

# 深度学习重建方法改善快速采集 PET 图像质量的临床研究

胡琳君 胡奕奕 郭彬威 梁梦 郝新忠 秦志星 李思进 武志芳

山西医科大学第一医院核医学科、分子影像精准诊疗省部共建协同创新中心,太原 030001

通信作者:武志芳, Email: wuzhifang01@163.com

**【摘要】** 目的 通过深度学习(DL)PET图像重建方法,提升不同采集时间 $^{18}\text{F}$ -脱氧葡萄糖(FDG)PET图像质量。方法 回顾性分析2020年9月至10月间山西医科大学第一医院核医学科45例恶性肿瘤患者[男20例、女25例,年龄(52.0±13.6)岁]PET图像。选择原始列表模式PET数据的短时30 s/床位PET图像作为输入,采用Unet网络,以全剂量标准采集时间(3 min)PET图像为模型判别标准,建立DL图像重建模型,以预测全剂量PET图像。分别对DL、30 s、90 s和120 s 4组图像进行图像质量评估及定量分析。采用5分法主观评估4组的图像质量。分别测量各组图像肝本底及肿瘤病灶定量参数:最大标准摄取值( $\text{SUV}_{\text{max}}$ )、平均标准摄取值( $\text{SUV}_{\text{mean}}$ )、标准差(SD)、信噪比(SNR)、对比度噪声比(CNR)及一阶纹理特征(偏度、峰度、均匀度和熵)。采用Kappa检验、 $\chi^2$ 检验、单因素方差分析(最小显著差异 $t$ 检验)进行数据分析。结果 4组图像质量评分具有高度一致性(Kappa=0.799, $P<0.001$ ),DL组评分 $\geq 3$ 分共6例,30 s、90 s和120 s组评分 $\geq 3$ 分别有4、7和8例( $\chi^2=125.47$ , $P<0.001$ )。DL组肝SD明显低于30 s组(0.26±0.07与0.43±0.11; $F=3.58$ , $t=-7.91$ , $P<0.05$ ),SNR高于30 s组(11.04±4.36与5.41±1.41; $F=10.22$ , $t=5.40$ , $P<0.05$ );DL组肝SD及SNR与90 s组一致(0.39±0.16, 8.46±3.34; $t$ 值:-0.87和2.17,均 $P>0.05$ )。在18个高摄取肿瘤病灶中,DL组病灶SNR及CNR均高于30 s组(60.21±29.26与38.38±16.54, 22.26±15.85与15.41±9.51; $F$ 值:13.09和7.05, $t$ 值:5.20和4.04,均 $P<0.001$ )。4组肝一阶纹理特征差异有统计学意义( $F$ 值:4.30~9.65,均 $P<0.05$ ),但DL组与120 s组间差异无统计学意义( $t$ 值:-1.25~0.15,均 $P>0.05$ )。结论 DL重建模型能较好地改善短帧PET图像质量,可以满足临床诊断、疗效评估和组学研究的需求。

**【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;脱氧葡萄糖

**基金项目:**国家自然科学基金(81971655);山西省科学技术厅基础平台项目(201805D131010)

DOI:10.3760/cma.j.cn321828-20210514-00164

## Clinical study of deep learning reconstruction to improve the quality of rapidly acquired PET images

Hu Linjun, Hu Yiyi, Guo Binwei, Liang Meng, Hao Xinzong, Qin Zhixing, Li Sijin, Wu Zhifang

Department of Nuclear Medicine, the First Hospital of Shanxi Medical University; Collaborative Innovation Center of Molecular Imaging Precision Diagnosis and Treatment, Taiyuan 030001, China

Corresponding author: Wu Zhifang, Email: wuzhifang01@163.com

**【Abstract】 Objective** To improve the quality of  $^{18}\text{F}$ -fluorodeoxyglucose (FDG) PET images at different acquisition times through deep learning (DL) PET image reconstruction methods. **Methods** A total of 45 patients (20 males, 25 females; age (52.0±13.6) years) with malignant tumors and PET/CT scans from September 2020 to October 2020 in the Department of Nuclear Medicine of the First Hospital of Shanxi Medical University were included in this retrospective study. The short acquisition time 30 s/bed PET images from the raw list mode were selected as the input of DL model. DL image reconstruction model, based on the Unet algorithm, was trained to output imitated PET images with full dose standard acquisition time (3 min). The image quality evaluation and quantitative analysis were carried out for four groups of images: DL images, 30 s, 90 s, and 120 s images, respectively. The quality of PET images in four groups was evaluated using the five-point method. Liver background activities, lesions quantification parameters (maximum standardized uptake value ( $\text{SUV}_{\text{max}}$ ), mean standardized uptake value ( $\text{SUV}_{\text{mean}}$ ), standard deviation (SD), signal-to-noise ratio (SNR), contrast-to-noise ratio (CNR)), and first-order texture features (skewness, kurtosis, uniformity, entropy) were measured. Kappa test,  $\chi^2$  test and one-way analysis of variance (least significant difference  $t$  test) were used for data analysis. **Results** The image quality scores between four groups were highly consistent (Kappa=0.799,  $P<0.001$ ). The number of patients with scores  $\geq 3$  in DL, 30 s, 90 s and

120 s groups were 6, 4, 7 and 8, respectively ( $\chi^2 = 125.47, P < 0.001$ ). The liver SD of DL group was significantly lower than that of 30 s group ( $0.26 \pm 0.07$  vs  $0.43 \pm 0.11$ ;  $F = 3.58, t = -7.91, P < 0.05$ ). The liver SNR of DL group was higher than that of 30 s group ( $11.04 \pm 4.36$  vs  $5.41 \pm 1.41$ ;  $F = 10.22, t = 5.40, P < 0.05$ ). The liver SD and SNR of DL group were similar to those of 90 s group ( $0.39 \pm 0.16, 8.46 \pm 3.34$ ;  $t$  values:  $-0.87$  and  $2.17$ , both  $P > 0.05$ ). In 18 tumor lesions with high uptake, SNR and CNR of DL group were significantly higher than those of 30 s group ( $60.21 \pm 29.26$  vs  $38.38 \pm 16.54, 22.26 \pm 15.85$  vs  $15.41 \pm 9.51$ ;  $F$  values:  $13.09$  and  $7.05$ ;  $t$  values:  $5.20$  and  $4.04$ , both  $P < 0.001$ ). There were statistically significant differences among four groups in the first-order texture features ( $F$  values:  $4.30-9.65$ , all  $P < 0.05$ ), but there was no significant difference between DL group and 120 s group ( $t$  values: from  $-1.25$  to  $0.15$ , all  $P > 0.05$ ). **Conclusion** DL reconstruction model can improve the quality of short-frame PET images, which meets the needs of clinical diagnosis, efficacy evaluation and radiomics research.

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

**Fund program:** National Natural Science Foundation of China (81971655); Basic Platform Project of Shanxi Provincial Department of Science and Technology(201805D131010)

DOI:10.3760/cma.j.cn321828-20210514-00164

对于部分患者(如儿童或无法长时间保持平卧的检查者)来说,适当缩短 PET 检查时间很有必要。如何在保证图像质量和图像诊断效能的前提下缩短采集时间是目前 PET 研究领域的热点。深度学习(deep learning, DL)重建是一种新的智能化重建方法,其将神经网络引入到重建流程,使 PET 图像质量得到明显提高<sup>[1-2]</sup>。但 DL 在改善 PET 低剂量图像质量的同时是否影响肿瘤定量准确性还有待探索。本研究对比分析了 DL 和不同采集时间 PET 图像本底及病灶定量参数和纹理参数,现报道如下。

## 资料与方法

1. 患者资料。回顾性收集 2020 年 9 月至 10 月间于山西医科大学第一医院核医学科行 PET/CT 的恶性肿瘤患者 45 例,其中男 20 例、女 25 例,年龄( $52.0 \pm 13.6$ )岁。45 例患者中,肺癌 12 例,结直肠癌 7 例,胃癌、淋巴瘤各 6 例,前列腺癌 5 例,乳腺癌 2 例,中枢神经系统肿瘤、口腔癌、甲状腺癌、肾癌、卵巢癌、宫颈癌、黑色素瘤各 1 例。本研究符合《赫尔辛基宣言》的原则。

2. PET/CT 显像及重建方法。采用美国 GE Discovery MI PET/CT 仪,<sup>18</sup>F-脱氧葡萄糖(fluorodeoxyglucose, FDG)由日本住友公司 HM-10 型回旋加速器生产。患者检查前禁食 4~6 h,血糖水平处于正常范围,按患者体质量静脉注射<sup>18</sup>F-FDG 3.7 MBq/kg,安静休息 50~70 min 行全身显像。扫描范围自颅底至股骨中部。PET 显像采用列表模式,3 min/床位,5~7 个床位。将 PET 列表模式数据按照 30 s、90 s 和 120 s 进行重建,重建参数均为有序子集最大期望值迭代法-飞行时间-点扩散函数-正则化算法,惩罚因子  $\beta = 350$ <sup>[3]</sup>。

3. DL 重建。(1)数据预处理。采用全局归一

化处理,提取短时间(30 s)扫描得到的每个断层图像及其前、后各  $N$  层图像,构成图像块输入模型。训练阶段提取 3 min 显像 PET 目标图像及其前后各  $N$  层图像作为标签数据;预测阶段取中间层目标断层图像作为网络的预测结果。

(2)模型结构。模型结构设计基于 Pixel2Pixel 框架<sup>[4]</sup>。① PET 图像生成网络。采用调整后的 Unet 网络,Unet 编码器下采样 3 次,共下采样 8 倍;对称地,其解码器部分相应上采样 3 次,将编码器得到的高级语义特征图恢复到原图像分辨率,并在同一个阶段使用跳跃连接,恢复出来的特征图融合了更多低级别及不同维度的图像特征,从而进行多尺度预测。②长时间扫描真实图像(3 min)和模型重建的图像判别模型。真实图像和生成图像按不同的前后顺序拼接,输入判别网络,如[真实图像 生成图像]对应的判别标签为[1, 0]。判别网络采用多层卷积神经网络(convolutional neural networks, CNN)卷积层堆叠构建得到,经多次卷积下采样后,拉直得到的特征,经过 2 层全连接层输出预测真实 3 min 图像和生成的 3 min 图像的判别概率。

(3)损失函数。①生成模型训练阶段的损失函数基于 L1 损失,如公式 1。

$$L_G = \frac{1}{N} \sum_{i=1}^n a_i \times |y_{i \text{ 预测}} - y_i| \dots\dots\dots \text{公式 1}$$

$y_{i \text{ 预测}}$  表示生成模型重建的第  $i$  层图像, $y_i$  表示真实的第  $i$  层图像归一化后真实的体素值, $a_i$  表示第  $i$  层图像的权重, $N$  表示图像层数。

②判别式模型训练阶段的损失函数是二进制交叉熵损失函数,如公式 2。

$$L_D = P \times \log Q - (1-P) \times \log(1-Q) \dots\dots\dots \text{公式 2}$$

$P$  表示 0~1 标签(0:表示图像来源于模型生成;1:表示图像来源于真实图像), $Q$  表示判别模型预测的

概率。

③由生成模型和判别模型得到最终损失函数,如公式 3。

$$L_{GAN} = \text{ArgMin}_G \max_D [E(\log(L_D(g, y))) + E(\log(1 - L_D(g, y)))] + E(\log(L_G(x))) \dots\dots\dots \text{公式 3}$$

公式中,ArgMin 为求全局最小值的函数,GAN 为对抗神经网络(generative adversarial network)。当生成模型输出的图像越来越逼近真实图像,生成模型 G 的损失越来越小,而判别模型 D 的损失越来越大,从而实现训练的优化过程。

(4)图像后处理阶段。①将网络预测得到的所有图像层面按顺序拼接起来,根据原始输入数据的最大值最小值,将 0~1 的结果输出,映射回 PET 图像的数据范围。

(5)共收集 45 例数据,采用 7:2 的比例随机分为训练集和测试集,35 例用于训练,10 例用于测试。

4. PET 图像视觉评估。由 2 位经验丰富的 PET/CT 医师盲法对各组 PET 图像质量进行主观视觉评分<sup>[5]</sup>。采用 5 级评分法,即 1 分不合格、2 分合格、3 分中等、4 分良好及 5 分优秀;意见不一致时,再引入第 3 位医师协商评价,以至少 2 位医师取得一致意见为最终结果。

5. PET 图像的半定量分析。应用影像组学智能应用平台软件(AK3.3.0R)对肝本底进行感兴趣体积(volume of interest, VOI)及肿瘤病灶三维(three-dimensional, 3D)靶区勾画。在 CT 上于肝右叶测量最大径 3 cm VOI,自动测量最大标准摄取值(maximum standardized uptake value, SUV<sub>max</sub>)、平均标准摄取值(mean standardized uptake value, SUV<sub>mean</sub>)、标准差(standard deviation, SD),计算肝信噪比(signal-to-noise ratio, SNR),并以肝为本底,计算肿瘤病灶 SNR、对比度噪声比(contrast-to-noise ratio, CNR)。同时提取肝及病灶 VOIs 的一阶纹理特征(偏度、峰度、均匀度、熵)。

6.统计学处理。采用 IBM SPSS 22.0 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 Kappa、 $\chi^2$  检验、单因素方差分析(最小显著差异 *t* 检验)进行数据分析。 $P < 0.05$  为差异有统计学意义。

### 结 果

1.图像质量的视觉评估。在 DL、30 s、90 s 和 120 s 组间,2 名医师的视觉评分具有高度一致性(Kappa = 0.799, 95% CI: 0.724 ~ 0.874,  $P < 0.001$ )。DL 组视觉评分  $\geq 3$  分者 6 例,30 s、90 s 和 120 s 组视觉评分  $\geq 3$  分别有 4、7 和 8 例。不同组间的视觉评分构成差异有统计学意义( $\chi^2 = 125.47, P < 0.001$ )。

2.不同组别肝本底及肿瘤病灶的定量参数比较(表 1)。对于肝本底定量参数,DL 组肝 SD 低于 30 s 组,但高于 120 s 组( $F = 3.58, t$  值: -7.91 和 6.60, 均  $P < 0.05$ );DL 组肝 SNR 高于 30 s 组( $F = 10.22, t = 5.40, P < 0.05$ );DL 组肝 SD 及 SND 与 90 s 组一致( $t$  值: -0.87 和 2.17, 均  $P > 0.05$ )。对于肿瘤病灶定量参数,<sup>18</sup>F-FDG 高摄取肿瘤病灶 18 个,DL 组病灶 SNR、CNR 均高于 30 s 组,上述参数均低于 120 s 组( $F$  值: 13.09 和 7.05,  $t$  值: 5.20 和 4.04, 均  $P < 0.05$ );余比较差异均无统计学意义( $t$  值: -0.69 ~ 0.08, 均  $P > 0.05$ )。

3.不同组别 PET 一阶纹理特征的比较(表 2)。DL 组肝本底的偏度、峰度、均匀度较 30 s 和 90 s 组均降低( $F$  值: 4.48 ~ 9.65,  $t$  值: -4.93 ~ -2.92, 均  $P < 0.05$ )、熵较 30 s 和 90 s 组有所增高( $F = 4.30, t$  值: 2.76 和 4.19, 均  $P < 0.05$ );但 DL 组各参数与 120 s 组差异均无统计学意义( $t$  值: -1.25 ~ 0.15, 均  $P > 0.05$ )。对于肿瘤病灶,DL 组与各组偏度、峰度、均匀度、熵的差异均无统计学意义( $F$  值: 0.34 ~ 0.70, 均  $P > 0.05$ )。

表 1 不同组别肝本底( $n = 45$ )和肿瘤病灶( $n = 18$ )PET 定量参数的对比( $\bar{x} \pm s$ )

组别	肝本底			肿瘤		
	SD	SNR	SNR	CNR	SUV <sub>mean</sub>	SUV <sub>max</sub>
DL 组	0.26±0.07	11.04±4.36	60.21±29.26	22.26±15.85	8.07±3.66	14.17±7.09
30 s 组	0.43±0.11 <sup>a</sup>	5.41±1.41 <sup>a</sup>	38.38±16.54 <sup>a</sup>	15.41±9.51 <sup>a</sup>	7.71±3.29	13.66±5.88
90 s 组	0.39±0.16	8.46±3.34	58.45±24.61	24.34±17.00	7.40±3.07	12.67±4.61
120 s 组	0.20±0.05 <sup>a</sup>	11.89±3.53	82.99±34.31 <sup>a</sup>	35.37±20.57 <sup>a</sup>	7.70±2.99	12.51±4.79
<i>F</i> 值	3.58	10.22	13.09	7.05	0.40	0.49
<i>P</i> 值	0.02	<0.01	<0.01	<0.01	0.75	0.69

注: CNR 为对比度噪声比, DL 为深度学习, SD 为标准差, SNR 为信噪比, SUV<sub>max</sub> 为最大标准摄取值, SUV<sub>mean</sub> 为平均标准摄取值; <sup>a</sup> 与 DL 组比较  $P < 0.001$

表 2 不同重建方法组肝本底( $n=45$ )和肿瘤病灶( $n=18$ )PET 一阶纹理特征的对比( $\bar{x}\pm s$ )

组别	肝本底				肿瘤病灶			
	偏度	峰度	均匀度	熵	偏度	峰度	均匀度	熵
DL 组	1.86±0.32	2.83±0.23	1.81±0.11	6.00±0.07	3.97±0.38	2.61±0.96	2.88±1.24	5.42±0.57
30 s 组	5.45±2.92 <sup>a</sup>	3.73±0.76 <sup>a</sup>	2.09±0.32 <sup>a</sup>	5.83±0.21 <sup>a</sup>	4.37±0.41	2.79±0.73	3.20±1.43	5.25±0.61
90 s 组	3.13±1.68 <sup>a</sup>	3.23±0.35 <sup>a</sup>	2.01±0.12 <sup>a</sup>	5.87±0.08 <sup>a</sup>	4.74±0.46	2.77±1.35	3.08±1.73	5.37±0.67
120 s 组	2.06±0.63	2.89±0.34	1.83±0.14	6.00±0.09	4.91±0.47	2.89±1.44	3.25±1.45	5.45±0.63
F 值	9.65	8.45	4.48	4.30	0.42	0.34	0.70	0.58
P 值	<0.01	<0.01	0.01	0.01	0.74	0.80	0.56	0.63

注:DL 为深度学习,30、90、120 s 指将 PET 列表模式数据按 30、90、120 s 重建;<sup>a</sup>与 DL 组比较  $P<0.05$

## 讨 论

近年来,DL 在医学图像分析领域引起了越来越多的关注<sup>[6-7]</sup>。基于 DL 的算法在低剂量 CT 重建和去噪过程中取得了很好的效果<sup>[8-9]</sup>,最近也有研究针对低剂量 PET 图像采用神经网络模型进行图像质量恢复或去噪<sup>[10-12]</sup>。Wang 等<sup>[11]</sup>应用基于 3D 条件生成 GAN (3D-conditional GAN, 3D-cGAN) 的端到端框架,根据低剂量 PET 图像得到了高质量的 PET 图像。Kaplan 和 Zhu<sup>[7]</sup>利用 CNN 从 1/10 剂量 PET 图像预测全剂量 PET 图像,该模型将损失函数中的特定图像特征考虑在内,得到了较好的边缘和结构细节。Ouyang 等<sup>[12]</sup>同样使用 GAN 从超低剂量图像生成标准剂量的淀粉样蛋白 PET 图像,利用峰值 SNR、结构相似性和均方根误差 (root mean square error, RMSE) 评估图像质量,也获得了可比的结果。以上几种重建模型均是基于 3D 图像进行的,重建速度较慢,对硬件要求相对高。

本研究尝试应用 Unet 网络、采用对称的跳跃连接结构,将低层信息直接复制到高层特征图上,进行不同维度、尺度预测,得到了更精细的图像细节。同时,网络训练参考 PchGAN 方式,每次只输入任意 1 个层面前后  $N$  层的图像层面集合,相比直接输入整个 3D 图像进行训练,减少了训练中的参数量,降低了对硬件的要求。采用该法本研究成功利用 30 s 扫描时间的 PET 图像预测出全剂量 (90 s、120 s) PET 图像,提示该 DL 重建模型在减少低剂量 PET 数据噪声和改善 SNR 方面具有巨大潜力。

与同样采用 Unet 网络进行 DL 重建的研究相比<sup>[13]</sup>,本研究除了基于 30 s 短帧 (约 30%) PET 数据作为输入,还应用标准剂量 3 min 的 PET 数据作为“金标准”,保证 Unet 网络中的定量精度。本研究纳入患者的肿瘤非单一病种,结果提示该法在合理的噪声水平范围内具有较强的鲁棒性,这对于将来应用于多样化患者群体至关重要。Lu 等<sup>[13]</sup>采用

10% 全剂量 PET 数据作为输入,从 10% 剂量水平恢复的图像在正常组织中仍具有良好的 RMSE 和 SNR,但病变组织  $SUV_{mean}$  和  $SUV_{max}$  的 SD 要大得多,因此需谨慎应用这 2 个指标进行临床判断。

DL 组肿瘤病灶的  $SUV_{max}$ 、 $SUV_{mean}$ ,与 30 s、90 s 及 120 s 组比较差异均无统计学意义,提示本研究 DL 模型在尽量恢复低剂量 PET 图像的同时,能保证定量精度,并提高了病灶 SNR 和 CNR。考虑到纳入病例较少、病灶较小,未进一步根据肿瘤大小行亚组分析。此外,对肝本底及肿瘤病灶一阶纹理特征进行的评估显示,DL 组与 120 s 组在偏度、峰度、均匀度和熵方面的差异均无统计学意义。这可能归因于在模型预测和判别训练的过程中分别增加了 L1 和二进制交叉熵损失函数<sup>[12,14]</sup>,有效恢复 30 s PET 原始图像的代谢信息;而对图像一阶纹理特征的改善,表明该模型代谢信息的恢复并不是简单的线性差值或超采样,而是将 3 min PET 图像的各像素间真实的代谢相关性应用于 30 s 原始图像。也有研究提出,将相应 CT 或 MRI 图像同时作为输入训练模型,可以保持更多的形态细节<sup>[14-15]</sup>。

该模型适用性限制于硅光电倍增管数字化 PET/CT 设备及基于正则化重建算法获得的数据。此外,本研究样本量不足,需进一步增加训练数据集,并开展相关多中心的研究来验证 DL 模型的泛化性。综上,本研究采用的 DL 重建模型能较好地改善短帧 PET 图像质量,可以满足临床诊断、疗效评估和组学需求。

利益冲突 所有作者均声明不存在利益冲突

## 参 考 文 献

- [1] Higaki T, Nakamura Y, Tatsugami F, et al. Improvement of image quality at CT and MRI using deep learning [J]. Jpn J Radiol, 2019, 37(1): 73-80. DOI:10.1007/s11604-018-0796-2.
- [2] Chen KT, Schürer M, Ouyang J, et al. Generalization of deep learning models for ultra-low-count amyloid PET/MRI using transfer learning [J]. Eur J Nucl Med Mol Imaging, 2020, 47(13): 2998-3007. DOI: 10.1007/s00259-020-04897-6.

- [3] 林乐军,王永涛,姚小芹,等. BPL 重建技术对  $^{18}\text{F}$ -FDG PET/CT 正常组织的代谢参数及图像质量的影响[J]. 中华核医学与分子影像杂志, 2021, 41(3): 155-160. DOI: 10.3760/cma.j.cn321828-20200218-00050.  
Lin LJ, Wang YT, Yao XQ, et al. Impact of Bayesian penalized likelihood algorithm on the metabolism parameters and image quality in  $^{18}\text{F}$ -FDG PET/CT background tissues[J]. Chin J Nucl Med Mol Imaging, 2021, 41(3): 155-160. DOI:10.3760/cma.j.cn321828-20200218-00050.
- [4] 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; IEEE, 2017: 5967-5976. DOI:10.1109/CVPR.2017.632.
- [5] Messerli M, Stolzmann P, Egger-Sigg M, et al. Impact of a Bayesian penalized likelihood reconstruction algorithm on image quality in novel digital PET/CT: clinical implications for the assessment of lung tumors[J]. EJNMMI Phys, 2018, 5(1): 27. DOI:10.1186/s40658-018-0223-x.
- [6] Akagi M, Nakamura Y, Higaki T, et al. Deep learning reconstruction improves image quality of abdominal ultra-high-resolution CT [J]. Eur Radiol, 2019, 29(11): 6163-6171. DOI: 10.1007/s00330-019-06170-3.
- [7] Kaplan S, Zhu YM. Full-dose PET image estimation from low-dose PET image using deep learning: a pilot study[J]. J Digit Imaging, 2019, 32(5): 773-778. DOI:10.1007/s10278-018-0150-3.
- [8] Chen H, Zhang Y, Zhang W, et al. Low-dose CT via convolutional neural network[J]. Biomed Opt Express, 2017, 8(2): 679-694. DOI:10.1364/BOE.8.000679.
- [9] 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.
- [10] 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.
- [11] Wang Y, Yu B, Wang L, et al. 3D conditional generative adversarial networks for high-quality PET image estimation at low dose [J]. Neuroimage, 2018, 174: 550-562. DOI:10.1016/j.neuroimage.2018.03.045.
- [12] Ouyang J, Chen KT, Gong E, et al. Ultra-low-dose PET reconstruction using generative adversarial network with feature matching and task-specific perceptual loss[J]. Med Phys, 2019, 46(8): 3555-3564. DOI:10.1002/mp.13626.
- [13] Lu W, Onofrey JA, Lu Y, et al. An investigation of quantitative accuracy for deep learning based denoising in oncological PET[J]. Phys Med Biol, 2019, 64(16): 165019. DOI: 10.1088/1361-6560/ab3242.
- [14] Chen KT, Gong E, de Carvalho Macruz FB, et al. Ultra-low-dose  $^{18}\text{F}$ -florbetaben amyloid PET imaging using deep learning with multi-contrast MRI inputs[J]. Radiology, 2019, 290(3): 649-656. DOI:10.1148/radiol.2018180940.
- [15] Xiang L, Qiao Y, Nie D, et al. Deep auto-context convolutional neural networks for standard-dose PET image estimation from low-dose PET/MRI[J]. Neurocomputing, 2017, 267: 406-416. DOI: 10.1016/j.neucom.2017.06.048.

(收稿日期:2021-05-14)

## · 读者 · 作者 · 编者 ·

## 2021 年本刊可直接用缩写的常用词汇

ATP(adenosine-triphosphate),三磷酸腺苷

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

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

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

SPECT(single photon emission computed tomography),单光子发射计算机体层摄影术

WBC(white blood cells),白细胞

WHO(World Health Organization),世界卫生组织

本刊编辑部