



人工智能在放射影像中的应用

朱佳瑞¹, 滕琳², 宋立明¹, 刘晨阳¹, 陈卫兴³, 赵马阳¹, 肖昊男⁴, 王颖慧¹, 职少华⁵, 杨龙², 孙鸿飞⁶, 任格¹, 秦文健⁷, 蔡璟^{1*}, 沈定刚^{2*}

1. 香港理工大学医疗科技及资讯学系, 香港 999077

2. 上海科技大学生物医学工程学院, 上海 201210

3. 中山大学计算机学院, 广州 510006

4. 山东第一医科大学附属肿瘤医院(山东省肿瘤医院, 山东省肿瘤防治研究院), 放射物理技术科, 济南 250117

5. 岭南大学跨学科学院, 香港 999077

6. 空军军医大学西京医院, 西安 710032

7. 中国科学院深圳先进技术研究院, 深圳 518055

* 联系人, E-mail: jing.cai@polyu.edu.hk; dgshen@shanghaitech.edu.cn

2024-12-20 收稿, 2025-03-28 修回, 2025-04-02 接受, 2025-04-03 网络版发表

摘要 近年来, 人工智能技术的兴起为放射影像处理的相关应用提供了更加准确、更加高效的解决方案。人工智能技术的高速发展也在持续地为放射影像处理提供更实用、更具变革性的技术手段。人工智能技术多层次的特征提取模式显著提升了影像分析的精度, 其端对端的学习模式极大提升了影像处理的速度, 其多模态的学习能力则能提供更为全面的影像诊断结果。然而, 人工智能技术的内在局限性也引起广泛的关注。模型对高质量标注数据的依赖、模型的泛化能力与可解释性仍是人工智能在应用过程中的主要挑战。为了更好地厘清人工智能在放射影像处理领域的发展脉络, 明确未来的研究重点, 本文总结了近年来人工智能在放射影像诊断、配准、分割、生成与重建五个方面的代表性应用, 并基于共引用频率分析方法选取、介绍了相关的奠基性工作, 着重探究了人工智能在放射影像应用领域中普遍面临的挑战与最新的发展趋势。

关键词 人工智能技术, 放射影像, 影像配准, 影像诊断与分割, 影像生成与重建

放射学(radiology)起源于X射线的发现, 并随着时间推移逐渐衍生出放射影像学(radiography)、放疗学(radiotherapy)、放射生物学(radiobiology)、医学物理学(medical physics)与影像诊断学(diagnostic imaging)等多个学科。放射影像学重点关注放射影像的成像技术。放射影像目前泛指临幊上各类用于查看生物内部结构的医学影像。根据成像原理的不同, 放射影像可以分为基于X射线成像的X射线影像(X-ray)、基于放射性同位素的核医学成像、依靠磁场与无线电波成像的磁共振成像(magnetic resonance imaging, MRI)以及依靠声波成像的超声波影像(ultrasound, US)。其中, X射

线影像又可分为2D X-ray、荧光镜成像(fluoroscopy)与计算机断层扫描成像(computed tomography, CT)。CT又可分为普通的扇形束CT与放疗过程中常用的锥形束CT(cone-beam computed tomography, CBCT)。此外, 基于放疗过程中对于实时影像引导的需求, 包含时间序列的新型4D CT、4D CBCT、4D MRI等成像技术也受到广泛关注。

放射影像在疾病的检测、诊断与治疗的过程中均起到了至关重要的作用。X射线成像可以更清晰地检测骨骼、胸腔以及肺部等部位的异常。CT相比X射线影像可以提供更全面的影像信息, 常用于肿瘤、器官损

引用格式: 朱佳瑞, 滕琳, 宋立明, 等. 人工智能在放射影像中的应用. 科学通报

Zhu J, Teng L, Song L, et al. The applications of artificial intelligence in radiographic imaging (in Chinese). Chin Sci Bull, doi: [10.1360/TB-2024-1352](https://doi.org/10.1360/TB-2024-1352)

伤与血管病变的检测，并以其HU取值范围固定的特点，被广泛用于放疗计划的计算对象。MRI具有更高的敏感性与对比度，对于软组织有更好的显示效果，常用于检测脑部、肝部、头颈与脊柱等病变。超声波以其无辐射与低成本的特点，被广泛用于妇产科检查、肝脏与肾脏等器官健康状况的评估。核医学成像则利用放射性同位素，有效反映人体的代谢状况，进而更好评估器官与组织的功能状况，对于癌症与心血管疾病的分析与诊断具有更为准确的诊断价值。

随着放射影像的全面数字化，如何更好地识别、融合与发掘影像数据所包含的解剖学与病理学信息，与如何将提取到的信息便捷、准确并可信地用于解决具体的临床问题，已成为放射影像处理领域的两大挑战。而人工智能技术(artificial intelligence, AI)作为一种强大的数据分析与处理工具，自出现起便从这两方面为放射影像处理的各类具体应用持续提供更准确、高

效的解决方案。

如图1所示，人工智能技术在放射影像处理领域的发展大致可分为依赖于人工特征的迭代优化、机器学习、大数据驱动的深度学习、深度学习网络的革新、多模态多任务学习、大模型背景下的泛化性与可解释性学习等六个阶段。

AI技术在应用于放射影像处理的初期，主要采用基于规则的传统算法，这些方法依赖于手工特征提取和优化算法。例如，图像配准中常用的迭代最近点(iterative closest point, ICP)算法^[1]和基于互信息(mutual information, MI)的优化方法^[2]，这些基础的优化规则具有较强的图像特征描述能力与跨模态鲁棒性，为后来自动化配准与生成等技术奠定了基础。然而，这些方法在处理复杂的非线性关系时表现出较大局限性，难以满足临床需求^[3]。

随着计算能力和数据规模的提升，机器学习方法

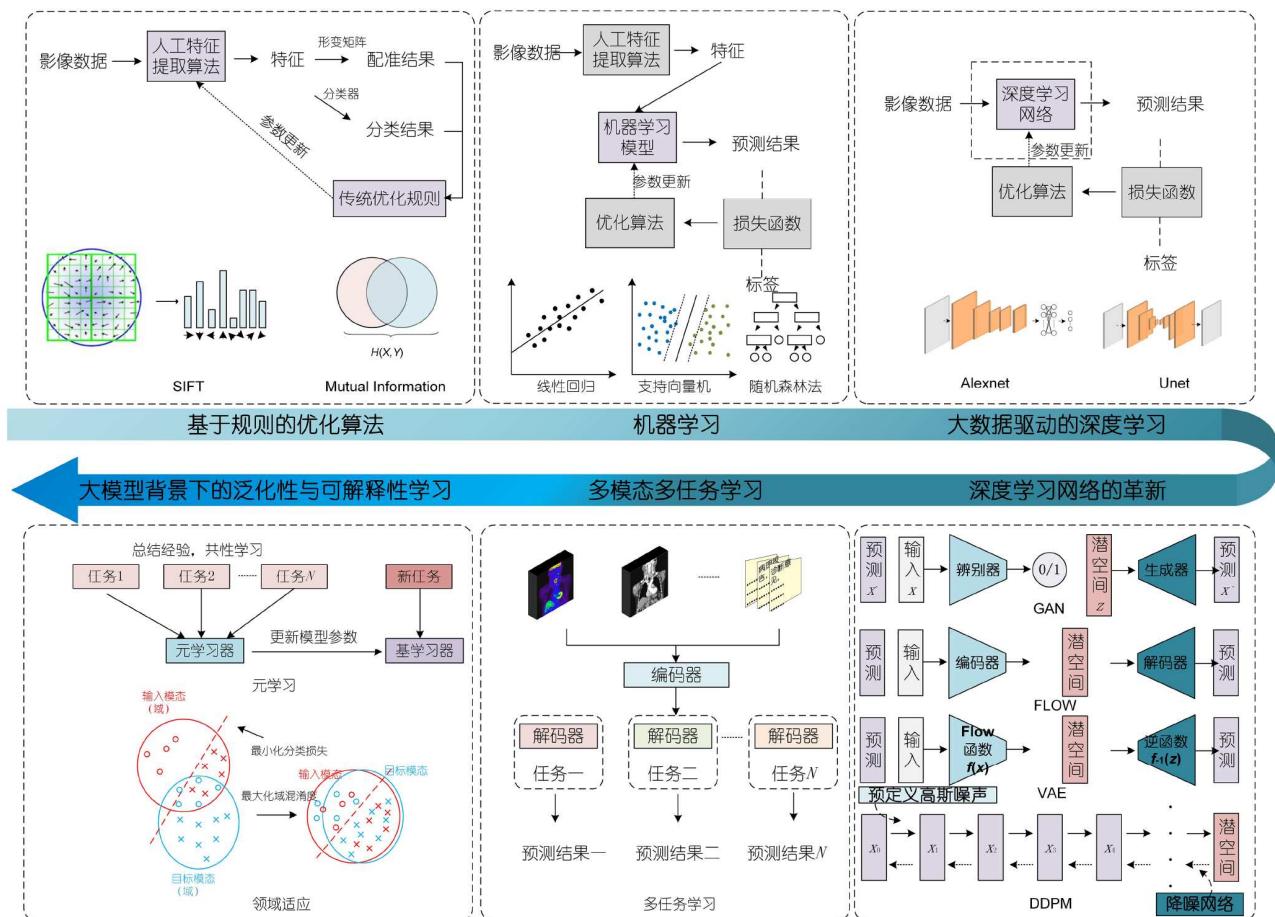


图 1 AI 技术在放射影像处理领域的发展趋势

Figure 1 The developing tendency of AI in radiological medical imaging processing

逐步兴起。机器学习的引入为医学影像分析带来了数据驱动的特征学习方法，相较于传统规则算法显著提升了性能^[4]。支持向量机(support vector machine, SVM)通过核函数机制在肿瘤检测和组织分类等任务中表现出色^[5]，而随机森林(random forest, RF)凭借集成学习的鲁棒性广泛应用于影像分割^[6]。机器学习技术通过提供高效的特征学习机制和初级标签生成能力，为后续深度学习的兴起奠定了坚实的基础。然而，这些方法对手工设计特征的依赖限制了其对复杂影像模式的全面表达能力，并在跨设备或跨数据集迁移时存在显著性能衰减。

随着深度学习的崛起，医学影像分析进入了端到端学习的智能化阶段。以卷积神经网络(convolutional neural network, CNN)为代表，深度学习突破了传统方法的特征依赖性，通过自动提取多层次特征显著提升了影像分析的效率和精度^[7]。2012年，AlexNet^[8]在ImageNet竞赛中的成功标志着深度学习的全面应用，其多层卷积结构和非线性激活机制为影像分类等任务设立了新标杆。在医学影像领域，U-Net^[9]等模型通过编码-解码结构实现了高效的多尺度特征捕捉，广泛应用于脑肿瘤、肝脏及心脏等复杂组织的分割任务。深度学习通过融合大规模标注数据进一步提升了性能，并在多模态融合中展现出独特优势。然而，这些模型对高质量标注数据的依赖，以及在泛化能力和可解释性上的局限，仍是其应用推广中的瓶颈问题。

在深度学习引领医学影像分析变革的背景下，新兴技术如生成对抗网络(generative adversarial network, GAN)的提出进一步拓展了深度学习的应用边界，增强了AI技术对于放射影像应用中数据稀缺和复杂任务等挑战的适应性^[10]。GAN通过生成器和判别器的博弈学习机制，在医学影像生成、增强和跨模态转换中表现出色，成为深度学习方法的重要延伸。其独特的无监督特性为医学领域解决数据稀缺问题提供了创新途径。例如，CycleGAN^[11]无需配对数据即可实现CT与MRI影像间的跨模态转换，为提升多模态诊断效率奠定了基础。同时，GAN在低质量影像的超分辨率重建和数据增强中展现了极大优势，通过生成高质量的合成影像有效改善了传统深度学习模型对小样本数据的依赖^[12]。光流模型(flow model)^[13]、变分自编码器(variational auto-encoder, VAE)^[14]、扩散模型(diffusion model)^[15]、Transformer^[16]等高性能模型的提出，也为影像生成与重建等任务提供了性能更优、过程更透明的全

新方法架构。这些应用进一步补充了深度学习对复杂特征的建模能力，使其在异构数据和非结构化任务中更具适应性。然而，这些自然图像处理领域的新兴技术，在处理信息量更大、信息模式更复杂的放射影像时，仍面临诸多挑战，如生成影像的真实性与可解释性、训练过程中的不稳定性和模式崩溃等问题^[17]。通过与现有卷积神经网络和弱监督学习技术的结合，这类以GAN为代表的新兴图像处理技术在医学影像分析中的潜力被持续挖掘，为多模态融合与精准诊断提供了强有力的工具支持，进一步深化了深度学习的实际影响力。

在生成对抗网络(generative adversarial network, GAN)等新兴模型进一步推动医学影像生成和增强的同时，人工智能技术的发展逐渐迈向多模态与多任务学习的智能整合阶段，强调为复杂医学问题提供系统化的解决方案。多模态学习通过融合不同影像模态(如CT、MRI、PET)的空间与语义信息，充分发挥各自的互补性，显著提高了影像配准、分割和诊断的准确性。例如，基于深度学习的多模态配准方法能够同时捕捉结构和功能特征，提升异质数据分析的鲁棒性^[18]。此外，多任务学习通过共享底层特征表达，在分割、分类与检测等任务中实现协同优化，有效缓解了单任务模型对高质量标注数据的依赖，同时增强了模型的泛化能力^[19]。Transformer等新型架构的引入进一步推动了多模态与多任务学习的革新，其全局注意力机制使得捕捉影像中的长距离依赖关系成为可能，为复杂结构特征的联合建模提供了全新路径。尽管如此，这一阶段的核心挑战仍在于如何协调多模态数据的差异性与多任务目标之间的潜在冲突。通过结合生成对抗网络进行数据补全以及弱监督和自监督学习技术，人工智能在多模态与多任务场景下的适应性与实用性得到了进一步提升。

随着多模态与多任务学习的逐步成熟，人工智能在医学影像分析中的未来发展逐渐聚焦于泛化能力与可信性的提升，以应对实际临床应用中的复杂挑战^[20]。尽管深度学习在特征建模、数据生成和多模态融合方面取得了显著进展，其性能却往往依赖于高质量和分布一致的训练数据，而在跨设备、跨人群和跨机构的迁移中表现出显著的性能退化^[21]。因此，提升模型的泛化能力成为AI医疗影像研究的关键目标。元学习(meta-learning)^[22]和领域适应(domain adaptation)^[23]等技术为解决分布偏移问题提供了潜在路径，通过学习跨任务

的共享知识或生成领域不变特征，从技术层面提升了模型对新场景的适应性。随着人工智能技术热度的不断提升，大量资源的投入也从数据层面催动ChatGPT^[24]、Segment Anything^[25]等对图像与文本具备复杂理解力的大模型出现，也为影像处理的各类应用提供了更具泛化性的强大工具。随之而来的重大挑战是如何有效将大模型迁移到医学影像处理领域^[26]。此外，可信AI的构建则是另一个核心问题，特别是在医学决策中，其结果的透明性、可靠性和可解释性直接影响其临床接受度。当前，基于注意力机制^[27]和因果推断^[28]的可解释性研究正在快速发展，为理解深度模型的决策依据提供了理论支持。同时，弱监督和自监督学习的引入缓解了高质量标注数据的需求，增强了模型在数据稀缺场景下的适用性^[29]。

在人工智能技术高速发展的今天，如何准确定位临床需求，并合理结合现有技术，以开发可适应多种临床场景的智能模型，已成为当前人工智能在放射影像应用处理领域的关键问题。本文旨在梳理人工智能技术在放射影像处理领域的应用发展脉络，明确各类具体应用的现存挑战与解决方案，以更好地推动适应复

杂临床场景的高性能智能模型的开发。如图2所示，本文基于共引用频率分析方法^[30]，将人工智能在放射影像中的应用分为了影像诊断、配准、分割、生成与重建等五个方面，总结了近年来人工智能在放射影像这五个方面应用中的代表性工作，选取并介绍了人工智能技术兴起以来高频出现的奠基性工作。

本文首先概述人工智能在放射影像处理领域中的应用趋势，然后介绍人工智能在放射影像诊断、配准、分割、生成与重建五个方面的具体应用，最后总结全文并讨论挑战与未来展望。

1 人工智能在影像诊断中的应用

本节重点探讨AI技术在放射影像诊断中的具体应用，包括病灶检测与定位、疾病分类与诊断，以及诊断报告生成，深入分析AI技术在提升诊断效率和准确性方面的贡献。

1.1 背景介绍

放射影像诊断一般指医生对放射影像的图像解读。X射线成像、CT与MRI是放射影像诊断过程中的常见

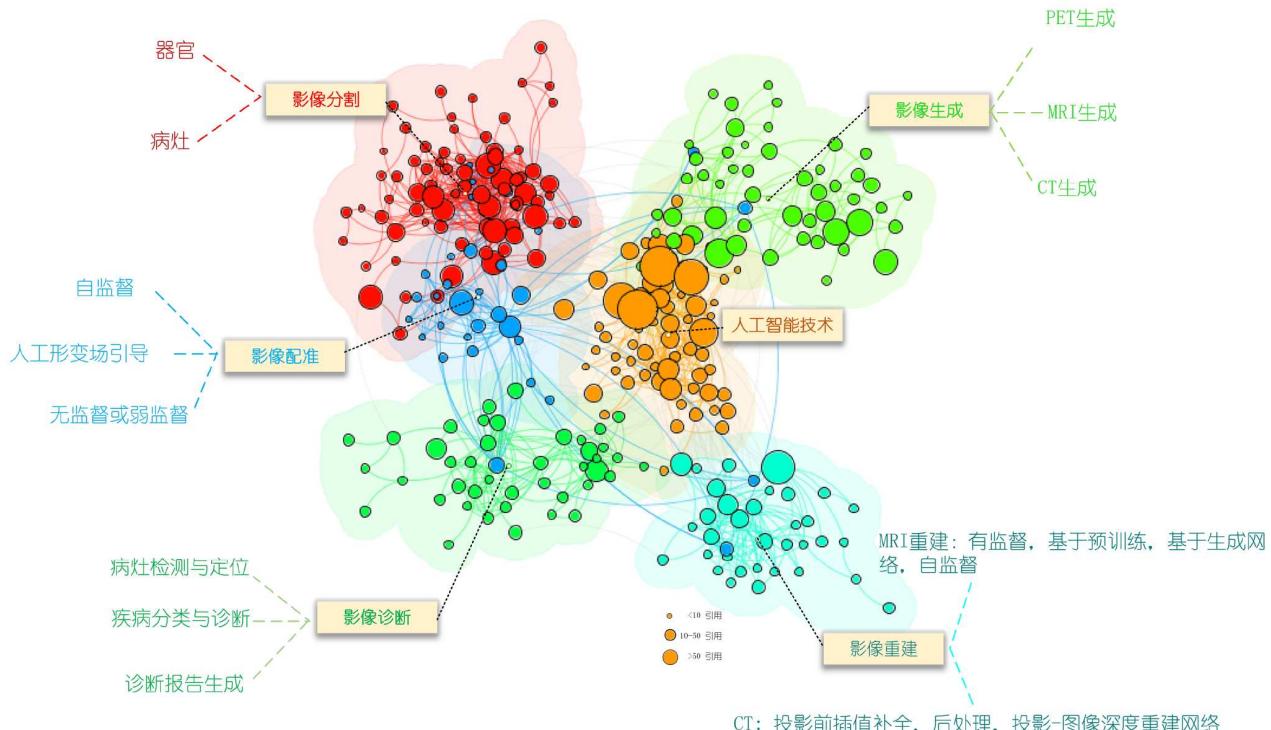


图 2 AI技术在放射影像领域相关应用的工作总结

Figure 2 Work summary of the applications of AI in radiological imaging

模态。其中, X射线成像被普遍用于基层医疗, 作为疾病筛查的主要手段。CT在肿瘤诊断中发挥核心作用。MRI则以优异的软组织对比度主导神经系统疾病诊断^[31], 并被广泛用于头颈癌等周边软组织密集的肿瘤诊断。尽管传统放射诊断技术已取得巨大发展, 但其仍面临着诊断标准的不一致、人工诊断的高工作负荷, 以及微小病灶的易漏诊等挑战^[32]。AI技术的引入为影像诊断提供了更普适、更高效、更全面的解决方案。

AI辅助的影像诊断的发展经历了三个阶段: 初期主要依赖人工设计的特征与传统的机器学习方法, 虽然诊断的效率有较大提升, 但应用场景与诊断准确度均相对局限; 随着卷积神经网络在影像分析中的广泛应用, AI辅助诊断模型的准确度不断上升, 但数据的难以取得严重限制了模型的泛化性能; 随着迁移学习、联邦学习与多模态学习等技术不断成熟, 大量的数据输入使小样本场景的泛化问题得以解决, 多模态的信息来源也在持续提升微小病灶的识别精度与疾病诊断的准确性。目前AI辅助诊断技术的准确性与多中心泛化性日渐成熟, 并被逐步应用于临床, 形成了规范化的诊断体系^[33]。AI辅助诊断系统在临床实践中的应用价值也日益凸显。根据预测目标的不同, 目前AI辅助影像诊断的相关工作可分为针对病灶的检测与定位、针对疾病的分类与诊断, 以及综合性自动诊断报告的生成。

1.2 病灶检测与定位

病灶检测与定位是AI辅助影像诊断的核心任务之一, 其目标是通过对影像中异常区域的精准识别与标记, 为疾病诊断和治疗规划提供直接依据。

依照方法框架的不同, 深度学习框架在影像诊断领域的应用可分为两大类: 以Faster R-CNN为代表的两阶段检测框架通过分布设计, 先基于临床先验信息生成候选区域, 后进行基于区域的病灶检测, 虽然需要人工的介入, 但是实现了较高的检测精度^[34]; 以YOLO和SSD为代表的单阶段检测框架则采用端到端的设计思路, 虽然具有更高的检测速度, 但是也牺牲了部分诊断精度。在这两种方法框架的基础上, DETR^[35]、Swin Transformer^[36]的引入则借助更强大的特征建模能力和更灵活的架构设计, 进一步提升了检测的性能。

AI辅助检测定位病灶的技术在多种医学影像模态的临床应用中均取得显著进展。对基于胸部X射线影像肺结节的检测, PN-DetX模型通过特征增强和上下文聚

合机制, 相比现有方法显著提升了检测准确度(mAP提升3.8%, AP0.5提升5.1%), 显著提升了早期肺癌筛查的效率^[37]。对基于CT的胰腺癌检测, PANDA模型通过多尺度特征提取和深度特征融合策略, 在包含20530名患者的真实场景验证中达到92.9%的敏感度和99.9%的特异度, 其诊断效果可媲美增强CT, 大大推进了大规模癌症筛查的实施^[38]。对基于MRI的前列腺癌检测, Lin等人^[39]提出的级联深度学习算法通过双参数MRI分析, 在658名患者的验证中实现了96%的临床显著性病变检出率, 其性能与经验丰富的放射科医师相当, 为规范化诊断提供了可靠的辅助工具。对基于PET的病灶检测, Shao等人^[40]结合CNN和Transformer并通过多分支特征提取策略, 在肝脏和肺部病变识别中展现出优于传统方法的检测性能, 其判断能力与临床专家相当, 为病灶检测的自动化评估开辟了新途径。

1.3 疾病分类与诊断

疾病分类与诊断是AI辅助影像诊断中的另一项关键任务, 其目标是通过对医学影像的系统分析, 实现疾病的准确识别、分类和分型。

卷积神经网络(CNN)以其独特的局部特征提取能力, 是初期解决疾病分类与诊断问题的有效手段。以EfficientNet^[41]为代表的新一代CNN架构通过复合缩放方法优化网络结构, 在维持较低计算复杂度的同时实现了优异的诊断性能。特别是在处理二维医学影像时, 其多尺度特征提取能力显著提升了病变识别的准确性。2021年以来, Transformer架构凭借其在处理长序列和建模全局依赖方面的优势, 开始在医学影像分析领域崭露头角。尤其是Swin Transformer等针对视觉任务优化的变体, 通过层次化的特征表达和改进的注意力机制, 在多个诊断任务中展现出超越传统CNN的潜力, 为复杂病变的诊断提供更全面的分析视角^[36]。

AI辅助分类诊断技术在多种医学影像疾病诊断中展现出优异的性能和实用价值。在侧位脊柱X射线影像分析中, VERTE-X模型通过构建双评分卷积神经网络系统, 在26299张X射线影像的验证中实现了0.93的椎骨骨折检出AUC值和0.85的骨质疏松诊断AUC值, 显著优于传统临床模型的诊断效能^[42]。对基于CT的颈部血管狭窄诊断, Fu等人^[43]通过血管狭窄分级和斑块特征的智能分析进行建模, 在3266名患者的验证中实现了85.6%的分类准确率, 不仅达到了与经验丰富的放射科医师相当的诊断水平, 还将诊断报告时间从28.8 min

缩短至12.4 min。在基于MRI的前列腺癌诊断中，可解释人工智能模型通过双序列MRI特征分析，在3260个前列腺病灶的验证中实现了0.89的AUC值，不仅提供了基于PI-RADS标准的诊断解释，还将非专家医师的阅片时间缩短了58 s^[44]。同时，自监督学习的引入有效解决了医学影像疾病分类标注数据不足的问题，显著提升了分类模型在小样本场景中的泛化能力^[45]。

1.4 诊断报告生成

自动诊断报告的生成是一种全面分析病人解剖学特性与生理状态，并兼具病灶检测与疾病诊断的综合性AI辅助影像诊断方案。自动诊断报告生成技术可以较大程度减轻放射科医生的工作负担，并能提供更具解释性的诊断预测结果，具有很大的临床潜力。

目前AI辅助的临床报告生成技术主要围绕大语言模型和多模态融合技术展开方法设计。基于大语言模型的工作一般利用临床文本数据，针对现存的大语言模型进行适应性插件的设计或专业场景的知识蒸馏，如Me-LLaMa^[46]、Med-PaLM2^[47]和BioBERT^[48]。基于多模态融合技术的工作通过整合影像与文本数据，以弥补单一模态的信息缺失，进一步提升诊断报告生成的精准度。多模态诊断报告生成技术在许多临床应用场景中均取得了不俗的表现。对基于胸部X射线成像的诊断报告生成，主流研究大致分为三种趋势：一些研究利用先验的医学标签指导视觉编码器提取与疾病相关的视觉特征^[49]，一些研究通过构建医学知识图谱来寻找疾病和器官之间的关联性^[50]，其余研究则是利用对比学习来促进医学图像和报告之间的跨模态对齐^[51]。文字与图像关联性的计算复杂度以及数据稀缺性限制了基于3D影响的诊断报告生成，如何结合诊断报告高效提取并对齐3D影像特征也是近期的研究热点，如CT2Rep^[52]在传统架构基础上利用了一种新颖的3D自回归因果视觉特征提取器，提升了模型对于细小病灶的检测能力。Chen等人^[53]提出了Dia-LLaMa，使用ViT3D来提取脑部CT的三维视觉特征，并结合疾病的临床诊断信息以定制针对疾病特性的三维脑部CT诊断报告生成方案，取得了良好的疾病诊断准确度。He等人^[54]单独分割MR中央矢状切片中的腰椎间盘区域，并将分割结果作为先验知识结合轻量文本生成网络进行诊断报告预测，其预测结果对于腰椎部分病灶的检测与疾病诊断的准确度均有显著提升。

2 人工智能在影像配准中的应用

本节重点讨论AI技术在放射影像配准中的具体应用，包括自监督配准模型、由形变场引导的配准模型以及基于无监督或弱监督学习的配准模型，深入分析AI技术在提升配准准确性、配准速度以及解决跨模态配准难题方面的贡献。

2.1 背景介绍

影像配准一般指利用形变矩阵将不同影像移动到同一空间坐标系的过程。配准操作通常在固定图像和移动图像两种图像之间进行。基于形变矩阵数学特性的不同，影像配准也可分为线性的刚性配准以及非线性的弹性配准。刚性配准的形变矩阵按照自由度的不同又可分为位移矩阵、旋转矩阵等。非线性弹性配准的形变矩阵常使用向量数与图像像素点数目一致的形变矢量场(deformable vectors fields, DVF)。相较于传统的基于人工特征的配准方法^[55]，基于AI的放射影像配准技术在准确性与配准速度两方面均有显著提升。同时基于AI的影像配准技术也能解决传统方法难以解决的宽基线配准、形变程度大的弹性配准以及跨模态配准问题。AI配准技术关键在于如何确定合适的损失函数以迭代优化形变矩阵的参数。而固定图像与移动图像的空间位置差异、解剖学形态差异以及扩模态分布差异是网络与优化策略设计的主要挑战。

2.2 自监督配准模型

自监督配准方法指利用深度学习网络直接从移动图像生成形变后的图像，并将形变后图像与固定图像的图像相似度差异作为损失函数引导网络迭代优化。在生成形变后图像的过程中，一般先利用深度学习网络从固定图像生成DVF，再使用DVF对移动图像进行形变。目前的自监督配准模型普遍使用CNN网络中的卷积层进行DVF的生成，并根据应用特点的不同引入先验知识以改进网络设计。如Fan等人^[56]通过带有间隙填充的U-Net实现了脑部MRI的准确配准。Cao等人^[57]构建了基于AlexNet的 $15 \times 15 \times 15$ 三维体素配准模型，并在CT和MRI的单模态配准应用中均取得良好表现。此外，Onieva^[58]基于强化学习策略设计配准网络，也取得了较好的肺部CT配准效果。对于损失函数的选择，均方误差(mean squared error, MSE)和平均绝对误差(mean absolute error, MAE)仍是单模态配准常用的图像相似

度差异描述公式。而扩模态配准则更多使用互信息描述图像差异。

2.3 由形变场监督的配准模型

由形变场监督的模型基于有监督学习范式，通过计算网络生成的形变场与真实形变场的差异以引导网络迭代优化。由于真实形变场难以取得，目前的工作一般直接模拟形变过程以获得形变场，或使用传统的配准方法，如ANTs、Syn、Demons、表面匹配和微分同胚映射(large deformation diffeomorphic metric mapping, LDDMM)等算法直接生成形变场。模拟性形变场生成的代表性工作如Krebs等人^[59]提出的基于感兴趣区域轮廓匹配与统计变形模型模拟形变场的方案。Sokooti等人^[60]提出了一种基于少量随机控制点，结合高斯滤波器进行平滑，以模拟包含不同空间频率的人工DVF的方案。这两种思路在通常的单模态配准问题上取得了与最先进方法相当的精度，也可用于解决挑战性较大的单模态宽基线配准或弹性配准等问题，但其配准的真实性与准确性往往受限于所采用的模拟或传统配准方法。

2.4 基于无监督或弱监督学习的配准模型

为了解决真实形变场数据缺失的问题，无监督或弱监督配准模型直接将少量不配对的真实形变场作为学习目标，并基于损失函数的设计提升配准性能。其损失函数一般包含DVF正则项，以及形变场之间或形变后图像与固定图像之间的差异性描述项。DVF的正则化函数一般采用DVF空间梯度描述函数^[61]。一些工作也将DVF正则化项进一步扩展到DVF空间梯度的一阶和二阶组合^[62]。DVF正则项的优化具有较大的计算负荷。为了提升计算效率，Krebs等人^[63]使用Kullback-Leibler (KL)散度将预测的DVF正则化到先验的可能性分布。而为了实现更对称更真实的配准，Kuang等人^[64]使用循环一致性损失正则化DVF，将变形的图像再变形回移动图像，并基于它们之间的差异性进行优化。除了使用正则项约束形变场的生成，Balakrishnan等人^[65]也提供了一个弱监督的学习策略，将结构轮廓的差异性也作为损失函数的一项。

无监督和弱监督配准模型更依赖先验信息的约束以及模型的学习能力，因为网络设计也往往更具复杂度。最常见的引入先验信息约束的方式是在训练样本的预处理过程中增强ROI区域，如Jiang等人^[66]将Lucas-

Kanada方法的第一次迭代所得到的包含ROI区域增强信息的光流函数同时作为输入的一部分，以提高配准精度。在模型的设计上，常见的设计思路是增加网络的深度，或进行基于U-Net架构的多尺度训练，进行由粗到细的配准^[67]。基于GAN的配准网络设计也取得了较高的配准精度^[68]。此外，通过结合运动估计与图像超分辨率重建技术，基于U-Net的配准网络在4D CBCT的图像配准中也取得了高性能的表现^[69]。

3 人工智能在影像分割中的应用

本节重点讨论AI技术在放射影像分割中的具体应用，包括针对普通器官的分割模型与针对病变区域的分割模型，深入分析AI技术在提高分割准确性方面的贡献。

3.1 背景介绍

放射影像分割是指将放射影像分成若干个特定的、具有独特性质的区域并提取出感兴趣目标如器官、组织、病灶等的技术。相较于医生的手动勾画，基于AI技术的自动影像分割技术更快速、更准确，而且能更好地融合多模态信息给出综合的分割结果。基于AI的放射影像分割技术在临幊上具有重要的实际应用意义，如帮助医生从影像中准确提取出病灶区域，如肿瘤、血管瘤、炎症等，提高对复杂或细微结构的识别能力并进而提升诊断精度及效率。基于AI的放射影像分割技术还可以量化病变区域的动态变化，如肿瘤体积的变化、器官萎缩程度等，提供客观的疗效监测依据。分割结果的准确性是目前相关研究的主要关注点，如在癌症病人的放疗计划阶段，器官与靶区的分割准确性直接影响最终放疗计划方案的质量。此外，多中心泛化性、多模态分割以及复杂病灶的高精度分割也是当前基于AI的放射影像分割技术的重要挑战。

随着深度学习技术的快速发展，许多创新的影像分割算法在准确性和效率上取得了显著提升。目前的主要方法可分为：基于监督学习的分割，通过已标注数据训练模型以自动分割图像中目标区域；基于半监督学习的分割，利用小规模的标注数据集和大量的未标注数据训练模型；基于无监督学习的分割，利用无标注数据训练模型，通过聚类、特征提取等方式进行分割。目前主流的放射影像框架均使用CNN或者结合Transformer结构，构建模型的编码器和解码器，例如经典的U-Net^[9]、V-Net^[70]和SwinUNETR^[71]。其损失函数一般

采用交叉熵损失函数、Dice系数损失函数和Focal损失函数引导模型的优化。

3.2 针对普通器官的分割

人体器官指的是身体内具有特定形态和功能的独立结构，每个器官通常由不同的组织(如肌肉组织、上皮组织等)构成，例如大脑、心脏、肝脏等。器官分割是计算机辅助诊断、疾病分析和术前规划的重要环节。通过自动或半自动地识别并分割图像中的特定器官区域，能够帮助临床医生更加精确地定位和测量目标组织，提高诊断的准确性和效率。例如，Teng等人^[72]提出一种基于知识引导的脑分割模型，自动分割脑组织和脑结构，用于量化分析全生命周期的脑发育和衰老轨迹。Zhuang等人^[73]提出一种基于配准的传播框架，能够准确提取心室(左心室、右心室)和心房(左心房、右心房)，帮助医生快速评估先天性心脏病、瓣膜病变等结构性疾病，提升诊断效率。You等人^[74]提出一种基于Wasserstein距离引导的域自适应模型，自动分割多模态的肝脏，可以帮助医生准确定位肝脏肿瘤的位置、体积和形状，为肝癌的诊断和分期提供重要依据。

3.3 针对病变区域的分割

病变区域通常指肿瘤、炎症、出血、梗死等异常组织，其分割结果能帮助医生准确地评估病灶的大小、位置、形状和病理特征，为制定治疗方案和评估预后提供科学依据。具体来说，在脑卒中或动脉瘤的诊断中，分割能直观显示出受影响的脑组织范围，例如，Seo等人^[75]提出MU-Net，从MRI图像上自动分割脑胶质瘤。Li等人^[76]提出一个基于U-Net的分割框架，用于自动检测和分割CT脑图像中的出血性中风。而对于肺部病变或肝脏肿瘤，分割结果可支持体积定量分析，指导靶向治疗。例如，Gerard等人^[77]提出使用多分辨率卷积神经网络从CT图像中分割炎症和纤维化肺部。Chen等人^[78]提出一种基于CNN的MRI左心室心肌梗死自动分割方法，用于分割在注射造影剂10分钟后的心肌梗死，为临床医生提供直观的病变分布信息。

3.4 基于AI的四维影像分割技术

AI在四维图像中全自动勾画方面的潜力也备受关注。在四维成像中，医师通常需要在每个呼吸相位上手动勾画目标区域，这是一项耗时费力的工作，极大增加了临床工作负担，而且人工勾画容易引入主观错误。人

工智能的自动勾画功能能够在所有呼吸相位上实现精准的目标区域勾画，显著减少了人工操作时间，从而降低了成本，并减少了由于手动操作可能带来的误差。例如，Li等人^[79]利用在ImageNet数据集上预训练的Inception V3架构对每个呼吸阶段的肿瘤进行分割，并将这些分割结果结合起来，以预测非小细胞肺癌患者的内部肿瘤。该研究显示了深度学习在提高目标区域精准勾画方面的潜力。这种自动化的解决方案不仅提升了四维成像的整体工作效率，减少了手动勾画的繁琐流程，同时还优化了整个影像处理流程，为实现个性化的精准放疗提供了强有力的技术支持。

4 人工智能在影像生成中的应用

本节重点探讨AI技术在放射影像生成中的具体应用，包括对于PET、MRI和CT等多种影像模式的模态转换与图像质量增强，深入分析AI技术在减少生成计算时间与增强关键解剖信息方面的贡献。

4.1 背景介绍

在计算机视觉领域，基于AI的图像生成技术有着广阔的应用范围，并可细分为文本-图像生成、图像模态转换、超分辨重建、缺失图像估计以及带注释数据集创建等许多方面^[80]。在放射或医学影像生成领域中，影像生成的分类一般立足于应用场景，强调如果在图像模态转换或增强降噪等过程中保留关键的解剖信息^[81]。本文依照最终生成目标模态的不同，将基于AI的放射影像生成技术分为面向CT、面向PET以及面向MRI的影像生成工作。

4.2 正电子放射断层扫描影像(PET)的生成

接受PET检查的患者需要注射大量放射性示踪剂，这会导致一定程度的辐射暴露，可能对患者造成较大危害，特别是对于需要多次检查的患者或有较高终生癌症风险的儿童患者。降低示踪剂的剂量可以减少辐射暴露，但是会降低图像质量，包括噪声、伪影的增加以及成像细节的缺失。因此，基于AI的PET影像生成或低质量PET图像质量增强技术受到广泛的研究，由AI生成的高质量PET影像对于提高癌症检测的准确性、监测肿瘤反应以及优化治疗计划具有重要意义。

4.2.1 CT、MRI-PET影像跨模态转换

PET影像合成技术一般指从CT或MRI等影像直接进行跨模态转换，合成PET影像。U-net模型是实现这一

转换的常用手段。如Apoorva等人^[82]首次引入了一种基于3D卷积U-Net模型的全局非线性方法，用于从MRI合成PET图像，捕捉MRI与PET图像之间的全局相关性。然而，由U-Net生成的影像通常面临解剖学细节缺失、轮廓模糊等成像质量问题，而GAN网络的引入则有效提升了成像细节的清晰度。如GLA-GAN网络^[83]利用结构相似性指数作为损失函数，以实现图像解剖学结构信息的有效还原。Shin等人^[84]尝试将GAN与Transformer相结合，通过自注意力机制与随机遮蔽预测机制，实现了较为完整的解剖学细节还原以及高质量的PET图像生成。

4.2.2 低质量PET影像质量增强

类似于PET影像合成技术，低质量PET影像增强技术也普遍采用各类深度生成网络实现图像质量的增强。如Sanaat等人^[85]使用U-Net模型在图像空间和投影空间中优化低剂量PET图像质量。而为了补全低质量PET影响本身信息的缺失，一些研究引入了CT与MRI等相关影像作为输入，并结合多模态融合技术实现多模态输入的PET影像质量增强。Wang等人^[86]结合GAN与局部自适应多模态融合技术，自适应调整各图像区域的贡献，实现了从低剂量PET和多模态MRI图像合成高质量的PET影像。Zhang等人^[87]结合ViT框架增强PET和MRI模态之间的全局上下文关系和互补信息整合，实现了具有较好去噪性能的低剂量PET影像质量增强。

4.3 MRI影像的生成

MRI成像通过不同的脉冲序列生成具有诊断价值的组织对比信息：T1加权图像可清晰显示灰质与白质的解剖结构，T2加权图像则能有效区分液体与皮质组织。多种对比度图像的联合应用可显著提升诊断信息的丰富度。然而，传统多序列扫描存在明显局限性：首先，长时间检查不仅增加医疗成本，还可能导致患者（尤其是儿童和老年群体）配合度下降；其次，为缩短扫描时间而获得的对比图像可能因噪声干扰或伪影影响而降低诊断可靠性；此外，多样化的成像协议和对比度参数设置往往导致图像数据的异质性。针对这些问题，基于现有序列合成缺失或目标序列图像的技术方案应运而生，该方案不仅能够提高多对比度MRI的临床可用性，还可有效降低检查成本、提升诊断准确性，同时减少患者的检查风险。如Zhao等人^[88]研究提出了一种新型MRI-Trans-GAN架构，该架构创新性地采用了非对称三维块处理策略：在矢状面和冠状面使用较大的3D

块，而在垂直轴向上采用较小的块。这种设计不仅有效降低了内存占用，还保持了相邻切片间的空间关联性，成功实现了从T1加权图像到T2加权图像等不同MRI模态间的跨序列合成。Yan等人^[89]设计了一种基于Swin Transformer的生成对抗网络，旨在解决传统视觉Transformer在MRI图像合成中难以有效捕捉全局特征和建模长距离依赖关系的技术瓶颈。该方法特别适用于具有复杂解剖结构的MRI图像，能够生成既保留源模态内容特征又具备目标模态风格特征的合成图像。

4.4 CT影像的生成

CT在软组织对比度上表现不佳，特别是在大脑、头部、颈部和盆腔区域，这使得直接勾画关键器官和目标区域变得具有挑战性。此外，反复进行CT扫描会使患者暴露于额外的电离辐射，带来潜在的健康风险。通过MRI合成CT图像，可以显著增强软组织对比度和减少辐射暴露。这种方法能够更好地勾画关键结构和目标区域，提高放射治疗计划的精确性和安全性。此外，CT作为癌症治疗过程中用于放疗计划的主要影像，因为受限于成本与设备采集条件，所以在放疗过程中难以多次采集。相应地，CBCT以其锥形束采集的特点被广泛应用于放疗过程中患者信息的采集，但是CBCT影像通常成像质量低、噪声伪影严重。因此，CBCT质量的增强技术，即从CBCT到CT的跨模态质量转换，也受到了研究者的广泛关注。

4.4.1 MRI-CT跨模态转换

如何有效结合MRI与CT的成像特点，以进行先进的深度生成模型的迁移，是MRI-CT跨模态转换技术的关键。Fu等人^[90]首次展示了一种端到端的3D CNN应用，用于将骨盆的MRI图像转换为CT图像。Sui等人^[91]采用混合目标函数集成对抗损失、像素转换损失和结构一致性损失，确保生成的CT图像在视觉真实感、电子密度信息准确性及与MR图像的结构一致性上有所提升。Li等人^[92]结合MRI引导的DM模型和稀疏视图CT测量嵌入，克服了传统CT重建中因投影数据稀疏导致的信息不完整问题，通过范围-空值空间分解，显著提升了合成CT图像的结构和解剖细节的精确度。

4.4.2 CBCT-CT跨模态转换

CBCT增强技术的难点在于CBCT与CT解剖学结构的空间不对称性。多数研究使用配准技术缩小CBCT与目标CT的空间差异，并基于像素差异进行优化。如Dahiya等人^[93]使用U-Net模型进行CBCT-CT跨模态转

换, 虽然收敛速度快, 但是生成图像解剖学细节模糊。Kurz等人^[94]使用Cycle GAN模型直接学习CBCT与CT的不对称性, 实现了较好的解剖学细节还原以及良好的去噪效果, 但是该模型泛化性十分有限。Zhu等人^[95]使用视觉损失优化框架替代像素损失, 实现了完整的解剖学细节保留与较好的去噪效果, 且模型具有优良的多中心泛化性。

5 人工智能在影像重建中的应用

本节重点探讨AI技术在放射影像重建中的具体应用, 包括MRI的重建, 以及CT和CBCT的重建, 深入分析AI技术在提升影像重建速度与增强重建质量方面的贡献。

5.1 背景介绍

放射影像重建一般指基于放射影像采集设备的原始数据生成可视化影像的过程。常见的影像重建应用包括由X射线投影数据生成CT影像, 以及由k空间数据生成MRI影像。根据原始数据采集过程是否包含了呼吸周期等时序信号, 影像重建又可分为三维影像重建与四维影像重建。传统重建方法庞大的计算负担带来的低重建速率, 以及原始数据有限时产生的低重建质量, 是影像重建技术长期以来面临的两大挑战。AI技术的引入一方面极大加快了影像重建的速度, 另一方面也显著提升了有限数据条件下的影像重建质量。

5.2 基于AI的MRI重建算法

根据应用AI技术的不同, 基于AI的MRI重建技术可分为基于监督学习的MRI重建算法、基于预训练以及无需训练的MRI重建算法、基于生成式神经网络的MRI重建算法, 以及基于自监督学习的MRI重建算法。

5.2.1 基于监督学习的MRI重建算法

基于监督学习的MRI重建算法通常利用端到端的神经网络, 构建一个由降采样数据到配对的全采样(金标准)数据集的映射。早期最著名的AUTOMAP结构利用全连接神经网络和卷积神经网络将降采样的k空间信号映射至图像域, 并利用配对数据集进行模型训练^[96]。更常见的端到端训练则为图像域到图像域的映射, 此类方法利用U-Net、ResNet等卷积神经网络架构, 又或是目前流行的transformer架构^[97], 将粗略重建的图像(例如零采样填充)映射到目标图像, 以此来实现提升重建速度抑或提高图像质量^[98]。当下, 基于展开(un-

rolled)结构的监督学习架构实现了最佳的重建性能。该结构将传统迭代算法(例如梯度下降)展开, 把传统约束项(例如全变分)替换为深度神经网络并加以监督训练。这种基于深度学习的约束项可以在图像域实现^[99], 也可以在k空间域实现, 抑或是在双域同时实现^[100]。展开结构的训练相较于一般的端对端的模型需要更大的计算量, 这是因为对应每一步迭代, 展开结构需要多个神经网络模块, 同时在训练中需要不断地进行物理运算(例如傅里叶变换)。

5.2.2 基于预训练及无需训练的MRI重建算法

早期的压缩感知方法依赖传统先验(例如全变分范数), 基于预训练的重建算法通过预先训练一个深度降噪器, 实现了即插即用(plug-and-play, PnP)的深度重建^[101]。与传统的压缩感知算法类似, 收敛需要多次迭代, 从而导致了较高的计算复杂度。

无需训练的MRI重建算法是指除了超参数调整之外, 不依赖训练数据的深度学习模型。这些方法通常不是基于大型数据集的传统训练, 而是基于梯度下降等算法将随机初始化的神经网络拟合到特定的测量值。例如, 深度影像先验(deep image prior, DIP)算法利用卷积神经网络来拟合实际测量的k空间信号, 并在去噪和压缩感知(例如加速MRI)方面表现良好^[102,103]。无需训练的MRI重建算法的优势在于不需要训练数据, 然而这种优势却是以牺牲性能为代价, 通常情况下其难以达到预训练网络的重建效果。

5.2.3 基于生成式神经网络的MRI重建算法

在过去几年中, GAN在MRI重建中也引起了广泛关注。例如, 深度去混叠伪影生成对抗网络提出了具有细化学习阶段的模型, 并使用了由对抗和感知组件组成的损失函数^[104]。Mardani等人^[105]提出了一种基于GAN的框架用于学习高质量MR图像背后的低维流形。

扩散模型通过学习逆转扩散过程, 逐渐将随机噪声转化为高质量的结构化图像, 在MRI重建中展现了非凡的潜力^[106]。例如, Jalal等人^[107]证明通过训练一个基于Langevin动力学的生成模型, 不对数据集做出任何假设, 即在分布内和分布外数据均实现了优秀的重建结果。Luo等人^[108]设计了一种使用数据驱动的马尔可夫链进行MRI重建的方法, 该方法在变换的采样模式下实现了高效的图像重建。

5.2.4 基于自监督学习的MRI重建算法

神经网络通常以有监督的方式进行训练, 然而这需要成对的训练和目标(真实)图像。在实践中, 由于种

种限制(扫描时间、信号衰减、生理运动等),成对的训练集难以获得.因此,自监督的MRI重建方法吸引了越来越多的研究兴趣并开发了大量的算法.这些方法或通过对训练数据进行假设,或使用额外的噪声,或使用部分训练数据来训练没有目标图像的网络.

Noise2Noise是一个成熟的自监督框架,其构建了一个基于自身随机独立采样的自监督的损失函数,仅使用含有不同但同分布噪声的图像对进行训练^[109].在MRI重建中,SSDU (self-supervised learning via data undersampling)算法是一个基于Noise2Noise框架的MRI重建算法,该方法将k空间数据划分为两个独立部分,即一个用于数据一致性约束,另一个用于计算损失^[110].

k波段(k-band)框架则是应用于分辨率不足的数据中自我监督训练思路^[111].该框架基于频率域波段(band)的采集,其中每个波段在MRI信号读取(readout)维度中为高分辨率,在相位编码(phase encoding)维度中为低分辨率.通过在训练迭代中随机波段的方向,可以使网络暴露于所有k空间区域,从而促进神经网络学习k空间区域之间的连接性.

由于低频信号在训练中会过多地被采集,自监督的重建框架往往采用k空间加权的损失函数,其降低了k空间中心低频信号的权重并加强了边缘高频信号的权重,从而抑制了低频数据的学习,并促进了高频细节的学习.

5.3 基于AI的CT重建算法

CT和CBCT技术在医学影像领域,尤其是在放射治疗、口腔医学和介入治疗等领域得到广泛应用.对于稀疏采样重建引起的条形伪影和噪声等挑战^[112],基于AI的CT重建算法可分为重建前投影数据的插值补全算法、图像后处理算法以及投影域到图像域的深度重建网络.

5.3.1 重建前的投影数据插值补全算法

对原始投影数据的插值补全是提升最终重建影像质量的直接手段.目前该类研究主要着重于如何从投影数据高效提取具有强内部相关性的特征,常见的方法架构包括将对抗网络和自编码相融合的AACNN (adversarial autoencoder CNN)^[113]等.

5.3.2 基于深度学习的图像后处理算法

面对原始投影数据的高获取难度,完全基于图像域的图像后处理算法研究始终保持着高研究热度.该

类方法完全依赖于所选用深度学习模型的生成能力,直接将重建问题作为低质量影像到高质量影像的模态转换问题.其方法性能较大程度上受限于输入影像模态与目标影像模态的空间与形态学对应程度,往往需要依赖配准算法进行数据的预对齐处理.该类方法最具挑战性的应用是4D CBCT影像的后处理.4D CBCT影像的后处理模型往往涉及多相位高冗余的图像输入,需要有效引入先验知识,如单独提取相位间关联性^[114]或基于病人特点设置约束^[115],或结合平均图像与相邻相位相关性,以及病人呼吸信号等信息,构建综合了多方面信息的重建模型.深度学习方法还可与传统代数重建算法相结合,形成深度学习增强代数重建技术(deep learning enhanced algebraic reconstruction,DLEAR)^[116].

5.3.3 投影域到图像域的深度重建网络

在已有足够原始数据与对应重建后影像数据的情况下,也可以直接构建端对端的由投影域到图像域深度重建网络.该类研究主要解决投影角度有限时进行高质量影像重建的挑战,如iCT-Net^[117]取得了较高的图像重建效率和重建质量.

5.3.4 基于AI的四维影像重建算法

高速的四维影像重建技术是实时放疗手术引导与计划生成的前提.四维影像原始数据的高度欠采样所导致的低成像分辨率与严重的噪声与伪影,是传统图像重建算法难以解决的挑战.而深度学习凭借其强大且自动的特征提取和表达能力,使高速高质量的四维影像重建成为可能.目前基于深度学习的四维影像重建技术着重于对成像速度与成像质量做出提升,这些工作依照方法框架的不同又可分为融合压缩感知技术缩小计算面积与结合传统重建方法进行后处理等两方面工作.一方面,一些工作将深度学习与传统的压缩感知(compressed sensing, CS)技术相结合,通过设计压缩感知正则项缩小计算面积,从而有效加速了重建过程,同时起到了去冗余信息的作用,提高了重建质量.在这一框架下,深度学习通过学习患者解剖结构的先验信息,有效限制了解空间的维度,加快了算法的收敛速度.代表性工作如Wang等人^[118]结合时空词典学习和神经网络技术,设计了能够自适应调整正则化系数的方法,用于加速非笛卡尔4D MRI的重建,与最先进的压缩感知方法相比,进一步提高了图像质量和计算效率.另一方面,深度学习还可以作为后处理手段,与传统重建方法相结合,在初步重建完成后进一步提升图

像质量,减少伪影和噪声,提升空间分辨率。Lee等人^[119]结合Res-U-Net与小波处理技术,有效去除了传统反投影重建(filtered back projection, FBP)技术计算所得图像中的条纹伪影。Jiang等人^[120]提出的对称残差卷积神经网络(symmetric residual CNN)则增强了基于总变分(total variation, TV)正则化重建欠采样4D CBCT图像中边缘的清晰度。这些改进大大增强了肿瘤的可见性,有助于更精准的靶区定位与放射治疗的实施,推动了四维成像技术在临床的广泛应用。

6 总结、挑战与未来展望

本文系统性地梳理了近五年人工智能技术在放射影像领域的相关应用,围绕放射影像诊断、配准、分割、生成与重建五个方面重点阐释了其核心算法框架、临床应用场景、现存技术瓶颈及具有里程碑意义的研究成果。

人工智能技术的出现对放射影像处理的应用领域产生了持续且深远的影响。随着人工智能技术的高速发展,其层次化特征解析机制显著提升病灶检测的敏感性与特异性,其端到端优化范式将传统多阶段处理流程压缩至亚秒级响应,其跨模态关联挖掘能力有效实现了多源影像信息的互补性解析。然而,人工智能技术的内在局限性也在引起越来越广泛的关注。模型对

高质量标注的需求推高了模型的训练成本,域偏移问题导致的跨中心性能衰减制约了模型的临床普适性,而黑箱模型决策逻辑与临床诊断路径的认知偏差则严重阻碍了医技人员建立信任。

新型深度学习模型的变革、多模态多任务学习策略的不断成熟,以及各类大模型的涌现,已经为精准医疗和个性化诊断提供了更具前瞻性的理论与技术支持。值得关注的是,Transformer架构的迭代创新与视觉大模型的突破性进展,正推动着医学影像分析范式向多任务联合学习与跨模态知识迁移方向演进。特别是基于自监督学习的预训练大模型,通过挖掘海量未标注影像中的解剖结构先验知识,为降低模型对标注数据的依赖性提供了新思路。此外,联邦学习框架的成熟使得跨机构协作建模成为可能,显著增强了模型的临床泛化能力。这些技术进展标志着医学影像分析已迈入智能化决策与个性化诊疗的新纪元。

展望未来,如何立足于临床应用特点,合理选择高性能新型模型,有效应用多模态与多任务学习技术,并充分结合泛化性与可信性理论,以建立能够适应复杂临床场景且具有明确诊断依据的智能模型,将成为AI在放射影像应用中的关键研究方向。只有实现技术创新与临床实践的深度耦合,才能真正推动放射影像分析技术向精准医疗的终极目标迈进。

参考文献

- 1 Stewart C V, Chia-Ling Tsai C V, Roysam B. The dual-bootstrap iterative closest point algorithm with application to retinal image registration. *IEEE Trans Med Imag*, 2003, 22: 1379–1394
- 2 Maes F, Vandermeulen D, Suetens P. Medical image registration using mutual information. *Proc IEEE*, 2003, 91: 1699–1722
- 3 Viergever M A, Maintz J B A, Klein S, et al. A survey of medical image registration – under review. *Med Image Anal*, 2016, 33: 140–144
- 4 Wang S, Summers R M. Machine learning and radiology. *Med Image Anal*, 2012, 16: 933–951
- 5 Baopu Li, Meng M Q H. Tumor recognition in wireless capsule endoscopy images using textural features and SVM-based feature selection. *IEEE Trans Inform Technol Biomed*, 2012, 16: 323–329
- 6 Mahapatra D. Analyzing training information from random forests for improved image segmentation. *IEEE Trans Image Process*, 2014, 23: 1504–1512
- 7 Shin H C, Roth H R, Gao M, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE Trans Med Imag*, 2016, 35: 1285–1298
- 8 Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks. *Commun ACM*, 2017, 60: 84–90
- 9 Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. In: Medical Image Computing and Computer-Assisted Intervention. Berlin: Springer, 2015. 234–241
- 10 Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks. *Commun ACM*, 2020, 63: 139–144
- 11 Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks. In: Proceedings of IEEE International Conference Computer Vision. Venice: IEEE, 2017. 2223–2232
- 12 Frid-Adar M, Klang E, Amitai M, et al. Synthetic data augmentation using GAN for improved liver lesion classification. In: Proceedings of IEEE International Symposium Biomedical Imaging. Washington: IEEE, 2018. 289–293

- 13 Yang Y, Yang Z, Yu J, et al. Fast calculation of probabilistic power flow: a model-based deep learning approach. *IEEE Trans Smart Grid*, 2019, 11: 2235–2244
- 14 Kingma D P, Welling M. Auto-encoding variational Bayes. In: International Conference on Learning Representations. 2013, arXiv: [1312.6114](#)
- 15 Kazerouni A, Aghdam E K, Heidari M, et al. Diffusion models in medical imaging: a comprehensive survey. *Med Image Anal*, 2023, 88: 102846
- 16 Han K, Xiao A, Wu E H, et al. Transformer in transformer. *Adv Neural Inf Process Syst*, 2021, 34: 15908–15919
- 17 Zhu J, Yang G, Lio' P. How can we make GAN perform better in single medical image super-resolution? A lesion focused multi-scale approach. In: Proceedings of IEEE International Symposium Biomedical Imaging. Venice: IEEE, 2019. 1669–1673
- 18 Fu M H, Zhang N, Huang Z X, et al. OIF-Net: an optical flow registration-based PET/MR cross-modal interactive fusion network for low-count brain PET image denoising. *IEEE Trans Med Imaging*, 2023, 34: 1554–1567
- 19 Zhou Y, He X D, Huang L, et al. Collaborative learning of semi-supervised segmentation and classification for medical images. In: Proceedings of IEEE/CVF Conference Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 2074–2083
- 20 van der Velden B H M, Kuijf H J, Gilhuijs K G A, et al. Explainable artificial intelligence (XAI) in deep learning-based medical image analysis. *Med Image Anal*, 2022, 79: 102470
- 21 Yan R, Qu L, Wei Q, et al. Label-efficient self-supervised federated learning for tackling data heterogeneity in medical imaging. *IEEE Trans Med Imag*, 2022, 42: 1932–1943
- 22 Hospedales T, Antoniou A, Micelli P, et al. Meta-learning in neural networks: a survey. *IEEE Trans Pattern Anal Mach Intell*, 2021, 44: 5149–5169
- 23 Zhang Y, Wei Y, Wu Q, et al. Collaborative unsupervised domain adaptation for medical image diagnosis. *IEEE Trans Image Process*, 2020, 29: 7834–7844
- 24 Stiennon N, Ouyang L, Wu J, et al. Learning to summarize with human feedback. *Adv Neural Inf Process Syst*, 2020, 33: 3008–3021
- 25 Kirillov A, Mintun E, Ravi N, et al. Segment anything. In: Proceedings of IEEE/CVF International Conference on Computer Vision and Pattern Recognition. Paris: IEEE, 2023. 4015–4026
- 26 Li X, Zhao L, Zhang L, et al. Artificial general intelligence for medical imaging analysis. *IEEE Rev Biomed Eng*, 2024, 18: 113–129
- 27 Saporta A, Gui X, Agrawal A, et al. Benchmarking saliency methods for chest X-ray interpretation. *Nat Mach Intell*, 2022, 4: 867–878
- 28 Chen W X, Liu Y, Wang C, et al. Cross-modal causal intervention for medical report generation. 2023, arXiv: [2303.09117](#)
- 29 Wu Y, Zeng D, Wang Z, et al. Distributed contrastive learning for medical image segmentation. *Med Image Anal*, 2022, 81: 102564
- 30 Chen C, Song M, Glanzel W. Visualizing a field of research: a methodology of systematic scientometric reviews. *PLoS One*, 2019, 14: e0223994
- 31 Bi W L, Hosny A, Schabath M B, et al. Artificial intelligence in cancer imaging: clinical challenges and applications. *CA Cancer J Clin*, 2019, 69: 127–157
- 32 Topol E J. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*, 2019, 25: 44–56
- 33 Litjens G, Kooi T, Bejnordi B E, et al. A survey on deep learning in medical image analysis. *Med Image Anal*, 2017, 42: 60–88
- 34 Xu J, Ren H, Cai S, et al. An improved faster R-CNN algorithm for assisted detection of lung nodules. *Comput Biol Med*, 2023, 153: 106470
- 35 Ickler M K, Baumgartner M, Roy S, et al. Taming detection transformers for medical object detection. In: BVM Workshop. Berlin: Springer, 2023. 183–188
- 36 Fu L, Chen Y, Ji W, et al. SSTrans-Net: smart swin transformer network for medical image segmentation. *biomed signal processing control*, 2024, 91: 106071
- 37 Liu C, Wu Z, Wang B, et al. Pulmonary nodule detection in x-ray images by feature augmentation and context aggregation. *Phys Med Biol*, 2024, 69: 045002
- 38 Cao K, Xia Y, Yao J, et al. Large-scale pancreatic cancer detection via non-contrast CT and deep learning. *Nat Med*, 2023, 29: 3033–3043
- 39 Lin Y, Yilmaz E C, Belue M J, et al. Evaluation of a cascaded deep learning-based algorithm for prostate lesion detection at biparametric MRI. *Radiology*, 2024, 311: e230750
- 40 Shao M, Byrd D W, Mitra J, et al. A deep learning anthropomorphic model observer for a detection task in PET. *Med Phys*, 2024, 51: 7093–7107
- 41 Tan M X, Le Q. EfficientNet: rethinking model scaling for convolutional neural networks. In: International Conference on Machine Learning. Long Beach: PMLR, 2019. 6105–6114
- 42 Hong N, Cho S W, Shin S, et al. Deep-learning-based detection of vertebral fracture and osteoporosis using lateral spine X-ray radiography. *J Bone Miner Res*, 2020, 38: 887–895
- 43 Fu F, Shan Y, Yang G, et al. Deep learning for head and neck CT angiography: stenosis and plaque classification. *Radiology*, 2023, 307: e220996
- 44 Hamm C A, Baumgärtner G L, Biessmann F, et al. Interactive explainable deep learning model informs prostate cancer diagnosis at MRI. *Radiology*, 2023, 307: e222276
- 45 Azizi S, Mustafa B, Ryan F, et al. Big self-supervised models advance medical image classification. In: Proceedings of IEEE/CVF International Conference on Computer Vision and Pattern Recognition. Montreal: IEEE, 2021. 3478–3488

- 46 Xie Q Q, Chen Q Y, Chen A K, et al. Me llama: Foundation large language models for medical applications. 2024, arXiv: [2402.12749](#)
- 47 Thirunavukarasu A J, Ting D S J, Elangovan K, et al. Large language models in medicine. *Nat Med*, 2023, 29: 1930–1940
- 48 Lee J, Yoon W, Kim S, et al. BioBERT: a pre-trained biomedical language representation model for biomedical text mining. *Bioinformatics*, 2020, 36: 1234–1240
- 49 You D, Liu F L, Ge S, et al. AlignTransformer: Hierarchical alignment of visual regions and disease tags for medical report generation. In: Medical Image Computing and Computer Assisted Intervention 2021. Berlin: Springer, 2021. 72–82
- 50 Wu X, Li J, Wang J, et al. Multimodal contrastive learning for radiology report generation. *J Ambient Intell Hum Comput*, 2023, 14: 11185–11194
- 51 Liu F L, Wu X, Ge S, et al. Exploring and distilling posterior and prior knowledge for radiology report generation. In: Proceedings of IEEE/CVF Conference Computer Vision and Pattern Recognition. Nashville: IEEE, 2021. 13753–13762
- 52 Hamamci I E, Er S, Menze B. CT2Rep: automated radiology report generation for 3D medical imaging. In: Medical Image Computing and Computer Assisted Intervention 2024. Berlin: Springer, 2024. 476–486
- 53 Chen Z X, Luo L Y, Bie Y Q, et al. Dia-LLaMA: towards large language model-driven CT report generation. 2024, arXiv: [2403.16386](#)
- 54 He S, Li Q, Li X, et al. Automatic aid diagnosis report generation for lumbar disc MR image based on lightweight artificial neural networks. *BioMed Signal Processing Control*, 2023, 86: 105275
- 55 Avants B B, Tustison N J, Song G, et al. A reproducible evaluation of ANTs similarity metric performance in brain image registration. *NeuroImage*, 2011, 54: 2033–2044
- 56 Fan J, Cao X, Yap P T, et al. BIRNet: brain image registration using dual-supervised fully convolutional networks. *Med Image Anal*, 2019, 54: 193–206
- 57 Cao X H, Yang J H, Zhang J, et al. Deformable image registration based on similarity-steered CNN regression. In: Medical Image Computing and Computer Assisted Intervention — MICCAI 2017. Berlin: Springer, 2017. 300–308
- 58 Onieva J, Martí-Fuster B, Puente M P, et al. Diffeomorphic lung registration using deep CNNs and reinforced learning. In: Image Analysis for Moving Organ, Breast, and Thoracic Images. Berlin: Springer, 2018. 284–294
- 59 Krebs J, Mansi T, Delingette H, et al. Robust non-rigid registration through agent-based action learning. In: Medical Image Computing and Computer Assisted Intervention 2017. Berlin: Springer, 2017. 344–352
- 60 Sokooti H, De Vos B, Berendsen F, et al. Nonrigid image registration using multi-scale 3D convolutional neural networks. In: Medical Image Computing and Computer Assisted Intervention 2017. Berlin: Springer, 2017. 232–239
- 61 de Vos B D, Berendsen F F, Viergever M A, et al. A deep learning framework for unsupervised affine and deformable image registration. *Med Image Anal*, 2019, 52: 128–143
- 62 Fu Y, Lei Y, Wang T, et al. LungRegNet: an unsupervised deformable image registration method for 4D-CT lung. *Med Phys*, 2020, 47: 1763–1774
- 63 Krebs J, Mansi T, Mailhé B, et al. Unsupervised probabilistic deformation modeling for robust diffeomorphic registration. In: Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop 2018. Berlin: Springer, 2018. 101–109
- 64 Kuang D. Cycle-consistent training for reducing negative Jacobian determinant in deep registration networks. In: Simulation and Synthesis in Medical Imaging2019. Berlin: Springer, 2019. 120–129
- 65 Balakrishnan G, Zhao A, Sabuncu M R, et al. VoxelMorph: a learning framework for deformable medical image registration. *IEEE Trans Med Imag*, 2019, 38: 1788–1800
- 66 Jiang P G, Shackleford J A. CNN driven sparse multi-level B-spline image registration. In: Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2018. 9281–9289
- 67 Jiang Z, Yin F F, Ge Y, et al. A multi-scale framework with unsupervised joint training of convolutional neural networks for pulmonary deformable image registration. *Phys Med Biol*, 2020, 65: 015011
- 68 Hu Y, Gibson E, Ghavami N, et al. Adversarial deformation regularization for training image registration neural networks. In: Medical Image Computing and Computer Assisted Intervention2018. Berlin: Springer, 2018. 774–782
- 69 Huang X, Zhang Y, Chen L, et al. U-Net-based deformation vector field estimation for motion-compensated 4D-CBCT reconstruction. *Med Phys*, 2020, 47: 3000–3012
- 70 Milletari F, Navab N, Ahmadi S A. V-Net: fully convolutional neural networks for volumetric medical image segmentation. In: Proceedings of International Conference on 3D Vision. Stanford: IEEE, 2016. 565–571
- 71 Hatamizadeh A, Nath V, Tang Y C, et al. Swin UNETR: swin transformers for semantic segmentation of brain tumors in MRI images. In: Medical Image Computing and Computer Assisted Intervention BrainLesion Workshop. Berlin: Springer, 2021. 272–284
- 72 Teng L, Zhao Z H, Huang J W, et al. Knowledge-guided prompt learning for lifespan brain MR image segmentation. In: Medical Image Computing and Computer Assisted Intervention2024. Berlin: Springer, 2024. 238–248

- 73 Zhuang X, Rhode K S, Razavi R S, et al. A registration-based propagation framework for automatic whole heart segmentation of cardiac MRI. *IEEE Trans Med Imag*, 2010, 29: 1612–1625
- 74 You C, Yang J, Chapiro J, et al. Unsupervised Wasserstein distance guided domain adaptation for 3D multi-domain liver segmentation. In: Medical Image Computing and Computer Assisted Intervention Interpretability of Machine Intelligence in Medical Image Computing Worksho2020. Berlin: Springer, 2020. 155–163
- 75 Seo H, Huang C, Bassenne M, et al. Modified U-Net (mU-Net) with incorporation of object-dependent high level features for improved liver and liver-tumor segmentation in CT images. *IEEE Trans Med Imag*, 2019, 39: 1316–1325
- 76 Li L, Wei M, Liu B, et al. Deep learning for hemorrhagic lesion detection and segmentation on brain CT images. *IEEE J Biomed Health Inform*, 2020, 25: 1646–1659
- 77 Gerard S E, Herrmann J, Xin Y, et al. CT image segmentation for inflamed and fibrotic lungs using a multi-resolution convolutional neural network. *Sci Rep*, 2021, 11: 1455
- 78 Chen Z, Lalande A, Salomon M, et al. Automatic deep learning-based myocardial infarction segmentation from delayed enhancement MRI. *Computized Med Imag Graphics*, 2022, 95: 102014
- 79 Li X, Deng Z, Deng Q, et al. A novel deep learning framework for internal gross target volume definition from 4D computed tomography of lung cancer patients. *IEEE Access*, 2018, 6: 37775–37783
- 80 Goceri E. Medical image data augmentation: techniques, comparisons and interpretations. *Artif Intell Rev*, 2023, 56: 12561–12605
- 81 Dayarathna S, Islam K T, Uribe S, et al. Deep learning based synthesis of MRI, CT and PET: review and analysis. *Med Image Anal*, 2023, 92: 102046
- 82 Sikka A, Peri S V, Bathula D R. MRI to FDG-PET: cross-modal synthesis using 3D U-Net for multi-modal Alzheimer's classification. In: Simulation and Synthesis in Medical Imaging 2018. Berlin: Springer, 2018. 80–89
- 83 Sikka A, Virk J S, Bathula D R. MRI to PET cross-modality translation using globally and locally aware GAN (GLA-GAN) for multi-modal diagnosis of Alzheimer's disease. 2021, arXiv: [2108.02160](#)
- 84 Shin H C, Ihsani A, Mandava S, et al. GANBERT: generative adversarial networks with bidirectional encoder representations from transformers for MRI to PET synthesis. 2020, arXiv: [2008.04393](#)
- 85 Sanaat A, Arabi H, Mainta I, et al. Projection space implementation of deep learning-guided low-dose brain PET imaging improves performance over implementation in image space. *J Nucl Med*, 2020, 61: 1388–1396
- 86 Wang Y, Zhou L, Yu B, et al. 3D auto-context-based locality adaptive multi-modality GANs for PET synthesis. *IEEE Trans Med Imag*, 2018, 38: 1328–1339
- 87 Zhang L, Xiao Z, Zhou C, et al. Spatial adaptive and transformer fusion network (STFNet) for low-count PET blind denoising with MRI. *Med Phys*, 2022, 49: 343–356
- 88 Zhao P, Pan H, Xia S Y. MRI-Trans-GAN: 3D MRI cross-modality translation. In: Proceedings of Chinese Control Conference. Shanghai: IEEE, 2021. 7229–7234
- 89 Yan S, Wang C, Chen W, et al. Swin transformer-based GAN for multi-modal medical image translation. *Front Oncol*, 2022, 12: 942511
- 90 Fu J, Yang Y, Singhrao K, et al. Deep learning approaches using 2D and 3D convolutional neural networks for generating male pelvic synthetic computed tomography from magnetic resonance imaging. *Med Phys*, 2019, 46: 3788–3798
- 91 Ang S P, Phung S L, Field M, et al. An improved deep learning framework for MR-to-CT image synthesis with a new hybrid objective function. In: Proceedings of IEEE International Symposium on Biomedical Imaging. Kolkata: IEEE, 2022. 1–5
- 92 Li X Y, Shang K, Wang G A, et al. DDMM-Synth: a denoising diffusion model for cross-modal medical image synthesis with sparse-view measurement embedding. 2023, arXiv: [2303.15770](#)
- 93 Dahiya N, Alam SR, Zhang P, et al. Multitask 3D CBCT-to-CT translation and organs-at-risk segmentation using physics-based data augmentation. *Med Phys*, 2021, 48: 5130–5141
- 94 Kurz C, Maspero M, Savenije M H F, et al. CBCT correction using a cycle-consistent generative adversarial network and unpaired training to enable photon and proton dose calculation. *Phys Med Biol*, 2019, 64: 225004
- 95 Zhu J, Sun H, Chen W, et al. Feature-targeted deep learning framework for pulmonary tumorous Cone-beam CT (CBCT) enhancement with multi-task customized perceptual loss and feature-guided CycleGAN. *Computized Med Imag Graphics*, 2025, 121: 102487
- 96 Zhu B, Liu J Z, Cauley S F, et al. Image reconstruction by domain-transform manifold learning. *Nature*, 2018, 555: 487–492
- 97 Guo P, Mei Y, Zhou J, et al. ReconFormer: accelerated MRI reconstruction using recurrent transformer. *IEEE Trans Med Imag*, 2023, 43: 582–593
- 98 Lin D J, Johnson P M, Knoll F, et al. Artificial intelligence for MR image reconstruction: an overview for clinicians. *Magn Reson Imag*, 2021, 53: 1015–1028
- 99 Schlemper J, Caballero J, Hajnal J V, et al. A deep cascade of convolutional neural networks for dynamic MR image reconstruction. *IEEE Trans*

- Med Imag*, 2017, 37: 491–503
- 100 Eo T, Jun Y, Kim T, et al. KIKI-net: cross-domain convolutional neural networks for reconstructing undersampled magnetic resonance images. *Magn Reson Med*, 2018, 80: 2188–2201
- 101 Kamilov U S, Bouman C A, Buzzard G T, et al. Plug-and-play methods for integrating physical and learned models in computational imaging: theory, algorithms, and applications. *IEEE Signal Process Mag*, 2023, 40: 85–97
- 102 Ulyanov D, Vedaldi A, Lempitsky V. Deep image prior. In: Proceedings of International Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 9446–9454
- 103 Heckel R, Hand P. Deep decoder: Concise image representations from untrained non-convolutional networks. In: International Conference on Learning Representations. United States: OpenReview, 2019. 15–28
- 104 Yang G, Yu S, Dong H, et al. DAGAN: deep de-aliasing generative adversarial networks for fast compressed sensing MRI reconstruction. *IEEE Trans Med Imag*, 2017, 37: 1310–1321
- 105 Mardani M, Gong E, Cheng J Y, et al. Deep generative adversarial neural networks for compressive sensing MRI. *IEEE Trans Med Imag*, 2018, 38: 167–179
- 106 Güngör A, Dar S U H, Öztürk Ş, et al. Adaptive diffusion priors for accelerated MRI reconstruction. *Med Image Anal*, 2023, 88: 102872
- 107 Jalal A, Arvinte M, Daras G, et al. Robust compressed sensing MRI with deep generative priors. *Adv Neural Inf Process Syst*, 2021, 34: 14938–14954
- 108 Luo G, Blumenthal M, Heide M, et al. Bayesian MRI reconstruction with joint uncertainty estimation using diffusion models. *Magn Reson Med*, 2023, 90: 295–311
- 109 Lehtinen J. Noise2Noise: Learning image restoration without clean data. 2018, arXiv: 1803.04189
- 110 Ekanayake M, Chen Z, Harandi M, et al. CL-MRI: self-supervised contrastive learning to improve the accuracy of undersampled MRI reconstruction. *BioMed Signal Processing Control*, 2025, 100: 107185
- 111 Singh D, Monga A, de Moura H L, et al. Emerging trends in fast MRI using deep-learning reconstruction on undersampled k-space data: a systematic review. *Bioengineering*, 2023, 10: 1012
- 112 Zhang Y, Jiang Z, Zhang Y, et al. A review on 4D cone-beam CT (4D-CBCT) in radiation therapy: technical advances and clinical applications. *Med Phys*, 2024, 51: 5164–5180
- 113 Dai X, Bai J, Liu T, et al. Limited-view cone-beam CT reconstruction based on an adversarial autoencoder network with joint loss. *IEEE Access*, 2018, 7: 7104–7116
- 114 Sun L, Jiang Z, Chang Y, et al. Building a patient-specific model using transfer learning for four-dimensional cone beam computed tomography augmentation. *Quant Imag Med Surg*, 2021, 11: 540–555
- 115 Zhang Z, Huang M, Jiang Z, et al. Patient-specific deep learning model to enhance 4D-CBCT image for radiomics analysis. *Phys Med Biol*, 2022, 67: 085003
- 116 Zhang Z, Liu J, Yang D, et al. Deep learning-based motion compensation for four-dimensional cone-beam computed tomography (4D-CBCT) reconstruction. *Med Phys*, 2023, 50: 808–820
- 117 Li Y, Li K, Zhang C, et al. Learning to reconstruct computed tomography images directly from sinogram data under a variety of data acquisition conditions. *IEEE Trans Med Imag*, 2019, 38: 2469–2481
- 118 Wang Z, She H, Zhang Y, et al. Parallel non-Cartesian spatial-temporal dictionary learning neural networks (stDLNN) for accelerating 4D-MRI. *Med Image Anal*, 2023, 84: 102701
- 119 Lee D, Kim K, Kim W, et al. Four-dimensional CBCT reconstruction based on a residual convolutional neural network for improving image quality. *J Korean Phys Soc*, 2019, 75: 73–79
- 120 Jiang Z, Chen Y, Zhang Y, et al. Augmentation of CBCT reconstructed from under-sampled projections using deep learning. *IEEE Trans Med Imag*, 2019, 38: 2705–2715

Summary for “人工智能在放射影像中的应用”

The applications of artificial intelligence in radiographic imaging

Jiarui Zhu¹, Lin Teng², Liming Song¹, Chenyang Liu¹, Weixing Chen³, Mayang Zhao¹, Haonan Xiao⁴, Yinghui Wang¹, Shaohua Zhi⁵, Long Yang², Hongfei Sun⁶, Ge Ren¹, Wenjian Qin⁷, Jing Cai^{1*} & Dinggang Shen^{2*}

¹ Department of Health Technology and Informatics, The Hong Kong Polytechnic University, Hong Kong 999077, China

² School of Biomedical Engineering, ShanghaiTech University, Shanghai 201210, China

³ School of Computer Science, Sun Yat-sen University, Guangzhou 510006, China

⁴ Department of Radiation Oncology, Cancer Hospital of Shandong First Medical University, Shandong Cancer Hospital, Shandong Cancer Institute, Jinan 250117, China

⁵ School of Interdisciplinary Studies, Lingnan University, Hong Kong 999077, China

⁶ Xijing Hospital of Air Force Military Medical University, Xi'an 710032, China

⁷ Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China

* Corresponding authors, E-mail: jing.cai@polyu.edu.hk; dgshen@shanghaitech.edu.cn

Artificial intelligence (AI) techniques are thriving in the area of radiography, providing more accurate and more efficient solutions for processing and analyzing radiographic imaging, including X-ray, CT, MRI, ultrasound and nuclear imaging. As the rapid development of AI explosively provides more practical and transformative techniques, to empower more performant model designs and further hasten clinical deployments, it's crucial to clarify the developing trajectory of the applications of AI in radiological image processing and analysis. The development of AI in radiography can be summarized in 6 stages, traditional rule-based optimization methods based on manual designed feature extraction algorithms, statistical machine learning, big data empowered deep learning, transformative innovations in deep learning networks, multimodal learning and multitask learning, and generalizability and interpretability learning in the era of foundations models. Along the six stages, this paper investigated the developing trajectories of the applications of AI in radiological image diagnosis, registration, segmentation, synthesis and reconstruction. Based on co-citation frequency analysis, we selectively introduced recent representative work and previous foundational work from these five application aspects. The main contribution of this paper is that we located prevailing challenges and recent advances. The successive births of transformative deep learning paradigms keep expanding more possible clinical scenarios, and the maturation of multimodal and multitask learning strategies and the rise of foundation models have provided a fundamental basis for precision medicine and personalized diagnosis, marking the start of a new era of comprehensive techniques integration and intelligent system design for radiological imaging processing and analyzing. In the meantime, although deep learning methods have significantly improved the accuracy, speed and comprehensiveness of radiological imaging processing and analysis, the reliance on high-quality annotated data, the generalization ability and the interpretability of AI methods remain as main challenges. In the future, it's of great clinical significance to develop highly integrated intelligent radiological imaging systems with clear diagnosis evidence and general adaptation to complex clinical scenarios.

artificial intelligence, radiography, medical imaging registration, medical imaging segmentation and diagnosis, medical imaging synthesis and reconstruction

doi: [10.1360/TB-2024-1352](https://doi.org/10.1360/TB-2024-1352)