

深度学习在肝硬化诊治中的应用研究进展

毛晓霞 李嘉颖

【摘要】 肝硬化是一种慢性进行性肝脏疾病,严重影响患者健康甚至危及生命。近年来,随着慢性肝炎病毒感染、酗酒、肥胖和 2 型糖尿病等患者的增加,肝硬化的发病率和死亡率也呈逐渐上升趋势。然而,传统的肝硬化诊治主要依赖于临床症状观察、影像学检查和医生经验,缺乏客观的工具辅助诊断和指导个性化治疗。人工智能在医疗领域的应用可以帮助临床医生提高工作效率,而深度学习作为人工智能分支,在肝硬化治疗方面的应用研究越来越多。本文就深度学习在肝硬化及其并发症治疗中的应用研究进展作一综述。

【关键词】 肝硬化;深度学习;人工智能;诊断;治疗

肝硬化是一种慢性进行性肝脏疾病,其发病过程非常缓慢,患者可能在多年甚至数十年内逐渐出现症状^[1],会严重危害患者的健康甚至危及生命。肝硬化的危害主要表现在肝功能受损、门静脉高压、脾功能亢进、肝性脑病以及肝癌风险增加等。近 30 年来,随着慢性肝炎病毒感染、酗酒、肥胖和 2 型糖尿病患者增加^[2],肝硬化的发病率也呈上升趋势,全球总人口约有 1%~2% 的肝硬化患者,每年死亡患者中有 2.4% 原因为肝硬化^[3]。当前肝硬化的诊断仍以传统的临床症状、体格检查和影像学检查为主,虽然这些方法能够提供基本的诊断信息,但存在依赖医生经验、难以制定个性化治疗方案、后续随访不足等缺点。深度学习是基于人工神经网络(artificial neural network, ANN)的机器学习方法^[4],主要作用于图像识别领域^[5],也是近年来人工智能(artificial intelligence, AI)领域发展迅速、最能体现机器智能的一个分支^[6],其通过构建多层神经网络来模拟人脑神经元的工作原理,从而实现了对复杂数据的学习和抽象表达。这种技术在医疗领域的应用潜力巨大,尤其在肝硬化的诊治中,深度学习可以帮助临床医生提高诊断准确性、个性化治疗效果

及早期干预能力等,为患者提供更加精准和有效的医疗服务^[7]。因此,深度学习在肝硬化诊治中的应用具有重要意义。本文就深度学习在肝硬化诊治中的应用进展作一综述。

1 深度学习在肝硬化影像诊断中的应用

肝硬化属于肝纤维化的晚期阶段,分为代偿期和失代偿期。多数肝硬化患者因早期无明显症状,导致就诊时已处于失代偿期。当失代偿期肝硬化患者出现消化道出血、肝性脑病、肝癌等并发症时,将严重影响其生活质量及生存状态,并给国家和社会带来巨大的经济负担。因此,早期诊断肝硬化尤为重要^[8]。目前已有许多研究表明深度学习对肝硬化的早期诊断具有较大的应用价值^[9],可以帮助医生更快地诊断疾病和预测疾病的进展。深度学习对肝硬化的诊断主要基于其强大的模式识别和数据分析能力^[10],从而诊断出是否发生肝硬化,以及确定肝硬化程度从而进行个性化治疗。张欢等^[11]在 AlexNet 网络的基础上建立了 SH-ImAlexNet 卷积神经网络(convolutional neural network, CNN)模型,通过采集 1 200 张正常肝脏和肝硬化样本的超声影像图并分为训练集和验证集,以分析该新模型的复杂度和鲁棒性,实验得出 ImAlexNet 模型对肝硬化的识别率相较于 AlexNet、视觉几何组网络模型等传统模型网络更优,且空间复杂度和时间复杂度更低,运行效率更高,能更精确高效地识别出肝硬化。付甜甜等^[12]将 354 例患者的肝脏灰阶超声图像和相应弹性图像作为训练集,并分别采用传统机器学习

DOI:10.12056/j.issn.1006-2785.2025.47.24.2024-2271

基金项目:浙江中医药大学科研项目(2022JKJNTZ20)

作者单位:310006 杭州,浙江中医药大学附属第一医院(浙江省中医院)医学影像科

通信作者:李嘉颖, E-mail:20213025@zcmu.edu.cn

方法的支持向量机 (support vector machine, SVM) 分类模型和稀疏表示分类器以及 LeNet-5 深度学习 CNN 来对超声图像数据集进行特征提取和分类, 经过多次测试后发现, 在对肝硬化的分类中, LeNet-5 的准确率高达 90%, 远超前传统机器学习模型的 80%。Yin 等^[13]利用 252 例患者经组织学证实肝纤维化分期的门静脉期 CT 增强图像建立 CNN 肝纤维化分期网络 (liver fibrosis staging network, LFS), 并采用梯度加强类激活映射技术来给出 LFS 的诊断决策可视化解释, 结果显示 LFS 在识别显著纤维化 (F2~F4)、晚期纤维化 (F3~F4) 和肝硬化 (F4) 上的 AUC 分别为 0.92、0.89 和 0.88, 且无纤维化患者 LFS 更多的集中在肝表面, 而肝硬化患者的 LFS 更多的集中在肝、脾实质, 证实了 LFS 能够利用基于 CT 的肝表面、肝实质和肝外信息来预测肝纤维化的分期。深度学习技术的不断发展和完善, 使基于深度学习的肝硬化诊断更加的快速、便捷、精确, 应不断完善深度学习的架构和算法, 结合多模态数据进行分析, 为患者提供更优的治疗。

2 深度学习在肝硬化病因治疗中的应用

常见的肝硬化病因有病毒性肝炎、酒精性肝病和非酒精性脂肪性肝病。深度学习通常被应用于以丙型肝炎为病因的肝硬化分析^[14], 为研制针对性药物做准备, 更好地对患者进行治疗。Decharatanachart 等^[15]纳入 AI 在慢性肝病中应用相关的 80 篇文献进行定性分析, 19 篇文献进行定量分析, 用于评估 AI 效能。结果发现, CNN 模型在检测严重肝硬化时灵敏度为 81%~85%, 特异度为 80%~85%, 并且发现将血液检测等临床数据与混合深度学习 (CNN 模型、ANN 模型) 相结合后, 可根据肝硬化的不同病因更精确地预测肝硬化的进展。这说明了深度学习可以判断肝硬化的病因, 以便医生更好地为患者制定个性化治疗方案。丙型肝炎病毒 (hepatitis C virus, HCV) 会引起病毒性肝炎, 导致肝硬化的发生。Kamboj 等^[16]收集了与 HCV 非结构蛋白相关的化合物数据, 并且用 SVM、k 临近算法、ANN、随机森林共同构建支持基于向量机的预测模型, 来寻找可针对 HCV 非结构蛋白的再利用药物, 该模型在 10 折交叉验证中相关系数为 0.80~0.92, 并且在独立性能测试上展现出与 10 折交叉验证相同的效能, 这也证实了该模型在 HCV 非结构蛋白的预测上具有可靠性, 也为未来寻找 HCV 治疗药物提供了技术支撑。Su 等^[17]阐明深度学习可以分析复杂的临床数据和基因组信息, 以支持个性化治疗决策, 更好的对

症治疗。深度学习在针对肝硬化病因的治疗中发挥着重要的作用, 在药物的研发、制定个性化治疗方案中, 深度学习表现出了较强的可靠性和稳健性。

3 深度学习在肝硬化并发症治疗中的应用

肝硬化患者经常会出现腹腔积液、肝性脑病和骨质疏松等并发症^[18], 这些并发症的发病率和死亡率很高, 尽早诊断和治疗是十分重要的。但像门静脉血栓、肝硬化肌少症等并发症, 发病率高却不容易被临床医生发现, 耽误治疗进程, 严重影响了患者的健康^[19]。Garcia-Pagan 等^[20]统计发现, 肝硬化患者出院后, 因并发症而在 90 d 内再次入院的概率为 21%~53%, 同时会产生大量的医疗和社会护理成本。而深度学习能够从各种图像中提取患有并发症的图像特征, 从而精准预测是否患并发症, 做出早期诊断病制定个性化治疗方案, 并帮助医生确认最佳干预时机, 避免并发症恶化。Wang 等^[21]开发了一种基于 AI 的方法来自动量化 CT 扫描中的腹水, 所构建的 QuanNet CNN 模型检测腹水时的准确率达 97.21%, 证实了深度学习可以精准的检测和评估腹水的发生。李芳菲等^[22]采集了肝硬化即肝性脑病患者的脑部 MRI 检查图像数据, 并利用深度学习对数据进行训练, 建立了能够预测脑龄的模型, 且通过分析预测脑龄与实际年龄差值、数字连接试验-A 和数字-符号试验评分, 得出了肝硬化患者的认知功能降低, 大脑衰老加速, 这些改变在肝性脑病患者中更加明显, 这也说明通过建立深度学习模型可以预测肝硬化患者的大脑衰老趋势, 以预测肝性脑病的发生。骨质疏松是肝硬化常见的并发症^[23], Zhang 等^[24]创建了深度卷积神经网络 (deep convolutional neural network, DCNN), 并用 1 616 幅腰椎 X 线检查图像对 DCNN 模型诊断骨质疏松的效能进行测试, 结果显示两组测试集中诊断骨质疏松模型的 AUC 分别为 0.767、0.726, 灵敏度分别为 0.737、0.684, 诊断骨质减少模型的 AUC 分别为 0.787、0.810, 灵敏度分别为 0.818、0.853, 也说明了深度学习诊断网络在检测由于肝硬化引发的骨质疏松方面具有巨大潜力。深度学习技术的不断优化与发展, 使其诊断疾病的精度和效率大大提升, 将会更加精准的预测并发症的发生, 成为临床更可靠的辅助工具, 为患者的健康与治疗提供更有力的支持与保障。

4 深度学习在肝硬化肝移植治疗中的应用

肝硬化的治疗方法多种多样, 包括药物治疗、控

制饮食、肝移植等。然而,肝移植作为一种重要的治疗手段,在提高患者生存率、改善患者生活质量以及显著改善肝硬化并发症等方面,效果更为显著,也被广泛认为是肝硬化治疗的主要手段。Markus 等^[25]通过比较接受肝移植的原发性胆汁性肝硬化患者与梅奥模型模拟对照组患者的生存概率得出,对于晚期原发性胆汁性肝硬化患者,肝移植是最有效的治疗方法。深度学习在肝移植中的应用对治疗肝硬化具有重要作用。Nitski 等^[26]研究了 3 837 例肝移植患者,用训练多层感知器、递归神经网络变体、时间卷积网络、Transformer 模型和逻辑回归模型对肝移植患者存活率及死亡原因方面进行预测,发现 Transformer 模型的 AUC 最高,而逻辑回归模型的 AUC 最低,得出深度学习在预测肝移植后患者死亡概率及病因方面的效能远高于普通机器模型。Kavur 等^[27]纳入 20 例活体捐赠者作为肝移植供体,使用 6 种半自动方法和 6 种全自动方法对其肝脏增强 CT 图像进行分割,后使用体积重叠和相对体积误差、平均对称表面距离、均方根对称表面距离、最大对称表面距离 5 个指标来评估每个分割图像,评分后取平均值作为最终成绩。6 种全自动方法的成绩分别为 79.6、79.5、77.2、74.5、49.7、37.6,6 种半自动方法的成绩分别为 72.8、68.2、62.3、56.1、45.3、23.7,而排名前 4 位均为自动深度学习模型,分别是两组用于图像分割的 CNN、深度医学分割模型、开源 CNN 框架。因此,在对肝移植供体进行肝脏分割和体积测量时,基于深度学习的自动分割算法可大幅提高其准确性和可重复性。深度学习在肝移植中的应用不仅涵盖了对肝脏进行医学影像分析、评估移植物分配的有效性^[28],还包括对患者生存率的预测、识别疾病复发以及预测并发症的发生^[29],且相对于传统的手动分割、临床特征分析等更准确高效。

5 深度学习在肝硬化治疗后并发症中的应用

肝硬化治疗后仍有可能出现肝癌、感染^[30]、肝功能不全^[31]以及出现肝移植排斥反应^[32]等并发症,甚至有些患者还会出现门静脉血栓、胸水。Mahmud 等^[33]以退伍军人为研究对象,发现肝硬化患者术后 8.7% 的患者出现间歇性失代偿,4.5% 的患者出现感染症状。Li 等^[34]将 504 例患者基于常规模型和深度学习神经网络模型分别构建术后感染预测模型,两者预测感染概率分别为 0.728 和 0.763,表明深度学习可以被应用于预测感染的发生。姜树森等^[35]指出近期研发基于健康肝脏 CT 图像的深度学习算法能够更加精准的测量出

肝脏容积,进而评估肝脏储备功能,可以预测肝功能衰竭的发生,为检测肝硬化术后肝功能不全提供更优途径。吴健等^[36]提出 ANN 模型可用来协助诊断肝移植术后排斥反应,预测肝移植受者急性排斥反应而把握治疗的最佳时期。如今,深度学习还可以用于其他肝硬化术后并发症的预测,如门静脉血栓^[37]、胸水^[38]和胆道并发症^[39]等。深度学习的不断发展,也使术后并发症的预测更加精确,更好地保障患者的身体健康。然而,在实时监测和长远预后评估等方面,深度学习仍存在着局限性,在算法的精确性、数据的多样性和临床应用等方面也有待进一步研究。

6 深度学习应用的局限性

尽管深度学习在肝硬化治疗中的应用展示了广阔前景,但目前仍存在一些局限性亟待解决。第一,目前大部分研究为回顾性研究,数据样本多来自单中心或局部区域,这导致结果在更广泛人群中的适用性和普遍性受到限制,需要采取多中心和前瞻性方法将深度学习方法应用到肝硬化治疗中。第二,深度学习通常被视为“黑盒”^[40],其决策过程缺乏透明性,这使得临床医生无法清楚理解做出诊断的依据和细节,也减少了模型的临床信任度,需开发可解释性更强的深度学习模型,减少模型的不透明性,增加可靠性。第三,当前深度学习模型的构建大多基于单一数据类型,而且现有模型对多模态数据的整合和分析能力尚显不足,在实际临床应用中,可结合基因组学、代谢组学、蛋白质组学等更多的多模态数据,提升模型的综合分析能力。

7 小结和展望

肝硬化是一种慢性进行性肝脏疾病,其诊断和治疗面临诸多挑战。近年来,随着深度学习技术不断发展,其在针对肝硬化病因、并发症治疗和肝移植预后预测等方面的应用越来越深入。未来可结合传统视觉影像、临床特征和分子基因组学等多模态信息,更好地将图像生物标志物与疾病生物学以及预后联系起来指导临床决策,真正地运用到临床中去。通过多中心研究和前瞻性验证,以及深度学习算法的不断完善,最终实现精准和个性化治疗的目标。

8 参考文献

- [1] Ginès P, Krag A, Abraldes JG, et al. Liver cirrhosis[J]. Lancet, 2021, 398(10308):1359–1376. DOI:10.1016/S0140–6736(08)60

- 383-9.
- [2] Thiele M, Pose E, Juanola A, et al. Population screening for cirrhosis[J]. *Hepatol Commun*, 2024, 8(9):e0512. DOI:10.1097/HC9.0000000000000512.
- [3] Huang DQ, Terrault NA, Tacke F, et al. Global epidemiology of cirrhosis— aetiology, trends and predictions[J]. *Nat Rev Gastroenterol Hepatol*, 2023, 20(6):388-398. DOI:10.1038/s41575-023-00759-2.
- [4] Dong S, Wang P, Abbas K. A survey on deep learning and its applications[J]. *Comput Sci Rev*, 2021, 40:100379. DOI:10.1016/j.cosrev.2021.100379.
- [5] Bhattacharya S, Reddy Maddikunta PK, Pham QV, et al. Deep learning and medical image processing for coronavirus (COVID-19) pandemic: a survey[J]. *Sustain Cities Soc*, 2021, 65:102589. DOI:10.1016/j.scs.2020.102589.
- [6] 杨洋, 吕光宏, 赵会, 等. 深度学习在软件定义网络研究中的应用综述[J]. *软件学报*, 2020, 31(7):2184-2204. DOI:10.13328/j.cnki.jos.006039.
- [7] 鞠维欣, 赵希梅, 魏宾, 等. 深度学习模型 GoogleNet-PNN 对肝硬化的识别[J]. *计算机工程与应用*, 2019, 55(5):112-117. DOI:10.3778/j.issn.1002-8331.1804-0300.
- [8] Chen YW, Tsai MY, Pan HB, et al. Gadoteric acid-enhanced MRI and sonoelastography: non-invasive assessments of chemoprevention of liver fibrosis in thioacetamide-induced rats with Sho-Saiko-To[J]. *PLoS One*, 2014, 9(12):e114756. DOI:10.1371/journal.pone.0114756.
- [9] Takahashi Y, Dungubat E, Kusano H, et al. Artificial intelligence and deep learning: new tools for histopathological diagnosis of nonalcoholic fatty liver disease/nonalcoholic steatohepatitis[J]. *Comput Struct Biotechnol J*, 2023, 21:2495-2501. DOI:10.1016/j.csbj.2023.03.048.
- [10] 罗会兰, 童康, 孔繁胜. 基于深度学习的视频中人体动作识别进展综述[J]. *电子学报*, 2019, 47(5):1162. DOI:10.3969/j.issn.0372-2112.2019.05.025.
- [11] 张欢, 赵希梅. 基于 STN 与异构卷积滤波器的肝硬化识别[J]. *计算机工程*, 2021, 47(5):301-307, 315. DOI:10.19678/j.issn.1000-3428.0057341.
- [12] 付甜甜, 姚钊, 丁红, 等. 计算机辅助诊断慢性乙肝患者肝纤维化进程的价值分析[J]. *中华医学杂志*, 2019, 99(7):491-495. DOI:10.3760/cma.j.issn.0376-2491.2019.07.003.
- [13] Yin Y, Yakar D, Dierckx RAJO, et al. Liver fibrosis staging by deep learning: a visual-based explanation of diagnostic decisions of the model[J]. *Eur Radiol*, 2021, 31(12):9620-9627. DOI:10.1007/s00330-021-08046-x.
- [14] Utku A. Deep learning based cirrhosis detection[J]. *Oper Res Eng Sci Theory Appl*, 2023, 6(1):95-114. DOI:10.31181/oresta171122136u.
- [15] Decharatanachart P, Chaiteerakij R, Tiyyarattanachai T, et al. Application of artificial intelligence in chronic liver diseases: a systematic review and Meta-analysis[J]. *BMC Gastroenterol*, 2021, 21(1):10. DOI:10.1186/s12876-020-01585-5.
- [16] Kamboj S, Rajput A, Rastogi A, et al. Targeting non-structural proteins of hepatitis C virus for predicting repurposed drugs using QSAR and machine learning approaches[J]. *Comput Struct Biotechnol J*, 2022, 20:3422-3438. DOI:10.1016/j.csbj.2022.06.060.
- [17] Su TH, Wu CH, Kao JH. Artificial intelligence in precision medicine in hepatology[J]. *J Gastroenterol Hepatol*, 2021, 36(3):569-580. DOI:10.1111/jgh.15415.
- [18] 文静, 张志云, 张艳华, 等. 肝硬化门静脉高压症合并原发性肝癌患者腹腔镜术后并发症危险因素分析[J]. *护理学杂志*, 2023, 38(6):27-31. DOI:10.3870/j.issn.1001-4152.2023.06.027.
- [19] 李飞, 陆伦根. 易被忽视的肝硬化并发症: 门静脉血栓、肌少症和肝性骨病[J]. *中华肝脏病杂志*, 2021, 29(3):193-195. DOI:10.3760/cma.j.cn501113-20210302-00102.
- [20] Garcia-Pagan JC, Francoz C, Montagnese S, et al. Management of the major complications of cirrhosis: beyond guidelines[J]. *J Hepatol*, 2021, 75:s135-s146. DOI:10.1016/j.jhep.2021.01.027.
- [21] Wang Z, Xiao Y, Peng L, et al. Artificial intelligence-based detection and assessment of ascites on CT scans[J]. *Expert Syst Appl*, 2023, 224:119979. DOI:10.1016/j.eswa.2023.119979.
- [22] 李芳菲, 张晓东, 卢子宁, 等. 基于结构磁共振的深度学习模型评估肝硬化及肝性脑病患者的脑龄改变[J]. *中华医学杂志*, 2024, 104(4):269-275. DOI:10.3760/cma.j.cn112137-20231011-00710.
- [23] 金秋, 杨婧, 马红琳, 等. 肝硬化合并骨质疏松症的危险因素, 发病机制及治疗进展[J]. *临床肝胆病杂志*, 2023, 39(4):929-935. DOI:10.3969/j.issn.1001-5256.2023.04.028.
- [24] Zhang B, Yu K, Ning Z, et al. Deep learning of lumbar spine X-ray for osteopenia and osteoporosis screening: a multicenter retrospective cohort study[J]. *Bone*, 2020, 140:115561. DOI:10.1016/j.bone.2020.115561.
- [25] Markus BH, Dickson ER, Grambsch PM, et al. Efficacy of liver transplantation in patients with primary biliary cirrhosis[J]. *New Engl J Med*, 1989, 320(26):1709-1713. DOI:10.1056/NEJM198906293202602.
- [26] Nitski O, Azhie A, Qazi-Arisar FA, et al. Long-term mortality risk stratification of liver transplant recipients: real-time application of deep learning algorithms on longitudinal data[J]. *Lancet Digit Health*, 2021, 3(5):e295-e305. DOI:10.1016/S2589-7500(21)00040-6.
- [27] Kavur AE, Gezer NS, Barış M, et al. Comparison of semi-automatic and deep learning-based automatic methods for liver segmentation in living liver transplant donors[J]. *Diagn Interv Radiol*, 2020, 26(1):11. DOI:10.5152/dir.2019.19025.
- [28] Tran J, Sharma D, Gotlieb N, et al. Application of machine learning in liver transplantation: a review[J]. *Hepatol Int*, 2022, 16(3):495-508. DOI:10.1007/s12072-021-10291-7.
- [29] Bhat M, Rabindranath M, Chara BS, et al. Artificial intelligence, machine learning, and deep learning in liver transplantation[J]. *J hepatol*, 2023, 78(6):1216-1233. DOI:10.1016/

- 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)