

跨模态医学图像预测综述

周 沛¹, 陈后金¹, 于泽宽², 彭亚辉¹, 李艳凤¹, 杨 帆¹

(1. 北京交通大学, 北京 100044; 2. 北京大学, 北京 100871)

摘 要: 医学影像技术与设备的进步在生物医学领域的各项研究中发挥着重要作用. 跨模态医学图像预测旨在由一种模态图像预测另一种模态图像. 本文详细综述了由 MRI 预测 CT 图像、7T-Like 图像重构、PET 预测及其他医学模态预测研究, 阐述了各类模态预测的必要性及存在的挑战, 说明各类预测方法的特点并进行性能比较, 最终得出结论: 基于深度学习的跨模态预测在预测精度和预测时间两方面更具优势.

关键词: 深度学习; CT 预测; 7T-Like 图像重构; PET 预测

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2019)01-0220-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.01.029

Review of Cross-Modality Medical Image Prediction

ZHOU Pei¹, CHEN Hou-Jin¹, YU Ze-kuan², PENG Ya-hui¹, LI Yan-feng¹, YANG Fan¹

(1. Beijing Jiaotong University, Beijing 100044, China; 2. Peking University, Beijing 100871, China)

Abstract: Advances in medical imaging technologies and equipment play an important role in the biomedical researches. Cross-modality image-prediction technology predicts one modal image from that of another modal. This paper presents an overview of the literatures on medical imaging prediction technology and its applications, such as predicting Computed Tomography images from Magnetic Resonance (MR) images, 7T-like MR image reconstruction, and predicting positron emission tomography images. The aim is twofold: the necessity and challenge for different modality medical image prediction technology; the overview and comparison of various methods in the field. We conclude that the cross-modality image prediction based on the deep learning technology has superiority in both predicting time and precision.

Key words: deep learning; computed tomography (CT) image prediction; 7T-like image reconstruction; positron emission tomography (PET) image prediction

1 引言

医学影像从产生至今, 一直致力于为医生提供更加准确和全面的诊断信息. 人体因疾病引起的形态或功能异常表现在各个方面, 单一模态成像设备获取的信息往往无法全面反映疾病的复杂特征, 多模态融合及综合辅助诊断已成为医学成像技术发展的重要趋势^[1]. 不同模态图像有其各自的优缺点及适用范围, 临床诊断中常用医学模态包括计算机断层扫描(Computed Tomography, CT)、磁共振成像(Magnetic Resonance Imaging, MRI)、正电子发射型计算机断层扫描(Positron Emission Computed Tomography, PET)和包括超声成像在内各类声学、光学成像模态等^[2]. 其中, CT对密度差异较大的组织成像效果较好, 对于钙化、骨皮质及骨折等

现象更为直观, 但具有电离辐射, 且软组织对比度差; MRI图像中软组织对比度高, 获得的诊断信息丰富, 成像过程不产生电离辐射, 但其空间分辨率不及CT, 且扫描时间较长, 期间易因病人移动而产生伪影; PET是目前唯一可在活体上显示生物分子代谢、受体及神经介质活动的新型影像技术. PET能在病变区的组织形态结构尚未呈现异常, 通过组织功能性的改变发现病灶所在并获得三维影像进行定量分析, 达到早期诊断目的, 但PET检查成本高价格昂贵; 超声成像虽然空间分辨率较差, 但是具有方便易用、成本低廉等优势, 在诊疗各个阶段应用广泛. 除了超声成像, 其他常用医学成像模态往往涉及价格昂贵的成像设备以及苛刻的场地限制和使用要求, 不易于也无必要全部配备. 若能利用已有医学图像通过跨模态预测得到不同模态图像, 实现多

模态融合及综合辅助诊断,将帮助医生更好地获得多模态图像信息从而提高诊断效果和效率.因此,精准的跨模态医学图像预测在未来计算机与医学影像相结合的发展中作用不可小觑.

现阶段跨模态医学图像预测主要应用于以下三个方面:放射治疗与衰减校正,CT 不仅能直接地应用于医疗诊断,同时对于 PET/CT 和 PET/MRI 系统中 PET 图像的衰减校正,以及基于核共振成像的放射治疗(MRI-only Radiotherapy)计划中剂量估计起着关键作用;获取特定模态信息,由于硬件设备条件、获取时间、成本等各方面因素的限制,很难快速获得某些特定模态的信息,因此精准的模态预测能帮助快速且经济地获得某些特定模态信息;多模态数据补充,不论是在临床诊断还是学术研究中,医学影像数据的缺失会带来不便.利用已有数据进行跨模态预测以补充部分缺失数据,可提高信息完整性.

本综述包括由 MRI 构造 CT、7T-like MRI 重构、PET 预测及多光谱图像预测等,归纳了各类模态预测中的常用方法,阐述了各类模态预测的特点及主要难点.通过对数据规模、预测精度、预测时间等多方面分析评估,最后得出基于深度学习的方法在预测时间与预测精度两方面具有显著的优势.

2 文献检索

本文使用 Web of Science [v. 5. 25. 1]-所有数据库进行数据检索,检索时间为 2000-2017 年,主题词或关键词:1. (CT prediction OR substitute CT OR pseudo CT) AND (PET attenuation correction OR MRI-only radiation therapy OR MRI-only radiotherapy) 和 2. 7T-Like MRI reconstruction 进行检索.其他类别模态预测如 CT 预测 PET、MRI 预测 PET 和彩色医学图像预测高光谱图像等文章数量较少,直接在文中第五部分给出结果.由调研结果统计 2000-2017 年的模态预测论文发表数量如图 1 所示,分析可得医学图像模态预测在近三年有快速的发展,并有数据显示深度学习在医学图像分析相关文献发表数量在 2015 和 2016 年快速增长^[3].近年来深度学习的发展为其在医学模态预测的应用提供了极大的动力,随着医学影像信息系统的快速发展,数据量将大大提升,传统方法将面临大数据的挑战,而基于深度学习的跨模态医学预测具有很大的潜力.

3 CT 预测

CT 成像时借助的 X 射线具有辐射效应并可能对人体造成伤害.研究表明,美国多达 0.4% 的癌症是由于 CT 扫描引发的,而这个比率在未来可能高达 1.5 ~ 2%^[4].相比之下,MRI 是一种无需借助 X 射线便可观




图1 模态预测文献数量统计

察人体结构的非侵入式方法.由于 MRI 图像越来越多地被用来勾画靶区与正常组织,以及由 MRI 图像指导的放射治疗系统不断发展,MRI-only 放疗系统已经成为放射医学影像研究的热点^[5],放疗时照射剂量估计需要电子密度信息,MRI 图像通常与 CT 图像配准建立映射关系进行剂量估计^[6].另外,衰减校正是 PET 成像的一个重要步骤,PET 衰减校正通常先确定组织断层上的湮灭辐射光子能量下 μ 值的分布,然后再对断层上各个体素上的计数实行补偿.在人体组织中,湮灭辐射光子的 μ 值大小取决于组织密度和厚度.通过 CT 可以得到组织衰减图,来反映体内正常或异常的组织密度变化情况^[7].由于 MRI-only 放疗系统或 PET/MR 系统中均不再配备 CT 扫描仪,故可由 MRI 图像预测伪 CT 再用于剂量估计或 PET 衰减校正.

3.1 基于图集的 CT 预测

基于图集 (Atlas-based) 的 CT 预测适用于脑部或全身性检查,图集由 MRI 图集以及 CT 图集两部分组成,其核心思想是将患者 MRI 与图集中 MRI 进行配准,并将配准所得的变换矩阵或变形场等信息作用于 CT 图集,得到伪 CT 图像^[8].

早期 Hofmann 等人于 2008 年提出局部模式识别与图集配准相结合的方法^[9],利用非刚性配准算法将目标 MRI 与图集中所有 MRI 进行配准,将得到的形变信息作用于图集中 CT 得到伪 CT 全局信息,再利用高斯过程建立 MRI 图像块(patch)体素强度与电子密度的映射关系.随后提出了将目标 MRI 分割为五类(空气、脂肪、骨骼等等)再进行后续处理的方法^[10].相似地,Hossein Arabi 等人于 2016 年提出基于分类图集的预测方法^[11],对肺部组织与非肺部组织使用了不同的高斯过程回归内核获取映射信息.

若只用单一图集来代表病理现象,则对于包含病灶的图像预测局限性很大.Burgos Ninon 等人于 2014 年提出基于多图集的预测方法^[12],并基于形态学相似性对不同的图集分配不同的权值,目标 MRI 与图集越相似则合成伪 CT 时该图集的权重越大.之后也将伪 CT 预测的迭代框架与图像分割结合,用于前列腺的 MRI-

only 放射治疗计划^[13]。

为减少配准过程中大量计算时间, Hossein Arabi 等人于 2016 年提出基于多图集的单次在线对准预测 (One Registration Multi-atlas-based, ORMA)^[14], 即只进行一次在线对准, 先计算图集中其余图像间相应变换矩阵, 配准时直接运用所得变换矩阵, 因此计算时间会以 $1/N$ (N 为图集中图像数量) 的因子大大缩短。Andreason 等人于 2016 年将局部图像块相似性和仿射配准相结合的方法用于前列腺检测中^[15]。该方法只对感兴趣的部分进行配准且使用近似图像块并行搜索。Angel 等人于 2016 年提出基于群组图像块 (groupwise patch-based) 的预测方法^[16], 先计算输入的 MRI 图像中每一个像素点所在图像块与所有图集中相邻结构处图像块的相似性权值, 再将权值分配给 CT 图集中对应图像块进行加权线性组合, 最后正则化输出相应伪 CT 图像块。由于处理单元不再是整个图像而是小的图像块, 故可用 GPU 并行处理减少计算时间。

3.2 基于随机森林的 CT 预测

随机森林是 Breiman Leo 和 Adele Cutler 于 2001 年提出的机器学习算法, 可进行分类、聚类、回归和生存分析^[17]。随机森林由多个决策树组成, 在每个决策树内部节点处选择某种特征, 分离输入的训练样本使信息增益最大化。基于随机森林的 CT 预测可视为回归问题, 自变量为 MRI 图像中获取的特征, 应变量为对应预测 CT 的像素点或图像块的值。

Huynh 等人于 2016 年使用结构化随机森林 (Structured Random Forest, SRF) 模型进行脑部伪 CT 预测^[18]。该方法以提取多尺度特征向量进行模型训练, 向量包含三种尺度的像素对差异特征、类哈尔特征、离散余弦变换系数特征以及空间坐标信息, 并使用 Auto-context 模型 (ACM)^[19] 提取预测 CT 的文本特征 (内部轮廓、形态等特征), 迭代地用于下一次训练中。Andreason 等人于 2016 年提出多级随机森林与 ACM 特征提取相结合的预测方法^[20], 应用于盆腔部位 CT 预测。该方法使用了 ACM 提取或优化的文本特征训练回归森林模型。Yang 等人于 2017 年使用基于图像块 (patch-based) 的随机森林进行脑部伪 CT 预测^[21], 同样先从对准的图像中提取患者特异性解剖特征, 再选择鲁棒性强且信息量大的特征训练随机森林。此外, Huynh 等人于 2015 年首次提出多源信息增益概念, 通过选取有效的多源信息源引导训练过程从而提高预测精度^[22]。

3.3 基于深度学习的 CT 预测

目前基于深度学习的 CT 预测网络以全卷积网络 (Fully Convolutional Networks, FCN)^[23], 深度卷积神经网络 (Deep Convolutional Neural Networks, DCNN)^[24,25], 对抗生成网络 (Generative Adversarial Network,

GAN)^[26,27] 为代表。此类方法的特点是可自行学习输入与输出间非线性映射关系, 但需要对大量参数进行训练, 且所需训练数据量十分庞大。

3D-CNN 模型在一定程度上解决了将 2D-CNN 架构直接作用于三维医学影像预测时切片与切片间不连续性的问题。Shen Ding-gang 等人于 2016 年利用 3D-FCN 实现从 MRI 图像预测对应的 CT 图像^[28], 以 MRI 和 CT 的图像块作为输入和输出, 每个体素合集对应分成 6,000 个图像块, 共近 200,000 个图像块用于网络训练。Xiao Han 于 2017 年使用 DCNN 实现从 MRI 预测 CT 的工作^[29], 此网络多达 35,000,000 个参数。实验数据为 18 个患脑肿瘤病人的 CT 和对应 T1 加权 MRI 图像, 由于实验数据数量有限, 但网络结构庞大且参数极多, 故利用了迁移学习^[30] 以及使用预训练模型进行权重初始化来搭建网络。该网络训练时间很长, 但相较于基于图集的传统方法, 其预测准确度更高, 且预测实时性强, 预测每张新图像只需 9s。

此前提到的方法均需用同一病人同一位置成对的 MRI-CT 数据, 且需要进行图像配准, 而配准时不可避免地存在误差, 这也将直接影响 CT 预测的准确率, 为了减少这种由配准产生的误差, Jelmer 等人于 2017 年直接采用非配对且未校准的 MRI-CT 数据用于 GAN 网络训练^[31], 其借鉴了合成自然图像的 CycleGAN 模型^[32] 用于 CT 预测。最终定性分析显示, 用非配对数据训练的模型既避免了严格的图像配准步骤, 同时获得的合成 CT 看起来更加真实, 包含较少的伪像, 且与配对数据训练的 CycleGAN 模型相比图像模糊度更小。

3.4 小结

基于图集类方法需要成对数据的图集, 且对图像来源、规格统一性要求十分严格; 性能高度依赖于图集和目标图像之间可变形配准的准确性; 建立映射关系及预测的运行时间很长。基于随机森林的预测方法不再需要图集, 此类方法仍需要主动选择特征用于训练随机森林, 预测结果与特征的选取及随机森林结构高度相关。而基于深度学习的方法避免了目标图像与图集多次精确配准的难点, 可通过神经网络自动抽取高维特征建立映射关系, 无需手动设计选取特征。

文献[28]中用相同的实验数据分别对 Atlas、SRF、SRF + (SRF + ACM)、FCN 等方法进行实验, 并以平均绝对误差 (mean absolute error, MAE)、峰值信噪比 (peak signal-to-noise ratio, PSNR) 定量比较如图 2 所示, 相较之下 FCN 图像预测质量更优。此外在文献[29]中, 作者将基于 DCNN 的预测与基于图集的预测在同一实验数据上进行对比, 前者的平均 MAE 为 84.8 ± 17.3 HU 而后者为 94.5 ± 17.8 HU。

表 1 为部分具有代表性的 CT 预测方法相关文献

中的病人数量、配准要求、特征选取方式及训练/预测时间的统计. 各类方法所用病例的数量为 20 左右, 一定程度说明获取病人成对多模态医学图像数据较为困难. 对于图像数据对配准要求从基于图集、基于随机森林到基于深度学习的方法依次降低. 由表 1 中“训练/预测时间”得知基于深度学习的预测实时性有显著优势. 虽然神经网络训练时间长, 需要网络框架的合理搭建及大量参数的调节, 但网络一旦训练好, 便可快速而准确地用于新数据的预测.





表 1 部分 CT 预测统计表

预测方法	数量	配准要求	特征选取	训练/预测时间		文献
分类图集	14	与图集精确配准	—	—	~2h	[11]
ORMA 图集	23	与图集精确配准	—	—	~1h	[14]
SRF +	16	数据对配准	手动设计	~4h	~20min	[18]
FCN	22	数据对配准	自动提取	*	*	[28]
DCNN	18	数据对配准	自动提取	*	9s	[29]
GAN	24	无需配准	自动提取	52h	10s	[31]

“—”表示无此指标, “*”表示数据不详

4 7T 磁共振图像重构

与传统的 3T 以及 1.5T MRI 图像相比, 7T MRI 图像具有高分辨率、组织对比度强的优点, 可由图 3 直观地观察两者的差别. 更高的图像分辨率和对比度有利于更早发现病灶的形态学变化, 帮助医生进行早期精准诊断^[33,34]. 由于 7T MRI 扫描仪设备资源的稀缺以及价格昂贵, 全球仅近 100 台 7T MRI 扫描设备, 而 3T MRI 扫描设备超过 20000 台. 若能从 3T MRI 构造在一定程度上能替代 7T MRI 的图像, 即高质量的仿 7T MRI (7T-like MRI) 图像, 并能够应用到实际的医疗诊断或者科研中, 这将为不具备硬件条件的地区提供极大的便利.

图3^[35] 脑部3T MRI(左)与7T MRI(右)

4.1 基于多级典型相关分析的重构

典型相关分析 (Canonical Correlation Analysis, CCA) 是利用综合变量对之间的相关关系来反映两组数据间的整体相关性的多元统计分析方法. Khosro Bahrami 等人于 2015 年提出并实现基于多级 CCA 的仿 7T MRI 重构^[36], 其使用基于实例^[37]和组稀疏的方法由低分辨率图像 (3T MRI) 重构高分辨率图像 (仿 7T

MRI), 并借鉴了将低分辨率图像与高分辨率图像映射到 CCA 空间的方法^[38], 提升两者的相关性. 使用多级 CCA 的方法来增加 3T、7T 字典与输入的 3T 图像块之间的相关性, 并将组合稀疏度纳入多级 CCA 空间, 分享相邻 3T 图像块之间的稀疏性, 以进行可靠和准确的仿 7T MRI 重建. Shi Feng 等人于 2016 年将多级 CCA 与组稀疏结合的方法应用于具体的脑组织图像分割^[35], 文中将预测的仿 7T MRI 进行白质、灰质、脑脊髓液及脑骨的分割, 实验结果表明此方法能恢复更准确的结构信息以及更好的数值结果.

4.2 基于随机森林与稀疏表示的重构

CCA 是一种捕获线性映射的方法, 它不能捕获从低分辨率到高分辨率空间映射的非线性特性. 为此, Islem Rekik 等提出基于随机森林与稀疏表示的框架完成仿 7T MRI 图像重构, 并完成后续的脑组织分割^[39]. 该方法使用随机森林建立 3T MRI 到 7T MRI 图像的非线性映射, 产生与真实 7T MRI 具有更高相关性和相似性的初始仿 7T 图像, 再将随机森林输出的初始仿 7T 图像与真实 7T MRI 建立稀疏表示关系, 其中使用了预选算法及组稀疏表示. 将随机森林回归与稀疏表示相结合的框架, 既弥补了由随机森林中不同决策树内部平均运算而导致的结果模糊, 同时也避免了直接从 3T 到 7T 空间的稀疏系数估计. 将问题转为初始仿 7T 图像到真实 7T MRI 之间的稀疏系数估计, 这样两者分布的差异更小, 预测结果更可靠.

4.3 基于卷积神经网络的重构

Khosro Bahrami 等人于 2016 年提出基于 CNN 的仿

7T 图像预测方法^[40], 实验数据为 15 个病人的脑部 3T、7T MRI 数据对. CNN 通过建立成对的低分辨率图像与高分辨率图像的非线性映射, 完成高分辨率图像的重建^[41,42]. 该网络结构包含 4 个卷积层, 用于提取多层次的特征, 包括大量高频和低频特征. 训练时使用外观特征 (appearance feature), 结合解剖结构标签 (anatomical features), 这有助于确保相邻图像块之间的结构一致性, 即相邻区域都属于白质、灰质或脑脊髓液, 具体使用 FAST^[43] 方法产生脑组织结构标签, 训练过程旨在学习映射函数, 如式(1):

$$Y = f(X, L) \quad (1)$$

其中 X 为 3T MRI 的强度信息, L 为脑组织标签, Y 为预测的仿 7T MRI.

4.4 小结

由以上三种方法重构的仿 7T MRI 对图像分辨率以及对比度均有不同程度的提高, 尤其对于脑组织分割应用具有重要意义. 与 4.1、4.2 节所提出的重构方法相比, 使用 CNN 重构仿 7T 图像最大的优势在于: 可从大量数据学习特征, 避免人为寻找或设计特征, 更无需再学习最佳词典或多维数据集来建立 3T 到 7T 图像块的映射. 上述方法中均使用了 13 ~ 15 个病例的脑部 3T-7T 数据对, 而由于设备条件及获取成本等限制, 7T 脑部图像往往难以获取, 因此获取充足实验数据对也成为了此类模态预测的难点.

5 其他医学影像模态预测研究

5.1 彩色图像预测高光谱图像

多光谱成像是重要的成像模态已经广泛应用于遥感、医学、农业、地质测绘等多个领域. 多光谱图像包含多个光谱带信息, 每个光谱带是一幅灰度图像, 由于不同物体尤其是人体生物组织对不同波段的光谱吸收及散射情况不同, 因此不同波段的光谱信息可以获得如肿瘤等病灶区域和感兴趣区域的不同结构信息. 但由于多光谱成像设备造价成本高, 受制于空间、光谱和时间分辨率等因素影响, 在诸多场景应用很难获得多光谱数据信息, 大部分应用如内窥镜图像、视网膜眼底图像、皮肤镜图像等都是 RGB 图像. RGB 图像是通过红、绿、蓝三个颜色通道叠加而成的图像, 大部分相机采集到的彩色图像都可以转换成 RGB 图像格式. Boad Arad 等人提出一种快速的从 RGB 图像重建多光谱图像的方法^[44], 该方法通过使用高光谱的先验信息构建稀疏的高光谱字典, 其投影映射到 RGB 空间, 提供 RGB 空间到高光谱图像之间的原子映射. Galliani S 等人通过多层卷积网络实现自然场景的 RGB 图像预测多光谱图像^[45]. Lin J 等人通过 DCNN 对猪的肠道, 羊和兔子的子宫壁 RGB 图像进行 243 组多光谱图像训练, 重建 24

个波段的像素级多光谱图像, 重建图像的 PSNR 大部分都大于 30^[46]. 这一方法有诸多应用, 例如窄带光谱成像, 组织分类和肿瘤检测.

5.2 PET 模态预测

Lei Bi 等人^[47]通过 CT 图像和将肺癌病灶区域分割好的 PET 图像进行训练, 构建多通道 GAN 对抗生成网络预测虚拟的 PET 图像. 数据为 50 个病人的 876 张 PET-CT 横断面图像, 每个病人包括 1 ~ 7 个肿瘤. 通过多通道 GAN 生成的 PET 图像 MAE 达到 4.6, PSNR 为 28.06. 通过 CT 图像进行多通道 GAN 生成的 PET 图像可以进行辅助诊断, 诊断正确率为 81.73%, F-score 63.84%; 利用真实 PET 图像进行诊断可以获得 88.31% 的精度, F-score 66.38%. 通过跨模态预测达到的辅助诊断正确率接近真实 PET 的诊断正确率, 作者提出利用此框架流程也可由 PET 生成 MRI, 框架流程如图 4 所示. 在传统模态预测方法中对不同模态图像的配准精度要求很高, 通过深度学习中对抗生成网络的方法可以逐步降低对配准精度的依赖, 直接进行端对端的图像预测研究.




图4 预测PET多通道GAN模型

此外, Rongjian L 等人早在 2014 年便利用 3D-CNN 进行了从 MRI 预测 PET 的工作^[48], 实验所用数据集为 Alzheimer's Disease Neuroimaging Initiative (ADNI) 中 830 个病例, 其中有 432 个病例样本不具有 PET 图像, 剩余样本同时具有 PET、MRI 图像. 将同时具有 PET、MRI 图像的数据对进行网络训练, 再用训练好的网络将剩余的 MRI 图像预测对应的 PET. 同样, 该实验采用将每个训练图像分成 500,000 个图像块来增大训练数据. 结果表明预测的 PET 可以提高数据完整度从而帮助提高诊断正确率.

6 总结与展望

本文对医学图像领域中一些有代表性的跨模态医学图像预测应用研究、预测方法做了较为全面的综述. 在 MRI 预测 CT、3T MRI 预测仿 7T MRI、彩色图像预测多光谱图像以及由 CT 或 MRI 预测 PET 图像等诸多研究中, 基于深度学习的预测方法都在预测精度及预测时间两方面更具优势, 生成的图像相较于传统方法可以获得更高的图像分辨率和更高的信噪比. 随着深度学习方法的普及和更多新算法的研究, 医学影像跨模态预测将成为一个新的医学图像处理研究热点. 本综


述认为未来将会有更多不同医学成像模态间的预测研究,甚至实现 2D 模态预测 3D 模态的研究. 目前模态预测的图像质量都与真实图像有一定的差距,这与现阶段的图像数量也有很大关系,预计在更多样本数据训练下,模态预测的图像质量将会有进一步的提高.

参考文献

- [1] 康雁. 医学成像技术与系统[M]. 北京:清华大学出版社,2014.
- [2] 田捷,杨鑫,秦承虎. 光学分子影像技术及其应用[M]. 北京:科学出版社,2010.
- [3] Greenspan H, Ginneken B V, Summers R M. Guest editorial deep learning in medical imaging: overview and future promise of an exciting new technique[J]. *IEEE Transactions on Medical Imaging*, 2016, 35(5): 1153 – 1159.
- [4] Brenner D J, Hall E J. Computed tomography-an increasing source of radiation exposure[J]. *The New England Journal of Medicine*. 2007, 357(22): 2277 – 2284.
- [5] Edmund J M, Nyholm T. A review of substitute CT generation for MRI-only radiation therapy[J]. *Radiation Oncology*, 2017, 12(1): 28.
- [6] Pereira G C, Traughber M, Muzic R F. The role of imaging in radiation therapy planning: past, present, and future[J]. 2014, 2014: 1 – 9.
- [7] 黄力宇. 医学成像的基本原理[M]. 北京:电子工业出版社,2009.
- [8] 王海鹏,等. PET/MRI 衰减校正技术研究进展[J]. *中国医学影像技术*, 2014, (02): 295 – 299.
Wang Hai-peng, et al. Developments of Attenuation Correction for PET/MRI[J]. *Chinese Journal of Medical Imaging Technology*, 2014, (02): 295 – 299. (in Chinese)
- [9] 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.
- [10] Hofmann M, Bezrukov I, et al. MRI-based attenuation correction for whole-body PET/MRI: quantitative evaluation of segmentation and atlas-based methods[J]. *Journal of Nuclear Medicine*, 2011, 52(9): 1392 – 1399.
- [11] Arabi H, Zaidi H. Magnetic resonance imaging-guided attenuation correction in whole-body PET/MRI using a sorted atlas approach[J]. *Medical Image Analysis*, 2016, 31: 1.
- [12] Burgos N, Cardoso M J, Thielemans K, et al. Attenuation correction synthesis for hybrid PET-MR scanners: application to brain studies[J]. *IEEE Transactions on Medical Imaging*, 2014, 33(12): 2332 – 2341.
- [13] Burgos N, et al. Iterative framework for the joint segmentation and CT synthesis of MR images; application to MRI-only radiotherapy treatment planning[J]. *Physics in Medicine and Biology*, 2017, 62(11): 4237 – 4253.
- [14] Arabi H, Zaidi H. One registration multi-atlas-based pseudo-CT generation for attenuation correction in PET/MRI[J]. *European Journal of Nuclear Medicine and Molecular Imaging*, 2016, 43(11): 2021 – 2035.
- [15] Andreasen D, Van Leemput K, Edmund J M. A patch-based pseudo-CT approach for MRI-only radiotherapy in the pelvis[J]. *Medical Physics*, 2016, 43(8): 4742 – 4752.
- [16] Torrado-Carvajal A, Herraiz J L, Alcaín E, et al. Fast patch-based pseudo-CT synthesis from T1-weighted MR images for PET/MR attenuation correction in brain studies[J]. *Journal of Nuclear Medicine*, 2016, 57(1): 136 – 143.
- [17] Breiman L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5 – 32.
- [18] Huynh T, Gao Y, Kang J, et al. Estimating CT image from MRI data using structured random forest and auto-context model[J]. *IEEE Transactions on Medical Imaging*, 2015, 35(1): 174 – 183.
- [19] Tu Z, Bai X. Auto-context and its application to high-level vision tasks and 3D brain image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(10): 1744 – 1757.
- [20] Andreasen D, et al. Computed tomography synthesis from magnetic resonance images in the pelvis using multiple random forests and auto-context features [A]. *Medical Imaging 2016: Image Processing [C]*. The International Society for Optics and Photonics, 2016. 9784.
- [21] Yang X F, Lei Y, Shu H K, et al. Pseudo CT estimation from MRI using patch-based random forest[J]. *Proceedings of SPIE-The International Society for Optical Engineering*, 2017, 10133: 101332Q.
- [22] Huynh T, Gao Y, Kang J, et al. Multi-source Information gain for random forest: An application to CT image prediction from MRI data [A]. *International Workshop on Machine Learning in Medical Imaging [C]*. Springer, 2015. 321 – 329.
- [23] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640 – 651.
- [24] Lecun Y. Deep learning & convolutional networks [A]. *IEEE Hot Chips Symposium [C]*. New York: IEEE, 2016. 1 – 99.
- [25] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436 – 444.
- [26] Goodfellow I J, et al. Generative adversarial nets [A]. *International Conference on Neural Information Processing Systems [C]*. MIT Press, 2014. 2672 – 2680.

- [27] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks [J]. arXiv preprint arXiv:1511.06434, 2015.
- [28] Nie D, Cao X, Gao Y, et al. Estimating CT Image from MRI Data Using 3D Fully Convolutional Networks [M]. Springer International Publishing, 2016.
- [29] Han X. MR-based synthetic CT generation using a deep convolutional neural network method [J]. Medical Physics, 2017, 44(4): 1408 – 1419.
- [30] Shin H C, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning [J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1285 – 1298.
- [31] Wolterink J M, Dinkla A M, Savenije M H F, et al. Deep MR to CT synthesis using unpaired data [A]. International Workshop on Simulation and Synthesis in Medical Imaging [C]. Medical Image Computing and Computer Assisted Intervention, 2017. 14 – 23.
- [32] Zhu J, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [A]. 2017 IEEE International Conference on Computer Vision (ICCV) [C]. Venice, Italy, 2018. 2242 – 2251.
- [33] Kolk A G V D, Hendrikse J, Zwanenburg J J M, et al. Clinical applications of 7 T MRI in the brain [J]. European Journal of Radiology, 2013, 82(5): 708 – 718.
- [34] Beisteiner R, et al. Clinical fMRI: evidence for a 7T benefit over 3T [J]. Neuroimage, 2011, 57(3): 1015 – 1021.
- [35] Bahrami K, Shi F, Zong X, et al. Reconstruction of 7T-Like images from 3T MRI [J]. IEEE Transactions on Medical Imaging, 2016, 35(9): 2085 – 2097.
- [36] Bahrami K, Shi F, Zong X, et al. Hierarchical reconstruction of 7T-like images from 3T MRI using multi-level CCA and group sparsity [A]. Medical Image Computing and Computer-Assisted Intervention [C]. Springer, 2015. 659 – 666.
- [37] Shilling R Z, Robbie T Q, Bailloleu T, et al. A super-resolution framework for 3-D high-resolution and high-contrast imaging using 2-D multislice MRI [J]. IEEE Transactions on Medical Imaging, 2009, 28(5): 633 – 644.
- [38] Huang H, He H, Fan X, et al. Super-resolution of human face image using canonical correlation analysis [J]. Pattern Recognition, 2010, 43(7): 2532 – 2543.
- [39] Bahrami K, Rekik I, Shi F, et al. 7T-guided learning framework for improving the segmentation of 3T MR images [A]. International Conference on Medical Image Computing and Computer-Assisted Intervention [C]. Springer, 2016. 572 – 580.
- [40] Bahrami K, Shi F, Rekik I, et al. Convolutional neural network for reconstruction of 7T-like images from 3T MRI using appearance and anatomical features [A]. Deep Learning and Data Labeling for Medical Application [C]. Springer International Publishing, 2016. 39 – 47.
- [41] Dong C, Loy C C, He K, et al. Image super-resolution Using deep convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295 – 307.
- [42] Kulkarni K, Lohit S, Turaga P, et al. ReconNet: non-iterative reconstruction of images from compressively sensed measurements [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. NEW YORK: IEEE, 2016. 449 – 458.
- [43] Zhang Y, M Brady N S S I, et al. Segmentation of brain MR images through a hidden markov random field model and the expectation-maximization algorithm [J]. IEEE Transactions on Medical Imaging, 2001, 20(1): 45 – 57.
- [44] Arad B, Ben-Shahar O. Sparse Recovery of Hyperspectral Signal from Natural RGB Images [M]. Springer International Publishing, 2016. 19 – 34.
- [45] Galliani S, Lanaras C, Marmanis D, et al. Learned spectral super-resolution [J]. arXiv preprint arXiv:1703.09470, 2017.
- [46] Lin J, Clancy N T, Elson D S. Recovering dense tissue multispectral signal from in vivo RGB images [J]. arXiv preprint arXiv:1707.03468, 2017.
- [47] Bi L, Kim J, Kumar A, et al. Synthesis of positron emission tomography (PET) images via multi-channel generative adversarial networks (GANs) [J]. Lecture Notes in Computer Science, 2017, 1055: 43 – 51.
- [48] Li R, Zhang W, Suk H I, et al. Deep learning based imaging data completion for improved brain disease diagnosis [J]. Medical Image Computing and Computer Assisted Intervention, 2014, 17(3): 305 – 312.

作者简介



周沛女, 1995 年出生, 硕博连读研究生在读, 主要研究方向为医学图像处理。

E-mail: 630005818@qq.com



陈后金 (通讯作者) 男, 1965 年出生, 博士, 教授, 主要研究方向为数字图像处理与模式识别。