

基于卷积神经网络的低剂量 CT 图像去噪方法

章云港, 易本顺, 吴晨玥, 冯雨

武汉大学电子信息学院, 湖北 武汉 430072

摘要 为了改善低剂量计算机断层扫描(CT)图像的视觉质量,提出一种基于卷积神经网络的图像去噪方法。网络引入批量归一化,并且学习的是低剂量 CT 图像到其噪声图像之间的映射;使用空洞卷积在不提高复杂度的情况下增大感受野;此外,还将前后层的特征图进行连接,使后方的卷积层能够利用前方各层的特征图作为输入,鼓励网络中特征图的重用。实验结果表明,与目前较先进的方法相比,所提网络结构在实现了更好去噪效果的同时大幅度降低了网络复杂度,能够快速、显著地改善低剂量 CT 图像的视觉质量。

关键词 图像处理; 图像去噪; 低剂量计算机断层扫描; 深度学习; 卷积神经网络

中图分类号 TP391

文献标识码 A

doi: 10.3788/AOS201838.0410003

Low-Dose CT Image Denoising Method Based on Convolutional Neural Network

Zhang Yungang, Yi Benshun, Wu Chenyue, Feng Yu

Electronic Information School, Wuhan University, Wuhan, Hubei 430072, China

Abstract In order to improve the visual quality of low-dose computed tomography (CT) images, an image denoising method based on convolutional neural network is proposed. The batch normalization is introduced to the network, and the mapping function between low-dose CT images and their corresponding noise images is learned. The dilated convolution is used to expand the receptive field without increasing the complexity. Besides, the feature maps from the front and back layers are concatenated, and all the feature maps of convolution layers ahead can be used as the input of a subsequent convolution layer. It encourages the reuse of feature maps in the network. The experimental results show that the proposed network architecture achieves better denoising performance and sharply reduces the network complexity when compared with the state-of-the-art method at present. So, it can quickly and significantly improve the visual quality of low-dose CT images.

Key words image processing; image denoising; low-dose computed tomography; deep learning; convolutional neural network

OCIS codes 100.3020; 110.6955; 170.3880

1 引 言

近年来,随着计算机断层扫描(CT)技术的不断发展,CT 成像在医学诊断中的应用越来越广泛。但是,CT 扫描过程中的高剂量辐射会对人体产生伤害,因此需要在保证图像质量满足临床诊断需求的同时降低辐射剂量。1990 年,Naidich 等^[1]提出了低剂量 CT 的概念,即在其他扫描参数不变的情况下,通过降低管电流以达到降低辐射剂量的目的。当管电流降低时,探测器接收到的光子数也

减少,从而产生“光子饥饿”效应^[2],导致投影数据被噪声污染,由此投影数据重建得到的 CT 图像不仅带有明显的噪声,还会产生条纹伪影,对临床诊断造成不利的影响。针对这些问题,人们提出了许多改善低剂量 CT 图像的质量的算法,可以分为投影域去噪算法、图像重建算法和图像域去噪算法等。

投影域去噪算法直接对投影数据去噪,典型的方法有双边滤波法^[3]、自适应平衡均值滤波法^[4]、自适应卷积滤波法^[5]、惩罚加权最小二乘(PWLS)

收稿日期: 2017-09-15; 收到修改稿日期: 2017-11-29

作者简介: 章云港(1994—),男,硕士研究生,主要从事深度学习与图像处理方面的研究。E-mail: zyg60714@126.com

导师简介: 易本顺(1965—),男,教授,博士生导师,主要从事多媒体信息处理以及无线通信网络方面的研究。

E-mail: yibs@whu.edu.cn

法^[6]等。这类算法的优势在于可以充分利用投影域噪声分布的统计规律^[7],而缺陷在于在投影域降噪过程中可能会产生数据不一致等问题,容易在重建后的图像中引入新的噪声或伪影^[8]。

CT 图像重建算法中最具代表性的是滤波反投影(FBP)算法^[9],其具有分辨率高和成像速度快的优点,是目前应用最为广泛的重建算法。近年来,一些改进的 FBP 算法^[10-11]以及自适应统计迭代重建(ASIR)、基于模型的迭代重建(MBIR)等迭代重建算法^[12]相继出现,但其在提高了 CT 图像重建质量的同时,也增加了算法的复杂度和计算耗时。

投影域去噪算法和图像重建算法都需要用到投影数据,然而在实际应用中,投影数据通常作为 CT 扫描仪的中间结果,一般用户难以直接获取,而图像域去噪算法不依赖于投影数据,能够直接对重建后的 CT 图像进行去噪,因而成为了目前低剂量 CT 图像去噪领域的研究热点。文献[13]基于第二代 Curvelet 变换,对低频子带进行非线性增强,对高频子带应用自适应阈值方法进行去噪;文献[14-15]分别利用改进的非局部平均(NLM)算法和三维块匹配滤波(BM3D)算法对低剂量 CT 图像进行去噪;文献[16]通过字典学习与稀疏表示的方法抑制噪声和伪影。虽然投影域的噪声分布符合一定的统计规律^[7],但经过 FBP 算法生成 CT 图像后,噪声的分布变得复杂,难以用较为精确的模型进行描述,并且图像中可能存在伪影,因此传统的图像域去噪方法难以达到理想的效果,在抑制噪声与伪影的同时容易损失边缘与细节信息。

近年来,深度学习^[17]快速发展,卷积神经网络在图像处理中的应用也愈加广泛。得益于卷积神经网络强大的特征学习与映射能力,在去除低剂量 CT 图像的复杂噪声时相比传统方法具有更大的优势,Chen 等^[18-20]在这方面做了较多工作。文献[18]提出一种简单的卷积神经网络用于低剂量 CT 图像去噪,与传统方法相比在主观视觉效果与客观评价指标上均有所改善。文献[19]在文献[18]的基础上进行了更为详尽的实验,充分显示了将卷积神经网络应用于低剂量 CT 图像去噪时相较于传统方法的优越性。文献[20]提出一种基于残差编解码器结构的卷积神经网络(RED-CNN),并与传统的方法以及其他基于卷积神经网络的方法进行对比。实验结果表明,不管是在主观视觉效果上,还是在峰值信噪比(PSNR)、结构相似性(SSIM)和均方根误差(RMSE)等客观评价指标上,RED-CNN 都是最优

的。虽然 RED-CNN 对低剂量 CT 图像的去噪效果达到了目前较为先进的水平,但其网络复杂度较高,运算耗时较长,难以适应当前的应用。本文提出一种新的卷积神经网络结构,与 RED-CNN 相比,不仅大幅度降低了网络参数数量,而且在一定程度上提升了去噪效果。

2 基于卷积神经网络的去噪方法

2.1 去噪模型

假设 \mathbf{X} 是正常剂量 CT 图像, \mathbf{Y} 是其对应的低剂量 CT 图像, \mathbf{Y} 与 \mathbf{X} 的残差 \mathbf{R} 即为图像中的噪声,则三者的关系可以表示为

$$\mathbf{Y} = \mathbf{X} + \mathbf{R}. \quad (1)$$

不同于多数传统方法致力于直接实现 \mathbf{Y} 到 \mathbf{X} 的端到端映射,所提网络学习的是 \mathbf{Y} 到 \mathbf{R} 之间的映射,即寻找一种映射 f 使得代价函数最小化:

$$\arg \min_f \|\mathbf{Y} - \mathbf{R}\|_2^2. \quad (2)$$

综上所述,网络的输入为低剂量 CT 图像 \mathbf{Y} , 输出为提取到的噪声 $\tilde{\mathbf{R}} = f(\mathbf{Y})$, 两者相减即可得到去噪后的图像 $\tilde{\mathbf{X}}$ 为

$$\tilde{\mathbf{X}} = \mathbf{Y} - f(\mathbf{Y}). \quad (3)$$

2.2 网络结构

图 1 为所提网络的结构示意图,其中包括卷积(Conv)、批量归一化(BN)^[21]与修正线性单元(ReLU)。每个 ConvBlock 均由两组 Conv-BN-ReLU 组成,且每个 ConvBlock 都将自身的输入特征图与输出特征图连接,作为下一层的输入。网络中除了最后一个 Conv 层用于输出残差图像外,共有 7 个 Conv 层,其中第 1 个与第 7 个 Conv 层输出的特征图数量设为 64,其余的输出特征图数量设为 48。所有 Conv 层的卷积核大小均为 3 pixel \times 3 pixel,但值得注意的是,3 个 ConvBlock 分别使用了步长为 2、3、2 的空洞卷积,所以其三者的实际卷积核大小为 5 pixel \times 5 pixel、7 pixel \times 7 pixel、5 pixel \times 5 pixel。若无特殊说明,则默认一个 ConvBlock 为一层。

1) BN 与残差学习^[22]。随着深度神经网络的不断加深,网络变得愈加难以训练。为了克服这种困难,人们提出了许多应对的方法,比如使用 BN 与残差学习。BN 通常作用于网络中的非线性映射单元之前,通过改变激活输入值的分布,使激活输入值落在非线性函数对输入比较敏感的区域,以此避免梯度消失的问题,具有加快收敛速度、提高网络性能、对权重初始化不敏感等优点。残差

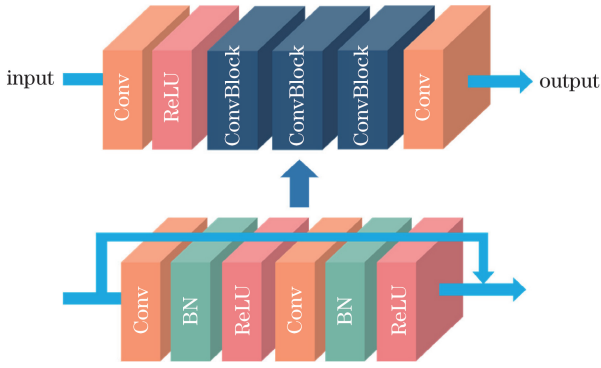


图 1 网络结构示意图

Fig. 1 Schematic of the network

学习的理论则认为,当函数 $H(x)$ 近似于恒等变换时,与其使用神经网络直接拟合,不如拟合残差函数 $F(x) = H(x) - x$ 更加容易训练。文献[23]分析研究了 BN 与残差学习在图像去噪中的应用,其实验分析表明,BN 与残差学习所具有的特点能够使其实现优势互补,因此两者的结合能够显著提升网络的去噪效果,并使网络训练时的收敛曲线更加稳定。借鉴了文献[23]的研究成果,在本文网络中使用了 BN 与残差学习的组合来提升网络性能。

2) 特征图连接。受 DenseNet^[24] 的启发,所提网

络采用了特征图连接的机制,即每个 ConvBlock 都将自身的输入与输出特征图连接,并一起作为下一层的输入,后方的所有层都能够利用前方每一层的输出特征图。采用这种特征图连接机制的优势在于: ①特征图的连接为网络中前后层之间创建了直连通路,梯度在反向传播时能够直接到达网络前方的任何一层,从而缓解了训练过程中梯度消失的问题,使网络更容易训练;②网络中的任何一层都能充分利用其前面各层的输出特征图,与只能利用前面一层输出特征图的传统卷积神经网络相比,这种特征图连接机制鼓励了特征图的重用,从而减少了每层所需特征图的数量。

3) 空洞卷积。在图像去噪中,像素的重建依赖于其对应的上下文信息。对于卷积神经网络,上下文信息的获取范围可以用感受野来衡量。增大感受野通常有 2 种方法:①增大卷积核的尺寸或网络的深度,但这显然也会增加网络参数的数量;②使用空洞卷积,其原理如图 2 所示,从左至右分别为普通的卷积核(即空洞步长为 1)及其对应的空洞步长分别为 2 和 3 的空洞卷积核。空洞卷积能够在不增加网络参数数量的前提下扩大卷积核的尺寸,从而增大整个网络的感受野。




图 2 空洞卷积示意图。(a)步长为 1;(b)步长为 2;(c)步长为 3

Fig. 2 Schematic of dilated convolution. (a) Step size is 1; (b) step size is 2; (c) step size is 3

3 实验与结果分析

实验仿真的计算机硬件配置为 Intel Core i7-6850K 与 Nvidia GeForce GTX 1080Ti,操作系统为 Ubuntu 16.04,使用 Caffe 训练神经网络并在 Matlab R2015b 上进行测试。

3.1 训练

选取 200 幅人体不同部位的 CT 图像作为训练数据,图像尺寸为 512 pixel×512 pixel,其均来自网上公开的 CT 图像数据集 TCIA。对每幅正常剂量 CT 图像做扇形射束投影变换,将得到的投影矩阵 S 进行指数运算后加入泊松噪声,然后取对数,再由经

典的 FBP 算法变换到图像域,以此来模拟对应的低剂量 CT 图像^[7]。投影域加噪式为

$$I_n = \text{Poisson}[b \cdot \exp(-S)], \quad (4)$$

$$S_n = \ln(b/I_n), \quad (5)$$

式中 b 为发射光子数,其值设为 10^6 ; I_n 矩阵为探测器接收到的光子数; S_n 为被噪声污染后的投影矩阵。

在开始训练前,使用尺寸为 55 pixel×55 pixel 的滑动窗,滑动间隔为 8,将低剂量 CT 图像及其残差图像分割为局部重叠的图像块,并且通过旋转、翻转的数据增强操作扩充数据集,训练网络时输入的是这些图像块而非整幅图像。

网络的权重采用高斯分布初始化,每个卷积层

的初始权重服从均值为 0、标准差为 0.01 的高斯分布,初始偏置均设为 0。网络损失层的损失函数由欧氏距离表示为

$$L = \frac{1}{N} \sum_{i=1}^N \|f(\mathbf{Y}_i) - \mathbf{R}_i\|_2^2, \quad (6)$$

式中 L 为损失值; \mathbf{Y}_i 为第 i 幅输入的低剂量 CT 图像块; $f(\mathbf{Y}_i)$ 为网络的输出; \mathbf{R}_i 为对应的实际残差图像块; N 为网络进行一次迭代训练输入的图像块数量,

实验中取 $N=128$ 。采用 Adam 算法^[25] 对损失函数进行优化,初始学习率为 10^{-3} ,随着训练的进行逐渐下降至 10^{-5} 。

3.2 主观效果

从 TCIA 数据集中随机选取了 10 幅 CT 图像作为测试图,其与训练用的 200 张图片不重复,如图 3 所示。对比方法为 RED-CNN^[20]。图 4 以第 ① 幅与第 ⑦ 幅测试图为例,展示了去噪效果。




图 3 测试图

Fig. 3 Testing images




图 4 去噪效果对比图。(a)原图;(b)低剂量图;(c) RED-CNN;(d)所提网络

Fig. 4 Denoising results comparison images. (a) Original CT image; (b) low-dose CT image; (c) RED-CNN; (d) proposed network

虽然 RED-CNN 与所提网络在去噪后的主观视觉效果上非常相似,但仔细观察图片后可以发现,在细节的保留程度上,所提网络要略优于 RED-CNN。图 5 为图 4(a)中方框区域的放大图,如箭头所指,原图中在白色骨质区域内有一小块灰色区域,RED-CNN 去噪后该灰色小块已经难以辨认,而所提网络去噪后仍然保留了明显的灰色小块。

3.3 客观指标

采用 PSNR、SSIM 和 RMSE 作为评价去噪效果的客观指标,10 幅测试图的详细测试结果及其平均值如表 1 所示。

在 10 幅测试图中,所提网络与 RED-CNN 相比在客观指标上有 6 幅领先、4 幅落后,其中 PSNR 的领先程度为 0.38 dB~1.73 dB,落后程度为 0.16 dB~0.24 dB,平均后的 PSNR 高出将近 0.6 dB;而 RMSE




图 5 图 4(a)中方框区域的放大图。(a)原图;(b)低剂量图;(c) RED-CNN;(d)所提网络

Fig. 5 Fig. 4(a) enlargement of the box region. (a) Original CT image; (b) low-dose CT image; (c) RED-CNN; (d) proposed network

表 1 所有测试图的客观指标

Table 1 Objective indexes of all the testing images

Serial number	Index	Low-dose	RED-CNN	Proposed network
①	PSNR /dB	26.27	32.35	32.73
	SSIM	0.8209	0.9378	0.9378
	RMSE	0.0486	0.0241	0.0231
②	PSNR /dB	27.49	32.59	32.34
	SSIM	0.8461	0.9573	0.9536
	RMSE	0.0422	0.0235	0.0241
③	PSNR /dB	30.43	35.75	36.28
	SSIM	0.9065	0.9621	0.9630
	RMSE	0.0301	0.0163	0.0153
④	PSNR /dB	24.72	31.65	33.19
	SSIM	0.7711	0.9184	0.9199
	RMSE	0.0581	0.0261	0.0219
⑤	PSNR /dB	22.00	27.07	28.80
	SSIM	0.7252	0.8922	0.8968
	RMSE	0.0794	0.0443	0.0363
⑥	PSNR /dB	20.82	26.72	28.16
	SSIM	0.6995	0.8950	0.8975
	RMSE	0.0909	0.0461	0.0391
⑦	PSNR /dB	29.30	36.85	36.69
	SSIM	0.8843	0.9660	0.9653
	RMSE	0.0343	0.0144	0.0146
⑧	PSNR /dB	29.78	35.51	35.29
	SSIM	0.9191	0.9707	0.9695
	RMSE	0.0324	0.0168	0.0172
⑨	PSNR /dB	27.59	37.75	37.53
	SSIM	0.8337	0.9618	0.9605
	RMSE	0.0417	0.0130	0.0133
⑩	PSNR /dB	27.27	32.37	33.53
	SSIM	0.8607	0.9341	0.9348
	RMSE	0.0433	0.0241	0.0211
Average	PSNR /dB	26.57	32.86	33.45
	SSIM	0.8267	0.9395	0.9399
	RMSE	0.0501	0.0249	0.0226

的领先程度为 0.0010~0.0080,落后程度为 0.0002~0.0006,平均后 RMSE 低出 0.0023。在 SSIM 指标上所提网络虽然略微领先于 RED-CNN,但差距较小,可以认为两者的表现相近。

3.4 复杂度

对比了 RED-CNN 与所提网络的复杂度与计算耗时,其中复杂度的计算式为 $O\{\sum_l n_{l-1} f_l^2 n_l\}$,可以近似表示网络中参数的数量,其中 n_l 为网络第 l 层输出的特征图数量; f_l 为网络第 l 层的卷积核大小。计算耗时的测试方法是:在 Matlab R2015b 上调用 Caffe 的接口函数,对 512 pixel×512 pixel 的测试图做 10 次正向传播,计算平均耗时。测试结果如表 2 所示。

表 2 复杂度对比

Table 2 Comparison of complexity

Item	RED-CNN	Proposed network
Complexity	1848000	216864
Time consumption (CPU) /s	12.472	3.908
Time consumption (GPU) /s	0.180	0.061

可以看出,所提网络相比于 RED-CNN,其网络复杂度降低了 88%,计算耗时降低了约 2/3,计算效率明显提升。

3.5 网络结构的影响

为了研究 2.2 节所述的网络三大结构特性对去噪效果的影响。分别对默认网络结构做如下改动:1) 删去 BN 层,让网络直接学习无噪的图像;2) 删去前后层特征图之间的连接;3) 把空洞卷积改回普通卷积。取 10 幅测试图去噪后的平均 PSNR、SSIM 与 RMSE 值作为评价指标,其实验结果如表 3 所示。

由表 3 可知,BN 与残差学习的组合使用、特征图连接机制、空洞卷积都对提升网络的去噪性能起到了积极的作用。

表 3 不同网络结构的对比

Table 3 Comparison of different network structures

Structure description	Default	Without BN and residual learning	Without concatenating feature maps	Without dilated convolution
	PSNR /dB	33.45	32.84	33.33
SSIM	0.9399	0.9369	0.9382	0.9373
RMSE	0.0226	0.0245	0.0229	0.0231

此外,为了探究每个 ConvBlock 包含 Conv-BN-ReLU 组数对网络性能的影响。保持卷积层总数及其自身结构不变,分别将每 1、2、3 组 Conv-BN-ReLU 封装为一层 ConvBlock,以 10 幅测试图去噪后的平均 PSNR、SSIM 和 RMSE 值作为评价指标,其实验结果如表 4 所示。

表 4 每个 ConvBlock 包含不同组数 Conv-BN-ReLU 对去噪效果的影响

Table 4 Impact on denoising performance when each ConvBlock contains different numbers of Conv-BN-ReLU

Structure description	Numbers of Conv-BN-ReLU contained in each ConvBlock		
	1	2	3
PSNR /dB	33.27	33.45	33.33
SSIM	0.9290	0.9399	0.9397
RMSE	0.0230	0.0226	0.0229

相比于每个 ConvBlock 包含 2 组 Conv-BN-ReLU,当 Conv-BN-ReLU 组数为 1 或 3 时,网络的去噪效果都有所下降,另外当组合顺序改为 BN-ReLU-Conv 时,去噪效果也会有所下降,因此,采用了每个 ConvBlock 包含 2 组 Conv-BN-ReLU 的方案。

4 结 论

针对传统去噪方法难以有效抑制低剂量 CT 图像噪声与伪影的问题,利用深度学习技术,构建了一种新型的轻量级卷积神经网络,其主要特点有:1) 利用 BN 与残差学习的组合优势;2) 通过特征图连接机制鼓励特征图的重用;3) 使用空洞卷积增大网络的感受野。实验结果表明:与目前较先进的 RED-CNN 相比,所提网络结构大幅度降低了其复杂度,并且在去噪效果上也略微超越了 RED-CNN,具有一定的实用价值。

参 考 文 献

- [1] Naidich D P, Marshall C H, Gribbin C, *et al.* Low-dose CT of the lungs: preliminary observations[J]. *Radiology*, 1990, 175(3): 729-731.
- [2] Mori I, Machida Y, Osanai M, *et al.* Photon starvation artifacts of X-ray CT: their true cause and a solution[J]. *Radiological Physics & Technology*, 2013, 6(1): 130-141.
- [3] Manduca A, Yu L F, Trzasko J D, *et al.* Projection space denoising with bilateral filtering and CT noise modeling for dose reduction in CT[J]. *Medical Physics*, 2009, 36(11): 4911-4919.
- [4] Hsieh J. Adaptive streak artifact reduction in computed tomography resulting from excessive X-ray photon noise[J]. *Medical Physics*, 1998, 25(11): 2139-2147.
- [5] Kachelriess M, Watzke O, Kalender W A. Generalized multi-dimensional adaptive filtering for conventional and spiral single-slice, multi-slice, and cone-beam CT[J]. *Medical Physics*, 2001, 28(4): 475-490.
- [6] Wang J, Li T F, Lu H B, *et al.* Penalized weighted least-squares approach to sinogram noise reduction and image reconstruction for low-dose X-ray computed tomography[J]. *IEEE Transactions on Medical Imaging*, 2006, 25(10): 1272-1283.
- [7] Whiting B R. Signal statistics in X-ray computed tomography[C]//*Medical Imaging 2002: Physics of Medical Imaging*, International Society for Optics and Photonics, 2002, 4682: 53-61.
- [8] Xu Q. Statistical reconstruction methods for insufficient X-ray CT projection data[D]. Xi'an: Xi'an Jiaotong University, 2012.
- [9] 许琼. X线 CT 不完备投影数据统计重建研究[D]. 西安: 西安交通大学, 2012.
- [9] Smith P R, Peters T M, Bates R H T. Image reconstruction from finite numbers of projections[J]. *Journal of Physics A: Mathematical, Nuclear and General*, 1973, 6(3): 361-382.
- [10] Wu W W, Quan C, Liu F L. Filtered back-projection image reconstruction algorithm for opposite parallel linear CT scanning[J]. *Acta Optica Sinica*, 2016, 36(9): 0911009.
- [10] 伍伟文, 全超, 刘丰林. 相对平行直线扫描 CT 滤波反投影图像重建[J]. *光学学报*, 2016, 36(9): 0911009.
- [11] Li Z G, Li L, Han Y, *et al.* A BPF-type reconstruction algorithm for circle-plus-line trajectory in cone beam CT[J]. *Acta Optica Sinica*, 2016, 36(9): 0911008.
- [11] 李增光, 李磊, 韩玉, 等. 锥束 CT 圆加直线轨迹反投影滤波重建算法[J]. *光学学报*, 2016, 36(9): 0911008.
- [12] Dong J W. The progress on research and principles of computed tomography iterative reconstruction[J]. *China Medical Equipment*, 2016, 13(10): 128-133.

[1] Naidich D P, Marshall C H, Gribbin C, *et al.* Low-

- 董继伟. CT 迭代重建技术原理及其研究进展[J]. 中国医学装备, 2016, 13(10): 128-133.
- [13] Zhang T, Wang B, Yang L J, *et al.* Low dose CT image enhancement based on second generation Curvelet transform[J]. Computer Engineering and Applications, 2010, 46(6): 191-193.
张涛, 王宾, 杨立娟, 等. 第二代 Curvelet 变换在低剂量 CT 图像增强中的应用[J]. 计算机工程与应用, 2010, 46(6): 191-193.
- [14] Li Z B, Yu L F, Trzasko J D, *et al.* Adaptive nonlocal means filtering based on local noise level for CT denoising[J]. Medical Physics, 2014, 41(1): 011908.
- [15] Kang D, Slomka P J, Nakazato R, *et al.* Image denoising of low-radiation dose coronary CT angiography by an adaptive block-matching 3D algorithm[C]// Proceedings of SPIE, 2013, 8669: 86692G.
- [16] Chen Y, Yin X, Shi L, *et al.* Improving abdomen tumor low-dose CT images using a fast dictionary learning based processing[J]. Physics in Medicine & Biology, 2013, 58(16): 5803-5820.
- [17] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [18] Chen H, Zhang Y, Zhang W H, *et al.* Low-dose CT denoising with convolutional neural network[C]// Proceedings of IEEE 14th International Symposium on Biomedical Imaging, 2017: 143-146.
- [19] Chen H, Zhang Y, Zhang W H, *et al.* Low-dose CT via convolutional neural network[J]. Biomedical Optics Express, 2017, 8(2): 679-694.
- [20] Chen H, Zhang Y, Kalra M K, *et al.* Low-dose CT with a residual encoder-decoder convolutional neural network (RED-CNN)[J]. IEEE Transactions on Medical Imaging, 2017, 36(12): 2524-2535.
- [21] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]// Proceedings of the 32nd International Conference on Machine Learning, 2015, 37: 448-456.
- [22] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition[C]// Processing of IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [23] Zhang K, Zuo W, Chen Y, *et al.* Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.
- [24] Huang G, Liu Z, Weinberger K Q, *et al.* Densely connected convolutional networks[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700-4708.
- [25] Kingma D P, Ba J. Adam: a method for stochastic optimization[C]// The 3rd International Conference on Learning Representations, 2015: 1-15.