

· 专家论坛 ·

DOI: 10.12449/JCH251103

人工智能在代谢相关脂肪性肝病中的应用

孙超, 范建高

上海交通大学医学院附属新华医院消化内科, 上海 200092

通信作者: 范建高, fanjiangao@xinhumed.com.cn (ORCID: 0000-0001-7443-5056)

摘要: 随着肥胖和代谢综合征的流行,代谢相关脂肪性肝病(MAFLD)已成为我国乃至全球最常见的慢性肝病。传统的诊断和监测方法依赖于肝活检、影像学 and 血清学标志物,但存在侵入性、成本高和灵敏度不足等局限性。近年来,人工智能(AI)技术在医学领域的快速发展为MAFLD的诊疗提供了新思路。本文探讨了AI技术在MAFLD疾病诊断模型、疾病进展预测和数字治疗等领域的应用,旨在为MAFLD的诊断和管理提供借鉴。

关键词: 代谢相关脂肪性肝病; 人工智能; 诊断; 治疗学

基金项目: 国家科技重大专项-四大慢病重大专项(2023ZD0508700, 2023ZD0508704); 上海交通大学医学院附属新华医院“学科攀峰计划”建设项目(XKPF2024B400, XKPF2024B401)

Application of artificial intelligence in metabolic associated fatty liver disease

SUN Chao, FAN Jianguo

Department of Gastroenterology, Xinhua Hospital Affiliated to Shanghai Jiao Tong University School of Medicine, Shanghai 200092, China

Corresponding author: FAN Jianguo, fanjiangao@xinhumed.com.cn (ORCID: 0000-0001-7443-5056)

Abstract: With the prevalence of obesity and metabolic syndrome, metabolic associated fatty liver disease (MAFLD) has become one of the most common chronic liver diseases in China and globally. Traditional diagnostic and monitoring methods rely on liver biopsy, imaging techniques, and serological markers, and their application is limited by invasiveness, high costs, and insufficient sensitivity. In recent years, the rapid development of artificial intelligence (AI) technology in the medical field has provided new ideas for the diagnosis and treatment of MAFLD. This article explores the application of AI technology in areas such as models for the diagnosis of MAFLD, the prediction of disease progression, and digital therapeutics, in order to provide a reference for the diagnosis and management of MAFLD.

Key words: Metabolic Associated Fatty Liver Disease; Artificial Intelligence; Diagnosis; Therapeutics

Research funding: Noncommunicable Chronic Diseases-National Science and Technology Major Project (2023ZD0508700, 2023ZD0508704); The Construction Project of the “Discipline Peak-Climbing Plan” of Xinhua Hospital Affiliated to Shanghai Jiao Tong University School of Medicine(XKPF2024B400, XKPF2024B401)

代谢相关脂肪性肝病(metabolic associated fatty liver disease, MAFLD)是一种常见的慢性进展性肝病,其发病率逐年攀升^[1-2]。MAFLD疾病谱表现为从单纯性脂肪肝到代谢相关脂肪性肝炎(metabolic associated steatohepatitis, MASH)的连续进展过程,晚期可能发展

为肝纤维化、肝硬化甚至肝细胞癌^[3]。在临床实践中,医生需综合来自多源数据的定性和定量信息,明确诊断、预测疾病进展并制订治疗方案。近年来,人工智能(artificial intelligence, AI)技术的发展实现了从复杂多样的临床数据集中提取相关信息,特别是影像学 and 病理学

图像数据,包含诊断、预后和预测信息,AI可以准确提取这些有效信息,作为决策支持工具应用于临床实践^[4]。

1 MAFLD临床诊疗现状和面临挑战

MAFLD是一种高度异质性的疾病,其临床表现、病理特征、疾病进展速度和治疗反应存在显著差异。这种异质性源于多种因素的交互作用,包括代谢异常、遗传背景、环境因素及肠道微生态等,导致其诊断和治疗复杂性和多样化^[5]。MAFLD的临床演变过程复杂,涉及肝脂肪变、炎症和肝纤维化等多个阶段,准确鉴别不同病理改变对于判断患者的管理和预后至关重要。目前,MASH诊断的金标准仍然是肝组织学评价,且其临床药物研发也依赖肝组织学分析筛选试验对象和评估疗效,但该评价方式受样本异质性、阅片者间差异以及序数评分系统等问题制约^[6]。影像学检查如超声、CT和MRI可以评估肝脂肪变和肝硬化,但存在无法准确诊断肝纤维化和成本较高等问题。肝纤维化4因子指数(fibrosis-4, FIB-4)、非酒精性脂肪性肝病纤维化评分(non-alcoholic fatty liver disease fibrosis score, NFS)等血清学标志物,虽可用于无创评估,但对疾病程度的评估有时存在不一致性,且对预后判断的灵敏度和特异度仍有待提高^[7]。

在治疗方面,MASH的有效干预和新药研发虽有突破,但远未满足临床需求,改变生活方式以减重仍是改善MASH和肝纤维化的重要举措^[8]。然而,MAFLD患者和非肝病专科医生对该病的危害及防治措施缺乏足够认知,且传统的生活方式干预依赖于患者定期到医院接受医生面对面的指导,医生对患者的管理缺乏延续性和有效实时监督,导致患者执行力差,减重效果不佳。因而,迫切需要更为高效智能的管理方法以提高生活方式干预的有效性。

近年来,AI赋予计算机从复杂数据中学习并解决现实世界问题的能力,不仅能复现并自动化人类专家的数据解读过程,也可以从复杂数据中提取人眼难以察觉的细微特征。AI在MAFLD医学影像分析、数字病理、疾病进展预测和临床干预方面展现出巨大潜力,为该病的早期筛查、精准诊断、风险评估和个体化治疗提供了新思路。

2 AI技术在MAFLD中的应用探索

2.1 疾病筛查和发病风险预测 AI在MAFLD高危人群筛查方面表现出一定优势。一项来自中国西北地区、大规模、多民族人群体检数据研究,纳入5 171 392例参

与者,通过LASSO回归模型筛选出20多个变量,经各算法参数优化后,CatBoost算法表现出最佳性能,其受试者操作特征曲线下面积(area under curve, AUC)达0.862;年龄、体质量指数、甘油三酯、空腹血糖、腰围、职业、高密度脂蛋白胆固醇、低密度脂蛋白胆固醇、总胆固醇、收缩压、舒张压、民族和心血管疾病是MAFLD高危人群筛查的前13位关键因素^[9]。

来自宁波的一项研究招募6 196例非MAFLD健康体检者,采用逻辑回归、决策树、支持向量机、随机森林、类别提升和极端梯度提升(extreme gradient Boosting, XGBoost)6种机器学习算法构建5年MAFLD风险模型。结果显示,基于11个因子构建的风险模型在训练集中预测性能最佳,AUC为0.81;研究人群5年MAFLD发病率为18.64%^[10]。此模型有助于预测5年内MAFLD高发风险人群,从而予以积极干预并减少肝脏不良预后事件的发生。

2.2 疾病诊断模型 AI在MAFLD的影像学诊断中展现了显著的优势,能够通过机器学习和深度学习算法分析超声、CT和MRI等影像数据,有效提高肝脂肪变、炎症和肝纤维化的诊断效能。当前,超声影像检查仍然是MAFLD患者最常用的初筛工具。一项加拿大大学者开展的AI应用于超声影像诊断的研究,招募了MAFLD、慢性乙型/丙型肝炎和自身免疫性肝炎患者,记录了超声弹性成像测量值、同调K分布参数图和总衰减系数斜率,采用随机森林分类和自助法筛选具有最佳诊断效能的参数组合。结果显示,与单纯剪切波弹性成像相比,定量超声联合弹性成像随机森林模型在肝脂肪变分级、炎症分级和纤维化分级中具有更高的诊断准确性^[11]。一项涵盖49项不同AI方法在超声图像诊断和量化MAFLD研究的荟萃分析显示,AI可显著提升MAFLD、MASH及肝纤维化的诊断效能,基于准确度、灵敏度和特异度等性能指标,对不同模态的图像采集、特征提取与选择、数据管理及分类器进行了评估比较^[12]。因此,AI辅助系统在MAFLD不同病理分期的检测与量化方面显示出良好的应用前景。

在CT诊断方面,美国学者基于三维卷积神经网络的全自动肝体积分割算法,对健康成人CT平扫和增强序列进行分析。研究发现,较平扫CT而言,增强CT肝脏衰减预测质子密度脂肪分数(proton density fat fraction, PDFF)5%、10%和15%阈值的AUC分别为0.669、0.854和0.962,肝脾衰减差值预测的AUC分别为0.662、0.866和0.986,且对中度脂肪变诊断准确性优于轻度脂肪变^[13]。

在肝纤维化诊断方面,有学者利用病理证实肝纤维化患者门静脉期CT图像数据集,建立肝纤维化分期的深度学习系统,该系统对显著肝纤维化、进展期肝纤维化及肝硬化分期识别的准确率为79.4%,显著优于放射科医师判读、天冬氨酸氨基转移酶/血小板比值指数(APRI)及FIB-4指数^[14]。同样,基于MRI检查,采用深度卷积神经网络模型训练获得的肝纤维化评分与肝纤维化分期呈显著相关性,提示该模型在肝纤维化分期中展现出较高的诊断效能^[15]。

在数字病理领域,全切片成像技术是典型代表,即通过机器人扫描和高分辨率数字重建,生成染色/未染色病理切片的虚拟图像,支持病理图像的在线共享、数字存储及远程医疗整合^[16-17]。另一创新是无染色成像技术,采用二次谐波/双光子激发荧光原理消除染色变异干扰,实现对细微结构的精准解析^[18]。新加坡中央医院和北京大学人民医院针对非酒精性脂肪性肝炎(non-alcoholic steatohepatitis, NASH)成人患者肝组织样本,采用改进版肝纤维化定量(qFibrosis)算法,通过新增门管区评估模块增强门静脉周围纤维化检测能力,在不同专家共同复核后更改分期的肝纤维化1期(fibrosis stage 1, F1)与F2病例中,28项参数呈现显著差异。进一步在确诊病例中验证发现,其中26项在区分F1和F2中存在显著差异。因此,通过改进版qFibrosis算法整合的26项新型参数对NASH的F1和F2具有良好区分能力^[19]。肝静脉压力梯度(hepatic venous pressure gradient, HVPG)是评估门静脉压力的金标准。有学者利用三色染色活检样本开发了可识别NASH伴代偿期肝硬化患者HVPG的机器学习模型,该模型评分与HVPG的相关性显著强于肝胶原形态计量结果;在判别临床显著门静脉高压方

面,训练集和测试集的AUC分别为0.85和0.76,其动态变化可预测临床事件的发生^[20]。AI辅助的数字病理分析在肝纤维化分期中的诊断效能显著优于传统评分系统,有望推动药物研发的成功率^[3]。此外,数字化病理图像能使无症状患者直观理解肝脏病变,提升生活方式干预和治疗的依从性^[21]。

2.3 疾病进展预测 AI可通过机器学习算法分析多因素数据,预测MAFLD的进展风险(图1)。MASH作为MAFLD的炎症进展阶段,是肝纤维化加速的“启动器”,也是临床试验药物干预的核心病理。在MASH风险预测方面,基于2017—2020年美国国家健康与营养调查数据,研究者针对5000余例具有肝弹性成像检测结果的受试者,开发了基于XGBoost算法的机器学习模型用于检测高风险MASH人群。研究显示,高风险MASH患病率为6.9%,XGBoost模型展现出优异的识别效能,灵敏度为82%,特异度为91%;且相较于FIB-4、APRI和NFS评分,该模型预测优势显著。通过模型解释性分析发现,丙氨酸氨基转移酶、 γ -谷氨酰转肽酶、血小板、腰围和年龄为高风险MASH的五大关键预测因子^[22]。在临床试验中,AI通过一些非侵入性数据(临床数据、血液学参数或影像学数据),可精确预测潜在的高危MASH人群,有效锁定最可能符合入组标准的患者,从而显著提高受试者筛选效率^[23]。

肝纤维化的严重程度直接影响MAFLD患者的临床结局,早期识别肝纤维化对改善MAFLD患者的长期预后至关重要。美国学者采用逻辑回归、随机森林和神经网络等机器学习模型,利用MAFLD患者的17项人口统计学和临床特征预测肝纤维化组织学分期。研究结果显示,对于 \geq F2、 \geq F3、F4级肝纤维化以及 \geq F2的NASH,所有机器



图1 AI对MASH和肝纤维化进展风险预测

Figure 1 AI predicts the risk of MASH and liver fibrosis progression

学习模型预测准确率均高于FibroScan、FIB-4、肝脏弹性检测-天门冬氨酸氨基转移酶评分(FAST)和NFS;且模型在“不确定区间”的占比均低于或等同于FIB-4和NFS^[24]。基于AI的无创诊断技术有望进一步提高肝纤维化风险评估的精准性,从而避免不必要的肝活检。

2.4 生活方式干预与管理 鉴于MAFLD疾病的异质性,结合患者生活行为习惯和代谢特征进行个体化的治疗是临床管理的核心。近年来,AI在MAFLD的生活方式干预中也进行了探索尝试,并取得良好的成效。AI数字疗法通过软件程序驱动,不受时空限制,为患者提供精准、规范的个体化治疗干预措施,帮助患者进行饮食和运动管理^[25-26]。美国一项招募成年MAFLD患者参与、为期6个月的移动技术干预项目,每周为MAFLD患者量身定制目标步数和营养评估,建议患者地中海饮食或碳水化合物控制饮食。干预6个月后,约50%的患者体质量减轻,甘油三酯和肝硬度水平下降;75%的患者脂肪肝变减轻,身体功能得到改善^[27]。以上证据表明,AI数字疗法可以在短时间内实现有效减重、改善代谢和脂肪肝变。

日本学者通过手机APP对19例肝活检证实的NASH患者给予生活方式干预,医生根据患者年龄、性别、饮食和运动习惯,通过内部算法为每位患者制定个性化干预方案。1年后的随访结果显示,68.4%的患者NAFLD活动度评分(NAFLD activity score, NAS)有所改善,其中,57.9%的患者NAS评分降低 ≥ 2 分的;对于F2/F3期患者,58.3%的患者肝纤维化分期降低^[28]。此研究证实APP干预生活方式可以有效改善NASH患者组织学NAS评分和肝纤维化程度。

韩国一项研究通过手机APP对102例MAFLD患者给予生活方式干预,APP根据患者饮食、运动、饮酒和睡眠等情况的调研,为患者提供肝病饮食方案和锻炼视频,每月评估患者执行情况并改进干预方案。6个月后的随访发现,干预组患者体质量、转氨酶和脂肪肝评分显著下降。生活质量调研显示,患者的疲劳、抑郁倾向均明显好转,自我管理能力提升,生活质量改善^[29]。

笔者团队近期也开展了一项基于微信小程序的干预研究,对超重和肥胖MAFLD人群饮食和运动进行干预,6个月后发现,干预组60%的患者体质量减轻超过5%,24.4%的患者体质量减轻超过10%,减重效果显著优于对照组。更重要的是,干预组57.8%的患者FibroScan受控衰减参数降低 $\geq 10\%$ 或正常化,且肝功能和甘油三酯、糖化血红蛋白等指标明显改善。研究表明,数字治疗通过行为干预可有效管理MAFLD。

3 AI在MAFLD应用中存在的问题

3.1 数据方面 尽管AI具备强大的数据处理功能,但因不同医院采集的影像数据格式、参数不统一,可能会导致AI模型训练效果不佳,诊断的准确率波动大。建立多方协作的数据共享机制,实现数据的标准化和质量控制,是未来发展的重要方向。此外,数据隐私和安全风险也是制约AI技术应用推广的主要障碍。未来需要制定严格的数据保护政策,确保患者数据的安全性和隐私性。

3.2 技术方面 由于AI算法的复杂性较高,医生难以理解模型做出预测的依据,这在一定程度上影响了临床医生对AI的信任度。开发解释性更强的AI算法,提高模型的透明度和可解释性,是AI在医疗领域应用的关键。同时,提高模型的泛化能力,使其在不同医疗场景中均能保持较高的诊断准确性,也是未来发展的重要方向。

3.3 临床监管方面 部分医生由于长期依赖传统的诊疗方式,对AI辅助诊断的结果持怀疑态度。因此,通过临床验证和教育培训提高医生对AI技术的信任度和接受度,也是AI在临床应用中的重要环节。此外,未来需进一步完善医疗AI监管政策,将有利于推广临床应用。

4 小结与展望

AI是MAFLD从工具到诊疗范式的变革,是MAFLD全程管理的加速器。未来,AI在MAFLD管理中的应用将进一步拓展。基于多模态数据训练的AI模型和更具解释性的AI算法开发,将提高AI在MAFLD管理中的诊断和治疗效能。AI与精准医疗的深度融合,以及在基层医疗中的普及应用,将推动MAFLD管理的个性化和普及化。此外,多方协作的数据共享机制和完善的政策支持,将为AI在MAFLD管理中的应用提供坚实的保障。

利益冲突声明: 本文不存在任何利益冲突。

作者贡献声明: 孙超负责查阅文献,撰写论文;范建高负责修改文章并最后定稿。

参考文献:

- [1] ZHAO J, LIU L, CAO YY, et al. MAFLD as part of systemic metabolic dysregulation[J]. *Hepatol Int*, 2024, 18(Suppl 2): 834-847. DOI: 10.1007/s12072-024-10660-y.
- [2] LOU TW, YANG RX, FAN JG. The global burden of fatty liver disease: The major impact of China[J]. *Hepatobiliary Surg Nutr*, 2024, 13(1): 119-123. DOI: 10.21037/hbsn-23-556.
- [3] YOUNOSSI ZM, KALLIGEROS M, HENRY L. Epidemiology of metabolic dysfunction-associated steatotic liver disease[J]. *Clin Mol Hepatol*, 2025, 31(Suppl): S32-S50. DOI: 10.3350/cmh.2024.0431.
- [4] NAM D, CHAPIRO J, PARADIS V, et al. Artificial intelligence in liver dis-

- eases: Improving diagnostics, prognostics and response prediction[J]. *JHEP Rep*, 2022, 4(4): 100443. DOI: 10.1016/j.jhepr.2022.100443.
- [5] CADDEO A, ROMEO S. Precision medicine and nucleotide-based therapeutics to treat steatotic liver disease[J]. *Clin Mol Hepatol*, 2025, 31(Suppl): S76-S93. DOI: 10.3350/cmh.2024.0438.
- [6] RATZIU V, FRIEDMAN SL. Why do so many nonalcoholic steatohepatitis trials fail?[J]. *Gastroenterology*, 2023, 165(1): 5-10. DOI: 10.1053/j.gastro.2020.05.046.
- [7] ABDELHAMEED F, KITE C, LAGOJDA L, et al. Non-invasive scores and serum biomarkers for fatty liver in the era of metabolic dysfunction-associated steatotic liver disease (MASLD): A comprehensive review from NAFLD to MAFLD and MASLD[J]. *Curr Obes Rep*, 2024, 13(3): 510-531. DOI: 10.1007/s13679-024-00574-z.
- [8] MIAO L, TARGHER G, BYRNE CD, et al. Current status and future trends of the global burden of MASLD[J]. *Trends Endocrinol Metab*, 2024, 35(8): 697-707. DOI: 10.1016/j.tem.2024.02.007.
- [9] DENG JL, JI WD, LIU HZ, et al. Development and validation of a machine learning-based framework for assessing metabolic-associated fatty liver disease risk[J]. *BMC Public Health*, 2024, 24(1): 2545. DOI: 10.1186/s12889-024-19882-z.
- [10] HUANG GQ, JIN QK, MAO YS. Predicting the 5-year risk of nonalcoholic fatty liver disease using machine learning models: Prospective cohort study[J]. *J Med Internet Res*, 2023, 25: e46891. DOI: 10.2196/46891.
- [11] DESTREMPES F, GESNIK M, CHAYER B, et al. Quantitative ultrasound, elastography, and machine learning for assessment of steatosis, inflammation, and fibrosis in chronic liver disease[J]. *PLoS One*, 2022, 17(1): e0262291. DOI: 10.1371/journal.pone.0262291.
- [12] ALSHAGATHRH FM, HOUSEH MS. Artificial intelligence for detecting and quantifying fatty liver in ultrasound images: A systematic review[J]. *Bioengineering*, 2022, 9(12): 748. DOI: 10.3390/bioengineering9120748.
- [13] PICKHARDT PJ, BLAKE GM, GRAFFY PM, et al. Liver steatosis categorization on contrast-enhanced CT using a fully automated deep learning volumetric segmentation tool: Evaluation in 1204 healthy adults using unenhanced CT as a reference standard[J]. *AJR Am J Roentgenol*, 2021, 217(2): 359-367. DOI: 10.2214/AJR.20.24415.
- [14] CHOI KJ, JANG JK, LEE SS, et al. Development and validation of a deep learning system for staging liver fibrosis by using contrast agent-enhanced CT images in the liver[J]. *Radiology*, 2018, 289(3): 688-697. DOI: 10.1148/radiol.2018180763.
- [15] YASAKA K, AKAI H, KUNIMATSU A, et al. Liver fibrosis: Deep convolutional neural network for staging by using gadoxetic acid-enhanced hepatobiliary phase MR images[J]. *Radiology*, 2018, 287(1): 146-155. DOI: 10.1148/radiol.2017171928.
- [16] ZARELLA MD, BOWMAN D, AEFNER F, et al. A practical guide to whole slide imaging: A white paper from the digital pathology association[J]. *Arch Pathol Lab Med*, 2019, 143(2): 222-234. DOI: 10.5858/arpa.2018-0343-RA.
- [17] TAYLOR-WEINER A, POKKALLA H, HAN L, et al. A machine learning approach enables quantitative measurement of liver histology and disease monitoring in NASH[J]. *Hepatology*, 2021, 74(1): 133-147. DOI: 10.1002/hep.31750.
- [18] ASTBURY S, GROVE JI, DORWARD DA, et al. Reliable computational quantification of liver fibrosis is compromised by inherent staining variation[J]. *J Pathol Clin Res*, 2021, 7(5): 471-481. DOI: 10.1002/cjp.2.227.
- [19] LEOW WQ, BEDOSSA P, LIU F, et al. An improved qFibrosis algorithm for precise screening and enrollment into non-alcoholic steatohepatitis (NASH) clinical trials[J]. *Diagnostics*, 2020, 10(9): 643. DOI: 10.3390/diagnostics10090643.
- [20] BOSCH J, CHUNG C, CARRASCO-ZEVALLOS OM, et al. A machine learning approach to liver histological evaluation predicts clinically significant portal hypertension in NASH cirrhosis[J]. *Hepatology*, 2021, 74(6): 3146-3160. DOI: 10.1002/hep.32087.
- [21] RATZIU V, HOMPESCH M, PETITJEAN M, et al. Artificial intelligence-assisted digital pathology for non-alcoholic steatohepatitis: Current status and future directions[J]. *J Hepatol*, 2024, 80(2): 335-351. DOI: 10.1016/j.jhep.2023.10.015.
- [22] NJEI B, OSTA E, NJEI N, et al. An explainable machine learning model for prediction of high-risk nonalcoholic steatohepatitis[J]. *Sci Rep*, 2024, 14(1): 8589. DOI: 10.1038/s41598-024-59183-4.
- [23] MUNK LAURIDSEN M, RAVNSKJAER K, GLUUD LL, et al. Disease classification, diagnostic challenges, and evolving clinical trial design in MASLD[J]. *J Clin Invest*, 2025, 135(10): e189953. DOI: 10.1172/JCI189953.
- [24] CHANG D, TRUONG E, MENA EA, et al. Machine learning models are superior to noninvasive tests in identifying clinically significant stages of NAFLD and NAFLD-related cirrhosis[J]. *Hepatology*, 2023, 77(2): 546-557. DOI: 10.1002/hep.32655.
- [25] KWON OY, CHOI JY, JANG Y. The effectiveness of eHealth interventions on lifestyle modification in patients with nonalcoholic fatty liver disease: Systematic review and meta-analysis[J]. *J Med Internet Res*, 2023, 25: e37487. DOI: 10.2196/37487.
- [26] TINCOPA MA, PATEL N, SHAHAB A, et al. Implementation of a randomized mobile-technology lifestyle program in individuals with non-alcoholic fatty liver disease[J]. *Sci Rep*, 2024, 14(1): 7452. DOI: 10.1038/s41598-024-57722-7.
- [27] TINCOPA MA, LYDEN A, WONG J, et al. Impact of a pilot structured mobile technology based lifestyle intervention for patients with nonalcoholic fatty liver disease[J]. *Dig Dis Sci*, 2022, 67(2): 481-491. DOI: 10.1007/s10620-021-06922-6.
- [28] SATO M, AKAMATSU M, SHIMA T, et al. Impact of a novel digital therapeutics system on nonalcoholic steatohepatitis: The NASH app clinical trial[J]. *Am J Gastroenterol*, 2023, 118(8): 1365-1372. DOI: 10.14309/ajg.0000000000002143.
- [29] KWON OY, LEE MK, LEE HW, et al. Mobile app-based lifestyle coaching intervention for patients with nonalcoholic fatty liver disease: Randomized controlled trial[J]. *J Med Internet Res*, 2024, 26: e49839. DOI: 10.2196/49839.

收稿日期: 2025-08-14; 录用日期: 2025-10-08

本文编辑: 刘晓红

引证本文: SUN C, FAN JG. Application of artificial intelligence in metabolic associated fatty liver disease[J]. *J Clin Hepatol*, 2025, 41(11): 2213-2217.
孙超, 范建高. 人工智能在代谢相关脂肪性肝病中的应用[J]. *临床肝胆病杂志*, 2025, 41(11): 2213-2217.