

基于 CycleGAN 的图像质量优化快速骨显像的可行性研究

任冉¹ 杨皓然² 刘杜娟¹ 朱安军¹ 李薇³ 潘祥² 赵艳军³ 倪建明¹

¹无锡市第九人民医院医学影像科, 无锡 214062; ²江南大学人工智能与计算机学院, 无锡 214122; ³江南大学附属中心医院核医学科, 无锡 214002

任冉和杨皓然对本文有同等贡献

通信作者: 倪建明, Email: jianming_ni@163.com; 赵艳军, Email: 03zyj@163.com

【摘要】 **目的** 探讨利用基于循环一致生成对抗网络 (CycleGAN) 的深度学习模型 squeeze-and-excitation (SE)-LiteCycleGAN 从快速骨显像数据生成高质量全身显像图的可行性及其临床诊断价值。**方法** 前瞻性队列研究。纳入 2024 年 4 月至 2024 年 11 月期间于江南大学附属中心医院行骨显像的 93 例骨骼疾病患者 [男 42 例、女 51 例, 年龄 (59.8±12.6) 岁]。给予患者⁹⁹Tc^m-亚甲基二膦酸盐 (MDP) 注射 (740~925 MBq) 后, 分别以 15 cm/min (标准显像) 和 45 cm/min (快速显像) 的速度采集图像。另从医院影像存储与传输系统 (PACS) 中纳入 2023 年 7 月至 2024 年 4 月的 200 例患者 [男 125 例、女 75 例, 年龄 (67.3±11.5) 岁] 的标准显像图用于模型训练。采用无监督 SE-LiteCycleGAN 优化快速显像图像质量, 并与 UNet、残差通道注意力网络 (RCAN)、Swin Transformer 图像恢复 (SwinIR)、增强的深度学习超分辨率重建网络 (EDSR) 等有监督模型以及无监督模型 CycleGAN 进行对比。使用结构相似性指数 (SSIM)、峰值信噪比 (PSNR)、Fréchet 初始距离 (FID)、学习感知图像块相似度 (LPIPS) 和均方根误差 (RMSE) 评估图像质量, 数据组间比较行单因素方差分析; 由 2 名核医学科医师进行图像主观评分和诊断效能评估, 并采用组内相关系数 (ICC) 分析一致性。**结果** SE-LiteCycleGAN 组图像 SSIM、PSNR、LPIPS、RMSE 分别为 0.877±0.008、(33.345±0.488) dB、0.036±0.001 与 0.022±0.001, 均优于其他深度学习组 (F 值: 163.92、26.12、1 199.46 和 7.65, 均 $P<0.001$), FID 值也最佳 (9.874)。快速显像组、SE-LiteCycleGAN 组和标准显像组图像质量的主观评分分别为 (2.86±0.45)、(4.02±0.66)、(4.27±0.61) 分, 2 名医师的评分具有高度一致性 [ICC=0.904 (95% CI: 0.881~0.924), $P<0.001$], SE-LiteCycleGAN 组与标准显像组在诊断效能上也保持一致 [ICC=0.836 (95% CI: 0.786~0.874), $P<0.001$], 2 组图像中诊断结果不一致的仅有 4 例。**结论** SE-LiteCycleGAN 能显著提升快速骨显像的图像质量, 达临床诊断要求, 具有提升患者舒适度和设备效率的潜力。

【关键词】 骨疾病; 深度学习; 图像处理; 计算机辅助; 体层摄影术, 发射型计算机, 单光子; 体层摄影术, X 线计算机; 99m 锝美罗酸盐

基金项目: 无锡市“太湖人才计划”医疗卫生高层次人才项目; 无锡市卫生健康委员会科研项目 (Z202209)

DOI: 10.3760/cma.j.cn321828-20250103-00004

Feasibility study on optimizing image quality for fast bone scan based on CycleGAN

Ren Ran¹, Yang Haoran², Liu Dujuan¹, Zhu Anjun¹, Li Wei³, Pan Xiang², Zhao Yanjun³, Ni Jianming¹

¹Department of Radiology, Wuxi No.9 People's Hospital, Wuxi 214062, China; ²School of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi 214122, China; ³Department of Nuclear Medicine, Jiangnan University Medical Center, Wuxi 214002, China

Ren Ran and Yang Haoran contributed equally to this article

Corresponding authors: Ni Jianming, Email: jianming_ni@163.com; Zhao Yanjun, Email: 03zyj@163.com

【Abstract】 **Objective** To explore the feasibility and clinical diagnostic value of squeeze-and-excitation (SE)-Lite cycle-consistent generative adversarial network (CycleGAN)—a deep learning model based on CycleGAN, for generating high-quality whole-body bone scan images from rapid acquisition data. **Methods** This prospective cohort study included 93 patients with skeletal diseases (42 males, 51 females; age (59.8±12.6) years) who underwent bone scan at Jiangnan University Medical Center between April and November 2024. After intravenous injection of ⁹⁹Tc^m-methylene diphosphonate (MDP) (740–925 MBq), images were acquired at speeds of 15 cm/min (standard scan) and 45 cm/min (fast scan). Additionally, standard scan

images of 200 patients (125 males, 75 females; age (67.3 ± 11.5) years) between July 2023 and April 2024 were included from the hospital's picture archiving and communication system (PACS) for model training. The unsupervised SE-LiteCycleGAN was employed for image quality optimization and compared with supervised models including UNet, residual channel attention network (RCAN), image restoration using Swin Transformer (SwinIR), enhanced deep super-resolution network (EDSR) and the unsupervised model CycleGAN. Image quality was evaluated using structural similarity index (SSIM), peak signal-to-noise ratio (PSNR), Fréchet inception distance (FID), learned perceptual image patch similarity (LPIPS) and root mean square error (RMSE). One-way analysis of variance was used for intergroup comparisons. Subjective scoring and diagnostic efficacy assessments were conducted by 2 nuclear medicine physicians, with consistency analyzed by using the intraclass correlation coefficient (ICC). **Results** The SE-LiteCycleGAN group achieved superior SSIM (0.877 ± 0.008), PSNR ((33.345 ± 0.488) dB), LPIPS (0.036 ± 0.001), and RMSE (0.022 ± 0.001) than other deep learning groups (F values: 163.92, 26.12, 1 199.46, and 7.65, respectively; all $P < 0.001$), and obtained the best FID (9.874). Subjective image-quality scores from 2 physicians demonstrated high consistency across the rapid scan, SE-LiteCycleGAN, and standard scan groups (ICC = 0.904 (95% CI: 0.881–0.924), $P < 0.001$), with scores of 2.86 ± 0.45 , 4.02 ± 0.66 , and 4.27 ± 0.61 , respectively. Diagnostic agreement between the SE-LiteCycleGAN and standard scan groups was also high (ICC = 0.836 (95% CI: 0.786–0.874), $P < 0.001$), with only 4 cases showing discrepant diagnoses. **Conclusion** SE-LiteCycleGAN significantly improves fast bone scan image quality to meet clinical diagnosis, demonstrating the potential to enhance both patient comfort and equipment throughput.

【Key words】 Bone diseases; Deep learning; Image processing, computer-assisted; Tomography, emission-computed, single-photon; Tomography, X-ray computed; Technetium Tc 99m medronate

Fund program: Wuxi "Taihu Talent Plan" Medical and Health High-Level Talents Project; Scientific Research Project of Wuxi Health Commission (Z202209)

DOI: 10.3760/cma.j.cn321828-20250103-00004

全身骨显像(whole-body bone scan, WBS)是核医学诊断骨骼疾病尤其是骨转移的常用技术,对于高龄或癌痛患者而言,适当缩短 WBS 检查时间很有必要。近年来,深度学习技术已成功应用于低剂量 PET 和 SPECT 图像优化^[1-4],并正被用于降低放射性药物剂量的研究。其中,有监督学习模型依赖的大量快速和标准图像配对的数据在临床中获取较为困难^[5-8],而循环一致生成对抗网络(cycle-consistent generative adversarial network, CycleGAN)作为一种无监督图像转换方法,虽无需配对数据,但存在图像细节模糊、结构保真性差和模型参数量大等问题。为此,本研究提出一种融合注意力机制的轻量化变体 squeeze-and-excitation (SE)-LiteCycleGAN,旨在通过该模型从 3 倍快速骨显像中生成高质量的标准骨显像图,评估其临床诊断效能,并探讨基于 SE-LiteCycleGAN 优化快速骨显像图像质量的可行性。

资料与方法

1.患者资料。本研究通过江南大学附属中心医院伦理委员会的批准(批件号:2024Y-22)。采用前瞻性队列研究设计,对 2024 年 4 月至 2024 年 11 月期间于江南大学附属中心医院进行 WBS 的患者进行分析。纳入标准:年龄在 18 岁以上,有原发骨骼病史、需评估骨骼代谢情况,且能配合完成检查流程。排除标准:存在严重认知障碍、检查期间显著体位变化、存在检查禁忌证或图像质量无法达到诊断

要求者。共纳入 93 例患者,其中男 42 例、女 51 例,年龄(59.8 ± 12.6)岁;疾病诊断:肺癌 18 例,乳腺癌 38 例,前列腺癌 18 例,其他肿瘤 7 例,不明原因骨痛 12 例。本组骨显像进行 3 倍快速显像和标准显像一一配对,患者均签署知情同意书。

为提升模型泛化能力并构建可持续更新的高质量数据库,另从江南大学附属中心医院影像存储与传输系统(picture archiving and communication system, PACS)中回顾性收集 2023 年 7 月至 2024 年 4 月期间的 200 例未配对常规骨显像(仅含标准显像)患者,其中男 125 例、女 75 例,年龄(67.3 ± 11.5)岁;包括肺癌 30 例,乳腺癌 34 例,前列腺癌 63 例,其他肿瘤 34 例,以及不明原因骨痛 39 例。

2.图像采集。采用荷兰 Philips Precedence 16 SPECT/CT 仪,配备低能通用平行孔准直器,能峰 140 keV,窗宽 20%。给予患者静脉注射 740 ~ 925 MBq ^{99m}Tc-亚甲基二膦酸盐(methylene diphosphonate, MDP;上海欣科医药有限公司苏州分公司;标记率 > 95%)后 3 ~ 4 h 行前后位 WBS,显像前嘱患者尽可能排空膀胱。先行标准显像,后立即进行快速显像。标准显像和快速显像床速分别为 15 和 45 cm/min,扫描时间分别约为 15 和 5 min。

3.模型构建。(1)数据预处理。对原始图像进行剪裁,去除周围无信息的黑边,再通过平移和翻转处理生成新的图像样本,以增加数据多样性并降低模型过拟合风险。将所有处理后图像的像素统一调

整为 1 024×256, 确保输入模型前尺寸一致。

(2) 模型结构。本研究提出基于 CycleGAN 的改进模型 SE-LiteCycleGAN; 在生成器中引入 SE 模块, 提升对关键结构的关注能力, 简化网络结构以降低计算负担。模型由 2 个生成器和 2 个判别器 (PatchGAN) 组成 (图 1)。

(3) 损失函数选择。本研究结合对抗损失和循环一致性损失, 使模型能够在不同数据分布下生成高质量图像。对抗损失: 生成器不断改进生成策略, 增加生成图像的真实性。其公式为:

$$L_{adv} = E_{y \sim P_y} [\log D(y)] + E_{x \sim P_x} [\log(1 - D(G(x)))] \dots \dots (1)$$

其中, $D(y)$ 是判别器对真实图像的预测, $G(x)$ 是生成器生成的图像, P_y 和 P_x 分别为真实数据分布和潜在空间分布, E_y 和 E_x 分别为对应分布的期望。

循环一致性损失: 确保图像经生成器转换后保持基本特征, 减少不必要的变换。公式为:

$$L_{cyc} = E_{x \sim P_x} [\| F(G(x)) - x \|_1] + E_{y \sim P_y} [\| G(F(y)) - y \|_1] \dots \dots (2)$$

其中, F 和 G 分别为 2 个生成器, x 和 y 分别代表源

域 (快速骨显像) 和目标域 (标准骨显像) 的图像, P_y, P_x, E_y, E_x 的定义同公式 (1)。

(4) 模型训练。采用 5 折交叉验证方案训练模型。训练采用 Adam 优化器, 学习率设为 0.000 2, beta1 设为 0.5。训练环境配备 12 GB 显卡视频内存 (video random access memory, VRAM) 的 NVIDIA RTX 3060 图形处理器 (graphic processing unit, GPU), 批处理大小设为最大值 8。

4. 图像的客观定量分析。采用结构相似性指数 (structural similarity index, SSIM)、峰值信噪比 (peak signal-to-noise ratio, PSNR)、Fréchet 初始距离 (Fréchet inception distance, FID)、学习感知图像块相似度 (learned perceptual image patch similarity, LPIPS) 和均方根误差 (root mean square error, RMSE) 来评估生成骨显像与真实骨显像的结构相似性、信噪比、特征分布和细节还原能力差异^[9-10]。此外, 将 SE-LiteCycleGAN 与 4 种常见的有监督图像重建模型 [UNet、残差通道注意力网络 (residual channel attention network, RCAN)、Swin Transformer 图像恢复 (image

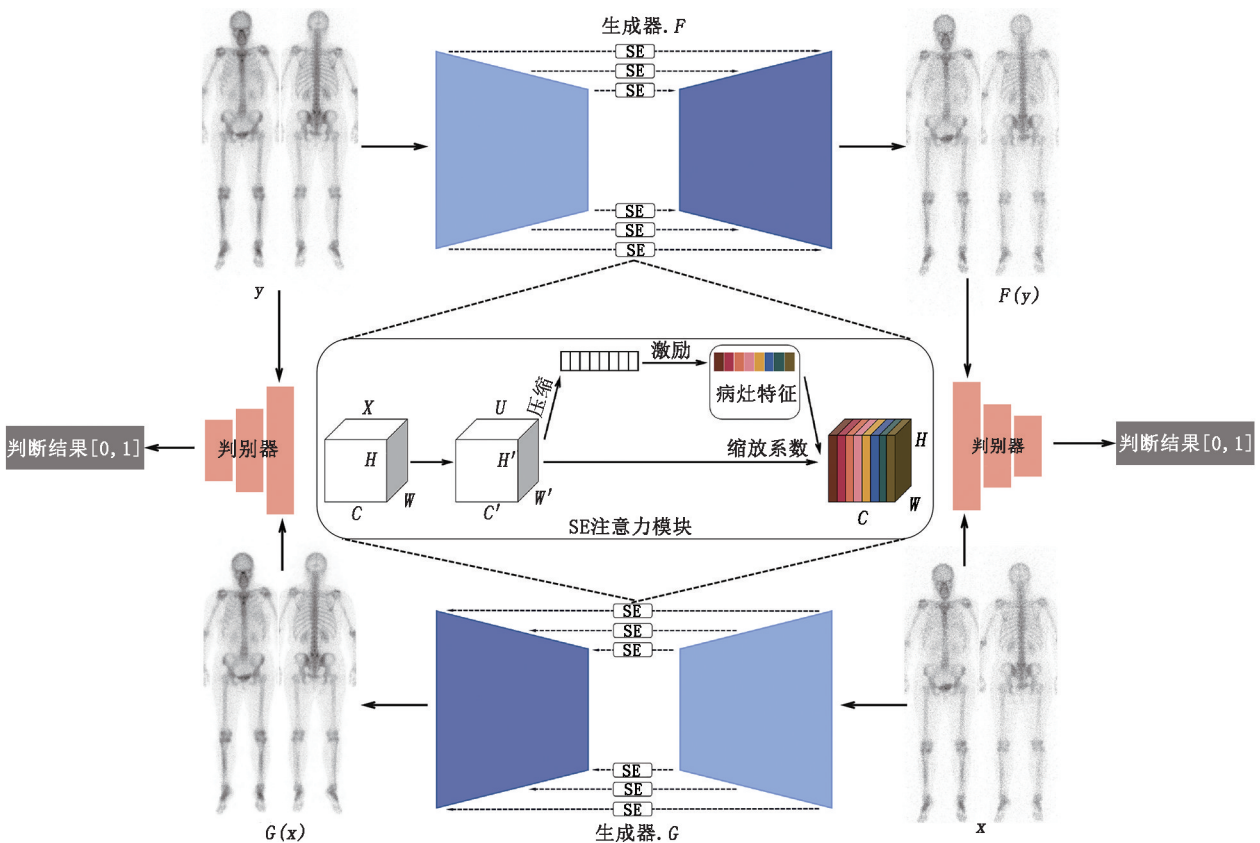


图 1 基于循环一致生成对抗网络 (CycleGAN) 的改进模型 [融合注意力机制的轻量化变体 squeeze-and-excitation (SE)-LiteCycleGAN] 结构示意图。基于 UNet 架构的生成器 (生成器 F 和 G) 同时集成 SE 注意力机制, 通过动态加权特征通道突出骨骼结构和病灶细节, 与基于 PatchGAN 的判别器分别实现快速骨显像 (x) 到标准骨显像 (y) 的转换及逆向映射, 评估局部真实性。图中立方体 X 为输入特征图, 其维度表示为 C, H, W [C 为输入特征图的通道数 (即卷积层输出的特征种类), H 为特征图的高度, W 表示特征图的宽度]; 特征图被映射为立方体 U , 其维度记为 C', H', W' , 即输出特征图的通道数、高度与宽度

restoration using Swin Transformer, SwinIR) 和增强的深度学习超分辨率重建网络 (enhanced deep super-resolution network, EDSR)] 以及基准无监督模型 CycleGAN 进行对比。

5. 图像视觉评估。2 名有 15 年以上经验的核医学科医师在接受统一培训后, 采用 5 分 Likert 量表对图像进行独立盲法评分: 1 分 (无法诊断)、2 分 (诊断信息有限)、3 分 (可接受)、4 分 (良好)、5 分 (优秀); 评分不一致时, 由 2 位医师协商确定最终评分^[11]。

6. 诊断效能评估。2 名有 15 年以上经验的核医学科医师在接受统一培训后对 SE-LiteCycleGAN 组与标准显像组进行独立盲法阅片, 评估诊断效能。具体诊断方法参照张一秋等^[12]的方法和分类标准, 诊断结果分为肿瘤骨转移、无肿瘤骨转移和不能确定。

7. 统计学处理。应用 IBM SPSS Statistics 27.0 软件进行数据分析, 符合正态分布的定量资料以 $\bar{x} \pm s$ 表示, 采用单因素方差分析进行组间比较, 若方差齐, 事后多重比较选择最小显著差异 *t* 检验, 方差不齐则选择 Tamhane 检验。用组内相关系数 (intraclass correlation coefficient, ICC) 评价 2 名医师的阅片评分和诊断结果的一致性。P<0.05 (双侧检验) 为差异或一致性有统计学意义。

结 果

1. SE-LiteCycleGAN 与其他深度学习模型的比较。SE-LiteCycleGAN 组图像的 SSIM、PSNR、RMSE 值优于其他深度学习组 (*F* 值: 163.92、26.12 和 7.65, 均 P<0.001; 表 1)。在 FID 和 LPIPS 指标方面, 以标准显像为基准 (FID=0, LPIPS=0), SE-LiteCycleGAN 获得了最好的 FID 和 LPIPS 值 (9.874 和 0.036±0.001),

优于快速显像组。RCAN 与 SwinIR 组分别在 FID 与 LPIPS 方面得分最高, 表现较差, EDSR 次之。UNet 虽优于快速显像组, 但其 FID 值仍较高, 表明其在细节还原和感知质量方面存在不足。CycleGAN 组 SSIM、PSNR 各定量指标仅次于 SE-LiteCycleGAN 组, 这表明无监督模型在快速骨显像图像还原中具有较大优势, 且基于 CycleGAN 改进的 SE-LiteCycleGAN 模型在整体特征分布和局部细节相似性上均表现出更优越的性能。

典型病例图像见图 2。与标准骨显像相比, 快速骨显像的噪声明显增加, 许多细节难以辨识。UNet、RCAN、SwinIR、EDSR (有监督方法) 及 CycleGAN、SE-LiteCycleGAN (无监督方法) 均能抑制图像噪声, 提供更多的骨骼细节。相比于有监督模型易导致的图像过度平滑、CycleGAN 模型对图像结构细节的丢失, SE-LiteCycleGAN 生成的图像更适合诊断。

2. 图像质量的主观评估。在快速显像组、SE-LiteCycleGAN 组和标准显像组中, 2 名医师的图像评分具有高度一致性 [ICC = 0.904 (95% CI: 0.881 ~ 0.924), P<0.001]。快速显像组最终评分为 (2.86±0.45) 分; SE-LiteCycleGAN 组为 (4.02±0.66) 分, 视觉评分 ≥4 分者 75 例; 标准显像组为 (4.27±0.61) 分, 视觉评分 ≥4 分者 83 例。

3. 诊断效能评估。在 SE-LiteCycleGAN 组和标准显像组中, 2 名医师的图像质量评分具有高度一致性 [ICC = 0.868 (95% CI: 0.828 ~ 0.900), P<0.001], 诊断效能同样具有高度一致性 [ICC = 0.836 (95% CI: 0.786 ~ 0.874), P<0.001]。2 组图像中诊断结果不一致的有 4 例。

讨 论

快速显像因能显著缩短检查时间而受到关注^[13-14],

表 1 快速显像组及不同深度学习方法重建后各组间客观定量指标比较 (n = 93)

组别	SSIM ($\bar{x} \pm s$)	PSNR (dB; $\bar{x} \pm s$)	LPIPS ($\bar{x} \pm s$)	RMSE ($\bar{x} \pm s$)	FID
快速显像组	0.711±0.013	29.610±0.496	0.151±0.003	0.026±0.001	11.412
UNet 组	0.775±0.008	32.070±0.408	0.091±0.002	0.026±0.001	14.131
RCAN 组	0.803±0.010	32.465±0.433	0.101±0.002	0.027±0.001	16.513
SwinIR 组	0.703±0.010	32.360±0.415	0.145±0.002	0.025±0.001	15.685
EDSR 组	0.715±0.009	31.423±0.433	0.134±0.002	0.025±0.001	14.564
CycleGAN 组	0.808±0.011	31.714±0.446	0.093±0.002	0.026±0.001	11.568
SE-LiteCycleGAN 组	0.877±0.008	33.345±0.488	0.036±0.001	0.022±0.001	9.874
<i>F</i> 值	163.92	26.12	1 199.46	7.65	-
<i>P</i> 值	<0.001	<0.001	<0.001	<0.001	-

注: RCAN 为残差通道注意力网络, SwinIR 为 Swin Transformer 图像恢复, EDSR 为增强的深度学习超分辨率重建网络, CycleGAN 为循环一致生成对抗网络, SE-LiteCycleGAN 为融合注意力机制的轻量化变体 squeeze-and-excitation (SE)-LiteCycleGAN, SSIM 为结构相似性指数, PSNR 为峰值信噪比, LPIPS 为学习感知图像块相似度, RMSE 为均方根误差, FID 为 Fréchet 初始距离; 各指标数据均为与标准显像组对比计算得到; 其他深度学习组与 SE-LiteCycleGAN 组两两比较, 均 P<0.001; - 表示无数据 (FID 是对整体的定量评估, 为均值, 无 *F*、*P* 值)




图 2 前列腺癌骨转移患者(男,61岁)快速显像及不同深度学习方法处理的快速显像图和标准显像图质量对比(上排为前位图,下排为后位图) A.快速显像的图像信噪比低,噪声多,骨结构轮廓不清晰,精确定位困难;B. UNet 生成的图像上噪声有所抑制,但图像过度平滑,骨结构边缘模糊,且在小腿、大腿内侧软组织区及膀胱周围出现无背景空白区(箭头示);C.残差通道注意力网络(RCAN)生成的图像上出现显著的条纹状伪影;D,E. Swin Transformer 图像恢复(SwinIR;D)和增强的深度学习超分辨率重建网络(EDSR;E)生成的图像细节保留有所提升,但整体对比度不足;F.循环一致生成对抗网络(CycleGAN)生成的图像整体透亮度较高,对软组织结构区显示欠清;G.融合注意力机制的轻量化变体 squeeze-and-excitation(SE)-LiteCycleGAN 生成的图像噪声显著减少,骨结构和病灶细节清晰可见,与标准显像图高度相似,但其在膀胱内也引入了小点状计数缺失(箭头示);H.标准显像图

但其图像质量下降导致临床应用受限。本研究开发的 SE-LiteCycleGAN 模型通过无监督深度学习提升了 3 倍快速骨显像的图像质量,该模型不仅能有效减少噪声、增强细节,还具备提高患者舒适度和设备使用效率的潜力,为核医学影像优化提供了新方案。

既往研究多采用模拟低质量数据或依赖精确配对数据进行有监督学习。例如, Ito 等^[5]和 Murata 等^[6]的方法依赖于模拟数据集(通过向标准显像图中添加噪声来模拟快速显像图),忽略了临床实际中患者运动和计数水平不一致等真实变异; Ichikawa

等^[7]通过多帧拼接模拟快速显像并恢复全时采集图像,但消除不同帧之间的错位并不容易; Pan 等^[8]虽使用了临床配对数据,但其有监督框架难以克服快速与标准显像间固有的体位变化和伪影导致的配准问题。与这些方法不同,本研究提出的 SE-LiteCycleGAN 基于 CycleGAN 的无监督框架,无需配对数据即可适应复杂的临床场景。SE 注意力机制通过学习通道间的依赖关系,对特征通道进行加权,从而突出重要特征、抑制次要特征,进一步增强了骨结构和病灶细节的重建能力,避免了 UNet 等传统编码-解码网

络常导致的图像过度平滑问题。此外,本研究通过减少每层卷积核的数量降低了模型参数量,轻量化设计降低了计算复杂度,适用于设备性能有限的核医学环境。本研究结果显示了 SE-LiteCycleGAN 在处理真实临床情景中的优势。

SE-LiteCycleGAN 在优化快速骨显像图方面具有潜力。本研究进行了 SE-LiteCycleGAN 与有监督模型 (UNet、RCAN、SwinIR、EDSR) 及无监督模型 CycleGAN 的对比,结果显示 SE-LiteCycleGAN 组图像的 SSIM、PSNR、RMSE 值优于其他深度学习组,表明在与标准显像图像的相似性和重建质量上,SE-LiteCycleGAN 组最佳,且细节保留更接近标准显像图像。同时,SE-LiteCycleGAN 获得了最好的 FID 和 LPIPS 值(9.874 和 0.036±0.001)。各学习模型均能抑制快速骨显像的噪声,提供更多的骨骼细节,且 SE-LiteCycleGAN 模型在整体特征分布和局部细节相似性上均展现出更优越的性能,生成的图像更适合诊断。UNet 生成的前位图像在膀胱周围出现明显的晕状空白区,小腿和大腿软组织区域也呈现无背景空白,这可能由于其编码-解码结构倾向于过度平滑,特别是在高信号膀胱与低信号软组织的高对比度过渡区域,模型可能将低计数信号误判为噪声而予以抑制^[15]。EDSR 图像中膀胱周围的晕状伪影较轻,但仍提示超分辨率方法在重建高-低信号边界时细节保留不足^[16],且缺乏全局纹理约束。RCAN 生成的图像显示条纹状伪影,这可能与其通道注意力机制和多残差块结构有关,该结构在处理快速扫描的非均匀噪声时可能引入局部过拟合,导致条纹状异常^[17]。相比之下,SE-LiteCycleGAN 通过对抗训练和 SE 模块有效避免了这些伪影。然而,SE-LiteCycleGAN 生成图像中膀胱内出现的小点状无信号区,可能为模型重建高强度区域时产生的技术性伪影,提示其在处理均匀高信号区域时存在局限,未来需进一步优化。

本研究为将 SE-LiteCycleGAN 技术拓展至更复杂的影像模态提供了依据。SPECT/CT 显像可提升平面 WBS 的特异性和定位精度,但耗时较长。近期研究,如 Pan 等^[18] 和 Qi 等^[19] 的工作表明深度学习可有效缩短 SPECT 采集时间,但这些方法仍依赖配对数据进行有监督学习。本研究 SE-LiteCycleGAN 在快速 WBS 上展现的优势可扩展到快速 SPECT/CT 显像的优化,其无监督框架结合对抗训练和 SE 注意力机制能更好地保留骨结构细节和病灶特征,可能适用于快速 SPECT 的三维重建。

本研究尚有不足之处:(1)本研究为单中心研究,样本量相对有限,未来需通过多中心大样本研究,验证模型的通用性;(2)图像质量的主观评估依赖医师经验,可能存在一定偏倚;(3)未评估模型对不同病灶类型(大小、位置、摄取强度)的鲁棒性,可能限制其在复杂病例中的表现。

综上所述,本研究基于 CycleGAN 开发了 SE-LiteCycleGAN 模型,成功从 3 倍速骨显像中生成接近标准骨显像的高质量图像,具有提升患者舒适度和设备效率的潜力。未来需通过多中心验证和不同设备测试,推动该技术在核医学工作中的应用。

利益冲突 所有作者声明无利益冲突

作者贡献声明 任冉、杨皓然:研究实施、统计学分析、论文撰写;刘杜娟、朱安军、李薇、潘祥:研究实施、数据分析;赵艳军、倪建明:研究指导、论文修改、经费支持

参 考 文 献

- [1] Arabi H, Zaidi H. Applications of artificial intelligence and deep learning in molecular imaging and radiotherapy [J]. Eur J Hybrid Imaging, 2020, 4(1): 17. DOI:10.1186/s41824-020-00086-8.
- [2] Balaji V, Song TA, Malekzadeh M, et al. Artificial intelligence for PET and SPECT image enhancement [J]. J Nucl Med, 2024, 65(1): 4-12. DOI:10.2967/jnumed.122.265000.
- [3] Hellwig D, Hellwig NC, Boehner S, et al. Artificial intelligence and deep learning for advancing PET image reconstruction: state-of-the-art and future directions [J]. Nuklearmedizin, 2023, 62(6): 334-342. DOI:10.1055/a-2198-0358.
- [4] 冯莉娟, 马欢, 鲁霞, 等. 基于生成对抗网络改善儿童低剂量 PET 图像质量的研究 [J]. 中华核医学与分子影像杂志, 2022, 42(12): 708-712. DOI: 10.3760/cma.j.cn321828-20220705-00212.
Feng LJ, Ma H, Lu X, et al. Study on improving the quality of low-dose PET images of children based on generative adversarial networks [J]. Chin J Nucl Med Mol Imaging, 2022, 42(12): 708-712. DOI:10.3760/cma.j.cn321828-20220705-00212.
- [5] Ito T, Maeno T, Tsuchikame H, et al. Adapting a low-count acquisition of the bone scintigraphy using deep denoising super-resolution convolutional neural network [J]. Phys Med, 2022, 100: 18-25. DOI:10.1016/j.ejmp.2022.06.006.
- [6] Murata T, Hashimoto T, Onoguchi M, et al. Verification of image quality improvement of low-count bone scintigraphy using deep learning [J]. Radiol Phys Technol, 2024, 17(1): 269-279. DOI: 10.1007/s12194-023-00776-5.
- [7] Ichikawa S, Sugimori H, Ichijiri K, et al. Acquisition time reduction in pediatric ^{99m}Tc-DMSA planar imaging using deep learning [J]. J Appl Clin Med Phys, 2023, 24(6): e13978. DOI: 10.1002/acm2.13978.
- [8] Pan Z, Qi N, Meng Q, et al. Fast SPECT/CT planar bone imaging enabled by deep learning enhancement [J]. Med Phys, 2024, 51(8): 5414-5426. DOI:10.1002/mp.17094.
- [9] Skandarani Y, Jodoin PM, Lalonde A. GANs for medical image synthesis: an empirical study [J]. J Imaging, 2023, 9(3): 69. DOI:10.3390/jimaging9030069.

- [10] Segal B, Rubin DM, Rubin G, et al. Evaluating the clinical realism of synthetic chest X-rays generated using progressively growing GANs[J]. SN Comput Sci, 2021, 2(4): 321. DOI:10.1007/s42979-021-00720-7.
- [11] Thibault F, Bailly M, Le Rouzig G, et al. Clinical evaluation of General Electric new Swiftscan solution in bone scintigraphy on NaI-camera: a head to head comparison with Siemens Symbia[J]. PLoS One, 2019, 14(9): e0222490. DOI:10.1371/journal.pone.0222490.
- [12] 张一秋, 石洪成, 顾宇参, 等. SPECT/CT 骨显像对肺癌骨转移诊断的增益价值[J]. 中华核医学杂志, 2011, 31(4): 219-222. DOI:10.3760/cma.j.issn.0253-9780.2011.04.002.
Zhang YQ, Shi HC, Gu YS, et al. The added diagnostic value of SPECT/CT imaging for bone metastases from lung cancer[J]. Chin J Nucl Med, 2011, 31(4): 219-222. DOI:10.3760/cma.j.issn.0253-9780.2011.04.002.
- [13] 胡琳君, 胡奕奕, 郭彬威, 等. 深度学习重建方法改善快速采集 PET 图像质量的临床研究[J]. 中华核医学与分子影像杂志, 2021, 41(10): 602-606. DOI: 10.3760/cma.j.cn321828-20210514-00164.
Hu LJ, Hu YY, Guo BW, et al. Clinical study of deep learning reconstruction to improve the quality of rapidly acquired PET images [J]. Chin J Nucl Med Mol Imaging, 2021, 41(10): 602-606. DOI:10.3760/cma.j.cn321828-20210514-00164.
- [14] 杨润君, 陈雪琪, 余浩军, 等. 全身 PET/CT 1 min 采集图像与常规 PET/CT 图像质量比较; 自身对照研究[J]. 中华核医学与分子影像杂志, 2024, 44(1): 12-15. DOI: 10.3760/cma.j.cn321828-20221027-00322.
Yang RJ, Chen XQ, Yu HJ, et al. Comparison of the image quality between total-body PET/CT with 1 min acquisition and conventional PET/CT: a self-control study[J]. Chin J Nucl Med Mol Imaging, 2024, 44(1): 12-15. DOI: 10.3760/cma.j.cn321828-20221027-00322.
- [15] Zunair H, Ben Hamza A. Sharp U-Net: depthwise convolutional network for biomedical image segmentation[J]. Comput Biol Med, 2021, 136: 104699. DOI:10.1016/j.compbiomed.2021.104699.
- [16] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution [C]//2017 IEEE conference on computer vision and pattern recognition workshops (CVPRW), Honolulu: IEEE, 2017; 1132-1140. DOI:10.1109/CVPRW.2017.151.
- [17] Zhang Y, Li K, Li K, et al. Image super-resolution using very deep residual channel attention networks [C]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer Vision-ECCV 2018. ECCV 2018. Lecture notes in computer science, vol 11211. Cham: Springer, 2018; 294-310. DOI:10.1007/978-3-030-01234-2_18.
- [18] Pan B, Qi N, Meng Q, et al. Ultra high speed SPECT bone imaging enabled by a deep learning enhancement method: a proof of concept [J]. EJNMMI Phys, 2022, 9(1): 43. DOI: 10.1186/s40658-022-00472-0.
- [19] Qi N, Pan B, Meng Q, et al. Deep learning enhanced ultra-fast SPECT/CT bone scan in patients with suspected malignancy: quantitative assessment and clinical performance [J]. Phys Med Biol, 2023, 68(13): 135012. DOI:10.1088/1361-6560/acddc6.
(收稿日期:2025-01-03)

· 读者 · 作者 · 编者 ·

2026 年本刊可直接用缩写的常用词汇

ATP(adenosine-triphosphate), 三磷酸腺苷
 AUC(area under curve), 曲线下面积
 CI(confidence interval), 可信区间
 CT(computed tomography), 计算机体层摄影术
 CV(coefficient of variation), 变异系数
 DNA(deoxyribonucleic acid), 脱氧核糖核酸
 FDG(fluorodeoxyglucose), 脱氧葡萄糖
 HAV(hepatitis A virus), 甲型肝炎病毒
 Hb(hemoglobin), 血红蛋白
 HBsAg(hepatitis B surface antigen), 乙型肝炎表面抗原
 HBV(hepatitis B virus), 乙型肝炎病毒
 HCV(hepatitis C virus), 丙型肝炎病毒
 MRI(magnetic resonance imaging), 磁共振成像
 PBS(phosphate buffered solution), 磷酸盐缓冲液

PCR(polymerase chain reaction), 聚合酶链反应
 PET(positron emission tomography), 正电子发射体层摄影术
 PLT(platelet count), 血小板计数
 RBC(red blood cells), 红细胞
 RNA(ribonucleic acid), 核糖核酸
 ROC(receiver operating characteristic), 受试者工作特征
 ROI(region of interest), 感兴趣区
 SPECT(single photon emission computed tomography), 单光子发射计算机体层摄影术
 SUV(standardized uptake value), 标准摄取值
 SUV_{max} (maximum standardized uptake value), 最大标准摄取值
 SUV_{mean} (mean standardized uptake value), 平均标准摄取值
 WBC(white blood cells), 白细胞
 WHO(World Health Organization), 世界卫生组织

本刊编辑部