

人工智能辅助超声心动图多普勒参数自动测量的临床实证研究

史中青¹, 巩旭龙², 戚占如¹, 翁和祥², 陈 慧¹, 姚 静¹, 罗守华², 郭冠军¹

1. 南京大学医学院附属鼓楼医院超声医学科, 江苏 南京 210008; 2. 东南大学生物科学与医学工程学院, 江苏 南京 210096

【摘要】 目的 评估人工智能(AI)模型自动测量超声心动图多普勒参数的准确性,并量化其使用对超声医师操作时间与手部操作负荷的节省效果。**方法** 回顾性收集 1668 例患者的超声心动图多普勒频谱图像(肺动脉瓣、主动脉瓣、二尖瓣前向频谱及间隔、侧壁组织多普勒频谱),以两名资深医师一致认可的切面分类与测量结果为金标准,按 4:1 比例划分训练集与验证集,构建基于 ResNet50(切面分类)、YOLOv5(心动周期检测)及 HRNet(关键点检测)的深度学习模型。模型部署后,前瞻性采集 747 例多普勒图像验证准确性;另纳入 661 例患者,分为 AI 辅助组(330 例)与非 AI 辅助组(331 例),通过姿态测量传感器记录检查时间、动作时间、静止时间及轨迹球操作次数,比较两组差异。**结果** AI 模型切面分类总体准确率 90.5~99.3%,各多普勒参数测量与金标准的组内相关系数(ICC)为 0.9902~0.9967,95%置信区间 0.99~1.00, Bland-Altman 分析显示偏倚趋近于 0。AI 辅助组中位检查时间、中位动作时间较非 AI 辅助组缩短($P<0.001$);两组静止时间比较,差异无统计学意义($P=0.068$)。AI 辅助组中位轨迹球操作次数少于非 AI 辅助组($P<0.001$)。**结论** 本研究构建的 AI 模型可高准确度自动测量超声心动图多普勒参数,并在真实临床实景下显著缩短检查时间、减少手部操作负荷,为降低超声医师重复性劳损风险、提升工作效率提供了可量化的实证依据,具有良好的临床转化价值。

【关键词】 人工智能;超声心动描记术;多普勒参数;自动化测量;操作负荷

【中图分类号】 R540.4⁺5

【文献标志码】 A

【文章编号】 1672-6170(2026)04-0042-08

Clinical empirical study on artificial intelligence-assisted automatic measurement of echocardiographic Doppler parameters SHI Zhong-qing¹, GONG Xu-long², QI Zhan-ru¹, WENG He-xiang², CHEN Hui¹, YAO Jing¹, LUO Shou-hua², GUO Guan-jun¹ 1. Department of Ultrasound Medicine, Nanjing Drum Tower Hospital Affiliated to Nanjing University, Nanjing 210008, China; 2. School of Biological Science and Medical Engineering, Southeast University, Nanjing 210096, China

【Corresponding author】 GUO Guan-jun

【Abstract】 Objective To evaluate the accuracy of an artificial intelligence (AI) model for automatic measurement of echocardiographic Doppler parameters and to quantify its effect of reducing sonographers' operation time and hand related operational load. **Methods** Doppler spectrum images such as pulmonary valve, aortic valve, mitral forward spectrum, septal and lateral tissue Doppler spectrum of 1668 patients were retrospectively collected. The view classification and measurements agreed upon by two senior sonographers were used as the gold standard. The dataset was split into training and validation sets at a ratio of 4:1. A deep learning model was constructed based on ResNet50 (view classification), YOLOv5 (cardiac cycle detection) and HRNet (key point detection). After model deployment, 747 Doppler images were prospectively collected for accuracy validation. Additionally, 661 patients were enrolled and divided into an AI-assisted group ($n=330$) and a non AI assisted group ($n=331$). Examination time, active operation time, stationary time and trackball operation counts were recorded using an attitude-measurement sensor. The differences were compared between the two groups. **Results** The overall view classification accuracy of the AI model ranged from 90.5% to 99.3%. The intraclass correlation coefficients (ICC) between AI measurements and the gold standard for each Doppler parameter ranged from 0.9902 to 0.9967, with 95% confidence intervals between 0.99 and 1.00. Bland Altman analysis showed that the bias was close to zero. The median examination time and median active operation time in the AI-assisted group were significantly shorter than those in the non-AI-assisted group (both $P<0.001$). There was no statistically significant difference in stationary time between the two groups ($P=0.068$). The median number of trackball operations in the AI-assisted group was significantly lower than that in the non-AI-assisted group ($P<0.001$). **Conclusions** The proposed AI model can automatically measure echocardiographic Doppler parameters with high accuracy. In real world clinical practice, it significantly shortens the examination time and reduces the hand related operational load. This provides the quantifiable evidence for lowering the risk of repetitive strain injuries and improves the work efficiency for sonographers. It has good clinical translational value.

【Key words】 Artificial intelligence; Echocardiography; Doppler parameters; Automated measurement; Operation load

【基金项目】江苏省卫生健康委 2022 年度医学科研项目资助 (编号:218)

【通讯作者简介】郭冠军,男,医学硕士,副主任医师。江苏省医学会超声医学分会第十届委员会超声心动图学组成员,中国超声医学工程学会超声心动图专业委员会成员。主要研究方向:心脏瓣膜病、先天性心脏病、人工智能在心脏超声中的应用。

心血管疾病是全球首要致死致残病因,也是我国突出的公共卫生难题。受人口老龄化及生活方式改变等因素影响,2024 年我国心血管疾病死亡率达 298.42/10 万,占总死亡的 43.56%,居城乡居民死因首位^[1]。超声心动图频谱多普勒技术通过测

量各瓣口血流速度、压力梯度、速度-时间积分等参数,为瓣膜病变评估、心腔及肺动脉压力测定、心室舒张功能评价等提供关键量化依据。然而,多普勒参数测量高度依赖医师手动描记,流程繁琐、重复性强,每一步均需大量时间与精细操作。与日益增长的检查需求形成鲜明对比的是,我国超声医学人才队伍严重短缺,工作负荷大,长期高频次操作导致医师肌肉骨骼损伤高发,尤以手腕、颈肩、腰部最为常见,多普勒测量中的反复定位与校准是造成腕部劳损的重要原因。职业损伤不仅影响医师的职业寿命与生活质量,也加剧了人才流失与资源紧张。

近年来,人工智能在超声领域的应用从切面识别、图像分割^[2-4]逐步拓展至多参数测量、疾病诊断^[5-9]等。已有研究可在 2 分钟内完成 30 余项参数测量^[10],并将自动测量与设备调节功能整合于超声机中^[11],切实减少了检查时间与操作负荷。但国外心脏超声检查多采用技师采集图像、医生离线报告的模式,其 AI 研究主要针对存储于诊断系统中的标准化图像。而国内实行“扫查-采集-测量-报告”一体化的实时工作模式,临床医生需在扫查同时完成测量与诊断,且因工作量庞大,仅能对核心参数进行重点评估,无法对所有患者进行全参数测量。更重要的是,国内 AI 辅助面临的是实时变化、充满非标准切面及干扰信息的超声界面,与离线分析中的理想图像差异显著,这对现有模型提出了更高挑战。

针对上述国情与一线需求,本研究开发了针对肺动脉瓣、主动脉瓣、二尖瓣前向血流频谱及间隔、侧壁组织多普勒频谱的实时识别与测量模型。该模型已完成实地部署,能够在动态变化的超声界面中精准识别目标频谱,自动标注测量位点并输出结果。本研究采用前瞻性设计,系统评估该 AI 模型在真实临床场景下多普勒参数测量的准确性,以及其对医师检查时间与手部键盘操作负荷的节省效果。

1 资料与方法

1.1 一般资料 本研究为单中心、前瞻性对照临床研究,随机收集 2025 年南京大学医学院附属鼓楼医院 1668 例患者超声心动图多普勒图像用于模型构建(训练集 1334 例,验证集 334 例);2026 年 3 月本地部署后,前瞻性纳入 747 例多普勒参数图像用于准确性验证;661 例患者用于效率与负荷评估,分为 AI 组 330 例,年龄 58(47,71)岁,男 147 例(44.5%),非 AI 组 331 例,年龄 59(44,70)岁,男 160 例(48.3%)。纳入标准:①年龄 ≥ 18 岁;②完成标准经胸超声心动图采集。排除标准:超声心动图多普勒图像不完整者。本研究经南京大学医学院附属鼓楼医院医学伦理委员会批准(批号:2024-

331-01)。本研究豁免知情同意。

1.2 仪器与设备 模型构建与性能验证使用 Philips EPIC 5C、Philips EPIC 7C、Philips EPIC CVx、GE Vivid E9、GE Vivid E95 超声检查设备采集的图像,操作时间及负荷实验使用 Philips EPIC 7C 超声诊断仪,S5-1 探头。AI 测量部署于本地工作站,硬件配置为:CPU:英特尔(Intel) i5-13400F,内存:16GB DDR4,硬盘:1TB SSD 固态硬盘,显卡: GeForce RTX 4060Ti 16GB。

1.3 方法

1.3.1 AI 多普勒参数测量模型构建 提取 1668 例超声心动图频谱数据(肺动脉瓣、主动脉瓣、二尖瓣前向频谱及 e' 间隔侧:室间隔侧组织多普勒 e' 峰;e' 侧壁侧:左室侧壁侧组织多普勒 e' 峰。其他为非目标切面的多普勒图像,不在本次研究的范围内。),由两名医生共同对其进行切面分类及测量,作为模型训练的金标准,训练集、验证集比例为 4 : 1。切面分类选用经典的神经网络 ResNet50 架构(如图 1a 所示),以提取图像的深层特征,进行频谱测值图像切面分类,输出相应的类别概率分布。

多普勒测量模型将目标检测和关键点检测技术的结合,精确地定位频谱图像中的目标区域,有效地捕捉到频谱中的关键特征。目标检测网络模型本文选用 YOLO v5 提取频谱图像的心动周期。它通过单个神经网络同时执行目标检测和分类,其网络模型结构示意图如图 1b 所示。YOLO v5 的模型结构由骨干网络、颈部网络和头部网络三部分组成。骨干网络采用轻量级 CSPDarknet-53,通过引入跨阶段局部连接(CSP)结构,在保证检测精度的同时降低计算量与内存占用。颈部网络结合特征金字塔(FPN)与金字塔注意力网络(PAN),FPN 向下传递强语义特征,PAN 向上传递定位特征,实现多尺度特征聚合。头部网络包含多个检测头,分别负责不同尺度的目标检测,输出边界框、类别概率及置信度分数,便于过滤低置信度检测结果。

关键点检测网络选用 HRNet,以主动脉前向流速多普勒图像为例,其结构如图 1c 所示。HRNet 由四个阶段组成,每阶段包含四个块操作。每阶段结束后拓展低分辨率支流作为下一阶段输入,通过反复交换平行流信息实现多分辨率融合,保留多尺度特征图以提升检测识别能力。与多数传统网络不同,HRNet 在整个网络中始终维持高分辨率特征图,有效捕捉细节与精细结构,并采用并行连接结构促进不同分辨率特征图间的信息流动,增强对物体整体与局部结构的理解能力。




图1 本研究中切面分类、目标检测及关键点检测模型网络架构 a;ResNet50 架构(切面分类);b;YOLOv5 模型网络结构(心动周期检测);c: HRNet 模型网络结构(频谱关键点检测)

1.3.2 AI 模型测量准确性验证 AI 模型部署于本地后,医生对患者进行常规扫查和测量,获取主动脉瓣(Ao)、肺动脉瓣(PA)、二尖瓣 E 峰、二尖瓣 A 峰、室间隔侧组织多普勒 e' 峰及左室侧壁侧组织多普勒 e' 峰,在医生不知道 AI 是否测量的状态下 AI 模型实时测量多普勒参数测值存于后台,对医生测量值与 AI 测量值进行对比,验证模型测量的准确性。

1.3.3 检查时间及操作负荷的测量方法 两组患者采集时间为不同周的周一至周五,以尽量减少患者基线差异及医生疲劳度对数据的影响。检查时间为第一个探查切面开始至最后一个探查切面结束,不包含患者体位摆放及擦拭皮肤时间,医师一手持探头扫查切面,另一手操作设备完成测量,测量过程包括按键点击与轨迹球滚动。其中,轨迹球

滚动产生独特的重复角速度,是衡量操作负荷的理想指标。本研究将姿态测量传感系统(厂家:深圳维特智能科技有限公司,型号:WT9011DCL-BT50)佩戴于医师操作设备的手背侧,同时通过视频设备录制每例患者检查过程中的手部操作视频。利用时间标尺,将传感器记录的角速度与视频动作进行比对,识别并计数轨迹球操作次数,同时记录静止时间(≥ 1 秒)。通过对 20 例检查视频的预试验验证,证实该方法可通过特定的角速度信号准确识别轨迹球操作次数。

医师佩戴姿态测量传感器,分别在开启 AI 辅助测量(图 2)与关闭 AI 辅助测量两种状态下完成检查,姿态测量传感器记录每例患者的检查时间及操作负荷。两组患者均按照指南要求完成心脏参数测量与图像留取。




图 2 AI 辅助测量二尖瓣瓣环侧壁侧 e' 测量显示界面

1.4 统计学方法 本研究使用 SPSS 26.0 与 R 统计分析软件。采用准确率、灵敏度、特异度、精确率及 F1 分数作为切面分类任务的评价指标采用组内相关系数(ICC)及 Bland-Altman 分析法评估参数测量的一致性。其他资料连续变量符合正态分布者以均值±标准差表示,组间比较采用独立样本 *t* 检验;不符合正态分布者以中位数(Q1, Q3)表示,采用 Mann-Whitney *U* 检验。有序分类变量(如瓣膜反

流分级)采用 Mann-Whitney *U* 检验,其他分类资料采用卡方检验。所有检验均为双侧检验。 $P<0.05$ 为差异有统计学意义。

2 结果

2.1 切面分类模型性能 在切面分类任务中, AI 模型对测试集中 645 个静态频谱图像数据进行推理,评估指标结果如表 1 所示,各切面识别准确率分别为 0.905、0.906、0.992、0.993、0.967。

表 1 各类多普勒图像测试集分类性能表现

类别	主动脉瓣频谱	肺动脉瓣频谱	二尖瓣频谱	e' 间隔侧	e' 侧壁侧	其他
样本量(例)	138	85	133	135	61	93
准确率	0.905	0.906	0.992	0.993	0.967	1.000
精确率	0.940	0.895	1.000	0.985	0.983	0.949
召回率	0.906	0.906	0.992	0.993	0.967	1.000
F1 分数	0.923	0.901	0.996	0.975	0.974	0.974

2.2 多普勒参数测量模型性能 AI 模型与医生在各多普勒参数测量中的一致性分析结果见表 2。ICC 分析显示, Ao、PA、二尖瓣 E 峰、二尖瓣 A 峰、室间隔侧组织多普勒 e' 峰及左室侧壁侧组织多普勒 e' 峰的 ICC 分别为 0.9963、0.9966、0.9967、0.9944、0.9902 及 0.9939, 95% 置信区间均 0.99 ~

1.00, 均 $P<0.001$ 。

Bland-Altman 法进一步评估两种测量方法的绝对一致性(图 3)。所有多普勒参数的散点图中,绝大多数数据点均落在 95% 一致性界限以内,且偏倚均接近于 0,未见明显的比例偏倚或系统误差趋势。

表 2 AI 模型与医生测量各多普勒参数的组内相关系数(ICC)

测量参数	样本量	ICC	95% 置信区间	<i>P</i>
Ao	104	0.9963	0.99~1.00	0.00
PA	131	0.9966	0.99~1.00	0.00
E 峰	131	0.9967	0.99~1.00	0.00
A 峰	116	0.9944	0.99~1.00	0.00
e' 间隔侧	133	0.9902	0.99~0.99	0.00
e' 侧壁侧	132	0.9939	0.99~1.00	0.00

Ao: 主动脉瓣频谱峰值流速; PA: 肺动脉瓣频谱峰值流速; E 峰: 二尖瓣舒张早期峰值流速; A 峰: 二尖瓣舒张晚期峰值流速; e' 间隔侧: 室间隔侧组织多普勒 e' 峰; e' 侧壁侧: 左室侧壁侧组织多普勒 e' 峰




图 3 AI 模型与医生测量各多普勒参数的 Bland-Altman 一致分析 a:主动脉瓣频谱峰值流速;b:肺动脉瓣频谱峰值流速;c:二尖瓣舒张早期峰值流速;d:二尖瓣舒张晚期峰值流速;e:室间隔侧组织多普勒 e' 峰;f:左室侧壁侧组织多普勒 e' 峰

2.3 AI 辅助测量对检查时间及操作负荷的影响

2.3.1 两组患者基线数据对比 两组患者在室壁厚度、左心室收缩及舒张末期内径、二尖瓣 E 峰流速及主动脉瓣前向流速等指标上差异有统计学意义($P<0.05$),AI 辅助组室壁厚度及左室大小略小于非 AI 辅助组;而在年龄、性别、瓣膜病变程度、

左心室射血分数、心房大小、肺动脉瓣前向流速、二尖瓣 A 峰流速、组织多普勒参数、肺动脉高压及先天性心脏病发生率、声窗条件等多个方面差异均无统计学意义($P>0.05$)。两组患者基线特征高度可比,操作时间及操作负荷具有良好的可比性。见表 3。

表 3 非 AI 测量辅助组与 AI 辅助测量组基线数据

项目		AI 辅助组	非 AI 辅助组	统计量	P
结构参数	主动脉内径(mm)	30.0(27.5,32.0)	30.0(27.6,32.0)	$U=38442.500$	0.812
	室间隔厚度(mm)	8.7(8.0,9.5)	9.0(8.0,10.0)	$U=46441.000$	0.001
	左室舒张末内径(mm)	46.0(44.0,48.4)	47.0(45.0,49.0)	$U=47602.000$	0.007
	左室收缩末内径(mm)	30.0(29.0,32.0)	30.5(29.0,32.1)	$U=43971.000$	0.025

项目		AI 辅助组	非 AI 辅助组	统计量	P
多普勒参数	左室后壁厚度(mm)	8.4(8.0,9.0)	8.8(8.0,9.3)	U=48255.500	0.012
	左房前后径(mm)	35.0(32.0,37.5)	35.0(33.0,38.0)	U=51807.000	0.271
	右心房增大 [n(%)]	17(5.2)	24(7.3)	$\chi^2=1.252$	0.263
	右心室增大 [n(%)]	7(2.1)	11(3.3)	$\chi^2=0.901$	0.342
	E 峰(m/s)	0.7(0.6,0.8)	0.7(0.6,0.9)	U=47293.500	0.049
	A 峰(m/s)	0.9(0.8,1.0)	1.0(0.9,1.1)	U=50109.000	0.052
	E/A	0.9(0.7,1.1)	0.9(0.8,1.2)	U=46833.500	0.093
	e' 间隔侧(m/s)	0.07(0.06,0.09)	0.07(0.06,0.09)	U=47670.000	0.282
	e' 侧壁侧(m/s)	0.1(0.08,0.12)	0.1(0.09,0.12)	U=47619.500	0.239
	E/e'	8.6(6.9,10.1)	8.6(7.1,10.3)	U=48626.000	0.460
	PA(m/s)	0.9(0.8,1.0)	1.0(0.9,1.1)	U=50095.000	0.080
	AO(m/s)	1.4(1.2,1.6)	1.4(1.2,1.6)	U=48660.000	0.023
主动脉瓣病变情况 [n(%)]	主动脉瓣术后	1(0.3)	5(1.5)	$\chi^2=52176.000$	0.228
	主动脉瓣狭窄	0	1(0.3)		
	轻度及以下反流	325(98.5)	319(96.4)		
	中度反流	4(1.2)	5(1.5)		
	重度反流	0	1(0.3)		
二尖瓣病变情况 [n(%)]	二尖瓣术后	3(0.9)	3(0.9)	$\chi^2=53616.000$	0.511
	轻度及以下反流	325(98.5)	318(96.1)		
	中度反流	1(0.3)	9(2.7)		
	重度反流	1(0.3)	1(0.9)		
三尖瓣病变情况 [n(%)]	三尖瓣术后	3(0.9)	4(1.2)	$\chi^2=54122.000$	0.715
	轻度及以下反流	319(96.7)	316(95.5)		
	中度反流	6(1.8)	8(2.4)		
	重度反流	2(0.6)	3(0.9)		
其他	LVEF(%)	63.0(62.0,64.4)	62.7(61.9,64.0)	U=51717.000	0.303
	心肌梗死 [n(%)]	5(1.5)	7(2.1)	$\chi^2=0.333$	0.564
	先天性心脏病 [n(%)]	2(0.6)	5(1.5)	$\chi^2=1.290$	0.256
	肺动脉压力增高 [n(%)]	28(8.5)	24(7.3)	$\chi^2=0.347$	0.556

2.3.2 AI 辅助对检查时间及操作负荷的影响 AI 辅助测量对单例患者检查时间及操作负荷的影响与未使用 AI 辅助组相比, AI 辅助组的中位检查时间显著缩短(233.5 秒 vs 247.9 秒, $P<0.001$), 其中操作手的中位动作时间由 221.9 秒降至 202.8 秒

($P<0.001$), 而静止时间两组差异无统计学意义(31.3 秒 vs 27.8 秒, $P=0.068$)。在操作负荷方面, AI 辅助组的中位轨迹球操作次数由 50 次降至 45 次($P<0.001$)。见表 4。

表 4 AI 辅助测量对单例患者检查时间及操作负荷的影响

项目	AI 辅助组	未使用 AI 辅助组	U	P
单个检查时间(s)	233.5(214.5,264.5)	247.9(224.7,291.6)	-4.903	0.000
静止时间(s)	31.3(21.2,44.3)	27.8(20.0,41.9)	-1.825	0.068
动作时间(s)	202.8(186.0,229.3)	221.9(199.6,259.0)	-6.850	0.000
轨迹球操作数量(次)	45(39,52)	50(43,59)	-5.818	0.000

3 讨论

3.1 AI 模型测量准确性的分析与对比 研究表明, 所构建的深度学习模型在超声心动图多普勒参数的自动测量方面具有优良的准确性。模型切面分类的识别准确率介于 90.5%~99.3%, 多普勒参数测量与金标准的组内相关系数为 0.99, Bland-Altman 分析显示测量偏差趋近于零, 处于可接受的临

床范围内, 略高于国际上多个多普勒参数测量模型^[5, 10, 12~14]。预测误差主要集中于主动脉瓣频谱图像与肺动脉瓣频谱图像之间, 原因有三: ①图像质量不稳——增益过高或噪声致频谱边缘模糊; ②有效区域过小——彩色血流、标尺或文字遮挡关键结构; ③形态高度相似——两者均为收缩期单峰高速血流, 采集角度或增益变化时更难区分。此外,

探头角度偏移亦会改变频谱形态,进一步增加误判风险。Sahashi 等^[14]开发的 EchoNet-Measurements 模型在 9 项多普勒测量中与超声医师测量的平均覆盖概率约为 0.839,且模型性能在不同患者特征及不同超声设备厂商之间保持一致。Peng 等^[5]研发的 Auto-Doppler 系统在多普勒参数测量中的相关系数范围为 0.81~0.99,所有脉冲多普勒参数的绝对相对偏差均在 10%以内,组织多普勒参数则全部在 5%以内。此外,US2.ai 平台在多普勒参数测量中的组内相关系数也多在 0.90 以上^[10]。上述结果进一步证实了深度学习技术在超声心动图多普勒频谱分析中的可行性与可靠性。

与既往研究多采用回顾性、静态频谱图像资料不同^[12, 15, 16],本研究研发了专门用于超声心动图检查多普勒参数的实时识别与测量模型。模型构建阶段使用回顾性数据,而模型验证则采用前瞻性实时采集的数据。此外,我们未对患者基础情况进行严格筛选,均是通过叫号系统随机呼叫等待检查的患者,患者群体更具有代表性,是贴近临床的实战验证。在真实临床场景下,面对不断变化、充满干扰图像的动态超声界面,该模型仍能保持极高的准确性,体现了其在临床部署中的实用价值。

3.2 AI 辅助多普勒测量在时间效率与操作负荷方面的获益及普适性优势分析 本研究构建的 AI 多普勒测量模型在国内心脏超声“扫查-采集-测量-报告”一体化的诊疗模式下,AI 实时辅助多普勒参数测量使单例患者的检查时间中位数缩短了 14.4 秒,其中动态操作时间减少了 19.1 秒,轨迹球操作次数平均减少 5 次(降幅 10%)。两组患者的医生手部静止时间未见显著差异,提示检查时间的缩短主要源于操作负荷的减少,而非单纯的动作停顿缩短。这一结果进一步支持 AI 辅助测量通过降低手部精细操作频率,从而提升检查效率的职业健康价值。目前,多数心脏超声 AI 研究均在实验室环境下执行^[16, 17],针对真实临床操作时间与操作负荷的量化研究较少。Sakamoto^[10]等利用 US2.ai 平台对 2D 及多普勒数据进行 AI 实时处理与测量,结果显示测量时间缩短约 51%[(159±66)秒 vs (325±94)秒],数据采集时间减少 1.3 分钟。然而,该平台的验证流程是对已获取的动态图像 DICOM 数据进行分析并形成“零点击报告”,并非在医师扫查同时进行实时测量。这一模式适用于国外技师采集图像、医生离线诊断的工作流程,但与国内一体化实时工作模式存在差异。Hollitt 等^[11]使用集成 AI 自动测量、扫描助手及多平面成像功能的 GE Vivid E95 超声机,对 35 名受检者自身对照两次扫查,通过双机位

视频录制+人工逐次计数量化操作负荷,结果显示:与常规流程相比,AI 联合自动化方案显著缩短扫查时间 4.6 分钟,减少设备交互操作 271.9 次。Shiokawa 等^[18]在 30 例连续患者中使用 AI 辅助测量包括结构参数和多普勒参数,结果显示无论对熟练者或新手,操作时间均缩短,总体可达 27.6%。但这些研究将 AI 与自动化及多平面成像捆绑验证,未单独报告 AI 多普勒参数测量本身的准确性,且所采用的扫描助手(Scan Assist Pro)、AI 自动分割及多平面成像均为特定品牌超声机的内置专利功能,研究结论高度依赖特定设备的技术组合,难以推广至普适性 AI 测量模型。

与上述研究相比,本研究的独特贡献体现在以下三个方面:①真实临床实景下的前瞻性验证。本研究未对患者基础情况进行严格筛选,通过叫号系统随机招募待检患者,患者群体更具代表性,实现了贴近临床的实战验证。在动态、充满干扰的超声界面中,模型仍保持极高准确性,验证了其临床部署的实用价值。②使用姿态测量传感器客观量化操作负荷的减少。既往研究中“节省时间”的结论往往隐含操作负荷减轻的假设,但缺乏直接证据。视频录制+人工逐次计数的方式严谨但是巨大的人力投入限制了其研究的样本量,本研究首次使用姿态测量传感器,通过测量轨迹球操作次数、静止时间和动作时间的变化,将“时间节省”与“手部操作负荷减少”两个维度分开量化,为 AI 辅助降低重复性劳损风险提供了直接实证依据。单个超声心动图检查通常需要数百次设备交互操作(包括按键点击与轨迹球滚动),每次操作均涉及手腕和手指的精细运动。本研究中,AI 实时辅助使单例患者的检查时间中位数缩短 14.4 秒,其中动态操作时间减少 19.1 秒,轨迹球操作次数平均减少 5 次(降幅 10%)。以日均 45 例检查计算,每位超声医师每日可减少总检查时间 648 秒(10.8 分钟),动态操作时间 860 秒(14.3 分钟),轨迹球操作 225 次。这些重复性精细动作的显著削减,对于预防腕管综合征、腱鞘炎等职业性重复性劳损具有重要的职业健康意义。③实现普适性实时测量,突破设备依赖。虽然 US2.ai 平台可快速完成 30 余项参数自动测量并显著提速工作流程,但其“零点击”报告仍需将数据上传平台后处理,而非在扫查同时完成参数实时识别与标注。本研究将 AI 实时测量工具整合于国内日常超声诊疗流程,使医生能够实时监督测量结果,在不牺牲测量准确性的前提下显著缩短检查时间、减轻操作负荷。当前,除部分内置 AI 功能的特定品牌超声机外,全面实现实时测量仍面临技术整

合难题。本研究另辟蹊径,将超声机界面数据实时输入 AI 模型处理器,测量结果实时显示于超声机旁的显示器,可适用于现有大部分超声设备,在可推广性方面更具优势。

本研究存在以下局限性:①模型构建与性能验证均来源于单中心数据。尽管前瞻性验证阶段未对患者基础条件进行严格筛选,患者群体具有一定代表性,但不同中心之间超声设备、扫描习惯及图像质量的差异可能影响模型的泛化能力。此外,操作时间及负荷数据基于 Philips EPIC 7C 单一机型采集,不同机型之间的操作步骤和布局存在差异,可能对结果的外推性产生影响。后续需开展多中心、多机型的外部验证以全面评估模型的普适性。②AI 模型目前主要覆盖临床核心的多普勒参数(主动脉瓣、肺动脉瓣、二尖瓣 E/A 峰及组织多普勒 e' 峰),尚未纳入速度时间积分、腔室大小、LVEF 等结构功能参数等部分重要参数,未来需扩展模型的测量范围以满足更全面的临床需求。③前瞻性效率评估部分未采用随机分组设计,尽管通过不同周的采集安排在一定程度上减少了患者基线差异和医生疲劳度的影响,但随机对照试验仍是验证 AI 临床价值的更优设计,有待后续研究进一步完善。

【参考文献】

- [1] 国家心血管病中心. 中国心血管健康与疾病报告[M]. 北京: 中国协和医科大学出版社, 2025.
- [2] Madani A, Ong JR, Tibrewal A, et al. Deep echocardiography: data-efficient supervised and semi-supervised deep learning towards automated diagnosis of cardiac disease[J]. NPJ Digit Med, 2018, 1: 59.
- [3] Cheng H, Shi Z, Qi Z, et al. Deep learning-based video-level view classification of two-dimensional transthoracic echocardiography[J]. Biomed Phys Eng Express, 2025, 11(2): 10.
- [4] Kusunose K, Haga A, Inoue M, et al. Clinically feasible and accurate view classification of echocardiographic images using deep learning[J]. Biomolecules, 2020, 10(5): 665.
- [5] Peng G, Ling R, Liu X, et al. Formal validation of a deep learning-based automated interpretation system for cardiac structure and function in adult echocardiography[J]. Quant Imaging Med Surg, 2025, 15(4): 3093-3110.
- [6] Celestin B, Bagherzadeh SP, Santana E, et al. Artificial intelligence-based echocardiography in pulmonary arterial hypertension [J]. CHEST, 2026, 169(1): 207-219.
- [7] Karužas A, Miščikas L, Kiziela A, et al. Deep learning-driven automated assessment of left ventricular diastolic function in echocardiography[J]. Echocardiography, 2025, 42(9): e70290.
- [8] Ioannou A, Khouri MG, Kitai T, et al. Diagnosis of Cardiac Amyloidosis on Echocardiography Using Artificial Intelligence. Circ Cardiovasc Imaging, 2026, 19(4): e018991.
- [9] Krishna H, Desai K, Slostad B, et al. Fully Automated Artificial Intelligence Assessment of Aortic Stenosis by Echocardiography. J Am Soc Echocardiogr, 2023, 36(7): 769-777.
- [10] Sakamoto A, Kagiya N, Sato E, et al. Artificial intelligence-based automated echocardiographic analysis and the workflow of sonographers: a randomized crossover trial (AI-echo RCT) [J]. J Am Heart Assoc, 2026, 15(1): e045637.
- [11] Hollitt KJ, Milanese S, Joseph M, et al. Can automation and artificial intelligence reduce echocardiography scan time and ultrasound system interaction? [J]. Echo Res Pract, 2025, 12(1): 11.
- [12] Lane ES, Jevsikov J, Shun-shin MJ, et al. Automated multi-beat tissue doppler echocardiography analysis using deep neural networks [J]. Med Biol Eng Comput, 2023, 61(5): 911-926.
- [13] Jevsikov J, Ng T, Lane ES, et al. Automated mitral inflow doppler peak velocity measurement using deep learning [J]. Comput Biol Med, 2024, 171: 108192.
- [14] Sahashi Y, Ieki H, Yuan V, et al. Artificial intelligence automation of echocardiographic measurements [J]. medRxiv, 2025: 2025.86(10): 1021-1034.
- [15] Dhutia NM, Zolgharni M, Mielewicz M, et al. Open-source, vendor-independent, automated multi-beat tissue doppler echocardiography analysis [J]. The International Journal of Cardiovascular Imaging, 2017, 33(8): 1135-1148.
- [16] Gosling AF, Thalappillil R, Ortoleva J, et al. Automated spectral Doppler profile tracing [J]. J Cardiothorac Vasc Anesth, 2020, 34(1): 72-76.
- [17] Lane ES, Jevsikov J, Shun-shin MJ, et al. Automated multi-beat tissue Doppler echocardiography analysis using deep neural networks [J]. Med Biol Eng Comput, 2023, 61(5): 911-926.
- [18] Shiokawa N, Izumo M, Shimamura T, et al. Accuracy and efficacy of artificial intelligence-derived automatic measurements of transthoracic echocardiography in routine clinical practice [J]. J Clin Med, 2024, 13(7): 1861.

(收稿日期:2026-05-08;修回日期:2026-05-15)

(本文编辑:侯晓林)