

基于深度学习的核磁图像超分辨率重建

潘梦雪, 曲宁, 夏业儒, 杨德勇, 王洪玉, 刘文龙*

大连理工大学电子信息与电气工程学部, 辽宁 大连 116024

摘要 针对乳腺癌肿瘤区域在整幅图像中占比较小影响早期乳腺癌排查准确率的问题, 提出了一种基于卷积残差块的宽残差深度神经网络来恢复乳腺癌核磁图像高分辨特征的方法。所提方法采用全局残差与局部残差相组合的方式, 使大量的低频信息可以直接被网络顶层接收, 在每个残差块前加入卷积层进行特征预提取, 并使用亚像素卷积层进行上采样操作完成低分辨率图像的重建。对包含 260 个病例的数据集进行了实验, 并将所提方法和现有其他方法进行了对比。实验结果表明, 所提方法在乳腺癌核磁图像超分辨率的应用中优于双立方插值及其他深度学习方法。

关键词 医用光学; 超分辨率; 核磁图像; 卷积神经网络; 残差学习

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP202259.2217001

Super-Resolution Reconstruction of Magnetic Resonance Image Based on Deep Learning

Pan Mengxue, Qu Ning, Xia Yeru, Yang Deyong, Wang Hongyu, Liu Wenlong*

Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116024, Liaoning, China

Abstract Given the relatively small proportion of breast cancer in the overall image, which affects the accuracy of early breast cancer detection, this study proposes a wide residual-depth neural network based on convolution residual blocks to restore the high-resolution features of breast cancer magnetic resonance images. The proposed method adopts the combination of global and local residuals, allowing the top layer of the network to directly receive a substantial amount of low-frequency information. A convolution layer is added in front of each residual block for feature pre-extraction, and the sub-pixel convolution layer is used for up-sampling to complete the reconstruction of the low-resolution image. Experiments on the dataset with 260 samples and comparisons with other methods reveal that the proposed network outperforms bicubic interpolation and other deep learning methods in super-resolution of breast cancer magnetic resonance images.

Key words medical optics; super-resolution; magnetic resonance image; convolutional neural network; residual learning

1 引言

磁共振成像因其无电离辐射安全可靠的优点, 被广泛应用于临床实践。核磁(MR)图像可以清晰呈现出软组织结构, 为明确病变性质提供丰富的影像信息, 现已成为医生治疗诊断必不可少的辅助条件。早期乳腺癌因其病变区域不明显而增大了误筛的概率, 如果能够从低分辨率图像中重建高分辨率图像, 便可以使肿瘤区域更明显表示出来, 对图像进行超分辨率操作是

一种可行的方法。

图像超分辨率技术旨在从单幅低分辨率图像或多幅低分辨率图像中重建出一幅高分辨率图像, 现已成为提高核磁图像空间分辨率的有效手段。传统的图像超分辨率大多采用插值^[1]的方法, 如双线性插值、双立方插值及最邻近插值等, 但由于图像中相邻像素值之间并非总是连续的, 通过插值方法所恢复出来的图像具有模糊效应。多图像超分辨率^[2]可以从多幅低分辨率图像中提取信息用于生成高分辨率图像, 但重建过程需

收稿日期: 2021-08-02; 修回日期: 2021-09-08; 录用日期: 2021-10-13

基金项目: 中央高校基本科研专项资金(DUT20YG112)、国家重点研发计划(2018YFE0197700)、中央高校基本科研业务费(LD202034)

通信作者: *liuwl@dlut.edu.cn

要进行复杂的图像配准工作,时间复杂度和空间复杂度都较高,因而在实际应用中并不常见。

近年来,随着深度学习的快速发展,其在图像和信号处理领域都得到了广泛的应用,基于深度学习的图像超分辨率方法^[3-9]也成为了超分辨率领域的主流。Dong 等^[10]首次将神经网络用于图像超分辨率工作,提出了一个端到端的超分辨率卷积神经网络(SRCNN),该网络直接从大量的训练图像中学习高分辨率图像与低分辨率图像的映射关系,其重建效果远超其他传统算法,但由于网络层次较浅,图像超分辨率效果受限。之后, Kim 等^[11]在 SRCNN 的基础上进行了改进,提出了一种深度的超分辨率神经网络(VDSR),该网络使用残差学习和自适应梯度裁剪来加速模型的训练,同时将单一倍数的超分模型扩展到多倍,增加了网络的普适性。但 SRCNN 和 VDSR 在训练时都需要先对低分辨率图像进行上采样,再将放大后的图像送入网络训练,限制了网络的重建效率。针对此问题, Dong 等^[12]继续对 SRCNN 进行改进,提出了一种加速的超分辨率神经网络(FSRCNN),该网络训练图像不再采用差值后的图像而是直接将低分辨率图像送入网络训练,同时增加了网络的深度,采用更小的卷积核减少网络的复杂度,加速了网络的训练。

除了自然图像领域,基于深度学习的图像超分辨率技术也被广泛应用到医学图像处理^[13-15]领域。Zhang 等^[16]提出了一种快速医学图像超分辨率方法(FMISR),该方法通过亚像素卷积和迷你网络层来提高训练速度,实现了视网膜图像的超分辨率重建。该网络和 FSRCNN 均采用了更轻量级的浅层网络模型,利用更少的网络层次来提升训练速度,但浅层网络不能充分提取图像特征,图像重建效果并不理想。Zhang 等^[17]为了重建退化的医学图像,提出了一种结合感知损失和均方误差损失的深度残差网络,该网络在提高图像质量的同时还降低了图像的噪声,但其主体部分是采用结构相同的残差块堆叠而成的,网络结构较单一,重建图像的清晰度不高。Jiang 等^[18]基于超分辨率生成对抗网络(SRGAN)提出了一种应用于计算机断层扫描(CT)图像超分辨率的改进算法,该算法引入扩展卷积模

块及平均结构相似性损失函数来提高 CT 图像的视觉质量,但由于生成对抗网络自身的局限性,模型训练存在不稳定问题,从而影响了高分辨图像的重建质量。

为了解决以上问题,本文提出了一种新型的深度残差网络来重建乳腺癌核磁图像。网络内部采用全局残差学习与局部残差学习相结合的方式,将前部分网络提取的特征送入尾部网络进行学习,以充分利用每一层提取到的特征进行训练,残差块的引入还改善了深度神经网络带来的梯度消失和训练速度变慢的问题。除此之外,还拓宽了网络中卷积核的宽度,并采用多变卷积核宽度的方式搭建网络,使得网络可以提取更加丰富的特征,进一步提升网络的性能。在图像上采样部分,采用亚像素卷积实现低分辨率图像到高分辨图像的重建。实验结果表明,所提方法在 4 倍下采样速率的条件下仍能较好地恢复图像的纹理细节,且图像的清晰度也优于其他方法。

2 所提方法

2.1 网络结构概述

所提网络主要包含 3 个模块:特征提取与表示模块、非线性映射模块和重建模块,如图 1 所示。特征提取与表示模块主要包括两层网络:卷积层和激活层。卷积层具有 64 个滤波器,尺寸为 9×9 ,卷积层后的激活函数选用的是参数整流线性单元(PReLU),以避免卷积过程中产生参数消亡现象。非线性映射模块由 7 个卷积残差块堆叠而成,每个卷积残差块包括 1 个卷积层和 2 个宽残差块,所有的卷积残差块都具有相同的结构,不同的是前四个卷积残差块的宽度随着网络深度的加深成倍增加,而后三个卷积残差块的宽度则依次减半。宽残差块的引入不仅解决了深度神经网络所产生的网络退化问题,还减轻了特征重用减少的困难。图像重建模块由两次亚像素卷积和一次卷积操作组成,假设图像的放大倍数为 scale,则每一次亚像素卷积在执行时均按一半 scale 的采样速率进行上采样,在经过两次上采样操作之后,图像尺寸恢复为超分辨率后的大小,再经过一个卷积核尺寸为 9×9 的卷积,生成高像素的超分辨率图像,最终完成图像的超分辨率重建工作。




图 1 网络结构

Fig. 1 Network structure

2.2 卷积残差块

网络的非线性映射部分由不同宽度的卷积残差块堆叠而成,卷积残差块的结构如图 2 所示,每一个卷积残差块由一个卷积层和两个残差块连接而成。卷积层的加入不仅起到了进一步优化特征的作用,还将来自上一个卷积残差块输出的特征与本次残差的输出进行了维度的统一,便于残差块中短跳跃连接部分进行相加操作。残差块通过在卷积层前增加跳跃连接结构将上一层网络的输出直接通到后面的网络层,使得在前向传播时,输入信号可以从任意底层直接传播到高层,在一定程度上解决了网络的退化问题。同时在反向传播时,错误信号可以不经任何中间权重矩阵变换直接传播到底层,缓解了梯度消失的问题。

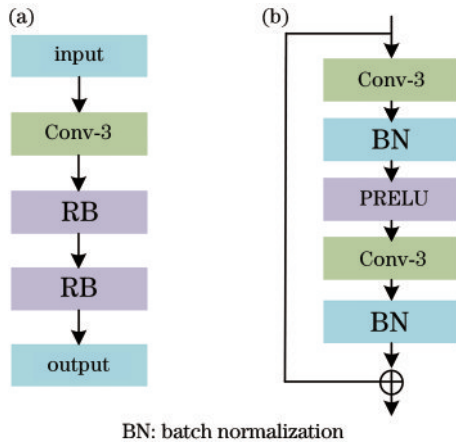


图 2 卷积残差块与残差块。(a)卷积残差块;(b)残差块
Fig. 2 Convolution residual block and residual block.
(a) Convolution residual block; (b) residual block

网络中共包含 7 个卷积残差块,并对每一个卷积残差块都设置了不同宽度的卷积核参数,具体参数如表 1 所示。随着网络层次的加深,每一个卷积残差块的宽度先是增加为上一层的两倍,并从第 5 个卷积残差块开始,后面的卷积残差块宽度依次减小为上一层的一半。多尺度卷积残差块的设置,使得网络可以从局部残差中提取更丰富的初始细节,并通过跳跃连接操作将图像的高频信息送入更深的网络,这不仅使深度网络得到更多细节部分,还有助于梯度的反向传播。

表 1 卷积残差块参数设置

Table 1 Convolution residual block parameter setting

Layer	Input	Filter	Output
Conv-RB1	128 × 128 × 64	3 × 3 × 64	128 × 128 × 64
Conv-RB2	128 × 128 × 64	3 × 3 × 128	128 × 128 × 128
Conv-RB3	128 × 128 × 128	3 × 3 × 256	128 × 128 × 256
Conv-RB4	128 × 128 × 256	3 × 3 × 512	128 × 128 × 512
Conv-RB5	128 × 128 × 512	3 × 3 × 256	128 × 128 × 256
Conv-RB6	128 × 128 × 256	3 × 3 × 128	128 × 128 × 128
Conv-RB7	128 × 128 × 128	3 × 3 × 64	128 × 128 × 64

2.3 上采样

图像超分辨率网络在对输入图像进行特征提取后,还需要经过上采样操作,将特征信息映射成高分辨图像。常用的上采样方法有插值法、反卷积和亚像素卷积:基于插值的上采样方法只能通过图像原有的内容提高图像分辨率,并没有带来更多的信息,还会带来放大噪声、增大计算量和模糊结果的副作用;反卷积可以实现图像尺寸的扩大,但放大后的图像并没有很好地保留高分辨率图像的像素值,会产生“棋盘效应”;亚像素卷积^[19]是针对图像超分辨率提出的图像上采样方法,先通过卷积学习图像特征,得到 r^2 个通道的特征张量,然后再通过一个周期性的混洗操作把一个尺寸为 $H \times W \times C \times r^2$ 的张量重新排列成尺寸为 $rH \times rW \times C$ 的张量,其具体操作流程如图 3 所示。




图 3 亚像素卷积
Fig. 3 Sub-pixel convolution

从图中可以看出,利用亚像素卷积进行图像上采样的过程,实际上并没有进行卷积操作,只是将得到的特征张量进行了重新排列。因此,与其他上采样方法相比,亚像素卷积可以直接将学习到的特征用于图像重建,这不仅有助于提高重建图像的质量还降低了运算复杂度,使重建过程变得简单快捷。

2.4 评价指标

图像评价指标按照是否有参考图像可以分为两类:有参考的图像评价指标和无参考的图像评价指标。峰值信噪比(PSNR)是衡量超分辨率效果使用最广泛的有参考的图像评价指标,但由于人类视觉特性的差异性,通常会出现评价结果与人的主观感受不一致的现象。而乳腺癌核磁图像质量好坏的主观评价之一,就是图像清晰度是否达到医生诊断所需,为此引入了一种无参考的图像清晰度评价标准——梯度能量函数。

PSNR是常用的衡量信号失真的指标,该参数基于图像灰度值进行统计分析,由图像所取得的最大可能像素值与图像之间的均方差(MSE)确定。给定一幅重建图像 \bar{I} 和与其对应的参考图像 I ,两者之间的 MSE 与 PSNR 的表达式为

$$f_{MSE} = \frac{1}{hw} \sum_{x=0}^{h-1} \sum_{y=0}^{w-1} [I(x, y) - \bar{I}(x, y)]^2, \quad (1)$$

$$f_{PSNR} = 10 \times \log_{10} \left[\frac{(2^n - 1)^2}{f_{MSE}} \right], \quad (2)$$

式中： h 和 w 分别表示图像的高度和宽度； x 和 y 表示图像第 x 行第 y 列的像素； $2^n - 1$ 为图像像素的峰值， n 表示像素二进制数据的位数，设为 8。从式(2)可以看出，当像素峰值固定时，PSNR 只依赖于图像之间的 MSE，MSE 越大，PSNR 越低。

梯度能量函数是衡量图像清晰度的传统算法，该算法从长和宽两个方向计算图像中相邻两个像素灰度差的平方和，获取图像边缘和细节信息。给定一幅灰度图 I ，其梯度能量可以描述为

$$f_{\text{Energy}} = \sum_{x=0}^h \sum_{y=0}^w \left\{ [I(x+1, y) - I(x, y)]^2 + [I(x, y+1) - I(x, y)]^2 \right\}, \quad (3)$$

该函数值越大，图像的清晰度越高。

3 实验结果与分析

3.1 实验数据集

目前，可以使用的公开乳腺癌核磁图像数据集较少，因此本实验组自建了一个乳腺癌 MR 图像数据集。此数据集数据由辽宁肿瘤医院提供，共包括 260 个病例，其中男性病例 17 个，女性病例 243 个，年龄范围覆

盖 32~78 岁。实验中使用的是患者的 CE3 图像，每个病例共有 48 张切片，对切片中全黑和质量较差切片图像进行了删除，最终获得 1310 张切片自建数据集。将得到的图像按照 4 倍的下采样率用双立方下采样方法进行下采样，得到低分辨率图像，并按照 6:2:2 的比例随机划分训练集、验证集与测试集。

3.2 训练细节与参数

训练前先对图像进行了标准化处理，以加速网络的收敛速度。在训练时，输入尺寸为 $128 \times 128 \times 3$ 的低分辨率图像，每批次训练数量设为 4，优化器选用 Adam，并将学习率设为 1×10^{-4} ，损失函数选用平均绝对误差(MAE)，训练过程共进行了 1200 次迭代，持续了大概 34 h。所有的实验都使用 Keras 框架在 NVIDIA RTX 2080ti 上进行。

3.3 实验结果与讨论

训练完成后，将高分辨率图像进行 4 次下采样获得低分辨率图像作为测试图像，再将低分辨率图像分别输入 FSRCNN、EDSR、SRResNet 和所提网络进行测试，除了深度学习方法外，还对图像进行了双立方插值(Bicubic)，各方法测试结果如图 4~6 所示。




图 4 不同算法重建图像 1 结果。(a)原图；(b) Bicubic；(c) FSRCNN；(d) EDSR；(e) SRResNet；(f)所提算法
Fig. 4 Image 1 reconstruction results with different algorithms. (a) Original image; (b) Bicubic; (c) FSRCNN; (d) EDSR; (e) SRResNet; (f) proposed algorithm




图 5 不同算法重建图像 2 结果。(a)原图；(b) Bicubic；(c) FSRCNN；(d) EDSR；(e) SRResNet；(f)所提算法
Fig. 5 Image 2 reconstruction results with different algorithms. (a) Original image; (b) Bicubic; (c) FSRCNN; (d) EDSR; (e) SRResNet; (f) proposed algorithm

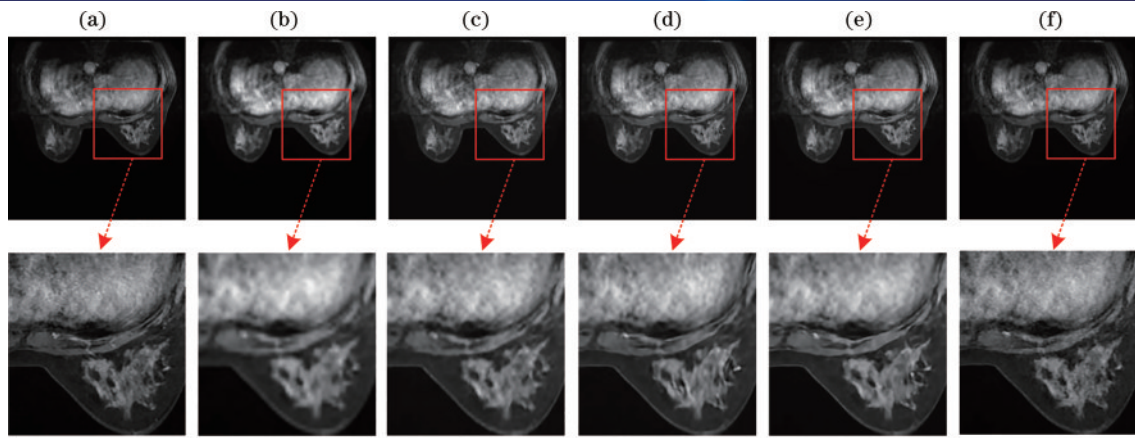


图6 不同算法重建图像3结果。(a)原图; (b) Bicubic; (c) FSRCNN; (d) EDSR; (e) SRResNet; (f)所提算法
Fig. 6 Image 3 reconstruction results with different algorithms. (a) Original image; (b) Bicubic; (c) FSRCNN; (d) EDSR; (e) SRResNet; (f) proposed algorithm

从图4~6放大区域可以清晰地看出,插值法重建图像的模糊现象较严重,而深度学习的方法所重建出的图像质量都要高于插值法。FSRCNN的重建效果略好于双立方插值法,但图像整体都较为模糊,图像质量并不高。EDSR和SRResNet重建的图像从视觉上取得了较好的效果,边缘部分可以清晰恢复,但胸腔部分的细节仍存在模糊现象。所提算法的重建效果最接近原始图像,无论是图像边缘部分的纹理细节还是图像内部器官处的明暗变化,都可以被清晰恢复出来。

为了定性的分析图像超分辨质量的好坏,从主观和客观两方面对图像质量进行了评估。主观上根据图像主观评价表对不同方法下重建的图像质量进行评分,该评价方法按照图像的相对质量和绝对质量将图像划分为5个级别,各个等级的相对测量尺度和绝对测量尺度如表2所示。根据该评价指标,志愿者们对重建图像进行了打分,结果如表3所示。从表3可知,相比于其他方法恢复出的图像,所提方法重建的图像更符合人主观视觉感受,且对于图像细节纹理的恢复效果均优于其他方法。

表2 图像主观评价表

Table 2 Image subjective evaluation form

Grade	Absolute measurement scale	Detail	Score
1	Excellent	The best in the group	5
2	Good	Better than the average in the group	4
3	Average	Group average	3
4	Fair	Worse than the average in the group	2
5	Poor	Worse in the group	1

客观上,选取PSNR和梯度能量值作为主要的评价指标,表4和表5分别表示各幅图像在不同重建方法下的PSNR值和梯度能量值。从表4和表5可以看出,

表3 各超分辨率重建方法主观评价价值对比

Table 3 Comparison of subjective evaluation values of super-resolution reconstruction methods

MR image	Bicubic	FSRCNN	EDSR	SRResNet	Proposed method
1	1.0	2.0	3.0	4.0	5.0
2	1.0	1.8	3.0	4.2	4.8
3	1.0	1.8	3.0	4.2	5.0

表4 各超分辨率重建方法PSNR值对比

Table 4 Comparison of PSNR values of various super-resolution reconstruction

MR image	Bicubic	FSRCNN	EDSR	SRResNet	Proposed method
1	28.69	29.93	29.23	29.25	31.18
2	23.10	24.23	24.17	24.75	29.88
3	26.40	25.01	26.87	26.62	29.12

表5 各超分辨率重建方法梯度能量值对比

Table 5 Comparison of energy gradient values of various super-resolution reconstruction

MR image	Bicubic	FSRCNN	EDSR	SRResNet	Proposed method
1	3931202	6710233	9213167	12092766	13343760
2	5533140	8946652	12582732	14374929	16688306
3	4547242	7907218	11300894	12340983	15936792

所提方法重建出的图像在峰值信噪比和梯度能量函数上都取得了最好的结果,这表明所提方法相比传统插值法和一些深度学习方法,能在保留原始图像病灶信息的基础上最大程度恢复出图像的细节部分。

4 结 论

图像超分辨率技术是目前图像处理领域的研究热点之一,也是改善医学图像质量的有效手段。针对乳腺癌核磁图像质量不高的问题,提出了一种基于残差学习的深度神经网络来解决核磁图像的重建问题。首

先对乳腺癌核磁图像进行 4 倍下采样处理,得到高分辨图像与低分辨率图像对,然后将大量的图像对送入深度神经网络进行训练,在训练过程中提取图像的有效特征,最后利用学习到的映射关系对低分辨率图像进行预测,实现乳腺癌图像的重建工作。

实验结果表明,所提方法在主观和客观评价上都取得了较好的结果。客观上,所提方法的峰值信噪比和梯度能量函数分别取得最好的结果;主观上,所提方法恢复出的图像质量更高,无论是边缘轮廓还是内部器官的明暗变化都更加清晰,更接近原始高分辨图像。从实验结果来看,该方法有望弥补核磁成像设备硬件上扫描时间长、成像质量不高的缺陷。在保证图像超分辨质量的基础上提高训练速率将是进一步的工作。

参 考 文 献

- [1] Li X, Orchard M T. New edge-directed interpolation[J]. IEEE Transactions on Image Processing, 2001, 10(10): 1521-1527.
- [2] Faramarzi E, Rajan D, Christensen M P. Unified blind method for multi-image super-resolution and single/multi-image blur deconvolution[J]. IEEE Transactions on Image Processing, 2013, 22(6): 2101-2114.
- [3] 肖康, 田立君, 王中阳. 基于深度学习的低信噪比下的快速超分辨荧光显微成像[J]. 中国激光, 2020, 47(10): 1007002.
Xiao K, Tian L J, Wang Z Y. Fast super-resolution fluorescence microscopy imaging with low signal-to-noise ratio based on deep learning[J]. Chinese Journal of Lasers, 2020, 47(10): .
- [4] 胡芬, 林洋, 侯梦迪, 等. 基于深度学习的细胞骨架图像超分辨重建[J]. 光学学报, 2020, 40(24): 2410001.
Hu F, Lin Y, Hou M D, et al. Super-resolution reconstruction of cytoskeleton image based on deep learning[J]. Acta Optica Sinica, 2020, 40(24): 2410001.
- [5] Tai Y, Yang J, Liu X M. Image super-resolution via deep recursive residual network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2790-2798.
- [6] 吴磊, 吕国强, 薛治天, 等. 基于多尺度递归网络的图像超分辨率重建[J]. 光学学报, 2019, 39(6): 0610001.
Wu L, Lü G Q, Xue Z T, et al. Super-resolution reconstruction of images based on multi-scale recursive network[J]. Acta Optica Sinica, 2019, 39(6): 0610001.
- [7] 彭晏飞, 高艺, 杜婷婷, 等. 生成对抗网络的单图像超分辨率重建方法[J]. 计算机科学与探索, 2020, 14(9): 1612-1620.
Peng Y F, Gao Y, Du T T, et al. Single image super-resolution reconstruction method for generative adversarial network[J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(9): 1612-1620.
- [8] Kim G, Park J, Lee K, et al. Unsupervised real-world super resolution with cycle generative adversarial network and domain discriminator[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 14-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1862-1871.
- [9] Liu C C, Sun X F, Chen C Y, et al. Multi-scale residual hierarchical dense networks for single image super-resolution[J]. IEEE Access, 2019, 7: 60572-60583.
- [10] 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.
- [11] 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, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1646-1654.
- [12] 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.
- [13] Du J L, Wang L L, Liu Y L, et al. Brain MRI super-resolution using 3D dilated convolutional encoder-decoder network[J]. IEEE Access, 2020, 8: 18938-18950.
- [14] Chen Y H, Xie Y B, Zhou Z W, et al. Brain MRI super resolution using 3D deep densely connected neural networks[C]//2018 IEEE 15th International Symposium on Biomedical Imaging, April 4-7, 2018, Washington, DC, USA. New York: IEEE Press, 2018: 739-742.
- [15] Sood R, Rusu M. Anisotropic super resolution in prostate MRI using super resolution generative adversarial networks [C]//2019 IEEE 16th International Symposium on Biomedical Imaging, April 8-11, 2019, Venice, Italy. New York: IEEE Press, 2019: 1688-1691.
- [16] Zhang S X, Liang G B, Pan S W, et al. A fast medical image super resolution method based on deep learning network[J]. IEEE Access, 2019, 7: 12319-12327.
- [17] Zhang Y F, Chi J N, Wu C D, et al. Deep residual network based medical image reconstruction[C]//2019 Chinese Control Conference (CCC), July 27-30, 2019, Guangzhou, China. New York: IEEE Press, 2019: 8550-8555.
- [18] Jiang X H, Xu Y F, Wei P P, et al. CT image super resolution based on improved SRGAN[C]//2020 5th International Conference on Computer and Communication Systems (ICCCS), May 15-18, 2020, Shanghai, China. New York: IEEE Press, 2020: 363-367.
- [19] 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, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1874-1883.