

ChestDS: A deep learning denoising model for low-dose chest CT

LI Ziyuan, LI Jianhui, ZHANG Xiaodong, LIU Jia, LI Wei, LIU Jianxin, WANG He*

(Department of Radiology, Peking University First Hospital, Beijing 100034, China)

[Abstract] **Objective** To develop a deep learning (DL) denoising model for low-dose chest CT (LDCT), and to observe its effect. **Methods** Based on ResNet feature extraction, UNet generation and VGG style loss, a ChestDS denoising model was established using data from training set (18 351 pairs of 2D images from AAPM dataset) and validation set (128 pairs of 2D images from AAPM dataset). The consistency of inter-observer subjective evaluation in visual assessment test set (LDCT images of 100 cases from a single center) was analyzed, and the subjective scores before and after denoising using ChestDS model were compared. Based on peak signal-to-noise ratio (PSNR) and structural similarity index measure (SSIM), the performance of ChestDS model for denoising and displaying anatomical structures were objectively evaluated with AAPM test set (211 pairs of 2D images). **Results** Before and after denoising using ChestDS model, the intra-class correlation coefficient (ICC) for noise score in lung window CT images was 0.88 and 0.96 (both $P < 0.05$), respectively, while ICC for noise score in mediastinal window CT images was 0.50 and 0.86, respectively (both $P < 0.05$), and the scores of image quality and displaying key anatomical structures were significantly improved (all $P < 0.05$). In AAPM test set, PSNR and SSIM of ChestDS model was 49.05 dB and 0.99, respectively. **Conclusion** ChestDS model applied in LDCT images could improve imaging quality through denoising and reduce radiation dose.

[Keywords] thorax; tomography, X-ray computed; radiation dosage; image processing, computer-assisted; deep learning

DOI:10.13929/j.issn.1003-3289.2026.01.026

ChestDS: 基于深度学习的胸部低剂量 CT 降噪模型

李子元, 李建辉, 张晓东, 刘佳, 李玮, 刘建新, 王鹤*

(北京大学第一医院医学影像科, 北京 100034)

[摘要] **目的** 基于深度学习(DL)建立胸部低剂量CT(LDCT)图像降噪模型并观察其效果。**方法** 基于ResNet图像特征提取编码器、UNet网络图像生成解码器及VGG网络图像风格损失函数,利用AAPM数据训练集(18 351对2D图像)和AAPM数据验证集(128对2D图像)数据生成ChestDS降噪模型;于视觉评估测试集(来自单中心的100例LDCT图像)分析观察者间主观评分的一致性,比较利用模型降噪前、后主观评分,并根据峰值信噪比(PSNR)及结构相似性(SSIM)于AAPM数据测试集(211对2D图像)对降噪及显示解剖结构效果进行客观评价。**结果** 降噪前、后肺窗噪声评分组内相关系数(ICC)分别为0.88及0.96(P 均 < 0.05),纵隔窗噪声评分ICC分别为0.50及0.86(P 均 < 0.05);图像质量评分及关键解剖结构显示评分均显著提升(P 均 < 0.05)。ChestDS模型在AAPM数据测试集的PSNR为49.05 dB、SSIM为0.99。**结论** ChestDS模型用于LDCT图像可在通过降噪提高图像质量的同时降低辐射剂量。

[关键词] 胸部; 体层摄影术, X线计算机; 辐射剂量; 图像处理, 计算机辅助; 深度学习

[中图分类号] TP181; R816.4 **[文献标识码]** A **[文章编号]** 1003-3289(2026)01-0124-04

[基金项目] 北京大学医学部教育教学研究课题项目(2024YB23)。

[第一作者] 李子元(1987—),男,黑龙江鸡西人,本科,主管技师。研究方向:医学影像技术。E-mail: lzy230321@163.com

[通信作者] 王鹤,北京大学第一医院医学影像科,100034。E-mail: wanghecrane@126.com

[收稿日期] 2025-06-09 **[修回日期]** 2025-11-21

低剂量 CT(low-dose CT, LDCT)可降低辐射风险,但图像噪声及伪影显著等问题可能影响诊断准确性^[1-2]。传统降噪方法在消除噪声时易丢失重要细节,深度学习(deep learning, DL)技术,特别是卷积神经网络(convolutional neural network, CNN)和生成对抗网络(generative adversarial network, GAN)用于 LDCT 图像去噪与重建表现出色^[3-7]。本研究基于 DL 建立胸部 LDCT 图像降噪模型并观察其效果。

1 资料与方法

1.1 研究对象 获取数据:①开源数据集(AAPM Low Dose CT Grand Challenge) (<https://www.aapm.org/GrandChallenge/LowDoseCT/>)中包括 10 名受检者的标准剂量 CT 及相应四分之一剂量 CT 图像(LDCT 图像),将每帧 3D CT 图像(维度为 512×512×N,N 表示层数)提取为 2D 轴位切片,最终获得 18 690 对 2D 图像对;②回顾性收集 2024 年 1 月—3 月北京大学第一医院 100 名受检者的胸部 LDCT 图像。将 AAPM 数据集分为训练集(8 名共 18 351 对)、验证集(1 名 128 对)与测试集(1 名 211 对)512×512 大小的 2D CT 图像,并以北京大学第一医院 100 名胸部 LDCT 作为视觉评估测试集。本研究获院伦理审查委员会的批准(2024 研 116-003)。

1.2 模型结构 基于 Pytorch 1.4.0、fastai 2.1.10 与 NVIDIA Tesla V100 GPU 生成 2D ChestDS 降噪模型,已实现输入原始 2D CT 图像数据后输出降噪后的 2D CT 图像。该模型由深度残差网络(ResNet)^[8-9]构建图像特征提取编码器,得到图像特征后由 UNet 网络^[10-11]组成图像生成编码器模块,结合以 ImageNet 预训练 VGG(Visual Geometry Group)网络^[12]为基础而构建的风格损失函数自动生成降噪图像,见图 1。

1.3 损失函数 采用由均方误差(mean squared error, MSE)损失(L_{MSE})、交叉熵损失(L_{CE})及感知损失(L_{VGG})综合形成的风格损失函数。

L_{MSE} 计算模型输出与目标图像之间的平方误差之和,见公式(1):

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N [T(i, j) - P(i, j)]^2 \quad (1)$$

其中, $T(i, j)$ 是目标图像在位置 (i, j) 的像素值。 $P(i, j)$ 是预测图像在位置 (i, j) 的像素值。 M 和 N 分别是图像的行数和列数。

L_{CE} 见公式(2):

$$\text{CrossEntropy} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + o = \hat{y}_i(1 - y_i) \log(1 - \hat{y}_i)] \quad (2)$$

其中, y_i 是真实标签, \hat{y}_i 是模型预测的标签, N 是样本数量。

L_{VGG} 见公式(3):

$$\text{PerceptualLoss} = \frac{1}{C \cdot H \cdot W} \sum_{i=1}^C \sum_{j=1}^H \sum_{k=1}^W [\varphi(T)(i, j, k) - \varphi(P)(i, j, k)]^2 \quad (3)$$

其中, $\varphi(T)$ 和 $\varphi(P)$ 分别是原始图像和失真图像通过预训练网络提取的特征, C 、 H 和 W 分别代表特征的通道数、高度和宽度。

风格损失函数见公式(4):

$$L_{total} = \alpha L_{MSE} + \beta L_{CE} + \gamma L_{VGG} \quad (4)$$

其中超参数经网格搜索确定为 $\alpha=0.6$, $\beta=0.2$, $\gamma=0.2$, 分别用于主导像素级灰度保真并预防结构畸变,增强器官边界判别,以及约束组织纹理的生物合理性。

1.4 主观评分 由 2 名具有 10 年以上胸部影像学诊断经验的影像科医师采用双盲法对利用模型降噪前、后 CT 图像质量进行主观评分。

1.4.1 评估体系 建立三维度+指标评估系统。噪声特征:肺窗/纵隔窗 CT 噪声与伪影评分;显示解剖结构:肺实质/血管支气管/纵隔肺门/腹部器官清晰度;对比特性:肺窗/纵隔窗图像组织对比度。

1.4.2 评分标准 采用 5 级 Likert 量表进行评分。

- 1 分:显著影响诊断,结构无法辨识;
- 2 分:存在明显缺陷,需要重复扫描;
- 3 分:满足基本诊断需求;
- 4 分:细节显示清晰,满足高级诊断;
- 5 分:呈现完美解剖细节;噪

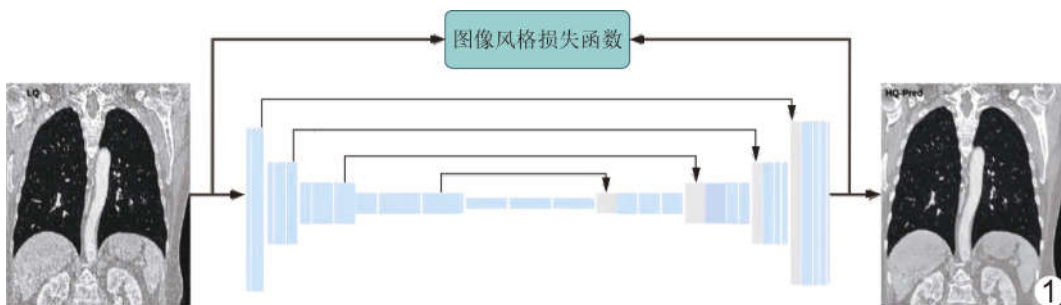


图 1 ChestDS 模型图

声指标反向计分。评估前通过典型病例图谱校准评分标准。

1.4.3 质量控制 ①阅前校准:利用 20 例典型病例(含 5 例争议样例)统一评分尺度,组内相关系数(intra-class correlation coefficient, ICC) > 0.90 方可进入正式评估;②交叉复核:2 名医师独立评分后,对差异 ≥ 2 分的项目启动 3 次会诊复核。

1.4.4 统计学分析 以 ICC 评估观察者间一致性,以 Wilcoxon 符号秩检验分析降噪前、后评分结果。P < 0.05 为差异有统计学意义。

1.5 客观评估 在测试集中通过目标图像 T 与预测生成图像 P 之间的峰值信噪比(peak signal-to-noise ratio)和结构相似性(structure similarity index measure, SSIM)评价模型效能,并与现有主流降噪模型(包括 REDCNN^[13]和 CTformer^[14]等)进行比较。

1.5.1 PSNR 通过比较目标图像 T 和预测图像 P 计算信号最大可能功率与影响观察的噪声功率比值,数值越高表示图像质量越好:

$$PSNR = 10 \log_{10} \left\{ \frac{MAX_I^2}{MSE} \right\} \quad (5)$$

其中的 MAX_I 是图像数据的最大可能值。

1.5.2 SSIM SSIM 是衡量 2 幅图像相似度的指标,介于 -1 和 1 之间,其值为 1 时表示 2 幅图像完全相同^[15]。

$$SSIM(T, P) = \frac{(2 \mu_T \mu_P + C_1)(2 \sigma_{TP} + C_2)}{(\mu_T^2 + \mu_P^2 + C_1)(\sigma_T^2 + \sigma_P^2 + C_2)} \quad (6)$$

其中, μ_T 和 μ_P 分别是图像 T 和 P 的平均亮度, σ_T² 和 σ_P² 分别是图像 T 和 P 的方差, σ_{TP} 是图像 T 和 P 的协方差, C₁ 和 C₂ 是常数,通常 C₁ = (0.01L)²、C₂ = (0.03L)²。

2 结果

2.1 主观评分 2 名观察者分别对降噪前、后视觉评估测试集 CT 图像进行主观评分。

2.1.1 观察者间一致性 降噪前肺窗原始图像噪声评分、肺实质清晰度、血管支气管显示、图像对比度及伪影评分的 ICC 分别为 0.88(0.82, 0.92)、0.90(0.84, 0.93)、0.93(0.89, 0.95)、0.93(0.90, 0.95)及 0.88(0.82, 0.92),降噪后分别为 0.96(0.94, 0.97)、0.96(0.95, 0.98)、0.97(0.95, 0.98)、0.98(0.97, 0.99)及 0.87(0.81, 0.91)。

降噪前纵隔窗原始图像噪声评分、纵隔肺门显示、肝脏/肾脏/肾上腺清晰度、图像对比度及伪影评分的

ICC 分别为 0.50(-0.08, 0.81)、0.56(-0.09, 0.82)、0.52(-0.07, 0.82)、0.51(-0.09, 0.81)及 0.53(-0.09, 0.82),降噪后分别为 0.86(0.75, 0.91)、0.88(0.81, 0.93)、0.80(0.64, 0.89)、0.86(0.76, 0.91)及 0.86(0.77, 0.91)。

2.1.2 降噪前、后主观评分比较 降噪前肺窗原始图像噪声评分、肺实质清晰度、血管支气管显示、图像对比度及伪影评分平均主观评分分别为 3.40 ± 0.67、3.43 ± 0.71、3.53 ± 0.67、3.55 ± 0.70 及 3.62 ± 0.60,降噪后分别提升至 4.04 ± 0.62、4.10 ± 0.67、4.11 ± 0.71、4.26 ± 0.71 及 3.79 ± 0.56(P 均 < 0.001)。

降噪前纵隔窗噪声评分、纵隔肺门显示、肝脏/肾脏/肾上腺清晰度、图像对比度及伪影评分平均主观评分分别为 1.82 ± 0.82、1.98 ± 0.89、1.69 ± 0.84、1.83 ± 0.83 及 1.85 ± 0.86,降噪后分别提升至 3.20 ± 0.85、3.30 ± 0.85、3.01 ± 0.93、3.16 ± 0.83 及 3.19 ± 0.84(P 均 < 0.001)。

2.2 客观评估 ChestDS 模型在 AAPM 数据测试集中的 PSNR 为 49.05 dB、SSIM 为 0.99,均优于现有主流降噪模型(REDCNN、CTformer 等),见表 1。

表 1 各模型降噪效能比较

模型	PSNR(dB)	SSIM
REDCNN	33.19	0.91
Eformer	33.35	0.92
CTformer	33.25	0.91
ChestDS	49.05	0.99

3 讨论

LDCT 可致图像信噪比下降、增加噪声及伪影,影响图像质量及诊断准确性;利用 DL 技术对 LDCT 图像进行去噪和重建有助于解决上述问题^[1-2,13-14]。本研究采用深度残差网络架构和结合了多种损失函数的综合风格损失函数生成的 ChestDS 降噪模型不仅能降低 LDCT 噪声,并保留了重要结构细节,有助于提高诊断准确性;且模型降噪效果分别于 AAPM 开源低剂量模拟数据集与单中心胸部 LDCT 数据集中得到验证。

本研究主观评分结果显示,降噪后,除伪影评分 ICC 出现微小波动外,肺窗 CT 图像其余评价指标的 ICC 均提升至 0.95 以上,证实所获 ChestDS 模型显示肺部细微结构(如支气管血管束)高度可靠。降噪前原始图像 ICC 均低于 0.6 且置信区间包含负值,提示观察者间一致性差;降噪后纵隔窗 CT 图像各指标 ICC 均提升至 0.80 以上,其中噪声评分的 ICC 从

0.50 提高到 0.86、显示肝脏/肾脏评分的 ICC 从 0.52 提至 0.80,表明 ChestDS 降噪模型可显著提升软组织对比度,尤其对于检出腹部肿瘤具有潜在应用价值。基于 AAPM 数据测试集的定量分析结果表明,相比现有主流降噪模型,ChestDS 模型的 PSNR 及 SSIM 均表现更佳性能,主要原因在于,相比 CTformer 等基于纯 Transformer 的模型,本研究所用方法在保持解剖结构完整性的同时有效克服了过度平滑问题。

综上,ChestDS 模型用于 LDCT 图像可在通过降噪提高图像质量的同时降低辐射剂量。本研究的主要局限性在于仅基于 PSNR 及 SSIM 进行客观评价,PSNR 对均匀区域噪声敏感、但可能低估细微结构损失(如亚段支气管壁的显示不连续),而 SSIM 虽能反映结构相似度、捕捉解剖失配,但评估诊断需要的关键特征(如磨玻璃结节边缘的毛刺征)的能力有限;有待后续通过前瞻性、多中心、随机对照临床试验验证 ChestDS 模型在临床工作中的应用价值并优化其泛化能力。

利益冲突:全体作者声明无利益冲突。

作者贡献:李子元查阅文献、数据分析、撰写文章;李建辉和刘佳图像处理和分析;张晓东研究设计、统计分析;李玮修改和审阅文章;刘建新审阅文章;王鹤指导、审阅文章、经费支持。

[参考文献]

- [1] YUAN H, JIA J, ZHU Z. SIPID: A deep learning framework for sinogram interpolation and image denoising in low-dose CT reconstruction[C]//2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), April 4—7, 2018, Omni Shoreham Hotel, Washington, DC. Piscataway, NJ: IEEE, 2018:1521-1524.
- [2] YIN X, ZHAO Q, LIU J, et al. Domain progressive 3D residual convolution network to improve low-dose CT imaging[J]. IEEE Trans Med Imaging, 2019, 38(12):2903-2913.
- [3] 毕忠旭,李子元,周宇,等.基于深度学习模型的 X 线胸片去骨的初步研究[J].放射学实践,2021,36(12):1582-1586.
- [4] 任昕,刘水,张晓东,等.基于 AI 算法的磁共振检查预约准时与迟到预测的可行性研究及其临床应用[J].中国医疗设备,2022,37(12):44-48.
- [5] 张晓东,孙兆男,任昕,等.基于深度残差网络研发辅助诊断软件用于 X 线胸片分类诊断[J].放射学实践,2019,34(9):952-957.
- [6] 张晓东,刘想,谢辉辉,等.使用深度学习模型对头颅 CT 平扫图像进行二分类的初步探讨[J].实用放射学杂志,2020,36(10):1670-1675.
- [7] 张晓东,邢倩,韩超,等.基于机器学习的低剂量胸部 CT 肺结节分类和预后随访的研究[J].临床放射学杂志,2020,39(10):1962-1966.
- [8] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27—30, 2016, Caesar's Palace Las Vegas, NV. Piscataway, NJ: IEEE, 2016:770-778.
- [9] TRAN D, WANG H, TORRESANI L, et al. A closer look at spatiotemporal convolutions for action recognition [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18—23, 2018, Calvin L. Rampton Salt Palace Convention Center, Salt Lake City, UT. Piscataway, NJ: IEEE, 2018:6450-6459.
- [10] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention: MICCAI 2015, October 5—9, 2015, Munich Philharmonic Hall (Gasteig), Munich. Cham: Springer, 2015:234-241.
- [11] ISENSEE F, JAEGER P F, KOHL S A A, et al. nnU-Net: A self-configuring method for deep learning-based biomedical image segmentation[J]. Nat Methods, 2021, 18(2):203-211.
- [12] JOHNSON J, ALAHI A, FEI-FEI L. Perceptual losses for real-time style transfer and super-resolution [C]//Computer Vision: ECCV 2016, October 11—14, 2016, Koninklijk Theater Carré, Amsterdam. Cham: Springer, 2016:694-711.
- [13] CHEN H, ZHANG Y, KALRA M K, et al. Low-dose CT with a residual encoder-decoder convolutional neural network [J]. IEEE Trans Med Imaging, 2017, 36(12):2524-2535.
- [14] WANG D, FAN F, WU Z, et al. CTformer: Convolution-free Token2Token dilated vision transformer for low-dose CT denoising[J]. Phys Med Biol, 2023, 68(6). doi:10.1088/1361-6560/acc000.
- [15] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: From error visibility to structural similarity [J]. IEEE Trans Image Process, 2004, 13(4):600-612.