

基于深度学习的低剂量CT图像去噪

谢丰雪¹, 杨帆¹, 冯维¹, 曾雷雷², 廖月红¹, 雷平贵³

1. 贵州医科大学生物与工程学院, 贵州 贵阳 550025; 2. 贵州医科大学大健康学院, 贵州 贵阳 550025; 3. 贵州医科大学附属医院影像科, 贵州 贵阳 550004

【摘要】目的:提出一种基于深度学习的方法用于低剂量CT(LDCT)图像的噪声去除。**方法:**首先进行滤波反投影重建, 然后利用多尺度并行残差U-net(MPR U-net)的深度学习模型对重建后的LDCT图像进行去噪。实验数据采用LoDoPaB-CT挑战赛的医学CT数据集, 其中训练集35 820张图像, 验证集3 522张图像, 测试集3 553张图像, 并采用峰值信噪比(PSNR)与结构相似性系数(SSIM)来评估模型的去噪效果。**结果:**LDCT图像处理前后PSNR分别为28.80、38.22 dB, SSIM分别为0.786、0.966, 平均处理时间为0.03 s。**结论:**MPR U-net深度学习模型能较好地去除LDCT图像噪声, 提升PSNR, 保留更多图像细节。

【关键词】低剂量CT; 图像去噪; 深度学习; 多尺度并行残差U-net

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2022)05-0547-04

Low-dose CT image denoising based on deep learning

XIE Fengxue¹, YANG Fan¹, FENG Wei¹, ZENG Leilei², MIAO Yuehong¹, LEI Pinggui³

1. School of Biology and Engineering, Guizhou Medical University, Guiyang 550025, China; 2. School of Big Health, Guizhou Medical University, Guiyang 550025, China; 3. Department of Radiology, the Affiliated Hospital of Guizhou Medical University, Guiyang 550004, China

Abstract: Objective To propose a deep learning-based method for low-dose computed tomography (LDCT) image denoising. **Methods** After reconstruction by filtered back projection, a deep learning model of multiscale parallel residual U-net (MPR U-net) was used for denoising the reconstructed LDCT images. The medical CT datasets of LoDoPaB-CT Challenge were used in the experiment, including 35 820 images in training set, 3 522 images in validation set and 3 553 images in test set. The denoising effect of the model was evaluated by peak signal-to-noise ratio (PSNR) and structural similarity (SSIM). **Results** The PSNR before and after LDCT image denoising was 28.80 and 38.22 dB, respectively, and the SSIM was 0.786 and 0.966, respectively. The average processing time was 0.03 s. **Conclusion** The proposed MPR U-net deep learning model can remove LDCT image noise better, improve PSNR and retain more image details.

Keywords: low-dose computed tomography; image denoising; deep learning; multiscale parallel residual U-net

前言

目前CT是临床上广泛使用的影像诊断设备,但检查过程中CT辐射会对患者的身体造成一定的伤害。

因此, Naildich等^[1]提出应用低剂量CT(Low-Dose Computed Tomography, LDCT)作为肺癌高危人群的筛查,以减少辐射对人体的危害。另外在一项I类临床实验中证实采用LDCT为高危人群进行肺癌筛查可以将肺癌死亡率降低20%左右^[2]。然而,临床上LDCT图像有明显的噪声、伪影以及对比度低等问题,这影响了医生的诊断,可能会造成误诊、错诊或漏诊^[3-4]。为解决问题,有研究提出改善LDCT图像质量的方法,如惩罚加权最小二乘法(Penalized Weighted Least-Squares, PWLS)^[5]、非局部均值(Non-Local Mean, NLM)滤波法^[6]、局部自适应双边滤波算法^[7]、弦图降噪算法^[8]、基于稀疏表达的小波技术^[9]等。虽然这些方法在一定程度上提高了CT图像质量,但对于复杂的医学图像,去噪效

【收稿日期】2021-12-20

【基金项目】贵州省科技计划项目[黔科合基础-ZK[2021]一般478]; 贵州省普通高等学校青年科技人才成长项目[黔教合KY字[2021]180]; 2020年省级大学生创新创业训练计划项目(S202010660031)

【作者简介】谢丰雪, 硕士研究生, 主要从事医学图像处理研究, E-mail: 1848431199@qq.com

【通信作者】杨帆, 副教授, 主要从事医学图像及人工智能等研究, E-mail: yangfan0404@126.com

果还有待提高。近几年,深度学习方法广泛应用于医学图像的处理和分析^[10-11],其中一些方法被用于CT图像的去噪,如Green等^[12]提出一种局部一致性的非局部均值(Locally-Consistent Non-Local Means, LC-NLM)去噪算法,该方法可实现LDCT图像的降噪并保留图像的精细细节;Kuanar等^[13]提出通过基于RegNet的自动编码器网络结构来消除CT图像的噪声;Heinrich等^[14]运用XCAT软件来模拟LDCT噪声模型,并提出采用残差U-net网络对LDCT图像进行去噪;Bager等^[15]和Leuschner等^[16]分析和评估了不同深度学习方法对于LDCT图像去噪的表现。

LDCT图像噪声复杂,以往深度学习方法基于单尺度的图像特征提取有限,图像去噪性能还需进一步提升。本研究在U-net模型的基础上提出多尺度并行残差U-net(Multiscale Parallel Residual U-net, MPR U-net)的深度学习方法对LDCT图像进行去噪,该方法采用多尺度结构进行不同尺度的特征提取,在上下采样路径使用残差结构,改善随着网络结构加深而梯度消失的问题,旨在去除图像噪声的同时尽可能保留LDCT图像信息。

1 材料与方法

1.1 数据集与预处理

1.1.1 数据集 本研究的实验数据来自公开的LoDoPaB-CT挑战赛数据库^[17],该数据集包括752名受试者标准剂量的CT图像和对应的模拟LDCT投影数据,各42 895张。其中,标准剂量CT图像来自于LIDC/IDRI数据库^[18]中正常剂量胸部CT扫描;对应的模拟LDCT投影数据中添加的噪声为泊松噪声,用于模拟LDCT扫描时的噪声。

1.1.2 预处理 将数据集划分为3个部分,其中训练集

632名受试者,共35 820张图像,验证集60名受试者,共3 522张,测试集60名受试者,共3 553张图像。对模拟LDCT投影数据采用滤波反投影重建算法(Filtered Back Projection, FBP)^[19]进行重建,重建结果如图1所示。




图1 图像重建
Figure 1 Image reconstruction

1.2 方法

1.2.1 模型结构 本研究提出的MPR U-net深度学习模型如图2所示,其输入和输出图像尺寸均为128像素×128像素,该模型主要由多尺度并行模块、残差连接、上下采样路径组成。其中,多尺度并行模块如图3所示,分别采用1×1、3×3、5×5的卷积核对输入图像进行卷积操作,不同的卷积核拥有不同的感受视野,可以帮助提取到不同程度的特征;残差连接包含3×3卷积层(Convolution, Conv)、归一化层(Batch Normalization Layer, BN)^[20]与线性整流激活函数(Rectified Linear Unit, ReLU)^[21];下采样路径阶段采用最大值池化(2×2)进行下采样,上采样路径阶段采用步长为2,卷积核尺寸2×2的反卷积恢复图像尺寸。在上下采样路径之间使用4个跳跃连接,用于深层与浅层结构的特征信息传递。

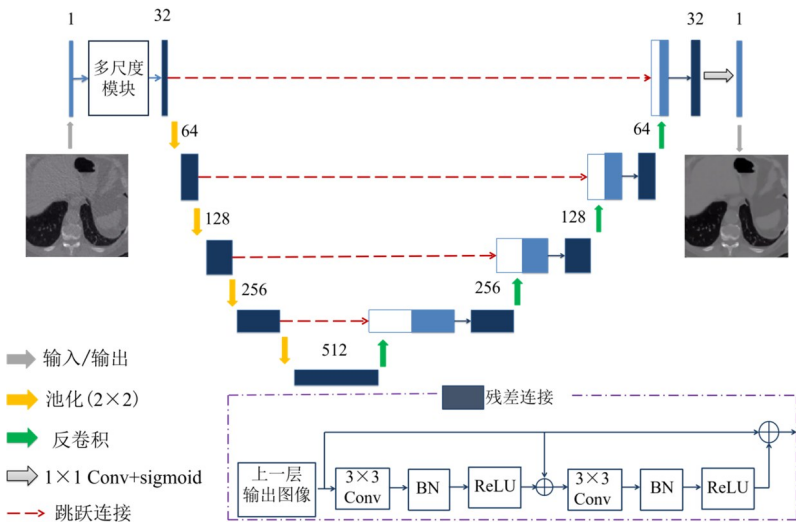


图2 MPR U-net模型结构
Figure 2 MPR U-net model architecture




图3 多尺度并行模块

Figure 3 Multiscale parallel module

1.2.2 实施细节 采用 Matlab R2020b 深度学习工具箱,并使用4块 NVIDIA RTX 2080 Ti 显卡对所提出的模型进行训练。训练过程中,使用 Adam(Adaptive moment Estimation) 优化器对模型参数进行优化^[22],网络初始学习率为 0.001, BatchSize 为 128, Epoch 为 100,每个 Epoch 结束后随机打乱数据,并将学习率下降为原来的 0.98 倍。

1.2.3 评估方法 采用峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)和结构相似性系数(Structural Similarity, SSIM)来评估模型的去噪效果。PSNR 主要用于评价实验结果与参考图像之间的质量好坏,PSNR 的值越大,实验结果图像的质量越高,公式如下所示:

$$\text{PSNR}(\tilde{x}, x) = 10 \log_{10} \left(\frac{L^2}{\text{MSE}(\tilde{x}, x)} \right) \quad (1)$$

其中, x 为参考图像; \tilde{x} 为实验结果; L 是图像的像素值取值范围,对于 LoDoPaB-CT 数据, $L=1.0$ 。SSIM 主要用于评价实验结果与参考图像之间的结构相似程度,取值范围为 0~1,值越大图像越相似,公式如下所示:

$$\text{SSIM}(\tilde{x}, x) = \frac{1}{M} \sum_{j=1}^M \frac{(2\tilde{u}_j u_j + C_1)(2\sum_j + C_2)}{(\tilde{u}_j^2 + u_j^2 + C_1)(\tilde{\sigma}_j^2 + \sigma_j^2 + C_2)} \quad (2)$$

其中, M 为样本数; u_j, \tilde{u}_j 分别表示参考图像 x 和实验结果 \tilde{x} 的均值; $\sigma_j^2, \tilde{\sigma}_j^2$ 分别表示 x, \tilde{x} 的方差; $C_1=(K_1 L)^2$, $C_2=(K_2 L)^2$ 是为了避免公式除零的两个常数, $K_1=0.01, K_2=0.03$ 。

2 结果

2.1 去噪效果

本研究从测试结果中随机选取 2 名受试者的部分图像展示去噪效果,图中红框区域显示了放大后图像的去噪表现,如图 4 所示。从图中可以看出相对于 FBP,所提方法明显提升图像的质量,并去除大部分噪声,其结果与标准剂量图像相似。

2.2 评价指标结果

运用 PSNR 与 SSIM 对测试集进行评估,表 1 为本研究所提的 MPR U-net 深度学习模型与 FBP 及其它深度学习方法的指标结果。与 FBP 比较,本研究提出的




图4 FBP重建图像、标准图像和本文方法重建图像比较

Figure 4 Comparison among images reconstructed by FBP, standard images and images obtained by the proposed method

方法去噪效果提升明显,PSNR和SSIM均高于FBP。与U-net模型相比,所提的多尺度结构与残差连接相组合的方法可以进一步提升模型的去噪性能。同时与最新LDCT图像深度学习去噪方法Learned Primal-Dual^[16,23]比较,虽然PSNR略低于该方法,但SSIM相较于该方法得到提升。主要原因在输入数据时采用多尺度的结构帮助提取了更多图像特征,更有利于恢复图像原本信息;另外该指标表明MPR U-net得到的结果与标准剂量图像最相似,因为SSIM越高,图像失真越小,越接近原始参考图像。然而本研究仅针对模拟的LDCT图像去噪,缺乏实际的LDCT扫描数据,后续研究需要采集更多的真实数据,进一步提升PSNR。

表1 不同方法的PSNR与SSIM比较
Table 1 Comparison of PSNR and SSIM
among different methods

方法	PSNR/dB	SSIM
FBP	28.80	0.786
U-net	37.18	0.959
Learned Primal-Dual ^[16,23]	40.52	0.926
MPR U-net(本文方法)	38.22	0.966

3 讨论

LDCT图像去噪的重点在于去除噪声的同时保留有用的临床诊断信息。本研究提出MPR U-net深度学习模型对LDCT图像进行去噪,相较传统去噪算法,能有效去除噪声并保留图像细节,在测试集上PSNR和SSIM分别达到38.22 dB和0.966,平均处理时间只需0.03 s,其中SSIM高于最新深度学习方法(Learned Primal-Dual)。

LDCT图像的噪声出现位置与程度不确定,采用单尺度的特征提取方式不能有效获取图像的全部特征,因此本研究在U-net深度学习模型基础上引入多尺度并行特征提取模块加大网络的感受野,获取更多图像特征信息,并利用跳跃连接方式传递特征信息,减少输入与输出之间特征图的差异,提升模型的去噪性能。另外通过残差连接让浅层特征输出直接参与到深层特征输入中,改善随着网络层数加深带来的梯度消失问题,进一步提升网络性能。

4 结论

本研究针对LDCT图像,提出MPR U-net深度学习模型对其去噪。该模型融入多尺度并行残差结构,相较传统方法有较高的PSNR与SSIM。与最新深度学习方法相比具有更高的SSIM,在去除噪声的同时具有更高的结构相似性。未来研究中,将继续对模型结构进

行优化,收集更多真实的LDCT数据,进一步提升LDCT图像的质量,帮助医生更准确地诊断疾病。

【参考文献】

- [1] Naidich DP, Marshall CH, Gribbin C, et al. Low dose CT of the lungs: preliminary observations[J]. Radiology, 1990, 175(3): 729-731.
- [2] Jeffers CD, Pandey T, Jambhekar K, et al. Effective use of low-dose computed tomography lung cancer screening[J]. Curr Probl Diag Radiol, 2013, 42(5): 220-230.
- [3] Pinsky PF. Assessing the benefits and harms of low-dose computed tomography screening for lung cancer[J]. Lung Cancer Manag, 2014, 3(6): 491-498.
- [4] Li Z, Huang J, Yu L, et al. Low-dose CT image denoising using cycle-consistent adversarial networks [C]//2019 IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC). Manchester: IEEE, 2019: 1-3.
- [5] Wang J, Li T, Lu H, et al. Penalized weighted least-squares approach to sinogram noise reduction and image reconstruction for low-dose X-ray computed tomography[J]. IEEE Trans Med Imaging, 2006, 25(10): 1272-1283.
- [6] Li Z, Yu L, Trzasko JD, et al. Adaptive nonlocal means filtering based on local noise level for CT denoising[J]. Med Phys, 2014, 41(1): 011908.
- [7] Manduca A, Yu L, Trzasko JD, et al. Projection space denoising with bilateral filtering and CT noise modeling for dose reduction in CT[J]. Med Phys, 2009, 36(11): 4911-4919.
- [8] Karimi D, Deman P, Ward R, et al. A sinogram denoising algorithm for low-dose computed tomography[J]. BMC Med Imaging, 2016, 16: 11.
- [9] Ghadrani S, Alirezaie J, Dillenseger JL, et al. Low-dose computed tomography image denoising based on joint wavelet and sparse representation[C]//2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Chicago: IEEE, 2014: 3325-3328.
- [10] Patel SM, Dharwa JN. Medical image enhancement through deep learning methods[J]. Nat J Syst Inform Technol, 2018, 11(1): 35-44.
- [11] Lakhani P, Gray DL, Pett CR, et al. Hello world deep learning in medical imaging[J]. J Digit Imaging, 2018, 31(3): 283-289.
- [12] Green M, Marom EM, Kiryati N, et al. Efficient low-dose CT denoising by locally-consistent non-local means (LC-NLM)[C]// Medical Image Computing and Computer-Assisted Intervention - MICCAI 2016. Athens: MICCAI, 2016: 423-431.
- [13] Kuanar S, Athitsos V, Mahapatra D, et al. Low dose abdominal CT image reconstruction: an unsupervised learning based approach[C]// 2019 IEEE International Conference on Image Processing (ICIP). Taipei: IEEE, 2019: 1351-1355.
- [14] Heinrich MP, Stille M, Buzug TM. Residual U-Net convolutional neural network architecture for low-dose CT denoising[J]. Curr Dir Biomed Eng, 2018, 4(1): 297-300.
- [15] Baguer DO, Leuschner J, Schmidt M. Computed tomography reconstruction using deep image prior and learned reconstruction methods[J]. Inverse Probl, 2020, 36(9): 094004.
- [16] Leuschner J, Schmidt M, Ganguly PS, et al. Quantitative comparison of deep learning-based image reconstruction methods for low-dose and sparse-angle CT applications[J]. J Imaging, 2021, 7(3): 44.
- [17] Leuschner J, Schmidt M, Baguer DO, et al. LoDoPaB-CT, a benchmark dataset for low-dose computed tomography reconstruction [J]. Scientific Data, 2021, 8: 109.
- [18] Armato SG, McLennan G, Bidaut L, et al. The lung image database consortium (LIDC) and image database resource initiative (IDRI): a completed reference database of lung nodules on CT scans[J]. Med Phys, 2011, 38(2): 915-931.
- [19] Zeng GL. Model based filtered backprojection algorithm: a tutorial[J]. Biomed Eng Lett, 2014, 4(1): 3-18.
- [20] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//In Proceedings of the 32nd International Conference on International Conference on Machine Learning (ICML'15). Lille: ICML, 2015, 37: 448-456.
- [21] Nair V, Hinton GE. Rectified linear units improve restricted boltzmann machines[C]//In Proceedings of the 27th International Conference on International Conference on Machine Learning (ICML'10). Haifa: ICML, 2010: 807-814.
- [22] Singarimbun RN, Nababan EB, Sitompul OS. Adaptive moment estimation to minimize square error in backpropagation algorithm[C]// In 2019 International Conference of Computer Science and Information Technology (ICoSNKOM). Medan: IEEE, 2019: 1-7.
- [23] Adler J, Öktem O. Learned primal-dual reconstruction[J]. IEEE Trans Med Imaging, 2018, 37(6): 1322-1332.

(编辑:谭斯允)