

基于深度学习技术的 PET 图像处理研究进展

王坤 袁增贝 赵军

同济大学附属东方医院核医学科, 上海 200120

通信作者: 赵军, Email: petcenter@126.com

【摘要】 PET 作为一种显像手段, 在神经系统和肿瘤等疾病的诊断中具有重要应用价值。人工智能(AI)已被应用于医学影像领域, 其中以卷积神经网络(CNN)和生成对抗网络(GAN)等为代表的深度学习(DL)技术已被广泛用于医学图像处理。该文综述了 DL 应用于 PET 图像处理的研究, 主要包括图像增强、图像重建、图像衰减校正、图像转换与合成等方面的最新进展, 以期为基于 DL 技术的 PET 图像处理研究提供参考。

【关键词】 深度学习; 图像处理, 计算机辅助; 正电子发射断层显像术; 发展趋势

基金项目: 上海市浦东新区卫生系统重点学科建设项目(PWZxk2022-12)

DOI: 10.3760/cma.j.cn321828-20250509-00139

Research progress of PET image processing based on deep learning technology

Wang Kun, Yuan Zengbei, Zhao Jun

Department of Nuclear Medicine, Shanghai East Hospital, Tongji University School of Medicine, Shanghai 200120, China

Corresponding author: Zhao Jun, Email: petcenter@126.com

【Abstract】 PET, as an imaging modality, holds significant value in the diagnosis of neurological and oncological diseases. Artificial intelligence (AI) has been widely applied in the field of medical image. Among these, deep learning (DL) techniques, including convolutional neural network (CNN) and generative adversarial network (GAN), have been extensively utilized in medical image processing. This review examines the latest advancements in the application of DL to PET image processing, focusing on key areas such as image enhancement, image reconstruction, attenuation correction, and image conversion and synthesis. This review aims to provide a reference for future research on PET image processing based on DL technologies.

【Key words】 Deep learning; Image processing, computer-assisted; Positron-emission tomography; Trends

Fund program: Key Discipline Construction Project of Shanghai Pudong New Area health Commission (PWZxk2022-12)

DOI: 10.3760/cma.j.cn321828-20250509-00139

人工智能(artificial intelligence, AI)已成为实现类人识别能力的强大工具^[1-3], 尤其是在医学影像诊断中的应用^[4-5]。AI 模型辅助图像处理, 在提高微小病灶检出率、降低 SUV 计算误差、量化特定生物标志物信息等方面效果显著, 有望减轻临床医师工作负担。

PET 显像利用同位素示踪剂表征人体代谢信息, 但常受到采集条件、显像设备、患者配合度等客观因素的影响, 导致 PET 图像噪声、分辨率受限、SUV 计算误差、图像重建复杂等问题, AI 为提高图像质量以及优化扫描与重建过程提供了新的思路。深度学习(deep learning, DL)是 AI 领域的一个代表性分支, 卷积神经网络(convolutional neural network, CNN)、生成对抗网络(generative adversarial network, GAN)为代表的 DL 技术在图像分割、分类、增强和重建中得以广泛应用。DL 独特优势在于其端到端的学习能力, 可以直接从原始数据中学习复杂的映射关系, 而无需人工设计特征^[6]。这种特性使得 DL 在解决 PET 图像处理中的图像质量提升、定量分析误差校正等问题时具有显著效果^[7]。同时, DL 模型还可以结合多模态数据(如 PET/MR、PET/CT), 通过跨模态

特征提取与融合进一步提高诊断准确性。

本文综述以 DL 技术为代表的 AI 在 PET 图像处理中的应用, 探讨 DL 在从图像增强、图像重建、衰减校正与图像转换与合成等方面的最新进展, 并对 DL 在 PET 显像应用中面临的问题及发展方向进行讨论并总结(表 1)。

一、图像增强

1. 提高图像质量。图像增强技术作为 PET 图像处理中的重要内容之一, 旨在通过调整图像的对比度、亮度、锐度等参数来提高图像的视觉质量和信息量, 以及降低图像噪声、提高分辨率、减少伪影等措施来优化对于目标区域的显示。随着 AI 技术的发展, 基于 DL 的图像增强技术也逐渐成为研究热点。DL 模型可以通过端到端训练学习 PET 显像过程中的噪声特征与结构先验信息, 提高图像信噪比与分辨率, 减少伪影。Cui 等^[8]采用深度图像先验(deep image prior, DIP)成功提高了¹⁸F-FDG PET/MR 图像对比度-噪声比(contrast to noise ratio, CNR), 改善率达到(46.80±25.23)%, 显著优于对照组中的高斯变换、深度解码器等方法。Gong 等^[9]使用基于患者的特定先验信息和测量数据的模型循环惩罚

表 1 PET 图像处理中的深度学习(DL)技术

应用领域	应用场景	主要方法	应用价值	定量指标
图像增强	提高图像质量	U-Net, DIP	通过学习 PET 显像过程中的噪声特征与结构先验信息, 提供更丰富的重建图像信息 ^[8-11]	SSIM, PSNR, CNR
	低剂量图像恢复	U-Net, GAN	基于 CNN ^[12-16] 、GAN ^[17-19] 通过从低质量图像中恢复标准质量图像	SSIM, PSNR, NRMSE
图像重建	直接重建	GAN	直接从正弦图域数据生成 PET 图像, 不增加硬件成本前提下提高图像质量 ^[20-24]	SSIM, SNR
	正则化重建	CNN, GAN	在重建框架中嵌入 DL 模型, 利用先验知识优化模型, 提升图像 PSNR 和 SSIM ^[11, 25-28]	PSNR, SSIM, MSE
图像衰减校正	无 CT 下衰减校正	CNN	训练模型从为衰减校正 PET 生成校正后 PET, 不依赖 CT 图像 ^[29-32]	SSIM, PSNR
	MR 信息下衰减校正	U-Net, Cycle-GAN	基于 MR 信息预测 PET 衰减系数, 解决 MR 信息难以用于衰减校正问题 ^[33-35]	RMSE
图像转换与合成	不同模态间转换	CNN, GAN	实现 PET、MR、CT 等模态间的图像转换 ^[36-41]	SSIM, ICC

注: DIP 为深度图像先验, GAN 为生成对抗网络, CNN 为卷积神经网络, PSNR 为峰值信噪比, SSIM 为结构相似性指数, CNR 为对比度-噪声比, NRMSE 为归一化均方根误差, SNR 为信噪比, MSE 为均方误差, RMSE 为均方根误差, ICC 为组内相关系数

重建方法, 相较于高斯平滑和解剖学引导等重建方法, 该模型实现了更高的图像对比度。Hashimoto 等^[10] 设计基于 DIP 的 PET 图像重建方法, 结果表明该方法获得的图像 CNR 为 11.7。Liu 等^[11] 提出基于先验信息引导的重建网络 (prior information-guided reconstruction network, PIGRN) 模型, 结合原始数据与先验图像, 获得了更高质量的全身 PET 图像, 峰值信噪比 (peak signal-to-noise ratio, PSNR) 与结构相似性指数 (structural similarity index, SSIM) 分别达到 31.849 8 dB 和 0.975 4。

2. 低剂量图像恢复。核医学检查过程中, 为尽量减少患者辐射暴露, 应尽可能保持较低的注射剂量。然而, 减少注射剂量会增加 PET 采集数据的噪声, 并降低图像质量。DL 为解决这一问题提供了新的思路, CNN、GAN 等经典 DL 模型已被应用于低质量图像到高质量图像的重建与恢复^[42-43]。研究人员使用 U-Net^[44-45] 和 GAN^[46-47] 从低剂量扫描获得的图像中恢复标准剂量 CT 扫描获得的图像, 验证了基于 DL 模型实现低剂量与快速扫描下的高质量 PET 图像重建的可行性。但不同模型自身结构、输入数据模态、训练策略均存在一定差异, 以下从典型研究中梳理各类模型的应用特点与重建性能。

通过多层卷积和池化操作, CNN 可以有效学习到图像的特征表示, 并实现对低剂量图像的准确恢复。Spuhler 等^[12] 构建膨胀卷积下的 CNN 模型, 实现 10% 剂量的 PET 图像恢复, 恢复图像的绝对百分比误差为 4.99 ± 0.68 , PSNR 为 (31.55 ± 1.31) dB, SSIM 为 0.9513 ± 0.0154 。Pan 等^[13] 提出 PET U-Net 模型, 实现 25% 剂量下全剂量 PET 图像重建, 获得 SSIM 为 0.975, PSNR 为 35.851 dB。Chaudhari 等^[14] 研究了基于低剂量 (25%) 全身 PET 扫描的 DL 模型, 经多中心验证, 该方法生成的图像对患者病灶检测灵敏度为 0.94, 特异度为 0.98, 与标准扫描效果相当。Liu 等^[15] 使用三维 U-Net 模型结合迁移学习策略, 实现 10% 剂量下的 PET 图像恢复, 并获得信噪比 (signal-to-noise ratio, SNR) 为 4.2, 归一化均方根误差 (normalized root mean square error, NRMSE) 为 96.3%。Ciborowski 等^[16] 研究了基于 SubtlePET 算法的低剂量 (66%) PET 图像采集, 在肝脏区域 DL 模型能有效降低噪声并保持 SUV_{max} 测

量误差在 6.5% 左右, 相较于有序子集最大期望值迭代法 (ordered subsets expectation maximization, OSEM) 显示出更好的一致性。

GAN 通过生成器和判别器之间的对抗训练来学习数据映射关系, 可用于低剂量 PET 图像恢复。Zhou 等^[17] 提出 Cycle-WGAN 模型可实现低计数 PET (1/106) 图像恢复, 该方法的 NRMSE, SSIM, PSNR 分别提高 $(17.15 \pm 3.27)\%$ 、 $(0.30 \pm 0.22)\%$ 、 $(2.11 \pm 1.67)\%$ 。Sanaat 等^[18] 提出了基于 Cycle-GAN 的低剂量 (12.5%) PET 图像恢复方法, 对于肝脏、肺部、脑部等区域恶性病灶的 SUV 偏差最低仅为 0.01%, 图像质量与全剂量采集类似。Lei 等^[19] 提出 Cycle-GAN 模型, 基于 12.5% 剂量下 PET 数据实现全剂量 PET 图像输出, 该方法的平均误差和 NRMSE 分别为 $(1.43 \pm 0.14)\%$ 和 $(0.52 \pm 0.19)\%$ 。

DL 模型在低剂量 PET 图像恢复中展现出良好的重建能力, 其中以 U-Net 系列模型和 Cycle-GAN 类对抗模型为主流。U-Net 模型结构简洁, 适用于中等剂量下的图像恢复; 相比之下, Cycle-GAN 等对抗网络善于模拟复杂映射关系, 能在极低剂量 ($<1\%$) 下生成质量接近全剂量的图像。

二、图像重建

PET 显像基础在于放射性同位素示踪剂从目标区域内部分发射不同角度的射线并由探测器捕获其投影信息, 故需要通过反投影的方式获取目标区域的示踪剂聚集情况。经典的 PET 图像重建方法包括解析法与迭代法。解析法可分为滤波反投影法 (filtered back projection, FBP)、反投影滤波法 (back projection filtered, BPF)、卷积反投影法 (convolution back projection, CBP) 等^[48-49]。PET 图像重建常用的迭代法有最大似然法 (maximum likelihood expectation-maximization, MLEM) 和 OSEM^[50-51]。基于 DL 模型的 PET 图像重建方法正逐渐成为研究热点。DL 模型能够在不依赖明确物理模型的前提下, 直接从大量图像数据中学习投影与图像之间的非线性映射关系, 或作为正则化模块嵌入传统重建流程中, 增强对图像纹理与噪声特性的建模能力, 提升图像质量与重建效率。根据 DL 介入方式不同, 可将其分为图像直接重建 (如从投影数据直接生成 PET 图像) 与正则化重建 (如在 OSEM

等框架中引入 DL 先验或约束项)两大类。AI 方法的引入为克服传统重建方法在图像质量、速度和鲁棒性等方面的瓶颈提供了新的解决路径。

1. 图像直接重建。DL 技术本质上通过提供一种映射关系来解决数据分解重构中的特定关键问题,如完成正弦图域和图像域之间的转换。PET 图像重建过程计算密集、复杂,利用 DL 模型可通过学习采集到的图像特征与重建图像间的映射关系而辅助图像重建,缩短重建时间。Häggröm 等^[20]提出了一种新颖的端到端 PET 图像重建技术,基于深度卷积编码器-解码器网络,通过 PET 正弦图数据作为输入可直接输出 PET 图像,结果表明该模型相较于 OSEM、FBP 等重建方法,SSIM 分别提高 1%、11%,PSNR 提高 1.1 dB 与 3.8 dB。Wang 与 Liu^[21]提出一种 FBP-Net 模型,可直接基于正弦图实现 PET 图像重建,该模型的 PSNR 为 23.98 dB,SSIM 为 0.941,显著高于 U-Net 和 Deep-PET 对照组。Gong 等^[22]基于 Patlak 模型与 Logan 模型提出非局部深度先验方法进行脑部动态 PET 重建,相较于传统方法,在¹⁸F-FDG 和¹¹C-匹兹堡化合物 B(Pittsburgh compound B, PIB)测试中展现出更高的 SNR。Hu 等^[23]基于改进 Wasserstein GAN (Wasserstein GAN, WGAN),利用正弦图像直接重建 PET 图像,所提出模型重建 263 幅 PET 图像的时间仅为 0.01 s,远低于对照组,显著降低了图像重建时间。Whiteley 等^[24]提出 Fast-PET 图像重建模型,该模型相较于 OSEM 重建方法,PET 图像重建时间仅为其 1/67。

2. 正则化重建。通过在重建框架中引入 DL 模型,可以利用先验知识来调整整个重建过程,优化图像 PSNR、SSIM 等指标。Gong 等^[52]训练了一个深度残差 CNN 模型并将其嵌入至 MLEM 迭代重建框架中,结果表明该模型能显著抑制图像噪声并保留图像细节。Mehrani 和 Reader^[25]提出的前-后向分裂期望最大化(forward-backward splitting expectation maximization, FBSEM)方法,将正则化、期望最大化和融合三步整合为迭代过程,通过 CNN 实现残差学习作为正则项,在多种数据下验证优于传统最大后验期望最大化(maximum a posteriori expectation maximization, MAPEM)和 OSEM 方法,其平均 NRMSE 分别为 14.4% 和 13.4%,显著低于 MAPEM(17.7%)和 OSEM(20.7%)。Liu 等^[11]开发的先验信息引导重建网络(prior information-guided reconstruction network, PIGRN)利用 FBP 图像作为先验输入,结合双尺度判别器,实验中 PSNR 达 31.85 dB,SSIM 达 0.975 4,明显优于 U-Net 和 Deep-PET。Hu 等^[26]基于列表模式数据的 PET 重建,使用残差注意力 U-Net 结构作为正则单元,在 25 组脑 PET 模拟数据中表现出比传统 List-mode 最大期望算法及全变差正则化方法更高的 PSNR 与 SSIM(27.18 dB 与 0.836)。Farsani 等^[27]提出基于 cGAN 模型的 PET 图像重建框架,并将图像 PSNR 提高了 33%,均方误差(mean square error, MSE)降低了 75%。Sanaat 等^[28]结合 Cycle-GAN 架构进行训练,重建¹⁸F-FDG PET 图像,所得图像在多个指标上优于其他方法,SSIM 高达 0.96,PSNR 约 33.6 dB。

三、图像衰减校正

PET 显像剂衰变过程产生的反向 γ 光子在穿过人体组织时因光电吸收和康普顿散射等作用导致计数损失,称为衰

减效应;通过衰减校正可消除其对显像的影响。基于 DL 方法实现 PET 衰减校正的过程包括:首先,输入数据前向传播依次遍历模型所有层并产生初步预测结果;其次,利用损失函数评估模型输出效果;最后,将损失反向传播进行权重调整。通过多次迭代以上过程直至预期损失最小化。

PET/CT 中的 CT 图像提供组织的密度信息,需通过能量映射方法将 HU 值转换为 γ 射线衰减系数(μ 值),进而应用于 PET 图像的衰减校正。其中,双线性插值法是一种经验性方法,主要用于软组织和骨组织的衰减校正。基于 DL 的 PET/CT 衰减校正可以在不依赖 CT 图像,仅基于 PET 数据生成衰减图,从而很好地应对 CT 图像不具备使用价值的情况。Liu 等^[29]提出 DL 衰减校正模型通过生成伪 CT 图像进行脑部 PET 衰减校正,平均误差小于 1%。Arabi 等^[30]基于 4 种放射性同位素示踪剂训练 CNN 模型,实现不基于 CT 图像的 PET 衰减校正并控制绝对 SUV 偏差小于 9%。Lord 等^[31]在双中心临床研究中利用 DL 模型实现⁶⁸Ga-1,4,7,10-四氮杂环十二烷-1,4,7,10-四乙酸-D-苯丙氨酸 1-酪氨酸 3-苏氨酸 8-奥曲肽(1,4,7,10-tetraazacyclododecane-1,4,7,10-tetraacetic acid-D-Phe1-Tyr3-Thr8-octreotide, DOTATATE)全身 PET/CT 显像的衰减校正,结果显示最高 PSNR 达到(52.86 \pm 6.6) dB,表明该方法可用于无 CT 图像下的衰减校正,从而减少患者含辐射显像检查需求。Liu 等^[29]开发了一种深度卷积编码解码网络模型,通过生成伪 CT 图像实现¹⁸F-FDG PET 脑部图像的衰减校正,相较于标准 CT 图像,该方法误差低于 1%。Yang 等^[32]基于 U-Net 网络直接进行 PET/CT 无 CT 条件下的衰减校正,该模型 PSNR 为(36.3 \pm 3.0) dB,SSIM 为 0.98 \pm 0.01。

与 PET/CT 不同,PET/MR 图像的衰减校正难点在于:(1) MRI 信号主要依赖质子密度和弛豫时间,与 γ 射线衰减系数无直接对应关系;(2) MRI 对骨组织信号较弱,难以准确估计骨组织的衰减系数;(3)空气-软组织界面的信号差异小,易导致误分类。目前,基于 MRI 的衰减校正(MRI based attenuation correction, MRAC)方法包括基于解剖模板、组织分割和 DL 的方法,其中 DL 方法近年来在提升 MRAC 精度方面取得了显著进展。经典的 MRAC 方法难以确定 CT 与 MR 图像信息之间的直接联系,DL 模型提供了根据图像底层特征完成两者关联的研究方式。Yang 等^[33]提出深度 CNN(deep CNN, DCNN)模型实现衰减校正,相较于 MRAC,SUV 误差为(4.0 \pm 15.4)%。Lei 等^[34]提出一种 Cycle-GAN 模型,基于 MR 图像进行非衰减校正 PET 图像的衰减校正,能够在全脑范围内将平均误差控制在 0.1%,表明该方法具有临床可行性与准确性。Jahangir 等^[35]采用双通道 DL 模型实现 PET/MR 衰减校正,结果显示全脑区域的 SUV 均方根误差(root-mean-square error, RMSE)仅为 0.157 \pm 0.08,证明了其在脑部 PET 图像中的优越表现。

四、图像转换与合成

基于 DL 技术实现不同模态间图像转换以及图像生成对于 PET 显像具有重要价值。首先,基于 DL 的图像生成模型(如 GAN 或超分辨率网络)可用于补充全因扫描条件、患者运动或低剂量采集导致的 PET 图像缺失区域,提高图像完整性和诊断可用性;其次,在 PET 图像采集过程中,使用 DL 模型可用于补充部分未扫描区域图像,缩短整体扫描时间,减轻

患者扫描负担;最后,不同模态图像转换与合成可以很好的应对医学影像数据小样本以及数据不平衡的特点,有利于后续 DL 模型训练优化。目前,CNN 和 GAN 等 DL 模型在实现计算复杂度较高的医学图像转换与生成中受到广泛关注。

Choi 等^[36]通过 PET 图像训练生成一个 GAN 模型,使其基于 PET 图像生成相应的 MR 图像,结果表明该模型生成图像与真实图像 SSIM 为 0.91 ± 0.04 。Kimura 等^[37]训练 CycleGAN 模型,使其实现 PET 阳性与阴性组别图像之间转化,达到补充缺失数据的效果。Kang 等^[38]提出深度生成网络(deep generative network, DGN)模型,用于实现不同显像剂 PET 图像之间转化,在¹⁸F 与¹¹C 图像转化中表现出良好的一致性。Guo 等^[39]基于 MR 中的动脉自旋标记(arterial spin labeling, ASL)与 T₁、T₂ 加权项,结合脑血流(cerebral blood flow, CBF)数据实现 PET/MR 扫描中的 PET 图像生成;结果表明所使用 U-Net 模型生成图像 SSIM 可达 0.854 ± 0.036 。Chen 等^[40]通过联合 2 组 DL 模型,基于 PET 与 MR 数据实现 CBF 变化预测。Matsubara 等^[41]使用 U-Net 模型基于 PET 与 MR 数据进行训练,实现氧提取分数预测,组内相关系数(intra-class correlation coefficient, ICC)为 0.597 ± 0.082 。

五、限制与不足

在使用 DL 模型进行 PET 图像处理的研究中,PET 图像的定量评估至关重要,将直接影响临床判读的可靠性。虽然 PSNR 和 SSIM 等指标可用于衡量图像的质量,但其无法准确反映 PET 图像的放射性定量特性。由于 PET 图像的定量分析与解剖影像不同,需要进一步研究适用于 PET 的评估方法,如 Bland-Altman 分析、SUV 测量稳定性和放射性浓度的一致性分析,以验证 PSNR 和 SSIM 等传统指标在 PET 图像定量分析中的适用性。另一个挑战是数据量的限制,PET 数据的获取受高成本、辐射暴露风险和数据隐私限制影响,导致样本量通常较小,这限制了 DL 模型的泛化能力。尽管可以通过迁移学习、数据增强(如 GAN 模型生成 PET 数据)等方法缓解这一问题,但数据分布偏差仍可能影响微调模型的效果。此外,模型的跨设备、跨中心泛化能力也是亟待解决的重要问题。不同扫描仪型号、显像协议和注射剂量等因素会导致图像质量和放射性分布存在系统性差异,影响数据整合分析,进而影响模型性能的稳定性与泛化能力。

未来研究可重点聚焦于以下几个方向:(1)构建多中心、多设备、多参数下的大规模标准化数据集,提升模型的泛化能力;(2)建立稳定的图像质量定量评估指标体系,以便更准确评估 DL 模型在 PET 中的表现;(3)进一步探索新型模型(如 Transformer 类网络)在 PET 图像分割、增强、转换等任务中的潜力。近年来,Vision Transformer 和 Swin Transformer 等变体已在医学影像分割、图像合成和超分辨率增强等任务中取得显著进展^[53-54],并在 PET 图像 ROI 分割中表现出优越性能^[55-56]。此外,其他类 DL 模型,如 Diffusion 模型、混合结构模型(Hybrid CNN-Transformer)、轻量级网络架构(如 MobileNet、EfficientNet 等)也为 PET 显像的进展提供了新的研究方向。

六、总结

本文介绍了 DL 在 PET 图像处理中的应用,特别是在图像增强、图像重建、衰减校正、图像转换与生成方面的进展。尽管目前 DL 模型仍存在泛化能力欠佳、训练样本受限等问

题亟待解决,但其使得计算机辅助临床诊疗成为可能,有望减轻临床医师和研究人员的负担,并为医学成像研究提供更精准的分析工具。

利益冲突 所有作者声明无利益冲突

作者贡献声明 王坤:文献整理、论文撰写;袁增贝:论文撰写;赵军:研究指导、论文修改

参 考 文 献

- [1] Hu J, Cheng R, Quan M, et al. Hypermetabolic pulmonary lesions detection and diagnosis based on PET/CT imaging and deep learning models[J]. *Eur J Nucl Med Mol Imaging*, 2025, 52(10): 3792-3806. DOI:10.1007/s00259-025-07215-0.
- [2] Howard J. Artificial intelligence: implications for the future of work [J]. *Am J Ind Med*, 2019, 62(11): 917-926. DOI:10.1002/ajim.23037.
- [3] Huang B, Yang Q, Li X, et al. Deep learning-based whole-body characterization of prostate cancer lesions on [⁶⁸Ga]Ga-PSMA-11 PET/CT in patients with post-prostatectomy recurrence [J]. *Eur J Nucl Med Mol Imaging*, 2024, 51(4): 1173-1184. DOI:10.1007/s00259-023-06551-3.
- [4] 宋昊,武志芳,柴象飞,等.深度学习在核素心肌灌注显像中的研究进展[J].*中华核医学与分子影像杂志*, 2024, 44(2): 116-119. DOI:10.3760/cma.j.cn321828-20221019-00315.
Song H, Wu ZF, Chai XF, et al. Research progress of deep learning in nuclear myocardial perfusion imaging [J]. *Chin J Nucl Med Mol Imaging*, 2024, 44(2): 116-119. DOI: 10.3760/cma.j.cn321828-20221019-00315.
- [5] 覃春霞,吕玉虎,代志博,等.多参数 MRI 深度学习人工智能分析联合⁶⁸Ga-PSMA PET 对前列腺癌的诊断价值[J].*中华核医学与分子影像杂志*, 2024, 44(9): 516-521. DOI:10.3760/cma.j.cn321828-20240628-00233.
Qin CX, Lyu YH, Dai ZB, et al. Diagnostic value of multiparametric MRI deep learning artificial intelligence analysis combined with ⁶⁸Ga-PSMA PET for prostate cancer [J]. *Chin J Nucl Med Mol Imaging*, 2024, 44(9): 516-521. DOI: 10.3760/cma.j.cn321828-20240628-00233.
- [6] Lv Z, Song X, Feng J, et al. Reduced-order prediction model for the Cahn-Hilliard equation based on deep learning [J]. *Eng Anal Bound Elem*, 2025, 172: 106118. DOI:10.1016/j.enganbound.2025.106118.
- [7] Matsubara K, Ibaraki M, Nemoto M, et al. A review on AI in PET imaging [J]. *Ann Nucl Med*, 2022, 36(2): 133-143. DOI:10.1007/s12149-021-01710-8.
- [8] Cui J, Gong K, Guo N, et al. PET image denoising using unsupervised deep learning [J]. *Eur J Nucl Med Mol Imaging*, 2019, 46(13): 2780-2789. DOI:10.1007/s00259-019-04468-4.
- [9] Gong K, Catana C, Qi J, et al. PET image reconstruction using deep image prior [J]. *IEEE Trans Med Imaging*, 2019, 38(7): 1655-1665. DOI:10.1109/TMI.2018.2888491.
- [10] Hashimoto F, Ohba H, Ote K, et al. 4D deep image prior: dynamic PET image denoising using an unsupervised four-dimensional branch convolutional neural network [J]. *Phys Med Biol*, 2021, 66(1): 015006. DOI:10.1088/1361-6560/abcd1a.
- [11] Liu Z, Wang B, Ye H, et al. Prior information-guided reconstruction network for positron emission tomography images [J]. *Quant Imaging Med Surg*, 2023, 13(12): 8230-8246. DOI:10.21037/qims-23-579.

- [12] Spuhler K, Serrano-Sosa M, Cattell R, et al. Full-count PET recovery from low-count image using a dilated convolutional neural network[J]. *Med Phys*, 2020, 47(10): 4928-4938. DOI: 10.1002/mp.14402.
- [13] Pan S, Abouei E, Peng J, et al. Full-dose whole-body PET synthesis from low-dose PET using high-efficiency denoising diffusion probabilistic model: PET consistency model[J]. *Med Phys*, 2024, 51(8): 5468-5478. DOI:10.1002/mp.17068.
- [14] Chaudhari AS, Mittra E, Davidzon GA, et al. Author correction: low-count whole-body PET with deep learning in a multicenter and externally validated study[J]. *NPJ Digit Med*, 2021, 4(1): 139. DOI:10.1038/s41746-021-00512-6.
- [15] 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.
- [16] Ciborowski K, Gramek-Jedwabna A, Goła**b** M, et al. Performance of a deep learning enhancement method applied to PET images acquired with a reduced acquisition time[J]. *Nucl Med Rev Cent East Eur*, 2023, 26(0): 116-122. DOI:10.5603/nmr.94482.
- [17] Zhou L, Schaefferkoetter JD, Tham IWK, et al. Supervised learning with cycleGAN for low-dose FDG PET image denoising[J]. *Med Image Anal*, 2020, 65: 101770. DOI:10.1016/j.media.2020.101770.
- [18] Sanaat A, Shiri I, Arabi H, et al. Deep learning-assisted ultra-fast/low-dose whole-body PET/CT imaging[J]. *Eur J Nucl Med Mol Imaging*, 2021, 48(8): 2405-2415. DOI: 10.1007/s00259-020-05167-1.
- [19] Lei Y, Dong X, Wang T, et al. Whole-body PET estimation from low count statistics using cycle-consistent generative adversarial networks[J]. *Phys Med Biol*, 2019, 64(21): 215017. DOI: 10.1088/1361-6560/ab4891.
- [20] Häggström I, Schmidtlein CR, Campanella G, et al. DeepPET: a deep encoder-decoder network for directly solving the PET image reconstruction inverse problem[J]. *Med Image Anal*, 2019, 54: 253-262. DOI:10.1016/j.media.2019.03.013.
- [21] Wang B, Liu H. FBP-Net for direct reconstruction of dynamic PET images[J]. *Phys Med Biol*, 2020, 65(23): 235008. DOI: 10.1088/1361-6560/abc09d.
- [22] Gong K, Catana C, Qi J, et al. Direct reconstruction of linear parametric images from dynamic PET using nonlocal deep image prior[J]. *IEEE Trans Med Imaging*, 2022, 41(3): 680-689. DOI:10.1109/TMI.2021.3120913.
- [23] Hu Z, Xue H, Zhang Q, et al. DPIR-Net: direct PET image reconstruction based on the Wasserstein generative adversarial network[J]. *IEEE Trans Radiat Plasma Med Sci*, 2020, 5(1): 35-43. DOI:10.1109/TRPMS.2020.2995717.
- [24] Whiteley W, Panin V, Zhou C, et al. FastPET: near real-time reconstruction of PET histo-image data using a neural network[J]. *IEEE Trans Radiat Plasma Med Sci*, 2020, 5(1): 65-77. DOI:10.1109/TRPMS.2020.3028364.
- [25] Mehranian A, Reader AJ. Model-based deep learning PET image reconstruction using forward-backward splitting expectation-maximization[J]. *IEEE Trans Radiat Plasma Med Sci*, 2020, 5(1): 54-64. DOI:10.1109/TRPMS.2020.3004408.
- [26] Hu R, Li Y, Liu H. ListmodeCNN: deep learning-based PET listmode image reconstruction[J]. *Proc SPIE*, 2023: 12463. DOI:10.1117/12.2647340.
- [27] Farsani SN, Jafaritadi M, Fisher J, et al. Noise mitigation for a short axial field of view brain PET insert prototype using deep learning[C]//2023 IEEE Nuclear Science Symposium, Medical Imaging Conference and International Symposium on Room-Temperature Semiconductor Detectors (NSS MIC RTSD). Piscataway, NJ: IEEE, 2023. DOI:10.1109/NSSMICRTSD49126.2023.10338686.
- [28] Sanaat A, Boehringer A, Ghavabesh A, et al. Deep-PVC: a deep learning model for synthesizing full-dose partial volume corrected PET images from low-dose images[C]//2021 IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC). Piscataway, NJ: IEEE, 2021. DOI: 10.1109/NSS/MIC44867.2021.9875501.
- [29] Liu F, Jang H, Kijowski R, et al. A deep learning approach for ¹⁸F-FDG PET attenuation correction[J]. *EJNMMI Phys*, 2018, 5(1): 24. DOI:10.1186/s40658-018-0225-8.
- [30] Arabi H, Bortolin K, Ginovart N, et al. Deep learning-guided joint attenuation and scatter correction in multitracer neuroimaging studies[J]. *Hum Brain Mapp*, 2020, 41(13): 3667-3679. DOI:10.1002/hbm.25039.
- [31] Lord MS, Islamian JP, Seyyedi N, et al. Deep-learning-based attenuation correction for ⁶⁸Ga-DOTATATE whole-body PET imaging: a dual-center clinical study[J]. *Mol Imaging Radionucl Ther*, 2024, 33(3): 138-146. DOI:10.4274/mirt.galenos.2024.86422.
- [32] Yang J, Sohn JH, Behr SC, et al. CT-less direct correction of attenuation and scatter in the image space using deep learning for whole-body FDG PET: potential benefits and pitfalls[J]. *Radiol Artif Intell*, 2021, 3(2): e200137. DOI:10.1148/ryai.2020200137.
- [33] Yang J, Park D, Gullberg GT, et al. Joint correction of attenuation and scatter in image space using deep convolutional neural networks for dedicated brain ¹⁸F-FDG PET[J]. *Phys Med Biol*, 2019, 64(7): 075019. DOI:10.1088/1361-6560/ab0606.
- [34] Lei Y, Dong X, Wang T, et al. MRI-aided attenuation correction for PET imaging with deep learning[C]//Medical Imaging 2020: Biomedical Applications in Molecular, Structural, and Functional Imaging. SPIE, 2020, 11317: 521-527. DOI:10.1117/12.2549388.
- [35] Jahangir R, Kamali-Asl A, Arabi H, et al. Strategies for deep learning-based attenuation and scatter correction of brain ¹⁸F-FDG PET images in the image domain[J]. *Med Phys*, 2024, 51(2): 870-880. DOI:10.1002/mp.16914.
- [36] Choi H, Lee DS, Alzheimer's disease neuroimaging initiative. generation of structural MR images from amyloid PET: application to MR-less quantification[J]. *J Nucl Med*, 2018, 59(7): 1111-1117. DOI:10.2967/jnumed.117.199414.
- [37] Kimura Y, Watanabe A, Yamada T, et al. AI approach of cycle-consistent generative adversarial networks to synthesize PET images to train computer-aided diagnosis algorithm for dementia[J]. *Ann Nucl Med*, 2020, 34(7): 512-515. DOI: 10.1007/s12149-020-01468-5.
- [38] Kang SK, Choi H, Lee JS, et al. Translating amyloid PET of different radiotracers by a deep generative model for interchangeability[J]. *Neuroimage*, 2021, 232: 117890. DOI:10.1016/j.neuroimage.2021.117890.
- [39] Guo J, Gong E, Fan AP, et al. Predicting ¹⁵O-water PET cerebral blood flow maps from multi-contrast MRI using a deep convolutional neural network with evaluation of training cohort bias[J]. *J Cereb Blood Flow Metab*, 2020, 40(11): 2240-2253. DOI:10.1177/0271678X19888123.
- [40] Chen D, Ishii Y, Fan AP, et al. Predicting PET cerebrovascular

- reserve with deep learning by using baseline MRI: a pilot investigation of a drug-free brain stress test[J]. *Radiology*, 2020, 296(3): 627-637. DOI:10.1148/radiol.2020192793.
- [41] Matsubara K, Ibaraki M, Shinohara Y, et al. Prediction of an oxygen extraction fraction map by convolutional neural network: validation of input data among MR and PET images[J]. *Int J Comput Assist Radiol Surg*, 2021, 16(11): 1865-1874. DOI:10.1007/s11548-021-02356-7.
- [42] Wang T, Lei Y, Fu Y, et al. A review on medical imaging synthesis using deep learning and its clinical applications[J]. *J Appl Clin Med Phys*, 2021, 22(1): 11-36. DOI:10.1002/acm2.13121.
- [43] Tian C, Fei L, Zheng W, et al. Deep learning on image denoising: an overview [J]. *Neural Netw*, 2020, 131: 251-275. DOI: 10.1016/j.neunet.2020.07.025.
- [44] Kang E, Min J, Ye JC. A deep convolutional neural network using directional wavelets for low-dose X-ray CT reconstruction[J]. *Med Phys*, 2017, 44(10): e360-e375. DOI:10.1002/mp.12344.
- [45] Shan H, Padole A, Homayounieh F, et al. Competitive performance of a modularized deep neural network compared to commercial algorithms for low-dose CT image reconstruction [J]. *Nat Mach Intell*, 2019, 1(6): 269-276. DOI:10.1038/s42256-019-0057-9.
- [46] Wolterink JM, Leiner T, Viergever MA, et al. Generative adversarial networks for noise reduction in low-dose CT[J]. *IEEE Trans Med Imaging*, 2017, 36(12): 2536-2545. DOI: 10.1109/TMI.2017.2708987.
- [47] Yi X, Babyn P. Sharpness-aware low-dose CT denoising using conditional generative adversarial network[J]. *J Digit Imaging*, 2018, 31(5): 655-669. DOI:10.1007/s10278-018-0056-0.
- [48] Tsai MY, Liang HL, Chuo CC, et al. A novel protocol for abdominal low-dose CT scans adapted with a model-based iterative reconstruction method[J]. *J Xray Sci Technol*, 2023, 31(3): 453-461. DOI:10.3233/XST-221325.
- [49] Lv L, Zeng GL, Chen G, et al. The effects of back-projection variants in BPF-like TOF PET reconstruction using CNN filtration—based on simulated and clinical brain data[J]. *Med Phys*, 2024, 51(9): 6161-6175. DOI:10.1002/mp.17191.
- [50] Tomazinaki ME, Stiliaris E. A stochastic alternative technique for compton maximum likelihood expectation-maximization (MLEM) reconstruction[J]. *Comput Biol Med*, 2023, 166: 107502. DOI: 10.1016/j.combiomed.2023.107502.
- [51] 尚琨, 胡杰, 王振明, 等. 不同重建方法对颞叶癫痫患者 FDG PET 图像质量及诊断效能的影响[J]. *中华核医学与分子影像杂志*, 2024, 44(11): 678-683. DOI:10.3760/cma.j.cn321828-20240108-00010.
- Shang K, Hu J, Wang ZM, et al. Impact of different reconstruction algorithms on PET image quality and diagnostic efficiency in patients with temporal lobe epilepsy[J]. *Chin J Nucl Med Mol Imaging*, 2024, 44(11): 678-683. DOI:10.3760/cma.j.cn321828-20240108-00010.
- [52] Gong K, Guan J, Kim K, et al. Iterative PET image reconstruction using convolutional neural network representation[J]. *IEEE Trans Med Imaging*, 2019, 38(3): 675-685. DOI:10.1109/TMI.2018.2869871.
- [53] Wang Y, Li Z, Mei J, et al. SwinMM: Masked Multi-view with Swin Transformers for 3D medical image segmentation[C]//*Medical Image Computing and Computer Assisted Intervention. MICCAI 2023*. Cham: Springer, 2023: 486-496. DOI:10.1007/978-3-031-43898-1_47.
- [54] Schlosser M, Prettnner S, Ivanovska T. On analysis of Swin UNETR: a robust architecture for medical image segmentation[C]//*2023 1st International Conference on Optimization Techniques for Learning (ICOTL)*. Piscataway, NJ: IEEE, 2023. DOI: 10.1109/ICOTL59758.2023.10435236.
- [55] Li GY, Chen J, Jang SI, et al. SwinCross: cross-modal Swin Transformer for head-and-neck tumor segmentation in PET/CT images [J]. *Med Phys*, 2024, 51(3): 2096-2107. DOI:10.1002/mp.16703.
- [56] Hatamizadeh A, Nath V, Tang Y, et al. Swin UNETR: Swin Transformers for semantic segmentation of brain tumors in MRI images [C]//*Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Brainles 2021*. Cham: Springer, 2023: 272-284. DOI:10.1007/978-3-031-08999-2_22.

(收稿日期:2025-05-09)

更正

本刊 2026 年第 46 卷第 1 期第 57 页表 1 中“良性甲状腺瘤”应改为“预后较好、具有摄碘能力的分化型甲状腺瘤”。

本刊编辑部