜像等,获得了更多的训练样本。训练过程采用小批量(mini-batch)学习,由于硬件资源的限制,小批量学习的数目设置为16。使用Adam优化算法优化网络<sup>[26]</sup>, $\beta_1$ 设置为0.9, $\beta_2$ 设置为0.999, $\epsilon$ 设置为 $10^{-8}$ 。初始学习率设置为 $10^{-4}$ ,迭代 $1.5 \times 10^5$  mini-batch后使学习率减半,再迭代 $1.5 \times 10^5$  mini-batch,确保训练至最优。

## 4 实验仿真与结果分析

使用两种不同的医学图像数据集用于实验仿真。第一种是美国国家肺癌中心的肺癌CT公开数据集<sup>[27]</sup>,从中挑选了400张纹理丰富、清晰度高的大小为 $512 \text{ pixel} \times 512 \text{ pixel}$ 的横切面CT图像作为训练集,挑选了100张横切面CT图像作为测试集。第二种数据集是荷兰奈梅亨拉德堡德大学医疗中心的前列腺MRI公开数据集<sup>[28]</sup>,该数据集包含T2W、PD-W、DCE和DW图像,所有的图像来源于两种不同的西门子3T-MR扫描仪,分别是MAGNETOM Trio和Skyra,T2W图像通过涡轮自旋回波序列采集得到,平面分辨率为0.5 mm,切片厚度为3.6 mm。从中挑选了400张清晰度高、细节丰富的大小为 $384 \text{ pixel} \times 384 \text{ pixel}$ 的T2W前列腺MRI图像作为训练集,挑选了100张T2W前列腺MRI图像作为测试集。

选取了两种传统的超分辨率方法和六种具有代表性的基于深度学习的方法作为对照,选取的传统方法是双线性插值法(Bilinear)与双三次插值法(Bicubic),选取的基于深度学习的方法为SRCNN<sup>[15]</sup>、ESPCN<sup>[17]</sup>、FSRCNN<sup>[18]</sup>、SRResNet<sup>[20]</sup>、VDSR<sup>[16]</sup>与EDSR<sup>[21]</sup>。为保证对比的公正性,在相同的硬件环境下使用部分作者开源的代码对对照实验进行了复现,对照方法的网络参数设置均为最优,实验的硬件环境参数如表1所示。

### 4.1 客观评价

均方误差(MSE)、信噪比(SNR)、峰值信噪比(PSNR)和结构相似性(SSIM)被广泛用于评价图像去噪、图像去除伪影、图像超分辨率的效果,本研究选用上述指标作为客观评价的指标。同时,超分辨率算法的实时性也是判别算法优劣的主要指标,本

表 2 各超分辨率方法的客观评价对比

Table 2 Objective evaluation of each super-resolution method

Method	Lung CT image testing set					Prostate MRI image testing set				
	MSE	SNR /dB	PSNR /dB	SSIM	Time /s	MSE	SNR /dB	PSNR /dB	SSIM	Time /s
Bilinear	366.0564	3.8746	22.7222	0.72824	0.0498	233.7763	6.0589	24.457	0.79361	0.0380
Bicubic	286.6879	4.3645	23.8058	0.79107	0.0505	180.016	7.1662	25.5926	0.85839	0.0406
ESPCN	148.2858	4.9720	27.1032	0.85065	0.1774	84.8268	7.6330	28.8576	0.90677	0.1542
SRCNN	138.0596	5.1149	27.5442	0.85281	0.2471	73.1347	7.9603	29.5002	0.90909	0.2146
FSRCNN	136.5873	5.1170	27.6013	0.85370	0.2579	70.3323	8.1547	29.6716	0.91008	0.2226
SRResNet	100.8272	5.7331	29.6335	0.86773	0.3402	20.5025	9.7195	35.0589	0.93164	0.3495
VDSR	100.7198	5.9098	29.7222	0.86756	0.3698	19.9907	10.1670	35.1910	0.92892	0.3794
EDSR	100.6880	6.0319	29.8013	0.87068	0.3944	19.0991	10.3805	35.3742	0.93266	0.3828
Proposed	94.8284	6.0913	29.9796	0.87213	0.4321	17.1458	10.7339	35.8514	0.9345	0.4226

PSNR 和 SSIM 上相比 Bilinear 方法与 Bicubic 方法分别有 6.1738 dB ~ 7.2574 dB 和 8.106% ~ 14.389% 的提升;相比基于深度学习的方法也有明显提升:相比 ESPCN、SRCNN、FSRCNN、SRResNet、VDSR、EDSR 方法分别有 0.178 dB ~ 2.876 dB 和 0.145% ~ 2.148% 的提升。单帧图像超分辨率耗时方面,Bilinear 方法最快,选取的基于深度学习的方法的耗时均高于 Bilinear 方法,所提方法牺牲了少量时间,提升了精度,且耗时均在 0.5 s 内,实时性较好,可应用于医学临床辅助诊断。除此之外,本文方法在前列腺 MRI 图像测试集上的表现均明显优于对照方法,充分证明了本文方法的优越性以及普适性。

各方法在肺部 CT 数据集和前列腺 MRI 数据集上的损失曲线如图 4、5 所示。以图 4 所示的曲线为例,可以看到,随着迭代次数的增加,各方法的损失整体呈现下降趋势,曲线后段趋于平缓,本文方法除了在迭代至  $10^4$  mini-batch 左右时遭遇较大的错误梯度导致损失短暂上升,其余阶段的收敛速度明显优于对照方法。迭代至  $1.5 \times 10^5$  mini-batch 使学习率减半,本文方法进一步快速收敛,且损失函数平稳时的损失低于对照方法。上述实验数据充分说明添加通道注意力块可加速网络收敛、进一步提升网络性能。

#### 4.2 主观评价

为展示各超分辨率方法的处理效果,选取四组纹理丰富、细节复杂的医学影像进行对比,分别是肺尖部、肺叶的横切面 CT 图像以及两组前列腺 MRI 图像。各方法的超分辨率效果图对比与相应的客观评价指标值如图 6 所示。整体看来,执行基于深度学习的方法超分辨率的效果明显优于传统基于插值的方法。基于深度学习的对比方法和本文方法均得到了效果较好的高分辨率图像,但对于某些部位,可

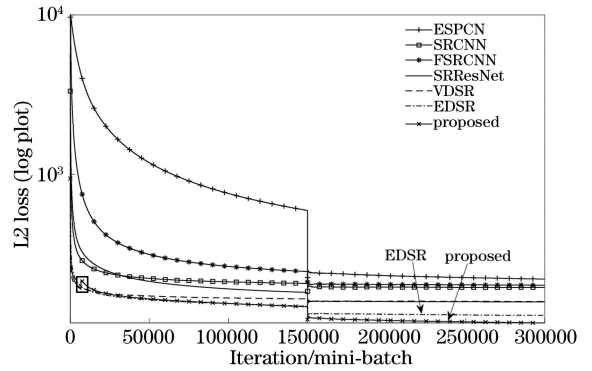


图 4 各方法在肺部 CT 数据集上的损失曲线

Fig. 4 Loss curve of each method on lung CT dataset

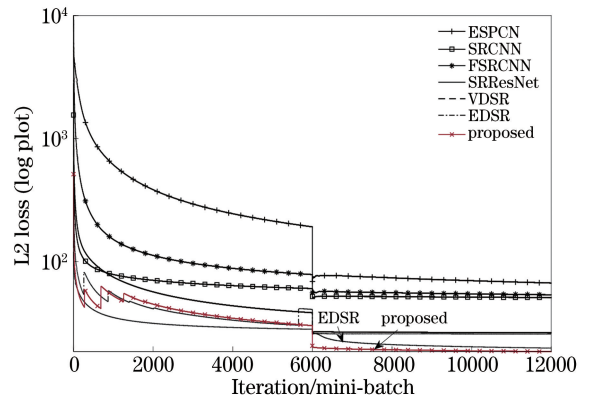


图 5 各方法在前列腺 MRI 数据集上的损失曲线

Fig. 5 Loss curve of each method on prostate MRI dataset

以看出本文方法具有更加逼真的纹理细节。具体来说,以图 6 所示的肺尖部影像和肺叶影像为例,基于插值的方法得到的图像整体看起来比较模糊;执行 ESPCN、SRCNN、FSRCNN 方法得到的图像,其图像锐度有了一定提升,但视觉上显得比较平滑,仍然存在模糊、分辨率低等缺点;执行 SRResNet、VDSR、EDSR 方法得到的图像具有较好的图像锐度,视觉效果也较好,但在图像的中下区标示区域出现了模糊伪影以及棋盘效应;本文方法具有较好的




图 6 各方法下超分辨率放大两倍后的图像效果图比较。(a)肺尖部横切面 CT;(b)肺叶横切面 CT;  
(c)前列腺 T2 加权横切面 MRI;(d)前列腺 T2 加权横切面 MRI

Fig. 6 Comparison of rendering of images with super-resolution magnification of 2 under each super resolution method.  
(a) Lung tip tra CT; (b) lung leaf tra CT; (c) prostateX-0061 T2\_tse\_tra MRI; (d) prostateX-0082 T2\_tse\_tra MRI

图像锐度,视觉效果好,图像清晰、亮度均匀、细节真实,没有出现模糊伪影,重建的图像最接近真实图像。

### 4.3 综合评价

从实验数据表 2 和各超分辨率方法效果对比图 6 可以看出,基于深度残差通道注意力网络的医学图像超分辨率方法客观指标高、纹理细节丰富、视觉体验较好。此方法在整个测试集上的客观评价指标(MSE、SNR、PSNR、SSIM)均高于传统基于插值的方法和基于深度学习 ESPCN、SRCNN、FSRCNN、SRResNet、VDSR、EDSR 的方法;从各超分辨率方法效果对比图图 6 可以看出,本文方法能重建出质量较高、具有更加逼真纹理细节、图像锐度更好的医学图像,重建的图像更加细腻,视觉体验较好,最接近真实高分辨率图像。该方法除了可应用于 CT 和 MRI 图像,也可将网络结构迁移,应用于 X 射线图像和正电子发射计算机断层扫描图像超分辨率,具有较好的普适性。

综上所述,基于深度残差通道注意力网络的医学图像超分辨率方法优于传统基于插值的方法和主流基于深度学习的方法。

## 5 结 论

本文融合残差神经网络和通道注意力机制,针对医学图像超分辨率重建过程中存在的细节丢失、含有模糊伪影等问题,提出了一种有效的超分辨率方法。该方法对于医生更加准确地发现病灶,提高临床诊断精确度具有重要的意义,该方法也为医学图像超分辨率重建方法的理论研究提供了新的思路。

下一阶段的主要改进方向有:提出一种以任意尺度执行超分辨率的算法,更贴近实际应用场景;充分利用医学图像序列之间的相关性,融合医学图像配准与多帧图像超分辨率算法,进一步提升超分辨率的精度。

### 参 考 文 献

[1] Park S C, Park M K, Kang M G. Super-resolution image reconstruction: a technical overview[J]. IEEE Signal Processing Magazine, 2003, 20(3): 21-36.

[2] Bai Y C, Zhang Y Q, Ding M L, et al. SOD-MTGAN: small object detection via multi-task generative adversarial network [M] // Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science.

Cham: Springer, 2018, 11217: 210-226.

- [3] Mudunuri S P, Biswas S. Low resolution face recognition across variations in pose and illumination [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(5): 1034-1040.
- [4] Greenspan H. Super-resolution in medical imaging [J]. The Computer Journal, 2008, 52(1): 43-63.
- [5] Chen J, Gao H B, Wang W G, et al. Methods and applications of image super-resolution restoration[J]. Laser & Optoelectronics Progress, 2015, 52(2): 020004.
- 陈健, 高慧斌, 王伟国, 等. 图像超分辨率复原方法及应用[J]. 激光与光电子学进展, 2015, 52(2): 020004.
- [6] Xi Z H, Hou C Y, Yuan K P, et al. Super-resolution reconstruction of accelerated image based on deep residual network [J]. Acta Optica Sinica, 2019, 39(2): 0210003.
- 席志红, 侯彩燕, 袁昆鹏, 等. 基于深层残差网络的加速图像超分辨率重建[J]. 光学学报, 2019, 39(2): 0210003.
- [7] Song P F, Trzasko J D, Manduca A, et al. Improved super-resolution ultrasound microvessel imaging with spatiotemporal nonlocal means filtering and bipartite graph-based microbubble tracking [J]. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 2018, 65(2): 149-167.
- [8] Zhang Y Q, Shi F, Cheng J, et al. Longitudinally guided super-resolution of neonatal brain magnetic resonance images [J]. IEEE Transactions on Cybernetics, 2019, 49(2): 662-674.
- [9] Oktay O, Ferrante E, Kamnitsas K, et al. Anatomically constrained neural networks (ACNNs): application to cardiac image enhancement and segmentation [J]. IEEE Transactions on Medical Imaging, 2018, 37(2): 384-395.
- [10] Dencks S, Piepenbrock M, Opacic T, et al. Clinical pilot application of super-resolution US imaging in breast cancer[J]. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 2019, 66(3): 517-526.
- [11] Chu J H, Hu F S, Zhang J Q, et al. An improved single-frame super-resolution algorithm for magnetic resonance image [J]. Laser & Optoelectronics Progress, 2018, 55(5): 051009.
- 褚晶辉, 胡风硕, 张佳祺, 等. 一种改进的单帧磁共振图像超分辨率算法[J]. 激光与光电子学进展, 2018, 55(5): 051009.



- [12] Dai S Y, Han M, Xu W, et al. SoftCuts: a soft edge smoothness prior for color image super-resolution [J]. *IEEE Transactions on Image Processing*, 2009, 18(5): 969-981.
- [13] Purkait P, Chanda B. Super resolution image reconstruction through Bregman iteration using morphologic regularization[J]. *IEEE Transactions on Image Processing*, 2012, 21(9): 4029-4039.
- [14] Yang J C, Wright J, Huang T S, et al. Image super-resolution via sparse representation [J]. *IEEE Transactions on Image Processing*, 2010, 19(11): 2861-2873.
- [15] Dong C, Loy C C, He K M, et al. Image super-resolution using deep convolutional networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295-307.
- [16] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 1646-1654.
- [17] Shi W Z, Caballero J, Huszár F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 1874-1883.
- [18] Dong C, Loy C C, Tang X O. Accelerating the super-resolution convolutional neural network[M]// Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016. Lecture notes in computer science*. Cham: Springer, 2016, 9906: 391-407.
- [19] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [20] Ledig C, Theis L, Huszar F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 105-114.
- [21] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 1132-1140.
- [22] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, June 18-22, 2018, Salt Lake City, Utah. New York: IEEE, 2018: 7132-7141.
- [23] Clevert D A, Unterthiner T, Hochreiter S. Fast and accurate deep network learning by exponential linear units (ELUs) [J/OL]. (2016-02-22) [2019-06-03]. <https://arxiv.org/abs/1511.07289>.
- [24] Hiai F, Lin M. On an eigenvalue inequality involving the Hadamard product [J]. *Linear Algebra and its Applications*, 2017, 515: 313-320.
- [25] Zhao H, Gallo O, Frosio I, et al. Loss functions for image restoration with neural networks [J]. *IEEE Transactions on Computational Imaging*, 2017, 3(1): 47-57.
- [26] Kingma D P, Ba J. Adam: a method for stochastic optimization [J/OL]. (2017-01-30) [2019-06-03]. <https://arxiv.org/abs/1412.6980>.
- [27] Data science bowl 2017 [EB/OL]. [2019-06-03]. <https://www.kaggle.com/c/data-science-bowl-2017>.
- [28] L Geert, D Oscar, B Jelle, et al. ProstateX challenge data [J/OL]. The Cancer Imaging Archive, 2017 (2019-06-03). <https://doi.org/10.7937/k9tcia.2017.murs5cl>.
- [29] Pomi A, Slusallek P. Interactive ray tracing for virtual TV studio applications[J]. *JVRB-Journal of Virtual Reality and Broadcasting*, 2005, 2(1): 1-10.