

基于 U-Net 深度学习模型改善⁹⁹Tc^m-MAA SPECT/CT 肝动脉灌注显像稀疏投影的图像质量

隋国庆¹ 张宏钰² 王子阳³ 王卫³ 郑明明³ 王亚亚³ 朱磊¹ 徐文贵¹

¹天津医科大学肿瘤医院分子影像及核医学诊疗科、国家恶性肿瘤临床医学研究中心、天津市恶性肿瘤临床医学研究中心、天津市肿瘤防治重点实验室,天津 300060;²天津医科大学肿瘤医院放射诊断科,天津 300060;³天津市肿瘤医院空港医院核医学科、国家恶性肿瘤临床医学研究中心,天津 300308

通信作者:徐文贵, Email: wenguixy@163.com

【摘要】 目的 探讨与全角度投影、稀疏投影重建对比,基于深度学习方法的稀疏投影重建对⁹⁹Tc^m-大颗粒聚合白蛋白(MAA) SPECT 图像质量的优化。**方法** 回顾性收集 2023 年 3 月至 2025 年 6 月于天津市肿瘤医院空港医院行⁹⁹Tc^m-MAA SPECT/CT 肝动脉灌注显像的肝肿瘤患者 51 例[男 34 例,女 17 例,年龄 60(51,65)岁]开展横断面研究。采用 U-Net 网络构建深度学习模型并进行训练,将全角度投影(60 个角度)重建的图像记为 A1,稀疏投影(15 个角度)重建的图像记为 A2,深度学习辅助稀疏投影重建的图像记为 A3。由 2 名医师分别对 3 组投影图像进行 3 分制主观评分,采用 Kappa 检验分析其评分一致性。通过后处理工作站获取肿瘤灌注区计数最大值(Counts_{max}),在肝脏的非肿瘤灌注区域选择摄取均匀的区域获取计数标准差(Counts_{SD}),计算病灶信噪比(SNR)。图像定量分析参数包括均方根误差(RMSE)、平均绝对误差(MAE)、峰值信噪比(PSNR)、结构相似性指数(SSIM)。将 A2 与 A1 的定量参数偏差记为 A₂₋₁,A3 与 A1 的定量参数偏差记为 A₃₋₁。组间差异采用 Friedman(两两比较行 Bonferroni 校正)或 Wilcoxon 符号秩检验对比。**结果** 2 位医师对 A1、A2、A3 组图像的主观评分一致性好(κ 值:0.94、0.96、0.94,均 $P<0.001$)。3 组图像的 2 名医师评分均值中位数分别为 3(3,3)、1(1,2)、3(3,3)分,A1 与 A2、A2 与 A3 差异有统计学意义($F=91.46, P<0.001$;均 Bonferroni 校正 $P<0.001$)。A2 与 A1、A3 的 SNR 差异有统计学意义($F=79.33, P<0.001$;均 Bonferroni 校正 $P<0.001$)。RMSE、MAE、PSNR、SSIM 的 A₂₋₁ 分别为 4.557(1.601, 8.103)、0.171(0.080, 0.410)、55.446(51.834, 57.760) dB 和 0.963(0.946, 0.973),A₃₋₁ 分别为 4.548(1.600, 7.656)、0.163(0.079, 0.379)、55.598(51.860, 57.943) dB 和 0.967(0.954, 0.980),2 组间差异均有统计学意义(Z 值:-5.45~5.89,均 $P<0.01$)。**结论** 构建的 U-Net 深度学习模型对⁹⁹Tc^m-MAA SPECT/CT 稀疏投影重建图像的质量有显著改善作用,可缩短采集时间,为精准的⁹⁰Y 微球选择性内放射治疗提供技术支撑。

【关键词】 肝肿瘤;^{99m}Tc 铟聚集白蛋白;体层摄影术,发射型计算机,单光子;体层摄影术,X 线计算机;图像处理,计算机辅助;深度学习;U-Net

基金项目:天津市医学重点学科建设项目(TJYXZDXK-3-004B)

DOI:10.3760/cma.j.cn321828-20251121-00424

Image quality enhancement in ⁹⁹Tc^m-MAA SPECT/CT hepatic arterial perfusion imaging from sparse projection using a deep learning model based on U-Net

Sui Guoqing¹, Zhang Hongyu², Wang Ziyang³, Wang Wei³, Zheng Mingming³, Wang Yaya³, Zhu Lei¹, Xu Wengui¹

¹Department of Molecular Imaging and Nuclear Medicine, Tianjin Medical University Cancer Institute and Hospital, National Clinical Research Center for Cancer, Key Laboratory of Cancer Prevention and Therapy, Tianjin's Clinical Research Center for Cancer, Tianjin 300060, China; ²Department of Radiology, Tianjin Medical University Cancer Institute and Hospital, Tianjin 300060, China; ³Department of Nuclear Medicine, Tianjin Cancer Hospital Airport Hospital, National Clinical Research Center for Cancer, Tianjin 300308, China
Corresponding author: Xu Wengui, Email: wenguixy@163.com

【Abstract】 Objective To investigate the optimization of ⁹⁹Tc^m-macroaggregated albumin (MAA) SPECT imaging quality using deep learning-based sparse projection reconstruction by comparing with full-angle

projection and sparse projection reconstructions. **Methods** A retrospective cross-sectional analysis was conducted on 51 liver tumor patients (34 males, 17 females, age 60(51,65) years) who underwent $^{99}\text{Tc}^{\text{m}}$ -MAA SPECT/CT hepatic arterial perfusion imaging at Tianjin Cancer Hospital Airport Hospital between March 2023 and June 2025. A deep learning model based on U-Net architecture was constructed and trained. The full-angle projection (60 angles) reconstructed images were designated as A1 group, the sparse projection (15 angles) reconstructed images were A2 group, and the deep learning-assisted sparse projection reconstruction images were A3 group. Two physicians independently performed subjective assessments of the 3 image sets using a 3-point scale, and the inter-rater agreement was analyzed using *Kappa* test. The maximum counts ($\text{Counts}_{\text{max}}$) in the tumor perfusion area and the standard deviation of counts ($\text{Counts}_{\text{SD}}$) in a homogeneous non-tumor liver perfusion region were obtained via the post-processing workstation to calculate the lesion signal-to-noise ratio (SNR). Parameters of quantitative image analysis including root mean square error (RMSE), mean absolute error (MAE), peak signal-to-noise ratio (PSNR), and structural similarity index measure (SSIM) were obtained. The deviations of quantitative parameters between A2 and A1 (denoted as A_{2-1}) and between A3 and A1 (denoted as A_{3-1}) were compared. The Friedman test (Bonferroni correction for post-hoc test) or Wilcoxon signed-rank test was used to analyze data differences. **Results** The two physicians demonstrated high inter-observer agreement in subjective scoring of A1, A2, and A3 groups (κ values: 0.94, 0.96, and 0.94; all $P<0.001$). The median visual scores for the 3 groups were 3(3,3), 1(1,2), and 3(3,3), respectively, with significant differences observed between A1 and A2, and between A2 and A3 ($F=91.46$, $P<0.001$; Bonferroni correction $P<0.001$ for both). SNR values differed significantly between A2 and A1, and between A2 and A3 ($F=79.33$, $P<0.001$; Bonferroni correction $P<0.001$ for both). The A_{2-1} deviations for RMSE, MAE, PSNR, and SSIM were 4.557(1.601,8.103), 0.171(0.080,0.410), 55.446(51.834,57.760) dB, and 0.963(0.946,0.973), respectively. The A_{3-1} deviations were 4.548(1.600,7.656), 0.163(0.079,0.379), 55.598(51.860,57.943) dB, and 0.967(0.954,0.980), respectively. The differences between the 2 deviation groups (A_{2-1} vs A_{3-1}) were statistically significant (Z values: -5.45 to 5.89, all $P<0.01$). **Conclusions** The U-Net model significantly improves $^{99}\text{Tc}^{\text{m}}$ -MAA SPECT/CT image quality from sparse projection. It enables a reduction in acquisition time, providing vital technical support for accurate ^{90}Y -selective internal radiation therapy.

[Key words] Liver neoplasms; Technetium Tc 99m aggregated albumin; Tomography, emission-computed, single-photon; Tomography, X-ray computed; Image processing, computer-assisted; Deep learning; U-Net

Fund program: Tianjin Key Medical Discipline Construction Project (TJYXZDXK-3-004B)

DOI:10.3760/cma.j.cn321828-20251121-00424

肝癌是全球较为常见的恶性肿瘤之一,多数患者无法接受手术等根治性治疗。 ^{90}Y 微球选择性内放射治疗(^{90}Y -selective internal radiation therapy, ^{90}Y -SIRT)逐渐成为临床研究的热点^[1-2],但该技术高度依赖术前 $^{99}\text{Tc}^{\text{m}}$ -大颗粒聚合白蛋白(macroaggregated albumin, MAA) SPECT/CT 肝动脉灌注显像^[3]。在当前临床实践中, $^{99}\text{Tc}^{\text{m}}$ -MAA SPECT/CT 的单次采集时间通常在 30 min 以上^[4-5]。长时间的扫描可能造成患者的不适^[6],易引发身体移位,产生运动伪影,影响诊断准确性。减少投影数量可以缩短单个视野的采集时间,但会导致投影数据稀疏,增加重建图像的噪声^[5]。已有研究通过深度学习方法改善 ^{177}Lu 、 ^{111}In 的 SPECT 稀疏投影重建图像质量,或基于 DuDoSS 方法实现 $^{99}\text{Tc}^{\text{m}}$ -替曲膦(tetrofosmin) SPECT 心肌灌注显像稀疏投影的有效降噪^[7-9],但鲜见对 $^{99}\text{Tc}^{\text{m}}$ -MAA SPECT/CT 肝动脉灌注显像稀疏投影重建图像改善的研究。本研究探索深度学习技术在该领域中的应用价值与可行性。

资料与方法

1.研究对象。回顾性收集 2023 年 3 月至 2025 年

6 月天津市肿瘤医院空港医院因拟行 ^{90}Y -SIRT 而在核医学科行 $^{99}\text{Tc}^{\text{m}}$ -MAA SPECT/CT 肝动脉灌注显像的肝肿瘤患者 51 例[男 34 例,女 17 例,年龄 60(51,65)岁]开展横断面研究。纳入标准:(1)原发性肝癌或肝转移瘤;(2)肝肺分流比(lung shunt fraction, LSF) $<20\%$ 。排除标准:胃肠道有 $^{99}\text{Tc}^{\text{m}}$ -MAA 摄取。本研究符合《赫尔辛基宣言》的原则,经天津市肿瘤医院空港医院医学伦理委员会审批(批件号:LWK-2025-0024)。

2.图像采集及重建。使用配备低能高分辨准直器的美国 GE 公司 Discovery 670 Pro SPECT/CT 仪进行显像。经股动脉置微导管于肝内肿瘤供血动脉,经微导管缓慢推注 185 MBq $^{99}\text{Tc}^{\text{m}}$ -MAA 后 1 h 内采集图像。先行全身平面显像,矩阵 256×1024 ,检查床移动速度 20 cm/min。平面显像完成行 SPECT/CT 断层采集,范围包含肝脏、肺部,能窗 140($\pm 10\%$) keV,矩阵 128×128 ,采用双探头旋转采集方式,每 6° 采集 1 帧,每帧采集 30 s,旋转 180° ;CT 管电压 120 kV,管电流 100 mA,矩阵 512×512 ,扫描层厚 2.5 mm。对 SPECT/CT 图像进行重建和衰减校

正,重建算法为有序子集最大期望值迭代法,2次迭代,10个子集。将全部60个角度投影重建的图像(即全角度投影)记为A1。为了获得稀疏角度投影的数据,设计如下采样策略:将全部60个角度视为循环序列,每4个连续角度为1组(即1~4、5~8……),从第1组的4个角度中随机选取1个作为起始角度,之后在循环序列中等间隔选取后续角度,从而确保抽稀后的投影集在圆周方向上尽可能地均匀分布,以包含更全面的角度信息。通过该方法筛选得到15个投影角度,经顺序重组后生成的投影(即稀疏投影)重建图像记为A2,深度学习辅助稀疏投影重建生成的图像记为A3。

3.深度学习网络构建及模型训练。(1)深度学习网络架构。采用U-Net网络架构(图1),由编码器和解码器两部分对称构成。在编码器阶段,网络通过连续4个下采样模块逐步提取图像的深层特征,每个模块包含2个3×3卷积层(每层后接ReLU激活函数)和一个步长为2的2×2最大池化层。经过编码器的逐层提取后,数据会流经1个位于网络结构图最底部的瓶颈层,该层由2个3×3卷积层构成,负责对编码器提取的高级抽象特征进行深度融合与提炼。随后进入解码器阶段,该阶段由4个上采样模块组成,每个上采样模块首先通过1个2×2反卷积层进行上采样,并与编码器对应层输出的特征图进行拼接(即跳跃连接),再接入2个3×3卷积层,每个卷积层后均接ReLU激活函数。网络的最后为输出层,由1个1×1卷积层构成,将具有64个通

道的特征图映射为单通道的结果输出。

(2)图像预处理。计算图像的非零区域均值(nonzero_mean),通过公式 $\text{normalized_pixel} = \text{pixel} / \text{nonzero_mean}$ 来对图像像素值进行归一化,其中pixel为原始像素值,normalized_pixel为归一化后的图像像素值。为使SPECT图像尺寸与模型输入要求一致,必要时采用双线性插值法对SPECT图像进行重采样;若存在器官或病灶掩膜数据,则采用最近邻域插值法完成重采样,以保障掩膜边界的完整性与定位准确性。

(3)模型训练。使用数字XCAT体模(包含解剖结构的肝脏、肺部、躯干全模型)模拟 $^{99}\text{Tc}^m\text{-MAA}$ SPECT/CT显像的人体躯干图像。生成120例XCAT仿真图像,肝脏肿瘤灌注区放射性活度为150~185 MBq,肝脏正常灌注区放射性活度约为肿瘤灌注区摄取量的1/20~1/10,肺本底按照分流5%~20%计算,其余身体组织的本底放射性活度设定为0。能窗140 keV,像素尺寸4.41 mm×4.41 mm×4.41 mm。60个投影角度,间隔6°。每4个连续角度为1组,随机选取1个作为起始角度,经顺序重组后生成15个投影角度。准直器为低能高分辨准直器。引入Poisson噪声,并与临床数据计数水平保持一致的噪声水平。重建算法使用有序子集最大期望值迭代法,采用CT衰减校正,通过无滤波后处理保持定量精度。采用简单随机方法,将XCAT数据集按9:1分为训练集($n=108$)与验证集($n=12$)。模型训练总轮次(epoch)为100,优化器参数采用Adam,




图1 U-Net网络架构

学习率设定 10^{-4} 。选择平均绝对误差 (mean absolute error, MAE) 损失函数 (L1 loss) 进行训练, 每轮训练中, 模型对整个训练集进行迭代训练, 处理每一批次数据时, 计算训练集中基于深度学习模型重建的图像与对应的参考图像之间的 MAE (计算公式见下文), 并将 MAE 作为该批次的损失值进行反向传播, 以更新模型参数。每个训练轮次结束后, 将该轮所有批次的损失值取平均值并记录, 可得到该轮次训练集 MAE。另外, 在每个轮次训练后单独计算验证集经模型输出的图像与对应参考图像之间 MAE、结构相似性指数 (structural similarity index measure, SSIM)、峰值信噪比 (peak signal-to-noise ratio, PSNR), 具体计算方法见下文, 参考图像即 60 个角度投影的 XCAT 仿真图像。在所有训练结束后, 基于各轮次记录的训练集指标绘制训练集 MAE 曲线, 并同步绘制 MAE 移动平均曲线, 以平滑训练过程中的局部波动, 监测训练稳定性与拟合状态; 同时, 基于验证集指标绘制其 MAE、SSIM、PSNR 随训练轮次变化的曲线。

4. 患者图像质量分析。由 1 名医师通过 Xeleris 工作站 (美国 GE 公司) 在肿瘤灌注区域以 CT 图为参考手动勾画病灶感兴趣体积 (volume of interest, VOI)^[10], 测量并记录肿瘤灌注区计数最大值 ($\text{Counts}_{\max}$), 在肝脏的非肿瘤灌注区域选择摄取均匀的区域勾画直径为 1 cm 的球形 VOI, 获取计数标准差 ($\text{Counts}_{\text{SD}}$), 计算信噪比 (signal-to-noise ratio, SNR): $\text{SNR} = \text{Counts}_{\max} / \text{Counts}_{\text{SD}}$ 。视觉评分由 2 名具有 2 年以上工作经验的 SPECT/CT 阅片医师对 A1、A2、A3 投影图像进行盲法独立评估: 1 分为肿瘤灌注区域边界严重模糊, 内部细节缺失, 背景噪声明显且掩盖病灶信息, 显像剂分布不均匀, 无法满足临床诊断需求; 2 分为肿瘤灌注区域边界较清晰, 内部细节基本完整, 背景存在少量噪声但不影响核心病灶的识别, 显像剂分布欠均匀, 基本满足临床诊断需求; 3 分为肿瘤灌注区域边界锐利清晰, 内部细节完整, 背景存在极少量噪声, 显像剂分布基本均匀, 满足临床诊断及术前评估。

5. 图像体素水平定量分析。体素水平定量评估参数包括均方根误差 (root mean square error, RMSE)、MAE、PSNR 和 SSIM。RMSE 衡量图像与参考图像的体素级差异, 反映噪声和重建误差的平均水平, 其数值越低表示图像与参考图像的偏差越小。计算公式如下:

$$\text{RMSE} = \sqrt{\frac{1}{nml} \sum_x \sum_y \sum_z (\text{IM}(x, y, z) - \text{RI}(x, y, z))^2} \cdots \cdots (1)$$

其中, IM 代表生成图像, RI 代表参考图像, $\text{IM}(x, y, z)$ 、 $\text{RI}(x, y, z)$ 分别为生成图像、参考图像在 (x, y, z) 位置的体素值, n, m, l 为 SPECT 图像在 3 个维度方向的体素总数。MAE 衡量生成图像与参考图像的体素级绝对差异的平均值, 反映噪声和重建误差的整体分布水平, 其数值越低表示图像与参考图像的整体偏差越小。计算公式如下:

$$\text{MAE} = \frac{1}{nml} \sum_{x=1}^n \sum_{y=1}^m \sum_{z=1}^l |\text{IM}(x, y, z) - \text{RI}(x, y, z)| \cdots \cdots (2)$$

PSNR 结合图像动态范围评估噪声水平, PSNR 越高表示图像质量越好, 噪声对图像的影响越小。计算公式如下:

$$\text{PSNR} = 20 \log_{10} \left(\frac{\text{MAX}}{\text{RMSE}} \right) \cdots \cdots (3)$$

其中, MAX 代表图像中最大的体素。SSIM 从结构信息保留的角度评估图像相似性, 取值范围为 0~1, 越接近 1 表示图像的结构特征与参考图像越相似。计算公式如下:

$$\text{SSIM}(\text{IM}, \text{RI}) = \frac{(2\mu_{\text{IM}}\mu_{\text{RI}} + C_1)(2\sigma_{\text{IMRI}} + C_2)}{(\mu_{\text{IM}}^2 + \mu_{\text{RI}}^2 + C_1)(\sigma_{\text{IM}}^2 + \sigma_{\text{RI}}^2 + C_2)} \cdots \cdots (4)$$

其中, μ_{IM} 、 μ_{RI} 分别为生成图像、参考图像的均值, σ_{IM}^2 、 σ_{RI}^2 分别为参考图像、生成图像的方差, σ_{IMRI} 为生成图像与参考图像的协方差, C_1 、 C_2 为稳定的常数。

对于患者图像, 以 A1 作为参考图像, 按上述公式计算得到的 A2 与 A1 定量参数偏差记为 A_{2-1} , A3 与 A1 的定量参数偏差记为 A_{3-1} 。

6. 统计学分析。采用 IBM SPSS Statistics 26.0 软件进行统计学分析, 不符合正态分布的数据用 $M(Q_1, Q_3)$ 表示。采用 Kappa 检验分析 2 名医师评分的一致性。采用 Friedman 检验比较 2 位医师评分均值与 SNR 的组间差异, 进一步两两比较行 Bonferroni 校正。采用 Wilcoxon 符号秩检验比较定量参数组间差异。双侧检验 $P < 0.05$ (Bonferroni 校正 $P < 0.017$) 为差异或一致性有统计学意义。

结 果

1. 患者基线资料。51 例肝肿瘤患者中肝原发恶性肿瘤 35 例, 肝继发恶性肿瘤 16 例; 病灶位于肝右叶者 31 例, 肝左叶者 20 例, 病灶长径为 5.8 (3.2, 8.7) cm。

2. 深度学习模型训练结果。图 2 展示了 XCAT 仿真图像在模型训练与验证阶段 MAE、SSIM、PSNR 随迭代次数的变化情况。100 轮次里的最佳参数对应验证集评价价值如下: MAE、SSIM、PSNR 分别为 0.011、0.999、41.971 dB。

3. 患者图像质量评估。A1、A2、A3 的图像 SNR




图2 深度学习模型训练与验证阶段平均绝对误差(MAE)、结构相似性指数(SSIM)、峰值信噪比(PSNR)随迭代次数的变化曲线 120例 XCAT 体模仿真图像,按 9:1 划分为训练集($n=108$)与验证集($n=12$)

分别为 39.795(20.412, 61.894), 23.284(14.926, 40.047) 和 35.340(19.449, 51.908), 组间差异有统计学意义 ($F=79.33, P<0.001$); A1 组和 A3 组 SNR 高于 A2 (均 Bonferroni 校正 $P<0.001$), 且 A3 组与 A1 组的差异无统计学意义 (Bonferroni 校正 $P=0.277$)。2 名医师对 3 组投影图像的主观视觉评分一致性好 (κ 值: 0.94、0.96、0.94, 均 $P<0.001$); A1、A2、A3 组中评分均值大于 2 分的占比分别为 80.39% (41/51)、0 (0/51)、80.39% (41/51), 3 组图像的 2 名医师评分均值中位数分别为 3(3, 3)、1(1, 2)、3(3, 3) 分, 差异有统计学意义 ($F=91.46, P<0.001$), 进一步两两比较发现, A1 和 A2、A2 和 A3 的组间差异均有统计学意义 (均 Bonferroni 校正 $P<0.001$), A1 和 A3 的组间的差异无统计学意义 (Bonferroni 校正 $P>0.999$), 图 3 展示了 1 例患者的图像及其 SNR 和视觉评分。




图3 肝恶性肿瘤患者(男, 65 岁) $^{99}\text{Tc}^{\text{m}}$ -大颗粒聚合白蛋白(MAA)SPECT/CT 肝动脉灌注显像图 全角度投影图像(左列图)的信噪比(SNR)为 61.69, 视觉评分均值为 3 分; 稀疏投影图像(中列图)SNR 为 40.98, 视觉评分均值为 2 分; 深度学习辅助重建图像(右列图)SNR 为 64.90, 视觉评分均值为 3 分

4. 定量参数评估。RMSE、MAE、PSNR 和 SSIM 的 A_{2-1} 和 A_{3-1} 结果及组间比较见表 1, A_{2-1} 和 A_{3-1} 组各参数的差异均有统计学意义 (Z 值: $-5.45 \sim 5.89$, 均 $P<0.01$)。

讨 论

PET、SPECT 显像常受噪声、低分辨率的限制,

深度学习作为人工智能的核心技术, 通过优化图像质量、提升分析效率与诊断精度, 为疾病诊疗提供关键支撑^[11-12]。本研究将深度学习用于 $^{99}\text{Tc}^{\text{m}}$ -MAA SPECT/CT 肝动脉灌注图像, 通过对比分析 $^{99}\text{Tc}^{\text{m}}$ -MAA SPECT 全角度投影、稀疏投影及深度学习辅助稀疏投影重建的图像质量与定量参数差异, 发现深度学习可改善肝肿瘤患者 $^{99}\text{Tc}^{\text{m}}$ -MAA SPECT 稀疏投影重建图像的质量。

在图像质量评估部分, 本研究的医师主观评分和 SNR 一致; A1 和 A3 均优于 A2 (均 Bonferroni 校正 $P<0.001$), A1 和 A3 之间差异无统计学意义 (均 Bonferroni 校正 $P>0.017$)。这一结果表明, 单纯的稀疏投影会导致图像噪声增加, 显著降低图像的 SNR。视觉分析中相应表现为肿瘤灌注区细节缺失、背景噪声干扰明显, 可能影响器官轮廓的精准勾画, 不利于临床个性化剂量学分析。通过引入深度学习模型, 稀疏角度投影的图像噪声得到有效抑制, 其 SNR 恢复至与全角度投影相近的水平, 且视觉评分均值在 2 分以上的图像占比达 80.39% (41/51), 与 A1 组持平。这一结果从客观层面证实了深度学习在改善稀疏投影图像噪声方面的有效性, 能为 ^{90}Y -SIRT 提供可靠的影像基础。

在定量分析部分, 本研究对比了 A2 与 A1、A3 在 MAE、RMSE、PSNR 和 SSIM 方面的偏差量 (A_{2-1} , A_{3-1}), 结果显示所有评估指标的 A_{2-1} 与 A_{3-1} 值差异均有统计学意义 (Z 值: $-5.45 \sim 5.89$, 均 $P<0.01$)。与全角度投影相比, 单纯稀疏投影定量指标均显示劣势, 加入深度学习的辅助后, 图像在体素层面的偏差 (RMSE、MAE) 降低, 图像噪声影响 (PSNR) 和结构相似度 (SSIM) 改善, 提示深度学习辅助在大幅度缩短采集时间的同时, 实现了与全角度投影相近的图像质量。

减少 SPECT 采集的投影数量是缩短采集时间的有效方法^[13]。然而这一方式会因角度采样数量

表 1 51 例肝肿瘤患者⁹⁹Tc^m-MAA SPECT/CT 肝动脉灌注显像不同投影重建图像的定量参数偏差 [$M(Q_1, Q_3)$]

组别	RMSE	MAE	PSNR (dB)	SSIM
A ₂₋₁	4.557 (1.601, 8.103)	0.171 (0.080, 0.410)	55.446 (51.834, 57.760)	0.963 (0.946, 0.973)
A ₃₋₁	4.548 (1.600, 7.656)	0.163 (0.079, 0.379)	55.598 (51.860, 57.943)	0.967 (0.954, 0.980)
Z 值	-2.89	-5.45	3.59	5.89
P 值	0.004	<0.001	<0.001	<0.001

注:MAA 为大颗粒聚合白蛋白, RMSE 为均方根误差, MAE 为平均绝对误差, PSNR 为峰值信噪比, SSIM 为结构相似性指数; 全角度投影重建的图像记为 A1, 稀疏投影重建的图像记为 A2, 深度学习辅助稀疏投影重建的图像记为 A3, A2 与 A1 的定量参数偏差记为 A₂₋₁, A3 与 A1 的定量参数偏差记为 A₃₋₁

过少导致投影数据无法完整描述物体空间信息, 易在重建图像中产生沿特定方向延伸的条状伪影^[14-15]。SPECT 显像需通过多角度投影数据重建物体显像剂摄取分布。本研究针对 SPECT 图像特点, 对基础 U-Net 进行了改进, 添加深度监督, 在解码器的每个上采样块后添加辅助输出, 用于中间层监督, 并基于⁹⁹Tc^m-MAA 肝动脉灌注显像的特点采用残差学习(学习 60 个投影角度和 15 个投影图像的差异), 直接对稀疏投影导致的伪影与噪声结构进行学习去除, 尽可能地保持重建图像定量精度和计数水平。本研究在模型参数选择中选取了 MAE 作为损失函数(L1 loss), 其可促使去伪影预测结果在像素层面与目标高度逼近, 在具备伪影抑制能力的同时保证结果定量分析的准确性, 临床实际应用的结果中, 去伪影带来的降噪效果可适度平滑原始数据中的噪声, 具有较好的可接受性。Wikberg 等^[7] 和 Rydén 等^[8,16] 选择了 L2 做为损失函数, 同样取得理想的定量参数指标。这一差异提示, 损失函数的适配性需结合目标显像的技术特性与临床需求综合判断。此外, Wikberg 等^[7] 证实深度学习方法改善了稀疏投影的肾脏和骨髓吸收剂量的准确性, 本研究中针对肿瘤灌注区域吸收剂量的准确性是否有改善还需进一步研究确认。

既往研究通过合成中间投影以补全缺失投影数据, 并将其用于后续的图像重建, 结果均表明重建图像在噪声水平、定量指标显著优于稀疏投影的图像, 且能大幅缩短采集时间^[7-8,16]。Li 等^[17] 提出一种结合长短记忆网络(long short-term memory, LSTM) 与 U-Net 的深度学习网络, 将其用于合成稀疏投影正弦图, 实现了不同投影数据的 SPECT 重建。Liu 等^[18] 的研究在减少扫描时间的同时提升心肌灌注成像质量与定量准确性。上述研究在噪声抑制、定量精度提升及扫描时间缩短方面取得显著成效, 且在像素级别的定量参数结果与本研究一致, 但均未涉及⁹⁹Tc^m-MAA 肝动脉灌注显像这一场景, 而本研究在该领域进行了探索。

本研究存在一定局限性: 首先, 临床样本量相对有限, 后续需通过前瞻性、多中心研究进一步验证当前结论的可靠性; 其次, 模型训练数部分是通过 XCAT 体模模拟的⁹⁹Tc^m-MAA SPECT/CT 图像, 后续可增加真实临床的稀疏投影和全角度投影配对数据, 进一步优化模型的泛化能力, 增强其临床应用价值。另外, 基于深度学习模型对噪声的高效抑制能力, 可进一步探索将注射活度减少 4 倍的可行性, 通过降低放射性药物注射剂量, 大幅减少患者所受辐射暴露, 这一优化能突破传统成像技术在受照剂量上的限制。

综上, 本研究构建的 U-Net 深度学习模型可有效改善⁹⁹Tc^m-MAA SPECT/CT 稀疏投影的图像质量, 在保持单个投影角度采集时长不变的情况下, 有望将总采集时间缩短至原来的 1/4(由 60 个投影角度减少至 15 个投影角度)。这一技术不仅能提升患者舒适度、降低运动伪影风险, 还能优化⁹⁰Y-SIRT 术前评估的流程。

利益冲突 所有作者声明无利益冲突

作者贡献声明 隋国庆: 研究设计、论文撰写; 张宏钰、王子阳: 数据采集及模型构建、统计学分析; 王卫、郑明明、王亚亚: 数据重建及分析; 朱磊: 技术指导; 徐文贵: 数据分析与解释、论文审阅

参 考 文 献

- [1] 卓冠翔, 甘林河, 连锦锋, 等. 钇-90 微球选择性内放射治疗转移性肝癌的应用进展[J]. 中国临床医学, 2025, 32(1): 15-23. DOI: 10.12025/j.issn.1008-6358.2025.20241533.
Zhuo GX, Gan LH, Lian JF, et al. Application progress of Yttrium-90 microsphere selective internal radiation therapy on metastatic liver cancer[J]. Chin J Clin Med, 2025, 32(1): 15-23. DOI: 10.12025/j.issn.1008-6358.2025.20241533.
- [2] 钟方云, 于丽娟, 王玉君, 等. 多模态影像评估⁹⁰Y 微球选择性内放射治疗对肝恶性肿瘤的早期疗效[J]. 中华核医学与分子影像杂志, 2025, 45(6): 325-329. DOI: 10.3760/cma.j.cn321828-20240205-00055.
Zhong FY, Yu LJ, Wang YJ, et al. Multimodal imaging evaluation of the early efficacy of ⁹⁰Y microsphere selective internal radiation therapy for liver malignant tumors[J]. Chin J Nucl Med Mol Imaging, 2025, 45(6): 325-329. DOI: 10.3760/cma.j.cn321828-20240205-00055.

- [3] 何作祥.多学科合作推进 ^{90}Y 微球选择性内放射治疗的临床应用[J].中华核医学与分子影像杂志, 2025, 45(6): 321-324. DOI:10.3760/cma.j.cn321828-20250414-00108.
- He ZX. Multidisciplinary cooperation promotes the clinical application of ^{90}Y microsphere selective internal radiation therapy [J]. Chin J Nucl Med Mol Imaging, 2025, 45(6): 321-324. DOI:10.3760/cma.j.cn321828-20250414-00108.
- [4] van der Velden S, Dietze M, Viergever MA, et al. Fast technetium-99m liver SPECT for evaluation of the pretreatment procedure for radioembolization dosimetry [J]. Med Phys, 2019, 46(1): 345-355. DOI:10.1002/mp.13253.
- [5] Chiesa C, Sjogreen-Gleisner K, Walrand S, et al. EANM dosimetry committee series on standard operational procedures: a unified methodology for $^{99\text{m}}\text{Tc}$ -MAA pre- and ^{90}Y peri-therapy dosimetry in liver radioembolization with ^{90}Y microspheres [J]. EJNMMI Phys, 2021, 8(1): 77. DOI:10.1186/s40658-021-00394-3.
- [6] Nightingale JM, Murphy FJ, Blakeley C. 'I thought it was just an x-ray': a qualitative investigation of patient experiences in cardiac SPECT-CT imaging [J]. Nucl Med Commun, 2012, 33(3): 246-254. DOI:10.1097/MNM.0b013e32834f90c6.
- [7] Wikberg E, Essen MV, Rydén T, et al. Improvements of ^{177}Lu SPECT images from sparsely acquired projections by reconstruction with deep-learning-generated synthetic projections [J]. EJNMMI Phys, 2024, 11(1): 53. DOI:10.1186/s40658-024-00655-x.
- [8] Rydén T, Emma W, Van Essen M, et al. Improvements of ^{111}In SPECT images reconstructed with sparsely acquired projections by deep learning generated synthetic projections [J]. Radiat Prot Dosimetry, 2021, 195(3-4): 152-157. DOI:10.1093/rpd/ncab056.
- [9] Chen X, Zhou B, Xie H, et al. DuDoSS: deep-learning-based dual-domain sinogram synthesis from sparsely sampled projections of cardiac SPECT [J]. Med Phys, 2023, 50(1): 89-103. DOI:10.1002/mp.15958.
- [10] Riveira-Martin M, Akhavanallaf A, Mansouri Z, et al. Predictive value of $^{99\text{m}}\text{Tc}$ -MAA-based dosimetry in personalized ^{90}Y -SIRT planning for liver malignancies [J]. EJNMMI Res, 2023, 13(1): 63. DOI:10.1186/s13550-023-01011-3.
- [11] Zhang MX, Liu PF, Zhang MD, et al. Deep learning in nuclear medicine: from imaging to therapy [J]. Ann Nucl Med, 2025, 39(5): 424-440. DOI:10.1007/s12149-025-02031-w.
- [12] Apostolopoulos ID, Papandrianos NI, Feleki A, et al. Deep learning-enhanced nuclear medicine SPECT imaging applied to cardiac studies [J]. EJNMMI Phys, 2023, 10(1): 6. DOI:10.1186/s40658-022-00522-7.
- [13] Henzlova MJ, Duvall WL. The future of SPECT MPI: time and dose reduction [J]. J Nucl Cardiol, 2011, 18(4): 580-587. DOI:10.1007/s12350-011-9401-0.
- [14] Liu H, Wu J, Lu W, et al. Noise reduction with cross-tracer and cross-protocol deep transfer learning for low-dose PET [J]. Phys Med Biol, 2020, 65(18): 185006. DOI:10.1088/1361-6560/abae08.
- [15] Wolf PA, Jørgensen JS, Schmidt TG, et al. Few-view single photon emission computed tomography (SPECT) reconstruction based on a blurred piecewise constant object model [J]. Phys Med Biol, 2013, 58(16): 5629-5652. DOI:10.1088/0031-9155/58/16/5629.
- [16] Rydén T, Van Essen M, Marin I, et al. Deep-learning generation of synthetic intermediate projections improves ^{177}Lu SPECT images reconstructed with sparsely acquired projections [J]. J Nucl Med, 2021, 62(4): 528-535. DOI:10.2967/jnumed.120.245548.
- [17] Li S, Ye W, Li F. LU-Net: combining LSTM and U-Net for sinogram synthesis in sparse-view SPECT reconstruction [J]. Math Biosci Eng, 2022, 19(4): 4320-4340. DOI:10.3934/mbe.2022200.
- [18] Liu H, Zhang Y, Lyu Z, et al. Investigation of a deep learning-based reconstruction approach utilizing dual-view projection for myocardial perfusion SPECT imaging [J]. Am J Nucl Med Mol Imaging, 2025, 15(1): 15-27. DOI:10.62347/MLFB9278.

(收稿日期:2025-11-21)

· 读者 · 作者 · 编者 ·

关于投稿提供伦理委员会批准文件及受试对象知情同意书的通告

根据中华医学会杂志社的相关规定,当论文主体是以人为研究对象时,作者应说明研究方案是否获得所在单位或地区伦理审查委员会的批准,提供伦理批准文件并注明文件批号;应说明受试对象或其亲属是否签署知情同意书,并提供相应材料。当论文主体以动物为研究对象时,应说明研究方案是否遵循了单位和国家的有关实验动物管理和使用的规定,如获得实验动物福利伦理审查批准,应注明批准文号;如未进行实验动物福利伦理审查,应说明研究是否遵循了“3R”原则,即减少(Reduction)、替代(Replacement)、优化(Refinement)原则,对实验动物给予人道的保护。

本刊编辑部