

基于噪声水平估计的多孔准直 X 射线荧光 CT 去噪算法

赵如歌¹, 冯鹏^{1,2*}, 罗燕¹, 张颂¹, 何鹏^{1,2}, 刘亚楠^{3**}

¹重庆大学光电技术及系统教育部重点实验室, 重庆 400044;

²重庆大学工业 CT 无损检测教育部工程研究中心, 重庆 400044;

³重庆工商职业学院电子信息工程学院, 重庆 400032

摘要 X 射线荧光 CT (XFCT) 是 X 射线 CT 与 X 射线荧光分析相结合的新型成像方式, 可用于探测被修饰后的纳米金颗粒在肿瘤内部的分布及质量分数, 在早期癌症诊疗方面具有较好的应用潜力。如何抑制 XFCT 成像的康普顿散射噪声是当前的热点问题。本文基于深度学习方法, 通过卷积神经网络学习图像中的噪声分布规律, 从而抑制噪声。基于此, 提出了一种基于噪声水平估计和卷积神经网络的 XFCT 去噪网络 (NeCNN) 算法, 该算法运用噪声估计子网络及去噪主网络进行去噪。估计子网络通过去噪卷积神经网络 (DnCNN) 估计噪声水平并初步降噪, 随后将估计结果输入去噪主网络——全卷积神经网络 (FCN) 用于学习康普顿散射的分布规律, 同时为兼顾局部与全局最优解采用均方误差 (MSE) 及结构相似度 (SSIM) 作为损失函数。数据集通过 Geant4 软件模拟扫描填充各种金属纳米颗粒 (Au、Bi、Ru、Gd) 的空气模体及聚甲基丙烯酸甲酯 (PMMA) 模体来获取, 且设置不同入射 X 射线的强度, 以此模拟不同噪声水平, 增强模型泛化能力。实验结果表明, 与三维块匹配滤波 (BM3D) 及 DnCNN 算法相比, NeCNN 算法的去噪结果最优, 其 SSIM 为 0.95066, 峰值信噪比 (PSNR) 为 29.01558, 图像质量提高最为显著。

关键词 X 射线荧光 CT; 康普顿散射; 噪声估计; NeCNN 算法

中图分类号 O434.1

文献标志码 A

DOI: 10.3788/AOS230679

1 引言

随着纳米药物的飞速发展, 将 X 射线荧光 CT (XFCT) 运用于活体成像, 检测早期癌症病灶成为可能。由于早期 XFCT 成像所用光源为同步辐射源, 其成本昂贵且体积庞大, 获取难度大。因此, 学者们开始使用常规 X 射线管源作为替代光源研究 XFCT 的成像性能。Manohar 在 2013 年利用蒙特卡罗中子输运 (MCNP) 程序模拟了将常规 X 射线管源作为入射源, 激发聚甲基丙烯酸甲酯 (PMMA) 模体内填充 0.5% (质量分数) 金纳米颗粒 (GNPs) 进行的成像^[1]; 2016 年, 该团队将常规 X 射线管源运用于活体实验, 对荷瘤小鼠内部的 GNPs 进行了成像, 实验结果表明, XFCT 的探测精度比常规 X 射线管源高两个数量级^[2]。然而, 常规 X 射线管源是宽能谱, 会产生大量的康普顿散射, 导致重建图像背景噪声严重, 难以达到临床应用水平。为了进一步提高检测精度, 学者们对 XFCT 的图像进行去噪研究。各类去噪方法可分为前处理方法与

后处理方法, 其中前处理方法主要包括调整辐射剂量、改善成像条件等。Hanson 等^[3]提出当 X 射线源入射方向平行于探测器方向时, 能够有效降低康普顿散射的影响。Deng 等^[4]提出使用针孔准直器进行 X 射线荧光成像, 利用其结构简单、可变焦的优点提升成像质量。后处理方法是对探测器所探测数据进行处理, 因为探测器所探测光子包含荧光光子和散射光子, 常用的去噪方法包括背景拟合法、扫描相减法、迭代去噪法及深度学习法等。背景拟合法^[5-6]通过插值拟合荧光能量处的散射光子数, 用总光子数 (N_{total}) 剔除拟合得到的散射光子数 (N_{scatter}), 即为荧光光子数 (N_{fluo}): $N_{\text{fluo}} = N_{\text{total}} - N_{\text{scatter}}$ 。该方法在拟合背景时需要根据实验设置及应用场景实时调整, 且光谱的半峰全宽较大, 适用于入射光子通量大、成像时间较长的场景 (如同步辐射 XFCT 成像), 但对基于宽能谱常规 X 射线管源的 XFCT 而言, 背景拟合的准确性不高。扫描相减法需要进行两次 XFCT 扫描, 一次是未在模体中填充造影剂时, 另一次是已在模体中填充造影剂后^[7]。因

收稿日期: 2023-03-15; 修回日期: 2023-04-18; 录用日期: 2023-05-19; 网络首发日期: 2023-06-28

基金项目: 重庆市科委基础研究与前沿探索专项 (cstc2020jcyj-msxmX0553)、重庆市研究生科研创新项目 (CYB21059)、重庆市科委技术创新与应用发展专项 (cstc2021jcsx-gksbX0056)、重庆市教委科研项目 (KJQN201904007)

通信作者: *coe-fp@cqu.edu.cn; **2030329861@qq.com

为两次扫描的时间、射线参数、几何位置关系等条件完全一致,对两次扫描的结果进行相减运算后,可以去除第二次扫描时由于模体本身导致康普顿散射噪声的影响,从而使得用于重建的数据大部分是有效的荧光光子信号,能提高重建图像的信噪比^[7]。该方法的优点是对于固定的待测样品,可以通过多次空扫描获取更为精确的背景噪声分布规律,生成信噪比更高的重建图像;但主要缺点在于需要两次扫描,额外增加了实验中待测样品对 X 射线的吸收剂量。迭代去噪法则属于在传统 XFCT 重建算法的基础上,将对散射光子的修正嵌入迭代算法中,分别对荧光信号和散射噪声进行估计与迭代,以降低散射噪声带来的影响。该方法可以获得较好的重建结果,但往往需要多次迭代,散射噪声的估计容易陷入局部最优,通常需引入全变差作为惩罚函数,耗时较长^[8-9]。基于深度学习的去噪和重建方法在生物发光断层成像(BLT)^[10]、锥束 X 射线磷光断层成像(XLCT)^[11]等同属发射 CT 成像模态中已有应用,利用深度学习强大的特征学习能力,无需成像系统的参数等先验信息,可有效降低由于背景噪声等问题带来的干扰,获得良好的成像质量。但上述方法并未考虑康普顿散射噪声的影响,对于信噪比更低的多孔准直 XFCT 成像,如何有效降低康普顿散射噪声的影响,提高重建图像质量则尤为重要。

综上所述,本文提出一种基于噪声水平估计和卷积神经网络的 XFCT 图像去噪网络(NeCNN)算法,探索利用深度学习来实现对图像噪声水平的估计和去噪,并通过 Geant4 算法模拟获取的数据集,验证提出算法的可行性,为后续进一步运用于实际 XFCT 系统奠定基础。

2 实验仿真

2.1 XFCT 原理

XFCT 为激发成像,当一定能量的射线照射原子使其成为受激态,受激态不稳定退激释放能量。由于荧光能量是内外电子层的能级差,且特定元素的荧光产额是一定的,即可根据测量的荧光能量对元素进行定性和定量分析^[5]。将金属纳米粒子附着于靶向材料时,由浓度分布可标记早期癌症病灶位置。

在探测时,为了便于得出荧光光子及入射光子的关系,考虑到常见的 XFCT 为旋转加平移模式,建立固定于样品上的旋转坐标系 $x-y$ 和实验坐标系 $s-t$ (图 1),在扫描成像中, $s-t$ 坐标系是 $x-y$ 坐标系绕原点顺时针旋转 α 所得, $s-t$ 和 $x-y$ 的关系如下:

$$\begin{cases} s = x \cos \alpha + y \sin \alpha \\ t = -x \sin \alpha + y \cos \alpha \end{cases}, \quad (1)$$

$$I = \int_{-\infty}^{+\infty} f(\alpha, s, t) g(\alpha, s, t) dt, \quad (2)$$

式中:




图 1 XFCT 成像原理图

Fig. 1 Schematic diagram of XFCT imaging

$$f(\alpha, s, t) = I_0 \exp \left[- \int_{-\infty}^s \mu^l(s, t') dt' \right]; \quad (3)$$

$$g(\alpha, s, t) = \mu_{\text{ph}} \omega \int_{\gamma^m}^{\gamma^M} \exp \left[- \int_0^{+\infty} \mu^F(s - b \sin \gamma, s + b \cos \gamma) db \right] d\gamma, \quad (4)$$

式中: $f(\alpha, s, t)$ 表示入射 X 射线经过路径 PQ 时的衰减; $g(\alpha, s, t)$ 表示 Q 点发射的荧光经过衰减到达探测器; α 表示入射 X 射线的角度偏移量; s 表示其平移偏移量; μ_{ph} 表示材料的光电吸收系数; ω 表示荧光产额; γ 表示荧光 X 射线与 t' 轴的夹角, γ^m 为其最小值, γ^M 为其最大值; I_0 表示入射 X 射线的强度; I 表示探测器所接收的荧光光子总强度。

2.2 NeCNN 算法

XFCT 成像过程中图像退化主要受到康普顿散射、光子分布(量子噪声也称散粒噪声,下文均使用量子噪声)和探测器二极管(电子噪声)的影响,根据图像退化理论可以建立 XFCT 图像的退化模型,如下式所示:

$$b = k \times s + n, \quad (5)$$

式中,退化图像 b 可认为是退化函数 k 和加性噪声项 n 对输入图像 s 进行处理得到的。康普顿散射是一个复杂的物理过程,很难用概率分布模型描述其对图像退化过程的作用机理。文献^[12]中指出,光子之间碰撞的过程可等效为信道的不理想,因此本文将康普顿散射噪声近似为一种乘性噪声 n_k 。剩余的量子噪声 n_q 和电子噪声 n_e 均为加性噪声,因此式(5)可以改写为

$$b = n_k \times s + n_q + n_e. \quad (6)$$

退化图像 b 可认为是两个加性噪声:量子噪声 n_q 和电子噪声 n_e 对输入图像 s 进行处理得到的。量子噪声 n_q 是由光量子的分布不均匀造成的,满足泊松分布,其统计模型为

$$n_q(r; \lambda) = \frac{e^{-\lambda} \lambda^r}{r!}, \quad (7)$$

式中: r 为探测器接收到的光子数; λ 为随机事件的均值。电子噪声符合高斯分布,其统计模型为

$$n_e(z) = \frac{1}{\sqrt{2\pi}\delta} e^{-\frac{(z-\mu)^2}{2\delta^2}} \quad (8)$$

复杂的耦合过程使得估计噪声模型的先验分布变得十分困难,为此本文采用深度学习算法,自动拟合噪声的概率分布并去除噪声。由于康普顿散射噪声和另外两种加性噪声具有不同的特点,本文提出一种基于深度学习的 NeCNN 去噪算法,包括噪声估计子网络和去噪主网络,其流程图如图 2 所示。Zhang 等^[13]通过实验证明,去噪卷积神经网络(DnCNN)擅长处理高斯盲噪声,因此本文的噪声估计子网络采用 DnCNN 学习量子噪声 n_q 和电子噪声 n_e 。网络共十七层,各层的组成如下:第一层到第十六层皆采用 64 个卷积核,尺寸为 3×3 ,跨步为 1,使用零填充保持卷积后的输出形状,简单的零填充策略不会导致任何边界伪影。子网络以带有噪声的原图像作为网络的输入,输出为噪声图像(噪声图 1),因此可得到初步去噪后的图像,即中

间输出等于原图减去噪声图 1。

去噪主网络使用的是全卷积神经网络(FCN),主要用于学习具有乘性特性的康普顿散射噪声,此外该网络由于集成了反卷积模块,可以实现图像的去噪重建。该网络采用 ResNet50^[14]作为骨干网络,包含 32 个卷积核,尺寸为 3×3 。主网络的作用是进一步提取输入图像(中间输出)的噪声水平图,并将含噪图像与生成的噪声水平图相减进行再一次降噪,同时提升网络的泛化能力。去噪主网络采用端对端的深度卷积神经网络,将初步降噪后的图像作为输入,将人工标注法所得去噪后图像作为目标进行训练学习。且为了节省时间,模拟时采用空气装载的模体进行训练,将其迁移至 PMMA 模体中以模拟人体组织。NeCNN 的优化采用均方误差(MSE)作为损失函数,并对中间输出以及最终输出同时进行监督,以加强网络的性能。

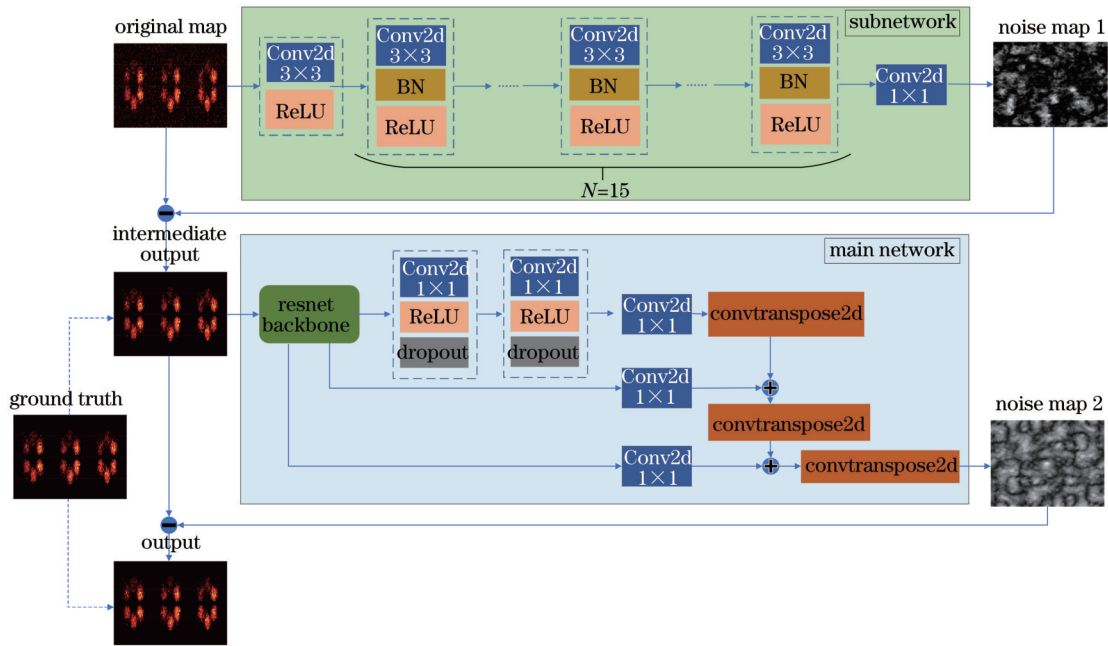


图 2 NeCNN 去噪算法流程图

Fig. 2 Flow chart of NeCNN denoising algorithm

2.3 实验设置

本文实验对比了 NeCNN、子网络 DnCNN^[12]及三维块匹配滤波(BM3D)算法^[15]的去噪结果。采用 MSE 及结构相似度(SSIM)作为网络训练时的损失函数(Loss),其目的是兼顾全局与局部的最优解。

$$L_{\text{loss}} = M_{\text{SE1}} + M_{\text{SE2}} + k \times S_{\text{SIM}}, \quad (9)$$

式中: M_{SE1} 为噪声初估计子网络输出的噪声初估计图与理论噪声之间的均方误差; M_{SE2} 为去噪主网络输出图像与参考图像的均方误差; S_{SIM} 为去噪主网络输出图像与参考图像之间的结构相似度。MSE 注重统计特征,未考虑人眼的感知特性,因此本文实验将 MSE 组合 SSIM 作为损失函数。经过多次对比实验可得, k

取 -0.2 时具有良好的去噪效果。

MSE 的计算表达式为

$$M_{\text{SE}} = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \quad (10)$$

SSIM 评估指标将人眼的视觉感知特性分为亮度、对比度与结构信息三部分,并在算法中相结合体现,其计算式为

$$S_{\text{SIM}} = l(x, y) \times c(x, y) \times s(x, y), \quad (11)$$

式中: x 与 y 分别代表待测图像与参考图像; $l(x, y)$ 、 $c(x, y)$ 和 $s(x, y)$ 分别对图像的亮度信息、对比度信息和结构信息进行计算,如下式所示:

$$l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1}, \quad (12)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2}, \quad (13)$$

$$s(x, y) = \frac{2\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3}, \quad (14)$$

式中: μ_x 、 μ_y 、 σ_x 、 σ_y 、 σ_{xy} 分别为待测图像与参考图像的均值、方差、协方差; C_1 、 C_2 、 C_3 均为正常数用于防止计算式的分母为零。

实验使用的编程语言为 Python 3.6, NeCNN 基于 Pytorch1.7.0 实现, 硬件平台配置为: Intel i5-9600kf CPU, Nvidia TITAN V (12 GB/Nvidia) GPU, 16 G DDR4 RAM。训练过程后的超参数如表 1 所示。

2.4 数据集

本文实验所用数据由 Geant4 模拟扫描模体获得。Geant4 是一款能够对基本粒子通过并与物质发生反应的过程进行蒙特卡罗模拟的软件, 通过蒙特卡罗模拟能够准确地仿真出粒子作用过程, 包括入射粒子与

表 1 NeCNN 超参数

Table 1 NeCNN hyperparameters

Hyperparameter	Value
Kernel size	3×3
Resolution	420×560
Num epoch	30
Layer	17
Learning rate	0.001
Optimizer	Adam
Batch size	8
Activation function	ReLU

材料的碰撞、激励、折射、吸收等。因此, 实验使用 Geant4 软件对入射 X 射线激发高原子序数元素作用生成特征荧光信号的过程进行模拟仿真并制作数据集^[16]。实验所用成像系统为多孔准直的快速成像系统, 此系统不需要平移旋转, 采用扇束扫描一次即可成像^[17]。系统设置如图 3 所示。




图 3 XFCT 成像系统设置

Fig. 3 Setup of XFCT imaging system

成像系统包含 X 射线源、待测模体、两组针孔准直器及两组荧光探测器。成像系统采用两组荧光探测器的目的在于, 可通过探测器测得投影数据的叠加等效获得双倍入射光子数下的投影, 从而降低辐射剂量。扇束 X 射线源与待测模体中心之间的距离为 15 cm, 针孔准直器与模体之间的距离为 5 cm, 探测器与针孔准直器之间的距离也为 5 cm。探测器由 55×185 个材料为碲化镉(CdTe)的探测晶体组成, 探测器能量分辨率为 0.5 keV, 晶体尺寸设计为 0.3 mm×0.3 mm。

为在有限的时间内尽可能获取更多的数据集, 本文实验将金属纳米粒子柱置于空气模体和 PMMA 模体分别进行仿真成像, 其中涉及到的元素种类包括金(Au)、钌(Ru)、铋(Bi)、钆(Gd)^[18-19]。成像模体设置为直径为 3 mm、高为 5 cm 的圆柱体, 元素质量分数的设

置分为高质量分数与低质量分数两种, 其中高质量分数分别为 0.2%、0.4%、0.6%、0.8%、1.0%、1.2%, 低质量分数分别为 0.10%、0.12%、0.14%、0.16%、0.18%、0.20%。PMMA 模体实物图与质量分数设置如图 4 所示。

训练所用数据集皆为直接放置于空气中, 与实际应用中探测人体相差较大, 因此将此模型迁移到 PMMA 中以模拟人体的组织情况。所以, 数据集获取部分还包括了 PMMA 模体的扫描, 数据集构成如表 2 所示。

标准数据集采用模拟仿真联合人工标注法获取。利用 1000 亿入射光子进行仿真, 按照文献[6]的方法构建探测系统并拟合背景噪声。采集各探测单元在元素特征 X 射线能量处接收的总光子数, 再通过多项式

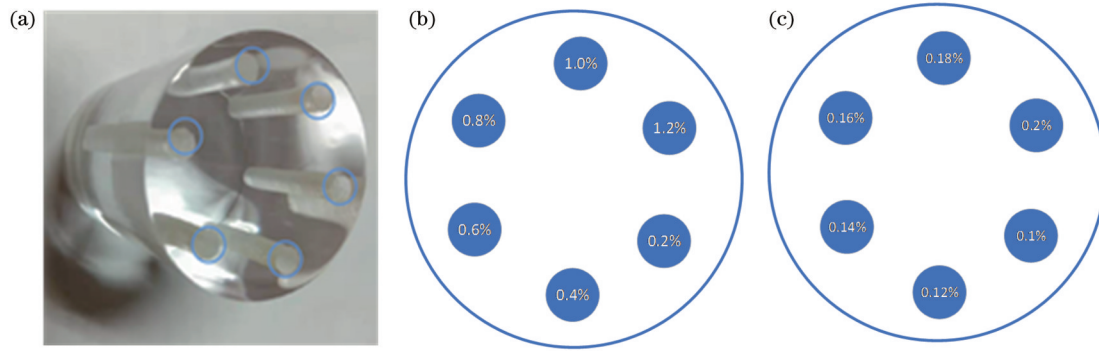


图 4 两种模体。(a) PMMA 模体实物;(b) 模体 1:高质量分数模体示意图;(c) 模体 2:低质量分数模体示意图

Fig. 4 Two kinds of phantoms. (a) Physical object of PMMA phantom; (b) phantom 1: phantom with high mass fraction; (c) phantom 2: phantom with low mass fraction

表 2 数据集参数设置

Table 2 Dataset parameter settings

Phantom	Air phantom	PMMA phantom
Image number	400	100
Format	.jpg	.jpg
Resolution	420×560	420×560
Number of training set	320	80
Number of test set	80	20

拟合扣除背景噪声得到可供计算使用的有效荧光光子




图 5 仿真产生的 XFCT 图像。(a) 含噪图像;(b) 标准图像

Fig. 5 XFCT images from simulation. (a) Noise image; (b) standard image (clean image)

3 实验结果

为了验证 NeCNN 算法的可行性,本文实验将其与经典的深度学习去噪网络 DnCNN 以及传统去噪算法 BM3D 进行比较。DnCNN 将残差学习与批归一化相结合,残差学习的使用避免了网络层数过深导致的梯度消失与梯度爆炸^[14];而批归一化能够在深层网络情况下更快地收敛。BM3D 算法是通过与相邻图像块进行匹配,将若干相似的块整合为三维矩阵,在三维空间进行滤波处理,再将结果反变换融合到二维,形成去噪后的图像^[15,20]。BM3D 算法的核心在于对噪声方差的估计,本文采用分块法对标准方差进行估计,将含噪图像分为多子块并分别计算其标准方差值,然后选取待定范围内的标准方差值均值作为含噪图像的整体方差。其中,图像子块划分参考了文献^[21]所提出的改

数,并生成对应的图像。该图像是在信噪比较强且扣除背景噪声的情况下获得的,可以用作本文算法的参考图像(标准图像)。由于计算能力的限制(探测单元越多,仿真的计算资源占用、时间消耗都将大幅增加),为了实现对整个模体的全覆盖,在设置探测阵列时,将行方向的探测单元数量与列方向的探测单元数量分别设置为 55 和 185,导致生成的图像在行列方向的比例不一致,列方向出现压缩,最终结果呈现椭圆形的现象。含噪图像及标准图像如图 5 所示。

进分块策略,最终确定所选子块尺寸为 20×20。DnCNN 和 BM3D 算法的参数分别如表 3 和表 4 所示。

本文使用峰值信噪比 (PSNR) 和 SSIM 作为网络

表 3 DnCNN 参数

Table 3 DnCNN parameters

Parameter	Value
Kernel size	3×3
Resolution	420×560
Num epoch	30
Layer	17
Learning rate	0.001
Optimizer	Adam
Batch size	8
Activation function	ReLU

表 4 BM3D 参数

Table 4 BM3D parameters

Parameter	Value
Size of block	20×20
Number of max matching block	16
Threshold of block-wise similarity (step 1)	250000
Threshold of block-wise similarity (step 2)	3600

输出图像的质量评价指标。PSNR 是广泛使用的图像质量的客观评价标准,其表达式为

$$P_{\text{SNR}} = 10 \lg \frac{M_{\text{AX}}^2}{M_{\text{SE}}}, \quad (15)$$

式中: M_{AX} 为图像像素的最大灰度值; M_{SE} 为均方误差。但是由于人眼对误差的感知结果的相对性,会受到空间频率及亮度等因素影响,因此亦采用 SSIM 作为标准,模拟人眼感知效果。

三种算法的去噪效果如表 5 所示,总体而言基于深度学习的去噪算法相比于传统的 BM3D 算法具有更优良的去噪性能,且 NeCNN 算法具有最大的 PSNR

(29.01558) 和 SSIM (0.95066) 值。相较于传统的 BM3D 算法, PSNR 和 SSIM 分别提升了 0.62013 和 0.14259, 表明此算法运用在 XFCT 图像去噪的良好效果。此外,相较于 DnCNN, 其 PSNR 和 SSIM 分别提升了 0.23993 和 0.02734, 这说明了本文所提去噪主网络的有效性, 可认为基于 ResNet50 的去噪主网络能有效地应对 XFCT 中的康普顿散射噪声。图 6 为不同含噪程度图像及其去噪效果局部图。从图中可看出: 1) 从整体的可视化效果来看, 对于不同的噪声水平, NeCNN 和 DnCNN 均能有效地减少背景区域的噪点, 而 BM3D 算法则难以处理这些背景噪声。这是因为背景区域的噪声以加性噪声(高斯噪声和量子噪声)为主, 而 NeCNN 的噪声初估计子网络 DnCNN 能有效地处理这些噪声; 2) 从局部感兴趣区域(ROI)的去噪效果来看, NeCNN 相较于 DnCNN 能更有效地去除 ROI 中心区域由自吸收所造成的异常像素点, 解决一次成像未进行吸收校正的缺点。这是因为 ROI 中心区域存在大量的康普顿散射, 周围的噪声以乘性噪声(康普




图 6 不同噪声水平下的去噪结果。(a)、(e)、(i)为原图,方差分别为 $\sigma_a=14.0525$ 、 $\sigma_e=20.7962$ 、 $\sigma_i=31.7817$; (b)、(f)、(j)为 NeCNN 去噪图; (c)、(g)、(k)为 DnCNN 去噪图; (d)、(h)、(l)为 BM3D 去噪图

Fig. 6 Denoising results under different noise levels. (a), (e), (i) are original images (testing images), and $\sigma_a=14.0525$, $\sigma_e=20.7962$, and $\sigma_i=31.7817$; (b), (f), (j) are denoising images of NeCNN; (c), (g), (k) are denoising images of DnCNN; (d), (h), (l) are denoising images of BM3D

顿散射噪声)为主,而 NeCNN 的去噪主网络通过深度神经网络自适应地学习康普顿散射噪声的分布规律,从而可以自适应地去除该噪声。

为接近人体组织的组成成分,实验进一步将空气填充模体换成 PMMA 填充模体,模拟人体组成成分。由于 PMMA 模体在 Geant4 中扫描时间为空气模体的数倍,因此实验只产生了 100 张 PMMA 模体图片。使用空气模体获取的数据集对 NeCNN 进行训练,然后使用 PMMA 模体数据集训练进行模型参数的微调,最后使用 PMMA 模体获取的测试数据集进行测试,分析去噪算法在 PMMA 模体中应用的可行性。

表 5 不同算法的去噪结果比较

Table 5 Comparison of denoising results with different algorithms

	PSNR /dB	SSIM
Original image	27.75589	0.76805
NeCNN	29.01558	0.95066
DnCNN	28.77565	0.92332
BM3D	28.39545	0.80807

测试集指标如表 6 所示,NeCNN 去噪算法应用在 PMMA 模体中仍具有良好的去噪效果,在 PSNR 指标

上具有一定的提升,在 SSIM 指标上也具有很好的效果。随机选取其中一张图片的去噪结果如图 7 所示,NeCNN 有效去除了背景噪声,且 ROI 边缘信息保存清晰完整。

表 6 PMMA 模体去噪结果

Table 6 Denoising results of PMMA phantom

	PSNR /dB	SSIM
Original Image	30.65151	0.93161
NeCNN	32.00803	0.95843

图 8 给出了 PMMA 模体在仿真生成的 XFCT 图像中某一列的灰度分布图。由于生成的模体图像表现为彩色(RGB),本文选取了其中的绿色通道并绘制相应的灰度分布曲线。其中虚线表示理想 ROI 像素值,实线表示实际像素分布。不难看出,由于康普顿散射噪声的影响,含噪图像 ROI 内也出现了较大的像素值波动,背景部分更是存在多处干扰。BM3D 去噪后,在 ROI 内像素起伏有一定的抑制,方差减少,但背景区域的噪声依然大量存在,说明 BM3D 对于康普顿散射噪声没有很好的抑制效果。本文提出的算法 NeCNN 则显著抑制了背景噪声,ROI 内的像素分布也相对较为平稳。




图 7 PMMA 模体去噪结果。(a) 测试图像;(b) NeCNN 去噪图像

Fig. 7 Denoising result of PMMA phantom. (a) Testing image; (b) denoising image of NeCNN




图 8 不同算法去噪后的像素值分布图。(a) 含噪图像;(b) BM3D 去噪图像;(c) NeCNN 去噪图像

Fig. 8 Profile of pixel value distribution with different denoising algorithms. (a) Noise image; (b) denoising image of BM3D; (c) denoising image of NeCNN

4 结 论

XFCT 是一种新型的早期癌症探测方式,极易受到常规 X 射线管源在成像过程中产生的大量康普顿散射噪声的干扰,从而影响最终的成像质量以及对结果

的判断。为了提高检测精度以及降低 X 射线的入射剂量和缩短扫描时间,本文以多孔准直的 XFCT 为基础,提出了一种基于 NeCNN 的 XFCT 图像去噪算法,通过噪声估计子网络估计康普顿散射噪声水平,去噪主网络对噪声进行降噪处理。实验结果表明,对于空

气模体和 PMMA 模体, 测试样本经 NeCNN 去噪后, PSNR 和 SSIM 指标皆高于 DnCNN 和 BM3D 算法, 这说明了本文提出的 NeCNN 去噪算法的有效性, 也为该方法在未来用于实际成像系统奠定了基础。

致谢 感谢罗家洋、邓希祥、范海鹏在本文撰写过程中所给予的帮助。

参 考 文 献

- [1] Manohar N, Cho S H. Quality of micro-CT images acquired from simultaneous micro-CT and benchtop X-ray fluorescence computed tomography (XFCT): a preliminary Monte Carlo study [C]//2013 IEEE Nuclear Science Symposium and Medical Imaging Conference (2013 NSS/MIC), October 27-November 2, 2013, Republic of Korea. New York: IEEE Press, 2014.
- [2] Manohar N, Reynoso F J, Diagaradjane P, et al. Quantitative imaging of gold nanoparticle distribution in a tumor-bearing mouse using benchtop X-ray fluorescence computed tomography [J]. Scientific Reports, 2016, 6: 22079.
- [3] Hanson A L. The calculation of scattering cross sections for polarized X-rays[J]. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 1986, 243(2/3): 583-598.
- [4] Deng B, Yang Q, Du G H, et al. The progress of X-ray fluorescence computed tomography at SSRF[J]. Nuclear Instruments and Methods in Physics Research Section B: Beam Interactions With Materials and Atoms, 2013, 305: 5-8.
- [5] Feng P, Cong W X, Wei B, et al. Analytic comparison between X-ray fluorescence CT and K-edge CT[J]. IEEE Transactions on Bio-Medical Engineering, 2014, 61(3): 975-985.
- [6] Jones B L, Manohar N, Reynoso F, et al. Experimental demonstration of benchtop X-ray fluorescence computed tomography (XFCT) of gold nanoparticle-loaded objects using lead- and tin-filtered polychromatic cone-beams[J]. Physics in Medicine and Biology, 2012, 57(23): N457-N467.
- [7] Jung S, Lee J M, Cho H, et al. Compton background elimination for *in vivo* X-ray fluorescence imaging of gold nanoparticles using convolutional neural network[J]. IEEE Transactions on Nuclear Science, 2020, 67(11): 2311-2320.
- [8] La Riviere P J, Vargas P A. Monotonic penalized-likelihood image reconstruction for X-ray fluorescence computed tomography[J]. IEEE Transactions on Medical Imaging, 2006, 25(9): 1117-1129.
- [9] Yang Q, Deng B A, Lü W W, et al. Fast and accurate X-ray fluorescence computed tomography imaging with the ordered-subsets expectation maximization algorithm[J]. Journal of Synchrotron Radiation, 2012, 19(2): 210-215.
- [10] Rezaeifar B, Wolfs C J A, Lieuwes N G, et al. A deep learning and Monte Carlo based framework for bioluminescence imaging center of mass-guided glioblastoma targeting[J]. Physics in Medicine & Biology, 2022, 67(14): 144003.
- [11] Lun M C, Cong W X, Arifuzzaman M, et al. Focused X-ray luminescence imaging system for small animals based on a rotary gantry[J]. Journal of Biomedical Optics, 2021, 26(3): 036004.
- [12] Wolterink J M, Leiner T, Viergever M A, et al. Generative adversarial networks for noise reduction in low-dose CT[J]. IEEE Transactions on Medical Imaging, 2017, 36(12): 2536-2545.
- [13] Zhang K, Zuo W M, Chen Y J, 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.
- [14] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [15] Dabov K, Foi A, Katkovnik V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering[J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080-2095.
- [16] 郭静, 冯鹏, 邓露珍, 等. 针孔 X 射线荧光 CT 探测角度优化研究[J]. 光学学报, 2020, 40(1): 0111017.
- [16] Guo J, Feng P, Deng L Z, et al. Optimization of detection angle for pinhole X-ray fluorescence computed tomography[J]. Acta Optica Sinica, 2020, 40(1): 0111017.
- [17] Luo Y, Feng P, Guo J, et al. Simulation research of multi-pinhole collimated L-shell XFCT imaging system[J]. IEEE Access, 2020, 8: 180273-180279.
- [18] Li Y Y, Shaker K, Larsson J C, et al. A library of potential nanoparticle contrast agents for X-ray fluorescence tomography bioimaging[J]. Contrast Media & Molecular Imaging, 2018, 2018: 8174820.
- [19] Luo Y, Feng P, Zhao R G, et al. Simulation research of potential contrast agents for X-ray fluorescence CT with photon counting detectors[J]. Frontiers in Physics, 2021, 9: 686988.
- [20] Zhong H, Ma K, Zhou Y. Modified BM3D algorithm for image denoising using nonlocal centralization prior[J]. Signal Processing, 2015, 106: 342-347.
- [21] 陈会娟, 戴声奎. 改进的基于分块法的图像噪声估计[J]. 计算机应用, 2014, 34(7): 2014-2017.
- [21] Chen H J, Dai S K. Improved block-based image noise estimation algorithm[J]. Journal of Computer Applications, 2014, 34(7): 2014-2017.

Denoising Algorithm of Multi-Pinhole Collimated X-Ray Fluorescence CT Based on Noise Level Estimation

Zhao Ruge¹, Feng Peng^{1,2*}, Luo Yan¹, Zhang Song¹, He Peng^{1,2}, Liu Yanan^{3**}

¹Key Lab of Optoelectronic Technology & Systems, Ministry of Education, Chongqing University, Chongqing 400044, China;

²ICT NDT Engineering Research Center, Ministry of Education, Chongqing University, Chongqing 400044, China;

³School of Electronics and Information Engineering, Chongqing Technology and Business Institute, Chongqing 400032, China

Abstract

Objective X-ray fluorescence CT (XFCT) is a novel imaging modality that combines X-ray CT with X-ray fluorescence analysis (XRFA) and can be employed to probe the distribution and concentration of functionalized gold nanoparticles inside the tumor. It has good potential in the diagnosis and treatment of early-stage cancers. How to suppress Compton scattering noise for XFCT imaging is a current hotspot. Traditional denoising methods include the background fitting method, scanning phase subtraction, and iterative denoising method. Deep learning-based denoising and reconstruction methods can utilize the powerful feature learning ability of deep learning without priori information such as parameters of imaging systems, which can effectively reduce the background noise and obtain sound imaging quality.

Methods We propose an XFCT denoising algorithm based on noise level estimation and convolutional neural networks (NeCNN), which consists of noise estimation subnetworks and main denoising networks (Fig. 2). The estimated subnetwork estimates the noise level and reduces the preliminary noise through the denoising convolutional neural network (DnCNN). The estimated results are input into the fully convolutional neural network (FCN) and the output is adopted to learn the Compton scattering distribution. Meanwhile, as the FCN integrates a deconvolution module, the denoising and reconstruction of end-to-end fluorescence CT images can be directly achieved. We utilize the air-loaded phantoms for pre-training, while the related parameters are transferred into the PMMA phantoms to simulate the human tissue and achieve faster convergence. This two-level network structure is not a simple cascade, and the input-output and hyper parameter settings between two-level networks are linked to each other. With preliminary noise level estimation and input into the secondary network as priori information, there is a superior denoising effect compared with a single denoising network. Additionally, the mean square error (MSE) and structure similarity (SSIM) are employed as the loss function to get the local and global optimal solutions.

Results and discussions The imaging system contains an X-ray source, a phantom to be measured, two sets of pinhole collimators, and two sets of fluorescence detectors (Fig. 1). The distances between the fan beam X-ray source and the phantom center, between the pinhole collimator and the phantom, and between the detector and pinhole collimator are 15, 5, and 5 cm respectively. The detector consists of 55×185 cadmium telluride (CdTe) detector units with an energy resolution of 0.5 keV, and the crystal size is designed to be $0.3 \text{ mm} \times 0.3 \text{ mm}$. The datasets are obtained with Geant4 software by scanning air phantom and PMMA phantom in which various metal nanoparticles (Au, Bi, Ru, Gd) are filled, and different incident X-ray intensities are set to simulate different noise levels and enhance the model's generalization ability. The imaging phantom is set as a cylinder with a diameter of 3 mm and a height of 5 cm, and the settings of element concentration are divided into two types, including high mass fraction versus low mass fraction, where high mass fraction includes 0.2%, 0.4%, 0.6%, 0.8%, 1.0%, and 1.2%, and low mass fraction includes 0.1%, 0.12%, 0.14%, 0.16%, 0.18%, and 0.2%. The programming language is Python 3.6 and the NeCNN is implemented based on Pytorch 1.7.0. Meanwhile, the hardware platform is configured as Intel i5-9600kf CPU, NVIDIA Titan V (12 GB/NVIDIA) GPU, and 16 G DDR4 RAM. The hyper parameters are shown in Table 1. Figure 6 shows the denoised images with NeCNN, BM3D, and DnCNN algorithms. We can easily find that both NeCNN and DnCNN can effectively reduce noise in the background region, which is difficult to handle for the BM3D algorithm. Additionally, NeCNN is more effective than DnCNN in removing abnormal pixel spots caused by self-absorption in the center region of interest (ROI). Generally, the proposed NeCNN is quantitatively and qualitatively superior to the traditional BM3D and DnCNN algorithms. The NeCNN algorithm has the largest PSNR (29.01558) and SSIM (0.95066) values. Compared with DnCNN, NeCNN shows an improvement of 0.23993 and 0.02734 in terms of PSNR and SSIM respectively.

Conclusions This study proposes a novel denoising algorithm for XFCT images based on deep learning to estimate the Compton scattering noise level by noise estimation subnetworks and noise reduction by the denoising main network. The experimental results show that for both air and PMMA phantoms, the PSNR and SSIM of images with NeCNN are both higher than DnCNN and BM3D. This illustrates the effectiveness of the proposed algorithm and shows its potential to be applied in practical imaging systems in the future.

Key words X-ray fluorescence computed tomography; Compton scattering; noise estimation; NeCNN network