

基于三维深度分离网络的PET双示踪剂混合图像分离方法

唐大洋^{1,2}, 胡德斌², 齐宏亮², 孙浩¹, 韩彦江³, 李翰威², 张新明^{1,2}, 潘智林², 喻文杰^{1,2}, 路利军¹, 陈宏文^{1,2}

1. 南方医科大学生物医学工程学院, 广东 广州 510515; 2. 南方医科大学南方医院医学工程科, 广东 广州 510515; 3. 南方医科大学南方医院PET中心, 广东 广州 510515

【摘要】目的:提出一种基于三维深度分离网络方法用于¹⁸F-FDG和¹⁸F-FAPI PET双示踪剂混合图像分离成像。**方法:**收集120例同一患者在不同时间单独扫描的¹⁸F-FDG和¹⁸F-FAPI PET图像,本研究采用模拟的形式生成PET双示踪剂混合图像,首先对同一患者两种PET示踪剂图像进行配准保证空间位置匹配,然后对配准的PET图像进行前向投影生成弦图数据,将两种弦图数据累加得到混合弦图数据,随后采用最大似然期望法重建得到PET双示踪剂混合图像,输入到基于3D DSN架构的网络进行分离成像,从而得到两种单示踪剂的PET图像。**结果:**本文提出的方法相较于3D CNN方法,分离得到的¹⁸F-FDG图像与真实¹⁸F-FDG图像的结构相似性指数(SSIM)提升0.87%,峰值信噪比(PSNR)提升11.8%,归一化均方根误差(NRMSE)减小52%。分离得到的¹⁸F-FAPI图像与真实¹⁸F-FAPI图像的SSIM提升1.1%,PSNR提升17.0%,NRMSE减小51%。**结论:**本文方法可以很好地应用在PET双示踪剂同时成像上,减少患者的扫描次数、时间和金钱成本,为临床医生提供更精准和更丰富的诊断信息。

【关键词】正电子发射断层成像; 双示踪剂成像; 图像配准; 深度分离网络; 深度学习

【中图分类号】R318;R817

【文献标志码】A

【文章编号】1005-202X(2025)02-0160-07

Dual-tracer PET image separation using three-dimensional depthwise separable convolution network

TANG Dayang^{1,2}, HU Debin², QI Hongliang², SUN Hao¹, HAN Yanjiang³, LI Hanwei², ZHANG Xinming^{1,2}, PAN Zhilin², YU Wenjie^{1,2}, LU Lijun¹, CHEN Hongwen^{1,2}

1. School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China; 2. Department of Clinical Engineering, Nanfang Hospital, Southern Medical University, Guangzhou 510515, China; 3. PET Center, Nanfang Hospital, Southern Medical University, Guangzhou 510515, China

Abstract: Objective To propose a novel method based on three-dimensional depthwise separable convolution network (3D DSN) for the separation of PET images with dual tracers of ¹⁸F-FDG and ¹⁸F-FAPI. **Methods** A total of 120 pairs of ¹⁸F-FDG and ¹⁸F-FAPI PET images of the same patient scanned separately at different time points were collected, and the dual-tracer PET image was generated through simulation. After the image registration of PET images of two tracers for ensuring spatial position matching, the registered PET images were forward-projected to generate sinogram data, and the sinogram data of two tracers were accumulated to obtain mixed sinogram data. Subsequently, the dual-tracer PET image was reconstructed using maximum likelihood expectation maximization and input into a 3D DSN based network for image separation, thereby obtaining PET images of two single tracers. **Results** Compared with 3D CNN method, the proposed method increased the structure similarity index measure (SSIM) of the separated ¹⁸F-FDG images to the real ¹⁸F-FDG images by 0.87%, increased the peak signal-to-noise ratio (PSNR) by 11.8%, and reduced the normalized root mean square error (NRMSE) by 52%. The SSIM of the separated ¹⁸F-FAPI images to the real ¹⁸F-FAPI images increased by 1.1%, PSNR increased by 17.0%, and NRMSE decreased by 51%. **Conclusion** The proposed method can be effectively applied to simultaneous PET imaging with dual PET tracers, reducing the number of scans and costs in time and money, and providing clinical doctors more accurate and abundant diagnostic information.

Keywords: positron emission computed tomography; dual-tracer imaging; image registration; depthwise separable convolution network; deep learning

【收稿日期】2024-08-15

【基金项目】国家重点研发计划(2023YFC2414601); 广东省医学会医学工程学分会青年委员会基金(2022-GDMAYB-05); 南方医科大学南方医院院长基金(2022B016)

【作者简介】唐大洋, 硕士, 研究方向: PET 成像, E-mail: 2735430380@qq.com

【通信作者】陈宏文, 教授, 硕士生导师, 研究方向: 医疗器械质量控制管理, E-mail: chw47922@126.com

前言

正电子发射断层成像 (Positron Emission Computed Tomography, PET) 技术是核医学领域一种重要的临床检查方式, 广泛应用于肿瘤学^[1]、脑成像^[2]、心脏病学等领域^[3-5]。临床上, 单次检查通常是注射一种示踪剂进行成像诊断, 因此只能对人体内的某一种生理过程进行探究。然而, 人体不同生理功能变化会导致疾病由多种因素造成, 不同因素或者生理功能变化的诊断可能需要不同的示踪剂, 临床上医生能够获得的信息越全面, 越有利于疾病的诊断^[6]。不同示踪剂提供的信息往往相互促进或互为互补, 两者结合能够更好地辅助诊断, 提高诊断的准确性, 进而具有重要的临床意义。有相关研究比较¹⁸F-成纤维细胞激活蛋白抑制剂 (Fibroblast Activating Protein Inhibitor, FAPI) 和¹⁸F-氟代脱氧葡萄糖 (Fluorodeoxyglucose, FDG) PET/CT 在初诊肺癌患者中的应用, 结果发现在肺腺癌及鳞癌患者中, ¹⁸F-FAPI 在肺癌原发灶具有较高的肿瘤摄取及检出率。然而在肺非上皮性肿瘤中则相反, ¹⁸F-FAPI 的放射性摄取普遍低于¹⁸F-FDG, 因此结合两种示踪剂可以提升肺癌的诊断率^[7]。

然而, 目前临床上双示踪剂检查采用同一患者在不同时间分别扫描两次不同示踪剂的 PET/CT, 这种成像方式不仅增加患者的辐射剂量, 也增加患者时间成本和金钱成本。因此, 研究者们提出两种示踪剂混合注射方法, 期望通过一次注射得到不同示踪剂的 PET 诊断图像^[8]。但是这样的扫描方式对于双示踪剂成像方法提出更高的要求和挑战。为了解决双示踪剂混合注射成像问题, 其中一类方法是采用平行多示踪剂房室模型, 利用相应示踪剂的叠加药代动力学模型拟合方法, 将重建的动态双示踪剂 PET 图像中提取的时间活度曲线来分离单个示踪剂信号^[9]。但是该类方法存在的问题是需要采集长时间的动态数据, 例如¹⁸F-FDG 需要 1 h 采集, 这导致患者不能坚持或者产生较大的运动伪影问题, 且需要两种示踪剂有不同的半衰期, 极大限制了该类方法的应用。Andreyev 等^[10]基于此问题提出另外一种方法, 利用额外的瞬发高能光子来区分两种示踪剂, 但是这种方法需要高能同位素, 对粒子加速器的要求高, 且需要额外的探测器来捕获高能光子, 可行性较低。随着深度学习技术的发展, 采用数据驱动的双示踪剂成像技术越来越受到关注。数据驱动的成像主要依赖于数据本身, 具体可以通过深度学习相关的算法来实现。Kadmas 等^[11]研究主成分分析法, 将双示踪剂 PET 信号明确分离为单个示踪剂成分, 但该方法对示踪剂组合比较敏感。Ruan 等^[12]将堆叠自

编码器用于双示踪剂信号分离, 这是深度学习方法首次应用于双示踪剂 PET 成像上。Xu 等^[13]提出利用深度置信网络来对相同同位素标记的双示踪 PET 组合进行分离的方法, 随后进一步提出一个双损失函数的三维卷积神经网络 (Three Dimension Convolutional Neural Network, 3D CNN)^[14]实现 PET 混合示踪剂图像的分离。

但以上这些数据驱动方法研究的基础数据大多是仿真数据或体模数据而并非临床数据, 且生成图像不够清晰。对于以上两点, 本文提出一种基于数据驱动的三维深度分离网络 (Three Dimension Deep Splitting Network, 3D DSN) 双示踪剂分离成像方法, 采用临床真实扫描数据, 将生成的双示踪剂混合 PET 图像输入到 3D DSN 网络中进行分离, 分别得到两种单示踪剂的图像, 并与同类的 3D CNN 方法进行对比^[14]。

1 方法

1.1 数据收集及处理

本研究利用上海联影 uEXPLORER PET/CT 设备采集 120 例同一患者的单独¹⁸F-FDG 和¹⁸F-FAPI 扫描图像, 数据进行脱敏处理。对患者的一些基本信息进行统计, 其中, 男 82 例, 女 38 例; 年龄 19~85 岁, 平均年龄 57.1 岁; 身高 1.43~1.83 m, 平均身高 1.66 m; 体质量 35~88 kg, 平均体质量 63.1 kg。患者注射活度为 3.95~9.72 mCi, 平均注射活度为 6.43 mCi。每例患者单示踪剂的 PET 图像维度为 192×192×673, 体素大小为 (3.125×3.125×2.886) mm³; CT 图像维度为 512×512×653, 体素大小为 (0.976 5×0.976 5×3) mm³。

1.1.1 双示踪剂图像配准 患者单次扫描时的 CT 和 PET 图像已自动配准, 因此不需要对 CT 和 PET 图像进行配准。但是由于患者的不同示踪剂的 PET 扫描数据并非在同一天收集得到, 患者的体位摆放可能不一样, 患者的局部肢体运动甚至呼吸运动也会导致 PET 图像发生偏移, 因此在双示踪剂混合图像重建前需要对两幅不同示踪剂的 PET 图像进行高精度非刚性的配准, 以实现空间位置的一致性。本研究调用 Python 中 ANTSpy (Advanced Normalization Tools in Python) 库里面的 ElasticSyN 变换得到配准矩阵, ElasticSyN 变换结合仿射变换和弹性变换, 可以很好地处理图像之间的非线性变形^[15]。基于 CT 图像的 PET 图像配准过程如图 1 所示。

1.1.2 双示踪剂混合图像生成 由于只采集同一患者单独的¹⁸F-FDG 和¹⁸F-FAPI 两种示踪剂数据, 为了模拟双示踪剂混合数据, 本研究在两种 PET 图像配准后进行前向投影产生弦图数据, 将两者的弦图数据

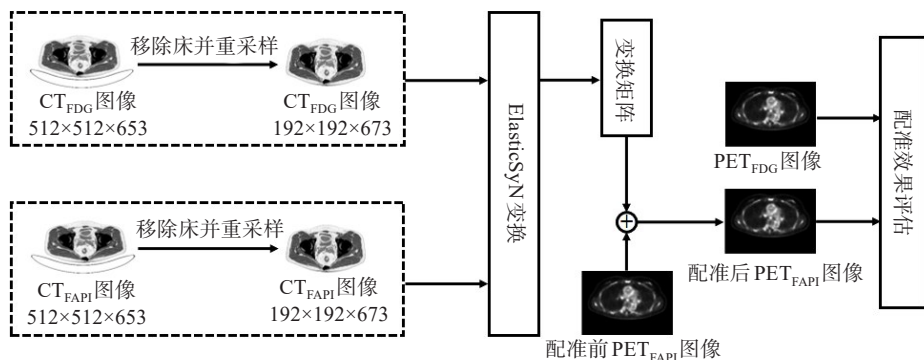


图 1 基于 CT 图像的 PET 图像配准流程图
Figure 1 Flowchart of PET image registration based on CT images

混合后产生双示踪剂混合数据,随后利用最大似然期望法 (Maximum Likelihood Expectation Maximization, MLEM)重建后得到双示踪剂混合图像^[16]。前向投影采用 ASTRA 工具包^[17]对 PET 图像进行前向投影,每例患者数据生成的弦图图像维度为 $192 \times 192 \times 673$ (192 个均匀探测器单元、192 个均匀角度和 673 层弦图图像)。随后将两种示踪剂的弦图数据累加,由于两种示踪剂注射剂量是 1:1,所以弦图累加的比例也是 1:1,最后用 ASTRA 工具包的 MLEM 重建算法进行 PET 图像重建得到两种示踪剂的混合图像。

1.2 双示踪剂深度分离方法

在双示踪剂信号分离的深度学习,本文提出的架构基于多任务学习中常用的硬参数共享方法,其中所有任务都共享公共空间表示,每个任务都有特定的附加层^[18]。由于所有任务都是同时学习的,硬参数共享有助于模型更好地泛化并降低过拟合的风险。本文提出的双示踪剂 DSN 架构如图 2 所示,包含一个编码模块,编码模块是所有任务的共享公共空间,另外有两个解码模块,解码模块是针对两个示踪剂分离任务设计,图像和模块下方的数字代表通道数。




图 2 3D DSN 网络结构
Figure 2 3D DSN architecture

$\text{Conv}3d_{3 \times 3 \times 3}$ 表示三维卷积,卷积核大小为 $3 \times 3 \times 3$,BN 为批量归一化,ReLU 和 PReLU 表示激活函数, $\text{ConvTranspose}3d_{2 \times 2 \times 2}$ 代表三维反卷积,反卷积核大小为 $2 \times 2 \times 2$ 。具体编码器共有 5 层:第一层包含两个卷积层、批量归一化、PReLU 激活函数^[19],它不改变输入特征的大小,但是将通道数变为 16;第二层是一个最大池化层,它使得输出特征的大小压缩为之前的

一半,通道数保持不变;第三层也包含两个卷积层、批量归一化、PReLU 激活函数,它不改变输入特征的大小,但是将通道数增加一倍。第四层与第二层、第五层与第三层的结构和功能相同。两个解码器的构造保持一致,都包含 5 层。第一层为反卷积层,它不仅将输入特征扩大一倍,同时使得输出通道数减半。第二层包含两个卷积层、批量归一化、PReLU 激活函

数,它不改变输入特征的大小,但使得通道数增加1倍。第三层与第一层、第四层与第二层的结构和功能相同。第五层包含一个卷积层和ReLU激活函数,它的卷积核大小为 $1 \times 1 \times 1$,将输出通道数变为1。

本网络的输入是两种示踪剂的混合图像,输出是两种示踪剂的独立图像,本研究采用均方根误差(Mean Squared Error, MSE)作为损失函数,定义如下:

$$L_{\text{main}} = \frac{1}{m} \sum_{i=1}^m (X_i - \tilde{X}_i)^2 + \frac{1}{n} \sum_{j=1}^n (Y_j - \tilde{Y}_j)^2 \quad (1)$$

其中, X_i 和 \tilde{X}_i 分别为示踪剂1真实图像矩阵和预测图像矩阵第*i*个值, Y_j 和 \tilde{Y}_j 分别为示踪剂2真实图像矩阵和预测图像矩阵第*j*个值。

1.3 训练细节

本文提出的3D DSN网络是在PyTorch上实现的,模型的训练和测试是在NVIDIA A100内存为40 GB的GPU上进行的。在训练过程中,选取320个epoch。原始数据的维度为 $192 \times 192 \times 673$,本研究将其处理成 $192 \times 192 \times 64$ 的patch尺寸用于训练,分割时重合的窗口大小为32。使用Adam优化器^[20],初始学习率为0.0001,两个动量参数分别为0.5和0.999。在整个训练过程中,学习率将线性衰减至0。本研究将120例数据划分为训练集80例、验证集20例和测试集20例。

1.4 评价指标

预测图像与真实图像的结构相似性指数(Structure Similarity Index Measure, SSIM)^[21]计算如下:

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

其中, μ_x 和 μ_y 分别是预测图像和真实图像所有体素的平均值, σ_x 和 σ_y 分别是预测图像和真实图像所有体素的标准差, σ_{xy} 是预测图像和真实图像协方差。 c_1 和 c_2 是两个常数,以防止出现分母为0的情况,同时它们的大小选择影响着SSIM对图像不同特征的敏感度,本研究中 c_1 取值为0.01, c_2 取值为0.03。

峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)是一种用于评估图像质量的指标,可以衡量原始图像与经过处理之后的图像之间的质量损失程度,PSNR值越大,图像的质量越好^[22]。PSNR的计算公式如下:

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{\text{MAX}^2}{\text{MSE}} \right) \quad (3)$$

其中,MAX表示图像的最大可能像素值,MSE表示预测图像与真实图像的均方误差,计算公式如下:

$$\text{MSE} = \frac{1}{lmn} \sum_{k=1}^l \sum_{i=1}^m \sum_{j=1}^n (x_{kij} - y_{kij})^2 \quad (4)$$

其中, x_{kij} 是真实图像中第*k*层第*i*行第*j*列的像素值, y_{kij} 是预测图像中第*k*层第*i*行第*j*列的像素值, l 、 m 和 n 分别表示图像的层数、高度和宽度。

本研究还采用归一化均方根误差(Normalized Root Mean Squared Error, NRMSE)作为评价指标^[23]。NRMSE的值为0~1,值越小,表示预测图像与实际图像之间的差异越小。它可以用来衡量真实图像与预测图像之间的差异程度。计算公式如下:

$$\text{NRMSE} = \frac{\sqrt{\text{MSE}}}{x_{\text{max}} - x_{\text{min}}} \quad (5)$$

其中, x_{max} 是真实图像中体素的最大值, x_{min} 是真实图像中体素的最小值,MSE表示预测图像与真实图像的均方误差。

互信息(Mutual Information, MI)衡量的是两幅图像之间的相互依赖性。MI值较大时,说明两幅图像的形变较小,MI值较小时,说明两幅图像的形变较大^[24]。对于两幅图像*X*和*Y*,MI可以通过以下公式计算:

$$\text{MI}(X, Y) = \sum_{x \in X} \sum_{y \in Y} p(X, Y) \log_2 \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (6)$$

其中, $p(X, Y)$ 是*X*和*Y*共同取某个值的概率, $p(x)$ 和 $p(y)$ 分别是*X*和*Y*独立取某个值的概率。

2 结果

图3展示了¹⁸F-FDG与¹⁸F-FAPI PET图像配准前后的效果。从图3配准前两种示踪剂的叠加图像(图3c)可以看出头部轮廓出现由于位置不一致的混叠伪影,而从配准后两种示踪剂的叠加图像(图3f)可以看出配准后两幅PET图像的结构高度相似,没有出现混叠伪影。本研究还计算了配准前后¹⁸F-FDG和¹⁸F-FAPI PET图像之间的MI、NRMSE值,配准前¹⁸F-FDG和¹⁸F-FAPI PET图像之间的MI值仅为0.39,NRMSE值为1.03。配准后¹⁸F-FDG和¹⁸F-FAPI PET图像的MI值为1.13,NRMSE值为0.91,相对于配准前的图像MI值提升0.74,NRMSE值减小0.12,配准后的图像能更好地用于网络的训练。

图4展示的是3D DSN和3D CNN网络训练过程中损失函数的变化,可以看到随着迭代次数的增加,网络在逐渐收敛,迭代次数大约为280次时,DSN网络达到收敛状态;迭代次数大约为320次时,CNN网络达到收敛状态。

图5和图6分别展示两例双示踪剂混合PET图像分离结果的横断面。在图5中¹⁸F-FDG PET图像中观察不到异常的代谢情况,但在¹⁸F-FAPI PET图像中




图3 ^{18}F -FDG 与 ^{18}F -FAPI PET 图像的配准结果

Figure 3 Results of ^{18}F -FDG and ^{18}F -FAPI PET image registrations

图 a 为配准前的 ^{18}F -FDG 图像;图 b 为配准前的 ^{18}F -FAPI 图像;图 c 为配准前的 ^{18}F -FDG 与 ^{18}F -FAPI 的叠加图像;图 d 为配准后的 ^{18}F -FDG 图像;图 e 为配准后的 ^{18}F -FAPI 图像;图 f 为配准后的 ^{18}F -FDG 与 ^{18}F -FAPI 的叠加图像

可以观察到代谢活动较强的组织,3D CNN 网络分离得到的 ^{18}F -FAPI PET 图像与真实的 ^{18}F -FAPI PET 图像相比,代谢异常的组织少了好几处,极有可能造成




图4 网络训练过程中损失函数变化曲线

Figure 4 Change in loss function during network training

成临床诊疗中肿瘤的漏诊,而 3D DSN 网络分离得到的 ^{18}F -FAPI PET 图像与真实 ^{18}F -FAPI PET 图像组织代谢情况较为一致。在图 6 中, ^{18}F -FDG 和 ^{18}F -FAPI PET 图像中都显示出代谢异常的组织,而 ^{18}F -FAPI PET 图像中显示的信息更丰富。同时可以看到 3D CNN 网络错误地将 ^{18}F -FAPI PET 图像中异常的代谢情况分离到 ^{18}F -FDG PET 图像中,这可能会使得临床诊断中出现误诊现象。而使用 3D DSN 网络分离得到的 PET 图像与真实的 PET 图像结构相似度高,示踪剂在体内的分布也与真实图像基本一致。同时相对于 3D CNN 网络分离得到的图像,3D DSN 网络分离得到的图像与真实 PET 图像结构相似程度更高,细节部分更为清晰。




图5 双示踪剂混合 PET 图像分离结果横断面对比图示例 1

Figure 5 Example 1 of cross-sectional comparison of the separated PET images of dual tracers

图 a 为真实的 ^{18}F -FDG PET 图像;图 b 为 3D CNN 网络分离得到的 ^{18}F -FDG PET 图像;图 c 为 3D DSN 网络分离得到的 ^{18}F -FDG PET 图像;图 d 为真实的 ^{18}F -FAPI PET 图像;图 e 为 3D CNN 网络分离得到的 ^{18}F -FAPI PET 图像;图 f 为 3D DSN 网络分离得到的 ^{18}F -FAPI PET 图像

表 1 展示的是生成的 ^{18}F -FAPI、 ^{18}F -FDG PET 图像与真实 ^{18}F -FAPI、 ^{18}F -FDG PET 图像进行定量分析得到的结果。根据表 1 结果可知,使用 3D DSN 网络分

离得到的图像质量要优于 3D CNN 网络。使用 3D DSN 网络相对于 3D CNN 网络分离得到的 ^{18}F -FAPI 和 ^{18}F -FDG PET 图像,SSIM 值分别提升 1.1%、0.87%,




图6 双示踪剂混合PET图像分离结果横断面对比图示例2

Figure 6 Example 2 of cross-sectional comparison of the separated PET images of dual tracers

图a为真实的¹⁸F-FDG PET图像;图b为3D CNN网络分离得到的¹⁸F-FDG PET图像;图c为3D DSN网络分离得到的¹⁸F-FDG PET图像;图d为真实的¹⁸F-FAPI PET图像;图e为3D CNN网络分离得到的¹⁸F-FAPI PET图像;图f为3D DSN网络分离得到的¹⁸F-FAPI PET图像

PSNR 值分别提升 17.0%、11.8%,NRMSE 值分别减小 51%、52%,这表明使用 3D DSN 网络分离得到的结果与真实图像更为相似,失真程度更低,差异更小。

表 1 生成图像与真实图像的评价指标计算结果

Table 1 Evaluation metrics for generated images compared with ground truth images

方法	¹⁸ F-FAPI 图像			¹⁸ F-FDG 图像		
	SSIM	PSNR/dB	NRMSE	SSIM	PSNR/dB	NRMSE
3D DSN	0.991 1	48.50	0.436 1	0.994 2	47.64	0.359 0
3D CNN	0.980 0	41.47	0.890 2	0.985 6	42.60	0.748 2

3 讨论

本研究提出一种双示踪剂混合PET图像的分离成像方法,对于临床真实数据进行配准、重建后得到混合双示踪剂PET图像,输入到3D DSN网络中进行训练,能同时分离成像单示踪剂PET图像。测试集的结果从定性的角度来看,分离得到的PET图像与真实的PET图像结构基本保持一致,不仅准确捕捉到了示踪剂在体内的分布,同时还保留图像丰富的结构信息,可以为临床医生提供参考价值。但同时部分生成图像的示踪剂浓度与真实图像略有偏差,这可能会使得临床医生在观察肿瘤的一些特征时受到影响,后续也将进一步改进。从定量的角度来看,相对于同类的方法,使用3D DSN网络分离得到的图像质量更高,与真实图像的结构更为相似,定量偏差更小,信噪比更高。

本研究也存在一定的局限性,由于临床双示踪剂同时注射数据稀缺,本文利用两种PET示踪剂图

像进行前向投影得到弦图,然后对弦图进行混合再使用MLEM重建得到PET混合示踪剂图像。从方法学角度来看,有研究者采用类似仿真方法进行数据处理研究,Hu等^[25]对临床图像数据进行正向投影获取弦图数据,然后对弦图数据进行噪声处理模拟临床低剂量采集情况从而研究PET图像的低剂量成像方法。采用临床数据仿真方法可以进一步研究相关方法在临床数据的应用情况,比单纯采用仿真模体数据更能贴近临床。本研究后续的工作需要采集更多的临床数据进行分析,深度学习方法是一种基于数据驱动的方法,用于网络训练的数据越多,得到的效果越好。同时,后续会跟医生针对生成图像进行临床诊断进行评估来验证本文方法在临床的应用效果。

综上所述,本研究提出一种新的双示踪剂混合PET图像分离方法,用于¹⁸F-FDG和¹⁸F-FAPI PET双示踪剂混合图像分离成像。本文将双示踪剂混合图像输入到基于3D DSN架构的网络进行分离成像,能

同时获取不同单示踪剂的PET图像。相对于同类的方法,使用3D DSN网络分离得到的图像质量更高,与真实图像的结构更为相似,均方根误差更小。本文提出的方法有望为临床医生提供更准确、更丰富的诊断信息,从而提高疾病的诊断准确率。

【参考文献】

- [1] Weissleder R, Mahmood U. Molecular imaging[J]. Radiology, 2001, 219(2): 316-333.
- [2] Sun X, Nie BB, Zhao SJ, et al. Tau PET distributional pattern in AD patients with visuospatial dysfunction[J]. Curr Alzheimer Res, 2019, 16(11): 1055-1062.
- [3] Qiao PX, Wang YT, Zhu K, et al. Noninvasive monitoring of reparative fibrosis after myocardial infarction in rats using 68Ga-FAPI-04 PET/CT[J]. Mol Pharm, 2022, 19(11): 4171-4178.
- [4] Kessler L, Kupusovic J, Ferdinandus J, et al. Visualization of fibroblast activation after myocardial infarction using 68Ga-FAPI PET[J]. Clin Nucl Med, 2021, 46(10): 807-813.
- [5] Wei YC, Sun YH, Liu JY, et al. Early detection of radiation-induced myocardial damage by [¹⁸F]AIF-NOTA-FAPI-04 PET/CT imaging[J]. Eur J Nucl Med Mol Imaging, 2023, 50(2): 453-464.
- [6] 徐金旻, 刘华锋. 双示踪正电子发射断层成像的关键技术及进展[J]. 光学学报, 2022, 42(17): 149-164.
Xu JM, Liu HF. Key technologies and advances of dual-tracer positron emission tomography[J]. Acta Optica Sinica, 2022, 42(17): 149-164.
- [7] 李友财, 张晓瑶, 张岩, 等. ¹⁸F-FAPI-42和¹⁸F-FDG PET/CT显像在初诊肺癌诊断中的应用比较[J]. 中华核医学与分子影像杂志, 2021, 41(12): 709-716.
Li YC, Zhang XY, Zhang Y, et al. Comparison of clinical utility of ¹⁸F-FAPI-42 and ¹⁸F-FDG PET/CT imaging in the diagnosis of newly diagnosed lung cancer[J]. Chinese Journal of Nuclear Medicine and Molecular Imaging, 2021, 41(12): 709-716.
- [8] Huang SC, Carson RE, Hoffman EJ, et al. An investigation of a double-tracer technique for positron computerized tomography[J]. J Nucl Med, 1982, 23(9): 816-822.
- [9] Koeppe RA, Raffel DM, Snyder SE, et al. Dual-[¹¹C]tracer single-acquisition positron emission tomography studies[J]. J Cereb Blood Flow Metab, 2001, 21(12): 1480-1492.
- [10] Andreyev A, Celler A. Dual-isotope PET using positron-gamma emitters[J]. Phys Med Biol, 2011, 56(14): 4539-4556.
- [11] Kadmas DJ, Rust TC. Feasibility of rapid multitracers PET tumor imaging[J]. IEEE Trans Nucl Sci, 2005, 52(5): 1341-1347.
- [12] Ruan DS, Liu HF. Separation of a mixture of simultaneous dual-tracer PET signals: a data-driven approach[J]. IEEE Trans Nucl Sci, 2017, 64(9): 2588-2597.
- [13] Xu JM, Liu HF. Deep-learning-based separation of a mixture of dual-tracer single-acquisition PET signals with equal half-lives: a simulation study[J]. IEEE Trans Radiat Plasma Med Sci, 2019, 3(6): 649-659.
- [14] Xu JM, Liu HF. Three-dimensional convolutional neural networks for simultaneous dual-tracer PET imaging[J]. Phys Med Biol, 2019, 64(18): 185016.
- [15] Avants BB, Tustison NJ, Stauffer M, et al. The insight Toolkit image registration framework[J]. Front Neuroinform, 2014, 8: 44.
- [16] Gaitanis A, Kontaxakis G, Spyrou G, et al. PET image reconstruction: a stopping rule for the MLEM algorithm based on properties of the updating coefficients[J]. Comput Med Imaging Graph, 2010, 34(2): 131-141.
- [17] van Aarle W, Palenstijn WJ, Cant J, et al. Fast and flexible X-ray tomography using the ASTRA toolbox[J]. Opt Express, 2016, 24(22): 25129-25147.
- [18] Caruana RA. Multitask learning: a knowledge-based source of inductive bias [M]//Machine Learning Proceedings 1993. San Francisco: Morgan Kaufmann, 1993: 41-48.
- [19] 吴怡喙, 杨定礼, 周辉, 等. 基于改进VGG网络的面部表情识别方法[J]. 电子器件, 2023, 46(4): 1062-1069.
Wu YZ, Yang DL, Zhou H, et al. Facial expression recognition method based on improved VGG network[J]. Chinese Journal of Electron Devices, 2023, 46(4): 1062-1069.
- [20] Kingma DP, Ba J. Adam: a method for stochastic optimization[EB/OL]. (2017-01-30). <https://arxiv.org/abs/1412.6980>.
- [21] Wang MW, Zhu FZ, Zhu B, et al. An improved remote sensing image blind deblurring algorithm[C]//2019 3rd International Conference on Electronic Information Technology and Computer Engineering (EITCE). Piscataway, NJ, USA: IEEE, 2019: 667-670.
- [22] Wang MW, Zhu FZ, Bai YY. An improved image blind deblurring based on dark channel prior[J]. Optoelectron Lett, 2021, 17(1): 40-46.
- [23] Langkammer C, Schweser F, Shmueli K, et al. Quantitative susceptibility mapping: report from the 2016 reconstruction challenge [J]. Magn Reson Med, 2018, 79(3): 1661-1673.
- [24] Pluim JP, Maintz JB, Viergever MA. Mutual-information-based registration of medical images: a survey[J]. IEEE Trans Med Imaging, 2003, 22(8): 986-1004.
- [25] Hu ZL, Xue HZ, Zhang QY, et al. DPIR-net: direct PET image reconstruction based on the wasserstein generative adversarial network [J]. IEEE Trans Radiat Plasma Med Sci, 2021, 5(1): 35-43.

(编辑:陈丽霞)