

人工智能靶区勾画技术在乳腺癌术后放射治疗中的研究进展

王妍灵 梁永^(通讯作者)

右江民族医学院附属桂平医院肿瘤科 广西 桂平 537200

【摘要】：乳腺癌术后放疗是提高局部控制率的核心手段。靶区勾画作为其关键环节，效率与质量受传统手动勾画局限制约。基于深度学习的人工智能（AI）技术为突破该瓶颈提供了颠覆性解决方案。本文系统梳理该领域智能勾画技术的应用现状及发展趋势：在高对比度危及器官（OAR）已达临床应用水平，显著提升效率与一致性；在术后解剖复杂、边界模糊的临床靶区（CTV）及淋巴引流区（RLN）虽获进展，仍面临模型泛化能力不足与微小病灶识别困难的挑战。当前，数据孤岛、模型可解释性差及与临床 workflow 整合难题制约其广泛应用。未来，联邦学习、多模态融合及可解释 AI 将是推动技术从“可用”迈向“可靠”的核心驱动力。

【关键词】：乳腺恶性肿瘤；放射疗法；靶区勾画

DOI:10.12417/2705-098X.26.07.071

引言

乳腺癌是全球女性发病率最高的恶性肿瘤，在中国同样呈现高发态势，构成严峻的公共卫生挑战^[1,2]。术后放疗是降低局部复发风险、延长总生存期的重要手段。靶区勾画作为其关键环节，准确性和一致性高度影响放疗质量^[3]。传统手动勾画存在显著临床痛点。其一，效率瓶颈：传统手动勾画过程繁琐，单例患者靶区及危及器官勾画通常耗时数小时，严重制约临床工作通量。其二，一致性难题：靶区勾画具有极强的主观性，即便遵循同一指南，不同年资医师、不同机构间勾画结果仍存在显著差异^[3,4]，直接影响治疗计划的稳定性和可重复性。其三，质量隐患：基层医院勾画质量参差不齐，可能导致靶区覆盖不足或危及器官（OAR）过量照射，严重影响疗效与安全性^[5]。

为解决上述难题，AI 技术在放疗靶区勾画领域应运而生并快速发展^[6]：早期基于卷积神经网络（CNN）的模型实现了 OAR 的初步自动分割，随着 U-Net 及其衍生模型、Transformer 融合架构等不断迭代，大幅提升勾画精度与效率，目前高对比度 OAR 的勾画已达临床应用水平，CTV 与 RLN 勾画也取得阶段性进展^[6,7]。但该领域技术相关研究成果分散，技术成熟度、临床泛化能力及转化路径尚需系统性评估。本文旨在综述 AI 在乳腺癌术后放疗靶区勾画领域的技术演进与应用现状，重点评述其在临床转化过程中面临的关键瓶颈与潜在突破路径，为后续研究方向聚焦与临床实践规范提供决策依据。

1 人工智能靶区勾画的技术基础

对放疗模拟定位 CT 图像信息的提取和处理质量是影响人工智能勾画靶区精度的最重要因素，目前研究较多的几种网络架构各有优缺点。

1.1 卷积神经网络

卷积神经网络（Convolutional neural network, CNN）是当前医学图像分割的经典架构，分为二维和三维两类。刘方杰^[8]采用二维卷积神经网络构建的自动勾画模型对临床靶区及危

及器官进行勾画，其戴斯相似系数（Dice Similarity Coefficient, DSC）普遍达到 0.90 以上。许卓华等^[9]应用三维卷积神经网络衍生模型，在乳腺癌保乳术后或根治术后放疗靶区勾画中显著提升了胸壁与淋巴结引流区等复杂区域的勾画准确性。卷积神经网络的优势在于特征学习能力强、易实现性及性能良好，平移不变性等，但在处理长距离空间或形态变异较大的靶区时仍面临挑战^[9,10]。

1.2 Transformer

Transformer 架构能有效克服 CNN 在长距离空间关系捕捉上的局限性，但这类架构较少单独应用，通常与其它架构融合使用。一、Transformer 作为编码器与卷积神经网络解码器（如 U 型网络，U-Net）相结合，TransUNet 等模型^[7]展示了通过 Transformer 提取全局表征，再由卷积神经网络恢复局部细节的能力，为提升分割精度提供了新范式。二、构建轻量化混合模型，如 EfficientUNetViT 模型通过采用预训练的 Vision Transformer 模块和深度可分离卷积，实现了高精度与低计算复杂度的平衡，为临床实时应用提供了可能^[11]。

1.3 生成对抗网络

生成对抗网络（Generative Adversarial Network, GAN）为解决乳腺癌放疗数据稀缺问题提供了有效途径。通过生成器与判别器的对抗训练，能生成具有解剖学合理性的合成影像。将 GAN 生成的合成感兴趣区域纳入训练集后，可显著提升下游任务模型的性能并降低过拟合风险^[12,13]。基于 Cycle GAN 等模型的算法能够解决乳腺癌放疗中多模态影像配准难题，生成高保真度的合成 CT^[14]。该技术还能将 MRI 的软组织对比度优势映射至 CT 影像，以辅助精确勾画瘤床及胸壁等结构^[15]。GAN 合成数据尚不能完全取代真实影像，但有助于 CT 和 MRI 图像桥联^[16]。

1.4 U 型网络

Net^[17]及其衍生模型是医学图像分割领域的基石。其经典

的编码器-解码器结构,通过逐级下采样提取层次化特征,再通过上采样恢复图像分辨率;跳跃连接作为其核心创新,有效地保留了细节信息,极大提升分割边界的精确度。这一基础框架催生了大量优化模型,通过引入更复杂的跳跃连接路径(如 U-Net++^[18])或集成注意力机制(如 Attention U-Net^[19])进一步提升特征表达能力。3D U-Net 因其处理三维容积数据及其变体的能力强大,在乳腺癌术后放疗靶区勾画中表现优异^[6],已成为研究的主流。TransUNet^[7]作为 U-Net 的解码器与 Transformer 的编码器相结合的混合架构,融合了卷积神经网络强大的局部特征捕捉能力与 Transformer 的全局上下文建模优势,代表了该领域的前沿发展方向。

2 人工智能靶区勾画在乳腺癌术后放疗中的应用

2.1 危及器官的勾画

危及器官(Organs at risk, OAR)的自动分割是深度学习在放疗领域应用最早且最为成熟的方向之一。基于卷积神经网络的模型,凭借 CT 影像中清晰的对比度与稳定的解剖结构,在心脏、双肺等器官的勾画中表现优秀^[17]。RTD 模型^[8]能够实现心脏、双肺及脊髓的高精度勾画(DSC>0.90)。但周边对比度低的组织勾画精度显著下降^[20]。为评估模型的临床泛化能力,一项多中心的研究^[21]结果显示现有技术可用于周边组织对比度清晰 OAR 勾画,并显著提高效率,但在处理剂量敏感的复杂结构时仍需人工复核与修正。

2.2 临床靶区的勾画

保乳术后与全乳切除术后胸壁解剖差异较大,智能勾画乳腺癌临床靶区(clinical target volume, CTV)时应区别对待。深度学习模型对相对完整的乳腺腺体勾画性能稳定,DSC 普遍达 0.88-0.94。许卓华等^[6]基于 3D ResSE-Unet 的研究证实保乳术后全乳临床靶区(CTVb)的 DSC 达 0.91±0.03,其核心突破是借助残差连接与 squeeze-excitation 注意力机制,强化了术后纤维化区域的识别,且当训练集含≥30%复杂术后病例(如合并严重瘢痕、血清肿)时,模型泛化性能提升 15%-20%,凸显了高质量标注数据的重要性。

2.3 区域淋巴引流区的勾画

区域淋巴引流区(Regional Lymph Node,RLN)的智能勾画因解剖边界模糊、个体差异大及与周围组织对比度低而成为技术难点。深度学习(Deep Learning,DL)技术,特别是基于 CNN 的语义分割模型,为 RLN 的自动、精准、标准化勾画提供了有效解决方案。当前研究主要采用全卷积网络(FCN)、U-Net 及其变体(如 3D U-Net,nU-Net)作为核心架构。3D ResSE-Unet 作为 U-Net 的改进架构,通过三维卷积与编码-解码结构增强空间特征提取,对锁骨上下区淋巴结勾画的 DSC 均值达 0.8^[6]。此外,如 HMT-Net 则通过联合功能指标(如 Ki-67 状态)及预测解剖结构的多任务学习框架来进一步优化分割精

度^[22]。

3 人工智能靶区勾画的应用价值

3.1 提高靶区勾画效率

乳腺癌术后放疗靶区人工勾画通常耗时数小时,而智能勾画可达分钟级完成。龚筱钦等^[23]研究显示:乳腺癌靶区手动勾画时间为平均 39 分钟而智能勾画为平均 10 分钟,效率提升超过 75%。Doolan 等^[24]研究结果显示,多部位危及器官同步勾画中,智能辅助勾画的校正时间减少 64%以上,且在乳腺、肺等区域节省效果较为显著。Byun 等^[25]的多中心研究提示,基于深度学习的自动勾画系统在保乳术后靶区勾画中表现优越,同人工勾画对比,节省时间达 84%,显著提升了勾画效率。

从临床 workflow 角度看,效率提升加快整个放射治疗流程,意味着将放疗医师从复杂、机械的手动勾画中解放出来,将宝贵的专业精力重新分配到更多临床任务上。AI 带来的效率革命,核心价值在于优化了稀缺的专家资源配置,为放疗流程的“质控”与“创新”环节预留了关键的时间窗口。

3.2 改善靶区勾画一致性

多中心研究显示,不同单位、不同年资医师间靶区勾画存在较大差异。智能勾画系统通过标准化特征提取后减少人因相关的变异性,即同质化勾画可以避免不同单位、不同年资医师之间因经验差异或者主观理解不同引起的人为性差异。对于保乳后辅助放疗患者的 OAR,人工勾画、智能勾画和智能勾画校正后的平均 DSC 分别为 0.88、0.90 和 0.90,其智能勾画系统提高了乳腺癌放疗的质量并有效降低了观察者间的变异性^[25]。Liu 等^[26]研究结果显示乳腺癌改良根治术后临床靶区自动勾画的平均 DSC 同样达 0.90,亦体现出良好的勾画一致性与准确性。基于大规模高质量数据集训练的深度学习模型输出结果具有高度可重复性,为多中心临床研究奠定了标准化基础^[27]。

一致性的提升具有双重临床意义。一、对于大型教学医院或区域医疗中心,意味着可将顶尖专家的勾画“经验”模式化为可复制、可传播的“金标准”,为开展高质量的多中心临床试验提供同质化基础,帮助标准化和改进现有临床实践。二、对于基层医院或年轻医师,一个可靠的 AI 模型扮演了“虚拟专家”与“质控工具”的角色。AI 提供的高质量勾画基准可有效弥补经验曲线,是推动放疗服务同质化、提升区域整体放疗水平的重要技术抓手。与此同时,仍需警惕“一致性”可能带来的固化风险,即模型可能系统性地复现并放大训练数据中的某些固有偏倚,这一点在后续模型的临床验证与监督中需予以高度关注。

3.3 提高特殊结构勾画准确性

针对传统勾画的薄弱环节,深度学习凸显出独特优势。在微小淋巴结(<1cm)等难识别结构上,一项研究引入难度感知双网络与空间注意力约束图模型,并在腋窝淋巴结(ALN)分

割方面表现出色^[28]。其核心技术为微小淋巴结自动勾画提供了关键的实现路径。在瘤床勾画上，许卓华等^[6]提出的3D ResSE-Unet模型借助squeeze-excitation注意力机制增强术后纤维化区域识别，并且在瘤床靶区勾画上的平均检出灵敏度达到了90.1%。在精准放疗靶区勾画中，融合PET-CT的多模态网络实现了“解剖+代谢”的双维优化，显著提升了分割精度^[29]。该技术思路为识别手术后的瘤床残余病灶等难题提供了极具潜力的解决方案。

实际上人类难以在低对比度CT影像上稳定识别模糊的术后纤维化边界，并在脑中完美融合多模态影像的复杂空间关系，而通过大数据训练的深度学习模型在一定程度上突破了人类视觉感知与认知处理的固有局限，能发现医师可能忽略或者不易察觉的影像细节信息和特征状态。其作为辅助工具，与医师形成人机协同，共同完成特殊结构边界的精准勾画任务，对实现真正意义上的个性化精准放疗至关重要。

4 人工智能靶区勾画存在问题

4.1 数据层面

深度学习模型放疗靶区勾画性能受限于训练数据的质量、代表性与可及性^[30]。首先，遵循指南共识，不同专家间仍存在显著差异^[3,4]。其次，数据代表性不足导致模型泛化能力受限，导致模型表现不佳，构成潜在的临床风险^[30,31]。再者，数据可及性受到隐私法规的严格制约。如《健康保险流通与责任法案》(HIPAA)和《通用数据保护条例》(GDPR)等法规，对传统的跨机构数据集中共享模式构成了根本性制约。为此，联邦学习(Federated Learning)等隐私保护计算技术应运而生，并试图在不共享原始数据的前提下进行多中心联合建模，但其应用尚处于早期探索阶段。

从根本上讲，数据层面的核心困境在于靶区勾画缺乏一个客观、绝对的“金标准”。现有的“专家共识”本身就是主观经验的集合体，这意味着模型性能的上限从一开始就受制于标注数据的“质量天花板”。模型学习得再好，也只是在无限逼近专家的主观判断，而非客观的生物学真实。未来研究的方向不仅要扩大数据样本，更要从多模态信息组学中探索如何整合病理、基因等多维度信息，去定义一个更接近“真实”的靶区范围，从而打破数据困境的魔咒。

4.2 模型层面

深度学习模型在乳腺癌术后放疗靶区勾画仍面临三重技术瓶颈。第一，靶区与周围组织间的低对比度、边界模糊的解剖关系导致勾画准确性受限^[32]。在放疗实践中，这意味着模型可能在胸壁与肺的交界、术后血清肿与瘤床的边缘等关键位置产生几何偏差，一个看似微小的豪斯多夫距离(HD)误差，就可能转化为导致局部复发的“边缘脱靶”。第二，模型决策过程缺乏临床可解释性^[30]，现有注意力机制虽能标识关注区

域，却难以关联术后瘢痕、血清肿等具体临床特征，导致临床信任度受限^[33]。可解释AI(XAI)的临床应用与验证本身就是一个快速发展的独立研究领域，其技术成熟度和标准化仍面临挑战^[34]。当模型给出一个与常规解剖认知相悖的勾画结果时，我们无法探究其“诊断逻辑”，这让医师在采纳其结果时面临巨大的不确定性和责任风险。第三，域偏移问题使得模型在不同设备应用时性能下降，成为跨机构推广的主要障碍^[31,35]。这个问题暴露了模型的“水土不服”。一个在A中心数据上训练出来的优秀模型，换到B中心测试就可能面临性能骤降。这种“脆弱性”严重阻碍了技术的规模化应用和多中心研究的标准化，使其难以成为一个真正普适、可靠的临床工具。因此，模型层面的挑战本质上是如何将一个擅长“应试”的算法，培养成一个能够在复杂多变的临床环境中稳健、可靠且值得信赖的“资深专家”。

4.3 临床转化层面

智能勾画在临床应用层面的困难揭示了AI技术在临床转化道路上必须跨越的“三大鸿沟”。第一是技术与流程的“集成鸿沟”。现有智能勾画模型多为独立软件，与Varian、Elekta等主流放疗计划系统(TPS)的私有数据格式与接口限制，导致勾画结果难以直接导入，使其沦为 workflow 中的“孤岛”。任何需要数据导入导出的额外步骤，不仅抵消了效率优势，更在分秒必争的临床环境中引入了潜在的数据错误风险。第二是证据与标准的“采纳鸿沟”。目前的验证研究大多聚焦DSC、HD95等几何学上的技术精度指标，这回答了“画得像不像”的相似度问题，但缺乏以患者为中心的“疗效-安全性”相关的长期临床数据支撑，这种“技术验证≠临床有效”的现状使其难以纳入放疗临床指南，限制规范化应用^[36]。第三，也是最核心的，是人机与责任的“信任鸿沟”。在缺乏统一审核标准和明确法律法规的背景下，AI的定位极其尴尬，医师态度亦呈现“过度依赖”与“过度质疑”的两极分化。过度依赖可能导致一部分低年资医师忽视模型的系统性错误，没有重点关注修正边缘模糊区域，易致靶区漏勾或危及器官(OAR)误勾，从而造成医疗安全隐患。过度质疑则让一部分高年资医师因不信任“黑箱模型”耗费时间进行大幅核对修改，反而丧失效率优势，最终导致技术价值难以充分发挥^[31]。当勾画结果出现偏差并导致不良事件时，责任归属的伦理与法律难题，悬在每一次AI辅助勾画的实践之上，是制约其广泛、负责任应用的最根本障碍。

5 发展方向

5.1 数据困境的解决方案

高质量大规模标注数据匮乏是制约乳腺癌放疗智能勾画模型性能与泛化能力的核心瓶颈，且数据分散于多机构、共享受隐私保护与伦理审查限制，其关键破解路径在于联邦学习、半/弱监督学习及生成对抗网络(GAN)。联邦学习旨在破解

“数据孤岛”与隐私限制，通过分布式训练仅共享梯度信息避免了原始数据泄露^[37]，结合差分隐私进一步降低数据重构风险，筑牢多中心协作安全屏障^[38]。半/弱监督学习试图降低对昂贵专家标注的依赖。半监督学习（SSL）以少量标注数据结合大量未标注数据提升泛化性，如 Wang 等^[39]采用 Mean Teacher 框架生成伪标签，将 HD95 误差从 8.2mm 降至 5.7mm。弱监督学习（WSL）通过使用图像级标签等弱监督信息来替代像素级标注，在保证模型性能（Dice 系数达 0.79）显著降低数据标注成本^[40]。GAN 及其变体通过生成逼真医学影像与标注数据，为解决“数据代表性不足”提供了有效的增广手段。Chen 等^[41]用其合成改良根治术后靶区变异数据，有效增强模型对解剖异质性的适应力，缓解了罕见病例数据稀缺问题。这些技术路径分别从不同维度出发，在保证数据安全和降低成本的共同目标前提下，构建出规模更大、更富于多样性的训练集，从而为模型泛化能力的提升奠定基础。

5.2 模型性能优化路径

为了提升乳腺癌放疗靶区勾画精度，多模态数据融合、注意力机制与可解释人工智能共同构成了关键的技术路径。多模态融合旨在克服 CT 影像的“低对比度”缺陷，通过整合 CT 的解剖结构、MRI 的软组织对比度与 PET-CT 的代谢信息，显著优化了肿瘤病灶的分割率^[42]。注意力机制致力于提升模型在“边界模糊”区域的分割能力，通过自适应权重分配强化了模糊区域的特征学习，进一步提高复杂图像的分割性能，使得 ALN 分割的 DSC 达到 83.41%^[28]。可解释 AI 技术则是弥补临床“信任鸿沟”、让“黑箱”变“白箱”的最关键钥匙，它让医师不仅知其然，更知其所以然。如梯度加权类激活映射（Grad-CAM）^[43]通过生成决策热力图，直观展示模型决策依

据的影像区域，辅助验证勾画结果、排查潜在错误，有效增强临床信任与结果可验证性。

5.3 临床转化加速策略

为加速深度学习智能勾画技术的临床转化，需构建“智能勾画-医师修正-模型迭代”的闭环反馈机制，通过持续整合临床修正数据提升模型适应能力可使复杂病例勾画精度提升。技术实现上，开发与主流治疗计划系统（如 Eclipse、Pinnacle）无缝对接的轻量化插件至关重要，如 RootPainter3D^[44]在心脏轮廓勾画任务中，将平均勾画时间从 7 分 1 秒缩短至 2 分 2 秒，显著提升了临床工作效率。同时应建立涵盖 Dice、HD95 等几何精度与临床终点的标准化评价体系，规范多中心的验证流程。

以上这些策略均直面严峻的临床转化难题。构建闭环反馈机制和开发无缝对接 TPS 的轻量化插件，旨在解决“ workflow 中断”的核心痛点，让 AI 成为一个“原生内嵌”而非“外挂”的工具。而建立涵盖临床终点的评价体系，则是推动 AI 从“技术验证”走向“临床指南推荐”的必经之路，是回答“AI 勾画能否带来真实患者获益”这一终极问题的唯一途径。

6 结语

基于人工智能的靶区勾画技术在乳腺癌术后放疗领域已取得长足进步，在危及器官、临床靶区及淋巴引流区的勾画中展现出提高效率与一致性的巨大优势。但数据质量与可及性不足、模型可解释性欠缺及临床转化障碍仍制约其广泛应用。未来需优化联邦学习、多模态数据融合及可解释 AI 技术，构建从技术验证到临床获益的标准化评价体系，推动技术从“临床可用”向“规范可靠”迈进，最终实现技术赋能下的个体化、精准化放疗，真正改善患者预后。

参考文献:

- [1] 王裕新,潘凯枫,李文庆.2022 全球癌症统计报告解读[J].肿瘤综合治疗电子杂志,2024,10(3):1-16.
- [2] 王少明,郑荣寿,韩冰峰,等.2022 年中国人群恶性肿瘤发病与死亡年龄特征分析[J].中国肿瘤,2024,33(03):165-174.
- [3] Buelens P,Willems S,Vandewinckele L,et al.Clinical evaluation of a deep learning model for segmentation of target volumes in breast cancer radiotherapy[J].Radiother Oncol,2022,171:84-90.
- [4] Kim Y W,Biggs S,Claridge Mackonis E.Investigation on performance of multiple AI-based auto-contouring systems in organs at risks(OARs)delineation[J].Physical and Engineering Sciences in Medicine,2024,47(3):1123-1140.
- [5] Chung S Y,Chang J S,Choi M S,et al.Clinical feasibility of deep learning-based auto-segmentation of target volumes and organs-at-risk in breast cancer patients after breast-conserving surgery[J].Radiation Oncology,2021,16(1):44.
- [6] 许卓华,杨慧,江舟,等.基于 3D ResSE-Unet 的智能靶区勾画在乳腺癌术后放疗中的应用研究[J].中华放射医学与防护杂志,2023,43(4):269-275.
- [7] Chen J,Mei J,Li X,et al.TransUNet:Rethinking the U-Net architecture design for medical image segmentation through the lens of transformers[J].Med Image Anal,2024,97:103280.
- [8] 刘方杰.基于卷积神经网络的乳腺癌放射治疗临床靶区及危及器官自动勾画[D].北京协和医学院,2020.

- [9] Zhao C, Qin B, Feng S, et al. Hyperspectral Image Classification With Multi-Attention Transformer and Adaptive Superpixel Segmentation-Based Active Learning[J]. *IEEE Trans Image Process*, 2023, 32:3606-3621.
- [10] Zhang X, Sun G, Jia X, et al. Spectral-Spatial Self-Attention Networks for Hyperspectral Image Classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60(1):1-15.
- [11] Anari S, de Oliveira G G, Ranjbarzadeh R, et al. EfficientUNetViT: Efficient Breast Tumor Segmentation Utilizing UNet Architecture and Pretrained Vision Transformer[J]. *Bioengineering(Basel)*, 2024, 11(9):945.
- [12] Guan S, Loew M. Breast cancer detection using synthetic mammograms from generative adversarial networks in convolutional neural networks[J]. *J Med Imaging(Bellingham)*, 2019, 6(3):31411.
- [13] Pang T, Wong J, Ng W L, et al. Semi-supervised GAN-based Radiomics Model for Data Augmentation in Breast Ultrasound Mass Classification[J]. *Comput Methods Programs Biomed*, 2021, 203:106018.
- [14] Kang S K, An H J, Jin H, et al. Synthetic CT generation from weakly paired MR images using cycle-consistent GAN for MR-guided radiotherapy[J]. *Biomed Eng Lett*, 2021, 11(3):263-271.
- [15] Zhao Y, Wang H, Yu C, et al. Compensation cycle consistent generative adversarial networks(Comp-GAN) for synthetic CT generation from MR scans with truncated anatomy[J]. *Med Phys*, 2023, 50(7):4399-4414.
- [16] 李成梁. 基于深度学习的乳腺癌放疗靶区勾画和剂量预测[D]. 山东大学, 2024.
- [17] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation, Cham, 2015[C]. Springer International Publishing, 2015-01-01.
- [18] Zhou Z, Siddiquee M, Tajbakhsh N, et al. UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation[J]. *IEEE Trans Med Imaging*, 2020, 39(6):1856-1867.
- [19] Oktay O, Schlemper J, Le Folgoc L I C, et al. Attention U-Net: Learning Where to Look for the Pancreas[J]. *ArXiv*, 2018, abs/1804.03999.
- [20] 韩笑辰, 韩若凌, 迟子锋, 等. 乳腺癌 RIHD 心脏亚结构模型及人工智能研究现状[J]. *河北医科大学学报*, 2024, 45(07):861-865.
- [21] Emin S, Rossi E, Hedman M, et al. Performance of multi-vendor auto-segmentation models for thoracic organs at risk trained on a single dataset[J]. *Phys Med*, 2025, 137:105089.
- [22] Sun R, Li X, Han B, et al. Multi-task learning for joint prediction of breast cancer histological indicators in dynamic contrast-enhanced magnetic resonance imaging[J]. *Comput Methods Programs Biomed*, 2025, 267:108830.
- [23] 龚筱钦. 基于深度学习软件的早期乳腺癌靶区及危及器官自动勾画技术在临床的应用研究[D]. 苏州大学, 2022.
- [24] Doolan P J, Charalambous S, Roussakis Y, et al. A clinical evaluation of the performance of five commercial artificial intelligence contouring systems for radiotherapy[J]. *Front Oncol*, 2023, 13:1213068.
- [25] Byun H K, Chang J S, Choi M S, et al. Evaluation of deep learning-based autosegmentation in breast cancer radiotherapy[J]. *Radiat Oncol*, 2021, 16(1):203.
- [26] Liu Z, Liu F, Chen W, et al. Automatic Segmentation of Clinical Target Volumes for Post-Modified Radical Mastectomy Radiotherapy Using Convolutional Neural Networks[J]. *Front Oncol*, 2020, 10:581347.
- [27] Men K, Zhang T, Chen X, et al. Fully automatic and robust segmentation of the clinical target volume for radiotherapy of breast cancer using big data and deep learning[J]. *Phys Med*, 2018, 50:13-19.
- [28] Xu Q, Xi X, Meng X, et al. Difficulty-aware bi-network with spatial attention constrained graph for axillary lymph node segmentation[J]. *Science China Information Sciences*, 2022, 65(9):192102.
- [29] Qiao X, Jiang C, Li P, et al. Improving Breast Tumor Segmentation in PET via Attentive Transformation Based Normalization[J]. *IEEE J Biomed Health Inform*, 2022, 26(7):3261-3271.
- [30] Barragán-Montero A, Bibal A, Dastarac M H, et al. Towards a safe and efficient clinical implementation of machine learning in radiation oncology by exploring model interpretability, explainability and data-model dependency[J]. *Phys Med Biol*, 2022, 67(11).

- [31] Lin H,Xiao H,Dong L,et al.Deep learning for automatic target volume segmentation in radiation therapy:a review[J].Quant Imaging Med Surg,2021,11(12):4847-4858.
- [32] Cardenas C E,Yang J,Anderson B M,et al.Advances in Auto-Segmentation[J].Semin Radiat Oncol,2019,29(3):185-197.
- [33] Gu R,Wang G,Song T,et al.CA-Net:Comprehensive Attention Convolutional Neural Networks for Explainable Medical Image Segmentation[J].IEEE Trans Med Imaging,2021,40(2):699-711.
- [34] Groen A M,Kraan R,Amirkhan S F,et al.A systematic review on the use of explainability in deep learning systems for computer aided diagnosis in radiology:Limited use of explainable AI?[J].Eur J Radiol,2022,157:110592.
- [35] L.Z,X.W,D.Y,et al.Generalizing Deep Learning for Medical Image Segmentation to Unseen Domains via Deep Stacked Transformation[J].IEEE Transactions on Medical Imaging,2020,39(7):2531-2540.
- [36] Alami H,Lehoux P,Papoutsi C,et al.Understanding the integration of artificial intelligence in healthcare organisations and systems through the NASSS framework:a qualitative study in a leading Canadian academic centre[J].BMC Health Serv Res,2024,24(1):701.
- [37] L.C,T.R,E.V,et al.Federated Learning Applications for Breast Cancer:2023 IEEE International Conference on Bioinformatics and Biomedicine(BIBM),2023[C].20235-8 Dec.2023.
- [38] Shukla S,Rajkumar S,Sinha A,et al.Federated learning with differential privacy for breast cancer diagnosis enabling secure data sharing and model integrity[J].Sci Rep,2025,15(1):13061.
- [39] Wang Z,Cao N,Sun J,et al.Uncertainty estimation-and attention-based semi-supervised models for automatically delineate clinical target volume in CBCT images of breast cancer[J].Radiation Oncology,2024,19(1):66.
- [40] Wang H,Huai L,Li W,et al.WeakMedSAM:Weakly-Supervised Medical Image Segmentation via SAM With Sub-Class Exploration and Prompt Affinity Mining[J].IEEE Trans Med Imaging,2025,44(7):2795-2807.
- [41] Chen Y,Yang X H,Wei Z,et al.Generative Adversarial Networks in Medical Image augmentation:A review[J].Comput Biol Med,2022,144:105382.
- [42] Zhai Y,Chen Z,Shao D.[Breast cancer lesion segmentation based on co-learning feature fusion and Transformer][J].Sheng Wu Yi Xue Gong Cheng Xue Za Zhi,2024,41(2):237-245.
- [43] Talaat F M,Gamel S A,El-Balka R M,et al.Grad-CAM Enabled Breast Cancer Classification with a 3D Inception-ResNet V2:Empowering Radiologists with Explainable Insights[J].Cancers(Basel),2024,16(21).
- [44] Smith A G,Petersen J,Terrones-Campos C,et al.RootPainter3D:Interactive-machine-learning enables rapid and accurate contouring for radiotherapy[J].Med Phys,2022,49(1):461-473.