

基于双域神经网络的稀疏视角光声图像重建

沈康^{1,2}, 刘松德^{1,2}, 施钧辉³, 田超^{1,2*}

¹中国科学技术大学工程科学学院, 安徽 合肥 230026;

²精密科学仪器安徽普通高校重点实验室, 安徽 合肥 230026;

³之江实验室, 浙江 杭州 311121

摘要 光声计算断层成像(PACT)是近年来迅速发展的一种无损生物医学成像技术,在生物医学领域有着较高的应用价值。为了获得高质量的光声图像,成像系统的信号采集装置需要配备高密度的阵列探测器。但在实际应用中,由于经济成本、制造工艺及成像时间等因素的限制,探测器的排布往往较为稀疏,难以实现稳定重建,导致重建图像中出现条纹伪影。为了解决这一问题,本文提出一种基于双域神经网络的 PACT 图像重建算法。该算法主要包含三个模块:数据域网络、反投影层和图像域网络,其中数据域网络和图像域网络可分别对光声数据和光声图像进行增强,以提升图像质量。为了对网络进行训练和测试,构建了一个血管仿真数据集和一个小鼠活体试验数据集。研究表明,所提算法可以有效地抑制条纹伪影,提升图像质量,并且重建性能优于其他重建算法。

关键词 生物光学; 光声成像; 图像重建; 神经网络; 稀疏视角

中图分类号 TP391

文献标志码 A

doi: 10.3788/CJL202249.0507208

1 引言

光声计算断层成像(PACT)是一种无损生物医学成像模态,具有光学成像对比度高和超声成像穿透深度大等优点,在基础生命科学和临床医学诊断中有着广泛而重要的应用^[1-5],例如早期肿瘤检测^[6-8]、炎症检测^[9]、手术导航^[10-11]及细胞成像^[12-13]等。光声成像的物理基础是 1880 年 Bell^[14]发现的光声效应,它表明脉冲激光可激发出声波信号。具体到 PACT 应用中:当生物组织受到脉冲激光照射时,组织内部的吸收体受热膨胀,产生超声信号;利用超声探测器接收向外传播的超声信号,通过相应的图像重建技术可以实现组织内部吸收体分布的可视化。图像重建是影响成像质量的一个关键步骤。目前 PACT 图像重建算法主要包括解析重建算法、迭代重建算法和基于深度学习的重建算法三类。

滤波反投影算法(FBP)是 PACT 中应用最为

广泛的一种解析类图像重建方法^[15-17]。在理论成像环境中,FBP 算法可实现高精度、高效率的 PACT 图像重建;但在实践应用中,由于经济成本、制造工艺及成像时间等因素的限制,成像系统的探测器排布往往较为稀疏,光声数据存在空间欠采样问题。欠采样数据无法满足 FBP 算法稳定重建的必要条件,导致重建图像中出现条纹伪影,降低了图像的可读性和量化精度^[18-20]。为了解决此问题,自适应反投影算法^[21]应运而生,该算法可以在一定程度上抑制由稀疏采样引起的条纹伪影。基于压缩感知的迭代重建算法可利用稀疏信号重建出较高质量的图像^[22-24],但这种算法需要反复多次计算光声的前向和后向过程,重建效率低,应用场景受限。

鉴于近年来深度学习技术在计算机视觉领域取得的显著成果^[25],基于深度学习的断层图像重建技术快速兴起^[26],并在 CT^[27-28]、MRI^[29-30]和 PACT^[31-33]等领域取得了一定的进展。在 PACT

收稿日期: 2021-11-29; 修回日期: 2021-12-23; 录用日期: 2022-01-12

基金项目: 国家自然科学基金(62122072, 12174368, 61705216)、安徽省科技重大专项(18030801138)、之江实验室(2019MC0AB01)、中国科学院人才项目、统筹推进世界一流大学和一流学科建设专项资金

通信作者: *ctian@ustc.edu.cn

中,深度学习技术被应用到有限视角图像重建^[34-36]、稀疏采样图像重建^[37-41]、反射伪影抑制^[42]、图像分割与重建^[43]等场景中。对于稀疏采样图像重建,基于深度学习的图像后处理技术是目前最受关注的深度学习图像重建方法之一^[37-39],其主要原理是让神经网络学习低质量图像和高质量图像之间的映射关系来实现图像增强。该方法已被证明可以抑制由稀疏采样引起的条纹伪影,提高图像质量,但此类方法无法利用数据域的信息,当输入图像质量较低时,图像中已被丢失的细节或被伪影遮挡的结构依然难以恢复。端到端的直接重建方法让网络直接学习光声信号和光声图像之间的映射^[40-41],重建过程完全由网络主导。光声信号和光声图像之间的映射关系较为复杂,因此端到端的重建网络往往包含大量训练参数,同时对训练数据的需求量也较大。基于深度学习的迭代重建算法是另一类被广泛研究的方法^[36, 44],其基本思想是将传统迭代算法展开成级联神经网络,通过让网络自动学习算法的正则表达式或优化过程,提升图像质量。但是,该算法的重建效率较低,并且需要较大的显存来支持端到端的训练。

为了进一步解决稀疏采样 PACT 图像重建问题,本文提出一种基于双域(数据域和图像域)神经网络的 PACT 图像重建算法(DI-Net 算法)。DI-Net 模型包含三个模块:数据域网络(D-Net)、自定义的反投影层和图像域网络(I-Net)。DI-Net 中的数据域网络和图像域网络可分别对光声数据和光声图像进行增强,以重建出高质量的图像。目前,在 CT 领域已有利用双域网络提升成像质量的相关报道^[45]。在该研究中,为了实现信号去噪,在数据域中使用一个浅层的去噪网络 DnCNN;在图像域中使用一个 Red-CNN 网络来抑制条纹伪影;数据域和图像域通过一个 FBP 层连接。所提 DI-Net 算法与文献[45]算法存在以下几点不同:1)为了尽可能地提高网络重建性能,DI-Net 的数据域和图像域均采用较深的残差 U-Net 网络^[46],同时为了保证效率,对数据域中的 U-Net 进行减参优化;2)为了简化模型应用和加快训练进程,本文在数据预处理环节执行滤波操作,数据域与图像域的连接仅需一个反投影层;3)不同于 CT 投影数据,光声数据是一种双极性信号,因此本文在设计算法时考虑了负值在网络中的传输。

本文采用数值仿真和活体试验研究方法测试 DI-Net 算法的性能,结果表明,所提算法可以有效

地抑制条纹伪影,提升图像质量。

2 原理和方法

2.1 基于 FBP 的光声图像重建

FBP 算法因其原理简单、鲁棒性强和计算效率高优点,在过去 20 年里得到了广泛的研究^[15-17, 47]。FBP 算法存在多个版本,其中较受关注的是 2005 年 Xu 等^[15]提出的一种适用于多类型探测几何的滤波反投影算法,其重建过程可以表为

$$p_0(\mathbf{r}_s) = \int_{\Omega} b(\mathbf{r}_d, t) \delta\left(t - \frac{\|\mathbf{r}_s - \mathbf{r}_d\|}{a}\right) \frac{d\Omega}{\Omega}, \quad (1)$$

$$b(\mathbf{r}_d, t) = 2 \left[p(\mathbf{r}_d, t) - t \frac{\partial p(\mathbf{r}_d, t)}{\partial t} \right], \quad (2)$$

式中: $p_0(\mathbf{r}_s)$ 为待重建图; $b(\mathbf{r}_d, t)$ 为反投影项; \mathbf{r}_s 和 \mathbf{r}_d 分别表示光声源和探测器的位置; a 为介质声速; Ω 为探测面所包裹的立体角(无限平面的立体角 $\Omega=2\pi$,球面和柱面的立体角 $\Omega=4\pi$), $d\Omega$ 为探测单元 $d\sigma$ 所对应的立体角。

$$d\Omega = \frac{d\sigma}{\|\mathbf{r}_s - \mathbf{r}_d\|^2} \left(\mathbf{n}_d \cdot \frac{\mathbf{r}_s - \mathbf{r}_d}{\|\mathbf{r}_s - \mathbf{r}_d\|} \right), \quad (3)$$

式中: \mathbf{n}_d 为探测器表面指向待重建位置的单位法向量。由(3)式可知, $d\Omega$ 是一个动态值,由探测单元面积 $d\sigma$ 、法向量 \mathbf{n}_d 、探测单元位置 \mathbf{r}_d 以及待重建位置 \mathbf{r}_s 共同决定。由于探测单元面积 $d\sigma$ 为固定值(在本文所用实验系统中, $d\sigma=5.5 \text{ mm}^2$),因此 $d\Omega$ 值的变化主要取决于 \mathbf{n}_d 及 \mathbf{r}_d 和 \mathbf{r}_s 的相对位置。

时域导数 $\partial p(\mathbf{r}_d, t)/\partial t$ 在频率域中可等价于 $j\omega$ (ω 为角频率),因此(2)式中对时间 t 的一阶导数 $\partial p(\mathbf{r}_d, t)/\partial t$ 实际上表示一个频率域的高通斜坡滤波器的 ω 。注意,直接应用该滤波器会导致图像存在振荡伪影,同时高频噪声也会被凸显出来,因此在实际应用中通常还会引入额外的低通或带通滤波器来解决此问题,例如本实验中使用了一个阶数为 3,通带为 0.5~10 MHz 的巴特沃斯带通滤波器。将引入的滤波器记作 W ,则(2)式的计算过程可写为

$$b(\mathbf{r}_d, t) = 2\mathcal{F}^{-1} \{ W\mathcal{F}[p(\mathbf{r}_d, t)] - t j\omega W\mathcal{F}[p(\mathbf{r}_d, t)] \}, \quad (4)$$

式中: \mathcal{F} 和 \mathcal{F}^{-1} 分别表示傅里叶变换和傅里叶逆变换。(4)式可理解为 FBP 算法中的滤波操作。

2.2 双域神经网络

如图 1(a)所示,DI-Net 网络主要包括三个部分:数据域网络 D-Net、自定义的反投影层和图像域网络 I-Net。其中,D-Net 网络和 I-Net 网络可分别对光声数据和光声图像进行处理,D-Net 和 I-Net

之间通过一个自定义的反投影层连接。利用自定义的反投影层,图像域的训练误差可以传播到数据域并用于更新网络的权重,因此 DI-Net 可以执行端到端的训练。

2.2.1 数据域网络

D-Net 网络是基于 U-Net^[46] 网络所设计的一个卷积神经网络。如图 1(b)所示,D-Net 网络主要由编码器和解码器构成。编码器负责分析和提取输入数据的特征,主要由 4 个子模块组成,每个子模块包含 2 个卷积核大小为 3×3 、步长为 1 的卷积层(Conv)和一个核大小为 2×2 、步长为 2 的最大池化层(Max pooling)。编码器的每个阶段依次将卷积核数量加倍,以提取尽可能多的数据特征。同时,编码器的最大池化层执行下采样操作,将输入图像大小减半,进而减少网络计算量,降低显存需求,提高训练效率。解码器和编码器相似,也是由 4 个子模块组成,每个子模块包含 1 个卷积核大小为 3×3 、步长为 1 的转置卷积层(ConvTranspose)和 2 个卷积核大小为 3×3 、步长为 1 的卷积层。与编码器的收缩路径对应,解码器可看作是一个扩展路径,解码器中的转置卷积层执行上采样操作,将图像分辨率恢复到原始尺寸。编码器中的多次下采样操作可能会造成空间分辨率损失。为了防止图像细节丢失,

在编码器和解码器之间引入跳跃连接。跳跃连接使得解码器网络既可以使用上采样后出现的特征,也可以使用同层编码器中的原始图像特征。另外,在第一层神经网络和最后一层神经网络之间建立的跳跃连接,使得网络只要学习输入图像和输出图像之间的差值图像,从而降低了网络的学习难度。为提高网络的重建性能和训练稳定性,在每个网络卷积层中加入了层归一化(InstanceNorm)和非线性激活函数层(Leaky ReLU)。非线性激活函数 ReLU 是一种广泛使用的激活函数,但该函数阻断了负值在网络中的传输,不利于网络对光声数据中负值部分的处理。而 Leaky ReLU 激活函数允许负值在网络中传输,更加适用于光声数据的处理。D-Net 网络中初始阶段滤波器数量 k 设置为 16,实验测试结果表明,使用该参数在保证网络重建性能的同时可有效降低参数计算量。

为了简化 DI-Net 网络的运算过程,加快网络训练进程,D-Net 网络将预处理后的反投影项作为网络的输入。输入数据的预处理过程如下:首先利用(2)式对稀疏采样数据进行处理,获得稀疏反投影数据;然后用线性插值法将稀疏反投影数据插值成低质量、密集的反投影数据,并将其作为网络的输入。




图 1 DI-Net 网络结构。(a) DI-Net 总体结构示意图;(b) D-Net($M=512, N=768, k=16$)和 I-Net($M=256, N=256, k=32$)的网络结构

Fig. 1 Network structure of DI-Net. (a) Overall schematic of DI-Net; (b) network structure of D-Net ($M=512, N=768, k=16$) and I-Net ($M=256, N=256, k=32$)

2.2.2 反投影层

如(1)~(4)式所示,FBP 算法的重建过程主要包括滤波和反投影两个步骤,其重建过程可进一步表示为

$$\mathbf{Y} = \mathcal{F}^{-1} \mathbf{F} \mathcal{F} \mathbf{X}, \quad (5)$$

$$\mathbf{P} = \mathbf{B} \mathbf{Y}_{\text{col}}, \quad (6)$$

式中: \mathbf{X} 和 \mathbf{Y} 分别为探测器测量的光声信号和滤波后的反投影项; \mathbf{F} 为滤波矩阵,矩阵元素值可根据(4)式进行求解; \mathbf{Y}_{col} 为反投影项 \mathbf{Y} 的一维列向量表示; \mathbf{B} 为反投影矩阵,矩阵元素值可根据(1)式和(3)式进行求解; \mathbf{P} 为待重建图像的一维列向量表达,通过重新排列,可以将该向量转化为二维图像。(5)式与(4)式对应,表示 FBP 重建过程中的滤波操作;(6)式与(1)式对应,表示 FBP 重建过程中的反投影操作。

将反投影项作为 DI-Net 网络的输入,相当于将 FBP 算法中的滤波操作移到数据预处理中。因此,数据域网络 D-Net 和图像域网络 I-Net 之间的连接可通过一个反投影层来实现。一个简单直接的方法是将反投影层设计成一个全连接层。但是,这种方法需要数量非常庞大的可学习参数,本文的全连接层参数数量可达 $256^2 \times 512 \times 768$ 。过多的参数不仅会增加对数据显存的需求,而且容易造成过拟合。另外一种可行的方法是将反投影矩阵 \mathbf{B} 作为反投影层并固定该层的参数,从而降低网络可学习参数的数量。直接应用庞大的反投影矩阵会占用较大的计算机内存。分析(1)式可知,反投影矩阵 \mathbf{B} 的元素值的计算过程可表示为

$$B_{n, iN_t + j} = \int_{\Omega} \delta \left(t - \frac{\|\mathbf{r}_s^n - \mathbf{r}_d^i\|}{a} \right) \Big|_{t=j\Delta t} \frac{d\Omega}{\Omega}, \quad (7)$$

$$n = 1, 2, \dots, N, \quad i = 1, 2, \dots, N_d, \quad j = 1, 2, \dots, N_t,$$

式中: n 为重建图像的网格编号; i 为探测器编号; j 为时序采样点编号; δ 为狄拉克分布函数; Δt 为采样时间间隔; \mathbf{r}_s^n 和 \mathbf{r}_d^i 分别表示第 n 个网格和第 i 个探测器的空间位置。由 δ 函数的抽样特性可知,只有满足 $at = \|\mathbf{r}_s^n - \mathbf{r}_d^i\|$ 时, $B_{n, iN_t + j}$ 元素值才不为 0, 因此投影矩阵 \mathbf{B} 具有高度稀疏性。相比于普通反投影矩阵,使用稀疏反投影矩阵可以大幅度降低算法对计算机内存的要求。Tensorflow 软件具有自定义函数层的功能,因此可以在该软件中将(6)式的稀疏矩阵乘法运算编写成一个自定义的函数层,通过该函数层即可实现数据域和图像域之间的连接。

2.2.3 图像域网络

所提算法的最终目标是抑制图像域中的重建伪影,降低重建图像和参考图像之间的误差。因此,所提算法中包含了一个图像域的后处理网络 I-Net,该网络会对反投影层输出的光声图像做进一步处理,以提升图像质量。I-Net 的网络结构与 D-Net 相似,也是由编码器和解码器两个部分构成,如图 1(b)所示。I-Net 网络中初始阶段滤波器数量被设置为 $k=32$,本文主要考虑到 I-Net 作为 DI-Net 网络的末端部分,需要对更多的细节特征进行提取和处理,将初始滤波器数量增加到 32,更有利于重建出包含丰富细节的图像。另外,D-Net 网络输入和输出的都是 512×768 大小的光声反投影数据,而 I-Net 网络输入和输出的都是 256×256 大小的光声图像。因此,I-Net 网络中初始滤波器数量的增加,并不会导致整体网络 DI-Net 参数计算量的大幅增加。

2.3 网络训练

2.3.1 数据集

为了训练和测试网络,本文构造了一个数值仿真数据集和一个活体试验数据集。仿真数据集的样本来自公开的 DRIVE 数据集^[48]。通过随机裁剪、翻转和旋转等操作共获得 2800 个训练样本,其中 2300 个用于训练,300 个用于验证,200 个用于测试。需要指出的是,训练、验证和测试所用样本的来源相互独立,在原始 DRIVE 数据集中没有交集。仿真数据集的光声信号通过 k-Wave 工具箱产生^[49]。信号采集装置如图 2 所示,环形探测器的探测半径为 40 mm,成像区域尺寸大小为 25 mm \times 25 mm。仿真过程中通过将探测器数量分别设置为 128 和 256,获得了实际应用中常见的 128 通道数和 256 通道数的空间欠采样数据。

为了获取高质量的实验数据集,利用本课题组开发的光声成像系统对 14 只小鼠进行断层成像,共获得 9074 个小鼠切片数据(不同小鼠所采集的切片数量不完全相同)。其中 12 只小鼠用于训练(7500 个切片),1 只小鼠用于验证(787 个切片),剩余 1 只小鼠用于测试(787 个切片)。实验信号采集装置是一个环形探测器阵列,包含 512 个独立的探测单元,探测器的探测半径和成像区域与仿真设置相似,如图 2 所示。通过对图 2 所示的装置采集的 512 通道数的光声数据进行 2 倍和 4 倍降采样,可以获得 256 通道和 128 通道的光声数据。512 通道的光声数据及其对应的 FBP 重建图像作为网络训练的参考。




图 2 实验装置示意图

Fig. 2 Schematic of the experimental setup

2.3.2 训练策略

网络训练包括三个阶段：首先，单独训练数据域网络 D-Net，通过该阶段的训练，D-Net 网络能够学习到稀疏光声数据和密集光声数据之间的映射关系；然后，固定 D-Net 网络参数，端到端地训练 DI-Net 网络，该阶段的训练使得 I-Net 网络能够将低质量的光声图像映射成高质量的光声图像；最后，为了使网络性能达到最优，在恢复 D-Net 网络参数的可训练性之后，再次执行端到端微调训练。训练使用的是平方误差损失函数，其定义为

$$L = \frac{1}{N} \sum_{i=1}^N \|y_i - y'_i\|^2, \quad (8)$$

式中： N 表示训练样本数量； y'_i 和 y_i 分别表示重建图像和参考图像； L 为参考图像和重建图像之间的误差。

网络训练过程中采用 Adam 算法进行优化，Batch size 为 8。第一阶段和第二阶段的初始学习率设置为 5×10^{-4} ，训练 100 个 epochs；第三阶段微调训练的初始学习率设置为 1×10^{-5} ，训练 30 个 epochs。训练过程中，使用学习率衰减策略，当验证集的损失值在 3 个 epochs 内没有下降时，学习率将自动衰减为原来的 80%。所有训练均在 Tensorflow 2.0 框架下完成，训练所用计算机的配置为 Inter Xeon Glod 6226R CPU、NVIDIA RTX TITAN GPU、Ubuntu 操作系统。

2.3.3 评价指标

为了定量评估网络的重建性能，选用均方误差 (MSE; E_{MSE})、峰值信噪比 (PSNR; R_{PSNR}) 和结构相似度 (SSIM; S_{SSIM}) 作为重建结果的评价标准。3 种评价指标定义为

$$E_{\text{MSE}} = \frac{1}{m \times n} \|x - x'\|_2^2, \quad (9)$$

式中： $m \times n$ 为图像的尺寸； x 和 x' 分别表示参考图像和重建图像。

$$R_{\text{PSNR}} = 10 \lg \frac{[\max(x)]^2}{E_{\text{MSE}}}, \quad (10)$$

式中： $\max(x)$ 表示 x 的最大值。

$$S_{\text{SSIM}} = \frac{(2\mu_x\mu_{x'} + C_1)(2\sigma_{xx'} + C_2)}{(\mu_x^2 + \mu_{x'}^2 + C_1)(\sigma_x^2 + \sigma_{x'}^2 + C_2)}, \quad (11)$$

式中： μ_x 、 $\mu_{x'}$ 、 σ_x 和 $\sigma_{x'}$ 分别表示 x 和 x' 的均值和标准差； $\sigma_{xx'}$ 表示 x 和 x' 的协方差； $C_1 = [0.01\max(x)]^2$ ； $C_2 = [0.03\max(x)]^2$ 。

3 实验结果

3.1 数值仿真

为了测试所提算法的性能，本节利用建立的数值血管仿体数据集进行稀疏视角光声成像的仿真研究。仿真中共包含两类空间欠采样光声数据，其探测视角数分别为 128 和 256。另外，为了进一步展示所提算法的有效性，将其与 FBP 算法和 Post-Unet^[37-38] 算法进行比较。

图 3 所示为 128 个探测视角条件下血管仿体的重建结果。图 3(a)~(d) 所示分别为参考图像、FBP 算法的重建结果、Post-Unet 算法的重建结果和 DI-Net 算法的重建结果，图 3(e)~(g) 所示为重建图像和参考图像之间的差值图像，图 3(h) 所示为 MSE、PSNR 和 SSIM 的定量评估结果。成像结果显示，由于空间域存在欠采样，FBP 算法的重建图像中出现严重的条纹伪影，同时图像细节也被展宽和模糊。虽然 Post-Unet 算法有效地抑制了由空间欠采样引起的条纹伪影，提升了图像质量，但重建的图像中存在细节丢失，如图 3(c) 中箭头所示。而所提出的 DI-Net 算法在去除条纹伪影的同时，可以完整地重建出图像中的细节，提高图像质量，如图 3(d) 所示。差值图像和定量评估结果也显示，相比于 FBP 和 Post-Unet 算法，DI-Net 算法的重建误差较小，具有较低 MSE、较高的 PSNR 和 SSIM。

图 4 所示为 256 个探测视角条件下血管仿体的重建结果。对比图 3 和图 4 可知，由于探测视角数量增加，3 种算法的重建效果均有一定的提升，但空间欠采样问题依然存在。从图 4(b) 可以看出，在 256 个探测视角条件下，FBP 算法重建的图像中仍然存在明显的条纹伪影，导致了最高的 MSE、最低的 PSNR 和 SSIM。利用 Post-Unet 算法和 DI-Net 算法可以有效地抑制条纹伪影，提升图像质量，如图 4(c)、(d) 所示。由于探测视角数量的增加，Post-Unet 实现了无伪影重建并恢复了所有细节，但其重建精度低于所提出的 DI-Net 算法，如图 4 的差值图像和定量分析结果所示。

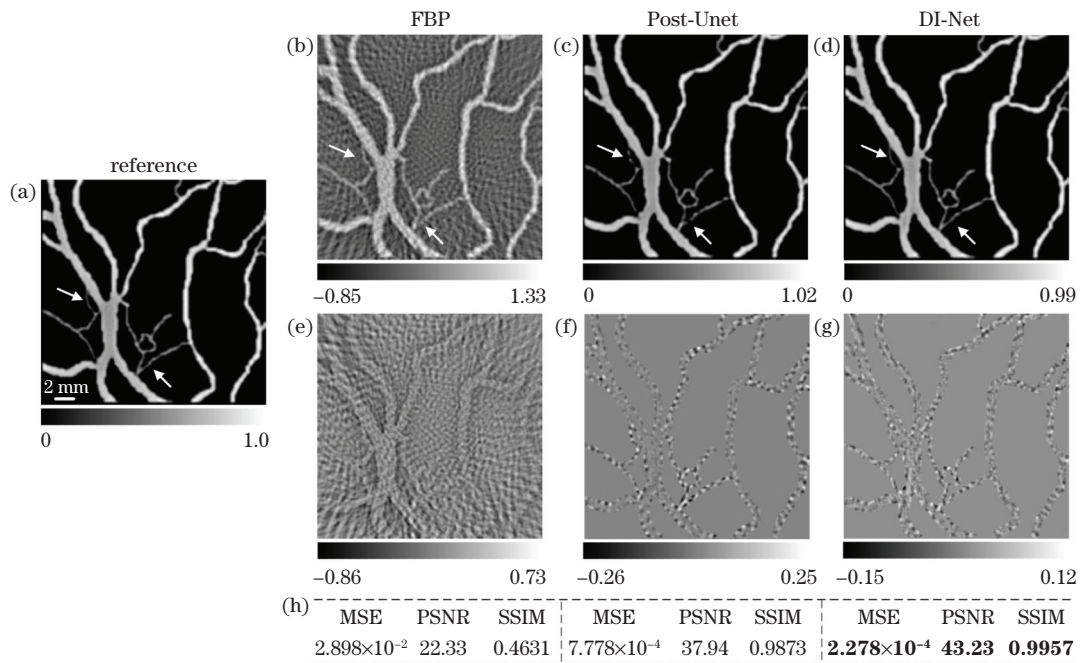


图 3 128 个探测视角的血管仿体重建结果(所有色度条都表示图像上像素点的幅值)。(a)参考图像;(b)~(d) FBP 算法、Post-Unet 算法和 DI-Net 算法的重建图像;(e)~(g)参考图像与 FBP 重建图像、Post-Unet 重建图像和 DI-Net 重建图像之间的差值图像;(h)重建图像的定量评估结果

Fig. 3 Reconstruction results of vascular phantom based on 128 projection views (All color bars stand for amplitudes of pixels on images). (a) Reference image; (b)–(d) images reconstructed by FBP algorithm, Post-Unet algorithm, and DI-Net algorithm, respectively; (e)–(g) difference images between the reference image and the images reconstructed by FBP, Post-Unet, and DI-Net, respectively; (d) quantitative evaluation results of the reconstruction images




图 4 256 个探测视角的血管仿体重建结果(所有色度条都表示图像上像素点的幅值)。(a)参考图像;(b)~(d) FBP 算法、Post-Unet 算法和 DI-Net 算法的重建图像;(e)~(g)参考图像与 FBP 重建图像、Post-Unet 重建图像和 DI-Net 重建图像之间的差值图像;(h)重建图像的定量评估结果

Fig. 4 Reconstruction results of vascular phantom based on 256 projection views (All color bars stand for amplitudes of pixels on images). (a) Reference image; (b)–(d) images reconstructed by FBP algorithm, Post-Unet algorithm, and DI-Net algorithm, respectively; (e)–(g) difference images between the reference image and the images reconstructed by FBP, Post-Unet, and DI-Net, respectively; (d) quantitative evaluation results of the reconstruction images

为了进一步验证 DI-Net 网络的有效性,对包含 200 个样本的血管仿体测试集进行图像重建并对重建结果进行定量分析。定量分析的统计结果如图 5 所示:由上至下,第一行和第二行分别是 128 个探测视角和 256 个探测视角重建图像的定量分析结果;从左到右,第一列至第三列分别对应 MSE、PSNR 和

SSIM 的定量分析结果。其中 d_{IQR} 表示四分位距。为了便于比较,MSE、PSNR 和 SSIM 在测试集上的平均值总结在表 1 中。由图 5 和表 1 可知,在 128 个探测视角和 256 个探测视角两种情况下,DI-Net 算法的表现都优于另外两种方法,在 MSE、PSNR 和 SSIM 3 个评价指标中都获得了最佳的评估结果。

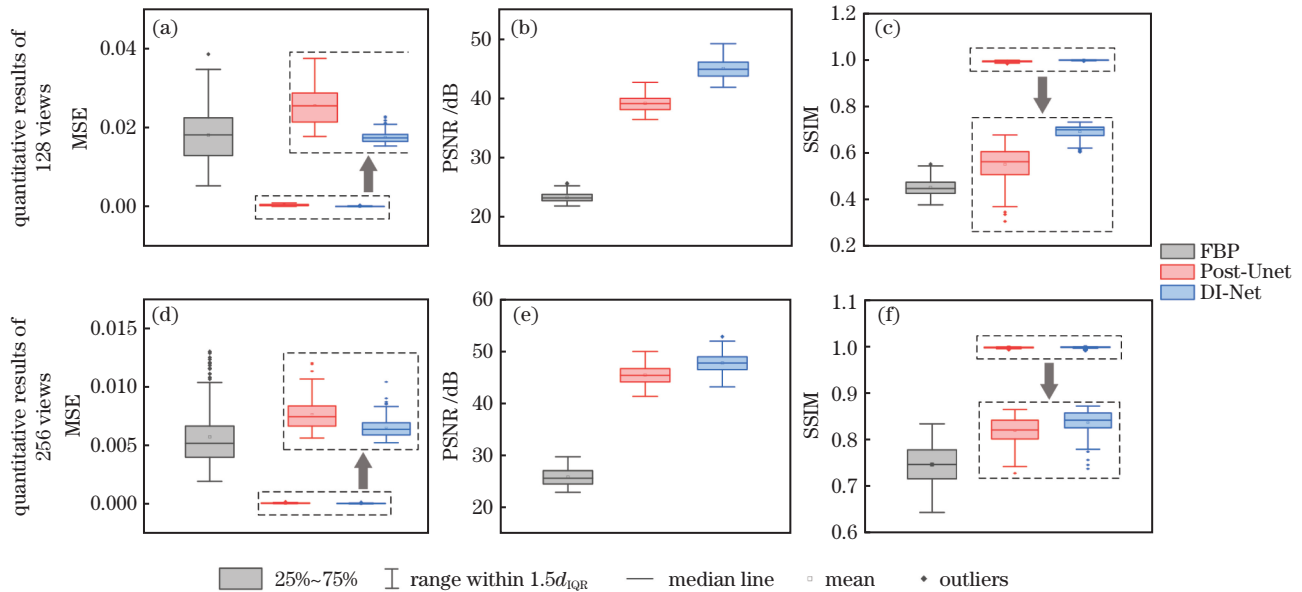


图 5 不同算法在血管测试集上的定量评估结果(为了便于观察,对小虚线框内的箱线图的纵坐标进行了拉伸变换,结果如大虚线框所示)。(a)(d) MSE;(b)(e) PSNR;(c)(f) SSIM

Fig. 5 Quantitative evaluation results of different algorithms on the vascular test dataset (To facilitate observation, the ordinate of the boxplot in the small dashed box is stretched and separately shown in the large dashed box).

(a)(d) MSE; (b)(e) PSNR; (c)(f) SSIM

表 1 不同算法在血管测试集上的定量评估结果的平均值
Table 1 Mean value of quantitative evaluation results for different algorithms on the vascular test dataset

| Number of views | Method | MSE | PSNR / dB | SSIM |
|-----------------|-----------|--|--------------|---------------|
| 128 | FBP | 1.880×10^{-2} | 23.18 | 0.4495 |
| | Post-UNET | 5.005×10^{-4} | 39.05 | 0.9919 |
| | DI-Net | 1.308×10^{-4} | 44.95 | 0.9974 |
| 256 | FBP | 5.700×10^{-3} | 25.90 | 0.7463 |
| | Post-UNET | 6.235×10^{-5} | 45.50 | 0.9978 |
| | DI-Net | 3.640×10^{-5} | 47.82 | 0.9984 |

3.2 活体试验

为了测试 DI-Net 算法在复杂试验数据中的重建性能,本节构造了两组基于活体小鼠的稀疏视角光声成像试验,稀疏数据的探测视角数量分别为 128 和 256。

图 6 展示了 128 个探测视角条件下小鼠断层数据的重建结果。从图 6(b)可以看出,由于空间域存在欠采样,FBP 算法的重建图像中出现了严重的条纹伪影,并且这些伪影遮挡了真实的光声结构,导致重

建图像中丢失了很多细节。虽然与 FBP 算法相比,Post-UNET 算法较好地抑制了这些伪影,但其重建图像中依然存在细节丢失问题,如图 6(c)中箭头所示。得益于双域网络的修正能力,DI-Net 算法实现了无伪影的稀疏视角光声图像重建,并且重建图像中的细节更完整、更清晰,如图 6(d)中箭头所示。差值图像和定量评估结果也表明,DI-Net 算法获得了最佳的重建结果,其重建图像具有较低的 MSE、较高的 PSNR 和 SSIM。

图 7 所示为 256 个探测视角条件下 FBP、Post-UNET 和 DI-Net 3 种算法的重建结果。从图 7(b)可以看出,由于探测视角数量的增加,FBP 算法的重建图像质量获得了显著提升,但图像中依然存在明显的条纹伪影,导致图像对比度低,整体视觉效果差。Post-UNET 算法和 DI-Net 算法较好地抑制了这些伪影,获得了无伪影的高质量图像,如图 7(c)、(d)所示。虽然在 256 个探测视角条件下,Post-UNET 可以重建出和 DI-Net 视觉质量相当的图像,但 DI-Net 的重建精度更高,重建图像更接近参考图像,具有较低的 MSE、较高的 PSNR 和 SSIM。




图 6 128 个探测视角的小鼠切片重建结果(所有色度条都表示图像上像素点的幅值)。(a)参考图像;(b)~(d) FBP 算法、Post-UNET 算法和 DI-Net 算法的重建图像;(e)~(g)参考图像与 FBP 重建图像、Post-UNET 重建图像和 DI-Net 重建图像之间的差值图像;(h)重建图像的定量评估结果

Fig. 6 Reconstruction results of mouse slice based on 128 projection views (All color bars stand for amplitudes of pixels on images). (a) Reference image; (b)–(d) images reconstructed by FBP algorithm, Post-UNET algorithm, and DI-Net algorithm, respectively; (e)–(g) difference images between the reference image and the images reconstructed by FBP, Post-UNET, and DI-Net, respectively; (d) quantitative evaluation results of the reconstruction images




图 7 256 个探测视角的小鼠切片重建结果(所有色度条都表示图像上像素点的幅值)。(a)参考图像;(b)~(d) FBP 算法、Post-UNET 算法和 DI-Net 算法的重建图像;(e)~(g)参考图像与 FBP 重建图像、Post-UNET 重建图像和 DI-Net 重建图像之间的差值图像;(h)重建图像的定量评估结果

Fig. 7 Reconstruction results of mouse slice based on 256 projection views (All color bars stand for amplitudes of pixels on images). (a) Reference image; (b)–(d) images reconstructed by FBP algorithm, Post-UNET algorithm, and DI-Net algorithm, respectively; (e)–(g) difference images between the reference image and the images reconstructed by FBP, Post-UNET, and DI-Net, respectively; (d) quantitative evaluation results of the reconstruction images

为了进一步验证 DI-Net 网络在实验环境中的有效性,利用 DI-Net 网络对包含 787 个小鼠切片的测试集进行图像重建并对重建图像进行定量评估。定量评估的统计结果如图 8 所示。为了便于比较,表 2 中总结了小鼠测试集 MSE、PSNR 和 SSIM

定量结果的平均值。从图 8 和表 2 可以看出,在 128 个探测视角和 256 个探测视角两种情况下,DI-Net 算法的重建性能依然优于 FBP 算法和 Post-Unet 算法,具有较低 MSE、较高的 PSNR 和 SSIM,与前文数值仿真研究结果一致。




图 8 不同算法在小鼠切片测试集上的定量评估结果。(a)(d)MSE; (b)(e)PSNR; (c)(f)SSIM

Fig. 8 Quantitative evaluation results of different algorithms on the mouse slice test dataset.

(a)(d) MSE; (b)(e) PSNR; (c)(f) SSIM

表 2 不同算法在小鼠切片测试集上的定量评估结果的平均值

Table 2 Mean value of quantitative evaluation results for different algorithms on the mouse slice test dataset

| Number of views | Method | MSE | PSNR / dB | SSIM |
|-----------------|-----------|---------------|--------------|---------------|
| 128 | FBP | 0.0848 | 28.57 | 0.5385 |
| | Post-Unet | 0.0119 | 37.00 | 0.8972 |
| | DI-Net | 0.0072 | 39.26 | 0.9371 |
| 256 | FBP | 0.0218 | 33.77 | 0.7719 |
| | Post-Unet | 0.0047 | 40.38 | 0.9462 |
| | DI-Net | 0.0022 | 43.52 | 0.9741 |

3.3 算法耗时

重建耗时也是评估算法性能的一个重要指标,表 3 展示了不同算法在不同数目探测视角条件下重建图像的耗时情况。算法所用光声信号的采样长度为 768,重建图像尺寸大小为 256×256 。FBP 算法是在 MATLAB 2019 软件上执行重建任务,Post-Unet 和 DI-Net 算法是在 Tensorflow 软件上进行工作,所用计算机的配置如 2.3.2 节所述。注意,Post-Unet 算法仅是一个图像后处理算法,需要使用 FBP 算法重建的图像作为网络输入,因此表 3 展

示的 Post-Unet 算法的耗时包含了 FBP 重建耗时。从表 3 可以看出:在 128 个探测视角情况下,FBP 算法和 Post-Unet 算法的重建耗时分别为 0.10 s 和 0.13 s, DI-Net 算法的耗时为 0.20 s;当探测器数目增加到 256 时,FBP 算法和 Post-Unet 算法的耗时分别增加到 0.20 s 和 0.23 s,而 DI-Net 算法耗时没有增加,保持在 0.20 s。综上所述,DI-Net 算法在实现高质量稀疏视角光声图像重建的同时,并没有导致重建耗时大幅增加。

表 3 不同算法的耗时比较

Table 3 Comparisons of consuming time for

| Number of views | different algorithms | | | unit: s |
|-----------------|----------------------|-----------|--------|---------|
| | FBP | Post-Unet | DI-Net | |
| 128 | 0.10 | 0.13 | 0.20 | |
| 256 | 0.20 | 0.23 | 0.20 | |

4 结 论

为了解决稀疏视角光声图像重建问题,提出一种基于双域神经网络 DI-Net 的光声图像重建算法。首先在数据域中对光声数据进行修正,将稀疏视角情况下的光声数据映射成密集视角情况下的光声数

据;然后在图像域对光声图像作进一步增强,以重建出高质量的图像。这种双域联动的修正机制,使得 DI-Net 可以在稀疏采样情况下实现高质量光声图像重建。数值仿真和活体试验结果表明,与其他重建算法相比,所提的 DI-Net 算法可以更加有效地抑制由稀疏采样引起的条纹伪影,重建出细节更丰富的图像。同时,大量的定量评估结果也表明,与另外两种算法相比,DI-Net 算法的重建性能最佳,其重建图像具有较低 MSE、较高的 PSNR 和 SSIM。

成像质量的不断提升是 PACT 快速发展的一个重要推动因素,而图像重建是影响成像质量的关键步骤。所提出的 DI-Net 算法显著地提升了稀疏视角 PACT 的图像质量,为 PACT 的进一步发展起到了较好的推动作用。

参 考 文 献

- [1] Wang L V, Hu S. Photoacoustic tomography: *in vivo* imaging from organelles to organs[J]. *Science*, 2012, 335(6075): 1458-1462.
- [2] Feng T, Zhu Y H, Morris R, et al. Functional photoacoustic and ultrasonic assessment of osteoporosis: a clinical feasibility study [J]. *BME Frontiers*, 2020, (1): 35-49.
- [3] Zhang G P, Deng L J, Bai Y, et al. Recent advances in photoacoustic tomography based on circular array transducer[J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 120004.
张国鹏, 邓丽军, 白杨, 等. 基于环形阵列式传感器的光声层析成像研究进展[J]. *激光与光电子学进展*, 2020, 57(12): 120004.
- [4] Liu Q, Jin T, Chen Q, et al. Research progress of miniaturized photoacoustic imaging technology in biomedical field[J]. *Chinese Journal of Lasers*, 2020, 47(2): 0207019.
刘强, 金天, 陈倩, 等. 小型化光声成像技术在生物医学领域的研究进展[J]. *中国激光*, 2020, 47(2): 0207019.
- [5] Wang T, Liu W, Tian C. Combating acoustic heterogeneity in photoacoustic computed tomography: a review [J]. *Journal of Innovative Optical Health Sciences*, 2020, 13(3): 2030007.
- [6] Gong F, Cheng L, Liu Z. Application of nanoprobe in photoacoustic cancer imaging [J]. *Laser & Optoelectronics Progress*, 2020, 57(18): 180004.
巩飞, 程亮, 刘庄. 基于纳米探针的肿瘤光声成像研究[J]. *激光与光电子学进展*, 2020, 57(18): 180004.
- [7] Yu J W, Wang X H, Feng J C, et al. Antimonene nanoflakes as a photoacoustic imaging contrast agent for tumor *in vivo* imaging [J]. *Chinese Journal of Lasers*, 2020, 47(2): 0207033.
于静文, 王秀翊, 冯金超, 等. 碲烯纳米层片用于活体肿瘤原位光声成像[J]. *中国激光*, 2020, 47(2): 0207033.
- [8] Huang L, Cai W, Zhao Y, et al. *In vivo* tumor detection with combined MR-photoacoustic-thermoacoustic imaging [J]. *Journal of Innovative Optical Health Sciences*, 2016, 9(5): 1650015.
- [9] Jo J, Tian C, Xu G, et al. Photoacoustic tomography for human musculoskeletal imaging and inflammatory arthritis detection[J]. *Photoacoustics*, 2018, 12: 82-89.
- [10] Liu S D, Wang H, Zhang C X, et al. *In vivo* photoacoustic sentinel lymph node imaging using clinically-approved carbon nanoparticles [J]. *IEEE Transactions on Bio-Medical Engineering*, 2020, 67(7): 2033-2042.
- [11] Wang H, Liu S D, Wang T, et al. Three-dimensional interventional photoacoustic imaging for biopsy needle guidance with a linear array transducer [J]. *Journal of Biophotonics*, 2019, 12(12): e201900212.
- [12] Köker T, Tang N, Tian C, et al. Cellular imaging by targeted assembly of hot-spot SERS and photoacoustic nanoprobe using split-fluorescent protein scaffolds[J]. *Nature Communications*, 2018, 9: 607.
- [13] Tian C, Qian W, Shao X, et al. Plasmonic nanoparticles with quantitatively controlled bioconjugation for photoacoustic imaging of live cancer cells [J]. *Advanced Science*, 2016, 3(12): 1600237.
- [14] Bell A G. On the production and reproduction of sound by light [J]. *American Journal of Science*, 1880, (118): 305-324.
- [15] Xu M H, Wang L V. Universal back-projection algorithm for photoacoustic computed tomography [J]. *Physical Review E*, 2005, 71(1): 016706.
- [16] Finch D, Patch S K. Determining a function from its mean values over a family of spheres [J]. *SIAM Journal on Mathematical Analysis*, 2004, 35(5): 1213-1240.
- [17] Deng K X, Cui M X, Zuo H Z, et al. Speed-of-sound heterogeneity compensation method in photoacoustic computed tomographic image reconstruction [J]. *Chinese Journal of Lasers*, 2021, 48(15): 1507001.
邓可欣, 崔曼修, 左宏志, 等. 光声计算断层图像重建中声速异质性补偿方法[J]. *中国激光*, 2021, 48(15): 1507001.
- [18] Tian C, Pei M L, Shen K, et al. Impact of system

- factors on the performance of photoacoustic tomography scanners[J]. *Physical Review Applied*, 2020, 13(1): 014001.
- [19] Shen K, Liu S D, Feng T, et al. Negativity artifacts in back-projection based photoacoustic tomography [J]. *Journal of Physics D*, 2021, 54(7): 074001.
- [20] Tian C, Zhang C X, Zhang H R, et al. Spatial resolution in photoacoustic computed tomography [J]. *Reports on Progress in Physics*, 2021, 84: 036701.
- [21] Cai C J, Wang X H, Si K, et al. Streak artifact suppression in photoacoustic computed tomography using adaptive back projection[J]. *Biomedical Optics Express*, 2019, 10(9): 4803-4814.
- [22] Provost J, Lesage F. The application of compressed sensing for photo-acoustic tomography [J]. *IEEE Transactions on Medical Imaging*, 2009, 28(4): 585-594.
- [23] Zhang Y, Wang Y Y, Zhang C. Total variation based gradient descent algorithm for sparse-view photoacoustic image reconstruction[J]. *Ultrasonics*, 2012, 52(8): 1046-1055.
- [24] Wang K, Su R, Oraevsky A A, et al. Investigation of iterative image reconstruction in three-dimensional photoacoustic tomography[J]. *Physics in Medicine and Biology*, 2012, 57(17): 5399-5423.
- [25] Voulodimos A, Doulamis N, Doulamis A, et al. Deep learning for computer vision: a brief review[J]. *Computational Intelligence and Neuroscience*, 2018, 2018: 7068349.
- [26] 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.
- [27] Wang G, Ye J C, de Man B. Deep learning for tomographic image reconstruction [J]. *Nature Machine Intelligence*, 2020, 2(12): 737-748.
- [28] McLeavy C M, Chunara M H, Gravell R J, et al. The future of CT: deep learning reconstruction[J]. *Clinical Radiology*, 2021, 76(6): 407-415.
- [29] Ghodrati V, Shao J X, Bydder M, et al. MR image reconstruction using deep learning: evaluation of network structure and loss functions[J]. *Quantitative Imaging in Medicine and Surgery*, 2019, 9(9): 1516-1527.
- [30] Liang D, Cheng J, Ke Z W, et al. Deep magnetic resonance image reconstruction: inverse problems meet neural networks[J]. *IEEE Signal Processing Magazine*, 2020, 37(1): 141-151.
- [31] Gröhl J, Schellenberg M, Dreher K, et al. Deep learning for biomedical photoacoustic imaging: a review[J]. *Photoacoustics*, 2021, 22: 100241.
- [32] Hauptmann A, Cox B T. Deep learning in photoacoustic tomography: current approaches and future directions [J]. *Journal of Biomedical Optics*, 2020, 25: 112903.
- [33] Yang C C, Lan H R, Gao F, et al. Review of deep learning for photoacoustic imaging [J]. *Photoacoustics*, 2021, 21: 100215.
- [34] Lan H R, Jiang D H, Yang C C, et al. Y-Net: hybrid deep learning image reconstruction for photoacoustic tomography *in vivo* [J]. *Photoacoustics*, 2020, 20: 100197.
- [35] Kim M W, Jeng G S, Pelivanov I, et al. Deep-learning image reconstruction for real-time photoacoustic system [J]. *IEEE Transactions on Medical Imaging*, 2020, 39(11): 3379-3390.
- [36] Hauptmann A, Lucka F, Betcke M, et al. Model-based learning for accelerated, limited-view 3-D photoacoustic tomography[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(6): 1382-1393.
- [37] Antholzer S, Haltmeier M, Schwab J. Deep learning for photoacoustic tomography from sparse data [J]. *Inverse Problems in Science and Engineering*, 2019, 27(7): 987-1005.
- [38] Davoudi N, Deán-Ben X L, Razansky D. Deep learning photoacoustic tomography with sparse data [J]. *Nature Machine Intelligence*, 2019, 1(10): 453-460.
- [39] Guan S, Khan A A, Sikdar S, et al. Fully dense UNet for 2-D sparse photoacoustic tomography artifact removal[J]. *IEEE Journal of Biomedical and Health Informatics*, 2020, 24(2): 568-576.
- [40] Feng J C, Deng J G, Li Z, et al. End-to-end Res-UNet based reconstruction algorithm for photoacoustic imaging [J]. *Biomedical Optics Express*, 2020, 11(9): 5321-5340.
- [41] Tong T, Huang W H, Wang K, et al. Domain transform network for photoacoustic tomography from limited-view and sparsely sampled data [J]. *Photoacoustics*, 2020, 19: 100190.
- [42] Davoudi N, Lafci B, Özbek A, et al. Deep learning of image-and time-domain data enhances the visibility of structures in photoacoustic tomography[J]. *Optics Letters*, 2021, 46(13): 3029-3032.
- [43] Boink Y E, Manohar S, Brune C. A partially-learned algorithm for joint photo-acoustic reconstruction and segmentation [J]. *IEEE Transactions on Medical Imaging*, 2020, 39(1): 129-139.
- [44] Li H S, Schwab J, Antholzer S, et al. NETT: solving inverse problems with deep neural networks [J]. *Inverse Problems*, 2020, 36(6): 065005.

- [45] Wang W, Xia X G, He C J, et al. A deep network for sinogram and CT image reconstruction[EB/OL]. (2020-01-20) [2021-05-04]. <https://arxiv.org/abs/2001.07150>.
- [46] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [47] Haltmeier M, Scherzer O, Burgholzer P, et al. Thermoacoustic tomography and the circular Radon transform: exact inversion formula[J]. Mathematical Models and Methods in Applied Sciences, 2007, 17(4): 635-655.
- [48] Staal J, Abràmoff M D, Niemeijer M, et al. Ridge-based vessel segmentation in color images of the retina[J]. IEEE Transactions on Medical Imaging, 2004, 23(4): 501-509.
- [49] Treeby B E, Cox B T. k-Wave: MATLAB toolbox for the simulation and reconstruction of photoacoustic wave fields[J]. Journal of Biomedical Optics, 2010, 15(2): 021314.

Dual-Domain Neural Network for Sparse-View Photoacoustic Image Reconstruction

Shen Kang^{1,2}, Liu Songde^{1,2}, Shi Junhui³, Tian Chao^{1,2*}

¹ School of Engineering Science, University of Science and Technology of China, Hefei, Anhui 230026, China;

² Key Laboratory of Precision Scientific Instrumentation of Anhui Higher Education Institutes, Hefei, Anhui 230026, China;

³ Zhejiang Lab, Hangzhou, Zhejiang 311121, China

Abstract

Objective Photoacoustic computed tomography (PACT) is a fast-evolving noninvasive biomedical imaging technique that shows great potential for basic life sciences and clinical practice. To generate high-quality photoacoustic (PA) images, imaging systems need to employ a dense array of ultrasonic detectors. However, due to economic constraints, fabrication complexity, and real-time data processing requirements, ultrasonic detectors are usually arranged sparsely. Such sparsity cannot satisfy the essential conditions of stable image reconstruction and results in significant artifacts in reconstructed images. To address this issue, we develop an innovative PACT image reconstruction algorithm based on a dual-domain neural network.

Methods The proposed network (Fig. 1), which we refer to as DI-Net, consists of a data-domain network (D-Net), a back projection layer and an image-domain network (I-Net). Both D-Net and I-Net are designed based on U-Net, a convolutional neural network that is developed for biomedical image segmentation. Based on U-Net, an instance normalization, a skip connection, and a leaky rectified linear unit are used to enhance the performance of the DI-Net. The back projection layer is a sparse matrix with fixed parameters that allows for gradient propagation from I-Net to D-Net. First, the D-Net maps sparse-view PA data into dense-view PA data in the data domain. Then, the back projection layer transforms the dense-view PA data into a PA image. Finally, the reconstructed image is further enhanced in the image domain by the I-Net. The performance of DI-Net is evaluated through numerical simulations and *in vivo* experimental data that contains 128-views and 256-views undersampled data. In addition, to further demonstrate the effectiveness of the network, two popular algorithms, i. e., filtered back projection (FBP) and Post-Unet, are compared with the proposed DI-Net.

Results and Discussions We first numerically test the performance of DI-Net using a synthetic vascular phantom dataset. The reconstruction results of 128 views show that the image reconstructed by FBP is significantly contaminated by the streak-type artifacts due to sparse-view sampling. Although both the Post-Unet and the DI-Net can reconstruct artifact-free images, some details are lost in the image reconstructed by the Post-Unet while the DI-Net completely recovers these details. Quantitative evaluation results demonstrate that the DI-Net provides image quality with the lowest mean square error (MSE), and the highest peak signal-to-noise ratio (PSNR) and structural similarity index measure (SSIM) (Fig. 3, Fig. 5, and Table 1). When the number of views is 256, streak-type artifacts caused by sparse-view sampling are reduced but are still clearly visible in the images reconstructed by FBP,

while Post-Net and DI-Net effectively suppress these artifacts and reconstruct high-quality images. Due to the increasing number of views, Post-Net completely reconstructs the details; however the quantitative accuracy of the reconstructed image is lower than that of the DI-Net (Fig. 4, Fig. 5, and Table 1). We further experimentally evaluated the performance of the DI-Net using an *in vivo* mouse slice dataset. Similar to the numerical simulations, experimental results also demonstrate the effectiveness of the proposed algorithm. Specifically, in the case of 128 views, the image reconstructed by FBP contains significant artifacts that occlude real PA structures, resulting in the loss of image details. Compared with FBP, Post-Net demonstrate better performance; however, not all PA structures are recovered. DI-Net can achieve accurate reconstruction and the reconstructed image is consistent with the reference image (Fig. 6, Fig. 8, and Table 2). In the case of 256 views, although the three algorithms reconstruct the PA structures, the image generated by DI-Net more closely resembles the reference image and has the lowest MSE and the highest PSNR and SSIM values (Fig. 7, Fig. 8, and Table 2).

Conclusions In this paper, we describe an innovative PACT image reconstruction algorithm based on DI-Net, a dual-domain neural network. Both numerical simulations and *in vivo* experiments are used to evaluate the performance of the proposed DI-Net. The imaging results reveal that DI-Net can effectively suppress streak-type artifacts caused by undersampling and the reconstructed images are comparable with the reference image. The imaging results also demonstrate that the proposed DI-Net provides better image quality compared with the widely-used FBP algorithm and the popular Post-Net algorithm.

Key words biotechnology; photoacoustic tomography; image reconstruction; neural network; sparse views