

深度学习在有限视角稀疏采样光声图像重建中的应用

孙正^{1,2}, 候英飒^{1,2}

(1. 华北电力大学电子与通信工程系, 保定 071003; 2. 华北电力大学河北省电力物联网技术重点实验室, 保定 071003)

摘要: 光声成像(Photoacoustic imaging, PAI)是一种多物理场耦合的新型功能成像技术,高质量图像重建是提高成像精度的关键。当探测器采集的光声信号数据不完备时,若采用标准重建方法(如反投影、时间反演和延迟求和等)会导致图像质量以及成像深度的下降。迭代重建算法可在一定程度上解决此问题,但存在计算成本高、需合理选择正则化方法等缺点。近年来,深度学习已经成为医学成像领域的首选方法,其在高效率重建高质量图像方面展现出了巨大潜力。本文对深度学习在有限角度稀疏采样光声图像重建中的应用进展进行总结,对主要方法进行分类归纳,并讨论不同方法的优势和不足。

关键词: 光声成像; 图像重建; 深度学习; 卷积神经网络; 迭代策略; 非迭代策略

中图分类号: TP391 **文献标志码:** A

A Survey on Application of Deep Learning in Photoacoustic Image Reconstruction from Limited-View Sparse Data

SUN Zheng^{1,2}, HOU Yingsa^{1,2}

(1. Department of Electronic and Communication Engineering, North China Electric Power University, Baoding 071003, China;
2. Hebei Key Laboratory of Power Internet of Things Technology, North China Electric Power University, Baoding 071003, China)

Abstract: Photoacoustic imaging (PAI) is a newly emerging hybrid functional imaging modality. High-quality image reconstruction is the key to improve the imaging accuracy. Incomplete photoacoustic (PA) measurements usually lead to the reduction in the imaging depth and the quality of images which are rendered by using conventional reconstruction techniques such as back projection (BP), time reversal (TR), and delay and sum (DAS). The iterative algorithms are capable of solving this issue to a certain extent at the cost of high computational burden and a properly selected regularization tool. In recent years, deep learning (DL) has exhibited promising performances in the field of medical imaging. It has also shown great potential in reconstructing images with high quality and high efficiency. This paper provides a survey on PA image reconstruction from sparsely sampled data in a limited view based on DL. The current methods are summarized and classified, and their advantages and limits are also discussed.

Key words: photoacoustic imaging (PAI); image reconstruction; deep learning (DL); convolutional neural network (CNN); iterative scheme; non-iterative scheme

引言

生物光声成像(Photoacoustic imaging, PAI)是一种新型复合功能成像技术,其原理是用短激光脉冲照射生物组织,组织吸收光能量后受热膨胀并对外辐射宽带(\sim MHz)超声波(即光声波),超声换能器采集光声波,送入计算机后进行图像重建,显示目标的形态结构和功能特性^[1]。

高质量的图像重建是PAI技术的关键,常规重建方法有反投影(包括通用反投影(Universal back projection, UBP)和滤波反投影(Filtered back projection, FBP))、时间反演(Time-reversal, TR)、基于傅里叶变换的方法、延迟求和(Delay and sum, DAS)以及基于模型的方法等^[2-3]。上述方法一般基于理想成像条件的假设,例如:入射光在被测目标表面均匀分布、组织中的声速恒定、忽略超声波在组织界面的反射和散射、探测器具有理想特性和足够带宽、采集光声信号的时间和空间采样率足够高且能够获得全视角完备测量数据等。但在实际应用中很难满足上述理想条件,采用代数重建技术(Algebraic reconstruction technique, ART)可在一定程度上提高图像质量,但由于在迭代过程中需要反复计算前向成像算子及其伴随算子,因而此类算法往往非常耗时,而且需要合理选择适当的正则化方法及其参数,重建图像质量很大程度上依赖于有关成像目标的先验假设模型,而该假设在实际应用中往往不能严格满足^[4-6]。

近年来,深度学习(Deep learning, DL)已成为人工智能领域的研究热点,基于其在计算机视觉领域的巨大成功,利用监督学习进行图像重建也成为医学成像的一个新兴研究领域^[7]。2017年,Antholzer等^[8]首次利用卷积神经网络(Convolutional neural network, CNN)重建光声图像,CNN通过学习权值/滤波器提取最佳特征,以减轻逆问题求解中的不适定性。按照是否进行迭代,可将基于DL的光声图像重建方法分为两类:非迭代方法和学习迭代方法(Learned iterative method)^[9],这两类方法的选择在一定程度上是重建速度与质量之间的权衡。本文从非迭代和迭代两个角度对根据有限角度稀疏测量数据重建光声图像的DL方法进行总结和归纳,分析各方法的优势和不足。

1 基于非迭代深度学习的光声图像重建

根据神经网络输入和输出的不同将非迭代方法分为3类:信号增强(信号到信号的转换)、图像增强(图像到图像的转换)和信号到图像的转换^[9]。

1.1 信号增强

在对目标进行光声扫描时,由于生物组织的复杂性以及成像设备的局限性等,探测器采集的光声信号中通常存在噪声,信噪比较低,因此信号去噪和增强是图像重建之前的重要步骤。例如,Awasthi等^[10-11]提出了一种对光声信号正弦图(Sinogram)数据进行超分辨率增强和去噪的方法,将含有噪声的正弦图数据作为CNN的输入,训练网络使其能够对输入数据进行去噪和增强,最终输出噪声明显减少的正弦图数据,进而利用标准重建算法(如FBP或TR)重建图像,得到伪影明显减少的图像。该方法不同于其他像素级的模型,它以正弦图作为输入,具有高鲁棒性和泛化能力。

1.2 图像增强

基于CNN的图像增强方法作用于图像域,主要分两个步骤进行:

步骤1 初始重建,即采用标准重建算法(如FBP^[6,8,12-14]、TR^[5,15-17]、DAS^[18-20]和基于动态孔径长度校正的UBP^[21-22]等)根据探测器采集的原始光声信号重建低质量的初始图像。

步骤2 后处理,即将初始图像作为训练后CNN的输入,对初始图像进行优化,以去除伪影,提高图像质量。采用的CNN框架主要有U-Net^[5-7,12,14,20-24]、S-Net^[6]、全密集U-Net(Fully dense U-Net, FD-UNet)^[15]、零空间网络(Nullspace network)^[13]、残差网络(Residual network, Res-Net)^[13]、双框架U-Net^[14]、紧框架U-Net^[14]、具有梯度惩罚的Wasserstein生成对抗网络(Wasserstein generative adversar-

ial network with gradient penalty, WGAN-GP)^[16]、注意块 U-Net (Attention block U-Net, AB-U-Net)^[17]、在 U-Net 中加入 Dropout 层以限制模型过拟合的网络^[19]以及生成对抗网络(Generative adversarial network, GAN)^[25]等,如表 1 所示。

表 1 基于 DL 的光声图像增强主要方法对比

Table 1 Comparison of main methods based on DL for photoacoustic image enhancement

方法	优点	缺点	适用范围
FBP+S-Net ^[6]	比迭代方法速度快,网络结构比 U-Net 简单	重建图像质量不及 U-Net	实时成像
FBP+U-Net ^[6]	可产生与迭代方法相当的图像质量,但重建速度比迭代方法快	网络结构比 S-Net 复杂	
TR+FDUNet ^[15]	网络密集的连通性减少了冗余特征的学习,增强了信息流,降低了对训练数据过拟合的可能性,在减少伪影方面优于 U-Net	要求训练数据和测试数据匹配良好	根据稀疏测量数据重建二维光声图像
TR+WGAN-GP ^[16]	在提高图像质量方面的性能优于 U-Net	未针对训练数据中的光通量变化训练网络;重建速度低于 U-Net	热消融中肿瘤血管的定位;超声溶栓过程中的血管检测
TR+AB-U-Net ^[17]	嵌入到特征提取中的注意块隐含地学习有用特征,并抑制不相关区域内的特征激活	采用仿真数据用于网络的训练和测试,仿真中未考虑在体成像条件	骨组织的光声成像

不同的网络体系对图像质量的改善程度也不同,例如双框架 U-Net、紧框架 U-Net、FD-UNet、WGAN-GP 和 GAN 均优于 U-Net,零空间网络优于 Res-Net^[13]。以“TR+WGAN-GP”方法为例,重建图像的峰值信噪比(Peak signal to noise ratio, PSNR)可达 35.24 dB,结构相似度(Structural similarity, SSIM)可达 0.99,明显优于“TR+U-Net”和 TR 重建质量^[16],如图 1 所示,但 WGAN-GP 的训练时间是 U-Net 的两倍。此外,将多幅低质量图像同时输入网络可提高后处理效果。例如, Awasthi 等^[18]将分别利用两种标准重建方法得到的两幅图像作为训练后网络的输入,提取图像特征,并通过上采样和下采样重建最终的图像。




图 1 双光子显微血管图像的重建结果^[16]

Fig.1 Reconstruction results of vascular two-photon microscopic images^[16]

基于 CNN 的光声图像增强方法的局限性在于 CNN 重建图像的性能很大程度上取决于初始重建质量,在初始重建中缺失的图像特征很可能在 CNN 重建图像中仍然缺失或被错误地重建^[15]。此外,由于隐含在实际测量数据中的细节信息在图像重建后会丢失,而 CNN 往往无法恢复出微弱信号,导致图像精细结构的丢失。

1.3 信号到图像的转换

基于DL的信号到图像的转换是通过“数据”驱动“学习”,直接利用探测器测量数据重建高质量图像。CNN学习信号到图像的映射,将探测器测量的原始光声信号或经过预处理的信号作为训练后网络的输入,网络提取光声信号中的有用特征并将其转换成图像的形式,最终输出高质量的重建图像。与图像增强方法相比,此过程省略了利用常规重建方法完成信号到图像转换的步骤。主要方法如表2所示,其中除“输入三维光声信号阵列+upgUNET方法”外,所列方法主要针对于光声层析成像(Photoacoustic tomography, PAT),是否适用于光声显微成像(Photoacoustic microscopy, PAM)则需进一步实验验证。

表2 基于DL的光声信号到图像转换方法对比

Table 2 Comparison of methods based on DL for photoacoustic signal-to-image transformation

方法	优点	缺点	适用范围
输入原始光声信号+DU-Net ^[26]	DU-Net在测试集上的性能优于U-Net;时间成本低于标准重建方法	网络结构比U-Net复杂	多频率PAI
输入像素插值光声信号+FD-UNET ^[27]	网络输入了更丰富的信息,计算效率高	重建图像中可能出现标准图像中没有的血管	实时PAI和超声成像
输入三维光声信号阵列+upgUNET ^[28]	upgUNET可从训练数据中有效学习滤波权值	丢失一些复杂吸收体的几何形状,产生较小的伪影;对垂直排列的结构成像质量较差	任何已知几何特性的实时PAI系统(特别是微血管成像)
输入归一化光声信号及其时间导数+FPnet+U-Net ^[29]	FPnet可处理不同的信号分布,减少学习参数的数量	比FBP+U-Net的重建速度慢;对信号进行非线性归一化处理可能会丢失目标的定量信息,不适用于定量成像	稀疏采样的有限视角光声图像重建

1.3.1 输入信号

CNN的输入数据包括以下5种:(1)探测器采集的原始光声信号^[26];(2)线性插值后的光声信号^[27];(3)像素插值后的光声信号^[27];(4)将具有时间和探测器维度的二维光声信号转换成具有两个空间维度和一个信道维度的三维信号阵列^[28];(5)归一化的光声信号及其时间导数,以提取原始信号在时间轴上的深层特征^[29]。

当网络的输入数据不同时,重建图像的质量也不同。例如Guan等^[27]提出的像素级深度学习(Pixel-wise deep learning, Pixel-DL)方法,将经过像素插值的光声信号作为网络输入,以达到将更多信息输入网络进而简化网络结构的目的,与将线性插值后的光声信号作为网络输入的方法(即改进的直接深度学习(Modified direct-DL, mDirect-DL))相比,重建图像质量更高,如图2所示。

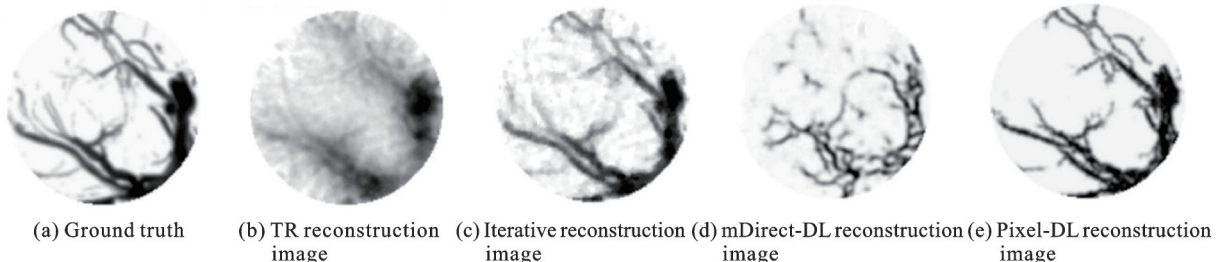


图2 小鼠大脑血管光声层析图像重建结果^[27]

Fig.2 Reconstructed PAT images of mouse brain vasculature^[27]

1.3.2 网络架构

Lan 等^[26]搭建了由两个并列 U-Net 构成的网络,称之为 DU-Net,如图 3 所示。与标准重建方法和单一 U-Net 相比,该方法重建图像的 PSNR 和 SSIM 分别可达 25.438 dB 和 0.611。Min 等^[28]提出了一种多通道输入网络 upgUNET,如图 4 所示,该网络与 U-Net 的不同之处在于其输入信号是三维阵列。实验结果表明,该方法重建图像的 PSNR 和 SSIM 分别可达 27.73 dB 和 0.754,重建图像质量明显优于 U-Net 和标准重建方法。Tong 等^[29]将特征投影网络 (Feature projection network, FPnet) 和 U-Net 相结合,将经过归一化处理的光声信号首先输入 FPnet,完成信号域到图像域的转换,然后将生成的图像作为 U-Net 的输入,进一步改善图像质量,如图 5 所示。与标准重建方法以及图像增强中的 FBP+U-Net^[6]方法相比,该方法重建图像的质量明显提高。

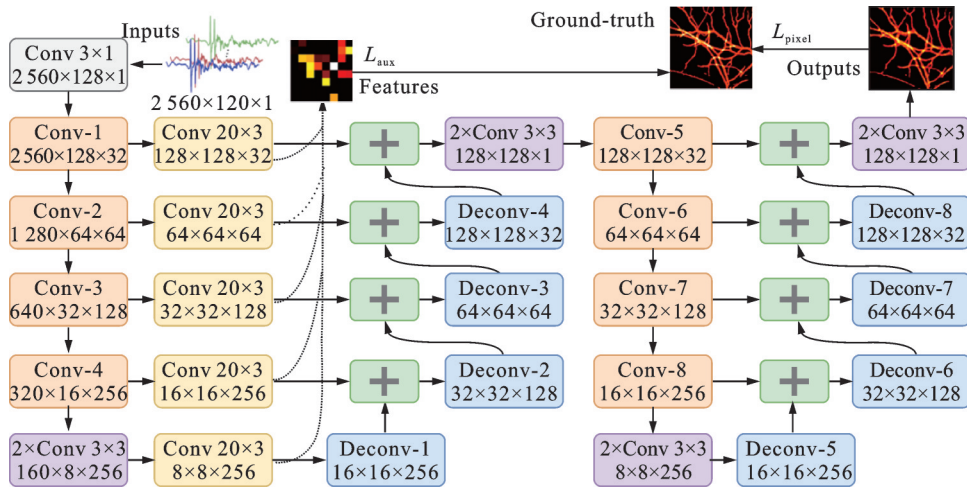


图 3 DU-Net 体系结构^[26]

Fig.3 Architecture of DU-Net^[26]

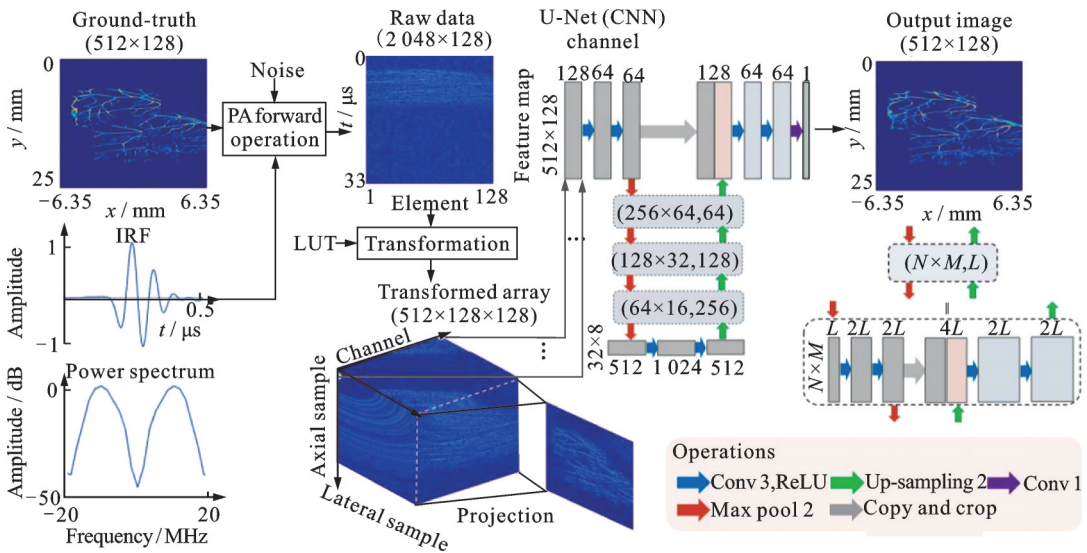


图 4 upgUNET 体系结构^[28]

Fig.4 Architecture of upgUNET^[28]

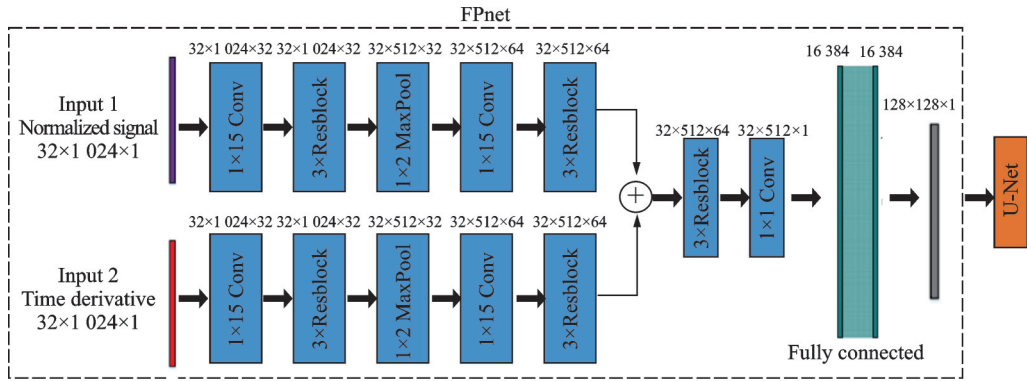


图5 FPnet体系结构(U-Net作为后处理)^[29]

Fig.5 Architecture of FPnet with the U-Net as a post-processing network^[29]

采用不同网络架构重建图像的质量也会受到输入信号的影响。如1.3.1节中所述,以像素插值后的光声信号作为网络输入时得到的重建图像质量明显优于以线性插值后的信号作为输入时的重建图像,这是由于对探测器测量数据进行像素插值后,网络将不再需要额外学习时域到图像域的映射关系,因而提高了网络的工作效率。此外,将二维信号映射成三维信号作为网络输入也可以提高网络的学习效率^[28]。

1.4 “图像到图像”与“信号到图像”转换方法的对比

以U-Net和FD-UNet网络框架为例,本节对“图像到图像”和“信号到图像”转换方法的性能进行对比。由于不同成像实验条件下超声换能器阵元数、光声信号采样率、训练和测试数据集及GPU的选取等均存在差异,因此只对比相同实验中不同方法的结果,分别如表3和表4所示。

表3 基于FD-UNet框架的“信号到图像”转换方法与图像增强方法的对比^[27]

Table 3 Comparison between signal-to-image conversion method and image enhancement method based on FD-UNet framework^[27]

方法	高分辨率眼底图像库		ELCAP公共肺脏图像库		小鼠脑血管图像库		性能
	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR/dB	SSIM	
TR+FD-UNet	21.01	0.57	24.07	0.48	19.17	0.71	输入像素插值光声信号+FD-UNet的重建速度优于TR+FD-UNet
输入像素插值光声信号+FD-UNet	23.15	0.70	26.27	0.52	24.50	0.80	

表4 基于U-Net框架的“信号到图像”转换方法与图像增强方法的对比^[29]

Table 4 Comparison between signal-to-image conversion method and image enhancement method based on U-Net framework^[29]

方法	脑MRI图像数据集		腹部MRI图像数据集		含视网膜血管图像的DRIVE数据集		性能
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	
FBP+U-Net	26.565 0	0.797 2	30.715 5	0.843 0	21.613 8	0.869 0	FBP+U-Net的重建速度优于输入归一化光声信号及其时间导数+FPnet+U-Net
输入归一化光声信号及其时间导数+FPnet+U-Net	27.690 8	0.862 0	31.333 5	0.885 2	25.117 0	0.905 9	

与“信号到图像”的转换相比,“图像到图像”的转换中CNN的输入是采用常规方法重建的初始图像,而CNN不能直接访问探测器测量数据,图像增强的过程中可能丢失原始光声信号中隐含的有用信

息,导致图像质量下降,因而此类方法的泛化性能较差,重建图像质量依赖于初始重建。“信号到图像”的转换方法以探测器采集的原始光声信号或者经过处理的光声信号作为网络输入,往往需要使用全连接或大卷积核的CNN处理信号矩阵的非对称性问题,且当仅使用原始光声信号作为网络输入时,难以映射出复杂目标的逆模型^[9,30-31]。

1.5 “图像到图像”与“信号到图像”转换方法的结合

为弥补“图像到图像”和“信号到图像”两种方法的缺点,Lan等^[31]提出了一种Y-Net框架,如图6所示,两个输入分别是原始光声信号(包含目标的细节信息)和采用DAS算法重建的含有伪影的低质量图像(包含图像的纹理信息),最终输出高质量图像。该方法可解决严重的有限角度伪影问题,但Y-Net框架受波束成形效应的影响,且没有充分利用稀疏数据的性能,重建图像中依然存在残留伪影。在此基础上,Guo等^[9]提出了面向多特征融合的注意力导向网络(Attention steered network, AS-Net),如图7所示,两个输入分别是折叠变换后的光声信号和采用DAS重建的低质量图像。不同于直接使用原始光声信号作为输入,折叠变换可以更好地利用原始稀疏数据,更快地重建高质量图像。相比于Y-Net的直接编码解码,AS-Net利用全局上下块保留更多的空间信息。该方法的验证是在时域中进行的,未来可将其推广到频域。此外,Francis等^[32]提出了一个基于GAN的框架,如图8所示,两个输入分别是增强的正弦图和采用TR算法重建的低质量图像,采用仿真图像的实验结果表明该方法可有效去除有限带宽和有限视角伪影,提高重建图像质量。

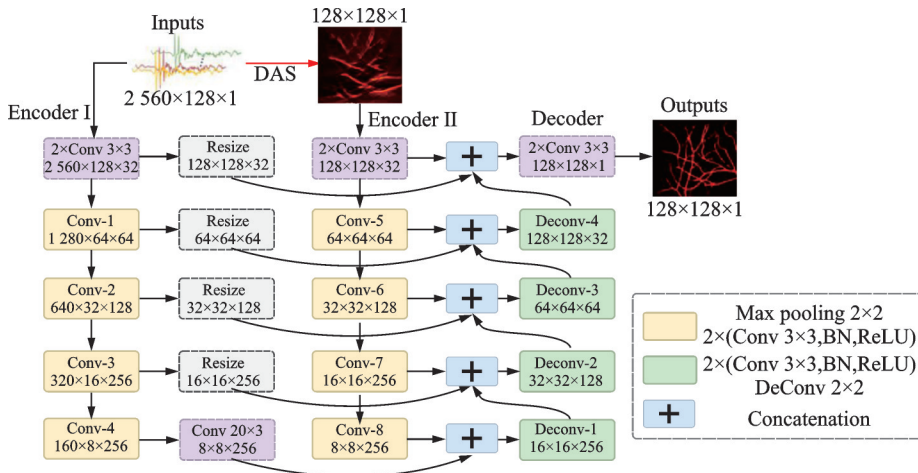


图6 Y-Net体系结构^[31]
Fig.6 Architecture of Y-Net^[31]

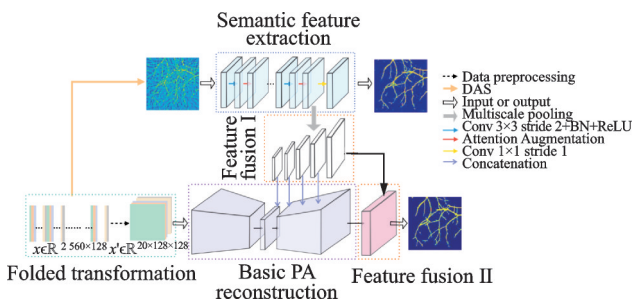


图7 AS-Net体系结构^[9]
Fig.7 Architecture of AS-Net^[9]

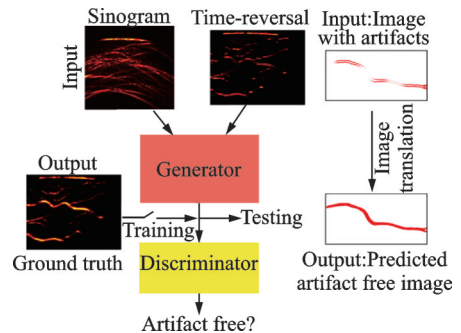


图8 GAN体系结构^[32]
Fig.8 Architecture of GAN^[32]

2 基于学习迭代的光声图像重建

与图像增强方法相比,学习迭代方法不需要进行初始重建,而是直接使用前向算子和伴随算子重建图像。与信号到图像的转换方法相比,学习迭代方法不是学习光声信号到图像的映射,而是在迭代重建框架中引入DL,利用神经网络从训练数据中学习先验约束^[27,33]。与传统迭代重建方法相比,学习迭代方法可用更少的迭代次数重建更高质量的图像,但是由于先验约束是由神经网络从训练数据中学习的,因而所需重建时间较长^[27]。

学习迭代方法可分为两类:基于梯度下降的方法和深度正则化法。前者通过基于梯度下降的网络训练使每次迭代达到最佳^[34-41],后者通过网络训练正则化工具提高重建图像质量^[42-46]。

2.1 基于梯度下降的迭代深度学习

Kelly等^[34]受近端梯度下降(Proximal gradient decent, PGD)算法的启发,用深度卷积神经网络代替近端算子,利用近似重建算子更新当前迭代结果,再用学习算子训练迭代结果的权重,验证结果如图9所示。该重建框架具有很高的通用性,可在框架中纳入其他近似重建算子,也可应用于图像重建以外的领域。虽然该框架采用的深度卷积神经网络相对较容易训练,但网络会对测量数据产生响应,且由于需要重复模拟物理模型,因而计算时间较长。

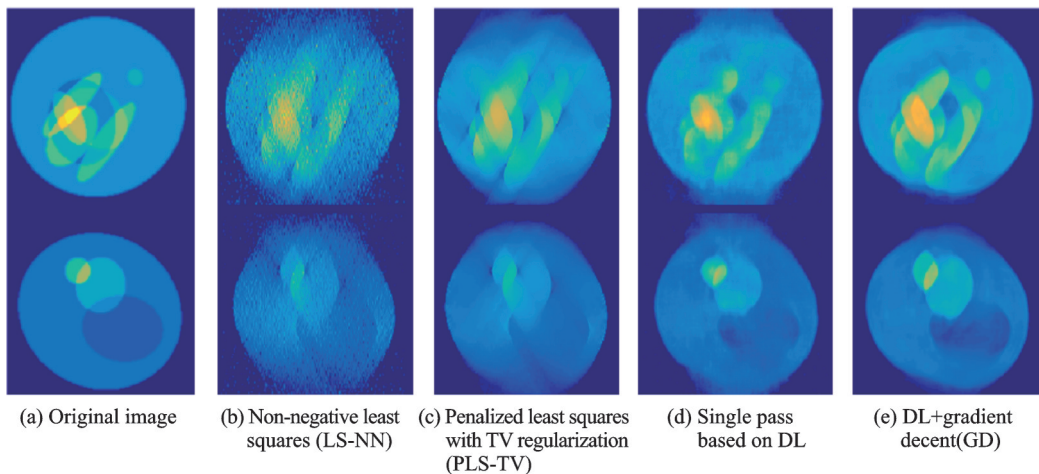


图9 根据噪声数据的光声图像重建结果^[34]

Fig.9 Photoacoustic images reconstruct by different methods from test noisy data^[34]

Hauptmann等^[36]提出了一种加速模型,利用深度梯度下降(Deep gradient descent, DGD)算法进行迭代更新,将前向成像模型包含到梯度信息中,并且将计算梯度信息的过程与网络训练分开,减少了网络训练对图形处理单元硬件的要求。与传统迭代方法和U-Net重建方法的对比结果表明,该模型可获得比迭代方法更好的鲁棒性(图10),且大幅减少了迭代时间,可用于三维稀疏数据高分辨率PAI中,但训练数据的质量会对最终重建结果产生影响。

为了解决声速不均匀问题,Shan等^[37]构建了同步重建网络(Simultaneous reconstruction network, SR-Net),通过在每次迭代过程中同时更新初始声




图10 对肿瘤仿体的图像重建结果^[36]

Fig.10 Reconstructed images of a tumor phantom^[36]

压和声速,实现初始声压和声速空间分布的同时重建。该网络可以数据驱动的方式自动学习,确定迭代步长、正则化项以及数据保真度和正则化之间的权衡,且不需要与声速有关的数据保真度梯度。

Adler等^[38]在原对偶(Primal dual, PD)算法的基础上提出了学习原对偶(Learned primal dual, L-PD)算法,它可看作是PD的学习变种。

Boink等^[39-41]利用L-PD算法对图像域中的原始算子和数据域中的对偶算子进行迭代更新,实现了对光声图像的同时重建和分割,如图11所示。为了提高方法的鲁棒性,需要针对多种图像和成像系统训练网络,非常耗时。未来可将L-PD与GAN相结合,用GAN学习真实图像的低维表示,通过对有限的成像系统设置进行学习,并对学习获得的流形(Manifold)插值,以覆盖所有合理的网络输入和系统设置。

2.2 深度正则化

采用有限角度稀疏光声测量数据重建初始声压分布图是严重不适定问题,在经典迭代重建方法中,需合理选择正则化方法,常用的有L1正则化、L2正则化、TV正则化和Tikhonov正则化等。深度正则化法是将深度神经网络与正则化方法相结合,用神经网络作为正则化项,求解图像重建问题^[42-46]。

网络Tikhonov(Network Tikhonov, NETT)将经典Tikhonov正则化与深度神经网络相结合,该网络可以是用户指定的基于正则化泛化框架的函数,也可以是训练后的CNN^[44]。利用NETT法进行图像重建的基本步骤是:首先进行初始重建,然后训练网络(即训练正则化项),通过调整参数,使误差函数或平均绝对误差函数最小,使网络达到最佳性能。实验结果表明,NETT能够很好地去除由低采样率导致的图像伪影,同时保留高分辨率的信息,如图12所示。

不同于NETT, Schwab等^[46]提出了基于DL的截断奇异值分解(Truncated singular value decomposition, TSVD)重建框架,使用TSVD作为正则化工具,并结合DL重建图像,其中TSVD在该框架中的

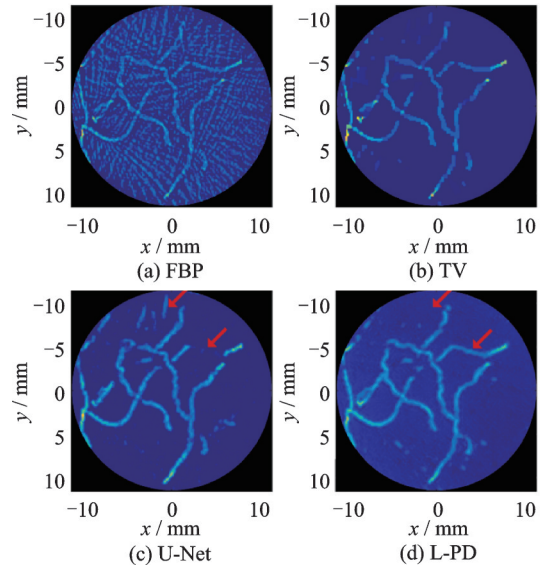


图11 对仿体的光声图像重建结果^[40]

Fig.11 Reconstructed photoacoustic images of an experimental phantom^[40]

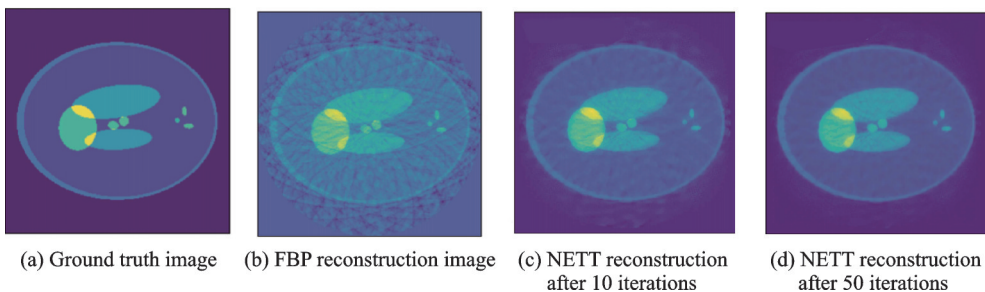


图12 采用NETT对Shepp-Logan仿体进行光声图像重建的结果^[44]

Fig.12 Results of photoacoustic image reconstruction for Shepp-Logan type phantom by NETT^[44]

作用是近似重建图像的低频分量。采用该框架重建图像包括两步:第一步利用 TSVD 获得初始重建,将小的奇异值截断,防止噪声被放大;第二步通过随机梯度下降训练一个 CNN,将初始重建映射到截断部分,恢复初始重建中缺失的高频部分,最终的重建图像是初始重建和网络输出的残差图像的总和。数值实验结果显示,基于 DL 的 TSVD 法重建图像的平均误差只有 0.088 7,远低于 TSVD 的 0.156 3,如图 13 所示。




图 13 采用基于 DL 的 TSVD 法对 Shepp-Logan 仿体进行图像重建的结果^[46]

Fig.13 Image reconstructions of Shepp-Logan type phantom by DL-based TSVD^[46]

3 结束语

在光声成像过程中,当探测器只能采集到不完备光声信号时,采用常规方法重建的图像中通常存在有限角度伪影,图像质量下降。近年来,将 DL 应用于有限角度稀疏测量数据的光声图像重建已成为该领域的研究热点。相较于常规方法,DL 技术极大提高了重建图像的质量和效率,但目前仍然面临诸多问题。例如:图像增强方法受初始重建的影响;信号到图像的转换方法需要全连接或大卷积核处理信号矩阵的非对称问题,且当 CNN 直接输入原始光声信号时,仅在对简单目标的成像中表现出良好性能;基于学习迭代的方法是以牺牲重建时间为代价获得高质量的图像等。未来的研究中,可以考虑从以下几方面提高基于 DL 的光声图像重建质量。

(1)改变网络输入信号的类型:信号到图像的转换方法可以直接提取光声信号中的有用信息并用于重建高质量图像,而利用数学工具或者物理模型等对原始光声信号测量数据进行预处理,转换网络输入信号的类型,可提高网络的学习效率,进而提高重建图像质量和重建速度。

(2)扩展数据集:CNN 需要大量的数据来训练和学习隐含的信息,而且构建训练数据集时需要尽可能多地包含测试集中可能观察到的图像特征,因此未来需要构建规模更大、质量更高的在体图像数据集,并使训练集适应使用真实光传播模型生成的图像。

(3)优化网络结构:复杂的网络结构虽然可以产生更好的重建结果,但往往是以重建速度为代价,对于三维图像重建来说,该过程将更加耗时,不利于实时应用。因此如何优化网络模型并改进训练策略,以更快的速度重建更高质量的图像是未来值得研究的问题。

(4)进行相同实验条件下不同方法之间的对比:目前评估图像重建方法的性能时,多与常规重建方法、同种类型方法及图像增强方法对比,在未来的研究中可进行相同实验条件下不同类型方法之间(如非迭代 3 种方法之间、非迭代方法与迭代方法之间)的对比,以分析不同方法的重建质量和效率。

参考文献:

- [1] DENG Handi, QIAO Hui, DAI Qionghai, et al. Deep learning in photoacoustic imaging: A review[J]. *Journal of Biomedical Optics*, 2021, 26(4): 040901.
- [2] LUTZWEILER C, RAZANSKY D. Optoacoustic imaging and tomography: Reconstruction approaches and outstanding challenges in image performance and quantification[J]. *Sensors*, 2013, 13(6): 7345-7384.


- [3] AMIR R, VASILIS N, DANIEL R. Acoustic inversion in optoacoustic tomography: A review[J]. *Current Medical Imaging*, 2013, 9(4): 318-336.
- [4] SCHWAB J, ANTHOLZER S, HALTMEIER M. Learned backprojection for sparse and limited view photoacoustic tomography[C]//*Proceedings of SPIE International Conference on Photons Plus Ultrasound: Imaging and Sensing*. San Francisco, California, United States: SPIE, 2019: 1087837.
- [5] FARNIA P, MOHAMMADI M, NAJAFZADEH E, et al. High-quality photoacoustic image reconstruction based on deep convolutional neural network: Towards intra-operative photoacoustic imaging[J]. *Biomedical Physics & Engineering Express*, 2020, 6(4): 045019.
- [6] HALTMEIER M, ANTHOLZER S, SCHWAB J, et al. Photoacoustic image reconstruction via deep learning[C]//*Proceedings of SPIE International Conference on Photons Plus Ultrasound: Imaging and Sensing*. San Francisco, California, United States: SPIE, 2018: 104944U.
- [7] LAN Hengrong, YANG Changchun, GAO Feng, et al. Better than ground-truth? Beyond supervised learning for photoacoustic imaging reconstruction[EB/OL]. (2020-12-04)[2021-07-07]. <https://arxiv.org/abs/2012.02472v2>.
- [8] ANTHOLZER S, HALTMEIER M, SCHWAB J. Deep learning for photoacoustic tomography from sparse data[EB/OL]. (2017-04-15)[2021-07-07]. <https://arxiv.org/pdf/1704.04587.pdf>.
- [9] GUO Mengjie, LAN Hengrong, YANG Changchun, et al. AS-Net: Fast photoacoustic reconstruction with multi-feature fusion from sparse data[EB/OL]. (2021-01-22)[2021-07-07]. <https://arxiv.org/abs/2101.08934>.
- [10] AWASTHI N, PARADASANI R, KALVA S K, et al. Sinogram super-resolution and denoising convolutional neural network (SRCN) for limited data photoacoustic tomography[EB/OL]. (2020-01-17)[2021-07-07]. <https://arxiv.org/abs/2001.06434>.
- [11] AWASTHI N, JAIN G, KALVA S K, et al. Deep neural network-based sinogram super-resolution and bandwidth enhancement for limited-data photoacoustic tomography[J]. *IEEE Transactions on Ultrasonics Ferroelectrics and Frequency Control*, 2020, 67(12): 2660-2673.
- [12] 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*, 2017, 26(9): 4509-4522.
- [13] ANTHOLZER S, SCHWAB J, HALTMEIER M. Deep learning versus l^1 -minimization for compressed sensing photoacoustic tomography[EB/OL]. (2019-01-19)[2021-07-07]. <https://arxiv.org/abs/1901.06510>.
- [14] HAN Y, YE J. Framing U-Net via deep convolutional framelets: Application to sparse-view CT[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(6): 1418-1429.
- [15] GUAN S, KHAN A, SIKDAR S, et al. Fully dense UNet for 2D sparse photoacoustic tomography artifact removal[J]. *IEEE Journal of Biomedical and Health Informatics*, 2020, 24(2): 568-576.
- [16] VU T, LI Mucong, HUMAYUN H, et al. A generative adversarial network for artifact removal in photoacoustic computed tomography with a linear-array transducer[J]. *Experimental Biology and Medicine (Maywood, N.J.)*, 2020, 245(7): 597-605.
- [17] CHEN Panpan, LIU Chengcheng, FENG Ting, et al. Improved photoacoustic imaging of numerical bone model based on attention block U-Net deep learning network[J]. *Applied Sciences-Basel*, 2020, 10(22): 8089.
- [18] AWASTHI N, PRABHAKAR R, KALVA S K, et al. PA-Fuse: A deep supervised approach for fusion of photoacoustic images with distinct reconstruction characteristics [J]. *Biomedical Optics Express*, 2019, 10(5): 2227-2243.
- [19] GODEFROY G, ARNAL B, BOSSY E. Compensating for visibility artefacts in photoacoustic imaging with a deep learning approach providing prediction uncertainties[J]. *Photoacoustics*, 2021, 21: 100218.
- [20] WAIBEL D J E. Photoacoustic image reconstruction to solve the acoustic inverse problem with deep learning[D]. Baden-Württemberg: University of Heidelber, 2018.
- [21] SCHWAB J, ANTHOLZER S, NUSTER R, et al. DALnet: High-resolution photoacoustic projection imaging using deep learning[EB/OL]. (2018-01-25)[2021-07-07]. <https://www.doc88.com/p-0488665629284.html?r=1>.
- [22] SCHWAB J, ANTHOLZER S, NUSTER R, et al. Real-time photoacoustic projection imaging using deep learning[EB/OL]. (2018-01-20)[2021-07-07]. <https://arxiv.org/abs/1801.06693>.
- [23] DENG Handi, WANG Xuanhao, CAI Chuangjian, et al. Machine-learning enhanced photoacoustic computed tomography in a

- limited view configuration[C]//Proceedings of the SPIE International Conference on Advanced Optical Imaging Technologies II. Hangzhou, China: SPIE, 2019: 111860J.
- [24] DAVOUDI N, DEÁN-BEN X L, RAZANSKY D. Deep learning optoacoustic tomography with sparse data[J]. *Nature Machine Intelligence*, 2019, 1(10): 453-460.
- [25] LU Tong, CHEN Tingting, GAO Feng, et al. LV-GAN: A deep learning approach for limited-view optoacoustic imaging based on hybrid datasets[J]. *Journal of Biophotonics*, 2021, 14(2): e202000325.
- [26] LAN Hengrong, YANG Changchun, JIANG Daohuai, et al. Reconstruct the photoacoustic image based on deep learning with multi-frequency ring-shape transducer array[C]//Proceedings of 2019 41st Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). Berlin, Germany: IEEE, 2019: 7115-7118.
- [27] GUAN S, KHAN A A, SILDAR S, et al. Limited view and sparse photoacoustic tomography for neuroimaging with deep learning[J]. *Scientific Reports*, 2020, 10(1): 8510.
- [28] MIN W K, 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.
- [29] TONG Tong, HUANG Wenhui, WANG Kun, et al. Domain transform network for photoacoustic tomography from limited-view and sparsely sampled data[J]. *Photoacoustics*, 2020, 19: 100190.
- [30] LAN Hengrong, ZHOU Kang, YANG Changchun, et al. Hybrid neural network for photoacoustic imaging reconstruction[C]//Proceedings of 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Berlin, Germany: IEEE, 2019: 6367-6370.
- [31] LAN Hengrong, JIANG Daohuai, YANG Changchun, et al. Y-Net: Hybrid deep learning image reconstruction for photoacoustic tomography in vivo[J]. *Photoacoustics*, 2020, 20: 100197.
- [32] FRANCIS K J, ARORA A, KANCHARLA P, et al. Generative adversarial network-based photoacoustic image reconstruction from bandlimited and limited-view data[C]//Proceedings of the SPIE International Conference on Photons Plus Ultrasound: Imaging and Sensing. [S.l.]: SPIE, 2021: 1164235.
- [33] ÖKTEM O, ADLER J. Solving ill-posed inverse problems using iterative deep neural networks[J]. *Inverse Problems*, 2017, 33(12): 124007.
- [34] KELLY B, MATTHEWS T P, ANASTASIO M A. Deep learning-guided image reconstruction from incomplete data[EB/OL]. (2017-09-02)[2021-07-07]. <https://arxiv.org/abs/1709.00584v1>.
- [35] HAUPTMANN A, COX B, LUCKA F, et al. Approximate k-space models and deep learning for fast photoacoustic reconstruction[C]//Proceedings of the 1st Workshop on Machine Learning for Medical Image Reconstruction (MLMIR) Held as Part of the 21st Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI). Granada, Spain: Springer, 2018: 103-111.
- [36] HAUPTMANN A, LUCKA F, BETCKE M, et al. Model based learning for accelerated, limited-view 3D photoacoustic tomography[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(6): 1382-1393.
- [37] SHAN Hongming, WIEDEMAN C, WANG Ge, et al. Simultaneous reconstruction of the initial pressure and sound speed in photoacoustic tomography using a deep-learning approach[C]//Proceedings of the 22nd Annual Conference on Novel Optical Systems, Methods, and Applications XXII. San Diego, California: SPIE, 2019: 1110504.
- [38] ADLER J, OKTEM O. Learned primal-dual reconstruction[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(6): 1322-1332.
- [39] BOINK Y E, VAN GILS S A, MANOHAR S, et al. Sensitivity of a partially learned model-based reconstruction algorithm [J]. *Proceedings in Applied Mathematics and Mechanics*, 2018, 18(1): 1-2.
- [40] BOINK Y E, MANOHAR S, BRUNE C. A partially learned algorithm for joint photoacoustic reconstruction and segmentation [J]. *IEEE Transactions on Medical Imaging*, 2020, 39(1): 129-139.
- [41] BOINK Y E, BRUNE C, MANOHAR S. Robustness of a partially learned photoacoustic reconstruction algorithm[C]//Proceedings of the SPIE International Conference on Photons Plus Ultrasound: Imaging and Sensing 2019. San Francisco, California, United State: SPIE, 2019: 108781D.
- [42] SCHWAB J, ANTHOLZER S, HALTMEIER M. Big in Japan: Regularizing networks for solving inverse problems[J].

Journal of Mathematical Imaging and Vision, 2020, 62(3): 445-455.

- [43] AMJAD J, LYU Z, RODRIGUES M R D. Deep learning for inverse problems: Bounds and regularizers[EB/OL]. (2019-01-31)[2021-07-07]. <https://arxiv.org/abs/1901.11352>.
- [44] LI Housen, SCHWAB J, ANTHOLZER S, et al. NETT: Solving inverse problems with deep neural networks[J]. Inverse Problems, 2020, 36(6): 1-23.
- [45] ANTHOLZER S, SCHWAB J, BAUER-MARSCHALLINGER J, et al. NETT regularization for compressed sensing photoacoustic tomography[C]//Proceedings of the SPIE International Conference on Photons Plus Ultrasound: Imaging and Sensing 2019. San Francisco, California, United State: SPIE, 2019: 108783B.
- [46] SCHWAB J, ANTHOLZER S, NUSTER R, et al. Deep learning of truncated singular values for limited view photoacoustic tomography[C]//Proceedings of the SPIE International Conference on Photons Plus Ultrasound: Imaging and Sensing 2019. San Francisco, California, United States: SPIE, 2019: 108783.

作者简介:



孙正(1977-),通信作者,女,教授,硕士生导师,研究方向:生物医学成像技术和生物医学信号处理等,E-mail:sun-zheng@ncepu.edu.cn。



候英飒(1997-),女,硕士研究生,研究方向:深度学习和生物医学成像技术等。

(编辑:王静)