

文章编号:1007-2780(2019)10-1006-07

基于多尺度残差网络的 CT 图像超分辨率重建

吴磊^{1,2}, 吕国强^{1,3}, 赵晨^{1,3}, 盛杰超^{1,3}, 冯奇斌^{1*}

(1.合肥工业大学 特种显示技术国家工程实验室 现代显示技术省部共建国家重点实验室

光电技术研究院,安徽 合肥 230009;

2.合肥工业大学 电子科学与应用物理学院,安徽 合肥 230009;

3.合肥工业大学 仪器科学与光电工程学院,安徽 合肥 230009)

摘要:为了将超分辨率重建算法应用于医学影像领域,提升各类医学影像的分辨率,针对当前主流算法网络结构和分辨率提升倍数的尺度单一性问题,提出了一种应用于 CT 图像的多尺度残差网络模型。首先,通过级联多层残差块构建模型框架,残差块内采用 3 种尺度的卷积核提取低分辨率图像的细节特征。然后,将特征图融合在一个维度进行特征映射和数据降维,并将多尺度特征信息导入下一残差块。最后,将网络学习到的残差图与低分辨率图像融合,重建高分辨率图像。采用经过多种放大倍数处理的 CT 图像对网络进行混合训练,实现了一个模型可以同时支持多种倍数的分辨率提升。实验结果表明:在 2,3,4 倍放大因子下,该模型重建的 CT 图像 PSNR 平均较 VDSR 算法高 0.87, 0.83, 1.16 dB。因此,本文模型有效提升了 CT 图像的超分辨率重建效果,更锐利地恢复了其细节特征,同时大大提升了算法实用性。

关键词:医学图像;超分辨率重建;多尺度特征;残差网络;深度学习

中图分类号:TP391.4 **文献标识码:**A **doi:**10.3788/YJYXS20193410.1006

CT image super-resolution reconstruction based on multi-scale residual network

WU Lei^{1,2}, LYU Guo-qiang^{1,3}, ZHAO Chen^{1,3}, SHENG Jie-chao^{1,3}, FENG Qi-bin^{1*}(1. *National Engineering Lab of Special Display Technology,**National Key Lab of Advanced Display Technology, Academy of**Photoelectric Technology, Hefei University of Technology, Hefei 230009, China;**2. School of Electronic Science & Applied Physics,**Hefei University of Technology, Hefei 230009, China;**3. School of Instrumentation and Opto-Electronics Engineering,**Hefei University of Technology, Hefei 230009, China)*

Abstract: In order to apply the super-resolution reconstruction algorithm to the field of medical imaging and improve the resolution of various medical images, a multi-scale residual network model

收稿日期:2019-06-13;修订日期:2019-08-18.

基金项目:安徽省科技重大专项(No.17030901053)

Supported by Anhui Province Science and Technology Major Project(No.17030901053)

* 通信联系人, E-mail: fengqibin@hfut.edu.cn

applied to CT images is proposed for the problem of the singleness of the network structure and the resolution multiplier of the current mainstream algorithm. Firstly, the model framework is built by cascading multi-level residual blocks, and the convolution kernels of three scales are used in the residual block to extract the detailed features of low-resolution images. Then, the feature map is fused in one dimension for feature mapping and data dimensionality reduction, and the multi-scale feature information is imported into the next residual block. Finally, the residual map calculated by the network is merged with the low-resolution image to reconstruct the high-resolution image. The network is trained by CT images processed by multiple magnifications, and so that a model can support multiple resolution enhancements at the same time. The experimental results show that under the 2, 3, and 4 times magnification factors, the PSNR of the reconstructed CT image is 0.87, 0.83, 1.16 dB higher than the VDSR algorithm. Therefore, the model of this paper effectively improves the super-resolution reconstruction effect of CT images, restores its detailed features more sharply, and greatly improves the practicality of the algorithm.

Key words: medical image; super-resolution reconstruction; multi-scale feature; residual network; deep learning

1 引 言

医疗影像技术如 CT、MRI 和 X 射线等是医生获取病人信息的常用途径,高分辨率(High Resolution, HR)的医疗影像可以使医生更精确地识别病变部位,因此它的清晰度直接影响医生对病人诊断的准确度,但是由于现有医疗成像技术的局限性以及图像采集设备的固有限制,往往无法给医生提供理想的高分辨率医学图像^[1]。超分辨率(Super Resolution, SR)重建技术^[2-3]就是仅从计算机算法层面入手,将图像采集设备获取到的低分辨率(Low Resolution, LR)图像提升为高分辨率图像的方法,因此采用超分辨率重建技术提高医学图像的分辨率对医学诊断具有重要意义。

近年来学者们在自然图像上的超分辨率研究取得了诸多成果,开发了一系列的重建算法,按照算法的基本思想,目前超分辨率重建技术可以分为基于插值^[4-5]、基于重建^[6]和基于学习^[7-8]的方法。基于插值的方法一般是通过基函数估计相邻像素点之间的连接像素,来填充高分辨率图像中的未知点。该方法虽然高效直观,但无法保证估计像素的精度,因此其重建图像往往存在伪影、模糊等问题;基于重建的方法一般是根据信号处理理论,以 LR 图像为约束条件,利用图像的先验信息估计 HR 图像,但是由于先验信息的不足,该

类方法重建的 HR 图像往往也存在细节缺失等问题。为了突破前两种方法的局限性,相关学者将学习的思想引入了 SR 领域,基于实例学习^[9]、基于稀疏编码^[10]以及固定邻域回归^[7]等 SR 算法相继被提出,将图像的 SR 质量又提升了一个层次。2016 年,Dong 等人^[11]率先开始了卷积神经网络在图像 SR 领域的应用研究,提出了基于卷积神经网络的图像超分辨率方法(SRCNN),SRCNN 采用 3 个卷积层分别对图像进行特征提取、非线性映射以及图像重建等操作,得到了明显优于传统算法的重建效果。为了加快重建速度,Dong 等人^[12]又将反卷积与原算法进行结合,提出了基于反卷积的快速图像超分辨率重建(FSRCNN)。随着研究的深入,学者们发现深层网络可以取得较好的超分辨率效果,但是层数的加深往往会导致网络梯度弥散或梯度爆炸等问题,使其无法收敛。由此,文献[13]借鉴残差网络(ResNet)的思想,利用深层残差网络加速网络学习,提出了基于深度卷积神经网络的超分辨率重建算法(VDSR)。

虽然上述基于学习的算法在自然图像上取得了较好的超分辨率效果,但是应用于 CT 图像仍然存在一些问题:VDSR 的单一尺度网络结构无法充分提取 CT 图像的主要特征;仅有 3 层网络的 SRCNN 恢复出的 CT 图像清晰度不足,且其算法复杂度较高,无法满足医学图像对处理速度的需求;FSRCNN 虽然进行了改进,但其网络深

度仍然不够提取医学图像的细节信息,同时一个网络只能应用于一种放大倍数更限制了上述两种算法在医疗影像领域的应用。

针对以上问题,本文从 CT 图像特征出发,结合残差学习思想,提出了基于多尺度残差网络的 SR 重建算法,通过搭建多尺度网络模型,更充分地提取了低分辨率 CT 图像的各种特征,引入残差学习的同时相应采取 Adam 优化算法^[14]加快了模型的收敛,同时训练前期在多种放大倍数下处理训练集,使得本文模型能够同时支持多种倍数的分辨率提升。

2 本文算法

2.1 网络结构

针对 CT 图像独有特征,结合残差学习思想,提出了基于多尺度全局残差网络的 SR 重建模型,网络结构如图 1 所示。该模型由 11 层多尺度残差块级联而成,每层残差块包含一组 3 种尺度的卷积核。网络运算前期,采用双三次插值算法先将原始低分辨率 CT 图像插值放大到目标分辨率,再将放大后的图像输入到网络中,逐一经过每个残差块进行特征提取、融合、映射以及全局残差学习,最终将学习到的残差图像与输入的低分辨率图像融合,输出高分辨率的 CT 图像。




图 1 本文网络结构图

Fig.1 Network structure diagram of our algorithm

2.2 多尺度残差块

在现有的超分辨率重建算法中,研究人员通常只在一个维度上提取低分辨率图像的细节特征,但 CT 图像特征复杂、结构多样,单一的提取尺度往往会忽略掉其部分纹理信息,导致网络无法恢复足够清晰的高分辨率图像,因此本文在 VDSR 算法的基础上对其单一的深层网络进行改进,构造了多尺度卷积的残差块,结构如图 2 所示,最终通过级联多层残差块的方式搭建了全局残差学习的网络模型。

该残差块主要采用 1×1 , 3×3 , 5×5 的 3 种




图 2 多尺度残差块结构图

Fig.2 Structure diagram of multi-scale residual block

尺度卷积核对低分辨率 CT 图像进行特征提取,每种尺度的卷积核对应生成 16,64,16 幅卷积特征图,然后采用 Concatenation 操作将上述特征图合并,在一个维度上进行重组。为了降低算法复杂度,同时提高网络的训练速度,采用 $1 \times 1 \times 16$ 的卷积核对合并后的多尺度特征信息进行特征映射及数据降维,最终将该残差块提取到的多尺度特征信息输出到下一残差块。为了保证多尺度特征提取的有效性,我们在特征提取层后设置了激活层,激活函数选用 PReLU。残差块的计算公式表示如下:

$$\begin{cases} C_1 = \sum_{i=1}^n \varphi(W_{1_i} * I^{LR} + B_{1_i}) \\ C_2 = W_{2_i} * C_1 + B_{2_i} \end{cases}, \quad (1)$$

$$\begin{cases} C_1^m = \sum_{i=1}^n \varphi(W_{1_i} * C_1^{m-1} + B_{1_i}) \\ C_2^m = W_{2_i} * C_1^m + B_{2_i} \end{cases}, \quad (2)$$

$$\varphi(x) = \max(ax, x), \quad (3)$$

式中: $*$ 表示卷积运算, C_1 表示第 1 个残差块的特征提取, C_2 表示映射降维, C_1^m 和 C_2^m 分别表示第 m 个残差块的提取和降维, n 表示特征提取层的卷积核数量,本文设置 $n = 3$, W 和 B 分别表示网络权重和偏置向量, I^{LR} 表示插值放大后的 LR 医学图像, $\varphi(x)$ 表示 PRelu 激活函数,参数 a 取 $0 \sim 1$ 之间的小数。

由于池化操作降低了图像的分辨率,与恢复高分辨率医学影像的目的相悖,因此本文网络不设置池化层。同时为了充分保留 CT 图像的边缘信息,我们在卷积计算前统一对图像进行边界零

填充,从而固定输出图像的尺寸。

3 实验设置及结果分析

3.1 实验设置

3.1.1 实验环境

算法测试所用计算机 CPU 为 Intel Core i7-3770U @ 3.40 GHz, 同时搭载了 NVIDIA GeForce GTX 1060 GPU, 配置 16GB 内存, 软件环境有 64 位的 Windows 7 操作系统、Matlab R2016a、CUDA Toolkit 8.0、Cudnn 5.0 和 caffe 框架模型。

3.1.2 数据集

所用数据集全部来自于癌症影像档案(The Cancer Imaging Archive, TCIA)网站公开的医学影像资料,该网站包含 CT、MRI 和 X 射线等各类医学图像,选用 CT 图像作为本次实验测试的主要图像。根据不同病患情况,我们下载了 TCGA-ESCA 食道癌、TCGA-STAD 胃腺癌和 TCGA-COAD 结肠腺癌等系列的 CT 图像数据集,分别如图 3 所示。




图 3 数据集示例

Fig.3 Dataset example

从 3 个系列数据集中分别选取 200 幅作为网络模型的训练集;再从每个系列剩下的图像中随机选取 20 幅,共计 60 幅,组成验证集;测试集则随机从每个系列中选取 5 幅图像,打乱后均分成 3 组,组成 3 个测试集。由于人眼对图像亮度分量最为敏感,因此以下操作只在图像亮度分量上进行。对训练集中的 600 幅高分辨率 CT 图像先进行多倍数的下采样处理,为了便于实验测试,分别做了 2,3,4 倍的下采样处理,接着采用双三次插值算法将下采样后的图像插值到目标分辨率,然后再将放大后的低分辨率图像不重叠地裁剪成 41×41 像素大小的图像块,以此增大网络的感受野,同时按照相同的方式对高分辨率 CT 图像进

行裁剪,最后将图像块对应组成高低分辨率数据对,送入网络进行训练。

3.1.3 参数设置

网络训练阶段使用 Adam 算法优化模型参数,该算法可以依据损失函数针对参数的梯度一阶矩估计和二阶矩估计动态改变对应的学习速率,从而加速网络模型的收敛。用公式可表示为:

$$s_t = \rho_1 s_{t-1} + (1 - \rho_1) g_t, \quad (4)$$

$$r_t = \rho_2 r_{t-1} + (1 - \rho_2) g_t g_t, \quad (5)$$

$$\hat{s} = \frac{s}{1 - \rho_1^t}, \hat{r} = \frac{r}{1 - \rho_2^t}, \quad (6)$$

$$\Delta \theta = -\epsilon \frac{\hat{s}}{\sqrt{\hat{r} + \delta}}, \theta = \theta' + \Delta \theta$$

式中: s_t 表示一阶矩估计, r_t 表示二阶矩估计,一二阶矩变量初始化为 0, $\hat{s}$ 和 $\hat{r}$ 分别表示修正的一二阶矩估计偏差,矩估计指数衰减速率 $\rho_1 = 0.9$, $\rho_2 = 0.999$, θ' 表示初始参数, θ 是更新后的参数,步长 ϵ 为 0.001, δ 用于数值稳定,取 10^{-8} 。

网络训练过程中动态调整学习率,也可以加速模型的收敛。首先采用高斯法初始化网络权重,动量和权值衰减分别固定为 0.9 和 0.000 1,然后采用较大基础学习率 0.01,使模型尽快找到收敛方向,一段时间训练后观察损失函数,当损失函数趋于平稳时,降低学习率继续训练,如此循环,直到学习率降至 0.000 1 时,模型基本收敛。

3.2 实验结果

3.2.1 客观评价标准

为了更客观地描述不同算法的效果差异,采用通用的图像质量评价标准:峰值信噪比(Peak Signal to Noise Ratio, PSNR)和结构相似性(Structural Similarity Index, SSIM)对每个算法恢复的高分辨率医学图像进行质量评价^[15]。

PSNR 是根据两幅图像对应像素点间的误差对图像质量进行评价的方法,其值越高表明输出图像的失真越少,图像重建质量越好。SSIM 是对比两幅图像相似度的评价标准,其值越接近于 1 表示重建图像越接近于原始的高分辨率图像。它们的计算公式分别如下所示:

$$K_{\text{PSNR}} = 10 \times \lg \left[\frac{(2^n - 1)^2}{K_{\text{MSE}}} \right], \quad (7)$$

式中: K_{MSE} 表示均方误差, n 为图像色彩位数,这里为 8。

$$K_{\text{SSIM}}(I, I^{\text{HR}}) = (2\mu_1\mu_{I^{\text{HR}}} + c_1) (2\delta_{II^{\text{HR}}} + c_2) /$$

$(\mu_I^2 + \mu_{I^{HR}}^2 + c_1)(\delta_I^2 + \delta_{I^{HR}}^2 + c_2)$, (8)

$c_1 = (k_1 L)^2, c_2 = (k_2 L)^2$, (9)

式中: I 和 I^{HR} 分别表示原始图像和重建后的高分辨率图像, μ_I 是原始图像的均值, $\mu_{I^{HR}}$ 表示重建后的图像均值, δ_I^2 和 $\delta_{I^{HR}}^2$ 分别为 I 和 I^{HR} 的方差, $\delta_{II^{HR}}$ 表示 I 和 I^{HR} 的协方差, c_1 、 c_2 为常数, 用于维持数据稳定, k_1 、 k_2 分别取 0.01 和 0.03, L 为像素大小的动态范围。

3.2.2 结果对比与分析

在上述两种客观评价标准下, 利用构造好的 3 个测试集分别对所搭建的网络模型进行实验测试, 并将测试结果与 Bicubic、SRCNN^[11]、FSRCNN^[12]

以及 VDSR^[13] 等主流算法在 2,3,4 等放大倍数下进行对比, PSNR 和 SSIM 数据对比如表 1 和表 2 所示, 表中的数据是每个测试集的所有图像分别经过对应算法处理后的平均值, 加粗的数据为最优结果。综合分析表 1、表 2 可以看出, 与传统的双三次插值算法相比, 所提模型重建的 CT 图像质量大幅提升, 每个测试集的 PSNR 结果平均提升都在 5 dB 以上。与基于深度学习的 SR 先进算法相比, 本文算法同样取得了较好的成绩, 测试集 2 的 PSNR 数据相较 VDSR 和 FSRCNN 算法平均提升了 1.01 dB 和 2.21 dB, 测试集 3 的 SSIM 数据相较 SRCNN 算法平均提升了 0.006。

表 1 PSNR 数据对比

Tab.1 Comparison of PSNR data

数据集	放大倍数	Bicubic	SRCNN	FSRCNN	VDSR	本文算法
测试集 1	×2	30.85	34.64	34.46	35.14	35.89
	×3	28.10	31.06	31.26	32.28	33.08
	×4	26.43	29.22	29.22	30.28	31.35
测试集 2	×2	30.76	35.32	35.01	35.89	36.86
	×3	27.90	31.43	31.47	32.77	33.62
	×4	26.35	29.28	29.23	30.64	31.85
测试集 3	×2	31.03	35.21	34.95	35.80	36.69
	×3	28.31	31.39	31.59	32.84	33.68
	×4	26.75	29.44	29.38	30.77	31.96

表 2 SSIM 数据对比

Tab.2 Comparison of SSIM data

数据集	放大倍数	Bicubic	SRCNN	FSRCNN	VDSR	本文算法
测试集 1	×2	0.987 9	0.997 2	0.997 4	0.997 5	0.997 5
	×3	0.940 2	0.965 2	0.966 7	0.969 9	0.970 7
	×4	0.901 4	0.941 2	0.939 7	0.950 7	0.952 7
测试集 2	×2	0.988 9	0.997 7	0.997 9	0.998 1	0.998 0
	×3	0.942 0	0.969 7	0.970 4	0.973 7	0.974 6
	×4	0.903 4	0.945 6	0.943 9	0.954 8	0.956 7
测试集 3	×2	0.987 4	0.997 3	0.997 5	0.997 7	0.997 6
	×3	0.937 4	0.964 9	0.966 0	0.969 9	0.970 9
	×4	0.897 1	0.939 5	0.938 2	0.950 3	0.952 3

为了更直观地对比不同算法的重建效果,图 4 至图 6 分别给出了不同算法在 2,3,4 放大倍数下的重建图像,测试图像分别选自 3 个测试集。由效果图可以看出传统的双三次插值算法重建结果最不清晰;SRCNN 和 FSRCNN 的处理效果虽然有了一定提升,但在 CT 图像的纹理区域仍有不足,且有伪影现象出现;VDSR 算法

虽然在肉眼上与我们的算法看不出多大差距,但从客观数据及网络的尺度结构对比,本文算法仍略胜一筹。因此综合对比上述 5 种算法,所提模型能够更准确全面地提取低分辨率 CT 图像的原始特征,更清晰锐利地重建其细节纹理,同时重建的图像边缘信息有很好的连续性,并且没有出现伪影现象。




图 4 2 倍放大倍数下测试集 1 中图像的主观效果对比

Fig.4 Comparison of subjective effects of images in test set one at two times magnification




图 5 3 倍放大倍数下测试集 2 中图像的主观效果对比

Fig.5 Comparison of subjective effects of images in test set two at three times magnification




图 6 4 倍放大倍数下测试集 3 中图像的主观效果对比

Fig.6 Comparison of subjective effects of images in test set 3 at four times magnification

4 结 论


本文提出了一种用于 CT 图像超分辨率重建的网络模型,用以解决现有模型网络结构单一以及实用性低等问题。借鉴残差网络思想,将全局残差学习与多尺度卷积神经网络相结合,构造多尺度残差块,通过级联多层残差块循

环学习低分辨率图像的残差特征,最后融合输入重建高分辨率图像。由实验数据分析可知,在 3 种放大因子下,该模型重建的 CT 图像 PSNR 平均较 VDSR 算法提高了 0.87, 0.83, 1.16 dB。由主观评测可以看出本文模型能够更清晰地恢复 CT 图像中人体器官的细节纹理,同时支持多倍数的超分辨率重建,提升了算法的实用性。

参 考 文 献:

- [1] GAO Y X, LI H J, DONG J W, *et al.* A deep convolutional network for medical image super-resolution [C]// *Proceedings of 2017 Chinese Automation Congress (CAC)* Jinan, China:IEEE, 2017: 5310-5315.
- [2] CHEN H G, HE X H, TENG Q Z, *et al.* Single image super resolution using local smoothness and nonlocal self-similarity priors [J]. *Signal Processing; Image Communication*, 2016, 43: 68-81.
- [3] ZHANG H Y, ZHANG L P, SHEN H F. A blind super-resolution reconstruction method considering image registration errors [J]. *International Journal of Fuzzy Systems*, 2015, 17(2): 353-364.
- [4] ZHANG L, WU X L. An edge-guided image interpolation algorithm via directional filtering and data fusion [J]. *IEEE Transactions on Image Processing*, 2006, 15(8): 2226-2238.
- [5] BÄTZ M, EICHENSEER A, SEILER J, *et al.* Hybrid super-resolution combining example-based single-image and interpolation-based multi-image reconstruction approaches [C]// *Proceedings of 2015 IEEE International Conference on Image Processing (ICIP)*. Quebec City, QC, Canada: IEEE, 2015: 58-62.
- [6] KIM K I, KWON Y. Single-image super-resolution using sparse regression and natural image prior [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(6): 1127-1133.
- [7] TIMOFTE R, DE V, VAN GOOL L. Anchored neighborhood regression for fast example-based super-resolution [C]// *Proceedings of 2013 IEEE International Conference on Computer Vision*. Sydney, NSW, Australia: IEEE, 2013: 1920-1927.
- [8] HUANG J B, SINGH A, AHUJA N. Single image super-resolution from transformed self-exemplars [C]// *Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition*. Boston, MA, USA: IEEE, 2015: 5197-5206.
- [9] FREEMAN W T, JONES T R, PASZTOR E C. Example-based super-resolution [J]. *IEEE Computer Graphics and Applications*, 2002, 22(2): 56-65.
- [10] YANG J C, WRIGHT J, HUANG T, *et al.* Image super-resolution via sparse representation [J]. *IEEE Transactions on Image Processing*, 2010, 19(11): 2861-2873.
- [11] 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.
- [12] DONG C, LOY C C, TANG X. Accelerating the super-resolution convolutional neural network [C]// *Proceedings of the 14th European Conference on Computer Vision*. Amsterdam, Netherlands: Springer, 2016: 391-407.
- [13] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks [C]// *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, NV, USA: IEEE, 2016: 1646-1654.
- [14] 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.
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. (in Chinese)
- [15] 陈清江, 张雪, 柴昱洲. 基于卷积神经网络的图像去雾算法[J]. *液晶与显示*, 2019, 34(2): 220-227.
CHEN Q J, ZHANG X, CHAI Y Z. Image defogging algorithms based on multiscale convolution neural network [J]. *Chinese Journal of Liquid Crystals and Displays*, 2019, 34(2): 220-227. (in Chinese)

作者简介:



吴磊(1994—),男,安徽利辛人,硕士研究生,2017年于安徽工程大学获得学士学位,主要从事超分辨率重建、液晶显示以及深度学习等方面的研究。
E-mail: wulei@mail.hfut.edu.cn



冯奇斌(1970—),女,天津人,博士,副教授,硕士生导师,2006年于维也纳工业大学获得博士学位,主要从事立体显示、LED背光等方面的研究。E-mail: fengqibin@hfut.edu.cn