

基于深度学习的EPRI稀疏重建方法

杜聪聪, 乔志伟

EPRI Sparse-Reconstruction Method Based on Deep Learning

Du Congcong and Qiao Zhiwei

在线阅读 View online: <https://doi.org/10.15953/j.ctta.2025.047>

您可能感兴趣的其他文章

Articles you may be interested in



关注微信公众号, 获得更多资讯信息

杜聪聪, 乔志伟. 基于深度学习的 EPRI 稀疏重建方法[J]. CT 理论与应用研究 (中英文), xxxx, x(x): 1-9. DOI:10.15953/j.ctta.2025.047.
Du C C, Qiao Z W. EPRI Sparse-Reconstruction Method Based on Deep Learning[J]. CT Theory and Applications, xxxx, x(x): 1-9. DOI:10.15953/j.ctta.2025.047. (in Chinese).

基于深度学习的 EPRI 稀疏重建方法

杜聪聪¹, 乔志伟²

1. 山西电子科技学院, 山西 临汾 041000

2. 山西大学计算机与信息技术学院, 太原 030006

摘要: 电子顺磁共振成像 (EPRI) 是一种先进的肿瘤氧气浓度成像方法。当前, EPRI 的瓶颈问题是扫描时间过长。稀疏重建, 即从稀疏视角下采集的投影数据中重建图像, 是一种有效的快速成像方法。然而, 使用经典的滤波反投影 (FBP) 算法稀疏重建出的图像含有严重的条状伪影, 影响了其后续处理。为此, 本文研究基于深度学习的 EPRI 稀疏重建方法。我们提出了一种残差式的、基于注意力的、密集 UNet 网络 (Residual, Attention-based, Dense UNet, RAD-UNet) 来实现条状伪影的压制。该网络的输入是 FBP 稀疏重建出来的含条状伪影的图像, 标签是 FBP 稠密重建出来的高质量图像。通过大规模数据的训练, 网络具有了压制条状伪影的能力。图像重建时, 首先用 FBP 算法稀疏重建出含条状伪影的 EPRI 图像, 然后将其输入 RAD-UNet 网络进行伪影压制处理, 最后得到高精度重建图像。该网络耦合了残差连接、注意力机制、密集连接和感知损失等先进策略, 提高了网络的非线性拟合能力, 提升了网络的压制条状伪影的能力。实际数据重建实验结果表明, 相比于现有的 3 种具有代表性的深度卷积网络, 该网络的稀疏重建精度更高, 压制条状伪影的能力更强。

关键词: 电子顺磁共振成像; 稀疏重建; 条状伪影; 深度学习; 卷积神经网络

DOI:10.15953/j.ctta.2025.047

中图分类号: TP391.41

文献标识码: A

EPRI Sparse-Reconstruction Method Based on Deep Learning

Du Congcong¹, Qiao Zhiwei²

1. Shanxi University of Electronic Science and Technology, Linfen 041000, China

2. College of Computer and Information Technology, Shanxi University, Taiyuan 030006, China

Abstract: Electron paramagnetic resonance imaging (EPRI) is an advanced method for imaging tumor oxygen concentration. The current bottleneck of EPRI is the extremely long scanning time. Sparse reconstruction, i.e., image reconstruction from projection data obtained from a sparse perspective, is an effective rapid-imaging method. However, sparse-reconstructed images using the classical filtered back-projection (FBP) algorithm contain severe streak artifacts, which affects their subsequent processing. Therefore, this study investigates the EPRI sparse-reconstruction method based on deep learning. We propose a residual, attention-based, dense U-network (RAD-UNet) to suppress streak artifacts. The input of the network is an image with streak artifacts from FBP sparse reconstruction, whereas the label is a high-quality image from FBP dense reconstruction. Through large-scale data training, the network suppresses streak artifacts. In image reconstruction, an EPRI image with streak artifacts is first sparse reconstructed from the FBP algorithm. Subsequently, it is input to the RAD-UNet for artifact suppression. Finally, a high-quality reconstructed image is obtained. The network couples advanced strategies such as residual connection, attention mechanism, dense connection, and perceptual loss, thus improving the nonlinear fitting ability of the network and the network's ability to suppress streak artifacts. Experimental results of actual data reconstruction show that compared with the existing three representative deep convolution networks, the investigated network offers a higher sparse-reconstruction accuracy and greater ability in suppressing streak artifacts.

Keywords: electron paramagnetic resonance imaging; sparse reconstruction; streak artifacts; deep learning; convolutional neural networks

1 引言

电子顺磁共振成像 (electron paramagnetic reson-

ance imaging, EPRI) 是一种基于顺磁性探针 (如三苯甲基自由基) 的非侵入式活体氧成像技术, 能够高分辨率、动态地定量检测组织微环境中的氧分压。

研究表明,肿瘤内部的氧气浓度对放疗效率有重要影响。缺氧区域对放射线有抵制效应,而高氧区域对射线更为敏感。所以,自适应精准放疗要求,对肿瘤内部的高氧区域和低氧区域应该分别施加低剂量和高剂量射线^[1]。可见,肿瘤氧成像是实现精准放疗的关键技术^[2]。EPRI 是一种公认的高分辨高精度的肿瘤氧成像模态^[3]。

当前,EPRI 的瓶颈问题是扫描时间过长。如,在 O2M Technologies JIVA-25 型号的小动物电子顺磁共振氧气成像仪中,扫描小鼠肿瘤,一般需要约 10 分钟。实现快速扫描的一种有效策略是稀疏重建,即从稀疏角度下的投影数据中重建图像。然而,经典的滤波反投影 (filtered back projection, FBP) 算法稀疏重建出的 EPRI 图像往往包含严重的条状伪影,影响其后的氧图像构建^[4]。所以,需要探索高精度稀疏重建方法。

2014 年,Johnson 等人提出了一种基于压缩感知的空间 EPRI 稀疏重建方法,重建出了高精度图像^[5]。2015 年,乔等人提出了一种约束的总变差 (Total Variation, TV) 最小 EPRI 稀疏重建模型,并采用 ASD-POCS 算法求解之,实现了脉冲式 EPRI 的高精度稀疏重建。2017 年,Chou 等人提出了一种部分傅里叶压缩感知算法,在加速 4 倍扫描过程的情况下,实现了高精度重建^[6]。2017 年,Durand 等人提出了耦合 TV 和 curvelets 的优化模型,进一步提高了空间 EPRI 的稀疏重建精度^[7]。2018 年,乔等人提出了一种 TV 约束的数据分离最小重建模型,推导了 Chambolle-Pock (CP) 求解算法,实现了脉冲式 EPRI 的高精度稀疏重建^[8]。这些方法,都是基于压缩感知原理,将成像问题建模为一个最优化问题,通过解最优化模型,实现高精度稀疏重建。其缺点是迭代过程异常耗时。

2016 年以来,深度学习被引入图像重建领域,展示了其潜在的优势^[9-12]。其根本原因是,深度学习可以学习到复杂的难被数学建模的非线性映射。比如,就图像去噪而言,实际的噪声往往类型不确定,因此很难设计出性能优越的正则器。而深度学习图像去噪却可以表现出优异的性能^[13]。深度学习图像重建,大致可以分为 4 类:①从投影到图像的端到端直接重建,比如 AUTOMAP^[14]。②投影域深度学习,比如将 CT 的稀疏正弦图智能插值为完备的投影图^[15]。③图像域深度学习,即对重建图像使用深度学习方法进行图像后处理,以获得高精度的重建图像^[16-19]。④将迭代法展开的深度学习

重建方法。这类方法是将迭代法展开成一个网络的形式,然后将图像正则部分使用 CNN 来代替,进而通过训练整个网络,实现从投影到图像的重建^[20-23]。就三维脉冲式 EPRI 而言,我们无法获得大量的三维图像对以构建训练数据集,所以无法使用第一类和第四类方法。三维 EPRI 的投影数据无法构成正弦图,所以也不适宜采用第二类方法。唯一可行的方法是第三类方法,即图像域深度学习。分别将 FBP 重建出来的低质量和高质量三维 EPRI 图像拆分成一系列二维 EPRI 图像。二维低质图像作为深度网络的输入,二维高质图像作为网络的标签,可以用来构建训练数据集,以训练深度网络。本文聚焦 EPRI 的深度学习稀疏重建,所以将重点探讨如果构建深度神经网络对 FBP 稀疏重建的含条状伪影的图像进行伪影压制。据我们所知,目前关于深度学习 EPRI 的文章很少^[24-25,47-49],所以有必要对其其他成像模态中的深度学习稀疏重建方法进行分析。

我们仅仅关注在图像域进行深度学习压制条状伪影的稀疏重建方法。

2016 年,Han 等人和 Jin 等人几乎同时提出使用经典的 UNet 网络压制条状伪影^[26-27]。2018 年,Zhang 等人进一步提出结合了密集连接和反卷积的 DD-Net 网络,实现了高精度稀疏 CT 重建^[28]。2018 年,Han 等人提出了一种改进的 UNet 网络,增强了图像的高频特征,提升了压制条状伪影的精度^[29]。2018 年,Lee 等人提出了一种深度残差学习网络去除 MRI 图像产生的条状伪影^[30]。2019 年,Guan 等人提出基于密集连接的 FD-UNet 网络来抑制条状伪影,实现了高精度稀疏光声断层重建^[31]。显然,在 CT、MRI 及光声断层成像等成像模态中,卷积神经网络,尤其是 UNet 网络,均展现了其高精度压制条状伪影的能力。

深度学习研究表明,残差学习可以在训练更深网络时一定程度上解决梯度消失和梯度爆炸问题^[32];密集连接可以增加浅层网络的特征映射在深层网络中的复用,提升网络的表达能力;注意力机制通过对空间或通道信息加权,强调有用信息,可以提升网络性能^[33-39];感知损失可以弥补均方误差 (mean square error, MSE) 仅描述像素级损失的缺点,提高深度学习图像处理的精度^[40-43]。

基于这些观察并借鉴现有的压制条状伪影深度网络的设计,我们提出了一种残差式的、基于注意力的、密集 UNet 网络 (Residual, Attention-based, Dense UNet, RAD-UNet) 来实现条状伪影的压制。

第二部分介绍我们提出的 RAD-UNet 网络，第三部分介绍数据集并展示实验结果，第四部分给出一个简洁的结论。

2 方法

本节首先介绍基于 CNN 的 EPRI 稀疏重建方法，然后介绍 RAD-UNet 网络，最后介绍与本文提出的方法进行对比的 3 种深度学习稀疏重建算法。

2.1 基于 CNN 的 EPRI 稀疏重建方法

CNN 是一种在图像处理中非常适宜的深度神经网络，可以很好的表示输入输出之间的非线性映射。基于 CNN 的 EPRI 稀疏重建方法示意图如图 1 所示。使用 CNN 对 FBP 算法稀疏重建的含条状伪影的 EPRI 图像进行处理，可以有效压制条状伪影。含条状伪影的 EPRI 图像 x 是网络的输入，高精度 EPRI 图像 y 是网络的标签。网络可以学习从 x 到 y 的映射，用公式表示为： $y = f(x)$ 。训练好的网络就是函数 $f(x)$ 的近似表达。条状伪影是一种复杂的非线性伪影且在图像中分布不均匀，难以用数学的方法进行建模。而深度学习方法能从大量的训练数据中学习条状伪影的特征，有实现高精度压制条状伪影的潜力。

2.2 RAD-UNet 网络

本文提出的 RAD-UNet 网络结构如图 2 所示。网络结构以大小为 80×80 的 EPRI 图像作为输入，在 U 型结构的左侧，第一个卷积单元（这里将每次下采样后到下一次下采样之前的卷积操作称作一个卷积单元）包含一个通道数为 32 的 3×3 卷积层、




图 1 基于 CNN 的 EPRI 稀疏重建示意图

Fig.1 Schematic diagram of CNN-based EPRI sparse reconstruction

BN (Batch Normalization) 层、ReLU (Rectified Linear Unit) 激活层和 RAD 块 (Residual Attention-based Dense Block) 等操作，其余 3 个卷积单元只包含 RAD 块操作^[33]。

在 U 型结构的右侧，每一次上采样之后的输出与 U 型结构左侧相同大小的特征映射图进行拼接，之后进行 1×1 卷积层、BN 层、ReLU 激活层和 RD 块 (Residual Dense Block) 等操作^[33]。 1×1 卷积将输入的特征图的通道数减少为原来的 $\frac{1}{4}$ 倍，RD 块操作将输入的特征图通道数转换为原来的 2 倍。其中，上采样过程中转置卷积操作卷积核大小为 4×4 ，步长为 2，padding 为 1。

输入为 32 通道输出为 64 通道的 RAD 块如图 3 所示，它是整个网络第一单元中的 RAD 块，其余单元中的 RAD 块有类似结构。在图 3 中，RAD 块共包含 5 个单元。前 4 个单元构成密集连接块，具体的特征映射图变化流程如图 3 所示。第 5 个单元是一个通道注意力模块，如图 4 所示。它通过学习到一个 64×1 的通道注意力权重，并将之与输入的通道数为 64 的特征映射图相乘，获得特定通道被加强的特征映射图。RD 块与 RAD 块的区别是没有第五个单元即注意力模块。




图 2 RAD-UNet 网络结构图

Fig.2 Architectural diagram of RAD-UNet




图3 RAD 块示意图

Fig.3 Structure of RAD block




图4 注意力模块示意图

Fig.4 Attention module

2.3 对比算法

本文选取具有代表性的 RED-CNN、FBPConvNet 和 FD-UNet 三种经典的方法作为压制 EPRI 图像条状伪影的深度网络, 从而与本文算法进行对比。

RED-CNN 网络结合了残差、反卷积和跳跃连接, 没有池化操作, 取得了高精度的 CT 图像去噪^[16]。FBPConvNet 网络其实是经典的残差 UNet 网络, 在 CT 稀疏重建中取得了较好的效果^[27]。FD-UNet 网络在 UNet 网络的收缩和扩展路径中均加入了密集连接, 在光声断层稀疏重建中性能优于经典 UNet^[31]。

3 结果

3.1 数据集的构建

本文使用小动物电子顺磁共振氧气成像仪扫描获取到三维 EPRI 图像, 对图像进行切片处理构建了训练 CNN 需要的 EPRI 数据集。该成像仪是由 O2M Technologies 生产的用于小动物的 JIVA-25 EPRI 氧气成像仪。实验模型由装有三苯甲基溶液的小型瓶体组成。在实验中, 我们一共设计了 25 个模体, 其中单瓶模型 5 个, 双瓶模型 10 个, 三瓶模型 10 个。EPRI 成像仪和小型瓶体的照片分别如图 5 和图 6 所示。

对于每个模体, 我们使用等立体角采样模式^[44]采集 208 个完备投影, 并通过三维 FBP 算法重建出大小为 $80 \times 80 \times 80$ 的高质量三维 EPRI 图像。使用投影数为 50、80、100、150 的稀疏投影数据进行稀疏重建。每组稀疏投影可以通过最大间隔投影排序 (Maximally spaced projection sequencing,




图5 JIVA-25 小动物电子顺磁共振氧气成像仪示意图

Fig.5 Photograph of JIVA-25 small-animal EPR oxygen imager




图6 小型瓶体示意图

Fig.6 Photograph of small bottle

MSPS) 技术从完备的投影数据中选择^[45]。以 100 个投影角度的稀疏重建为例, 从 208 个完备的投影中均匀采集 100 个投影, 然后使用 FBP 算法稀疏重建出含条状伪影的 EPRI 图像。对于每个 $80 \times 80 \times 80$ 大小的三维 EPRI 图像, 我们在三个方向上

对其进行切片, 得到 240 张 80×80 大小的二维图像。从所有的 25 个模型中, 可以获取得到 6000 个二维 EPRI 图像。其中, 一张含条状伪影的低质量图像和对应的高精度图像组成一个样本, 这样一共可以获得 6000 个样本。将它们分成样本数 4800、600 和 600 三个部分, 分别构建训练集、验证集和测试集。部分样品的示意图如图 7 所示。

3.2 网络训练超参数设定

在实验中, RED-CNN、FBPConvNet、FD-UNet 三种网络使用 RMSE 损失函数, RAD-UNet 网络中损失函数使用 RMSE 与感知损失组合的复合损失函数, 其它参数保持一致。所有的网络使用 Adam 算法 ($\beta_1 = 0.5$, $\beta_2 = 0.999$), 迭代次数为 6000, 初始学习率为 0.002, 迭代 3000 次以后学习率下降到 0.0001, batch size 为 32。所有的卷积和反卷积滤波器采用何等人提出的初始化方法^[46]。网络训练时间约为 1 小时。

实验配置 CPU 是 Inter(R) Xeon(R) CPU E5-2620 v4 @ 2.10GHz, GPU 是 NVIDIA Geforce GTX 1080 Ti。本实验在 Windows 操作系统下, 基于 Tensorflow 和 Keras 深度学习框架实现。

3.3 实验结果及分析

本文开展了 2 个实验, 首先是 RAD-UNet 网络与 RED-CNN、FBPConvNet、FD-UNet 三种经典的深度学习稀疏重建方法进行实验对比, 然后是 RAD-UNet 方法在不同的投影稀疏度情形下的重建

性能实验对比。

3.3.1 不同算法稀疏重建能力比较

为了探索 RAD-UNet 方法重建 EPRI 稀疏图像的性能, 将其与 RED-CNN、FBPConvNet、FD-UNet 三种稀疏重建算法进行实验对比, 采集 100 个角度下的投影数据进行 FBP 稀疏重建的含条状伪影的 EPRI 图像作为网络的输入图像, 相对应的高精度 EPRI 图像采取 208 个投影角度, 作为 RAD-UNet 网络的标签进行训练。

重建结果如图 8 所示, ROI 区域图像重建结果如图 9 所示, 从图中可以看到, FBP 算法稀疏重建的图 (b) 具有明显的条状伪影, RED-CNN 网络重建的图 (c) 细节信息被平滑掉了, FBPConvNet 网络重建的图像 (图 (d)) 与 FD-UNet 网络重建的图像 (图 (e)) 中的伪影明显减少且细节信息增多, 而 RAD-UNet 网络重建的图像 (图 (f)) 较为清晰, 保留了更多的图像细节。

本文采用测试集对应的重建图像的峰值信噪比 (PSNR)、均方根误差 (RMSE) 和结构相似性 (SSIM) 的均值 $\pm$ 标准差作为评价指标, 来定量分析重建精度 (表 1)。从表 1 中可以看出, RAD-UNet 网络重建的 EPRI 图像 PSNR 高出 FD-UNet 网络 1.3 dB, RMSE 降低了将近 0.9×10^{-5} , SSIM 略微领先。

定性和定量分析均表明, RAD-UNet 网络与 RED-CNN、FBPConvNet、FD-UNet 三种稀疏重建方法相比, 保留的细节信息更多, 重建出的 EPRI 图像精度更高。




图 7 二维 EPRI 图像示意图, 显示窗口为 $[0, 0.0018]$

Fig.7 2D EPRI images, Display window: $[0, 0.0018]$




图 8 稀疏重建结果, 显示窗口为 [0, 0.0018]

Fig.8 Sparse-reconstruction results, Display window: [0, 0.001 8]




图 9 ROI 图像稀疏重建结果, 显示窗口为 [0, 0.0018]

Fig.9 ROI sparse-reconstruction results, Display window: [0, 0.001 8]

表 1 稀疏重建实验对比结果

Table 1 Comparison results of sparse-reconstruction experiments

重建算法	FBP	RED-CNN	FBPCNN	FD-UNet	RAD-UNet
RMSE	$0.00011 \pm 4.2 \text{ e-}5$	$7.0 \text{ e-}5 \pm 2.5 \text{ e-}5$	$6.6 \text{ e-}5 \pm 1.6 \text{ e-}5$	$5.7 \text{ e-}5 \pm 1.5 \text{ e-}5$	$4.8 \text{ e-}5 \pm 1.1 \text{ e-}5$
SSIM	$0.999979 \pm 2.1 \text{ e-}5$	$0.999992 \pm 9.3 \text{ e-}6$	$0.999993 \pm 4.3 \text{ e-}6$	$0.999996 \pm 2.7 \text{ e-}6$	$0.999997 \pm 1.5 \text{ e-}6$
PSNR	85.42 ± 3.18	89.54 ± 2.74	89.83 ± 1.90	91.17 ± 2.14	92.43 ± 1.82

3.3.2 不同稀疏度下重建性能比较

为了探索在不同投影角度下 RAD-UNet 网络稀疏重建算法的性能, 分别采集 50、80、100、150

个角度下的投影数据进行稀疏重建。

实验结果如图 10 所示, 稀疏度为 50 时, 该方法重建的图 (f) 缺少很多的细节信息, 在稀疏度为




图 10 不同稀疏度下的重建图像对比图, 显示窗口为 [0, 0.0018]

Fig.10 Comparison results of reconstructed images with different sparsity degrees, Display window: [0, 0.001 8]

80 时, 图 (g) 仍然存在明显的条状伪影, 稀疏度为 100 时, 图 (h) 保留的细节信息明显增加, 从图 (i) 中可以看出, 150 个投影角度下保留的细节信息更多, 纹理结构更加明显。

定量比较结果如表 2 所示, 在 150 个稀疏角度下重建出的 EPRI 图像 PSNR 值比 100 个稀疏度下重建的 EPR 图像高出 0.5, RMSE 值降低了 $1e-6$, SSIM 的值也略微领先。

表 2 不同稀疏度下重建图像的 PSNR 值、SSIM 值、RMSE 值
Table 2 PSNR, SSIM, and RMSE values of reconstructed images with different sparsity degrees

稀疏度	RAD-UNet-50	RAD-UNet-80	RAD-UNet-100	RAD-UNet-150
RMSE	$5.6e-5 \pm 1.3e-5$	$5.6e-5 \pm 1.8e-5$	$4.8e-5 \pm 1.1e-5$	$4.7e-5 \pm 1.3e-5$
SSIM	$0.999996 \pm 2.3e-6$	$0.999996 \pm 6.4e-6$	$0.999997 \pm 1.5e-6$	$0.999997 \pm 2.8e-6$
PSNR	91.15 ± 2.01	91.44 ± 2.48	92.43 ± 1.82	92.92 ± 2.38

定性和定量实验结果表明, 本文提出的方法在一定投影角度范围内重建的 EPRI 图像有效地压制了条状伪影, 投影角度越少的 EPRI 图像在该网络中越不容易训练出高精度 EPRI 图像, 投影角度越多的 EPRI 图像在该网络中越容易训练出高精度 EPRI 图像。

4 结论

EPRI 稀疏重建具有非常重要的意义。目前, 基于压缩感知的方法已经实现了高质量的 EPRI 稀疏重建。然而, 基于迭代的方法重建图像需要很长时间。受 CT、MRI 和 PAT 等成像模式中深度学习的稀疏重建的启发, 我们提出了 RAD-UNet 方法, 并应用于 EPRI 领域, 探索深度网络在 EPRI 领域的适用性。该方法结合了多损失机制、密集连接、残差学习和注意力机制, 实现密集连接、残差学习与注意力机制的多级耦合, 突破传统 UNet 的层级限制, 从而实现高精度 EPRI 稀疏重建; 其次, 针对 EPRI 领域的特性定制 RAD 块与 RD 块, 为医学成像算法提供新范式。

与经典的基于深度学习的稀疏重建算法 RED-CNN、FBPConvNet 和 FD-UNet 相比, 所提出的 RAD-UNet 网络重建的 EPRI 图像中的条状伪影得到了很好的压制, 图像纹理和细节信息都得到了更好的保留。此外, 我们发现投影个数越多, RAD-UNet 网络就越容易实现高精度 EPRI 稀疏重建。在这项工作中获得的见解也可以应用于其他成像模式, 如 MRI 和 PET。

参考文献

[1] EPEL B, REDLER G, HALPERN H J. How in vivo EPR measures and images oxygen[J]. *Advances in Experimental Medicine & Biology*, 2014, 812: 113-119, 2014.

[2] EPEL B, REDLER G, TORMYSHEV V et al. Towards human oxygen images with electron paramagnetic resonance imaging[J]. *Advances in Experimental Medicine & Biology*, 2016, 876: 363-369.

[3] EATON S S, EATON G R. EPR imaging[J]. *Journal of Magnetic Resonance*, 1984, 59(3): 474-477.

[4] QIAO Z, REDLER G, EPEL B, et al. Comparison of parabolic filtration methods for 3D filtered back projection in pulsed EPR imaging[J]. *Journal of Magnetic Resonance*, 2014, 248: 42-53. DOI:10.1016/j.jmr.2014.08.010.

[5] JOHNSON D H, AHMAD R, HE G, et al. Compressed sensing of spatial electron paramagnetic resonance imaging[J]. *Magnetic resonance in medicine*, 2014, 72(3): 893-901. DOI:10.1002/mrm.24966.

[6] CHOU C C, CHANDRAMOULI G V, SHIN T, et al. Accelerated electron paramagnetic resonance imaging using partial Fourier compressed sensing reconstruction[J]. *Magnetic resonance imaging*, 2017, 37: 90-99. DOI:10.1016/j.mri.2016.10.029.

[7] DURAND S, FRAPART Y M, KEREBEL M. Electron paramagnetic resonance image reconstruction with total variation and curvelets regularization[J]. *Inverse Problems*, 2017, 33(11): 114002. DOI:10.1088/1361-6420/aa8412.

[8] QIAO Z, ZHANG Z, PAN X, et al. Optimization-based image reconstruction from sparsely sampled data in electron paramagnetic resonance imaging[J]. *Journal of Magnetic Resonance*, 2018, 294: 24-34. DOI:10.1016/j.jmr.2018.06.015.

[9] WANG G, KALRA M, ORTON C G. Machine learning will transform radiology significantly within the next 5 years[J]. *Medical physics*, 2017, 44(6): 2041-2044. DOI:10.1002/mp.12204.

[10] WANG G. A perspective on deep imaging[J]. *IEEE Access*, 2017, 4: 8914-8924.

[11] WANG G, YE J C, MUELLER K, et al. Image reconstruction is a new frontier of machine learning[J]. *IEEE transactions on medical imaging*, 2018, 37(6): 1289-1296. DOI:10.1109/TMI.2018.2833635.

- [12] WANG G, YE J C, MAN B D. Deep learning for tomographic image reconstruction[J]. *Nature Machine Intelligence*, 2020, 2(12): 737-748. DOI:10.1038/s42256-020-00273-z.
- [13] 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. DOI:10.1109/TIP.2017.2662206.
- [14] ZHU B, JEREMIAH et al. Image reconstruction by domain-transform manifold learning[J]. *Nature*, 2018, 555: 487-492. DOI:10.1038/nature25988.
- [15] LEE H, LEE J, CHO S. View-interpolation of sparsely sampled sinogram using convolutional neural network[J].
- [16] HU C, YI Z, 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(9): 2524-2535.
- [17] KANG E, MIN J, YE J C. A deep convolutional neural network using directional wavelets for low - dose X - ray CT reconstruction[J]. *Medical physics*, 2017, 44(10): e360-e375.
- [18] PARK J, HWANG D, KIM K Y, et al. Computed tomography super-resolution using deep convolutional neural network[J]. *Physics in Medicine & Biology*, 2018, 63(14): 145011.
- [19] SHAN H, PADOLE A, HOMAYOUNIEH F, et al. Competitive performance of a modularized deep neural network compared to commercial algorithms for low-dose CT image reconstruction[J]. *Nature Machine Intelligence*, 2019, 1(6): 269-276. DOI:10.1038/s42256-019-0057-9.
- [20] CHEN H, ZHANG Y, CHEN Y, et al. LEARN: Learned Experts' Assessment-based Reconstruction Network for Sparse-data CT[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(6): 1333-1347. DOI:10.1109/TMI.2018.2805692.
- [21] YANG Y, LI H, XU Z, et al. ADMM-Net: A Deep Learning Approach for Compressive Sensing MRI[J]. 2016, 10-18.
- [22] HE J, YANG Y, WANG Y, et al. Optimizing a parameterized plug-and-play ADMM for iterative low-dose CT reconstruction[J]. *IEEE transactions on medical imaging*, 2018, 38(2): 371-382.
- [23] GUPTA H, JIN K H, NGUYEN H Q, et al. CNN-based projected gradient descent for consistent CT image reconstruction[J]. *IEEE transactions on medical imaging*, 2018, 37(6): 1440-1453. DOI:10.1109/TMI.2018.2832656.
- [24] 钱佩璋, 乔志伟, 杜聪聪. 基于 3MNet 去噪网络的快速 EPRI 成像[J]. *CT 理论与应用研究*, 2023, 32(01): 55-66. DOI:10.15953/j.ctta.2022.065.
- QIAN P Z, QIAO Z W, DU C C. Fast EPRI Imaging Based on 3MNet Denoising Network[J]. *CT Theory and Applications*, 2023, 32(01): 55-66. DOI:10.15953/j.ctta.2022.065.
- [25] DU C C, QIAO Z W, EPRI sparse reconstruction method based on deep learning[J]. *Magnetic resonance imaging*. 2023, 97, 24-30.
- [26] HAN Y S, YOO J, YE J C. Deep Residual Learning for Compressed Sensing CT Reconstruction via Persistent Homology Analysis[J]. 2016.
- [27] JIN K H, MCCANN M T, FROUSTEY E, et al. Deep Convolutional Neural Network for Inverse Problems in Imaging[J]. *IEEE Transactions on Image Processing*, 2016, 26(9): 4509-4522.
- [28] ZHANG Z, LIANG X, XU D, et al. A Sparse-View CT Reconstruction Method Based on Combination of DenseNet and Deconvolution[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(6): 1407-1417. DOI:10.1109/TMI.2018.2823338.
- [29] HAN Y, YE J C. Framing U-Net via Deep Convolutional Framelets: Application to Sparse-View CT[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(6): 1418-1429. DOI:10.1109/TMI.2018.2823768.
- [30] LEE D, YOO J, TAK S, et al. Deep Residual Learning for Accelerated MRI using Magnitude and Phase Networks[J]. *IEEE Transactions on Biomedical Engineering*, 2018, 65(9): 1985-1995. DOI:10.1109/TBME.2018.2821699.
- [31] GUAN S, KHAN A, SIKDAR S, et al. Fully Dense UNet for 2D Sparse Photoacoustic Tomography Artifact Removal[J]. *IEEE Journal of Biomedical & Health Informatics*, 2019, 24(2): 568-576.
- [32] 韩泽芳, 上官宏, 张雄, 等. 基于深度学习的低剂量 CT 成像算法研究进展[J]. *CT 理论与应用研究*, 2022, 31(01): 117-134. DOI:10.15953/j.1004-4140.2022.31.01.14.
- HAN Z F, SHANG G H, ZHANG X, et al. Research Progress on Deep Learning-Based Low-Dose CT Imaging Algorithms[J]. *CT Theory and Applications*, 2022, 31(01): 117-134. DOI:10.15953/j.1004-4140.2022.31.01.14.
- [33] QIAO Z, DU C. RAD-UNet: a Residual, Attention-Based, Dense UNet for CT Sparse Reconstruction[J]. *Journal of Digital Imaging*, 2022.
- [34] JIE H, LI S, GANG S, et al. Squeeze-and-Excitation Networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 42(8): 2011-2023.
- [35] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module[J]. *Springer, Cham*, 2018, 11211: 3-19.
- [36] TAY C P, ROY S, YAP K H. AANet: Attribute Attention Network for Person Re-Identifications[J]. 7127-7136.
- [37] LI H, XIONG P, AN J, et al. Pyramid Attention Network for Semantic Segmentation[J]. 2018.
- [38] 杜聪聪, 乔志伟. 基于对抗式残差密集深度神经网络的 CT 稀疏重建[J]. *CT 理论与应用研究*, 2022, 31(02):

- 163-172. DOI:[10.15953/j.ctta.2021.032](https://doi.org/10.15953/j.ctta.2021.032).
- DU C C, QIAO Z W. CT Sparse Reconstruction Based on Adversarial Residual Dense Deep Neural Network[J]. [CT Theory and Applications](#), 2022, 31(02): 163-172. DOI:[10.15953/j.ctta.2021.032](https://doi.org/10.15953/j.ctta.2021.032).
- [39] 乔一瑜, 乔志伟. 基于 CNN 和 Transformer 耦合网络的低剂量 CT 图像重建方法[J]. [CT 理论与应用研究](#), 2022, 31(06): 697-707 + 694. DOI:[10.15953/j.ctta.2022.114](https://doi.org/10.15953/j.ctta.2022.114).
- QIAO Y Y, QIAO Z W. Low-dose CT Image Reconstruction Method Based on CNN and Transformer Coupled Network[J]. [CT Theory and Applications](#), 2022, 31(06): 697-707 + 694. DOI:[10.15953/j.ctta.2022.114](https://doi.org/10.15953/j.ctta.2022.114).
- [40] JOHNSON J, ALAHI A, LI F F. Perceptual Losses for Real-Time Style Transfer and Super-Resolution[J]. Springer, Cham, 2016, 9906: 694-711.
- [41] YANG Q, YAN P, ZHANG Y, et al. Low-Dose CT Image Denoising Using a Generative Adversarial Network with Wasserstein Distance and Perceptual Loss[J]. [IEEE Transactions on Medical Imaging](#), 2018, 37(6): 1348-1357. DOI:[10.1109/TMI.2018.2827462](https://doi.org/10.1109/TMI.2018.2827462).
- [42] MARYAM, GHOLIZADEH A, JAVAD, et al. Low-dose CT Denoising Using Edge Detection Layer and Perceptual Loss[J]. 2019, 6247-6250.
- [43] 樊雪林, 文昱齐, 乔志伟. 基于 Transformer 增强型 U-net 的 CT 图像稀疏重建与伪影抑制[J]. [CT 理论与应用研究](#), 2024, 33(01): 1-12. DOI:[10.15953/j.ctta.2023.183](https://doi.org/10.15953/j.ctta.2023.183).
- FAN X L, WEN Y Q, QIAO Z W. CT Image Sparse Reconstruction and Artifact Suppression Based on Transformer-Enhanced U-net[J]. [CT Theory and Applications](#), 2024, 33(01): 1-12. DOI:[10.15953/j.ctta.2023.183](https://doi.org/10.15953/j.ctta.2023.183).
- [44] SIDKY E Y, JØRGENSEN J H, PAN X. Convex optimization problem prototyping for image reconstruction in computed tomography with the Chambolle-Pock algorithm[J]. [Physics in Medicine & Biology](#), 2011, 57(10): 3065-3091.
- [45] REDLER G, EPEL B, HALPERN, et al. Maximally spaced projection sequencing in electron paramagnetic resonance imaging[J]. [Concepts in Magnetic Resonance Part B Magnetic Resonance Engineering](#), 2015, 45(1): 33-45. DOI:[10.1002/cmr.b.21280](https://doi.org/10.1002/cmr.b.21280).
- [46] HE K, ZHANG X, REN S, et al. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification[J]. [IEEE International Conference on Computer Vision \(ICCV\)](#), 2015, 1026-1034.
- [47] LIU P, ZHANG Y, XI Y, et al. PU-CDM: A pyramid UNet based conditional diffusion model for sparse-view reconstruction in EPRI[J]. [Biomedical Signal Processing and Control](#), 2025, 100.
- [48] ZHANG Z, EPEL B, CHEN B, et al. Preliminary investigation of image reconstruction from sparse data in spectral-spatial electron paramagnetic resonance imaging, 2023 NSS MIC RTSD, 2023, 1-1.
- [49] PENG L, CHEN F, ZHI Q. An edge-preserving total nuclear variation minimization algorithm in EPR image reconstruction[J]. [Biomedical Signal Processing and Control](#), 2024, 87, DOI:[10.1016/j.bspc.2023.105426](https://doi.org/10.1016/j.bspc.2023.105426).