

## 综述

## 人工智能辅助心电分析用于心血管疾病诊断的研究进展

黄晓红、曾俊童\*、胡圣懿综述, 郑哲审校

**摘要** 心电信号为临床诊疗提供重要的心血管功能状态信息, 基于人工智能(AI)技术的复杂心电信号分析逐渐成为近年来心血管疾病领域的研究热点。作为临床运用最广泛的心电信号源, 心电图(ECG)所记录与反映的心脏周期性电活动变化图像, 具有获取便捷、价格低廉、信息丰富的特点, 对心血管疾病的诊疗决策具有重要意义。另一方面, 光电容积脉搏波(PPG)信号作为一种新型心电信号, 常与可穿戴设备等结合以实现持续心电监测, 显示出其独特价值。本文总结了近年基于 AI 技术的 ECG 和 PPG 分析以辅助心血管疾病诊断的最新研究进展, 以及当前研究局限性和未来研究的关注重点。

**关键词** 人工智能; 心电信号; 心电图; 光电容积脉搏波; 疾病诊断

心电信号是心肌电活动产生的生物信号。近年来, 人工智能(AI)技术辅助的心电信号如心电图(ECG)和光电容积脉搏波(PPG)信号的分析逐渐成为研究热点<sup>[1]</sup>。在中国, 心血管疾病患病率处于持续上升阶段<sup>[2]</sup>, ECG 作为一种无创的心电监测手段, 对其有重要的诊断价值<sup>[3]</sup>。但对 ECG 的准确解读为临床运用的主要局限, 且 ECG 的解读规则长期无更新<sup>[4]</sup>。近年来, PPG 作为一种新兴心电信号, 已被证实与 ECG 之间存在高度相关性<sup>[5]</sup>。PPG 通过记录血管中血流量的变化反映心脏泵的状态, 基于 PPG 的心电参数测定已被广泛用于便携医疗设备中指氧、心率、血压等信号的连续监测中。

随着医疗大数据的发掘和应用, AI 技术在处理复杂医学信息方面展示出巨大潜力。机器学习(ML)作为运用最广泛的 AI 技术, 在自动分析和学习变量之间关联模式方面存在优势。深度学习(DL)通过模仿人脑多层神经网络结构与分析模式, 学习输入数据的内在规律和表现层次, 并进行自动预测。其中, 卷积神经网络模型(CNN)尤其擅长以图像为输入信号的预测任务, 因而在 AI 辅助心电信号波形分析中应用广泛<sup>[6]</sup>。

本综述总结了国内外近年来 AI 辅助 ECG (AI-ECG) 和 PPG 分析在心血管疾病诊疗中的最新研究进展, 并讨论目前研究的局限性与未来推广的关注重点。

## 1 有明确心电图诊断标准的疾病

### 1.1 缺血性心脏病

心肌缺血的常见 ECG 表现包括 ST 段或 T 波改变等, 但在临床诊疗中其灵敏度和特异度并不理想<sup>[7]</sup>。对于缺血性心脏病, 目前多数 AI-ECG 分析算法研究主要集中于急性冠状动脉综合征(ACS)。Al-Zaiti 等<sup>[8]</sup>利用一组前瞻性急诊胸痛患者( $n=745$ )的 ECG, 分别构建了三种预测 ACS 的 ML 模型, 并在另一组外部队列中( $n=499$ )进行验证。结果显示, 联合三种 ML 模型对 ACS 预测的 AUC 可达 0.82 (95%CI:0.77~0.86), 显著优于临床医师 AUC [0.67 (95%CI:0.61~0.74)], 同时其灵敏度达到 77%, 相比临床医师(40%)和商业心电图诊断软件(25%)均明显提高。此外, 一系列研究提示, ECG 中存在大量潜在急性心肌缺血相关信息有待开发。Bouzid 等<sup>[9]</sup>基于专家的识别与 ML 特征提取的方法, 从 544 个 ECG 的时间-空间特征中确定了 73 个同时具有生理学基础与数据关联性的心肌缺血特征, 并证实了由这些特征构建的逻辑回归模型在验证集( $n=499$ )中诊断 ACS 的灵敏度显著优于临床医师与商业 ECG 诊断软件(72% vs. 40% vs. 25%)。此类相关新型 ECG 特征对今后心肌缺血诊断规则更新有重要参考价值。

### 1.2 心律失常

近年来, 心律失常的 ECG 辅助分析与诊断成

基金项目: 北京协和医学院专项基金(2022E-SD02)

作者单位: 100730 北京市, 中国医学科学院 北京协和医学院 临床医学专业试点班(黄晓红、胡圣懿); 中国医学科学院 北京协和医学院 国家心血管病中心 阜外医院 国家心血管病临床研究中心 心血管疾病国家重点实验室 心外科(曾俊童、郑哲)

通信作者: 郑哲 Email: zhengzhe@fuwai.com \* 共同第一作者

中图分类号: R541.4 文献标识码: A 文章编号: 1000-3614 (2023) 02-0222-05 DOI: 10.3969/j.issn.1000-3614.2023.02.018

为 AI 算法的重要研究热点。Hannun 等<sup>[10]</sup>利用来自 53 549 例患者的 91 232 张单导联 ECG 训练了一个端到端的深度神经网络(DNN)模型,可将输入的 ECG 自动分为包括正常心律、噪音信号以及 10 种常见心律失常在内的 12 类预测结果。在包含 328 张 ECG 的独立验证集中,模型对各类心律失常预测的平均 AUC 约为 0.91,调和平均数(F1)显著优于心内科医师的平均水平(0.837 vs. 0.780)。研究者进一步将该算法迁移至一个外部公共 ECG 数据库中进行端对端训练并验证( $n=8\ 528$ ),得到相似的效能( $F1=0.830$ ),提示其存在较好的外推性。Zhu 等<sup>[11]</sup>的研究算法实现对有多个心律失常诊断的 ECG 识别,平均 F1 值达到 0.887,进一步验证了 AI 辅助 ECG 心律失常分析应用的广泛性。

心房颤动(房颤)在国内外 AI-ECG 研究中已初步取得较好的预测效果。Cai 等<sup>[12]</sup>开发了一种一维深度密集连接神经网络模型以识别 ECG 上房颤信息,该研究利用多中心 16 557 张 12 导联 10 s ECG 训练模型,模型在测试集的准确度与灵敏度分别达到( $99.35 \pm 0.26$ )%和( $99.19 \pm 0.31$ )%。除了识别 ECG 中已明确存在的房颤信号外,Attia 等<sup>[13]</sup>实现了在当前无明显房颤特征信号的 ECG 中分析并预测未来房颤发生;其研究假设此类患者在 ECG 上出现房颤特征性变化前心脏已经存在如纤维化等结构变化,但其所反映的细微 ECG 变化难以被人眼所识别。因此,该团队利用来自 180 922 例患者的 649 931 张窦性 ECG,训练并验证了一个可通过分析无明确房颤特征的 ECG 来预测患者既往是否曾发生过房颤的 CNN 算法。在一个包含 3 051 例(8.4%)曾有至少一次明确房颤的患者测试集中,所训练的 AI 辅助算法实现正确预测的 AUC 可达 0.87(95%CI:0.86~0.88),提示基于 CNN 图像识别技术的 ECG 辅助分析算法对于细微、非特异性房颤特征的识别存在一定可行性。

## 2 无明确 ECG 诊断标准的疾病

许多心血管疾病尽管缺乏明确 ECG 诊断标准,但其相关的心脏结构与功能变化仍有可能引起 ECG 改变。因而,利用 AI 技术分析相关 ECG 并进行预测,有望用于提高疾病诊断前概率,辅助高危人群的早期诊疗。

### 2.1 左心功能不全

左心功能不全与相关临床危险因素、B 型利钠肽、某些心电图特征等显著相关,但其预测效能均欠佳,疾病筛查的成本-效益比有待考量<sup>[14]</sup>。为提高基于 ECG 信息的左心室功能不全的诊断效能,Attia 等<sup>[15]</sup>

纳入来自 44 959 例患者的 12 导联 ECG 构建了一个预测左心室收缩障碍(LVSD)的 CNN 模型,该模型在 52 870 例患者的外部验证中取得了较好的预测效果(AUC:0.93)。同时,即使被该模型识别为阳性、但实际上目前非 LVSD(即假阳性)的患者,其未来发生 LVSD 的风险相比阴性患者升高 4 倍以上,提示模型预测结果存在一定预后危险分层价值。Jentzer 等<sup>[16]</sup>进一步构建了一个 LVSD 死亡风险预测 AI-ECG 模型,预测结果与住院死亡率(校正后 OR=1.05,95%CI:1.03~1.08)及 1 年死亡率(校正后 HR=1.04,95%CI:1.03~1.05)相关。同样,Kagiyama 等<sup>[17]</sup>构建了一个预测左心室舒张速度的 AI-ECG 模型,其内部验证和外部验证平均绝对误差分别为 1.46 cm/s 和 1.93 cm/s,提示 ECG 有望作为左心舒张障碍的初步预测手段。

### 2.2 肥厚型心肌病(HCM)

HCM 存在相应的非特异 ECG 表现(如电轴左偏、左心室高电压、T 波倒置和异常 q 波等)。Ko 等<sup>[18]</sup>纳入梅奥诊所 3 060 例 HCM 患者及 63 941 例对照,训练并验证了一个 HCM 的 CNN 预测模型,AUC 可达到 0.95(95%CI:0.94~0.97);亚组分析提示该模型在年轻人(<40 岁)中的诊断效能尤其好。Tison 等<sup>[19]</sup>基于 36 186 张 12 导联 ECG 所构建的 CNN-ECG 模型在结合临床变量基础上对 HCM 预测的 AUC 可达到 0.91(95%CI:0.90~0.92)。研究者进一步发现,对该模型 HCM 预测具有高度提示意义的 ECG 特征包括 V<sub>1</sub> 导联 ST-T 段后半段、P 波时长、QT 间期、PR 间期等。

### 2.3 心脏瓣膜病

超声心动图为心脏瓣膜疾病的主要评估与诊断方式<sup>[20]</sup>,但 ECG 中也存在许多疾病相关信息。Kwon 等<sup>[21]</sup>纳入 32 186 张 ECG 构建了一个预测主动脉狭窄(AS)的 CNN 模型,在 10 865 张 ECG 构成的外部验证队列中,该模型的 AUC 可达到 0.861(95%CI:0.858~0.863)。灵敏度分析提示,胸前导联 T 波为模型识别重度 AS 的关键 ECG 特征。Cohen-Shelly 等<sup>[22]</sup>利用梅奥诊所 258 607 份 ECG 也构建了一个 CNN 模型(AUC:0.85),在 15 年随访中显示,即使被模型预测为假阳性的患者,其发生中重度 AS 的风险是真阴性患者的两倍以上(HR=2.18,95%CI:1.90~2.50),提示这种基于 ECG 的模型预测结果可作为 AS 疾病预测的潜在“生物标志”。基于类似的方法,Kwon 等<sup>[23]</sup>纳入 56 670 张 ECG 构建 CNN 模型以预测中重度二尖瓣反流,也获得了较好的预测效能(AUC:0.877),提示 AI 分析技术有望提

高多种心脏瓣膜病的 ECG 预测效能。

### 3 基于 PPG 信号的心电分析

相较传统数理统计分析, AI/ML 模型可自动提

取、整合大量潜在 PPG 信号特征用于模型预测(表 1), 利用高效的分析计算能力, 深入发掘变量间的复杂关联性, 提升模型整体的预测效果。

**表 1 基于 PPG 信号的心律失常监测研究**

| 研究项目(第一作者/发表年份)            | 国家及地区 | 采集设备 | 目标                  | 研究数据  | 信号处理方法                 | 研究结果                 |
|----------------------------|-------|------|---------------------|---|------------------------|----------------------|
| Poh/2018 <sup>[24]</sup>   | 美国    | 智能手机 | 房颤、窦性心律、异位起搏点、噪声的区分 | 来源于多中心公共数据库的 17 s PPG 信号片段(训练集/内部验证/外部验证: 149 048/18 638/2 029) | 深度卷积神经网络               | AUC:0.997            |
| Tison/2018 <sup>[25]</sup> | 美国    | 智能手表 | 房颤                  | 训练集为来自公共数据库的 9 750 段 PPG 信号, 外部验证队列为住院患者收集的 51 段 PPG 信号         | 8 层深度神经网络              | AUC:0.97             |
| Dörr/2019 <sup>[26]</sup>  | 德国、瑞士 | 智能手表 | 房颤                  | 前瞻性采集 672 例患者的 PPG 信号, 同时采集单导联心电图                               | 数学函数模型 <sup>[27]</sup> | 灵敏度:93.7%, 特异度:98.2% |
| Sun/2022 <sup>[28]</sup>   | 中国台湾  | 商业相机 | 房颤及其他异常心律           | 采集 453 例患者的面部图像, 通过函数分析重点区域的 RGB 信号构建了 7 320 段 30 s iPPG 信号     | 12 层深度神经网络模型           | 灵敏度:95.0%, 特异度:87.3% |

注: PPG: 光电容积脉搏波信号; iPPG: 视频光电容积脉搏波信号; 房颤: 心房颤动; RGB: 红绿蓝三原色

可穿戴设备因其无创、便携性, 可实现对于机体生物信号的连续监测与采集。智能手表为近年来最广泛普及与研究的可穿戴智能设备, 其已实现通过 PPG 信号采集以监测、预测心律失常事件的发生。2017 年基于美国大规模社区人群的 Apple 心脏研究入组 419 297 例苹果手表使用者, 在为期 117 d 的中位观察时间中, 共 2 161 例(0.52%)佩戴者收到不规则心律提示, 其中 450 例受试者完成后续确诊性 ECG 评估; 结果显示, 明确诊断房颤的比例(即阳性预测值, PPV)为 34%(95%CI:29%~39%)<sup>[29]</sup>。类似地, Guo 等<sup>[30]</sup>纳入 187 912 例华为智能手表使用者的华为心脏研究中, 262 例受试者收到可疑通知且完成确诊评估, 其中 227 例最终确诊存在房颤, PPV 为 91.6%。相比于 Apple 心脏研究, 华为心脏研究对 PPG 信号分析额外制定了一套更为严苛的规则判断算法, 以提高其发出的可疑房颤通知的准确性。尽管目前消费市场上已有多种具备类似心律监测功能的可穿戴设备, 但达到医疗器械监管要求的设备数量仍较少。

由于可穿戴设备需要与人体直接接触采集 PPG 信号, 因而易受采集部位移动带来的影响。近年来, 出现了以分析现成视频影像中监测部位光线颜色变化进而提取出视频 PPG (iPPG) 的非接触式 PPG 技术, 以期用于广泛人群中更优成本-效益比的房颤筛查。Yan 等<sup>[31]</sup>通过智能手机摄像头采集 217 例住院患者的面部视频录像, 进而提取 iPPG 信号并分析其脉搏间变异性, 以实现房颤检出。研究结果显示, 基于 iPPG 的房颤监测灵敏度和特异度分别为 95%

和 96%, 且与同期采集的指尖 PPG 信号监测房颤的结果具有高度一致性( $k=0.86$ , 95%CI:0.79~0.93), 初步验证了分析 iPPG 用于房颤监测的可行性。Yan 等<sup>[32]</sup>进一步利用 iPPG 采集的非接触特点, 将 5 例患者同时拍摄于视频画面内, 并利用一个此前验证用于房颤监测的 DNN 算法<sup>[25]</sup>来分析上述多例患者的 iPPG。结果显示, 在区分房颤与窦性心律方面, 算法灵敏度可达到 93.8%, 特异度为 98.1%; 且同时将一段视频内 5 例患者均判断正确的概率为 79.7%。基于该研究所展示的非接触式、多人同时房颤监测场景, 将有望尝试于房颤大规模社区人群筛查。随着相关传感器技术进步以及基于 PPG 心电分析设备研究的开展, 未来在心律失常移动监测领域将涌现出更多相关研究与产品<sup>[33]</sup>。

#### 4 局限性及展望

尽管 AI 模型预测效果在多项研究中已取得令人满意的效果, 但在临床应用与推广方面仍存在较大阻碍, 未来的工作应注意以下几方面。

##### 4.1 AI 算法的外推性

目前 AI 辅助心电分析研究多由单中心开展, 其预测效能在外部研究的表现尚不明确。Attia 等<sup>[34]</sup>对其基于单中心 ECG 所训练的 LVSD 预测模型进行外部验证时, 模型灵敏度仅为 26.9%, 显著低于其原始训练人群(灵敏度:86.3%)。对于数据驱动的 AI 模型构建而言, 多中心的数据来源是训练数据体量与广度的保证。此外, 临床实践中不同中心、不同仪器所采集的心电信号种类与格式均可能存在差异, 这将显著影响模型于外部验证中的效能。因此,

多渠道来源的训练数据与广泛的外部验证, 应为此类 AI 模型临床应用的重点。目前, 已有公共数据库(如 PhysioBank、PhysioToolkit、PhysioNet<sup>[35]</sup>、PTB-XL<sup>[36]</sup>等)为基于心电信息的 AI 模型开发提供庞大且多样的数据来源。

#### 4.2 可解释性

AI 算法结果的解释性(“黑箱”问题)是限制其临床应用的主要困难, 也是包括监管部门、临床医师以及患者等多方参与者是否信任 AI 算法的重要前提。Lin 等<sup>[37]</sup>通过对不同面部区域的遮盖, 从而明确所开发的基于面部照片的冠心病 AI 算法预测的重点关注区域, 与既往文献报导的冠心病相关面部特征存在一致性。这在提示算法可能工作原理的同时, 提升了算法效果的可信度。类似地, Cohen-Shelly 等<sup>[22]</sup>借助显著性地图分析展示了算法关注的 ECG 重点区域。Bouzid 等<sup>[9]</sup>则通过结合专业领域知识与算法数据筛选, 共同提取 73 个与 ACS 相关的 ECG 特征, 进而利用这些特征构建了一个内在可解释的 ACS 预测算法。这类 AI 算法可解释性研究不仅增加了算法预测的可信度, 也有助于发现新的临床知识。

#### 4.3 AI 算法的临床场景与获益

目前基于 AI 算法的心电分析涉及疾病的筛查、诊断及预后等多种临床场景, 尚未明确其在实际临床诊疗中的最佳运用环节及适应证等, 且普遍存在回顾性数据采集、缺乏严格外部人群验证等问题, 仍应通过开展前瞻性临床试验来论证其是否能够带来临床获益。Glissen 等<sup>[38]</sup>开展的全球首个验证 AI 算法临床有效性的独立外部随机对照临床试验, 论证了在临床中医师在基于结肠镜视频的 AI 辅助下, 相比单纯医师常规诊疗的腺瘤漏诊率降低近 36%, 单次肠镜平均腺瘤检出率增加近 33%, 明确了该 AI 算法的临床应用场景及获益。

#### 5 总结

心电信号如 ECG、PPG 在临床具有重要应用价值, AI 技术有望充分发掘其中大量未知信息、提高心电信号分析的预测效果。目前, 基于 AI 技术的心电信号分析模型已在多种心血管疾病的诊断中展示出较高的预测效果。搭载于可穿戴设备的 PPG 信号采集可实现长程、持续的心律监测, 而非接触式的 iPPG 信号则有望进一步提高疾病筛查的效率。目前研究的主要局限性包括模型训练与验证的数据库来源单一、缺少高质量的外部人群验证、模型机制与结果的可解释性工作较不足等方面。因此, 未来研

究应将模型外推性、可解释性以及真实临床场景评估作为研究的重要方向。

**利益冲突:** 所有作者均声明不存在利益冲突

#### 参考文献

- [1] Nagarajan VD, Lee SL, Robertus JL, et al. Artificial intelligence in the diagnosis and management of arrhythmias[J]. *Eur Heart J*, 2021, 42(38): 3904-3916. DOI: 10.1093/eurheartj/ehab544.
- [2] 中国心血管健康与疾病报告编写组. 中国心血管健康与疾病报告 2021 概要 [J]. *中国循环杂志*, 2022, 37(6): 553-578. DOI: 10.3969/j.issn.1000-3614.2022.06.001.
- [3] Kligfield P, Gettes LS, Bailey JJ, et al. Recommendations for the standardization and interpretation of the electrocardiogram: part I: the electrocardiogram and its technology: a scientific statement from the American Heart Association Electrocardiography and Arrhythmias Committee, Council on Clinical Cardiology; the American College of Cardiology Foundation; and the Heart Rhythm Society: endorsed by the International Society for Computerized Electrocardiology[J]. *Circulation*, 2007, 115(10): 1306-1324. DOI: 10.1161/CIRCULATIONAHA.106.180200.
- [4] Reichlin T, Abacherli R, Twerenbold R, et al. Advanced ECG in 2016: is there more than just a tracing?[J]. *Swiss Med Wkly*, 2016, 146: w14303. DOI: 10.4414/sm.w.2016.14303.
- [5] 陈真诚, 于邦文, 梁永波, 等. 基于光电容积脉搏波信号与心电信号相关性的研究 [J]. *生物医学工程研究*, 2019, 38(3): 370-375. DOI: 10.19529/j.cnki.1672-6278.2019.03.22.
- [6] Feeny AK, Chung MK, Madabhushi A, et al. Artificial intelligence and machine learning in arrhythmias and cardiac electrophysiology[J]. *Circ Arrhythm Electrophysiol*, 2020, 13(8): e007952. DOI: 10.1161/CIRCEP.119.007952.
- [7] Hamm CW, Bassand JP, Agewall S, et al. ESC guidelines for the management of acute coronary syndromes in patients presenting without persistent ST-segment elevation: the Task Force for the Management of Acute Coronary Syndromes (ACS) in Patients Presenting Without Persistent ST-segment Elevation of the European Society of Cardiology (ESC)[J]. *Eur Heart J*, 2011, 32(23): 2999-3054. DOI: 10.1093/eurheartj/ehr236.
- [8] Al-Zaiti S, Besomi L, Bouzid Z, et al. Machine learning-based prediction of acute coronary syndrome using only the pre-hospital 12-lead electrocardiogram[J]. *Nat Commun*, 2020, 11(1): 3966. DOI: 10.1038/s41467-020-17804-2.
- [9] Bouzid Z, Faramand Z, Gregg RE, et al. In search of an optimal subset of ECG features to augment the diagnosis of acute coronary syndrome at the emergency department[J]. *J Am Heart Assoc*, 2021, 10(3): e017871. DOI: 10.1161/JAHA.120.017871.
- [10] Hannun AY, Rajpurkar P, Haghpanahi M, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network[J]. *Nat Med*, 2019, 25(1): 65-69. DOI: 10.1038/s41591-018-0268-3.
- [11] Zhu H, Cheng C, Yin H, et al. Automatic multilabel electrocardiogram diagnosis of heart rhythm or conduction abnormalities with deep learning: a cohort study[J]. *Lancet Digit Health*, 2020, 2(7): e348-e357. DOI: 10.1016/s2589-7500(20)30107-2.
- [12] Cai W, Chen Y, Guo J, et al. Accurate detection of atrial fibrillation from 12-lead ECG using deep neural network[J]. *Comput Biol Med*,

- 2020, 116: 103378. DOI: 10.1016/j.combiomed.2019.103378.
- [13] Attia ZI, Noseworthy PA, Lopez-Jimenez F, et al. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction[J]. *Lancet*, 2019, 394(10201): 861-867. DOI: 10.1016/s0140-6736(19)31721-0.
- [14] Siontis KC, Noseworthy PA, Attia ZI, et al. Artificial intelligence-enhanced electrocardiography in cardiovascular disease management[J]. *Nat Rev Cardiol*, 2021, 18(7): 465-478. DOI: 10.1038/s41569-020-00503-2.
- [15] Attia ZI, Kapa S, Lopez-Jimenez F, et al. Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram[J]. *Nat Med*, 2019, 25(1): 70-74. DOI: 10.1038/s41591-018-0240-2.
- [16] Jentzer JC, Kashou AH, Lopez-Jimenez F, et al. Mortality risk stratification using artificial intelligence-augmented electrocardiogram in cardiac intensive care unit patients[J]. *Eur Heart J Acute Cardiovasc Care*, 2021, 10(5): 532-541. DOI: 10.1093/ehjacc/zaaa021.
- [17] Kagiya N, Piccirilli M, Yanamala N, et al. Machine learning assessment of left ventricular diastolic function based on electrocardiographic features[J]. *J Am Coll Cardiol*, 2020, 76(8): 930-941. DOI: 10.1016/j.jacc.2020.06.061.
- [18] Ko WY, Siontis KC, Attia ZI, et al. Detection of hypertrophic cardiomyopathy using a convolutional neural network-enabled electrocardiogram[J]. *J Am Coll Cardiol*, 2020, 75(7): 722-733. DOI: 10.1016/j.jacc.2019.12.030.
- [19] Tison GH, Zhang J, Delling FN, et al. Automated and interpretable patient ECG profiles for disease detection, tracking, and discovery[J]. *Circ Cardiovasc Qual Outcomes*, 2019, 12(9): e005289. DOI: 10.1161/CIRCOUTCOMES.118.005289.
- [20] 中华医学会心血管病学分会心血管影像学组, 北京医学会心血管病学分会影像学组. 中国成人心脏瓣膜病超声心动图规范化检查专家共识 [J]. *中国循环杂志*, 2021, 36(2): 109-125. DOI: 10.3969/j.issn.1000-3614.2021.02.002.
- [21] Kwon JM, Lee SY, Jeon KH, et al. Deep learning-based algorithm for detecting aortic stenosis using electrocardiography[J]. *J Am Heart Assoc*, 2020, 9(7): e014717. DOI: 10.1161/JAHA.119.014717.
- [22] Cohen-Shelly M, Attia ZI, Friedman PA, et al. Electrocardiogram screening for aortic valve stenosis using artificial intelligence[J]. *Eur Heart J*, 2021, 42(30): 2885-2896. DOI: 10.1093/eurheartj/ehab153.
- [23] Kwon JM, Kim KH, Akkus Z, et al. Artificial intelligence for detecting mitral regurgitation using electrocardiography[J]. *J Electrocardiol*, 2020, 59: 151-157. DOI: 10.1016/j.jelectrocard.2020.02.008.
- [24] Poh MZ, Poh YC, Chan PH, et al. Diagnostic assessment of a deep learning system for detecting atrial fibrillation in pulse waveforms[J]. *Heart*, 2018, 104(23): 1921-1928. DOI: 10.1136/heartjnl-2018-313147.
- [25] Tison GH, Sanchez JM, Ballinger B, et al. Passive detection of atrial fibrillation using a commercially available smartwatch[J]. *JAMA Cardiol*, 2018, 3(5): 409-416. DOI: 10.1001/jamacardio.2018.0136.
- [26] Dörr M, Nohturfft V, Brasier N, et al. The WATCH AF Trial: SmartWATCHes for detection of atrial fibrillation[J]. *JACC Clin Electrophysiol*, 2019, 5(2): 199-208. DOI: 10.1016/j.jacep.2018.10.006.
- [27] Koenig N, Seeck A, Eckstein J, et al. Validation of a new heart rate measurement algorithm for fingertip recording of video signals with smartphones[J]. *Telemed J E Health*, 2016, 22(8): 631-636. DOI: 10.1089/tmj.2015.0212.
- [28] Sun Y, Yang YY, Wu BJ, et al. Contactless facial video recording with deep learning models for the detection of atrial fibrillation[J]. *Sci Rep*, 2022, 12(1): 281. DOI: 10.1038/s41598-021-03453-y.
- [29] Perez MV, Mahaffey KW, Hedlin H, et al. Large-scale assessment of a smartwatch to identify atrial fibrillation[J]. *N Engl J Med*, 2019, 381(20): 1909-1917. DOI: 10.1056/NEJMoa1901183.
- [30] Guo Y, Wang H, Zhang H, et al. Mobile photoplethysmographic technology to detect atrial fibrillation[J]. *J Am Coll Cardiol*, 2019, 74(19): 2365-2375. DOI: 10.1016/j.jacc.2019.08.019.
- [31] Yan BP, Lai WHS, Chan CKY, et al. Contact-free screening of atrial fibrillation by a smartphone using facial pulsatile photoplethysmographic signals[J]. *J Am Heart Assoc*, 2018, 7(8): e008585. DOI: 10.1161/JAHA.118.008585.
- [32] Yan BP, Lai WHS, Chan CKY, et al. High-throughput, contact-free detection of atrial fibrillation from video with deep learning[J]. *JAMA Cardiol*, 2020, 5(1): 105-107. DOI: 10.1001/jamacardio.2019.4004.
- [33] Fuller D, Colwell E, Low J, et al. Reliability and validity of commercially available wearable devices for measuring steps, energy expenditure, and heart rate: systematic review[J]. *JMIR Mhealth Uhealth*, 2020, 8(9): e18694. DOI: 10.2196/18694.
- [34] Attia IZ, Tseng AS, Benavente ED, et al. External validation of a deep learning electrocardiogram algorithm to detect ventricular dysfunction[J]. *Int J Cardiol*, 2021, 329: 130-135. DOI: 10.1016/j.ijcard.2020.12.065.
- [35] Goldberger AL, Amaral LA, Glass L, et al. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals[J]. *Circulation*, 2000, 101(23): E215-E220. DOI: 10.1161/01.cir.101.23.e215.
- [36] Wagner P, Strodthoff N, Bousseljot RD, et al. PTB-XL, a large publicly available electrocardiography dataset[J]. *Sci Data*, 2020, 7(1): 154. DOI: 10.1038/s41597-020-0495-6.
- [37] Lin S, Li Z, Fu B, et al. Feasibility of using deep learning to detect coronary artery disease based on facial photo[J]. *Eur Heart J*, 2020, 41(46): 4400-4411. DOI: 10.1093/eurheartj/ehaa640.
- [38] Glissen Brown JR, Mansour NM, Wang P, et al. Deep learning computer-aided polyp detection reduces adenoma miss rate: a United States multi-center randomized tandem colonoscopy study (CADET-CS Trial)[J]. *Clin Gastroenterol Hepatol*, 2022, 20(7): 1499-1507. e4. DOI: 10.1016/j.cgh.2021.09.009.

(收稿日期:2022-06-10)

(编辑:汪碧蓉)