

## 生成对抗网络在 CT 与 PET 影像跨模态生成中的研究进展

邵小南<sup>1</sup> 牛荣<sup>1</sup> 高建雄<sup>1</sup> 葛欣宇<sup>1</sup> 王跃涛<sup>1</sup> 周军<sup>2</sup>

<sup>1</sup>苏州大学附属第三医院、常州市第一人民医院核医学科,苏州大学核医学与分子影像临床转化研究所,常州市分子影像重点实验室,常州 213003;<sup>2</sup>苏州大学附属第三医院、常州市第一人民医院呼吸与危重症医学科,常州 213003

通信作者:王跃涛, Email: yuetao-w@163.com

**【摘要】** 近年来,生成对抗网络(GAN)技术迅速发展,此法可通过学习 CT 与 PET 影像之间的映射关系实现跨模态生成,既能融合解剖与功能信息、提高图像质量,也在一定程度上减少患者辐射负担。该文系统梳理条件 GAN、循环 GAN 等典型 GAN 架构的原理与应用,聚焦其在肿瘤初诊与分期、疗效评估与随访以及 PET/CT 辐射剂量降低等方面的研究进展,探讨小样本学习、模型可解释性和跨机构标准化等挑战,展望 GAN 跨模态生成技术的临床应用前景。

**【关键词】** 算法;正电子发射断层显像术;体层摄影术,X 线计算机;生成对抗网络;发展趋势

**基金项目:**常州市高技术研究重点实验室(CM20193010);常州市科技计划项目(CJ20220228);常州市“十四五”卫生健康高层次人才培养工程——拔尖人才(2022CZBJ037,2024CZBJ008);常州市临床医学中心(核医学)(CZZX202204);常州市第五批科技计划项目(CE20235057);常州市卫生健康委员会重大科技项目(ZD202405)

DOI:10.3760/cma.j.cn321828-20250212-00034

### Research progress on cross-modality generation of CT and PET images using generative adversarial networks

Shao Xiaonan<sup>1</sup>, Niu Rong<sup>1</sup>, Gao Jianxiong<sup>1</sup>, Ge Xinyu<sup>1</sup>, Wang Yuetao<sup>1</sup>, Zhou Jun<sup>2</sup>

<sup>1</sup>Department of Nuclear Medicine, the Third Affiliated Hospital of Soochow University, the First People's Hospital of Changzhou; Institute of Clinical Translation of Nuclear Medicine and Molecular Imaging, Soochow University; Changzhou Key Laboratory of Molecular Imaging, Changzhou 213003, China; <sup>2</sup>Department of Respiratory and Critical Care Medicine, the Third Affiliated Hospital of Soochow University, the First People's Hospital of Changzhou, Changzhou 213003, China

Corresponding author: Wang Yuetao, Email: yuetao-w@163.com

**【Abstract】** With the rapid development of generative adversarial networks (GAN), learning the mapping between CT and PET images enables cross-modality generation. This not only integrates anatomical and functional information to improve image quality, but also helps reduce the radiation exposure to some extent. Based on a review of representative GAN architectures such as conditional GAN and CycleGAN, this paper discusses their research progress and limitations in various application scenarios, including initial tumor diagnosis and staging, treatment evaluation and follow-up, as well as methods for reducing PET/CT radiation dose. Additionally, challenges related to small-sample learning, model interpretability, and cross-institutional standardization are highlighted, and the clinical application prospects of GAN-based cross-modality generation technology are explored.

**【Key words】** Algorithms; Positron-emission tomography; Tomography, X-ray computed; Generative adversarial networks; Trends

**Fund program:** Key Laboratory of Changzhou High-tech Research Project (CM20193010); Changzhou Science and Technology Program (CJ20220228); Top Talent of Changzhou "The 14th Five-Year Plan" High-Level Health Talents Training Project (2022CZBJ037, 2024CZBJ008); Changzhou Clinical Medical Center (Nuclear Medicine) (CZZX202204); Changzhou Science and Technology Bureau (Social Development Projects) (CE20235057); Major Project of Changzhou Health Commission (ZD202405)

DOI:10.3760/cma.j.cn321828-20250212-00034

CT 与 PET 在医学影像学中各具优势:CT 利用 X 线提供高分辨率解剖结构信息,广泛应用于疾病筛查和解剖学评估;PET 通过定量分析显像剂(如<sup>18</sup>F-FDG)的摄取情况揭示功能代谢变化,在肿瘤、心血管及神经系统疾病等领域具有

诊断与疗效评估价值<sup>[1-2]</sup>。然而,CT 与 PET 均存在辐射暴露问题;此外,PET 设备价格昂贵、分辨率相对有限,导致在资源匮乏地区难以普及。MRI 虽然无电离辐射,但难以完全取代 CT 与 PET 的联合应用。因此,如何结合 CT 和 PET 的解剖

与功能优势,同时降低患者辐射暴露并提升诊断效率,始终是医学影像领域的重要研究方向。

近年来,随着深度学习特别是生成对抗网络 (generative adversarial networks, GAN) 的兴起,人工智能 (artificial intelligence, AI) 模拟生成在医学影像中受到广泛关注,其可通过学习不同模态间的映射关系,实现 CT 生成 PET 或 PET 生成 CT 等跨模态合成<sup>[3-4]</sup>。这种技术在设备不足地区和辐射敏感的特殊人群 (如儿童、孕妇) 中具有潜在应用价值,可减少不必要的重复扫描和患者累计辐射剂量。例如,在癫痫病灶定位、肿瘤疗效评估及延迟显像等场景中,PET 功能显像相较 CT 更具诊断优势,因此临床上常优先选择进行 PET 检查,利用 AI 生成相应的 CT 影像实现解剖定位与衰减校正,从而降低辐射暴露<sup>[5]</sup>。然而,GAN 生成的影像在临床应用前仍需结合医师经验与多模态检查综合判断,并遵循相关伦理和监管要求。基于此,本文综述 GAN 在 CT 与 PET 影像跨模态生成中的研究进展,重点讨论其在肿瘤诊断、剂量优化及解剖-功能信息融合等方面的临床应用价值,同时结合最新文献探讨数据、模型可解释性及跨机构标准化的挑战,并展望未来研究方向。图 1 展示了典型的条件 GAN (conditional GAN, cGAN) 与循环 GAN (CycleGAN) 结构在 CT 到 PET 跨模态生成中的示意流程。

一、AI 在医学影像生成中的进展与跨模态影像生成技术

近年来,AI 在医学影像分析与模拟生成方面展现出巨大潜力,涵盖从分割、诊断到跨模态影像合成等多重任务<sup>[6-7]</sup>。与依赖人工特征提取的传统方法相比,深度学习,尤其是卷积神经网络的崛起,使模型能够自动学习多层次图像特征,并在分类、分割及重建中取得显著成果<sup>[7-8]</sup>,为跨模态生成奠定了技术基础。

跨模态影像生成旨在通过深度模型模拟另一种成像模态 (如 CT→PET)<sup>[4]</sup>,以弥补目标模态获取难或扫描成本高的问题并提升诊断效率。其具体方法不仅取决于数据特性 (如是否具备成对 CT-PET 样本、样本规模、噪声水平),也会根据任务需求进行相应设计<sup>[9]</sup>。在医疗影像的实际场景中,若源模态与目标模态在采集时刻或配准环节存在偏差,易导致解剖-功能错配;为减轻此风险,一些研究在 GAN 中结合了解剖先验、配准算法或注意力机制<sup>[10]</sup>。近年来,也有学者探索扩散模型或多模态 Transformer 等新架构,以在小样本、高噪

声环境下实现更细腻的图像细节与较高的生理合理性<sup>[9]</sup>。

根据是否需成对数据进行监督学习,跨模态影像生成通常可分为有监督 (需配对) 和无监督 (无需配对) 两大类。有监督方法 (如 Pix2Pix) 通常依赖成对且配准良好的 CT-PET 图像来学习映射关系,能更精准地对应解剖与功能信息,但对高质量配准数据依赖度高;无监督方法 (如 CycleGAN) 则无需成对数据,通常通过对抗训练或变分推断分别建模源域与目标域的分布映射,但由于缺乏像素级对应,易在某些区域出现解剖-功能错配或伪影<sup>[11-12]</sup>。部分研究还探索半监督、多阶段 GAN 等混合策略<sup>[13-14]</sup>,在仅有少量配对数据的情境下兼顾映射精度与数据多样性。值得注意的是,医学影像往往存在低对比度、噪声、器官形变及病灶功能异质性等挑战,若模型缺乏足够的解剖或功能先验,可能生成不符合实际代谢分布的虚假热点或漏检病灶。

二、CT 与 PET 影像跨模态生成的效能评价方法

1. 图像质量评价。跨模态生成影像的质量通常从视觉质量与定量指标两方面衡量。前者着重评估结构、纹理等外观还原度,常用指标包括结构相似性 (structural similarity, SSIM)、峰值信噪比 (peak signal-to-noise ratio, PSNR) 和 Fréchet 初始距离 (Fréchet inception distance, FID)<sup>[15-16]</sup>。SSIM 与 PSNR 越高、FID 越低,说明生成图像在解剖结构与细节纹理上更接近真实影像。Wang 等<sup>[14]</sup>在 PET 到 CT 跨模态合成中提出双阶段生成器 GAN,通过多损失函数优化与局部判别器设计,显著提升了 SSIM 和 PSNR,并降低了 FID 值,表明在图像结构与纹理精度方面取得良好效果。

在定量评估上,特定任务 (如衰减校正、解剖一致性) 的数值或几何精准度更受关注。例如,Rao 等<sup>[5]</sup>从延迟显像 PET 生成伪 CT 并配合非刚性配准,使生成影像在 PSNR、平均绝对百分比误差等指标上优于传统 GAN 方法。但需指出,这些指标主要是“图像-图像”的技术性评估,并不能直接说明对临床诊断或治疗决策的实际影响。

2. 临床效益评价。与图像质量评价侧重技术指标不同,临床效益评价主要关注生成影像对提高病灶检测灵敏度、特异度,降低辐射剂量等的实用价值<sup>[17]</sup>。常见做法是将生成的影像与真实 PET 或常规 CT 进行对比,看其对诊断准确性、治疗决策乃至患者预后有无显著影响。若要充分验证跨模态生成对临床路径的改进,仍需要大规模、多中心的前瞻

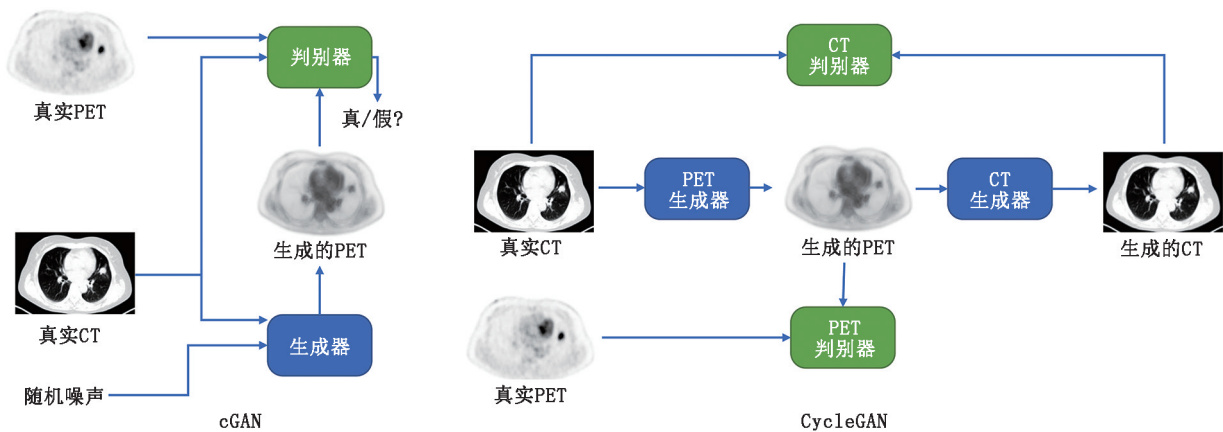


图 1 条件生成对抗网络 (cGAN) 与循环生成对抗网络 (CycleGAN) 在 CT 到 PET 跨模态生成中的示意图

性研究,并结合患者随访及经济效益分析进行综合评估。

### 三、CT 与 PET 影像生成的临床应用

#### 1. CT 生成 PET 影像在肿瘤诊断与治疗随访中的应用。

(1) 初诊与分期:解剖-功能融合的早期诊断。跨模态生成在肿瘤初诊与分期中的价值已获初步验证。Salehjahromi 等<sup>[18]</sup>在多中心肺癌队列(1 478 例)中利用 cGAN 模型,将常规 CT 转换为仿真 PET 影像,结果显示合成 PET 与真实 PET 的 SUV、肿瘤代谢体积等关键指标高度相关(相关系数最高达 0.95),在肺结节良恶性辨别中带来 2%~5% 的准确性增益。该团队还发现生成的“高代谢区”能成功再现真实 PET 在基因组学分析中对应的关键通路富集(如上皮-间质转化、血管生成等侵袭相关途径),提示合成影像在功能层面具有一定生物学可信度。进一步的对照试验发现,CT+合成 PET 与 CT+真实 PET 在肺癌分期准确性上非常接近(66.7%与 70%),2 名医师的分期一致性达 87%<sup>[18]</sup>。该研究表明,当无法及时或充分获得真实 PET 时,通过 GAN 生成的 PET 可在初诊与分期阶段起到一定的辅助作用。

其他研究也报道了类似结果:Ben-Cohen 等<sup>[4,19]</sup>将全卷积网络与 cGAN 相结合,降低了近 30% 的肝脏病灶检测时的假阳性数,并提高了诊断灵敏度与特异性。Liebgott 等<sup>[20]</sup>的研究则表明,在时序差异较大的 CT 上通过 GAN 预测出的 FDG 摄取仍具有较高准确性,为初诊时难以获得真实 PET 检查的场景提供了可行的无创评估手段。

(2) 疗效评估与随访监测:动态代谢应答的观察。在肿瘤治疗过程中,CT 生成 PET 同样能帮助追踪病灶代谢变化,用于评估疗效或早期发现复发。Salehjahromi 等<sup>[18]</sup>指出,若治疗后合成 PET 的 SUV 仍显著偏高,与真实 PET 组一样提示预后较差;反之,若代谢指标随疗程明显下降,则提示较好的应答效果。其他研究者也提出,GAN 合成 PET 可用于区分治疗后残余活性病灶与瘢痕组织,在无法频繁进行真实 PET 扫描的情况下,通过随访 CT 推断代谢信息,能够减少辐射和经济负担<sup>[4,20]</sup>。

由此可见,CT 生成 PET 在肿瘤初诊与分期中可增强早期检出与功能评估效果,也能在治疗随访时提供代谢信息以指导临床决策。尽管多数研究尚处小规模试点阶段,大规模多中心试验和长期随访数据仍有待积累,但其通过融合 CT 解剖信息与 PET 代谢优势的应用前景值得期待。

2. PET 生成 CT 影像在 PET/CT 检查辐射剂量降低中的应用。在 PET/CT 检查中,CT 扫描主要用于衰减校正和解剖定位,但产生的电离辐射对儿童、孕妇以及需多次复查的恶性肿瘤患者带来潜在风险<sup>[21-23]</sup>。文献估计 CT 可占 1 次 PET/CT 总有效剂量的 40%~60%,具体比例取决于扫描协议(如低剂量 CT 仅数 mSv,而全剂量诊断 CT 可达 10 mSv 甚至更高)。若能利用 AI 生成的伪 CT 影像替代真实 CT,则患者整体辐射暴露可望明显减少<sup>[24]</sup>。Li 等<sup>[24]</sup>使用 Pix2Pix 模型从非衰减校正 PET 影像生成与真实 CT 高度相似的伪 CT,所得图像不仅在解剖结构细节和 SUV 定量上与真实图像吻合度较高,而且能够有效降低多次复查患者的累计辐射剂量。Dong 等<sup>[25]</sup>在 PET/MR 环境下用三维 CycleGAN 生成 CT,结果骨骼与软组织密度精度明显提升,也为全身衰减校正提供了可行方案。量化结果提示,可使 1 次检查的有效剂

量减少约 4~8 mSv(针对低剂量 CT 基准),若患者需长期随访,则累计可减少 10~20 mSv 的 X 线暴露<sup>[24-25]</sup>。

需要指出的是,GAN 在生成伪 CT 的过程中仍存在潜在误差风险。一旦在骨或肺部等高对比区域出现偏差,可能导致病灶定位不准或 SUV 校正偏差<sup>[24]</sup>;另有个案报道出现对小病灶的漏检或对某些组织摄取的高估情形,提示在实际应用中仍需结合医师经验、补充低剂量 CT 或其他成像方式予以交叉验证<sup>[25]</sup>。至于 AI 生成影像的责任归属,现行法律和指南尚无明确界定,多国学者呼吁加快制订医疗 AI 监管框架。总体而言,GAN 技术在降低辐射剂量的同时,可在多数解剖区域保持较好的 SUV 精度,为 PET/CT 检查提供替代方案,但仍亟需更多大规模多中心研究及法规完善,以确保临床应用的安全性与可行性。

### 四、面临的挑战

当前 CT 与 PET 跨模态生成技术仍面临多重挑战。(1) 数据与泛化能力不足。现有公开数据主要集中于常见病种,在罕见病或复杂病理(如异质性转移瘤)上样本有限,模型在小样本场景下难以泛化<sup>[26]</sup>。未来可结合元学习、数据增强及联邦学习等隐私保护机制<sup>[27]</sup>,促进多中心数据共享并提升对罕见病的学习能力。(2) 模型可解释性与实时性不佳。GAN 等深度网络仍是“黑箱”,难以追溯生成过程及判别依据<sup>[28-29]</sup>,且需要高端图形处理单元(graphics processing unit, GPU)及较长推理时间,在资源有限的机构中部署受限。(3) 标准化与跨机构适配性缺乏。不同设备型号、扫描协议及重建算法导致影像差异,模型在跨中心、跨设备时准确性与一致性尚待验证。有必要建立统一的质量评估与临床验证流程,如美国食品与药品监督管理局(Food and Drug Administration, FDA)/欧洲合格认证要求,并在数据预处理、训练及后处理上形成规范。(4) 临床接受度尚不高。多中心大样本验证不足,医师对 GAN 生成影像的可靠性持观望态度,相关技术尚需更多前瞻性研究来验证其安全性与可行性。

### 五、总结与展望

GAN 在 CT 与 PET 跨模态影像生成中的应用已取得可观进展,为降低辐射剂量、改善图像质量和辅助临床诊断带来了新的机遇。然而,数据不足(尤其罕见病或复杂病理)、模型可解释性与标准化不足是主要瓶颈。未来应着力于小样本学习策略、模型轻量化与可视化,并通过多中心数据共享与联邦学习推动跨设备、跨协议的一致性验证,逐步完善跨机构适配与法规监管。随着技术与临床的进一步融合,跨模态生成在精准医疗及早期筛查等方面有望发挥更大作用,推动临床影像诊断迈向新的高度。

**利益冲突** 所有作者声明无利益冲突

**作者贡献声明** 邵小南:论文撰写;牛荣、高建雄、葛欣宇:论文修改;王跃涛、周军:研究指导、论文修改、经费支持

### 参 考 文 献

- [1] Al-Sharif ZT, Al-Sharif TA, Al-Sharif NT, et al. A critical review on medical imaging techniques (CT and PET scans) in the medical field [J]. IOP Conf Ser: Mater Sci Eng, 2020, 870: 012043. DOI:10.1088/1757-899X/870/1/012043.
- [2] 吴环华,陈少波,尚靖杰,等.基于深度神经网络的颞叶癫痫<sup>18</sup>F-FDG PET 术后复发预测研究[J].中华核医学与分子影像杂志,

- 2024, 44(4): 220-224. DOI: 10.3760/cma.j.cn321828-20231228-00150.
- Wu HH, Chen SB, Shang JJ, et al. Deep neural networks analysis of  $^{18}\text{F}$ -FDG PET imaging in postoperative patients with temporal lobe epilepsy[J]. Chin J Nucl Med Mol Imaging, 2024, 44(4): 220-224. DOI:10.3760/cma.j.cn321828-20231228-00150.
- [3] Armanious K, Jiang C, Fischer M, et al. MedGAN: medical image translation using GANs[J]. Comput Med Imaging Graph, 2020, 79: 101684. DOI:10.1016/j.compmedimag.2019.101684.
- [4] Ben-Cohen A, Klang E, Raskin SP, et al. Cross-modality synthesis from CT to PET using FCN and GAN networks for improved automated lesion detection[J]. Eng Appl Artif Intell, 2019, 78: 186-194. DOI:10.1016/j.engappai.2018.11.013.
- [5] Rao F, Wu Z, Han L, et al. Delayed PET imaging using image synthesis network and nonrigid registration without additional CT scan[J]. Med Phys, 2022, 49(5): 3233-3245. DOI:10.1002/mp.15574.
- [6] Anaya-Isaza A, Mera-Jiménez L, Zequera-Diaz M. An overview of deep learning in medical imaging[J]. Inform Med Unlocked, 2021, 26: 100723. DOI:10.1016/j.imu.2021.100723.
- [7] Bir P, Balas VE. A review on medical image analysis with convolutional neural networks[C]//2020 IEEE international conference on computing, power and communication technologies (GUCON), Great Noida, 2020: 870-876. DOI:10.1109/GUCON48875.2020.9231203.
- [8] Yaqub M, Jinchao F, Arshid K, et al. Deep learning-based image reconstruction for different medical imaging modalities[J]. Comput Math Methods Med, 2022, 2022: 8750648. DOI:10.1155/2022/8750648.
- [9] Dayarathna S, Islam KT, Uribe S, et al. Deep learning based synthesis of MRI, CT and PET: review and analysis[J]. Med Image Anal, 2024, 92: 103046. DOI:10.1016/j.media.2023.103046.
- [10] Honkamaa J, Khan U, Koivukoski S, et al. Deformation equivariant cross-modality image synthesis with paired non-aligned training data[J]. Med Image Anal, 2023, 90: 102940. DOI:10.1016/j.media.2023.102940.
- [11] Isola P, Zhu JY, Zhou T, et al. Image-to-image translation with conditional adversarial networks[C]//2017 IEEE conference on computer vision and pattern recognition (CVPR), Honolulu, 2017: 5967-5976. DOI:10.1109/CVPR.2017.632.
- [12] Zhu JY, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//2017 IEEE international conference on computer vision (ICCV), Venice, 2017: 2242-2251. DOI:10.1109/ICCV.2017.244.
- [13] Yurt M, Dalmaz O, Dar S, et al. Semi-supervised learning of MRI synthesis without fully-sampled ground truths[J]. IEEE Trans Med Imaging, 2022, 41(12): 3895-3906. DOI:10.1109/TMI.2022.3199155.
- [14] Wang H, Wang X, Liu F, et al. DSG-GAN: a dual-stage-generator-based GAN for cross-modality synthesis from PET to CT[J]. Comput Biol Med, 2024, 172: 108296. DOI:10.1016/j.compbiomed.2024.108296.
- [15] Sara U, Akter M, Uddin MS. Image quality assessment through FSIM, SSIM, MSE and PSNR—a comparative study[J]. J Comput Commun, 2019, 7(3): 8-18. DOI:10.4236/jcc.2019.73002.
- [16] Heusel M, Ramsauer H, Unterthiner T, et al. GANs trained by a two time-scale update rule converge to a local nash equilibrium[C]//NIPS'17: proceedings of the 31st international conference on neural information processing systems, 2017: 6629-6640.
- [17] Theruvath AJ, Siedek F, Yermeni K, et al. Validation of deep learning-based augmentation for reduced  $^{18}\text{F}$ -FDG dose for PET/MRI in children and young adults with lymphoma[J]. Radiol Artif Intell, 2021, 3(6): e200232. DOI:10.1148/ryai.2021200232.
- [18] Salehjahromi M, Karpinets TV, Sujit SJ, et al. Synthetic PET from CT improves diagnosis and prognosis for lung cancer: proof of concept[J]. Cell Rep Med, 2024, 5(3): 101463. DOI:10.1016/j.xcrm.2024.101463.
- [19] Ben-Cohen A, Klang E, Raskin SP, et al. Virtual PET images from CT data using deep convolutional networks: initial results[C]//Tsaftaris SA, Gooya A, Frangi AF, et al. Simulation and synthesis in medical imaging. SASHIMI 2017. Lecture notes in computer science, vol 10557. Switzerland: Springer, Cham, 2017: 49-57. DOI:10.1007/978-3-319-68127-6\_6.
- [20] Liebgott A, Hindere D, Armanious K, et al. Prediction of FDG uptake in lung tumors from CT images using generative adversarial networks[C]//2019 27th European signal processing conference (EUSIPCO), A Coruna, 2019: 1-5. DOI:10.23919/EUSIPCO.2019.8902935.
- [21] 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.
- [22] Bagherzadeh S, MirDerikvand A, MohammadSharifi A. Evaluation of radiation dose and radiation-induced cancer risk associated with routine CT scan examinations[J]. Radiat Phys Chem, 2024, 217: 111521. DOI:10.1016/j.radphyschem.2024.111521.
- [23] Bosch de Basea M, Thierry-Chef I, Harbron R, et al. Risk of hematological malignancies from CT radiation exposure in children, adolescents and young adults[J]. Nat Med, 2023, 29(12): 3111-3119. DOI:10.1038/s41591-023-02620-0.
- [24] Li Q, Zhu X, Zou S, et al. Eliminating CT radiation for clinical PET examination using deep learning[J]. Eur J Radiol, 2022, 154: 110422. DOI:10.1016/j.ejrad.2022.110422.
- [25] Dong X, Wang T, Lei Y, et al. Synthetic CT generation from non-attenuation corrected PET images for whole-body PET imaging[J]. Phys Med Biol, 2019, 64(21): 215016. DOI:10.1088/1361-6560/ab4eb7.
- [26] Röglin J, Ziegeler K, Kube J, et al. Improving classification results on a small medical dataset using a GAN; An outlook for dealing with rare disease datasets[J]. Front Comput Sci, 2022, 4: 858874. DOI:10.3389/fcomp.2022.858874.
- [27] Li T, Sahu AK, Talwalkar A, et al. Federated learning: challenges, methods, and future directions[J]. IEEE Sig Process Mag, 2020, 37(3): 50-60. DOI:10.1109/MSP.2020.2975749.
- [28] Murad NY, Hasan MH, Azam MH, et al. Unraveling the black box: a review of explainable deep learning healthcare techniques[J]. IEEE Access, 2024, 12: 66556-66568. DOI:10.1109/ACCESS.2024.3398203.
- [29] ŞAHİN E, Arslan NN, Özdemir D. Unlocking the black box: an in-depth review on interpretability, explainability, and reliability in deep learning[J]. Neural Comput & Applic, 2025, 37: 859-965. DOI:10.1007/s00521-024-10437-2.

(收稿日期:2025-02-12)