

王亚东,贾福运,刘思睿,等. 人工智能在心力衰竭预测中的应用 [J]. 中国比较医学杂志, 2026, 36(4): 108-117.
Wang YD, Jia FY, Liu SR, et al. Application of artificial intelligence for prediction of heart failure [J]. Chin J Comp Med, 2026, 36(4): 108-117.
doi: 10.3969/j.issn.1671-7856.2026.04.011

人工智能在心力衰竭预测中的应用

王亚东¹, 贾福运², 刘思睿¹, 张瑞¹, 祁光伟¹, 徐强^{2*}

(1.天津中医药大学,天津 301617;2.天津中医药大学第二附属医院,天津 300150)

【摘要】 心力衰竭是全球范围内高发率和高病死率的疾病,人工智能(AI)在心血管领域的应用越来越广泛。本文基于AI在心力衰竭预测方面的现状,总结了AI技术与临床诊察手段方面结合的应用及其研究进展。AI通过学习超声心动图的参数评估心脏结构并对心力衰竭做出预测;AI建立的心电图模型在心力衰竭的预测中表现出极高的准确度;AI发现的新型生物标志物和遗传基因能够指导心力衰竭的预测和高风险人群筛选,还能通过对其他疾病特征的学习识别心力衰竭风险。AI技术对心力衰竭的预测具有便捷、可靠、效率高的优点,为其提供了新的可能性与挑战,并能够为临床专家的决策提供参考。

【关键词】 心力衰竭;人工智能;预测

【中图分类号】 R541.6;TP18;R319 **【文献标识码】** A **【文章编号】** 1671-7856 (2026) 04-0108-10

Application of artificial intelligence for prediction of heart failure

WANG Yadong¹, JIA Fuyun², LIU Sirui¹, ZHANG Rui¹, QI Guangwei¹, XU Qiang^{2*}

(1. Tianjin University of Traditional Chinese Medicine, Tianjin 301617, China.

2. the Second Affiliated Hospital of Tianjin University of Traditional Chinese Medicine, Tianjin 300150)

【Abstract】 Heart failure has high incidence and mortality rates worldwide. Artificial intelligence (AI) is increasingly used in the cardiovascular field. This article summarizes progress in combining AI technology with clinical examination method for the prediction of heart failure. AI can evaluate the structure of the heart, and predict heart failure by learning parameters from echocardiography. The electrocardiogram model established by AI has high agility in predicting heart failure. New biomarkers and gene involvement discovered by AI can guide the prediction of heart failure and the screening of high-risk populations. AI can also identify the risk of heart failure by learning other disease characteristics. AI technology has the advantages of convenience, reliability, and high efficiency for the prediction of heart failure, presented new possibilities and challenges for this field and provided valuable references for the clinical decision-making of medical specialists.

【Keywords】 heart failure; artificial intelligence; prediction

Conflicts of Interest: The authors declare no conflict of interest.

心力衰竭是各类心血管疾病的终末阶段,往往造成患者的高住院率和高死亡率^[1]。人工智

能(artificial intelligence, AI)是一种基于计算机算法的复杂统计工具,可以在减少人为干预的前提

【基金项目】 国家自然科学基金(82374195)。

【作者简介】 王亚东(1998—),男,在读硕士研究生,研究方向:心血管疾病。E-mail:wyd202303@163.com

【通信作者】 徐强(1973—),男,博士,主任医师,研究方向:中医药治疗心血管疾病。E-mail:temxuqiang@hotmail.com

下对智能行为进行模拟学习和建模,并做出预测或决策^[2,3]。其中风险预测模型能够识别心力衰竭的风险,提高预测的精准度,有效对患者实施预防性治疗^[4]。目前在心力衰竭领域没有单一的预测标准,相对于治疗和预后管理,心力衰竭的风险预测还存在诸多困难,而准确的早期预测能有效降低医疗成本,对于心力衰竭的防治具有重要意义。AI 相对于传统预测工具,以其独特优势应用于心力衰竭的风险预测中,使心力衰竭的预防更加个性化、精准化^[5]。现对 AI 在心力衰竭预测中的应用现状做一综述。

1 AI 在心力衰竭领域的发展状况

AI 最初广泛应用于计算机系统,通常表现为输入过去的数据并进行学习的能力,能够在学习和解决问题过程中模仿与人脑相关的认知行为。机器学习是 AI 的一种算法,其中深度学习是机器学习的一个子集,在医学领域中得到广泛的应用。其他 AI 算法包括人工神经网络、卷积神经网络、支持向量机、分类和回归、生成对抗网络、符号学习和元学习等^[6]。人工神经网络虽然有识别和学习的能力,但不能自动提取图像特征。CURRIE 等^[7]使用人工神经网络评价心电图、冠脉造影等原始临床数据,证明当左心室射血分数(left ventricular ejection fraction, LVEF)下降超过 10% 时,碘 - 123 间碘苄胍 (¹²³I-Metaiodobenzylguanidine, ¹²³I-MIBG)放射性核素平面总体洗脱 >30% 是心力衰竭风险的最佳指标。相较于人工神经网络,卷积神经网络在图像处理方面有更出色的表现,且能够从局部到全部分层处理信息。支持向量机适用于样本量较少的预测模型,样本量过多时将显著增加计算量和运算时间。有研究团队通过支持向量机分析 5~7 个临床指标,预测心力衰竭患者的药物依从性,模型最高检测准确率达到 77.63%^[8]。分类与回归都属于常用的机器学习预测方式,分类目的是寻找决策边界,输出值是定性的;回归目的则是找到最优拟合,其输出值偏于定量。生成对抗网络是一种基于人工神经网络和深度学习合成图像的技术,目前多应用于医学影像的数据增强和图像重建^[9]。符号学习和深度学习是一种互补关系,深度学习擅长构建模糊的、高维的隐式数据

模型;而符号学习擅长构建精确的、可解释的显式数据模型。元学习能够在多个学习阶段改进学习算法,一般用于提高 AI 模型的学习能力。

AI 在心力衰竭领域已逐步开展应用。通过 AI 改进的心电图已被证实可以有效提高心力衰竭的识别率,特别是在急诊室环境中能提供更快速、更精确的治疗方案,AI 已然成为精确诊断和治疗心血管疾病的潜在技术^[10];相较于传统逻辑回归模型,基于机器学习的预测模型在确定急性心力衰竭患者 30 d 的再入院风险方面,表现出更显著的性能^[11]。有研究评估了安徽省 2794 例住院心力衰竭患者的基线数据和恶性心律失常事件,结果表明,该机器学习模型可以有效地预测住院心力衰竭患者恶性心律失常的风险^[12]。另一方面,将机器学习引入心音描记术、将声音作为心力衰竭语音生物标志物等新型方法,为心力衰竭的诊断、筛查和评估奠定了新的基础^[13]。

2 AI 基于多模态数据对心力衰竭的风险预测

2.1 AI 在超声心动图方面预测心力衰竭的应用

评估心脏的收缩和舒张对综合诊断心脏功能至关重要,超声心动图可以通过准确描述心脏结构和功能来判断心脏情况,有助于识别心力衰竭患者^[14]。AI 可通过学习大量超声心动图而降低误差,减少由操作者主观因素导致的图像质量差异,因此采用 AI 算法与超声心动图信号相结合的方式,可以协助临床医生提高预测心力衰竭的效率和准确度。SIMONSEN 等^[15]使用无监督机器学习分析 3710 名无心力衰竭的普通人群纵向应变曲线,研究发现,随着心力衰竭发病率的增加,应变曲线显示超声心动图舒张早期应变与峰值应变的比值降低,揭示了一种心脏整体纵向应变以外的、与心力衰竭风险增加有关的新模式。LVEF 是评估心脏功能的关键指标,一般用超声心动图测量,反映左心室的收缩功能,常用于诊断心力衰竭。ZHANG 等^[16]使用 Atrous 卷积神经网络分割左心室,且使用基于椭球单平面模型的面积长度公式来计算 LVEF 值,并在包含 10 030 张超声心动图的开源数据集中进行内部验证,在 LVEF 的预测方面,AI 与临床专家分析的皮尔逊相关系数为 0.83 ($P < 0.001$)。该研究证明了基

于神经网络的 LVEF 自动计算与临床专家对心脏收缩功能进行的逐帧手动评估相当,表明 AI 算法有助于临床专家对心力衰竭诊断做出决策。亦有研究者使用血流动力学、脉搏形态和身体信息等参数,通过机器学习算法估计 LVEF,进而预测心力衰竭风险,结果显示,有 9 个参数与 LVEF 病理生理学参数一致^[17]。

2.2 AI 在心电图方面预测心力衰竭的应用

12 导联心电图是临床心脏病学中最常用的技术,对于大多数心血管疾病包括急性心肌梗死、心律失常、心力衰竭等患者的循证管理至关重要。AI 通过对大量心电图的学习,能够创建用于预测心力衰竭风险的模型。相关研究者挖掘出一种风险估计器平台,分析了包含 189 539 例患者的 1 163 401 张心电图数据集,通过深度学习和离散时间生存模型创建了一个具有单个心电图检查结果患者的特异性生存曲线,准确预测了全因死亡率的风险^[18]。KWON 等^[19]开发的 AI 纳入了一家医院的 547 645 张心电图,在同 1 d 又纳入了另一家医院接受过双导联智能手表心电图和超声心动图检查的 755 例成年患者,结果显示使用智能手表心电图检测射血分数保留型心力衰竭 (heart failure with preserved ejection fraction, HFpEF) 的 AI 接收器 AUC 为 0.934 (95% CI: 0.913~0.955),敏感性、特异性、阳性预测值和阴性预测值分别为 0.897、0.860、0.258 和 0.994。有研究者建立了一个机器学习系统,使用心电图信号预测部分心血管疾病风险,最终在充血性心力衰竭的预测方面达到了 100% 准确率^[20]。AI 的准确率与性能优势为临床医生的决策提供了有价值的参考。

动态心电图相较于普通心电图而言,有着持续性强、容错率高的特点,能够更好地监测患者心律失常等异常情况,诊断价值较高。有研究团队通过预测模型结合动态心电图的 R-R 间期分析,预测心力衰竭心源性猝死风险,以确定是否需要植入式除颤器治疗,最终预测结果发生的 AUC 为 0.79,经验证后确定性为 97.3%^[21]。在未来,有 AI 加成的动态心电图或将更适用于重症监护室与预后护理,其高敏感性可实现对患者病情的连续监测,并及时发出预警。

2.3 AI 在生物标志物方面预测心力衰竭的应用

心血管生物标志物检测,旨在弥补心电图、超声心动图、心脏影像学 and 临床症状评估的不足,目前已成为临床诊断、鉴别诊断、风险分层和预后的常规评估手段,并指导疑似心血管疾病患者的临床管理。

利钠肽被认为是临床实践中诊断心力衰竭的首选生物标志物,而其他几种潜在生物标志物的作用和可能的临床应用仍在研究中^[22]。因此,合理运用 AI,探索更多的生物标志物,促进患者的早期诊断和病程管理已成为一种趋势。ZHU 等^[23]采用机器学习集成框架和蛋白质相互作用网络来识别诊断生物标志物,从而预测心力衰竭,结果表明高血浆骨多糖的遗传易感性会增加心力衰竭的风险,因此骨多糖可以作为心力衰竭的诊断生物标志物。白蛋白是体液平衡的重要组成部分,与心血管疾病有关,可通过血液检查进行测量。由于体液平衡与心电图变化有关,相关研究团队建立了一个深度学习模型来通过心电图估计白蛋白含量,结果显示在内部验证集中,识别低白蛋白血症的 AUC 为 0.88,敏感性为 56.0%,特异性为 90.7%,连续分析中的皮尔逊相关系数为 0.69,此外,白蛋白严重低的组别死亡率及心血管事件风险较高,这表明深度学习模型能够通过心电图估计白蛋白含量,从而警告无症状患者^[24]。

脂质组学网络在多步骤工作流程中与心力衰竭风险相关,WITTENBECHER 等^[25]的机器学习模型在波茨坦队列的子样本中进行了外部验证,确定并验证了 2 种脂质代谢产物 (神经酰胺和磷脂酰胆碱) 作为心力衰竭风险的潜在新生物标志物。脂质分析能捕捉到易患心力衰竭者的临床前分子变化。在一项从美国医疗机构纳入 1069 名受试者的前瞻性研究中,利用机器学习模型结合循环生物标志物和计算机断层扫描测量,使用全自动深度学习软件对 48 种血清生物标志物进行了测定,结果显示血清生物标志物在机器学习模型中提供了超出临床数据和 CT 测量的增量预测价值,净重新分类指数为 0.53 (95% CI: 0.23~0.81)^[26]。机器学习再一次为人类发现了新的长期心力衰竭风险预测指标。

炎症反应、代谢紊乱和营养不良参与并相互

作用于 HFpEF 的发病机制。有研究者通过机器学习建立一个代谢-营养不良-炎症评分模型来预测 HFpEF 患者的死亡风险,模型纳入 6 种炎症、营养成分和尿酸生物标志物,结果显示,1 年、3 年和 5 年模型的平均 AUC 分别为 0.778、0.782 和 0.772,评分模型与全因死亡率独立相关,风险比为 1.98(95%CI:1.70~2.31, $P<0.001$)^[27]。AI 通过生物标志物的预测可有效识别高危 HFpEF 患者,为潜在的 HFpEF 患者提供个体化管理策略。LIU 等^[28]基于机器学习算法,从免疫细胞浸润的角度探究与急性心肌梗死血管生成相关的诊断标志物,鉴定血栓调节蛋白基因为急性心肌梗死的潜在诊断标志物(AUC=0.93),为未来 AI 进一步从免疫角度作用于心力衰竭预测提供了启发。

2.4 AI 在基因遗传方面预测心力衰竭的应用

心力衰竭的遗传景观是复杂和多方面的,包括常见和罕见的遗传变异,这些变异对疾病易感性和进展有重大影响。基于遗传特征对 HFpEF 和其他类型心力衰竭的区分进一步强调了心力衰竭的异质性和量身定制治疗方法的必要性。此外,多基因风险评分在预测心力衰竭风险方面的作用是可观的,有指导早期诊断的潜力^[29]。基因数据一般来源于 GEO、TCGA、NCBI、Ensembl、UCSC 和 CellAge 等数据库,采集方法包括 DNA 提取、基因测序及血液、唾液、组织等样本收集。在一项近期关于基因组及心力衰竭的大规模研究中,发现 ACTN2 和 BAG3 基因的突变会导致扩张型心肌病;PITX2 基因调控心脏电信号,与房颤风险密切相关;IGFBP7 基因会加速心肌细胞老化,在 HFpEF 中作用显著。除此之外,肾脏组织在 HFpEF 中遗传贡献度最高,而血管平滑肌细胞的基因变异会同时增加动脉硬化和心力衰竭风险^[30]。单核苷酸多态性(single nucleotide polymorphism, SNP)是基因组水平由单个核苷酸变异引起的 DNA 序列多样性,不同的 SNP 特征可以影响蛋白质功能,且与疾病易感性相关。YANG 等^[31]使用 AI 辅助的全基因组关联研究 117 名无症状高危个体的 SNP 数据库时,确定了由 13 个 SNP 组成的 SNP 特征,这些被注释并定位到 6 个蛋白质编码基因、1 个假基因和各种非编码 RNA 基因。SNP 特征在预测心力衰竭进展

时具有良好的性能,准确率达 85.7%,AUC 为 0.91,结果表明 AI 辅助识别 SNP 特征和临床参数能够有效筛选易患心力衰竭的无症状高危受试者^[31]。YU 等^[32]通过 CellAge 数据库获取心力衰竭的衰老相关基因,并通过 GO 和 KEGG 富集分析阐明心力衰竭和衰老的生物学功能和信号通路,之后使用 3 种机器学习算法进一步筛选心力衰竭的衰老相关基因,最终共获得了 57 个上调和 195 个下调的心力衰竭衰老相关基因。随后在 2 个外部验证集共 240 例患者中验证了结果,最高准确率为 0.95。相关学者采用基因表达综合数据库中的心力衰竭数据集作为训练和验证队列,使用两种机器学习算法进行特征选择,构建列线图模型,根据选定的关键基因预测心力衰竭风险,其所提出的列线图中包含了 7 个关键基因,为预测心力衰竭患者提供了新的策略^[33]。WANG 等^[34]通过类似的机器学习方法从 GEO 数据库筛选心力衰竭患者的特征基因,最终发现心力衰竭患者心肌细胞中 SDSL 基因表达的升高可能是促进心力衰竭发生和发展的重要因素,随后在临床数据集的应用中表现出高准确性(AUC>0.94),为临床提供了新的预测和治疗方向。

2.5 AI 在其他影像学方面预测心力衰竭的应用

心脏成像在心力衰竭的准确诊断中起着至关重要的作用。虽然超声心动图是最常用于心力衰竭患者首次评估的成像技术,但多模态成像是诊断心力衰竭病因的关键。X 射线是确诊心力衰竭肺水肿的重要依据;心脏磁共振是心肌病鉴别诊断的关键;冠状动脉计算机断层扫描血管造影术越来越多地用于排除缺血性心脏病。此外,核心脏病学技术能够达到可视化细胞代谢,并能分析心力衰竭的炎症原因^[35]。研究人员通过深度学习分析胸部 X 射线以预测心力衰竭心脏事件,有效解决了 X 射线灵敏度和特异性相对较低的局限性,且其预测结果准确度超过了临床医生^[36]。KUCUKSEYMEN 等^[37]通过机器学习模型结合心脏磁共振成像来预测心力衰竭患者的住院风险,预测能力(AUC=0.81)明显高于传统预测模型(AUC=0.64)。光学相干断层扫描血管造影已被发现可以识别患者视网膜微血管各种心脏代谢因素的变化。HUANG 等^[38]的研究使用机器学习和光学相干断层扫描血管造影预测心

血管疾病存在与否及其相关风险因素,模型在 3 mm×3 mm 扫描中识别充血性心力衰竭方面展现出优异性能表现 (AUC = 0.61)。NAKAJIMA 等^[39]基于¹²³I-MIBG 创建的多变量风险模型预测心力衰竭患者的 2 年死亡率,在队列验证后结果显示¹²³I-MIBG 的验证模型准确率优于 LVEF 和利钠肽。

3 AI 对其他疾病继发心力衰竭风险的预测

心力衰竭常作为多种慢性疾病的并发症出现,如肺癌、糖尿病、高血压、严重抑郁症和慢性肾病等。在患者群体中,除了常规预测和诊断方法,通过 AI 学习非心力衰竭疾病特征,进而提供

精确的预测和预防策略,将成为新的心力衰竭预测方向(见表 1)。

3.1 AI 对呼吸系统疾病继发心力衰竭风险的预测

无论是维持氧气供应还是酸碱平衡,呼吸系统都对心血管系统至关重要,二者通过血液循环紧密相连,任何一方出现障碍都可能对另一方造成深远影响。AI 通过监测呼吸系统疾病的状况,能够达到预测心力衰竭的效果。有研究者使用机器学习技术通过智能手机麦克风对患者咳嗽和喘息的变化进行记录,从而发现心力衰竭的早期迹象,样本准确率 $\geq 70%$ ^[40]。HOU 等^[41]使用卷积神经网络模型从肺部体积和质地指标层面预测心力衰竭,研究发现较大的异质性和粗糙的

表 1 利用 AI 对其他疾病继发心力衰竭风险的预测
Table 1 Prediction of the risk of secondary heart failure in other diseases using AI

研究者 Researchers	AI 类型 AI type	来源 Source	原发病 Primary disease	结果指标 Outcome indicators
WINDMON A ^[40]	机器学习 Machine learning	47 例成人咳嗽样本 47 adult cough samples	慢性咳嗽 Chronic cough	样本准确率 $\geq 70%$ Sample accuracy $\geq 70%$
HOU C R, RAMO J, KANY S, et al ^[41]	卷积神经网络(深度学习) Convolutional neural network (deep learning)	英国生物库的心血管磁共振成像中肺野的纹理参数 Texture parameters of lung field in cardiovascular magnetic resonance imaging of the UK Biobank	肺组织病变 Lung tissue lesions	较大的异质性和粗糙的肺纹理与心力衰竭风险增加相关 Greater heterogeneity and rough lung texture are associated with an increased risk of heart failure
WÄNDELL P, CARLSSON A C, ERIKSSON J, et al ^[42]	机器学习 Machine learning	45 490 例糖尿病患者 45 490 cases of diabetes	糖尿病 Diabetes	糖尿病患者心力衰竭的预测模型 AUC 约为 0.85 AUC of the prediction model of heart failure in diabetes patients is about 0.85
AMINIAN A, ZAJICHEK A, ARTERBURN D E, et al ^[43]	机器学习 Machine learning	接受/不接受代谢手术共 2287 例糖尿病患者 2287 cases of diabetes with or without metabolic surgery	糖尿病 Diabetes	手术组和非手术组的受试者心力衰竭预测 AUC 分别为 0.73 和 0.75 AUC values for predicting heart failure in the surgical and non-surgical groups were 0.73 and 0.75, respectively
LIN C, KUO F C, CHAU T, et al ^[44]	机器学习 Machine learning	33 246 例甲状腺亢进患者 33 246 patients with hyperthyroidism	甲状腺亢进 Hyperthyroidism	准确度 AUC 达到 0.725~0.761 Accuracy AUC reaches 0.725~0.761
ZHU H, QIAO S, ZHAO D, et al ^[45]	机器学习 Machine learning	8894 例慢性肾病患者 8894 patients with chronic kidney disease	慢性肾病 Chronic kidney disease	测试集中的极端梯度提升曲线下面积为 0.89 Area under the extreme gradient lift curve in the test set is 0.89
ZHANG T Y, AN D A, YAN H, et al ^[46]	机器学习 Machine learning	254 例终末期肾病患者 254 patients with end-stage renal disease	终末期肾病 End stage renal disease	预测模型 C 指数为 0.81 C index of the prediction model is 0.81

续表 1

研究者 Researchers	AI 类型 AI type	来源 Source	原发病 Primary disease	结果指标 Outcome indicators
ZHANG C, SONG Y, CEN L, et al ^[47]	机器学习 Machine learning	抑郁症和心力衰竭的 GWAS 数据 GWAS data for depression and heart failure	抑郁症 Depression	鉴定出 315 个心力衰竭关键基因和 332 个抑郁症相关分泌蛋白 Identified 315 key heart failure genes and 332 depression related secreted proteins
GIRI S, BOSE J C, CHANDRASEKAR A, et al ^[48]	机器学习 Machine learning	66 例接受化疗的癌症患者 66 cancer patients receiving chemotherapy	癌症 Cancer	预测准确率为 87.8% Prediction accuracy is 87.8%
ZHOU S, BLAES A, SHENOY C, et al ^[49]	深度学习 Deep learning	电子健康记录数据 Electronic health record data	乳腺癌 Breast cancer	预测 AUC 评分高达 0.9334 Predicted AUC score as high as 0.9334
WU X, YUAN X, WANG W, et al ^[50]	机器学习 Machine learning	508 例高血压患者 508 hypertensive patients	高血压 Hypertension	用于识别具有复合终点的患者一致性为 0.757 Consistency for identifying patients with composite endpoints is 0.757
ZHOU H, YANG C, LI J, et al ^[51]	机器学习 Machine learning	6772 例肥胖患者 6772 obese patients	肥胖 Obesity	逻辑回归显示, 对全因死亡率 (AUC = 0.869) 和心血管死亡率 (AUC = 0.851) 的预测性能好 Logistic regression shows good predictive performance for all-cause mortality (AUC = 0.869) and cardiovascular mortality (AUC = 0.851)

肺纹理与心力衰竭风险增加相关, 1-SD 风险比分别为 1.21 (95% CI: 1.12~1.31) 和 1.32 (95% CI: 1.18~1.47), 这种关联在非吸烟者亚组中仍然显著, 且在调节 LVEF 后依然存在, 表明心力衰竭在前期很可能表现为肺组织的变化, AI 模型能够从对肺组织特征的分析中预测心力衰竭发生风险。心肺的强关联性表现出未来 AI 对于这方面分析的潜力, 但目前 AI 对呼吸系统疾病继发心力衰竭风险预测的应用较少, 临床验证也需进一步完善。

3.2 AI 对内分泌系统疾病继发心力衰竭风险的预测

内分泌系统疾病与心血管疾病关联密切。目前通过 AI 预测心力衰竭风险的内分泌系统疾病以糖尿病居多。WÄNDELL 等^[42] 创建机器学习预测模型, 以识别糖尿病患者的充血性心力衰竭新病例, 结果显示, 糖尿病患者心力衰竭的模型预测准确度很高, AUC 约为 0.85, 灵敏度超过 0.783, 特异性超过 0.708。AMINIAN 等^[43] 构建并验证机器学习预测模型, 评估 2 型糖尿病并发

心力衰竭的风险, 体现出可靠的预测效果。证明该模型能够为 2 型糖尿病患者提供有关心力衰竭的风险预警, 且具备临床参考价值。相关研究团队开发 AI 模型, 通过心电图检测甲状腺功能亢进, 并研究其预测心力衰竭的潜力, 模型在甲状腺功能亢进症检测中 AUC 达到了 0.73~0.76, 优于传统的预测模型^[44]。

3.3 AI 对泌尿系统疾病继发心力衰竭风险的预测

心血管疾病是慢性肾病患者死亡的主要原因。研究者用 7 种机器学习模型预测慢性肾病的心血管疾病风险, 以支持临床决策并改善慢性肾病患者预后, 在测试集中预测模型的 AUC 最高为 0.89^[45]。左心室小梁的复杂性与多种心血管疾病的预后有关。有研究者采用随机森林和传统 Cox 回归模型预测终末期肾病患者主要不良心脏事件^[46], 根据模型得出的评分和比较的生存率, 将患者分为低风险组和高风险组, 结果预测模型两组的 C 指数 (C-index, 指预测结果与实际结果一致所占的比例, 用于评估预测模型预测能力的

统计指标)达到了 0.81,其判别能力明显优于 Cox 回归模型。由上述研究可见,AI 通过对肾脏疾病的生理指标分析,同样能够做到对心力衰竭的预测,其预测结果也能够为临床医生的决策提供参考。

3.4 AI 对其他疾病继发心力衰竭风险的预测

重度抑郁症在心力衰竭的发生中起着至关重要的作用。ZHANG 等^[47]使用机器学习算法预测重度抑郁症相关的心力衰竭风险,结果显示,重度抑郁症与心力衰竭风险增加有关($OR = 1.129, P < 0.001$)。癌症患者的心血管疾病会增加计划外再次入院的风险。据报道,癌症幸存者患心血管疾病的风险更高,其中血液肿瘤和乳腺癌幸存者更易发生心力衰竭^[52]。研究团队使用机器学习技术预测癌症住院患者因心血管疾病导致的 180 d 计划外再入院风险,最终模型最高 AUC 达到 0.75,证明机器学习模型可以预测癌症住院患者因心血管疾病而意外再次入院的风险^[53]。化疗引起的心脏毒性会导致充血性心力衰竭的发展,GIRI 等^[48]使用支持向量机对癌症接受化疗和未接受化疗的患者进行研究,以从血浆中确定血管损伤的指标,观察到模型可以预测癌症患者化疗前后心血管损伤的风险,准确率为 87.8%, $AUC = 0.912$ 。有研究者开发了心脏病的预测模型,用于预测乳腺癌患者发生心血管疾病的风险,结果显示心力衰竭 AUC 评分高达 0.93,该研究使癌症幸存者有望对心血管疾病进行早期干预^[49]。WU 等^[50]使用机器学习方法预测年轻高血压患者预后,并将其性能与目前临床实践中常用的方法进行了比较,AI 模型用于识别具有复合终点患者的 C 指数为 0.757(95%CI:0.660~0.854),而对于 Cox 回归模型和重新校准的 Framingham 风险评分模型,其 C 指数为 0.723(95%CI:0.636~0.810)和 0.529(95%CI:0.403~0.655),机器学习在确定年轻高血压患者的临床预后方面与 Cox 回归相当,并且优于重新校准的 Framingham 风险评分模型。N-末端 B 型利钠肽前体(N-terminal pro-brain natriuretic peptide, NT-proBNP)是评估心功能的重要指标,广泛应用于心力衰竭的检测。有研究者建立机器学习模型预测肥胖症患者和心血管死亡率之间的关系:NT-proBNP ≥ 300 pg/mL 与全因死亡率($HR 3.00,$

95%CI:2.48~3.67)和心血管死亡率($HR 6.05,$ 95%CI:3.67~9.97)呈正相关,并且在不同的体质指数分层中保持显著;在没有腹部肥胖的参与者中,NT-proBNP 与心血管死亡率之间的相关性显著降低^[51]。这表明 AI 可以通过肥胖患者的生理指标预测心力衰竭风险。

4 结论与展望

AI 通过对大样本患者的各项临床特征和生理病理特征进行客观学习,从而构建能够预测心力衰竭风险的预测模型,并具有一定的准确度,可辅助临床医生做出更精确和个性化的治疗方案,可见其未来的发展潜力巨大。对于心力衰竭患者,多渠道、多方法的预测手段具有重要意义,AI 以其独特优势,应用于超声心动图、心电图、影像学等多种检测手段,为临床的评估提供更全面的数据。在 AI 通过分析原发病的参数进而预测心力衰竭方面,目前较多应用于 2 型糖尿病、严重的肾病及癌症,其他疾病中运用较少。远程监控型可穿戴设备,如双导联智能手表、可穿戴纺织电极、可穿戴腰带等,与 AI 相结合,能够成功实现更便捷的心力衰竭风险预测判断,使患者就医更及时。如果未来 AI 能通过远程穿戴设备对患者进行电子健康记录,持续跟踪病程,或将显著提升 AI 诊断水平和对临床参数分析的明晰度,提高临床诊断和治疗的实时性,为心力衰竭患者提供更精准、更全面、更有效的治疗方案。肠道微生物群与宿主一起发育、成熟和老化,与心血管疾病相互作用并参与其发生和发展,心力衰竭患者或动物模型的肠道微生物群如乳酸杆菌、双歧杆菌、梭菌和拟杆菌等产生的胆汁酸含量存在显著的特异性变化^[54],通过这些变化,可以在新兴 AI 的帮助下开发无创诊断策略,帮助预测心力衰竭风险。

同时,当前 AI 也存在局限性,机器学习模型虽能从心电图、超声心动图等复杂医学数据中提取特征,但其决策过程类似“黑箱”,难以向临床医生直观解释预测结果的依据。这种不可解释性不仅阻碍了医生对模型的信任,也为医疗纠纷埋下隐患,例如,当模型预测结果与临床经验相悖时,医生难以判断决策的合理性。同时,医疗数据的跨中心标准化问题严重制约了 AI 模型的

能力,不同医疗机构的设备参数、数据采集标准、标注规范存在显著差异,导致数据特征分布不一致。例如,超声心动图中 LVEF 的测量、不同超声仪的成像参数及医师操作手法会造成数据偏差,使基于单一中心数据训练的模型在其他中心应用时性能大幅下降。在数据标准化方面,急需建立大规模、多中心、标准化的数据共享机制,以提升 AI 模型的可靠性与普适性。随着新型 AI 技术应用于临床,一些法律和伦理问题也将逐步涌现,患者的隐私安全需要有效的保护体系。在处理患者个人数据和医疗信息时,需要满足相关法律规定,充分保护患者隐私安全。当 AI 本身出现问题时,也需要明确的责任划分和处理方式。

不可否认, AI 在计算和分析数据方面的效率远高于人类,但人类的理智与思维也是 AI 无法替代的。 AI 在未来一段时间内并不能完全取代人类预测心力衰竭,但随着 AI 技术的不断发展,其在医学领域的应用将对疾病的预测做出更多实质性贡献,并有望改变未来的诊疗模式,为智能化医疗开辟全新的可能性。

参考文献:

- [1] 吴娟, 龙萍, 曾露, 等. 《中国心力衰竭诊断和治疗指南 2024》药物更新透视 [J]. 医药导报, 2024, 43(11): 1718-1722.
WU J, LONG P, ZENG L, et al. Pharmacologic therapy updates of 2024 guidelines for the diagnosis and treatment of heart failure in China [J]. Her Med, 2024, 43(11): 1718-1722.
- [2] RANKA S, REDDY M, NOHERIA A. Artificial intelligence in cardiovascular medicine [J]. Curr Opin Cardiol, 2021, 36(1): 26-35.
- [3] HAMET P, TREMBLAY J. Artificial intelligence in medicine [J]. Metabolism, 2017, 69: S36-S40.
- [4] MATASIC D S, ZEITOUN R, FONAROW G C, et al. Advancements in incident heart failure risk prediction and screening tools [J]. Am J Cardiol, 2024, 227: 105-110.
- [5] OLSEN C R, MENTZ R J, ANSTROM K J, et al. Clinical applications of machine learning in the diagnosis, classification, and prediction of heart failure [J]. Am Heart J, 2020, 229: 1-17.
- [6] GUPTA R, SRIVASTAVA D, SAHU M, et al. Artificial intelligence to deep learning: machine intelligence approach for drug discovery [J]. Mol Divers, 2021, 25(3): 1315-1360.
- [7] CURRIE G, IQBAL B, KIAT H. Intelligent imaging: radiomics and artificial neural networks in heart failure [J]. J Med Imaging Radiat Sci, 2019, 50(4): 571-574.
- [8] SON Y J, KIM H G, KIM E H, et al. Application of support vector machine for prediction of medication adherence in heart failure patients [J]. Health Inform Res, 2010, 16(4): 253-259.
- [9] KOSHINO K, WERNER R A, POMPER M G, et al. Narrative review of generative adversarial networks in medical and molecular imaging [J]. Ann Transl Med, 2021, 9(9): 821.
- [10] ALI MUZAMMIL M, JAVID S, AFRIDI A K, et al. Artificial intelligence-enhanced electrocardiography for accurate diagnosis and management of cardiovascular diseases [J]. J Electrocardiol, 2024, 83: 30-40.
- [11] ZHANG Y, XIANG T, WANG Y, et al. Explainable machine learning for predicting 30-day readmission in acute heart failure patients [J]. iScience, 2024, 27(7): 110281.
- [12] WANG Q, LI B, CHEN K, et al. Machine learning-based risk prediction of malignant arrhythmia in hospitalized patients with heart failure [J]. ESC Heart Fail, 2021, 8(6): 5363-5371.
- [13] NAHAR J K, LOPEZ-JIMENEZ F. Utilizing conversational artificial intelligence, voice, and phonocardiography analytics in heart failure care [J]. Heart Fail Clin, 2022, 18(2): 311-323.
- [14] NAGUEH S F. Left ventricular diastolic function: understanding pathophysiology, diagnosis, and prognosis with echocardiography [J]. JACC Cardiovasc Imaging, 2020, 13(1 Pt 2): 228-244.
- [15] SIMONSEN J Ø, MODIN D, SKAARUP K, et al. Utilizing echocardiography and unsupervised machine learning for heart failure risk identification [J]. Int J Cardiol, 2025, 418: 132636.
- [16] ZHANG Y, LIU B, BUNTING K V, et al. Development of automated neural network prediction for echocardiographic left ventricular ejection fraction [J]. Front Med, 2024, 11: 1354070.
- [17] LIU S H, YANG Z K, PAN K L, et al. Estimation of left ventricular ejection fraction using cardiovascular hemodynamic parameters and pulse morphological characteristics with machine learning algorithms [J]. Nutrients, 2022, 14(19): 4051.
- [18] SAU A, PASTIKA L, SIELIWONCZYK E, et al. Artificial intelligence-enabled electrocardiogram for mortality and cardiovascular risk estimation: a model development and validation study [J]. Lancet Digit Health, 2024, 6(11): e791-e802.

- [19] KWON J M, JO Y Y, LEE S Y, et al. Artificial intelligence-enhanced smartwatch ECG for heart failure-reduced ejection fraction detection by generating 12-lead ECG [J]. *Diagnostics*, 2022, 12(3): 654.
- [20] SINGHAL A, AGARWAL M. An automatic risk assessment system for sudden cardiac death using look ahead pattern [J]. *Multimed Tools Appl*, 2024, 83(9): 27243–27258.
- [21] AU-YEUNG W M, REINHALL P G, POOLE J E, et al. SCD-HeFT: Use of R-R interval statistics for long-term risk stratification for arrhythmic sudden cardiac death [J]. *Heart Rhythm*, 2015, 12(10): 2058–2066.
- [22] WANG X Y, ZHANG F, ZHANG C, et al. The biomarkers for acute myocardial infarction and heart failure [J]. *Biomed Res Int*, 2020, 2020: 2018035.
- [23] ZHU Y, CHEN B, ZU Y. Identifying OGN as a biomarker covering multiple pathogenic pathways for diagnosing heart failure: from machine learning to mechanism interpretation [J]. *Biomolecules*, 2024, 14(2): 179.
- [24] LEE Y T, LIN C S, FANG W H, et al. Artificial intelligence-enabled electrocardiography detects hypoalbuminemia and identifies the mechanism of hepatorenal and cardiovascular events [J]. *Front Cardiovasc Med*, 2022, 9: 895201.
- [25] WITTENBECHER C, EICHELMANN F, TOLEDO E, et al. Lipid profiles and heart failure risk: results from two prospective studies [J]. *Circ Res*, 2021, 128(3): 309–320.
- [26] TAMARAPPOO B K, LIN A, COMMANDEUR F, et al. Machine learning integration of circulating and imaging biomarkers for explainable patient-specific prediction of cardiac events: a prospective study [J]. *Atherosclerosis*, 2021, 318: 76–82.
- [27] FENG J, HUANG L, ZHAO X, et al. Construction of a metabolism-malnutrition-inflammation prognostic risk score in patients with heart failure with preserved ejection fraction: a machine learning based Lasso-Cox model [J]. *Nutr Metab*, 2024, 21(1): 77.
- [28] LIU G, HUANG L, LV X, et al. Thrombomodulin as a potential diagnostic marker of acute myocardial infarction and correlation with immune infiltration: Comprehensive analysis based on multiple machine learning [J]. *Transpl Immunol*, 2024, 85: 102070.
- [29] FIGUEIRAL M, PALDINO A, FAZZINI L, et al. Genetic biomarkers in heart failure: from gene panels to polygenic risk scores [J]. *Curr Heart Fail Rep*, 2024, 21(6): 554–569.
- [30] HENRY A, MO X, FINAN C, et al. Genome-wide association study meta-analysis provides insights into the etiology of heart failure and its subtypes [J]. *Nat Genet*, 2025, 57(4): 815–828.
- [31] YANG N I, YE H C H, TSAI T H, et al. Artificial intelligence-assisted identification of genetic factors predisposing high-risk individuals to asymptomatic heart failure [J]. *Cells*, 2021, 10(9): 2430.
- [32] YU Y, WANG L, HOU W, et al. Identification and validation of aging-related genes in heart failure based on multiple machine learning algorithms [J]. *Front Immunol*, 2024, 15: 1367235.
- [33] YAN W, LI Y, WANG G, et al. Clinical application and immune infiltration landscape of stemness-related genes in heart failure [J]. *ESC Heart Fail*, 2025, 12(1): 250–270.
- [34] WANG T, SUN Y, ZHAO Y, et al. Identification of hub genes in heart failure by integrated bioinformatics analysis and machine learning [J]. *Front Cardiovasc Med*, 2024, 10: 1332287.
- [35] KASA G, BAYES-GENIS A, DELGADO V. Latest updates in heart failure imaging [J]. *Heart Fail Clin*, 2023, 19(4): 407–418.
- [36] KUSUNOSE K, HIRATA Y, YAMAGUCHI N, et al. Deep learning approach for analyzing chest X-rays to predict cardiac events in heart failure [J]. *Front Cardiovasc Med*, 2023, 10: 1081628.
- [37] KUCUKSEYMEN S, ARAFATI A, AL-OTAIBI T, et al. Noncontrast cardiac magnetic resonance imaging predictors of heart failure hospitalization in heart failure with preserved ejection fraction [J]. *J Magn Reson Imaging*, 2022, 55(6): 1812–1825.
- [38] HUANG S, BACCHI S, CHAN W, et al. Detection of systemic cardiovascular illnesses and cardiometabolic risk factors with machine learning and optical coherence tomography angiography: a pilot study [J]. *Eye*, 2023, 37(17): 3629–3633.
- [39] NAKAJIMA K, MARUYAMA K. Nuclear cardiology data analyzed using machine learning [J]. *Ann Nucl Cardiol*, 2022, 8(1): 80–85.
- [40] WINDMON A. Detecting symptoms of chronic obstructive pulmonary disease and congestive heart failure via cough and wheezing sounds using smart-phones and machine learning. secondary detecting symptoms of chronic obstructive pulmonary disease and congestive heart failure via cough and wheezing sounds using smart-phones and machine learning [D]. South Florida; University of South Florida, 2020.
- [41] HOU C R, RAMO J, KANY S, et al. Abstract 12928: deep learning-derived characterization of lung tissue predicts future diagnosis of heart failure [J]. *Circulation*, 2023, 148(Suppl_1).
- [42] WÄNDELL P, CARLSSON A C, ERIKSSON J, et al. A

- machine learning tool for identifying newly diagnosed heart failure in individuals with known diabetes in primary care [J]. *ESC Heart Fail*, 2025, 12(1): 613–621.
- [43] AMINIAN A, ZAJICHEK A, ARTERBURN D E, et al. Predicting 10-year risk of end-organ complications of type 2 diabetes with and without metabolic surgery: a machine learning approach [J]. *Diabetes Care*, 2020, 43(4): 852–859.
- [44] LIN C, KUO F C, CHAU T, et al. Artificial intelligence-enabled electrocardiography contributes to hyperthyroidism detection and outcome prediction [J]. *Commun Med*, 2024, 4(1): 42.
- [45] ZHU H, QIAO S, ZHAO D, et al. Machine learning model for cardiovascular disease prediction in patients with chronic kidney disease [J]. *Front Endocrinol*, 2024, 15: 1390729.
- [46] ZHANG T Y, AN D A, YAN H, et al. Fractal analysis of left ventricular trabeculae in patients with end-stage renal disease: a random survival tree analysis [J]. *J Magn Reson Imaging*, 2024, 60(5): 1948–1961.
- [47] ZHANG C, SONG Y, CEN L, et al. Screening of secretory proteins linking major depressive disorder with heart failure based on comprehensive bioinformatics analysis and machine learning [J]. *Biomolecules*, 2024, 14(7): 793.
- [48] GIRI S, BOSE J C, CHANDRASEKAR A, et al. Increased plasma nitrite and von willebrand factor indicates early diagnosis of vascular diseases in chemotherapy treated cancer patients [J]. *Cardiovasc Toxicol*, 2019, 19(1): 36–47.
- [49] ZHOU S, BLAES A, SHENOY C, et al. Risk prediction of heart diseases in patients with breast cancer: a deep learning approach with longitudinal electronic health records data [J]. *iScience*, 2024, 27(7): 110329.
- [50] WU X, YUAN X, WANG W, et al. Value of a machine learning approach for predicting clinical outcomes in young patients with hypertension [J]. *Hypertension*, 2020, 75(5): 1271–1278.
- [51] ZHOU H, YANG C, LI J, et al. Association of N-terminal pro-B natriuretic peptide with all-cause mortality and cardiovascular mortality in obese and non-obese populations and the development of a machine learning prediction model: National Health and Nutrition Examination Survey (NHANES) 1999–2004 [J]. *Diabetes Obes Metab*, 2024, 26(12): 5609–5620.
- [52] SZABO L, COOPER J, CONDURACHE D G, et al. Cardiovascular disease burden and risk factor management in cancer survivors: insights into a multiethnic, socioeconomically deprived urban population [J]. *Heart*, 2025, 112(1): e325309.
- [53] HAN S, SOHN T J, NG B P, et al. Predicting unplanned readmission due to cardiovascular disease in hospitalized patients with cancer: a machine learning approach [J]. *Sci Rep*, 2023, 13(1): 13491.
- [54] SHI B, LI H, HE X. Advancing lifelong precision medicine for cardiovascular diseases through gut microbiota modulation [J]. *Gut Microbes*, 2024, 16(1): 2323237.

[收稿日期]2025-06-11