

CT 影像组学在肺肿瘤诊治中的应用研究进展

曹振宇 王健

【摘要】 CT 影像组学为肺肿瘤良、恶性鉴别提供了新的诊断方法。影像组学方法通过靶区勾画和特征提取反映组织特性,定量特征在此过程中尤为重要,特征筛选和统计分析是提升模型预测能力和可靠性的关键。此外,结合深度学习技术、肿瘤周围信息、生存信息及 Ki-67 等免疫标志物数据,能增强影像组学的应用潜力及个性化医疗的实用性。本文对影像组学在肺肿瘤诊治中的应用研究进展作一综述。

【关键词】 肺肿瘤;影像组学;机器学习;深度学习

影像组学作为一种新兴的医学影像分析方法,自 21 世纪初提出以来,已在医学影像领域取得了显著进展。影像组学的核心思想是从医学影像中提取大量的定量特征,这些特征能够反映组织的纹理、形状、强度等信息,从而为疾病的诊断和预后评估提供更丰富的数据支持^[1-2]。本文就影像组学在肺肿瘤诊治中的应用研究进展作一综述,旨在阐述其从影像中提取定量特征以反映组织纹理、形状、强度等信息的核心理念,分析其在疾病诊断与预后评估中的临床价值、技术可行性和应用前景,为今后的临床实践和研究提供依据。

1 影像组学的发展现状

荷兰研究者在 2012 年系统地提出影像组学概念,并通过大量研究验证了其在癌症研究中的潜力。随着计算能力的提升和算法的发展,影像组学经历了从基础特征提取到高级深度学习分析的多阶段演变^[1]。近年来,影像组学的进展主要体现在机器学习和人工智能技术的应用、多模态影像融合、个性化医学以及生物信息学与基因组学的结合等方面^[3]。

1.1 机器学习的应用 机器学习技术可分为监督式学习、非监督式学习和半监督式学习。监督式学习通

过分析带标签的数据集来进行分类或预测;非监督式学习揭示数据内在结构;半监督式学习结合了标记和未标记的数据以提高模型的泛化性能^[4]。(1)监督式学习:核心任务是建立模型将输入特征映射到输出标签,以实现未知数据的预测。主要包括回归任务(如线性回归、最小绝对收缩和选择算子回归)和分类任务[如逻辑回归、决策树、支持向量机(support vector machine, SVM)等]^[5]。①逻辑回归:用于分类问题,通过 sigmoid 函数将连续输出值转换为概率值,以实现二分类。②决策树与随机森林(random forest, RF):决策树通过递归判断特征实现分类;RF 通过集成多个决策树来提高泛化能力。③SVM:适用于小规模数据集,通过构建最优超平面实现分类^[6]。④朴素贝叶斯:高效的分类算法,适用于特征相互独立的数据^[7]。(2)非监督式学习:从未标记的数据中提取潜在结构或模式。它不依赖于标签信息,主要用于数据探索和聚类。常见的算法包括①聚类:如 K 均值、层次聚类和基于密度的空间聚类算法,用于将数据点分组,使得同一组内的数据相似度高,而不同组之间的相似度高。②降维:如主成分分析和 t 分布随机邻域嵌入,帮助减少特征数量,同时保留数据的主要信息,便于可视化和后续分析。(3)半监督式学习:结合少量标记数据和大量未标记数据,以提高模型的学习能力和泛化性能。它通常用于标记数据获取成本高的场景。常见的方法有①自训练:模型首先在标记数据上进行训练,然后使用模型对未标记数据进行预测,再将高置信度的预测结果作为新标签进行进一步训练。②生成对抗网络:通过对抗训练生成样本,从而增强模型

DOI:10.12056/j.issn.1006-2785.2025.47.24.2024-2228

基金项目:浙江省中医药科技计划项目(2025ZL020)

作者单位:310012 杭州,浙江省立同德医院放射科

通信作者:王健, E-mail:119202405@qq.com

的学习能力。

1.2 深度学习技术的应用 卷积神经网络(convolutional neural networks, CNN)和变换器通过构建多层神经网络处理高维复杂数据^[8]。CNN在图像识别和分类任务中表现出色,显著提升了影像特征提取的精度和预测准确性。

1.3 多模态影像融合 将CT、MRI、正电子发射断层扫描(positron emission tomography, PET)等不同影像模态的信息整合,提供更全面的疾病特征和诊断依据,增强影像组学的应用潜力。

1.4 个性化医学 通过结合影像组学和临床数据,使得临床决策更加精确,从而提升治疗效果和患者的生活质量。此外,影像组学与生物信息学和基因组学的结合,揭示了疾病的分子机制,例如大组织和单细胞RNA测序数据,这进一步推动了精准医学的发展^[9-10]。后文着重介绍CT影像组学在评估肺肿瘤方法及准确性方面的提升。

2 影像组学模型构建及效能评估的流程

2.1 图像处理 在对图像进行分析前,需对患者信息进行匿名化处理;对不同型号CT机采集到的图像进行均质化处理,例如调整层间距使其在三维空间均匀分布,调整窗宽窗位、进行小波变换抑制图像噪声等;对图像进行格式转换,统一成NIFTI格式,以保证数据的统一性、完整性。

2.2 病灶分割 完成图像预处理后,研究重点主要集

中在感兴趣区(region of interest, ROI)的勾画及特征提取。当前图形分割的方法主要分为手动分割和自动分割两种,其中自动分割分为无监督、监督、自监督分割3种方法,见表1。无监督分割方法采用阈值化、边缘检测等数字图像处理,无需标注数据,分割精度有限,通常用于初步的肿瘤分割,后续需要手动校准。监督分割方法通常采用深度学习来提取放射学信息,需要大量标注数据来训练分割模型是自动分割中精度最高的一种^[11]。自监督分割方法只需少量的标注数据,并辅以高效的学习任务,即可达到高精度的图像分割,但当前问题是如何设计有效的自监督任务。虽然自动分割方法已经日渐完善,但当前仍旧以手动分割方法作为金标准,针对手动分割的不同观察者间及不同时间的差异性,可以通过交叉验证提高手动分割的稳定性和一致性。常用分割软件有3D Slicer、ITK-Snap、Image J等开源软件。病灶ROI通常分2D和3D两种类型。

2.3 特征提取 图像特征对临床预测模型的构建至关重要,提取有用的特征是影像组学研究最重要的目的之一。在过去数十年的研究中,许多图像特征被广泛采用,这些特征可以根据定义方式分为手工设计的特征与基于深度学习的特征。(1)手工设计特征:机器学习中由研究人员或工程师根据领域知识和经验手动设计和选择的特征,这些特征能够将原始数据(如图像)转换为更有意义的形式,从而使算法能够有效的进行分类、回归或其他分析。手工设计特征进一步

表1 不同分割方法的差异

特性	无监督分割方法	监督分割方法	自监督分割方法
数据需求	不需要标注数据	需要大量标注数据	大量未标注数据,少量标注数据
方法类型	阈值分割、边缘检测、区域生长、聚类	深度学习(如FCN、U-Net、Mask R-CNN)	自监督学习任务(如预测旋转角度、解决拼图、对比学习)
数据处理	直接对图像进行处理,无需训练模型	使用像素级标注的肿瘤区域作为训练数据	通过自监督任务预训练模型,然后使用少量标注数据微调
模型训练	通过算法直接处理图像,如K均值聚类	训练深度学习模型,最小化预测和真实标注的差异	预训练阶段无需标注,微调阶段需要标注数据
应用难点	区分肿瘤和其他肺组织(如血管)可能困难	需要大量的标注工作,且模型可能过拟合	设计有效的自监督任务,确保模型能够学习到有用的特征
优势	不需要标注,适用于新领域	能够提取肿瘤相关的详细特征,提高分割精度	利用大量未标注数据,减少对标注数据的依赖
劣势	分割精度有限,易受其他组织影响	需要大量的标注数据,成本高	自监督任务的设计和微调过程可能复杂
代表性算法	阈值法、区域生长法、K均值聚类	FCN、U-Net、Mask R-CNN	自监督学习策略(如预测旋转角度、解决拼图)
应用场景	初步的肿瘤分割,自动化程度较低	临床使用,自动化程度高	大数据集条件下的自动化肿瘤分割,标注样本较少时

注:FCN为全卷积神经网络;U-Net为U型神经网络;CNN为卷积神经网络。

分为语义特征和定量特征,语义特征是肿瘤的描述性分类和分级,定量特征是连续测量的数值特征,通常被成为放射特征。定量特征可以从不同角度对肿瘤特征进行测量,定量特征大致可分为6类:形状特征、纹理特征、强度特征、统计特征、形态特征和小波特征^[12],见表2。(2)深度学习特征:随着深度学习的发展,模型能够从大量数据中自动学习到更复杂和抽象的特征,过去大多数基于深度学习的影像组学研究采用CNN来提取图像特征。CNN能够在不同卷积中捕获多视图图像特征。现如今变换器模型在深度学习中表现出卓越的效能,其他模型(如DenesSharp模型)以及变换器联合CNN模型的融合模型也均表现出更优的效能^[8]。目前已有研究将上述模型应用于放射组学分析肿瘤,为临床决策提供了新的工具^[13]。

2.4 模型构建 影像组学特征提取后,构建临床预测模型涉及多个关键方面。首先,建模材料包括单纯的2D或3D医学影像、2D与3D影像的联合、不同增强期影像的结合,以及影像数据与临床数据(如患者的性别、年龄、基因和病理信息)的结合^[2,14-15]。这些方法有助于提高模型的综合性和准确率。在建模方法方面,机器学习技术如极限梯度提升、RF和SVM等^[6,16-17],可以单独使用或结合在一起,形成复杂的混合模型,从而利用各自算法的优势来提升预测效能。同时,深度学习技术,特别是CNN,能够自动从影像中提取特征,进行更深层次的分析 and 预测。此外,生境分析关注影像特征与生物学环境之间的关系,例如肿瘤的组织异质性或微环境特征^[18]。这有助于研究人员理解影像特征的生物学意义,从而优化诊断和治疗策略。通过这些方法的综合运用,可以构建更加准确和全面的预测模型,提升医学影像分析的临床价值。

2.5 模型效能评估 评估影像组学模型的效能主要采用以下指标:ROC曲线、AUC、灵敏度、特异度、准确

率、F1分数、决策曲线分析、校准-干预曲线等,对于多分类变量,通常还有宏平均和微平均的指标^[19-20]。为了提高影像组学模型的准确性和实用性,通常采用以下方法:增加样本数量、划分训练/测试集、K折交叉验证、引入外部验证等。

2.6 模型解释 过去,机器学习模型常常被视为“黑箱”,缺乏透明性。然而,随着沙普利加性解释(SHapley Additive exPlanations, SHAP)等技术的发展,能够对机器学习过程中的特征使用进行有效解释^[20-21]。对于深度学习模型,除了SHAP之外,还存在多种解释方法,如梯度加权类激活映射、局部可解释模型和显著性图^[22],这些技术能够揭示模型在决策过程中各特征的重要性及其贡献。

3 影像组学在肺肿瘤评估中的应用

具体到肺肿瘤的评估,影像组学的进展尤为显著。过去,肺肿瘤的评估主要依赖于影像学专家的主观判断,准确性和可重复性较差^[23]。然而,影像组学通过引入定量特征分析,显著提高了评估的客观性和准确性^[14]。基于深度学习的影像分析方法能够自动提取和量化肿瘤的纹理特征,这些特征与肿瘤的生物学行为和预后相关联,为肺肿瘤的分类和预测提供了重要的依据^[24]。此外,通过多模态影像融合技术,研究人员能够整合CT和PET等影像信息,进一步提升了对肺肿瘤的诊断和分期准确性。影像组学技术还应用于肺癌放疗前的生物学标志物以及靶区预处理^[25],以预测放疗后的肺炎的发生概率^[26]。这些技术的应用使得影像组学在肺肿瘤的评估中展现出了显著的优势,改善了疾病管理和治疗决策的质量。

3.1 肺肿瘤的鉴别诊断 影像组学可以帮助区分肺肿瘤的良好、恶性。通过提取CT图像中的多种影像组学特征,并结合不同机器学习模型,可以提高对肺结

表2 用于分析的影像组学手工设计特征参数

特征类别	说明	小类别特征
形状特征	描述肿瘤的几何形状,用于了解肿瘤的外观特征和空间分布	体积、表面积、外形指数、长轴/短轴比等
纹理特征	反映图像灰度级的分布和变化,帮助分析肿瘤的内部结构和异质性	能量、对比度、同质性、相关性等
强度特征	描述图像中灰度值的统计特性,用于评估肿瘤密度和组织成分	均值、标准差、偏度、峰度等
统计特征	包括图像中的统计描述量,用于总结肿瘤区域的整体强度和变化情况	互信息量、统计总能量、统计均衡、中位数等
形态特征	包括肿瘤的表面光滑度、长轴/短轴比等。帮助理解肿瘤的三维形态特征	体积、表面积、外形指数、圆度等
小波特征	如小波变换和局部二值模式等,更复杂的纹理描述方式。用于捕捉更细微的纹理变化和结构信息	小波变换特征、局部二值模式、Gabor滤波器特征、灰度差分矩阵、高斯滤波特征、二阶矩特征、纹理聚合度、高级熵特征等

节性质的预测准确率。Priyadarshini 等^[27]采用 7 种机器学习方法,筛选出最优模型,将准确率提高到 93.1%。此外在恶性肿瘤亚型与异质性的鉴别诊断方面,影像组学也表现优异,如针对非小细胞肺癌(non-small cell lung cancers, NSCLC),影像组学可以区分不同亚型,在 Pan 等^[19]研究中,建立了三分类模型,对非典型腺瘤增生和原位腺癌、微创性腺癌、浸润性腺癌进行预测,准确率达到 85% 以上。这种区分亚型的能力对治疗的选择和患者的预后非常有效。

3.2 肺癌的疗效评估和预后 疗效评估主要涉及以下 3 个方面。(1)生存分析:对患者的生存期限、生存概率以及影响生存的因素进行预测,目的是掌握肺癌的疾病发展和预后;如 Han 等^[28]研究通过影像组学勾画治疗前后肿瘤的 ROI 进行疗效的预测,结果发现可以准确预测肺癌后的生存时间,效能超过常规采用临床信息及单一治疗前影像组学的模型;(2)复发风险评估:针对初次治疗后癌症复发或病情加剧的可能性进行预测,如 Tian 等^[29]研究通过对肿瘤及瘤周的勾画,采用共识聚类的方法,有效地对 NSCLC 患者的术后复发风险进行分层,并为临床提供潜在的预后信息;(3)转移风险评估:对癌细胞通过血液或淋巴系统扩散至身体其他部位并形成新肿瘤的可能性进行预测。

3.3 瘤周信息 肿瘤与周围正常组织的关系,如肿瘤侵犯的程度、肿瘤的卫星灶等形态特征,都有助于提高疾病良、恶性的鉴别准确率^[29-31]。

3.4 基因、细胞水平 影像组学的影像特征能够反映肿瘤内部的组织异质性及周围的微环境状况。Ki-67 作为细胞分裂和增殖的生物标志物,其表达水平通常可以反映肿瘤的增殖速度,常用于预测癌症的进展和预后。在临床研究中,Ki-67 的高表达通常意味着肿瘤细胞增殖活跃,暗示肿瘤具有更高的侵袭性。有研究将影像特征与 Ki-67、表皮生长因子受体等表达数据相关联,揭示了影像特征在分子层面的预测作用^[32-33]。

4 展望

目前,利用机器学习和深度学习方法进行肺癌的预测及预后评估,已经取得了一定的进展,准确率较为满意,未来的研究希望能够通过大模型的参数优化,进一步提高预测准确率,并且对小模型进行参数调整,使小模型也能拥有优秀的预测效能,能够部署并应用于临床^[34-36]。同时,通过多种机器学习方法的结合,联合多个算法的优势,提高影像组学的优势变得可能,Zhang 等^[37]研究给了笔者启发,未来也许是新

的研究方向。

然而,影像组学的应用也面临一些技术挑战。首先,数据隐私问题是影像组学发展中的关键难题之一^[38],如何在保证数据安全的前提下进行大规模数据分析,需要进一步的技术创新和政策支持。其次,影像组学模型的泛化能力仍然是研究中的热点问题。尽管已有模型在特定数据集上取得了较好的效果^[32],但不同医院、设备、采集条件等因素对影像数据的影响,使得模型在不同环境中的表现可能不稳定^[39-40]。为了提高模型的泛化能力,需要加强数据标准化、跨数据集的验证以及多中心临床研究的开展。此外,影像数据的质量与标准化也是限制影像组学广泛应用的因素之一,尤其是 CT 图像的噪声、分辨率、扫描方法等差异性,可能影响特征提取的准确性^[41]。

因此,未来的研究需要更加注重这些技术挑战,开发更加稳定和高效的算法,并推动影像组学技术的临床转化。

5 参考文献

- [1] Mayerhoefer ME, Materka A, Langs G, et al. Introduction to radiomics[J]. *J Nucl Med*, 2020, 61(4):488-495. DOI:10.2967/jnumed.118.222893.
- [2] Cheng DO, Khaw CR, McCabe J, et al. Predicting histopathological features of aggressiveness in lung cancer using CT radiomics: a systematic review[J]. *Clin Radiol*, 2024, 79(9):681-689. DOI:10.1016/j.crad.2024.04.022.
- [3] Singh S, Mohajer B, Wells SA, et al. Imaging genomics and multiomics: a guide for beginners starting radiomics-based research[J]. *Acad Radiol*, 2024, 31(6):2281-2291. DOI:10.1016/j.acra.2024.01.024.
- [4] 章子怡, 王荣临, 张俊有, 等. 多组学数据驱动的机器学习模型在乳腺癌生存及治疗响应预测中的应用[J]. *遗传*, 2024, 46(10):820-832. DOI:10.16288/j.ycz.24-156.
- [5] Yichu S, Fei L, Ying L, et al. Potential of radiomics analysis and machine learning for predicting brain metastasis in newly diagnosed lung cancer patients[J]. *Clin Radiol*, 2024, 79(6):e807-e816. DOI:10.1016/j.crad.2024.01.038.
- [6] Hata A, Aoyagi K, Hino T, et al. Automated interstitial lung abnormality probability prediction at CT: a stepwise machine learning approach in the Boston lung cancer study[J]. *Radiology*, 2024, 312(3):e233435. DOI:10.1148/radiol.233435.
- [7] Zhang J, Hao L, Xu Q, et al. Radiomics and clinical characters based Gaussian Naive Bayes (GNB) model for preoperative differentiation of pulmonary pure invasive mucinous adenocarcinoma from mixed mucinous adenocarcinoma[J]. *Technol Cancer Res Treat*, 2024, 23:15330338241258415. DOI:10.1177/15330338241258415.

- [8] Andrade-Miranda G, Jaouen V, Tankyevych O, et al. Multi-modal medical transformers: a Meta-analysis for medical image segmentation in oncology[J]. *Comput Med Imaging Graph*, 2023, 110:102308. DOI:10.1016/j.compmedimag.2023.102308.
- [9] Bai QR, Yang X, Li QF, et al. Metastatic tumor cell-specific FABP7 promotes NSCLC metastasis via inhibiting β -catenin degradation[J]. *Cells*, 2022, 11(5):805. DOI:10.3390/cells11050805.
- [10] Lee J, Kim S, Hyun D, et al. Deep single-cell RNA-seq data clustering with graph prototypical contrastive learning[J]. *Bioinformatics*, 2023, 39(6):btad342. DOI:10.1093/bioinformatics/btad342.
- [11] Saqi A, Liu Y, Politis MG, et al. Combined expert-in-the-loop: random forest multiclass segmentation U-net based artificial intelligence model: evaluation of non-small cell lung cancer in fibrotic and non-fibrotic microenvironments[J]. *J Transl Med*, 2024, 22(1):640. DOI:10.1186/s12967-024-05394-2.
- [12] 侯志昌, 杨灏瀛, 汪红兵. 融合手工设计特征与深度学习的磨粒缺陷检测模型[J]. *河北冶金*, 2025(6):46-52. DOI:10.13630/j.cnki.13-1172.2025.0607.
- [13] Arulkumaran K, Deisenroth MP, Brundage M, et al. A brief survey of deep reinforcement learning[J]. *IEEE*, 2017, 34(6):26-38. DOI:10.1109/MSP.2017.2743240.
- [14] Chen M, Lu H, Cpoley SJ, et al. A novel radiogenomics biomarker for predicting treatment response and pneumotoxicity from programmed cell death protein or ligand-1 inhibition immunotherapy in NSCLC[J]. *J Thorac Oncol*, 2023, 18(6):718-730. DOI:10.1016/j.jtho.2023.01.089.
- [15] Wang L, Ye M, Lu Y, et al. A combined encoder-transformer-decoder network for volumetric segmentation of adrenal tumors[J]. *Biomed Engl Online*, 2023, 22(1):106. DOI:10.1186/s12938-023-01160-5.
- [16] Kuang BL, Zhang JX, Zhang MQ, et al. Advancing NSCLC pathological subtype prediction with interpretable machine learning: a comprehensive radiomics-based approach[J]. *Front Med*, 2024, 11:1413990. DOI:10.3389/fmed.2024.1413990.
- [17] Nair SS, Devi VNM, Bhasi S. Enhanced lung cancer detection: Integrating improved random walker segmentation with artificial neural network and random forest classifier[J]. *Heliyon*, 2024, 10(7):e29032. DOI:10.1016/j.heliyon.2024.e29032.
- [18] Caii W, Wu X, Guo K, et al. Integration of deep learning and habitat radiomics for predicting the response to immunotherapy in NSCLC patients[J]. *Cancer Immunol Immunother*, 2024, 73(8):153. DOI:10.1007/s00262-024-03724-3.
- [19] Pan Z, Hu G, Zhu Z, et al. Predicting invasiveness of lung adenocarcinoma at chest CT with deep learning ternary classification models[J]. *Radiology*, 2024, 311(1):e232057. DOI:10.1148/radiol.232057.
- [20] Meng LY, Zhu P, Xia KJ. Application value of the automated machine learning model based on modified CT index combined with serological indices in the early prediction of lung cancer[J]. *Front Public Health*, 2024, 12:1368217. DOI:10.3389/fpubh.2024.1368217.
- [21] Hu JL, Xu J, Li M, et al. Identification and validation of an explainable prediction model of acute kidney injury with prognostic implications in critically ill children: a prospective multicenter cohort study[J]. *EClinical Medicine*, 2024, 68:102409. DOI:10.1016/j.eclinm.2023.102409.
- [22] Geng Z, Li K, Mei P, et al. Multichannel deep learning prediction of major pathological response after neoadjuvant immunotherapy in lung cancer: a multicenter diagnostic study[J]. *Int J Surg*, 2025, 111(10):6614-6626. DOI:10.1097/JS9.0000000000002821.
- [23] 中华医学会肿瘤学分会, 中华医学会杂志社. 中华医学会肺癌临床诊疗指南(2023版) [J]. *中华医学杂志*, 2023, 103(27):2037-2074. DOI:10.3760/cma.j.cn112137-20230510-00767.
- [24] 李元婕, 王渊, 邱志新. 人工智能在肺磨玻璃结节鉴别诊断中的研究进展[J]. *中华结核和呼吸杂志*, 2024, 47(6):566-570. DOI:10.3760/cma.j.cn112147-20231214-00370.
- [25] Zhang RH, Zhu HM, Chen MB, et al. A dual-radiomics model for overall survival prediction in early-stage NSCLC patient using pre-treatment CT images[J]. *Front Oncol*, 2024, 14:1419621. DOI:10.3389/fonc.2024.1419621.
- [26] Hirose TA, Arimura H, Ninomiya K, et al. Radiomic prediction of radiation pneumonitis on pretreatment planning computed tomography images prior to lung cancer stereotactic body radiation therapy[J]. *Sci Rep*, 2020, 10(1):20424. DOI:10.1038/s41598-020-77552-7.
- [27] Priyadarshini K, Ali SA, Sivanandam K, et al. Human lung cancer classification and comprehensive analysis using different machine learning techniques[J]. *Microsc Res Tech*, 2025, 88(1):234-250. DOI:10.1002/jemt.24682.
- [28] Han XY, Wang YJ, Jia X, et al. Predictive value of delta-radiomic features for prognosis of advanced non-small cell lung cancer patients undergoing immune checkpoint inhibitor therapy[J]. *Transl Lung Cancer Res*, 2024, 13(6):1247-1263. DOI:10.21037/tlcr-24-7.
- [29] Tian Q, Zhou SY, Qin YH, et al. Analysis of postoperative recurrence-free survival in non-small cell lung cancer patients based on consensus clustering[J]. *Clin Radiol*, 2024, 79(10):e1214-e1225. DOI:10.1016/j.crad.2024.06.011.
- [30] Su QS, Wang BY, Guo J, et al. CT-based radiomics and clinical characteristics for predicting bone metastasis in lung adenocarcinoma patients[J]. *Transl Lung Cancer Res*, 2024, 13(4):721-732. DOI:10.21037/tlcr-24-38.
- [31] Xu R, Wang KY, Peng B, et al. Evaluating peritumoral and intratumoral radiomics signatures for predicting lymph node metastasis in surgically resectable non-small cell lung cancer[J]. *Front Oncol*, 2024, 14:1427743. DOI:10.3389/fonc.

(下转第 2688 页)

- j.jhep.2023.01.006.
- [30] 张静雯, 时永全, 韩英. 肝硬化的治疗进展[J]. 临床肝胆病杂志, 2015, 31(3):465–468. DOI:10.3969/j.issn.1001–5256.2015.03.037.
- [31] 陈斌, 胡志强. 原发性肝癌肝切除术后肝功能衰竭的风险因素分析[J]. 中华肝胆外科杂志, 2020, 26(12):881–885. DOI:10.3760/cma.j.cn113884–20200229–00103.
- [32] 王凯, 刘凯, 周春雷, 等. Treg/Th17 细胞在胆道闭锁儿童肝移植术后急性排斥反应中的变化[J]. 中华肝胆外科杂志, 2019, 25(1):5–9. DOI:10.3760/cma.j.issn.1007–8118.2019.01.002.
- [33] Mahmud N, Fricker Z, Lewis JD, et al. Risk prediction models for postoperative decompensation and infection in patients with cirrhosis: a veterans affairs cohort study[J]. Clin Gastroenterol Hepatol, 2022, 20(5):e1121–e1134. DOI:10.1016/j.cgh.2021.06.050.
- [34] Li P, Wang Y, Li H, et al. Prediction of postoperative infection in elderly using deep learning-based analysis: an observational cohort study[J]. Aging Clin Exp Res, 2023, 35(3):639–647. DOI:10.1007/s40520–022–02325–3.
- [35] 姜树森, 姚红兵, 谭李军. 肝癌术前肝脏储备功能评估方法的应用与研究进展[J]. 中国普通外科杂志, 2024, 33(1):88–99. DOI:10.7659/j.issn.1005–6947.2024.01.010.
- [36] 吴健, 曹林平. 机器学习在肝移植中的应用[J]. 器官移植, 2022, 13(6):722–729. DOI:10.3969/j.issn.1674–7445.2022.06.005.
- [37] Wang R, Tang LV, Hu Y. Genetic factors, risk prediction and AI application of thrombotic diseases[J]. Exp Hematol Oncol, 2024, 13(1):89. DOI:10.1186/s40164–024–00555–x.
- [38] Huang T, Yang R, Shen L, et al. Deep transfer learning to quantify pleural effusion severity in chest X-rays[J]. BMC Med Imaging, 2022, 22(1):100. DOI:10.1186/s12880–022–00827–0.
- [39] Fodor M, Zelger P, Pallua JD, et al. Prediction of biliary complications after human liver transplantation using hyperspectral imaging and convolutional neural networks: a proof-of-concept study[J]. Transplantation, 2024, 108(2):506–515. DOI:10.1097/TP.0000000000004757.
- [40] Holm EA. In defense of the black box[J]. Science, 2019, 364(6435):26–27. DOI:10.1126/science.aax0162.
- (收稿日期:2025–02–24)
(本文编辑:严玮雯)

(上接第 2683 页)
2024.1427743.

- [32] Wu JR, Meng H, Zhou L, et al. Habitat radiomics and deep learning fusion nomogram to predict EGFR mutation status in stage I non-small cell lung cancer: a multicenter study[J]. Sci Rep, 2024, 14(1):15877. DOI:10.1038/s41598–024–66751–1.
- [33] Le NQK, Kha QH, Nguyen VH, et al. Machine learning-based radiomics signatures for EGFR and KRAS mutations prediction in non-small-cell lung cancer[J]. Int J Mol Sci, 2021, 22(17):9254. DOI:10.3390/ijms22179254.
- [34] Wong J, Baine M, Wisnoskie S, et al. Effects of interobserver and interdisciplinary segmentation variabilities on CT-based radiomics for pancreatic cancer[J]. Sci Rep, 2021, 11(1):16328. DOI:10.1038/s41598–021–95152–xIF.
- [35] Wang YF, Zhou C, Ying L, et al. Leveraging serial low-dose CT scans in radiomics-based reinforcement learning to improve early diagnosis of lung cancer at baseline screening[J]. Radiol Cardiothorac Imaging, 2024, 6(3):e230196. DOI:10.1148/ryct.230196.
- [36] Zarei M, Abadi E, Vancoillie L, et al. Protocol selection for formalism for minimizing detectable differences in morphological radiomics features of lung lesions in repeated CT acquisitions[J]. J Med Imaging, 2024, 11(2):025501. DOI:10.1117/1.JMI.11.2.025501.
- [37] Zhang G, Wang ZY, Tong Z, et al. AI hybrid survival assessment for advanced heart failure patients with renal dysfunction[J]. Nat Commun, 2024, 15(1):6756. DOI:10.1038/s41467–024–50415–9.
- [38] Shi Z, Zhovannik I, Traverso A, et al. Distributed radiomics as a signature validation study using the personal health train infrastructure[J]. Sci Data, 2019, 6(1):218. DOI:10.1038/s41597–019–0241–0.
- [39] Strotzer QD, Wagner T, Angstwurm P, et al. Limited capability of MRI radiomics to predict primary tumor histology of brain metastases in external validation[J]. Neurooncol Adv, 2024, 6(1):vdae060. DOI:10.1093/oaajnl/vdae060.
- [40] DeVries DA, Tang T, Alqaidy G, et al. Dual-center validation of using magnetic resonance imaging radiomics to predict stereotactic radiosurgery outcomes[J]. Neurooncol Adv, 2024, 6(1):vdae060. DOI:10.1093/oaajnl/vdae060.
- [41] Ferro A, Bottosso M, Dieci MV, et al. Clinical applications of radiomics and deep learning in breast and lung cancer: a narrative literature review on current evidence and future perspectives[J]. Crit Rev Oncol Hematol, 2024, 203:104479. DOI:10.1016/j.critrevonc.2024.104479.
- (收稿日期:2025–02–19)
(本文编辑:严玮雯)