

基于成像切片连续性的PET直接生成CT的衰减校正算法

郑涵元, 葛荣骏, 何升级, 李楠

引用本文

郑涵元, 葛荣骏, 何升级, 李楠. [基于成像切片连续性的PET直接生成CT的衰减校正算法](#)[J]. 计算机科学, 2025, 52(10): 115-122.

ZHENG Hanyuan, GE Rongjun, HE Shengji, LI Nan. [Direct PET to CT Attenuation Correction Algorithm Based on Imaging Slice Continuity](#) [J]. Computer Science, 2025, 52(10): 115-122.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[面向肿瘤早期诊断的延迟PET图像重建:多模态PET/CT核矩阵约束延迟成像算法](#)

Delayed PET Reconstruction for Early Tumor Diagnosis:Multimodal PET/CT Nuclear Matrix-constrained Delayed Imaging Algorithm

计算机科学, 2025, 52(9): 119-127. <https://doi.org/10.11896/jsjcx.250400037>

[基于ESC-TransUNet网络的脑出血CT图像分割](#)

CT Image Segmentation of Intracranial Hemorrhage Based on ESC-TransUNet Network

计算机科学, 2025, 52(6A): 240700030-9. <https://doi.org/10.11896/jsjcx.240700030>

[基于双向多层级交互网络的肺部CT图像分类](#)

Bi-MI ViT:Bi-directional Multi-level Interaction Vision Transformer for Lung CT ImageClassification

计算机科学, 2025, 52(6A): 240700183-6. <https://doi.org/10.11896/jsjcx.240700183>

[基于解释Petri网的新型CPS分解方法](#)

New Decomposition Method for Cyber-Physical Systems Based on Interpreted Petri Nets

计算机科学, 2025, 52(4): 49-53. <https://doi.org/10.11896/jsjcx.241000103>

[基于边缘增强的选择性特征融合肾癌三维CT图像分割](#)

Selective Feature Fusion for 3D CT Image Segmentation of Renal Cancer Based on Edge Enhancement

计算机科学, 2025, 52(3): 41-49. <https://doi.org/10.11896/jsjcx.240300091>

基于成像切片连续性的 PET 直接生成 CT 的衰减校正算法

郑涵元¹ 葛荣骏² 何升级³ 李楠⁴

1 南京航空航天大学人工智能学院 南京 211106

2 东南大学仪器科学与工程学院 南京 210096

3 赛诺联合医疗科技(北京)有限公司 北京 100192

4 江苏赛诺格兰医疗科技有限公司 江苏 扬州 225200

(njzhenghy@nuaa.edu.cn)

摘要 PET 衰减校正技术在临床上具有重要意义,其能够有效降低癌症误诊率并制定更为精确的治疗计划。然而,传统的 PET 衰减校正方法面临扫描时间较长和后期处理引入误差等问题,限制了其应用范围。近期,基于 PET 直接生成 CT 的衰减校正方法凭借更短的扫描时长和无后期处理误差的优势,逐渐流行于临床应用。然而,由于 PET 与 CT 之间的语义差异巨大且不对齐,使得 PET 直接生成 CT 的衰减方法在模态生成中面临着巨大的挑战。针对这一挑战,提出了一种基于 Cycle-S2SCT-Net 生成网络的 PET 衰减校正方法。Cycle-S2SCT-Net 在整体上借助循环生成对抗结构学习 PET 与 CT 分布变换映射,实现了 PET 与 CT 两种模态间的语义转换。在单个生成对抗网络内部,Cycle-S2SCT-Net 集成了成像切片连续性模块,以增强网络的语义对齐能力,从而提高生成成像的连续性和准确性。此外,还引入了网络特征层损失函数(Layer Loss),以增强生成网络的特征提取能力。实验结果表明,Cycle-S2SCT-Net 生成的 CT 及其衰减校正后的 PET,在定量评估指标峰值信噪比(PSNR)、结构相似性(SSIM)、均方根误差(RMSE),以及可视化结果上均表现出色。

关键词: PET; 衰减校正方法; CT; 切片连续性; 循环生成对抗

中图分类号 TP391

Direct PET to CT Attenuation Correction Algorithm Based on Imaging Slice Continuity

ZHENG Hanyuan¹, GE Rongjun², HE Shengji³ and LI Nan⁴

1 College of Artificial Intelligence, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China

2 College of Instrument Science and Engineering, Southeast University, Nanjing 210096, China

3 SinoUnion Healthcare Inc., Beijing 100192, China

4 Jiangsu Sinogram Medical Technology Co., Ltd., Yangzhou, Jiangsu 225200, China

Abstract PET attenuation correction technology is of significant clinical importance, effectively reducing cancer misdiagnosis rates and enabling more precise treatment planning. However, traditional PET attenuation correction methods face challenges such as long scan times and errors introduced during post-processing, limiting their applicability. Recently, attenuation correction methods based on directly generating CT from PET have gained popularity in clinical settings due to shorter scan times and the advantage of avoiding post-processing errors. However, the substantial semantic differences and misalignment between PET and CT pose significant challenges for direct PET-to-CT attenuation methods in modal generation. To address this challenge, this paper proposes a PET attenuation correction method based on Cycle-S2SCT-Net. Cycle-S2SCT-Net utilizes a cyclic generative adversarial structure to learn the mapping between PET and CT distributions, facilitating semantic translation between the two modalities. Within a single generative adversarial network, Cycle-S2SCT-Net integrates an imaging slice continuity module to enhance the network's semantic alignment capability, thereby improving the continuity and accuracy of generated images. Additionally, this paper introduces a network feature layer loss function(Layer Loss) to enhance the feature extraction capability of the generation network. The experimental results demonstrate that CT generated by Cycle-S2SCT-Net and its attenuation-corrected PET exhibit excellent performance in both quantitative evaluation metrics, such as peak signal-to-noise ratio(PSNR), structural similarity index(SSIM), root mean square error(RMSE), and visual quality.

到稿日期:2024-07-22 返修日期:2024-11-01

基金项目:国家自然科学基金(62101249);江苏省双创博士项目(JSSCBS20220202);中国博士后科学基金(2022M721611,2021TQ0149)

This work was supported by the National Natural Science Foundation of China(62101249), Jiangsu Province Double Innovation Doctoral Program(JSSCBS20220202) and China Postdoctoral Science Foundation(2022M721611,2021TQ0149).

通信作者:葛荣骏(rongjun_ge@seu.edu.cn)

Keywords PET, Attenuation correction methods, CT, Slice continuity, Cycle generative adversarial

1 引言

PET^[1]衰减校正技术能够提供更为精确的 PET 成像,从而帮助临床人员对器官代谢异常进行精确判断。PET 衰减校正^[2]技术借助于 CT 成像中的器官和骨骼信息对 PET 原始成像进行校正,从而消除了原始 PET 图像中组织和骨骼的不同衰减特性所导致的信号损失。将衰减校正后的 PET 应用于临床领域,能降低肿瘤疾病的误诊率,并能在后续监测中制定更精确的治疗计划。

目前,在临床层面应用较为成熟的 PET 衰减校正技术,可根据不同的获取方式分为两类:基于 PET/CT 的衰减校正和基于 PET/MRI 的衰减校正。基于 PET/CT 的方法直接借助 PET/CT 成像设备,采集患者的 PET 和 CT 数据,并利用采集到的 CT 成像对 PET 成像进行校正^[3]。基于 PET/MRI 的方法则借助 PET/MRI 成像设备,通过图像生成算法将 MRI 与 CT 进行图谱配准,最后使用转换得到的 CT 数据完成 PET 校正^[4-5],其主要包括 3 种方法:地图集法、机器学习方法^[6]以及近期流行的深度学习方法。Hofmann 等^[7]和 Uh^[8]等将患者的输入成像与脑显像的 MRI/CT 地图集数据进行配准得到生成 CT 数据,并借助该生成信息完成脑部 PET 衰减校正任务。而对于机器学习方法,Roy 等^[9]采用概率统计模型将 MR 合成 CT,并增加了 CT 和 MR 的配准。Andreasen 等^[10]使用随机森林方法,提取 MR 特征并将特征输出至 CT 空间。近期,随着深度学习的发展,PET/MRI 方法逐渐使用深度生成网络来完成这两种模态间的转换。Gong 等^[11]、Leynes 等^[12]和 Torrado-Carvajal 等^[13]借助 U 型神经网络来完成 MRI 生成至 CT 的任务,并且在实验中发现,借助深度神经网络方法能取得比目前现有方法更好的效果。

然而,现有的 PET 衰减校正技术由于其复杂的成像机理和多模态联合成像的特点,面临着扫描时间较长以及引入处理误差的问题。前述两类方法所使用的 PET/CT 和 PET/MR 多模态成像设备,不仅增加了设备采集和维护的费用,还延长了患者的扫描时长。在后期处理阶段,这两种方法分别需要将 PET/CT 数据对和 PET/MRI 数据对进行配准等预处理步骤,这些步骤容易引入处理误差,从而间接影响最终的衰减校正结果。因此,碍于扫描时间长、设备成本高和引入处理误差等问题,现有的衰减校正方法的临床应用范围受到了一定的限制。

近期,基于 PET 直接生成 CT 的 PET 衰减校正方法^[14],凭借其更快捷的 CT 获取方式和简洁的成像机理,拥有了扫描时长更短、设备成本更低且无后期处理误差的优势,逐渐在临床应用中普及开来。直接由 PET 生成 CT 的衰减方法仅需要 PET 单模态成像采集设备,大大缩短了扫描时间,降低了设备的采购和维护成本,使得扫描不耐受人群也可以进行临床诊断。此外,该方法不需要对多模态输入进行后期处理,从而避免了处理误差,加快了临床诊断流程,同时也帮助临床医生更精确地诊断机体代谢水平。

然而,基于 PET 直接生成 CT 的衰减校正方法则面临

PET 与 CT 分布之间语义差异巨大和语义不对齐这两个挑战,进一步增大了 PET 生成 CT 任务的难度。PET 成像主要通过检测体内放射性示踪剂的分布来反映人体的代谢活动和功能变化,提供关于器官和组织的代谢信息,具有较低的空间分辨率和较高的噪声水平。而 CT 成像通过不同组织对 X 射线的吸收差异生成清晰的横断面图像^[15],能够展示骨骼、血管以及软组织的解剖结构,具有高空间分辨率和精细的解剖学细节。此外,PET 和 CT 联合成像设备异步扫描的特点,可能导致同一位置上的 PET 和 CT 图像在解剖学特征上不一致,从而进一步影响网络训练数据的语义对齐。以上两个难点使得 PET 直接生成 CT 任务具有临床挑战性。

为了应对 PET 生成 CT 语义差异巨大的挑战,现有的方法^[14,16]均以生成对抗结构作为网络的基本架构,同时将 U-Net 作为生成器,以捕捉 PET 与 CT 成像间的深层和浅层特征,从而完成 PET 至 CT 的语义转换任务。但是,对于输入 PET 与 CT 成像语义不对齐,从而导致生成 CT 模糊、参差的挑战,现有的工作并未涉及。

为了在完成 PET 至 CT 的语义转换、提高生成 CT 分布质量的基础上,进一步增强模型的语义对齐性能,本文提出了含有切片连续性模块和循环生成结构的 PET 至 CT 生成网络,名为 Cycle-S2SCT-Net。本文方法的主要贡献有以下:

1)提出了成像切片连续性 Transformer 模块,将视觉 Transformer^[17]用于解决生成任务中语义不对齐的问题。该模块通过捕捉和整合相邻 PET 切片之间的相关性,使得生成网络能够获得更为精确的 PET 至 CT 映射参数,从而提高生成的 CT 图像的连续性和准确度。

2)将生成模型纳入循环结构中,通过对 PET 至 CT 的正向和逆向生成过程进行双向和统一的约束,完成 PET 至 CT 的语义转换,并减小生成 CT 分布与真实 CT 分布的差异。该循环结构的网络设计使得网络能更准确地刻画 PET 成像与 CT 成像间的分布迁移信息,使得网络在应对临床人体不同结构时能保持鲁棒性。

3)提出了一种新的网络中间特征层损失函数,旨在增强网络的特征提取能力。通过引入该损失函数,网络能够更加有效地学习生成网络中的成像特征,并递进式地提高网络在上采样的成像特征,从而最终增强生成网络的输出 CT 成像。

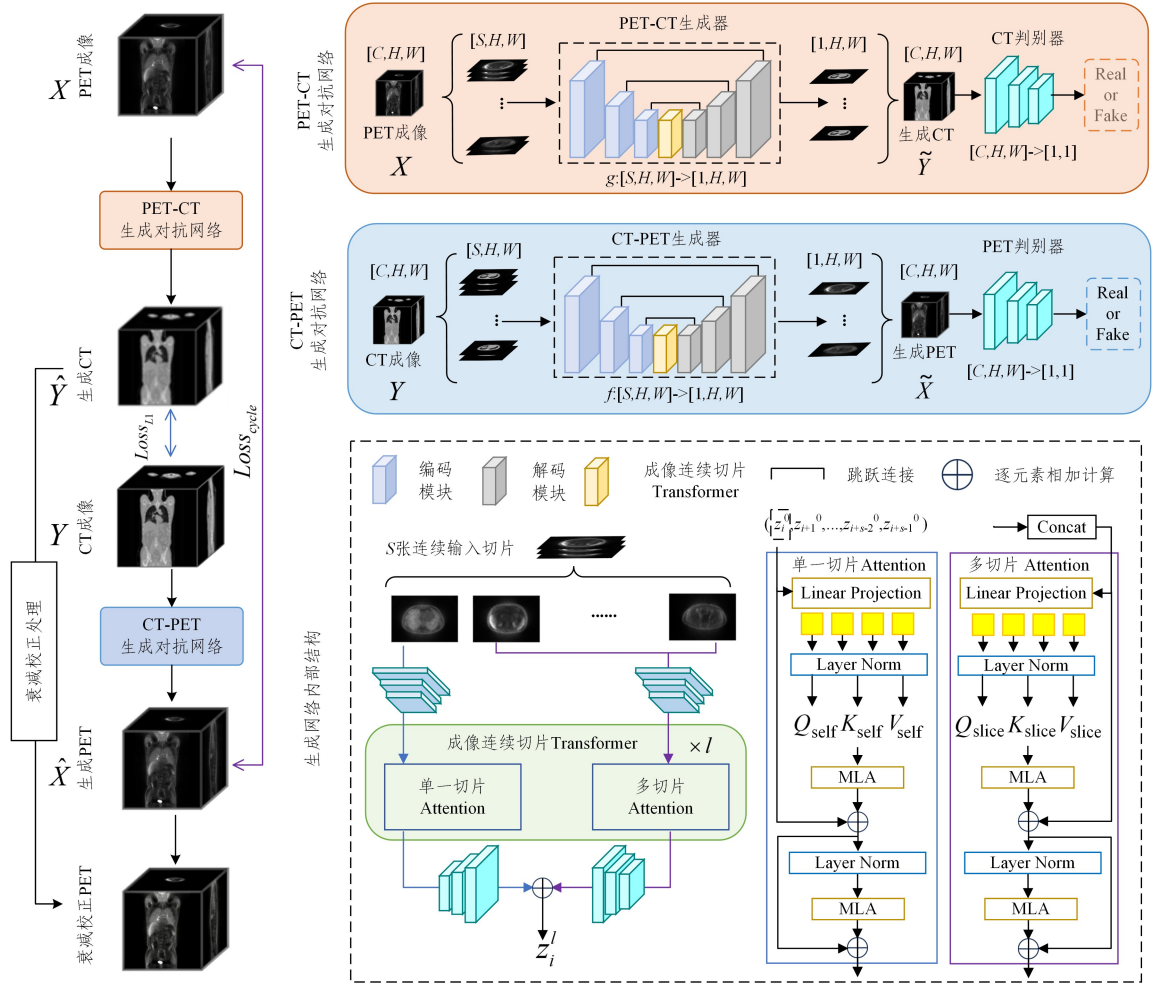
2 本文方法

为了应对 PET 直接生成 CT 任务中的横断面不连续,并提升输出 CT 分布的准确性,本文设计了 Cycle-S2SCT-Net 模型,其结构如图 1 所示。

首先,Cycle-S2SCT-Net 通过循环生成对抗网络^[18],即 PET 至 CT 和 CT 至 PET 的生成对抗网络,完成了 PET 至 CT 的语义转换,从而生成可用于临床衰减校正的 CT。通过这种双向生成过程进行局部和总体约束,从而确保 PET-CT 生成对抗网络语义转换性能。其次,在每个生成对抗网络内部,本文引入了成像切片连续性 Transformer 模块,以增强生成过程中 PET 和 CT 的语义对齐性。该模块通过捕捉和整

合相邻 PET 或 CT 成像切片之间的相关性,使生成网络能够更精确地完成 PET 与 CT 间的映射,从而增强生成 CT 图像的连续性和准确度。此外,为了提高生成网络的特征提取

能力,本文在生成网络的编码层嵌入了编码层损失函数。通过对编码层特征的约束,逐步提高网络在解码层的成像特征,从而提升最终生成 CT 的质量。



注:整个网络采用循环生成对抗结构,单个生成对抗内嵌入了成像连续成像切片 Transformer 层。

图1 Cycle-S2SCT-Net 的整体结构

Fig. 1 Overall structure of Cycle-S2SCT-Net

2.1 PET-CT 循环生成对抗网络

为了将 N 组包含 S 张切片的 PET 成像 $X = [x_1, x_2, \dots, x_s]$ 生成同样为 S 张切片的 CT 成像 $Y = [y_1, y_2, \dots, y_s]$, 完成 PET 至 CT 的语义转换, 本文设计了 PET-CT 循环生成对抗网络。该网络包含两个生成对抗子网络^[19], 分别是完成 PET 至 CT 转换的 PET-CT 子网络和完成 CT 至 PET 转换的 CT-PET 子网络。通过联合训练这两个子网络, Cycle-S2SCT-Net 能够学习 PET 与 CT 之间的风格迁移和语义差异信息。

PET-CT 子网络包含一个用于完成语义转换的生成器 $G_{\text{PET} \rightarrow \text{CT}}$ 和判断输出 CT 真实度的判别器 D_{CT} 。生成器 $G_{\text{PET} \rightarrow \text{CT}}$ 接受 PET 成像 X 作为输入, 并借助于 U-Net 结构提取 PET 成像的深浅像素特征, 输出生成 CT \tilde{Y} 。为了训练生成器, 使用了 $L_{\text{pixel}_{\text{PET} \rightarrow \text{CT}}}$ 损失函数, 以减小生成 CT 和真实 CT 像素级的语义差异, 进而完成 PET 至 CT 模态的语义转换:

$$L_{\text{pixel}_{\text{PET} \rightarrow \text{CT}}} = \frac{1}{N} \sum_{i=1}^N |\tilde{Y} - Y| + \beta_1 * \frac{1}{N} \sum_{i=1}^N |\tilde{Y} - Y|^2 \quad (1)$$

其中, β_1 为平衡生成 CT 的 L_1 与 L_2 损失函数的超参数。接着, PET-CT 子网络使用判别器 D_{CT} 评估生成的 CT 图像 \tilde{Y} 和真实的 CT 成像 Y 之间的差异, 帮助生成器学习生成更贴近于真实 CT 成像的图像。损失函数 $L_{\text{GAN}_{\text{PET} \rightarrow \text{CT}}}$ 定义如下:

$$L_{\text{GAN}_{\text{PET} \rightarrow \text{CT}}} = E_Y [\log D_{\text{CT}}(Y)] + E_X [\log(1 - D_{\text{CT}}(G_{\text{PET} \rightarrow \text{CT}}(X)))] \quad (2)$$

通过最小化生成器和判别器的损失函数, 使得 PET-CT 子网络在完成 PET 至 CT 的语义转换的同时, 还能提高生成 CT 的真实感, 从而增加生成 CT 的临床适用性。

对于用于完成 CT 至 PET 语义转换的 CT-PET 子网络, 该网络同样包含一个生成器 $G_{\text{CT} \rightarrow \text{PET}}$ 和用于判断生成 PET 真实程度的判别器 D_{PET} 。该子网络使用 U-Net 结构作为其生成网络, 并提取 PET-CT 子网络生成的 CT 成像 \tilde{Y} 的深浅像素特征, 最终转换为生成的 PET \tilde{X} 。为了使 CT-PET 子网络收敛, 本文分别使用生成器损失函数 $L_{\text{pixel}_{\text{CT} \rightarrow \text{PET}}}$ 和判别器损失函数 $L_{\text{GAN}_{\text{CT} \rightarrow \text{PET}}}$ 对网络进行训练。两个损失函数分别如下所示:

$$L_{\text{pixel}_{\text{CT} \rightarrow \text{PET}}} = \frac{1}{N} \sum_{i=1}^N |\tilde{X} - X| + \beta_2 * \frac{1}{N} \sum_{i=1}^N |\tilde{X} - X|^2 \quad (3)$$

$$L_{\text{GAN}_{\text{PET} \rightarrow \text{CT}}} = E_Y [\log D_{\text{CT}}(Y)] + E_X [\log(1 - D_{\text{CT}}(G_{\text{PET} \rightarrow \text{CT}}(X)))] \quad (4)$$

其中, β_2 为用于平衡生成 PET 的 L_1 与 L_2 损失函数的超参数。

最后, Cycle-S2SCT-Net 通过对两个子生成对抗网络进行联合训练, 并引入循环损失 L_{cycle} 来增强联合训练的效果, 使得循环生成对抗网络收敛。循环损失 L_{cycle} 定义如下:

$$L_{\text{cycle}} = \frac{1}{N} \sum_{i=1}^N (\|X - G_{\text{CT} \rightarrow \text{PET}}(G_{\text{PET} \rightarrow \text{CT}}(X)) + \|Y - G_{\text{PET} \rightarrow \text{CT}}(G_{\text{CT} \rightarrow \text{PET}}(\tilde{Y}))\|) \quad (5)$$

通过最小化循环损失, 使得 Cycle-S2SCT-Net 能够保证整体网络语义转换的输出一致性, 并能提高网络泛化能力, 从而更适用于临床任务。最终, 取 Cycle-S2SCT-Net 中 PET-CT 网络的输出 $\tilde{Y} = [\tilde{y}_1, \tilde{y}_2, \dots, \tilde{y}_s]$ 作为衰减校正所使用的 CT, 对原始 PET 成像进行校正。

2.2 成像切片连续性 Transformer 模块

2.2.1 单一切片 Attention

单一切片 Attention^[20] 机制可以有效捕捉单一成像切片内部的连续性和语义关系, 从而提高生成图像的准确性。对于通过编码层的切片张量 $\mathbf{z}_i^0 \in [1, H', W']$, 单一切片 Attention 将其进行裁剪、拼接和线性投影操作, 从而得到输入张量 $\mathbf{Z}_i^0 \in [N, P \times P]$, 其中 $N = \frac{H' \times W'}{P^2}$ 。之后, \mathbf{Z}_i^0 分别乘以权重矩阵 $\mathbf{W}_Q, \mathbf{W}_K, \mathbf{W}_V$, 从而得到对应的 $\mathbf{Q}_{\text{self}}, \mathbf{K}_{\text{self}}$ 和 \mathbf{V}_{self} 矩阵。单一切片的 Attention 表达式如下:

$$\text{Att}_{\text{single}} = \text{softmax}\left(\frac{\mathbf{Q}_{\text{single}} \mathbf{K}_{\text{single}}^T}{\sqrt{d}}\right) \mathbf{V}_{\text{single}} \quad (6)$$

当同一切面的 PET 成像切片和 CT 成像切片语义较为对齐时, 单一切片 Attention 能够让生成器聚焦于单切片内的语义连续性, 确保生成的图像在单个切片内部具有高度一致的语义关系。

2.2.2 多切片 Attention

多切片 Attention 机制通过捕捉多切片之间的关联性, 使得生成器能充分提取连续切片的语义差异特征, 从而使得网络可以更准确地对齐输入和输出切片。该机制以连续 s 张通过编码层的切片张量 $[\mathbf{z}_i^0, \mathbf{z}_{i+1}^0, \dots, \mathbf{z}_{i+s-1}^0] \in [s, H', W']$ 作为输入。之后, 对 s 个切片张量进行拼接预处理后, 得到拼接张量 $\mathbf{Z}^0 \in [s \times N, P \times P]$ 。在计算其 Attention 机制前, 用可学习矩阵 $\mathbf{M} \in [1 \times s, P \times P]$ 乘以 \mathbf{Z}^0 , 从而保证其尺度与 \mathbf{Z}_i^0 一致。其 Attention 表达式如下:

$$\text{Att}_{\text{multi}} = \text{softmax}\left(\frac{\mathbf{Q}_{\text{multi}} \mathbf{K}_{\text{multi}}^T}{\sqrt{d}}\right) \mathbf{V}_{\text{multi}} \quad (7)$$

当同一切面的 PET 成像切片和 CT 成像切片语义不对应时, 多切片 Attention 能够通过增强语义对齐来提高网络的生成效果, 从而扩大其临床适用范围。

最终, Cycle-S2SCT-Net 将上述两种 Attention 机制进行融合, 以帮助生成器更准确地理解和匹配输入与输出切片, 从而有效应对多模态异步成像中的语义对齐问题。

2.3 网络特征层损失函数 Layer Loss

为了提高成像切片连续性 Transformer 模块的性能, 同时增强 Cycle-S2SCT-Net 总体的语义转换效果, 本文引入了网络特征层损失函数 L_{layer} , 并将其嵌入至 PET-CT 子网络。该损失函数使得生成器聚焦于 U 型网络中间层的特征提取, 提高 Transformer 模块输入张量的准确度, 进而增强生成网络的输出成像质量。Layer Loss 损失函数结构如图 2 所示。

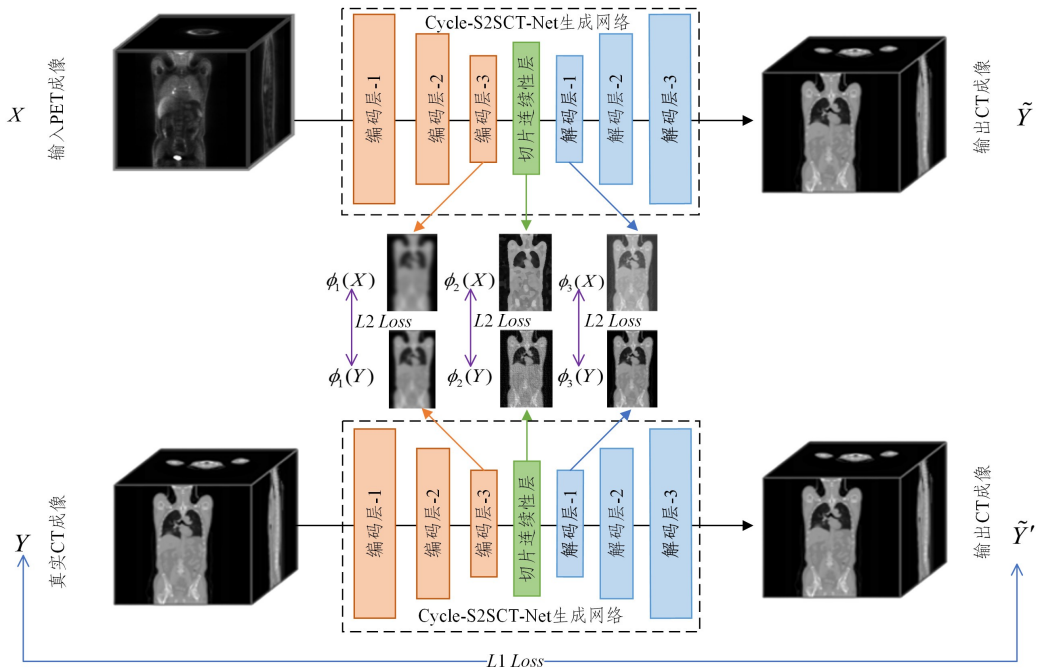


图2 网络特征层损失函数 Layer Loss 结构图

Fig. 2 Structural diagram of the network feature layer loss function Layer Loss

首先, 该损失函数约束生成器完成输出成像至输出成像的恒等映射。接着, 以该映射下的中间层特征作为

基准, 对输入成像的中间层特征进行约束。具体地, L_{layer} 的定义如下:

$$L_{\text{layer}} = \sum_l \alpha_l |\phi_l(X) - \phi_l(Y)|^2 + \sum_{i=1}^N |\tilde{Y}_i - Y| \quad (8)$$

其中, $\phi_l(\cdot)$ 表示 Unet^[21] 中间层第 l 层的特征层输出。通过在生成器中嵌入 L_{layer} , 从而帮助 PET-CT 生成器在特征空间内更好地学习 PET 图像到 CT 图像的映射关系, 确保生成的 CT 图像在特征表示上与真实 CT 图像更加接近, 从而提升生成质量和模型的泛化能力。

3 实验和结果

3.1 数据集

本文使用 50 对 PET/CT 数据对提出的 Cycle-S2SCT-Net 方法进行了定量和定性评估。该数据集来源于北京协和医院, 伦理审批号为 HS2015016。PET/CT 数据由 PoleStar m660 PET/CT 设备采样获取, 放射性葡萄糖注射剂 18F-FDG 剂量约为 0.1 mCi/kg, 注射时长为 180 s。每个 PET/CT 样本包括 386~589 张切片, 分辨率为 192×192 像素, PET/CT 体素大小为 $3.147 \times 3.147 \times 1.8665 \text{ mm}^3$ 。在实验前, 先对 CT 数据值进行截断, 将亨氏单位 (HU)^[22] 值固定在 $[-1024, 3072]$ 内。之后, 在预处理流程中, 引入了归一化, 以确保输入数据的缩放一致性, 同时增加了旋转和翻折处理操作, 对数据对进行了增广。本文将 Cycle-S2SCT-Net 模型与 4 种 PET 直接生成 CT 的衰减校正方法进行了比较, 分别是 Unet^[21], cGAN^[23], CycleCT^[16] 和 ASEG^[14]。

3.2 实验设置

实验使用单张显存为 24GB 的 Nvidia GeForce RTX 3090 显卡作为算力设备, 并使用 Python 3.9.2 版本与 PyTorch 2.3.1+CUDA11.8 软件环境对 Cycle-S2SCT-Net 进行了实现。在训练网络时, 采用 Adam 作为网络优化器, 并设置初始学习率为 1.0×10^{-4} , 其他超参数设置为 $\beta_1 = \beta_2 = 0.5$, $\alpha_1 = 1.0$, $\alpha_2 = 0.8$, $\alpha_3 = 0.4$ 。实验阶段还增加了步进学习率调度

器, 并让学习率每迭代一轮就乘以 0.9。

为评估 Cycle-S2SCT-Net 的性能, 本文采用以下指标评估生成 CT 和衰减校正 PET 的质量: 峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 结构相似性指数 (Structural Similarity Index, SSIM) 和均方根误差 (RMSE)。

PSNR 可以使用分贝以对数的形式表示生成图像和校正图像的质量, PSNR 的计算式如下:

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{\text{MAX}^2}{\text{MSE}} \right) \quad (9)$$

其中, MAX 是生成和真实成像的图像像素最大值, MSE 是前两者的均方误差。

SSIM 从亮度、对比度和结构 3 个方面衡量生成图像和真实成像间的相似性, 其表达式如下:

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (10)$$

其中, μ_x 和 μ_y 分别为图像 x 和 y 的平均值, σ_x^2 和 σ_y^2 分别为图像 x 和 y 的方差, σ_{xy} 为图像 x 和 y 的协方差, c_1 和 c_2 为稳定常数。

RMSE 则是计算生成和真实成像之间的标准化均方误差, 用于衡量两者之间的差异。其计算式如下:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N |\tilde{y}_i - y_i|^2} \quad (11)$$

其中, y_i 和 \tilde{y}_i 分别为真实和生成图像, N 表示图像的总像素数。

3.3 结果分析

3.3.1 CT 定量结果分析

将 Cycle-S2SCT-Net 与其他 4 种对比算法生成的 CT 按前述指标进行比较, 其结果如表 1 所列。将人分为头部、躯干部和腿部 3 部分, 并分别计算相应指标, 以便更全面地评估模型性能。

表 1 在 PET/CT 数据集上与其他方法生成 CT 的定量比较

Table 1 Quantitative comparison of CT generation with other methods on PET/CT dataset

Metric	Body-Part	Unet	cGAN	CycleCT	ASEG	Cycle-S2SCT-Net (Ours)
PSNR	Total-Body	35.14±0.55	35.02±0.18	34.96±0.26	35.37±0.63	35.58±0.52
	Head	31.74±0.88	31.15±0.26	31.07±0.73	31.29±0.97	32.03±0.69
	Torso	<u>36.51±0.25</u>	35.94±0.18	36.03±0.10	36.54±0.10	36.49±0.22
	Leg	<u>37.42±0.46</u>	36.19±0.03	36.07±0.57	37.39±0.64	37.47±0.43
RMSE	Total-Body	73.02±6.40	70.13±3.45	72.18±3.55	<u>69.04±5.69</u>	68.56±7.38
	Head	110.15±15.62	<u>108.24±7.61</u>	116.93±14.84	108.28±20.73	105.76±12.64
	Torso	58.14±1.04	57.50±2.71	57.47±1.31	56.31±1.07	<u>57.08±0.07</u>
	Leg	58.23±5.50	<u>64.70±3.15</u>	69.70±7.14	66.24±7.69	65.45±6.52
SSIM	Total-Body	94.17±0.11	94.02±0.07	93.91±0.18	<u>94.23±0.03</u>	94.30±0.07
	Head	92.12±0.82	91.74±0.12	90.90±0.77	91.51±0.16	<u>92.07±0.58</u>
	Torso	<u>94.46±0.06</u>	93.88±0.05	93.32±0.07	94.43±0.16	94.89±0.13
	Leg	<u>95.32±0.02</u>	94.82±0.13	94.16±0.21	95.06±0.32	95.49±0.16

注: 加粗表示最好的结果, 下划线表示次好的结果。

从结果来看, Cycle-S2SCT-Net 生成方法相比于其他算法性能, 取得了较为优越的量化结果。在全身和身体各部位 PSNR, RMSE 和 SSIM 指标上, Cycle-S2SCT-Net 基本取得了最佳和次佳的生成结果。

对于 cGAN, 虽然引入了生成对抗结构, 但由于未增强特征提取能力, cGAN 生成的 CT 图像在细节和结构上仍存在

不足, 无法达到预期的效果。

对于 CycleCT, 其通过循环一致性损失提高了生成图像的准确性, 但由于未能充分捕捉 PET 和 CT 图像之间的语义差异, 生成的 CT 图像质量仍有待提高。

对于 Unet, 其由于简单的结构和较少的参数, 能够捕捉 PET 至 CT 转换的体素级特征, 因此生成的 CT 指标位居前

列。ASEG 在捕捉 PET 至 CT 转换特征方面表现较好,但与 Cycle-S2SCT-Net 相比,缺乏切片连续性模块的增强,使其生成 CT 图像指标位居第二。

而 Cycle-S2SCT-Net 通过引入切片连续性 Transformer 模块和编码层损失函数,在特征提取和图像生成方面表现出色。生成的 PET 图像在细节保留、结构完整性和整体视觉效果上均优于其他对比方法。

3.3.2 CT 定性结果分析

为了获取直观的生成 CT 比较结果,以进一步验证模型




图 3 各 PET 衰减校正方法的生成 CT 视觉结果

Fig. 3 Visual results of CT generation for each PET attenuation correction method

在定性结果层面,Cycle-S2SCT-Net 通过引入切片连续性 Transformer 模块和编码层损失函数,有效提升了生成 CT 图像的整体和细节质量。该模块和损失函数能够增强网络的特征提取和语义对齐能力,从而生成更加准确和连续的 CT 图像。这使得 Cycle-S2SCT-Net 在 PET 衰减校正中表现出色,能够生成在临床上可用于衰减校正的高质量 CT 图像。

3.3.3 PET 衰减校正结果定量分析

为了评估 Cycle-S2SCT-Net 在 PET 衰减校正任务中的性能,本节将生成的 CT 图像应用于 PET 图像的衰减校正,其衰减 PET 指标结果如表 2 所列。表中指标是通过将每种算法的衰减校正结果与相应的真实 PET 衰减校正结果进行比较得出的。

表 2 各衰减校正方法对原始 PET 进行衰减校正后的定量比较
Table 2 Quantitative comparison of attenuation-corrected PET using different attenuation correction methods

Metric	Unet	cGAN	CycleCT	ASEG	Cycle-S2SCT-Net (Ours)
PSNR	46.45	44.81	<u>46.62</u>	46.53	48.78
RMSE	57.16	59.20	47.32	<u>45.59</u>	44.16
SSIM	99.64	99.71	<u>99.77</u>	99.64	99.80

注:加粗表示最好的结果,下划线表示次好的结果。

观察表 2 可知,Cycle-S2SCT-Net 在所有指标上分别达到了最佳结果;同时,对比方法 Unet, cGAN, CycleCT 和 ASEG 也取得了优良的衰减校正量化结果。其主要原因,实验中的 5 种生成方法都能弥补 PET 至 CT 成像间的语义

的性能,在图 3 中展示了不同方法生成的 CT 图像的直观比较结果,包括不同方法在冠状面、矢状面和横断面的生成的 CT 图像。其中,第一行为横断面结果对比,第二行为矢状面结果对比,最后一行为冠状面结果对比。

可以明显看出,Cycle-S2SCT-Net 和 ASEG 生成的 CT 图像在整体结构上均优于其他方法。而细节层面,Cycle-S2SCT-Net 相比于 ASEG 更优。特别是在细节处理和边缘保留方面,Cycle-S2SCT-Net 生成的图像更加清晰,结构更加完整。

鸿沟,使得生成的 CT 在解剖结构上与真实 CT 都较为近似,从而保证生成 CT 可以校正临床 PET 扫描成像。但除了弥补语义鸿沟外,Cycle-S2SCT-Net 还增加了语义增强模块,使得其生成的 CT 图谱在细节上更优于 4 种对比算法。这些细节优势在 PET 衰减校正步骤中也发挥了积极作用,最终提升了整个衰减校正算法流程的性能。

由 PET 衰减校正实验量化结果可以得出,Cycle-S2SCT-Net 的算法在衰减校正任务中取得了更为优良的性能,可以较为出色地完成 CT 生成和 PET 衰减校正任务,具有临床应用价值。

3.3.4 PET 衰减校正结果定性

为了展示 Cycle-S2SCT-Net 在 PET 衰减校正任务中的定性性能,本节将每种生成算法的 PET 衰减校正结果与真实 CT 图像生成的 PET 衰减校正结果进行了对比分析,如图 4 所示。其中,第一行为横断面结果对比,第二行为矢状面结果,最后一行为冠状面展示结果。

由视觉结果可知,Cycle-S2SCT-Net 方法较其他 4 种对比算法,在 PET 衰减校正结果上更贴近于用真实 CT 进行衰减校正后的 PET 结果。

对于 Unet, cGAN, CycleCT 和 ASEG 这 4 种对比算法的衰减校正结果,虽然在全身分布视觉上其结果与真实 CT 的衰减校正结果较为贴切,但在细节层面,例如人体的咽喉与肺部区域,其定性结果有一定的视觉差异。

得益于 Cycle-S2SCT-Net 生成的 CT 图像的质量高,因此在借助生成的 CT 进行衰减校正后的 PET 图像质量更

接近于真实 CT 衰减校正的结果。尤其是在喉部和肺部, Cycle-S2SCT-Net 方法的效果明显优于其他衰减校正方法。

通过对衰减校正后的 PET 进行分析,充分证明了利用 Cycle-S2SCT-Net 衰减校正对原始 PET 进行校正后,能够获得高质量的临床可用 PET 图像,因此具有临床应用价值。




图 4 各 PET 衰减校正方法的衰减 PET 视觉结果

Fig. 4 Visual results of attenuation-corrected PET for each PET attenuation correction method

结束语 本文提出了基于 Cycle-S2SCT-Net 的 PET 衰减校正方法,显著提高了 CT 生成的精度和衰减校正后的 PET 图像质量。具体地嵌入循环生成对抗结构:

利用循环生成对抗网络结构,实现了 PET 与 CT 之间的高效语义转换,提升了生成图像的质量和连续性。引入了成像切片连续性模块,增强了网络的语义对齐能力,进一步提高了生成成像的准确性。

采用了网络特征层损失函数(Layer Loss),增强了生成网络的特征提取能力,使生成的 CT 图像在定量评估指标上表现优异。实验结果表明,Cycle-S2SCT-Net 在定量评估指标和视觉效果上均表现出色,证明了其在临床应用中的潜力。

但是,在临床 PET 衰减校正场景中,本文算法还以下方向还有待改进:首先,在临床 PET 扫描中往往会产生运动伪影,因而需要 PET 衰减校正模型具有抗伪影鲁棒性能,以应对不同场景下的病患 PET 输入;其次,Cycle-S2SCT-Net 模型的时空复杂度较高,而临床场景下为了降低患者等待时长和设备采购成本,需要在保证算法性能的前提下进一步降低时空复杂度。在后续的衰减校正研究中,将尝试从上述两个方向进行改进。

参考文献

[1] CHERRY S R, DAHLBOM M, PHELPS M E. PET: Physics, Instrumentation, and Scanners[M]. New York: Springer, 2006.

[2] WAHL R L. To AC or not to AC; that is the question [J]. Journal of Nuclear Medicine Official Publication Society of Nuclear Medicine, 1999, 40(12): 2025-2028.

[3] KINAHAN P E, TOWNSEND D W, BEYER T, et al. Attenuation correction for a combined 3D PET/CT scanner[J]. Medical Physics, 1998, 25(10): 2046-2053.

[4] HOFMANN M, STEINKE F, SCHEEL V, et al. MRI-Based At-

tenuation Correction for PET/MRI: A Novel Approach Combining Pattern Recognition and Atlas Registration[J]. Journal of Nuclear Medicine, 2008, 49(11): 1875-1883.

[5] SCHULZ V, TORRES-ESPALLARDO I, RENISCH S, et al. Automatic, three-segment, MR-based attenuation correction for whole-body PET/MR data [J]. European Journal of Nuclear Medicine and Molecular Imaging, 2011, 38(1): 138-152.

[6] GAO Y, ZHAO J H. The research progress of PET/MR attenuation correction technology [J]. China Medical Equipment, 2015, 30(7): 75-78.

[7] HOFMANN M, STEINKE F, SCHEEL V, et al. MRI-Based Attenuation Correction for PET/MRI: A Novel Approach Combining Pattern Recognition and Atlas Registration[J]. Journal of Nuclear Medicine, 2008, 49(11): 1875-1883.

[8] UH J, MERCHANT T E, LI Y, et al. MRI-based treatment planning with pseudo CT generated through atlas registration [J]. Medical Physics, 2013, 41(5): 051711.

[9] ROY S, CARASS A, JOG A, et al. MR to CT registration of brains using image synthesis[C]// Proceedings of SPIE: the International Society for Optical Engineering, 2014.

[10] ANDREASEN D, EDMUND J M, ZOGRAFOS V, et al. Computed tomography synthesis from magnetic resonance images in the pelvis using multiple random forests and auto-context features[C]// Medical Imaging 2016: Image Processing. SPIE, 2016.

[11] GONG K, YANG J, KIM K, et al. Attenuation correction for brain PET imaging using deep neural network based on dixon and ZTE MR images[J]. Physics in Medicine & Biology, 2018, 63(12): 125011.

[12] LEYNES A P, YANG J, WIESINGER, F, et al. Zero-Echo-Time and Dixon Deep Pseudo-CT (ZeDD CT): Direct Generation of

- Pseudo-CT Images for Pelvic PET/MRI Attenuation Correction Using Deep Convolutional Neural Networks with Multiparametric MRI[J]. *Journal of Nuclear Medicine*, 2018, 59(5):852-858.
- [13] TORRADO-CARVAJAL A, VERA-OLMOS J, IZQUIERDO-GARCIA D, et al. Dixon-VIBE Deep Learning (DIVIDE) Pseudo-CT Synthesis for Pelvis PET/MR Attenuation Correction [J]. *Journal of Nuclear Medicine*, 2019, 60(3):429-435.
- [14] PAN Y, LIU F, JIANG C, et al. Revealing Anatomical Structures in PET to Generate CT for Attenuation Correction[C]// *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer, 2023:24-33.
- [15] KALENDER W A. X-ray computed tomography[J]. *Physics in Medicine & Biology*, 2006, 51(13):R29.
- [16] DONG X, WANG T, LEI Y, et al. Synthetic CT generation from non-attenuation corrected PET images for whole-body PET imaging[J]. *Physics in Medicine & Biology*, 2019, 64(21):215016.
- [17] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[J]. *arXiv*:2010.11929, 2020.
- [18] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C] // *Proceedings of the IEEE International Conference on Computer Vision*. 2017:2223-2232.
- [19] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11):139-144.
- [20] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]// *Advances in Neural Information Processing Systems*. 2017.
- [21] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]// *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer, 2015:234-241.
- [22] DENOTTER T D, SCHUBERT J. Hounsfield unit[M]. *StatPearls Publishing*, 2025.
- [23] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J]. *arXiv*:1411.1784, 2014.



ZHENG Hanyuan, born in 2000, post-graduate. His main research interests include medical image reconstruction and deep learning.



GE Rongjun, born in 1992, Ph.D, associate professor, is a member of CCF (No. 13248M). His main research interests include deep learning, intelligent reconstruction and analysis of medical image.

(责任编辑:柯颖)