

• 综述 •

人工智能在原发性肝癌影像学的机遇和挑战

褚晓彤，付宇，郑爽，何刊，张惠茅

【摘要】 原发性肝癌是严重危害个体生命安全的恶性肿瘤之一,影像学在原发性肝癌的诊治过程中发挥着关键作用。精准医疗体系的建立和数字智能时代的到来,不仅加深了人们对肝癌的认识,也完善了肝癌的诊疗手段,人工智能技术在肝癌影像学领域的应用已被广为探索。本文着重对基于医学影像的人工智能在肝脏及肿瘤的分割、肝癌的诊断、组织学分级、微血管浸润(MVI)评估、预测术后复发和治疗后疗效方面的应用进行综述,并且对现有的挑战提出了看法,对未来的发展方向进行了展望。

【关键词】 肝;肝肿瘤;人工智能;影像组学;组织学分级;微血管浸润

【中图分类号】 R735.7;R814.42;R445.2 **【文献标识码】** A

【文章编号】 1000-0313(2024)09-1244-06

DOI:10.13609/j.cnki.1000-0313.2024.09.020

开放科学(资源服务)标识码(OSID):



根据世界卫生组织国际癌症研究署(world health organization international agency for research on cancer, WHO/IARC)对全球癌症的统计数据显示,肝癌发病率位居恶性肿瘤的第 6 位,病死率位居第 3 位^[1]。在我国,原发性肝癌是第 4 位常见恶性肿瘤及第 2 位肿瘤致死病因,严重威胁我国居民的生命安全^[2]。目前,我国肝癌 5 年生存率仅为 11.7%~14.1%^[3,4],降低肝癌根治性治疗后复发率、提高复发肝癌的早期诊断率是提高 5 年生存率的重要措施之一^[5]。影像学在原发性肝癌的监测、诊断、分期以及治疗后随访中起着关键作用,CT 及动态增强扫描常应用于肝癌的临床诊断及分期,多参数 MRI 在对直径≤2.0 cm 肝癌的检出和诊断,评估肝癌是否侵犯门静脉、肝静脉主干及其分支,以及腹腔或腹膜后间隙淋巴结转移方面具有优势^[2],但由于肝癌危险因素和发病机制的广泛异质性,现有的术前预测分级和预后手段仍然十分有限。随着数字化时代的到来,肝癌的诊断和治疗正在经历一场前所未有的生命科学革命,人工智能(artificial intelligence, AI)技术的快速发展在肝癌的个性化精准医疗方面发挥了重要作用。目前在医学影像学领域广泛应用的人工智能主要有两类,一类是传统的机器学习(machine learning, ML)算法,另一类是深度学习(deep learning, DL)算法。ML 使用数字技术来整合计算、优化和统计的原理,并专注于探索模拟人类的学习机制^[6]。DL 是一种使用具有多个非

线性处理单元的人工神经网络来学习数据的算法,主要使用深度神经网络(deep neural networks, DNN)进行模式识别^[7]。DL 专注于研究如何在大数据环境下有效利用信息,从海量数据中获取隐藏的、有效的、可理解的知识^[8,9]。近年来,许多研究证明了基于医学影像的人工智能在肝脏及肿瘤的分割、肝癌的诊断、组织学分级、微血管浸润(microvascular invasion, MVI)评估、预测术后复发和治疗后疗效等方面的应用价值。

肝脏及肿瘤分割

肝脏和肿瘤[包括肝细胞癌(hepatocellular carcinoma, HCC)和其他肝脏恶性肿瘤]的分割对于评估肿瘤负荷、检测早期复发、提取影像组学特征以及规划理想的治疗方案具有重要意义。目前,肝脏肿瘤的分割仍依赖于人工分割,然而在病灶较小或弥漫的情况下,手动分割肝脏和肿瘤不容易,其次人工分割具有主观性,重复性差,具有较高的观察者间差异性,并且耗时。基于传统图像处理算法的各种计算机辅助方法,如阈值法^[10]、空间正则化技术^[11]、监督分类和无监督聚类方法^[12]等已被提出用于肝脏和病变的分割。然而,由于肿瘤的形状、外观和定位的高度变异性,没有清晰可见的边缘,以及对比剂导致的额外噪声等,自动分割肝脏和肿瘤尚有难度。

近年来,深度学习的发展极大地促进了医学图像的分割,卷积神经网络已经成功地应用于多种脏器及肿瘤的分割^[13-15],在肝脏影像方面,深度学习在肝脏和肿瘤分割方面也取得了显著成就,有学者利用深度学习从腹部 CT 和 MRI 图像中实现了全自动的器官分割,该模型结合了级联卷积网络和对抗性网络,增强了深度学习模型自动描绘多个腹部器官的能力,并且该

作者单位:130024 长春,吉林大学第一医院放射科

作者简介:褚晓彤(1998—),女,河北邯郸人,硕士研究生,主要从事医学影像诊断工作。

通讯作者:何刊, E-mail: hekan@jlu.edu.cn; 张惠茅, E-mail: huimao@jlu.edu.cn

基金项目:吉林省科技发展计划项目基金(基金编号:2YDZJ202201ZYTS679);国家自然科学基金(基金编号:82202256)

模型在 2019 年联合健康腹部器官分割挑战赛 [combined (CT-MR) healthy abdominal organ segmentation, CHAOS] 中获得了 CT 和 MRI 图像分割肝脏方面的第 1 名^[16]。Perez 等^[17] 利用深度学习人工智能工具在 3065 例进行结直肠筛查 ($n=1960$) 或肾供体评估 ($n=1105$) 的患者 CT 图像中自动分割肝脏, 确立肝脏体积并建立了肝脏肿大的阈值, 得出该分割模型的 Dice 评分为 0.887 ± 0.006 , 提供了比线性测量更准确客观的肝脏体积评估手段。与整个肝脏的分割不同, 肝脏局灶性病变的分割长期以来一直是一个难题, 与肺部等其他器官不同, 背景肝脏和局灶性肝脏病变的图像之间对比度较低, 尽管对比剂的使用增加了图像对比度, 但检测肝癌病灶的结构仍然很困难^[18,19], 深度学习技术在肝脏肿瘤分割领域逐渐受到关注, 为自动分割肝脏肿瘤提供了新的可能。2017 年肝脏肿瘤分割挑战赛 (liver tumor segmentation challenge, LiTS) 中, 研究者开发基于 AI 的算法在 CT 图像上自动分割肝脏肿瘤, 采用 Dice 评分评估模型的分割准确度, 在这场比赛中评分前十的模型均使用卷积神经网络 (convolutional neural networks, CNN) 方法分割肝脏肿瘤, 其中效能最高的算法 Dice 评分为 0.830。近年来许多学者探索了新的改良算法自动分割肝脏肿瘤, Zhou 等^[20] 在 U-net 网络的 skip-connection 中添加了具有反卷积和激活操作的剩余路径提升了在 CT 图像中肝脏的分割精度, 在 LiTs 挑战赛的数据集中验证该模型, 得到其对肝脏肿瘤分割的 Dice 相似系数为 89.72%; 也有学者提出了一个基于残差块和扩张卷积的自动统一无配准的深度学习模型来训练端对端的肝脏病变分割模型, 在 LiTS 数据集中得到肝脏病灶的 Dice 评分为 86.7%^[21]; Zheng 等^[22] 建立了一种基于 3D 卷积和卷积长短期记忆 (c-lstm) 的 4 维 (4D) 深度学习模型, 在 MRI 增强图像对 HCC 病灶进行分割, 具体来说, 该研究设计了一种基于浅 U-net 的三维 CNN 模块用于提取增强图像各期的三维空间特征, 另外设计了一个 4 层 C-LSTM 网络模块, 用于提取增强各期的时域信息, 该模型分割肝脏肿瘤的 Dice 系数为 0.825 ± 0.077 。由此可见, 人工智能方法在对肝脏和肝脏肿瘤的分割中展现出了较好的效能, 但要将这些算法从工作台带到临床应用场景, 还需要对模型的准确性、精确度、速度进行更严格的评估及改进。

肝癌诊断及组织学分级

人工智能方法在肝癌诊断方面的研究多集中在对肝脏肿块的良恶性鉴别及肝癌的分级方面, 基于 CNN 的深度学习方法在图像的模式识别方面越来越受到关注。CNN 由卷积层、汇聚层、非线性层和完全连接层

等一系列层组成, 其中居于核心地位的卷积层对图像用不同的滤波器进行处理, 可以有效识别图像模式。相比需要在学习之前从图像中提取特征的传统机器学习方法, 卷积层的应用允许 CNN 在学习过程中使用图像本身, 从而使基于 CNN 的深度学习能够应用图像中包含的所有信息^[23]。Yasaka 等^[24] 建立了基于 CNN 的深度学习模型, 探究其在增强 CT 图像上区分肝脏肿块的效能, 将肝脏肿块分为五类: A 类为典型肝癌, B 类为非典型和早期肝癌, C 类为不确定肿块和肿块样病变, D 类为血管瘤, E 类为囊肿, 并在测试集 100 例患者中验证了模型性能, 结果显示该模型鉴别 A、B 类与 C-E 类肿块的 ROC 曲线下面积 (area under curve, AUC) 为 0.920, 诊断性能良好。有研究建立了基于 T₂WI、DWI 的影像组学模型对肝细胞癌与肝富血供良性病变进行鉴别, 发现与临床预测模型、影像组学模型相比, 该模型具有较高的诊断性能, 在训练集、测试集中的 AUC 分别为 0.988、0.955, 且该模型的诊断效能显著高于影像医师 (分别为 0.808 和 0.780)^[25]。另有学者研究了 CNN 模型在多时相 MRI 图像上对肝脏肿块的分类性能, 对 494 个常见六种肝脏病变 (囊肿、血管瘤、HCC、肝内胆管细胞癌、肝脏局灶性结节增生、结直肠癌转移灶) 进行分类, 该模型的诊断准确度、敏感度、特异度及 AUC 分别为 92%、92%、98% 及 0.992, 对每个病变的计算时间为 5.6 ms, 该模型的敏感度和特异度均高于影像医师 (分别为 82.5%、96.5%)^[26]。

相关临床研究表明肝癌预后较差, 易复发^[27], 一般而言, 病理分级越高的 HCC, 术后复发率越高, 患者生存期越短^[28], 因此准确预测肝癌的病理分级对于制定治疗策略至关重要。根据临床指南, 针吸活检是恶性肿瘤术前评估的常规方法, 但由于其存在并发症及样本错误的风险, 因此不建议用于诊断肝癌。在医学图像上评估肝癌分级对放射科医生来说也是一项具有挑战性的工作, 人工智能的出现为通过医学成像方法非侵入性地预测肝癌病理分级提供了新的思路。有学者回顾性地从 297 例肝癌患者的增强 CT 图像中提取影像组学特征以建立对肝癌病理分级的预测模型, 模型的 AUC 为 0.801, 该研究表明基于机器学习的增强 CT 影像组学分析可以提高预测模型的准确性, 并且可以非侵入性地探索 HCC 的图像与病理分级之间的潜在关联^[29], 但该研究仅利用了增强 CT 数据, 并未在多模态组学模型上探索。Zhou 等^[30] 将挤压-激励网络与三维密度链接卷积网络相结合, 开发了一种新的深度神经网络分析来自两个中心的增强 MRI 图像, 对肝癌进行分级, 得到该网络的精确度为 83%; Li 等^[31] 提出了一种基于深度学习架构的注意力引导的判别自

适应融合方法,在增强 MRI 图像中对肝癌进行分级,在 2D 图像(AUC=0.881)及 3D(AUC=0.927)图像上均获得良好效果,并且与其他已有研究相比,此模型效能最高。

评估肝癌微血管浸润

据报道,MVI 是肝癌治疗后 2 年内早期复发的主要风险因素^[32,33]。目前 MVI 大多通过术后的组织病理学进行诊断,这可能会影响术前制定合理的治疗方案。近期研究表明,某些成像方式在预测 MVI 方面具有很大的潜力。一些影像学特征,如非光滑肿瘤边缘、动脉期瘤周强化、肿瘤 MRI 低信号和肝胆期(hepatobiliary phase,HBP)图像上的瘤周低信号等,是 MVI 预测的非侵入性成像生物标志物^[34-38],然而这些定性特征由于观察者间的不可重复性和缺乏外部验证在预测 MVI 方面具有局限性。影像组学可以对图像进行高通量挖掘和定量分析。有学者将临床特征、影像特征和增强 CT 影像组学特征相结合,建立 MVI 的术前预测模型,在测试集中得到该模型的 AUC 值为 0.889^[39];Nebbia 等^[40]研究了利用多参数 MRI 影像组学来预测术前 MVI 状态,从 5 个 MRI 序列(T₁WI、T₂WI、DWI、动脉晚期和门静脉期图像)图像的肿瘤区域和瘤周区域提取影像组学特征,建立了单独序列与联合序列模型,比较他们对 MVI 的预测效能,单独应用时 T₂WI 的预测效能最好(AUC 为 0.810),结合使用时 T₂WI 和门静脉期结合效果最好(AUC 为 0.870)。有学者利用基于增强 MRI 影像组学方法对 MVI 进行术前预测,从增强 MRI 动脉期(arterial phase,AP)、门静脉期(portal venous phase,PVP)及延迟期(delay period,DP)图像提取特征,构建基于 AP、PVP、DP 及基于 3 期特征融合的影像组学模型和临床因素预测模型,得出增强 MRI 影像组学模型中 3 期联合模型与临床影像特征结合建立的临床影像组学模型的诊断效能最高,训练组与测试组 AUC 值分别为 0.934、0.911,表明基于增强 MRI 建立的临床影像组学模型能够在术前无创地评估和预测 MVI^[41]。另有研究利用 133 例肝癌患者的术前钆剂增强 MRI 图像建立了针对 MVI 预测的单任务和针对 MVI 和包裹肿瘤簇的血管(vessels encapsulating tumor clusters,VETC)同时预测的 3D CNN 深度学习模型,单独预测 MVI 的 3D CNN 模型的 AUC 为 0.896,同时预测 MVI 和 VETC 的多任务 3D CNN 模型的 AUC 值为 0.917,该研究发现此模型在评估 VETC 状态的同时可以提高 MVI 预测的性能,另外还发现这种联合预测可以对 HCC 患者的预后进行分层,并在根治性切除术前实现个性化预测^[42]。Xia 等^[43]从经病理证实的

肝癌患者的门脉期 CT 图像中提取了肝癌肿瘤和瘤周区域的影像学特征,与临床影像学特征相结合建立混合模型术前预测 MVI,结果显示模型在内部测试集和外部测试集的 AUC 分别为 0.860 和 0.840,该研究利用 TCIA 公开数据集中 35 例患者的 RNA 测序数据进行基因分析,发现 MVI 阳性患者的差异表达基因通常与糖代谢有关。

预测肝癌治疗后疗效和预后

在治疗前有效预测肝癌患者的治疗反应及预后对制定肝癌个体化治疗方案有重要意义,人工智能方法在术前预测肝癌的疗效方面具有巨大潜力。2018 年 Akai 等^[44]在 127 例患者的术前 CT 图像中提取影像组学特征对患者肝癌切除术后的总生存期进行了有效预测。有学者利用来自 3 家医疗机构的 789 例接受经动脉化疗栓塞术(transcatheter arterial chemoembolization,TACE)的肝癌患者的术前 CT 图像,训练并验证了在术前预测中晚期肝癌患者接受 TACE 后反应的深度学习模型,在训练集中该模型对完全反应(complete response,CR)、部分反应(partial response,PR)、稳定疾病(stable disease,SD)和进展疾病(progressive disease,PD)的预测准确率为 84.3%,AUC 分别为 0.970、0.960、0.950 和 0.960;在另外两个验证集中,深度学习模型对 CR、PR、SD 和 PD 的预测准确率分别为 85.1% 和 82.8%^[45]。另有研究探索了采用深度学习方法建立术前预测经 TACE 联合索拉菲尼治疗的肝癌患者的总生存期,研究者利用多中心的 201 例患者的术前 CT 图像的深度学习特征联合临床特征建模,得到患者的中位总生存期为 19.2 个月,模型的 C 指数在训练组和验证组分别为 0.717 和 0.714^[46]。有学者探究了 MRI 扩散加权成像联合外周血 CD4+/CD8+ 比值预测 CalliSpheres 载药微球栓塞介入治疗晚期肝癌疗效的价值,结果显示 ADC 值、外周血 CD4+/CD8+ 比值及两者联合预测治疗后疗效的 AUC 分别为 0.876、0.824 和 0.918^[47]。近年来,免疫治疗作为新兴热点广受关注,Chen 等^[48]从免疫治疗前钆塞酸增强 MRI 图像中提取影像组学特征,建立了瘤内影像组学模型、瘤周-瘤内影像组学模型、临床-影像组学联合模型等 3 种免疫评分预测模型,结果显示临床-影像组学联合模型的 AUC(0.926)高于其他两种模型(AUC 分别为 0.823、0.904)。另有学者运用机器学习方法构建模型,预测接受免疫治疗的晚期肝癌患者 1 年内的癌症相关死亡率,其 AUC 值达到了 0.920^[49]。

近年来,也有许多学者对采用影像组学和人工智能方法无创性地预测肝癌术后复发进行了探索。Kim

等^[50]研究了在肝癌切除术前预测患者术后的早期复发(≤2年)和晚期复发(>2年),从167例接受手术切除且经病理证实为肝癌的2~5cm单发病灶中提取MRI组学特征,利用随机生存森林方法建立影像组学模型、临床病理学模型和临床病理学-影像组学联合模型,结果显示临床病理学-影像组学模型的预测效能最高,对无病生存的预测精度达0.716。另有研究从来自双中心接受肝癌切除术的286例经病理证实为HCC的术前钆塞酸二钠(gadolinium ethoxybenzyl diethylenetriamine pentaacetic acid, Gd-EOB-DTPA)增强MRI图像中提取深度学习特征,结合临床特征和影像学特征建立了术前预测肝癌切除术后早期复发的深度学习列线图,其在训练集和验证集中的AUC分别为0.949、0.909,证明了基于深度学习的诺模图在肝癌术后早期复发预测和术后监测方面比传统的临床线图更有效^[51]。

由此可见,人工智能方法在预测不同肝癌疗法的疗效及预后方面均表现出良好的效果,可以帮助临床医生更好地对肝癌患者进行治疗的受益评估,有利于制定患者的个性化治疗方案。

现存挑战及未来展望

在肝癌的诊治过程中,影像手段发挥着不可替代的重要作用。人工智能和影像组学技术可以提高对原发性肝癌的诊断和鉴别诊断效能,帮助预测肝癌的分期、组织学分级、MVI、治疗反应和预后等,有望成为术前制定个性化治疗决策的有力工具,但目前仍然存在局限性和诸多挑战:首先,深度学习需要大量的高质量数据才能训练出准确的模型,现有研究的分割模型仅来自一个或者几个机构的数据,在新的数据上应用时可能遭受泛化问题,另外目前在MRI图像上进行肝脏肿瘤自动分割的研究相对较少,未来这一方面尚待学者们进一步探索;其次,目前对于肝脏肿瘤标注质量控制的共识较少,已有研究在肝脏局灶性病变的标注标准方面提出了初步指导意见,帮助构建鲁棒性好、泛化能力强的肝脏AI算法模型^[52],随着肝脏AI研究的不断深入,标注的标准也将进一步规范;最后,现有研究的训练集和测试集数据尺度不一,数据量普遍较小,并且大多数依赖回顾性数据建模,因此未来需要前瞻性大样本研究进行开发和验证。相信随着技术的进步和研究的进展,人工智能在肝癌的诊疗中必将发挥更加重要甚至不可替代的作用,从而促进精准医疗的进步。

参考文献:

- [1] Sung H, Ferlay J, Siegel RL, et al. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA Cancer J Clin, 2021, 71(3): 209-249.
- [2] Bureau of Medical Administration, National Health Commission of the People's Republic of China. Standardization for diagnosis and treatment of hepatocellular carcinoma (2022 edition)[J]. Zhonghua Gan Zang Bing Za Zhi, 2022, 30(4): 367-388.
- [3] Park JW, Chen M, Colombo M, et al. Global patterns of hepatocellular carcinoma management from diagnosis to death: the BRIDGE Study[J]. Liver Int, 2015, 35(9): 2155-2166.
- [4] Marrero JA, Kulik LM, Sirlin CB, et al. Diagnosis, staging, and management of hepatocellular carcinoma: 2018 practice guidance by the American association for the study of liver diseases[J]. Hepatology, 2018, 68(2): 723-750.
- [5] Chinese Society of Hepatology, Chinese Medical Association. The consensus on tertiary prevention of primary liver cancer (2022 version)[J]. Zhonghua Gan Zang Bing Za Zhi, 2022, 30(8): 832-845.
- [6] Saria S, Butte A, Sheikh A. Better medicine through machine learning: What's real, and what's artificial? [J]. PLoS Med, 2018, 15(12): e1002721.
- [7] Rehman A, Khan ma, Saba T, et al. Microscopic brain tumor detection and classification using 3D CNN and feature selection architecture[J]. Microsc Res Tech, 2021, 84(1): 133-149.
- [8] Khan MA, Ashraf I, Alhaisoni M, et al. Multimodal brain tumor classification using deep learning and robust feature selection: a machine learning application for radiologists[J]. Diagnostics (Basel), 2020, 10(8): 565.
- [9] Khan ma, Akram T, Zhang YD, et al. Attributes based skin lesion detection and recognition: A mask RCNN and transfer learning-based deep learning framework[J]. Pattern Recogn Lett, 2021, 143: 58-66.
- [10] Nader H, Mohiy M, Khalid M, et al. Fully automatic liver tumor segmentation from abdominal CT scans[C]. The 2010 International Conference on Computer Engineering & Systems, 2010: 197-202.
- [11] Hoogi A, Subramaniam A, Veerapaneni R, et al. Adaptive estimation of active contour parameters using convolutional neural Networks and texture analysis[J]. IEEE Trans Med Imaging, 2017, 36(3): 781-791.
- [12] Conze PH, Noblet V, Rousseau F, et al. Scale-adaptive supervoxel-based random forests for liver tumor segmentation in dynamic contrast-enhanced CT scans[J]. Int J Comput Assist Radiol Surg, 2017, 12(2): 223-233.
- [13] Havaei M, Davy A, Warde-Farley D, et al. Brain tumor segmentation with Deep Neural Networks[J]. Med Image Anal, 2017, 35(1): 18-31.
- [14] Chen Y, Feng L, Zheng C, et al. LDANet: Automatic lung parenchyma segmentation from CT images[J]. Comput Biol Med, 2023, 155: 106659.
- [15] Bhattacharjee A, Murugan R, Goel T, et al. Pulmonary nodule segmentation framework based on fine-tuned and pretrained deep neural Network using CT images[J]. IEEE Trans Radiat Plasma Med Sci, 2023, 7(4): 394-409.
- [16] Conze PH, Kavur AE, Corne Le Gall E, et al. Abdominal multi-organ segmentation with cascaded convolutional and adversarial

- deep networks[J].*Artif Intell Med*, 2021, 117: 102109.
- [17] Perez AA, Noe-Kim V, Lubner MG, et al. Deep learning CT-based quantitative visualization tool for liver volume estimation: defining normal and hepatomegaly[J].*Radiology*, 2022, 302(2): 336-342.
- [18] Gul S, Khan MS, Bibi A, et al. Deep learning techniques for liver and liver tumor segmentation: A review[J].*Comput Biol Med*, 2022, 147: 105620.
- [19] Yamada A, Kamagata K, Hirata K, et al. Clinical applications of artificial intelligence in liver imaging[J].*Radiol Med*, 2023, 128(6): 655-667.
- [20] Zhou Z, Siddiquee MMR, 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.
- [21] Khan RA, Luo Y, Wu FX. RMS-UNet: residual multi-scale UNet for liver and lesion segmentation[J].*Artif Intell Med*, 2022, 124: 102231.
- [22] Zheng R, Wang Q, Lv S, et al. Automatic liver tumor segmentation on dynamic contrast enhanced MRI using 4D information: deep learning model based on 3D convolution and convolutional LSTM[J].*IEEE Trans Med Imaging*, 2022, 41(10): 2965-2976.
- [23] Soffer S, Ben-Cohen A, Shimon O, et al. Convolutional neural Networks for radiologic images: a Radiologist's guide[J].*Radiology*, 2019, 290(3): 590-606.
- [24] Yasaka K, Akai H, Abe O, et al. Deep learning with convolutional neural Network for differentiation of liver masses at dynamic contrast-enhanced CT: a preliminary study[J].*Radiology*, 2018, 286(3): 887-896.
- [25] 杨晨, 朱帆东, 夏阳, 等. MRI 多模态影像组学鉴别肝细胞肝癌与肝富血供良性病变的应用价值[J]. 放射学实践, 2023, 38(5): 581-586.
- [26] Hamm CA, Wang CJ, Savic LJ, et al. Deep learning for liver tumor diagnosis part I: development of a convolutional neural network classifier for multi-phasic MRI[J].*Eur Radiol*, 2019, 29(7): 3338-3347.
- [27] Wang YY, Zhong JH, Su ZY, et al. Albumin-bilirubin versus Child-Pugh score as a predictor of outcome after liver resection for hepatocellular carcinoma[J].*Br J Surg*, 2016, 103(6): 725-734.
- [28] Haratake J, Takeda S, Kasai T, et al. Predictable factors for estimating prognosis of patients after resection of hepatocellular carcinoma[J].*Cancer*, 1993, 72(4): 1178-1183.
- [29] Mao B, Zhang L, Ning P, et al. Preoperative prediction for pathological grade of hepatocellular carcinoma via machine learning-based radiomics[J].*Eur Radiol*, 2020, 30(12): 6924-6932.
- [30] Zhou Q, Zhou Z, Chen C, et al. Grading of hepatocellular carcinoma using 3D SE-DenseNet in dynamic enhanced MR images[J].*Comput Biol Med*, 2019, 107: 47-57.
- [31] Li S, Xie Y, Wang G, et al. Attention guided discriminative feature learning and adaptive fusion for grading hepatocellular carcinoma with Contrast-enhanced MR [J].*Comput Med Imaging Graph*, 2022, 97: 102050.
- [32] Imamura H, Matsuyama Y, Tanaka E, et al. Risk factors contributing to early and late phase intrahepatic recurrence of hepatocellular carcinoma after hepatectomy[J].*J Hepatol*, 2003, 38(2): 200-207.
- [33] Cucchetti A, Piscaglia F, Caturelli E, et al. Comparison of recurrence of hepatocellular carcinoma after resection in patients with cirrhosis to its occurrence in a surveilled cirrhotic population[J].*Ann Surg Oncol*, 2009, 16(2): 413-422.
- [34] Renzulli M, Brocchi S, Cucchetti A, et al. Can current preoperative imaging be used to detect microvascular invasion of hepatocellular carcinoma? [J].*Radiology*, 2016, 279(2): 432-442.
- [35] Lee S, Kim SH, Lee JE, et al. Preoperative gadoxetic acid-enhanced MRI for predicting microvascular invasion in patients with single hepatocellular carcinoma[J].*J Hepatol*, 2017, 67(3): 526-534.
- [36] Ahn SY, Lee JM, Joo I, et al. Prediction of microvascular invasion of hepatocellular carcinoma using gadoxetic acid-enhanced MR and ¹⁸F-FDG PET/CT [J].*Abdom Imaging*, 2015, 40(4): 843-851.
- [37] Kim JY, Kim MJ, Kim KA, et al. Hyperintense HCC on hepatobiliary phase images of gadoxetic acid-enhanced MRI: correlation with clinical and pathological features[J].*Eur J Radiol*, 2012, 81(12): 3877-3882.
- [38] Kim KA, Kim MJ, Jeon HM, et al. Prediction of microvascular invasion of hepatocellular carcinoma: usefulness of peritumoral hypointensity seen on gadoxetate disodium-enhanced hepatobiliary phase images[J].*J Magn Reson Imaging*, 2012, 35(3): 629-634.
- [39] Xu X, Zhang HL, Liu QP, et al. Radiomic analysis of contrast-enhanced CT predicts microvascular invasion and outcome in hepatocellular carcinoma[J].*J Hepatol*, 2019, 70(6): 1133-1144.
- [40] Nebbia G, Zhang Q, Arefan D, et al. Pre-operative microvascular invasion prediction using multi-parametric liver MRI radiomics [J].*J Digit Imaging*, 2020, 33(6): 1376-1386.
- [41] 黄京城, 刘金韵, 胡景卉, 等. 增强 MRI 影像组学对肝癌微血管侵犯的预测价值[J]. 放射学实践, 2022, 37(10): 1243-1248.
- [42] Chu T, Zhao C, Zhang J, et al. Application of a convolutional neural Network for multitask learning to simultaneously predict microvascular invasion and vessels that encapsulate tumor clusters in hepatocellular carcinoma[J].*Ann Surg Oncol*, 2022, 29(11): 6774-6783.
- [43] Xia TY, Zhou ZH, Meng XP, et al. Predicting microvascular invasion in hepatocellular carcinoma using CT-based radiomics model [J].*Radiology*, 2023, 307(4): e222729.
- [44] Akai H, Yasaka K, Kunimatsu A, et al. Predicting prognosis of resected hepatocellular carcinoma by radiomics analysis with random survival forest[J].*Diagn Interv Imaging*, 2018, 99(10): 643-651.
- [45] Peng J, Kang S, Ning Z, et al. Residual convolutional neural network for predicting response of transarterial chemoembolization in hepatocellular carcinoma from CT imaging[J].*Eur Radiol*, 2020, 30(1): 413-424.
- [46] Zhang L, Xia W, Yan ZP, et al. Deep learning predicts overall survival of patients with unresectable hepatocellular carcinoma treated by transarterial chemoembolization plus sorafenib[J].*Front Oncol*, 2020, 10: 593292.
- [47] 蔡争, 宋建涛, 甄文瑞, 等. MRI 扩散加权成像联合外周血 CD4+ /CD8+ 比值预测 GalliSpheres 载药微球栓塞介入治疗晚期肝

- 癌疗效的价值[J].放射学实践,2023,30(1):84-88.
- [48] Chen S, Feng S, Wei J, et al. Pretreatment prediction of immuno-score in hepatocellular cancer: a radiomics-based clinical model based on Gd-EOB-DTPA-enhanced MRI imaging[J]. Eur Radiol, 2019, 29(8):4177-4187.
- [49] Lui TKL, Cheung KS, Leung WK. Machine learning models in the prediction of 1-year mortality in patients with advanced hepatocellular cancer on immunotherapy: a proof-of-concept study [J]. Hepatol Int, 2022, 16(4):879-891.
- [50] Kim S, Shin J, Kim DY, et al. Radiomics on gadoxetic acid-enhanced magnetic resonance imaging for prediction of postopera-

- tive early and late recurrence of single hepatocellular carcinoma [J]. Clin Cancer Res, 2019, 25(13):3847-3855.
- [51] Yan M, Zhang X, Zhang B, et al. Deep learning nomogram based on Gd-EOB-DTPA MRI for predicting early recurrence in hepatocellular carcinoma after hepatectomy[J]. Eur Radiol, 2023, 33(7):4949-4961.
- [52] 中华医学会放射学分会医学影像大数据与人工智能工作委员会,中华医学会放射学分会,腹部学组,中华医学会放射学分会磁共振学组.肝脏局灶性病变 CT 和 MRI 标注专家共识(2020)[J].中华放射学杂志,2020,54(12):1145-1152.

(收稿日期:2023-05-19 修回日期:2023-09-08)

本刊可直接使用的医学缩略语

医学论文中正确、合理使用专业名词可以精简文字,节省篇幅,使文章精炼易懂。现将放射学专业领域为大家所熟知的专业名词缩略语公布如下(按照英文首字母顺序排列),以后本刊在论文中将对这一类缩略语不再注释其英文全称和中文。

- ADC (apparent diffusion coefficient): 表观扩散系数
 ALT:丙氨酸转氨酶;AST:天冬氨酸转氨酶
 BF (blood flow): 血流量
 BOLD (blood oxygenation level dependent): 血氧水平依赖
 BV (blood volume): 血容量
 b: 扩散梯度因子
 CAG (coronary angiography): 冠状动脉造影
 CPR (curve planar reformation): 曲面重组
 CR(computed radiography): 计算机 X 线摄影术
 CT (computed tomography): 计算机体层成像
 CTA (computed tomography angiography): CT 血管成像
 CTPI(CT perfusion imaging): CT 灌注成像
 DICOM (digital imaging and communication in medicine): 医学数字成像和传输
 DR(digital radiography): 数字化 X 线摄影术
 DSA (digital subtraction angiography): 数字减影血管造影
 DWI (diffusion weighted imaging): 扩散加权成像
 DTI (diffusion tensor imaging): 扩散张量成像
 ECG (electrocardiography): 心电图
 EPI (echo planar imaging): 回波平面成像
 ERCP (endoscopic retrograde cholangiopancreatography): 经内镜逆行胰胆管造影术
 ETL (echo train length): 回波链长度
 FLAIR (fluid attenuation inversion recovery): 液体衰减反转恢复
 FLASH (fast low angle shot): 快速小角度激发
 FOV (field of view): 视野
 FSE (fast spin echo): 快速自旋回波
 fMRI (functional magnetic resonance imaging): 功能磁共振成像
 IR (inversion recovery): 反转恢复
 Gd-DTPA:钆喷替酸葡甲胺
 GRE (gradient echo): 梯度回波
 HE 染色:苏木素-伊红染色
 HRCT(high resolution CT): 高分辨率 CT
 MPR (multi-planar reformation): 多平面重组

- MIP (maximum intensity projection): 最大密(强)度投影
 MinIP (minimum intensity projection): 最小密(强)度投影
 MRA (magnetic resonance angiography): 磁共振血管成像
 MRI (magnetic resonance imaging): 磁共振成像
 MRS (magnetic resonance spectroscopy): 磁共振波谱学
 MRCP(magnetic resonance cholangiopancreatography): 磁共振胆管成像
 MSCT (multi-slice spiral CT): 多层螺旋 CT
 MTT (mean transit time): 平均通过时间
 NEX (number of excitation): 激励次数
 PACS (picture archiving and communication system): 图像存储与传输系统
 PC (phase contrast): 相位对比法
 PET (positron emission tomography): 正电子发射计算机体层成像
 PS (surface permeability): 表面通透性
 ROC 曲线(receiver operating characteristic curve): 受试者操作特征曲线
 SPECT (single photon emission computed tomography): 单光子发射计算机体层摄影术
 PWI (perfusion weighted imaging): 灌注加权成像
 ROI (region of interest): 兴趣区
 SE (spin echo): 自旋回波
 STIR(short time inversion recovery): 短时反转恢复
 TACE(transcatheter arterial chemoembolization): 经导管动脉化疗栓塞术
 T₁WI (T₁ weighted image): T₁ 加权像
 T₂WI (T₂ weighted image): T₂ 加权像
 TE (time of echo): 回波时间
 TI (time of inversion): 反转时间
 TR (time of repetition): 重复时间
 TOF (time of flight): 时间飞跃法
 TSE (turbo spin echo): 快速自旋回波
 VR (volume rendering): 容积再现
 WHO (World Health Organization): 世界卫生组织
 NAA(N-acetylaspartate): N-乙酰天门冬氨酸
 Cho(choline): 胆碱
 Cr(creatinine): 肌酸

(本刊编辑部)