

DOI:10.3969/j.issn.1005-202X.2026.04.001

医学放射物理

基于DCRU-Net的有限视角放疗辐射致声3D在体剂量重建方法

赵新新¹,汪新怡¹,杜胤达¹,陈博湧¹,周凌宏¹,李永宝²,宋婷¹

1.南方医科大学生物医学工程学院,广东广州510515;2.中山大学肿瘤防治中心/华南肿瘤学国家重点实验室/肿瘤医学协同创新中心,广东广州510060

【摘要】目的:针对有限视角下放疗辐射致声(RA)成像用于在线剂量监测时存在的图像畸变与伪影问题,提出一种基于深度级联残差U-Net(DCRU-Net)的3D在体剂量重建方法,以提升剂量监测精度。**方法:**构建深度级联网络DCRU-Net,通过分步优化实现有限视角下声学信号与剂量分布的复杂映射。第一级子网络以反投影(BP)重建的初始压力图为输入,旨在恢复缺失的声场信息,重建全视角3D压力场;第二级子网络在物理转换的基础上进一步校正误差并细化特征,生成高精度3D剂量图。基于80例前列腺癌患者的临床CT及计划剂量数据,利用k-Wave工具箱模拟会阴区2D传感器阵列采集的有限视角RA信号,并引入组织异质性、声速变化及噪声。采用相对均方根误差(rRMSE)、结构相似性(SSIM)及Gamma通过率作为主要评估指标。**结果:**定性分析显示,DCRU-Net能有效消除有限视角引起的失真与伪影,重建结果与标签高度一致。定量评估显示,预测压力图与剂量图的rRMSE分别为3.40%和2.50%,剂量图的SSIM达0.98。在3%/5 mm标准下,0%和70%阈值的Gamma通过率分别为98.18%和99.32%。此外,该方法在不同噪声水平下均表现出较强的稳定性。**结论:**本研究方案实现了高效率、高精度的有限视角3D剂量重建,克服了实际临床中传感器覆盖范围受限的问题,为RA成像在实时在体剂量监测中的应用提供了重要技术手段。

【关键词】放疗辐射致声成像;3D在体剂量监测;反投影重建;有限视角;深度学习

【中图分类号】R318;R811.1

【文献标志码】A

【文章编号】1005-202X(2026)04-0421-09

DCRU-Net-based three-dimensional *in vivo* dose reconstruction method for limited-view radiation-induced acoustic imaging

ZHAO Xinxin¹, WANG Xinyi¹, DU Yinda¹, CHEN Boyong¹, ZHOU Linghong¹, LI Yongbao², SONG Ting¹

1. School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China; 2. Sun Yat-sen University Cancer Center/State Key Laboratory of Oncology in South China/Collaborative Innovation Center for Cancer Medicine, Guangzhou 510060, China

Abstract: Objective A novel three-dimensional (3D) *in vivo* dose reconstruction method based on a deep cascaded residual U-Net (DCRU-Net) is proposed to address the issues of image distortion and artifacts in limited-view radiation-induced acoustic (RA) imaging for online dose monitoring, thereby improving the accuracy of dose monitoring. **Methods** A DCRU-Net was constructed to achieve the complex mapping from limited-view acoustic signals to dose distribution through stepwise optimization. The first-stage sub-network took the initial pressure map reconstructed by back-projection (BP) as input, aiming to recover the missing acoustic information and reconstruct a full-view 3D pressure field. The second-stage sub-network further corrected errors and refined features based on physical conversion, generating a high-precision 3D dose map. Based on the clinical CT and planned dose data from 80 prostate cancer patients, the k-Wave toolbox was adopted to simulate limited-view RA signals acquired by a two-dimensional transducer array in the perineal region, with consideration of tissue heterogeneity, acoustic velocity variations, and noise. The relative root mean square error (rRMSE), structural similarity index (SSIM), and Gamma pass rate were taken as the primary evaluation metrics. **Results** Qualitative analysis demonstrated that the DCRU-Net effectively eliminated distortion and artifacts caused by limited-view acquisition, with reconstructed results showing high consistency with the ground truth maps. Quantitative evaluation revealed that the predicted pressure maps and dose maps achieved rRMSE of 3.40% and 2.50%, respectively, and the dose maps achieved an SSIM of 0.98. Under the 3%/5 mm criterion, the Gamma pass rates at 0% and 70%

【收稿日期】2025-12-20

【基金项目】国家自然科学基金(82472117);广东省基础与应用基础研究基金(2024A1515010820, 2024A1515011831)

【作者简介】赵新新,硕士研究生,研究方向:肿瘤放射物理,E-mail: zhaoxinxin0230@i.smu.edu.cn

【通信作者】李永宝,副研究员,研究方向:肿瘤放射物理,E-mail: liyib1@sysucc.org.cn;宋婷,副教授,博士生导师,研究方向:肿瘤放射物理,E-mail: tingsong2015@smu.edu.cn

threshold conditions were 98.18% and 99.32%, respectively. Furthermore, the proposed method exhibited strong stability across different noise levels. **Conclusion** The proposed method realizes efficient and high-precision 3D dose reconstruction from limited-view data, and overcomes the practical clinical limitation of restricted transducer coverage, providing a significant technical approach for the application of RA imaging in real-time *in vivo* dose monitoring.

Keywords: radiation-induced acoustic imaging; three-dimensional *in vivo* dose monitoring; back-projection reconstruction; limited-view; deep learning

前言

放射治疗是当前治疗恶性肿瘤的重要手段之一,在体剂量监测则是确保放射治疗计划准确执行的重要环节^[1]。目前,放射治疗的在体剂量测量技术主要包括用于3D剂量重建的电子射野影像装置(EPID)以及各类点剂量探测器。然而,EPID在体剂量重建依赖于间接测量透射光子通量并结合剂量计算模型来推算患者体内剂量。该方法缺乏来源于人体吸收剂量的直接信号,计算模型会引入重建误差,同时EPID中的高原子序数材料也会带来射线能量响应问题^[2]。热释光探测器^[3]、光释光探测器、塑料闪烁体探测器^[4]及金属氧化物半导体场效应晶体管^[5]等点剂量探测器主要适用于测量人体的自然腔道剂量,且存在干扰射束、准确性、时间分辨率和空间分辨率有限等问题。此外,近年来随着超高剂量率放射治疗技术FLASH的发展,针对脉冲剂量的在体监测也成为重要研究方向,而EPID及上述探测器均缺乏对脉冲剂量的监测能力。因此,亟需开发一种能够实现直接、非侵入式的3D在体剂量重建与脉冲剂量监测的新方法。

放疗辐射致声成像(RAI)是一种新兴的无创生物医学成像技术,为实时3D在体剂量监测提供了新的可能^[6]。当脉冲电离辐射穿过组织时,组织吸收辐射能量并发生瞬时热弹性膨胀,从而产生可探测的声波^[7]。声信号的振幅与沉积的脉冲剂量成正比^[8],因此可通过检测这些辐射致声信号来重建体内剂量分布。自2013年Xiang等^[6]首次提出放疗辐射致声计算机断层成像以来,RAI技术取得了显著进展。为了提升成像速度,Zheng等^[9]开展了仿真研究,采用半球形3D超声换能器阵列,并验证了放疗辐射致声计算机断层成像在立体定向部分乳腺照射剂量测量中的潜力。为推进RAI技术的临床转化,Zhang等^[10]首次基于研究型超声平台开发了放疗辐射致声成像与B超双模态系统,可同时显示解剖结构与剂量分布。随后,Zhang等^[11]通过集成2D矩阵阵列与多通道前置放大板,实现了治疗期间辐射剂量沉积的高灵敏度实时体积成像,并在体模、兔模型及患者试验中验

证其临床可行性。这些进展均显示RAI在临床实时剂量监测中的巨大应用潜力。然而,在临床实际场景中,探测器通常只能放置在射束之外的有限范围内,仅能采集有限视角的信号,导致重建结果存在严重失真和伪影。传统的通用反投影^[12]与时间反转算法^[13]在有限视角条件下重建质量显著下降;而基于模型的迭代算法^[14]虽可改善伪影,但计算耗时较长,难以满足临床在线剂量验证的需求。

近年来,基于深度学习的方法在医学图像重建领域展现出卓越性能,尤其是在有限视角问题中表现出强大的特征恢复能力^[15-18]。其中,以U-Net^[19]为代表的卷积神经网络结构,凭借其独特的编码器-解码器架构和跳跃连接设计被广泛采用,显著提升图像质量并加快了重建速度。Jiang等^[20]利用U-Net模型有效恢复了有限视角数字断层合成图像中的结构畸变。Choi等^[21]则针对光声计算机断层扫描提出三维渐进式U-Net,显著抑制有限视角伪影,实现活体高时空分辨率动态监测。Jiang等^[22]还将U-Net应用于电致声断层扫描,校正了由有限视角线性阵列采集导致的图像畸变,生成了更准确的压力分布图。

考虑到深度学习方法在有限视角重建中的显著优势,本研究拟采用深度学习方法以解决RAI有限视角重建问题。为此,笔者提出了一种基于深度级联残差U-Net(DCRU-Net)网络的3D在体剂量重建方法。该方法首先采用反投影(BP)算法,从有限视角放疗辐射致声(RA)信号中重建3D初始压力图,并将其输入级联网络。该网络先对压力图进行恢复并完成剂量转换,再对剂量图进行进一步校正与细化,最终输出精确的3D剂量分布,用于放射治疗在体剂量监测。为验证所提方法的可行性,本研究基于前列腺癌患者容积旋转调强放疗(VMAT)计划的CT图像和剂量数据进行声学仿真和剂量重建。

1 材料与方法

1.1 放疗辐射致声理论与剂量-声压关系

当脉冲电离辐射穿过组织时,其能量被组织吸收并转化为热能,引发局部温度的瞬时升高,从而引

起声信号的产生和传播。在热约束的假设下,这一过程可以用波动方程描述^[23-25]:

$$\left(\nabla^2 - \frac{1}{c^2} \frac{\partial^2}{\partial t^2}\right) P(\mathbf{r}, t) = -\frac{\beta \eta_{th}}{C_p} \frac{\partial A_p(\mathbf{r}, t)}{\partial t} \quad (1)$$

其中, c 为声速, $P(\mathbf{r}, t)$ 为位置 \mathbf{r} 和时间 t 的压力, β 为热膨胀系数, η_{th} 是被吸收的电能转化为热能的百分比, C_p 为比热容, A_p 为单位体积和单位时间内沉积的电离辐射能量。

在满足应力约束的条件下,单个辐射脉冲可由狄拉克 δ 函数近似表征,声传播可求解为:

$$P(\mathbf{r}, t) = \frac{1}{4\pi c^2} \frac{\partial}{\partial t} \int d\mathbf{r}' \frac{1}{|\mathbf{r} - \mathbf{r}'|} P_0(\mathbf{r}') \delta\left(t - \frac{|\mathbf{r} - \mathbf{r}'|}{c}\right) \quad (2)$$

其中, $P_0(\mathbf{r}')$ 为电离辐射产生的初始压力。

当同时满足热约束和应力约束时^[23],单个辐射脉冲产生的声信号振幅与组织单位时间内的沉积剂量成正比。此时初始压力 $P_0(\mathbf{r})$ 与剂量 $D(\mathbf{r})$ 的关系为^[23,26]:

$$P_0(\mathbf{r}) = D(\mathbf{r}) \rho \quad (3)$$

其中, ρ 为密度, Γ 为Grüneisen参数,可以通过以下公式计算:

$$\Gamma = c^2 \beta / C_p \quad (4)$$

1.2 有限视角的RA仿真及BP重建

1.2.1 患者数据与预处理

本研究收集了80例行VMAT治疗的前列腺癌患者的CT图像和相应的放疗计划剂量数据,所有数据的使用均经机构伦理委员会批准,并进行了匿名化处理。将全部数据按7:1:2的比例划分为训练集(56例)、验证集(8例)与测试集(16例)。为构建可用于后续仿真与模型训练的配对

数据集,所有CT与剂量分布图均经空间重采样处理,统一分辨率为 $1.25 \text{ mm} \times 1.25 \text{ mm} \times 1.25 \text{ mm}$ 。随后,对剂量分布进行最大值归一化处理;同时,基于阈值分割算法,将CT图像根据不同的HU值分割为空气、脂肪、软组织和骨骼4种组织类型。为避免声阻抗不匹配,将分割得到的空气区域替换为水。最后,为不同组织类型赋予其特定的热声参数(表1)^[27-28],从而完成仿真前的数据准备工作。

表1 RA信号仿真中使用的组织特异性参数

Table 1 Tissue-specific parameters used in RA signal simulation

| 组织类型 | HU值 | $\rho/\text{kg} \cdot \text{m}^{-3}$ | Γ | $c/\text{m} \cdot \text{s}^{-1}$ |
|------|----------------|--------------------------------------|----------|----------------------------------|
| 空气 | [-1 000, -200) | - | - | - |
| 脂肪 | [-200, -50) | 920 | 0.80 | 1480 |
| 水 | 0 | 1000 | 0.11 | 1500 |
| 软组织 | [-50, 100) | 1040 | 0.30 | 1540 |
| 骨骼 | [100, max) | 1900 | 0.80 | 2000 |

ρ : 密度; Γ : Grüneisen 参数; c : 速度

1.2.2 声学仿真设置与初始压力重建

图1展示了本研究采用的有限视角RA仿真及BP重建工作流程。首先,基于CT图像和表1,生成了声速图、密度图和Grüneisen参数图(图1a)。其中,声速图和密度图用于建模声波传播过程,密度图与Grüneisen参数图相乘用于得到剂量-声压转换系数图($\rho \times \Gamma$)。然后根据公式(3),将预处理得到的剂量分布图转换为仿真所需的初始压力分布图。

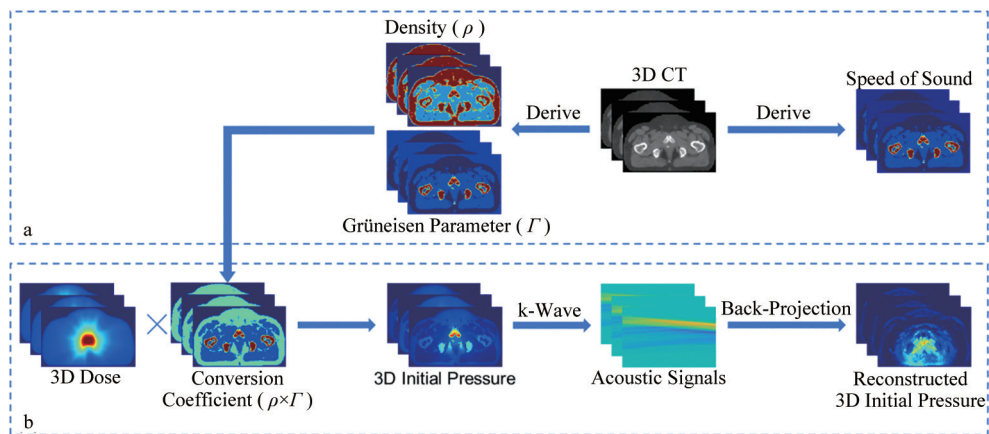


图1 有限视角RA仿真及BP重建工作流程

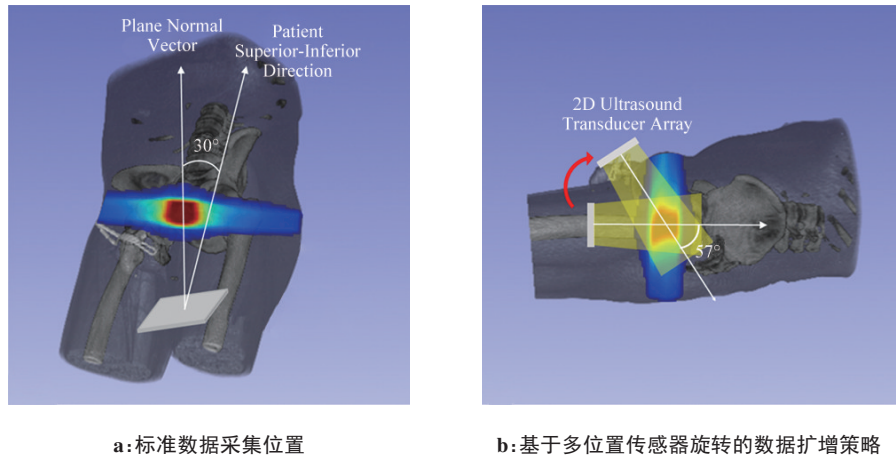
Figure 1 Workflow for limited-view RA simulation and BP reconstruction

随后,在MATLAB(R2023b)环境中,利用开源k-Wave工具箱^[29]进行有限视角的声学仿真(图1b)。

为模拟有限视角采集条件,声信号的采集通过一个置于会阴部位的2D超声传感器阵列(80×80 阵元,有

效面积 10 cm×10 cm)实现。该阵列的中心对准靶区中心,其法线方向与患者身体头脚方向呈 30°夹角,以避开骨盆骨(图 2a)。为模拟更真实的测量条件,仿真采样率设为 5 MHz,并充分考虑了组织异质性和

声速不均匀性的影响。此外,在采集的 RA 信号中添加了信噪比为 10 dB 的高斯白噪声。为了模拟自由场传播并抑制边界反射,计算域边界设置了 10 像素的完美匹配层。



a: 标准数据采集位置

b: 基于多位置传感器旋转的数据扩增策略

图 2 超声传感器阵列位置示意图

Figure 2 Schematic of the ultrasound transducer array position

最后,采用 BP 算法^[30]对采集的声信号进行重建。BP 算法以其较高的重建效率,为快速在线剂量验证提供了可行的技术基础。本研究利用 k-Wave 工具箱提供的伴随反投影算子进行反投影重建,重建得到的 3D 初始压力图将作为本研究所提出网络的输入。

1.2.3 数据扩增策略 为了扩大训练样本的数据量,降低模型过拟合风险,本研究在会阴区域的不同位置模拟传感器(图 2b)。将平面阵列初始位置置于前列腺正下方会阴区域,保持其法线方向与患者头脚方向平行,以此作为仿真的起点。随后按图示箭头旋转方向,以 3°为间隔旋转传感器,最大旋转角度为

57°,共旋转 19 次。最终,56 例训练集患者共产生 1 176 个样本,而验证集与测试集不作扩增。

1.3 基于 DCRU-Net 的有限视角 RAI 剂量重建

1.3.1 级联式重建流程

本研究构建了一个用于 RAI 在体剂量重建的级联深度学习流程(图 3)。该流程首先将 BP 重建的初始压力图输入第一级残差 U-Net (Res-UNet),以补全因传感器探测角度受限而缺失的声场空间信息,重建出全视角压力场;随后,将预测的全视角压力图通过物理关系转换为剂量图,并输入到第二级 Res-UNet,以进一步校正系统误差并细化特征。最终,网络输出高精度的 3D 剂量分布图,用于放射治疗在体剂量监测。

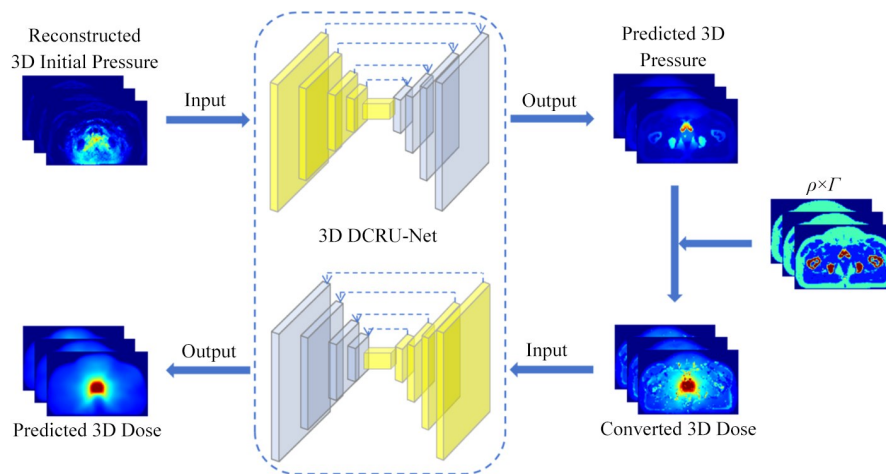


图 3 基于 DCRU-Net 的有限视角 RA 剂量重建流程

Figure 3 Workflow of limited-view RA dose reconstruction based on the DCRU-Net

1.3.2 DCRU-Net 网络架构 DCRU-Net 网络由两个级联的 Res-UNet 模型(图4)构成。在标准 U-Net 的基础上,每个 Res-UNet 引入了残差连接^[31],将输入与输出相加。该设计有效缓解了深度网络中的梯度消失问题,促进了特征复用,并降低了过拟合风险。网络全部采用 3D 卷积层以充分利用体积数据的空间上

下文信息。为适配小批次的训练条件,编码器-解码器各阶段使用对批次大小不敏感的实例归一化层^[32]。此外,在瓶颈层(即最后一次下采样与第一次上采样之前)引入了 Dropout 层^[33]作为正则化,通过随机失活神经元以提升模型的泛化能力。




图4 Res-UNet 架构

Figure 4 Res-UNet architecture

1.3.3 模型训练 本研究对 DCRU-Net 进行端到端的联合训练,同步优化两个级联网络的参数。训练数据包含 1 176 对有限视角 BP 算法重建的初始压力图及其对应的全视角初始压力图与剂量图构成。第一级网络以有限视角初始压力图作为输入,以全视角初始压力图作为监督目标进行训练;第二级网络以第一级网络输出的压力图转换得到的剂量图作为输入,以全视角剂量图作为监督目标进行训练,最终输出高精度的 3D 剂量分布。

在输入网络之前,所有样本依次经过零填充、重采样处理,最终尺寸统一为 $80 \times 96 \times 160$,并进行最大值归一化。为提升模型泛化能力,训练过程中采用多种随机数据增强策略,包括:以 0.8 的概率在矢状面与冠状面内进行随机翻转;以 0.3 的概率在矢状面内从预设角度(0° 、 40° 、 80° 、 120° 、 160° 、 200° 、 240° 、 280° 、 320°)中随机选择进行旋转;以 0.8 的概率在 1 个或多个方向上进行最大 20 像素的随机平移。

在模型训练阶段,通过最小化第一级网络与第二级网络的联合损失进行优化。联合损失函数由两

级网络输出与对应标签图像之间的均方误差构成,其损失权重均设为 1。优化器设置为 Adam, beta1 为 0.900, beta2 为 0.999。初始学习率设置为 0.000 1,并采用线性衰减策略,在训练过程中逐渐降低至 0。总训练轮数设为 1 000。批量大小设置为 1。训练过程中,使用验证集监控泛化性能,并采用早停策略,根据验证集损失选择最优模型检查点,防止过拟合。此外,超参数(如损失函数、损失函数权重、初始学习率与衰减策略等)在验证集上进行调优以优化模型性能。模型构建及训练基于 PyTorch 平台完成,运行环境为配备 Intel Xeon Gold CPU、128 GB 内存及 NVIDIA RTX GPU(显存 48 GB)的工作站。

1.4 模型评估

1.4.1 重建性能评估 为评估模型性能,本研究在包含 16 例患者的测试集上进行验证。测试数据经相同的有限视角仿真与 BP 算法重建后,输入到训练好的 DCRU-Net 模型,得到高质量的 3D 压力与剂量分布,并与对应的标签图像进行定性和定量比较。

1.4.2 噪声鲁棒性测试 为检验模型对噪声的鲁棒

性,在测试集声学信号中添加不同信噪比的高斯白噪声,其信噪比分别为5、10、15、20和30 dB。使用与1.4.1相同的方法,将这些在不同噪声水平下生成的数据输入已训练的网络(该网络使用10 dB信噪比数据训练)进行预测,并分析其性能变化。

1.4.3 评估指标 本研究采用相对均方根误差(rRMSE)、峰值信噪比(PSNR)和结构相似性指数(SSIM)定量评估重建的压力图与剂量图相对于标签图像的差异,以反映模型的整体重建精度和结构保真度。其中,rRMSE通过标签图像的最大值进行归一化。此外,还采用Dice相似系数(DSC)与Gamma通过率对重建的剂量图进行进一步评估。对于DSC,从剂量图中提取10%、25%、50%、75%和90%的等剂量线,并在这些等剂量线区域内计算DSC。

对于Gamma分析,采用临床常用标准(3%/3 mm、2%/3 mm、3%/5 mm、2%/5 mm),分别在全局区域(阈值为0%)和肿瘤及周围高剂量区域(阈值为70%)计算Gamma通过率,以评估模型在临床关键区域的剂量重建效果。

2 结果

2.1 预测的压力图

图5展示测试集中1个代表性病例的初始压力图预测结果。由于有限的探测视角,BP算法重建的初始压力图存在明显的畸变与伪影。经过本文方法校正后,图像结构更加清晰,伪影显著减少。预测的初始压力图与标签图像在主要结构上高度吻合。

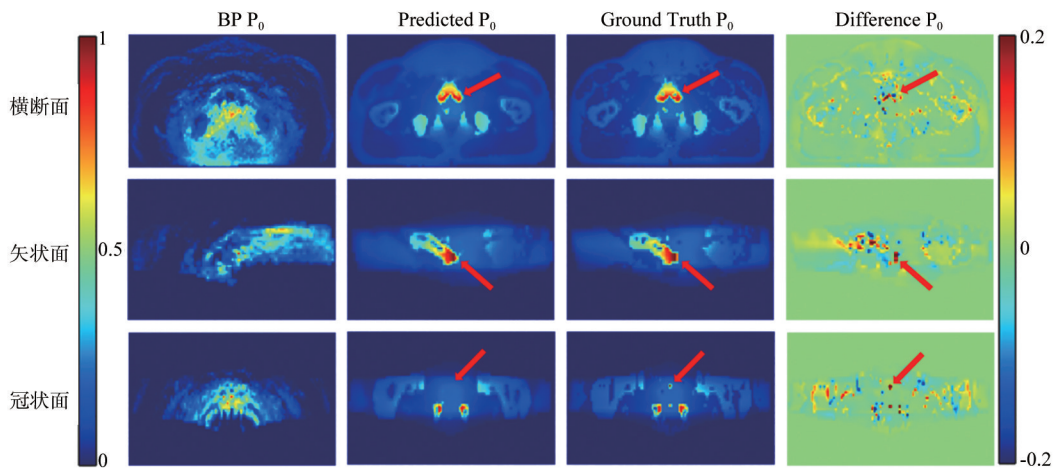


图5 预测的初始压力图示例

Figure 5 Examples of the predicted initial pressure maps

P_0 :初始压力图;BP P_0 :反投影重建的初始压力图;Predicted P_0 :第一级网络预测的初始压力图;Ground Truth P_0 :初始压力的标签图像;Difference P_0 :预测的初始压力图与标签图像之间的差异图

表2显示了16例测试集患者预测的定量结果。与标签图像相比,预测的初始压力图显示出了低rRMSE、高PSNR和高SSIM。这表明本文方法有效提高了图像质量。

2.2 预测的剂量图

图6展示了同一病例的剂量图预测结果。第一级网络预测的初始压力图转换为剂量图后仍存在失真

和伪影,经过第二级网络的进一步校正与细化,预测的最终剂量图与标签图像相比,表现出高度一致性。定量结果(表2)进一步证实,剂量图的各项评估指标相较于压力图有进一步提升,其中rRMSE低至2.50%,PSNR达到32.42 dB,SSIM达到0.98,充分体现了级联网络架构在剂量重建过程中的优势。

表3显示了16例测试集患者预测剂量图的DSC和Gamma通过率。所有DSC均超过0.90;在0%阈值下,Gamma通过率(3%/5 mm)达到98.18%。在70%阈值下,Gamma通过率显著提升,其中Gamma通过率(2%/5 mm)从96.26%提高至98.93%,Gamma通过率(2%/3 mm)从90.64%提高至94.11%。结果表明,在临床关键的肿瘤及周围高剂量区域,本文方法能够更准确地重建剂量分布。

表2 预测的初始压力图和剂量图的定量结果

Table 2 Quantitative results of the predicted initial pressure and dose maps

| 类型 | rRMSE/% | PSNR/dB | SSIM |
|------|----------|------------|-----------|
| 初始压力 | 3.40±0.5 | 29.18±1.34 | 0.85±0.02 |
| 剂量 | 2.50±0.4 | 32.42±1.24 | 0.98±0.01 |

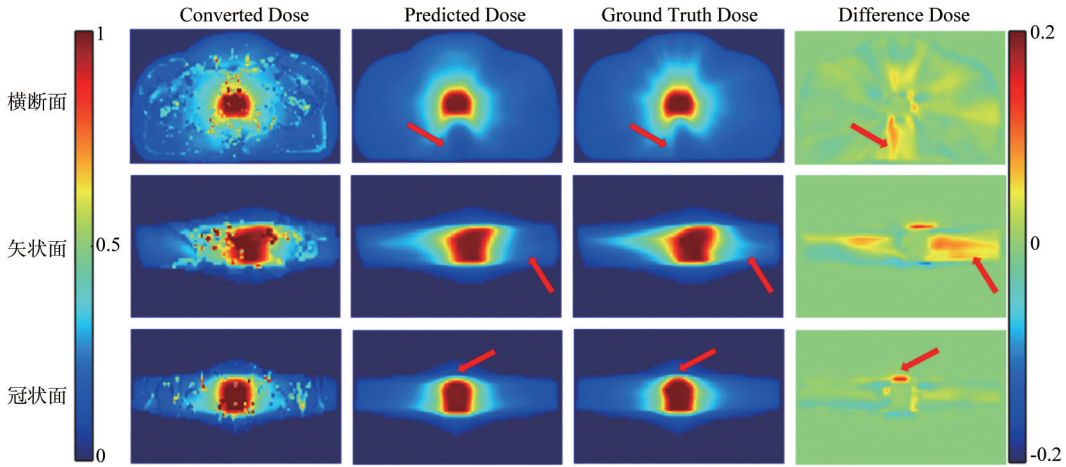


图6 预测的剂量图示例

Figure 6 Examples of the predicted dose maps

Converted Dose: 由第一阶段网络预测的初始压力图转换得到的剂量图; Predicted Dose: 第二阶段网络预测的剂量图;
Ground Truth Dose: 剂量的标签图像; Difference Dose: 预测的剂量图与标签图像之间的差异图

表3 预测的剂量图的定量结果

Table 3 Quantitative results of the predicted dose maps

| 类型 | 指标 | 数值 |
|-------------------|---------|------------|
| DSC | 10%等剂量线 | 0.98±0.01 |
| | 25%等剂量线 | 0.92±0.01 |
| | 50%等剂量线 | 0.93±0.02 |
| | 75%等剂量线 | 0.92±0.03 |
| | 90%等剂量线 | 0.90±0.04 |
| Gamma通过率(0%阈值)/% | 3%/5 mm | 98.18±0.95 |
| | 3%/3 mm | 95.16±1.60 |
| | 2%/5 mm | 96.26±1.41 |
| | 2%/3 mm | 90.64±2.77 |
| Gamma通过率(70%阈值)/% | 3%/5 mm | 99.32±1.73 |
| | 3%/3 mm | 95.86±2.52 |
| | 2%/5 mm | 98.93±2.45 |
| | 2%/3 mm | 94.11±2.48 |

2.3 对信噪比变化的鲁棒性

图7、图8展示了在测试集中,1个代表性病例在不同信噪比下的定性结果。与信噪比为10 dB的数据相比,信噪比为5、15、20和30 dB时,预测的初始压力图出现轻微变化,剂量图基本无变化。

图9显示了测试集中所有病例在不同评估指标和信噪比下的箱线图。可以看出,随信噪比变化,各项指标(rRMSE、PSNR、SSIM、Gamma通过率及DSC)的波动幅度较小,表明该模型在噪声干扰下仍能保持稳定表现,具有较强的鲁棒性。

3 讨论

本研究针对放疗RA剂量重建中因有限视角探测导致的图像畸变与伪影问题,提出一种基于DCRU-Net的深度学习的方法。该方法以有限视角RA信号BP算法重建的3D初始压力图为输入,通过级联网络依次完成压力图的恢复、剂量转换与优化,最终输出精确的3D剂量分布。研究结果显示,该方法不仅能够实现高精度的剂量重建,还显著提高了重建效率。

在RAI领域,以往研究主要依赖于传统算法^[11,34]进行剂量重建。这类算法本质上受限于成像几何和物理模型,当探测角度不足时难以有效补偿缺失信息,容易产生严重的伪影与结构畸变(图5)。相比之下,本研究采用的深度学习的方法通过让网络学习大量训练数据中的空间上下文特征,实现了对有限视角下信息缺失的有效补偿,从而抑制了伪影并恢复出更接近真实的解剖结构,显著提升了重建质量。此外,本研究基于BP算法结合深度学习网络重建的方案在保证高预测精度的同时,具备较高的重建效率,为前列腺癌VMAT治疗的在体剂量监测提供新的可能。

模型在临床关键区域(肿瘤及周围高剂量区)重建的剂量分布与标签图像高度一致,但在低剂量区域的重建精度相对较低(图6)。这是由于VMAT治疗计划的完整剂量图范围较大,而2D超声传感器阵列尺寸有限,仅能覆盖肿瘤及周围高剂量区,从而限制了低剂量区域的重建精度。采用更大尺寸的阵列有望提高低剂量区域的重建精度,但存在临床场景下探测器放置的困难。




图 7 不同信噪比水平下预测的压力图示例

Figure 7 Examples of the predicted pressure maps at different SNR levels




图 8 不同信噪比水平下预测的剂量图示例

Figure 8 Examples of the predicted dose maps at different SNR levels

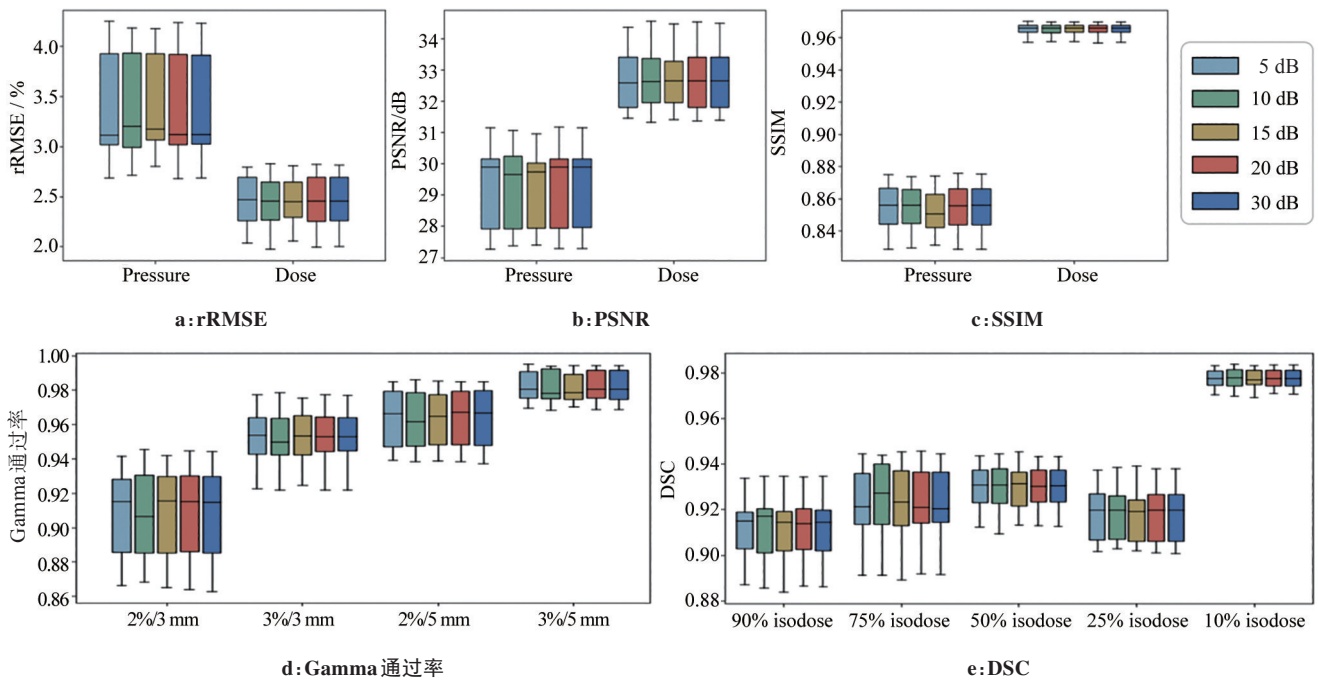


图 9 不同信噪比下各评价指标的 rRMSE、PSNR、SSIM、Gamma 通过率和 DSC 指标的箱线图
Figure 9 Box plots of rRMSE, PSNR, SSIM, Gamma pass rate, and DSC at different SNR levels

此外,模型在不同噪声水平下保持稳定表现(图9),其鲁棒性主要来源于两个方面:模型在训练阶段使用含噪声的输入与无噪声的标签图像进行监督学习,使网络能够学习有效的噪声抑制能力;另一方面,本研究采用了随机翻转、随机平移、随机旋转的数据增强策略,使模型避免过拟合于特定噪声水平,从而学习到更具普适性的特征表示。

本研究仍存在以下局限性:(1)训练数据规模有限:由于临床数据较为稀缺,模型可能存在一定的过拟合风险。虽然通过数据扩增策略(调整传感器放置位置)有效缓解了该问题并提升了模型性能,但未来仍需进一步扩充数据规模与多样性,以提高模型的泛化能力。(2)验证环境与真实临床场景存在差异:本研究结果基于仿真数据,尽管在仿真中引入了组织异质性和噪声,但仍无法完全复现真实患者体内的复杂声学环境与个体差异性。未来工作将推进临床试验,利用真实患者数据全面评估该方法的临床可行性与准确性。

4 结论

本研究提出了一种基于深度学习的有限视角RAI剂量重建方法,通过DCRU-Net与BP算法相结合,显著提升了剂量重建的精度与效率。该方法证明了在前列腺癌VMAT治疗中利用RA信号实现在体3D剂量监测的可行性,这对于保障放射治疗的实施精度具有重要意义。

【参考文献】

- [1] Shimohigashi Y, Toya R, Saito T, et al. Tumor motion changes in stereotactic body radiotherapy for liver tumors: an evaluation based on four-dimensional cone-beam computed tomography and fiducial markers[J]. *Radiat Oncol*, 2017, 12(1): 61.
- [2] Olaciregui-Ruiz I, Vivas-Maiques B, Kaas J, et al. Transit and non-transit 3D EPID dosimetry versus detector arrays for patient specific QA[J]. *J Appl Clin Med Phys*, 2019, 20(6): 79-90.
- [3] Rivera T. Thermoluminescence in medical dosimetry[J]. *Appl Radiat Isot*, 2012, 71 Suppl: 30-34.
- [4] Wootton L, Kudchadker R, Lee A, et al. Real-time in vivo rectal wall dosimetry using plastic scintillation detectors for patients with prostate cancer[J]. *Phys Med Biol*, 2014, 59(3): 647-660.
- [5] Den RB, Nowak K, Buzurovic I, et al. Implanted dosimeters identify radiation overdoses during IMRT for prostate cancer[J]. *Int J Radiat Oncol Biol Phys*, 2012, 83(3): e371-e376.
- [6] Xiang LZ, Han B, Carpenter C, et al. X-ray acoustic computed tomography with pulsed x-ray beam from a medical linear accelerator[J]. *Med Phys*, 2013, 40(1): 010701.
- [7] Hickling S, Leger P, El Naqa I. On the detectability of acoustic waves induced following irradiation by a radiotherapy linear accelerator[J]. *IEEE Trans Ultrason Ferroelectr Freq Control*, 2016, 63(5): 683-690.
- [8] Hickling S, Hobson M, El Naqa I. Characterization of X-ray acoustic computed tomography for applications in radiotherapy dosimetry[J]. *IEEE Trans Radiat Plasma Med Sci*, 2018, 2(4): 337-344.
- [9] Zheng Y, Samant P, Merill J, et al. X-ray-induced acoustic computed tomography for guiding prone stereotactic partial breast irradiation: a simulation study[J]. *Med Phys*, 2020, 47(9): 4386-4395.
- [10] Zhang W, Oraiqat I, Lei H, et al. Dual-modality X-ray-induced radiation acoustic and ultrasound imaging for real-time monitoring of radiotherapy[J]. *BME Front*, 2020, 2020: 9853609.
- [11] Zhang W, Oraiqat I, Litzenberg D, et al. Real-time, volumetric imaging of radiation dose delivery deep into the liver during cancer treatment[J]. *Nat Biotechnol*, 2023, 41(8): 1160-1167.
- [12] Xu MH, Wang LÜ. Universal back-projection algorithm for photoacoustic computed tomography[J]. *Phys Rev E Stat Nonlin Soft Matter Phys*, 2005, 71(1 Pt 2): 016706.
- [13] Treeby BE, Zhang EZ, Cox BT. Photoacoustic tomography in absorbing acoustic media using time reversal[J]. *Inverse Probl*, 2010, 26(11): 115003.
- [14] Pandey PK, Wang SQ, Sun LS, et al. Model-based 3-D X-ray induced acoustic computerized tomography[J]. *IEEE Trans Radiat Plasma Med Sci*, 2023, 7(5): 532-543.
- [15] Jiang ZR, Chen YX, Zhang YW, et al. Augmentation of CBCT reconstructed from under-sampled projections using deep learning[J]. *IEEE Trans Med Imaging*, 2019, 38(11): 2705-2715.
- [16] Chen HC, Li QX, Zhou LZ, et al. Deep learning-based algorithms for low-dose CT imaging: a review[J]. *Eur J Radiol*, 2024, 172: 111355.
- [17] Tian C, Shen K, Dong WD, et al. Image reconstruction from photoacoustic projections[J]. *Photon Insights*, 2024, 3(3): R06.
- [18] Jiang ZR, Polf JC, Barajas CA, et al. A feasibility study of enhanced prompt gamma imaging for range verification in proton therapy using deep learning[J]. *Phys Med Biol*, 2023, 68(7): 075001.
- [19] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//*Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015*. Cham: Springer International Publishing, 2015: 234-241.
- [20] Jiang ZR, Yin FF, Ge Y, et al. Enhancing digital tomosynthesis (DTS) for lung radiotherapy guidance using patient-specific deep learning model[J]. *Phys Med Biol*, 2021, 66(3): 035009.
- [21] Choi S, Yang JG, Lee SY, et al. Deep learning enhances multiparametric dynamic volumetric photoacoustic computed tomography *in vivo* (DL-PACT)[J]. *Adv Sci (Weinh)*, 2023, 10(1): 2202089.
- [22] Jiang ZR, Xu YF, Sun LS, et al. Enhanced electroacoustic tomography with supervised learning for real-time electroporation monitoring[J]. *Precis Radiat Oncol*, 2024, 8(3): 110-118.
- [23] Zhou Y, Yao JJ, Wang LV. Tutorial on photoacoustic tomography[J]. *J Biomed Opt*, 2016, 21(6): 61007.
- [24] Kruger RA, Liu P, Fang YR, et al. Photoacoustic ultrasound (PAUS)--reconstruction tomography[J]. *Med Phys*, 1995, 22(10): 1605-1609.
- [25] Wang LV, Wu HI. *Biomedical optics: principles and imaging*[M]. Hoboken, NJ: John Wiley & Sons, 2007.
- [26] Gebauer B, Scherzer O. Impedance-acoustic tomography[J]. *SIAM J Appl Math*, 2008, 69(2): 565-576.
- [27] Prince JL, Links JM. *Medical imaging signals and systems*[M]. Upper Saddle River, NJ: Pearson Prentice Hall, 2006.
- [28] Yao DK, Zhang C, Maslov K, et al. Photoacoustic measurement of the Grüneisen parameter of tissue[J]. *J Biomed Opt*, 2014, 19(1): 17007.
- [29] Treeby BE, Cox BT. k-Wave: MATLAB toolbox for the simulation and reconstruction of photoacoustic wave fields[J]. *J Biomed Opt*, 2010, 15(2): 021314.
- [30] Arridge SR, Betcke MM, Cox BT, et al. On the adjoint operator in photoacoustic tomography[J]. *Inverse Probl*, 2016, 32(11): 115012.
- [31] He KM, Zhang XY, Ren SQ, et al. Deep residual learning for image recognition[C]//*2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway, NJ, USA: IEEE, 2016: 770-778.
- [32] Ulyanov D, Vedaldi A, Lempitsky V. Instance normalization: the missing ingredient for fast stylization[EB/OL]. (2017-11-06). <https://arxiv.org/abs/1607.08022>.
- [33] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. *J Mach Learn Res*, 2014, 15(1): 1929-1958.
- [34] Wang MX, Samant P, Wang SQ, et al. Toward in vivo dosimetry for prostate radiotherapy with a transperineal ultrasound array: a simulation study[J]. *IEEE Trans Radiat Plasma Med Sci*, 2021, 5(3): 373-382.

(编辑:薛泽玲)