

·述评·

心电及影像大模型在心血管疾病中的应用与挑战

陈波^{1,2} 林肖健¹ 张萍¹¹清华大学附属北京清华长庚医院心血管内科,北京 102218; ²清华大学临床医学院,北京 102218

通信作者:张萍,Email:zhpdoc@126.com

【摘要】新一代人工智能技术正推动心血管疾病诊疗进入新纪元,其中基于海量数据预训练的大模型极具发展潜力。其通过自监督学习范式能够从影像、心电和各类检查数据中学习通用表征,在心血管疾病诊断预警、个性化治疗与决策支持、患者管理与远程监测等方面性能均明显得到提升。然而,大模型在临床运用中仍面临数据规模、模型性能和应用监管等多方面瓶颈制约。该文系统梳理了大模型在心血管疾病的创新应用、核心挑战及应对策略,并对其未来向高效、可靠、可信的临床辅助工具的演进路径进行了展望。

【关键词】 人工智能; 大模型; 心血管疾病

Large-scale electrocardiogram and imaging models in cardiovascular diseases: applications and challenges

Chen Bo^{1,2}, Lin Xiaojian¹, Zhang Ping¹¹Department of Cardiology, Beijing Tsinghua Changgung Hospital, Tsinghua University, Beijing 102218, China; ²School of Clinical Medicine, Tsinghua University, Beijing 102218, China

Corresponding author: Zhang Ping, Email: zhpdoc@126.com

根据世界卫生组织和全球疾病负担研究数据,心血管疾病每年导致 1 790 万至 1 800 万人死亡,占全球总死亡人数的 32% 左右,是全球范围内的主要死因,也是当今世界面临的最重大公共卫生挑战之一^[1]。传统的临床诊断与风险评估方法包括统计学风险评分(如基于人口统计学和传统危险因素的模型)、影像学检查(超声、CT、磁共振等)、电生理检测(如心电图)等。在一级预防与人群筛查场景中,临床仍高度依赖传统风险预测工具,例如美国人群众队列衍生的 Framingham 风险评分(用于估计未来 10 年总体心血管事件风险)、欧洲指南推荐并按风险地区校准的 SCORE2/SCORE2-OP(用于估计 10 年致死与非致死心血管疾病风险)、英国基层医

疗服务体系常用的 QRISK3(用于预测 10 年心血管疾病风险),以及基于中国人群开发与验证的中国动脉粥样硬化性心血管疾病风险预测模型(China-PAR)等^[2-6]。这类模型虽然在临床与公共卫生实践中具有可操作性,但他们都有一个共同特点——依赖有限数量的结构化变量(如年龄、性别、血压、血脂指标、吸烟、糖尿病等),且通常建立在特定地区/队列之上,需要进行地区化校准后方能外推。同时对专家经验依赖较强,且受限于高通量、标准化与自动化分析能力的不足,这些因素进一步制约了大规模精准筛查与早期干预目标的实现。

近年来,机器学习尤其深度学习技术迅速发展,其已被广泛应用于医学影像分析、信号处理、电

DOI: 10.3760/cma.j.cn112148-20251223-00901

收稿日期 2025-12-23 本文编辑 白洋

引用本文:陈波,林肖健,张萍.心电及影像大模型在心血管疾病中的应用与挑战[J].中华心血管病杂志,2026,54(2): 1-7. DOI: 10.3760/cma.j.cn112148-20251223-00901.



子病历分析、风险预测与分类等任务。随着卷积神经网络、循环神经网络及其变体的成熟,研究者开始将这些方法用于心血管疾病的诊断、分型与风险预测^[7-8]。然而,传统深度学习方法多以“任务为中心”的监督学习范式为主,常受到 3 类瓶颈制约:(1)模型通常针对单一任务与特定数据分布进行训练,跨中心、跨设备或跨人群时易受分布偏移影响;(2)性能提升高度依赖高质量标注与人工特征设计或强先验约束;(3)面对影像、信号、文本、结构化临床变量等高维异构数据时,多模态联合建模的成本与复杂度明显上升,从而限制了其在临床应用的规模化和可持续扩展。

为应对“多模态、高异质、弱标注与跨场景泛化”的现实问题,面向医学的大模型应运而生,推动了心血管智能分析从任务驱动的监督学习向预训练驱动的通用表征与可迁移能力转变。大模型主要指在大规模数据上进行预训练,在学习到具有代表性的通用特征后,通过少量数据进行模型微调然后适配多种具体临床任务。大模型的引入正在改变心电与心脏影像的建模方式:在心电方面,基于大规模数据训练的心电图大模型被用于跨任务泛化与多场景迁移,可作为通用基座模型支撑多种诊断/预测任务^[9];在影像方面,视觉-语言大模型通过学习超声视频与专家报告之间的对应关系,为超声心动图的解释与临床语义对齐提供了新的可扩展范式^[10]。

一、大模型在心血管疾病中的应用

1. 疾病诊断与风险预测:在心电图智能分析领域,Zhang 等^[11]和 Jin 等^[12]分别对原始心电信号进行随机掩蔽,并构建无标签预训练框架对掩蔽后的心电信号进行编码并补全掩蔽部分或预测波形变化,以学习与下游任务无关的通用特征,进而用于疾病诊断、风险预测与报告生成等多种下游任务;研究结果表明,此类预训练底座在心律失常识别与风险分层等任务上,相较于传统深度学习方法曲线下面积和准确率等指标都得到了一定程度提升,并在少标注或数据分布与预训练数据相差较大时表现出更好的鲁棒性。除上述无标签预训练外,Tian 等^[13]和 Xie 等^[14]进一步引入诊断文本/报告作为配对信息,构建心电-文本的跨模态对比预训练/对齐学习框架,以学习心电特征和疾病语义之间的对应关系。此类方法由于使用了诊断文本/报告作为训练数据的一部分,严格意义上更接近弱监督/有监督的对比学习与跨模态对齐,即让同一患者的心电与

报告描述对应更紧密,并与不相关的报告描述拉开差异。这种模型构建方式可直接利用医师在临床报告中的诊断描述,使预训练模型更适用于疾病识别、报告生成、信号预测与智能问答等任务。从医师实际诊疗流程角度,用此类心电-文本对齐方式辅助生成报告、定位关键异常,能有效减少医护人员的工作量,但生成内容仍需医师审核以降低“幻觉”(编造/虚构内容)风险。

在心脏影像分析领域,将 SAM 为代表的可提示分割大模型引入影像分析过程并适当对模型进行微调,可使模型具备多模态、多器官、多任务的通用分割能力,如 MedSAM^[15];结合添加适配器等参数高效迁移策略可进一步提升模型在医学场景中的可用性^[16];在更大规模医学二维数据上对 SAM 进行扩展与细化的工作也进一步增强了模型的泛化能力,如 SAM-Med2D^[17]。影像-文本大模型可利用超声视频与临床报告的配对信息进行训练,使模型支持更贴近临床流程的影像解释、相似病例检索等任务,这种方式也减少了对数据精细标注的需求^[18];针对心脏磁共振,相关研究通过在大规模数据上进行预训练获取影像的通用特征,然后添加不同任务网络对预训练模型进行微调,使模型在磁共振影像分割、心脏功能评估等任务上表现更加稳定,也更容易迁移到其他任务或新数据源^[19];针对三维心脏 CT,同样通过影像-报告文本进行配对训练,使模型更好地整合影像信息和临床描述,为复杂异常的检测及相关临床预测提供支持^[20]。

2. 个性化治疗与决策支持:目前在心血管领域,大模型在个性化治疗与决策支持方面的运用仍相对有限,既往研究多停留在风险分层、预防干预建议与临床管理辅助等上游环节,例如通过整合人口统计学、传统危险因素、生活方式与辅助检查数据(影像、心电等)提供个体化风险评估与预防建议^[21],以及利用心电与心脏磁共振的预训练/跨模态表征学习实现心脏功能评估^[22]。但严格意义上的治疗决策,如药物选择与剂量优化、手术时机决策、围手术期策略调整等不仅需要进行各变量的相关性预测,更需要可解释的因果推断、风险-获益权衡以及前瞻性临床验证,这也是其在临床推进相对缓慢的关键原因之一。当前主要采用“大模型预训练+下游任务适配”的形式对个性化治疗和决策支持应开展探索^[15-17]。因此,大模型的治疗与决策支持应理解为:以大模型提供的标准化表征(结构、功能、语义)为底座,在下游以指南/路径为约束,实现

在医护人员主导下可追溯的对药物方案、治疗时机与随访管理的辅助决策支持。同时仍需在前瞻性验证、风险责任界定与合规审查等方面进一步完善。大模型在决策支持中的直接价值主要体现在：提供更一致的结构化量化结果(如分割结果和功能参数)、支持相似病例检索、辅助生成诊断报告等，降低医师对各种临床信息进行整合的负担，但并不等同于自动给出治疗处方。

3. 患者管理与远程监测：随着可穿戴设备、居家影像随访与互联网医院的普及，心血管疾病管理正从单次就诊转向跨时空连续监测。大模型通过可复用的通用特征，将远程数据快速转化为可对比、可追踪的临床指标与语义结论，降低对人工标注和专家读片的依赖。在实际流程中，其输出内容通常包括多次或连续测量的关键量化指标(如结构尺寸、功能参数、节律负荷等)、异常事件提示与风险分层标签，以及便于医护人员快速审核的随访结论或报告。以影像结构化为例，MedSAM 及其在医学二维大规模数据上的扩展工作，使得不同模态、不同器官的分割与结构提取具备更强的通用性与可复用性，为远程随访场景下的心脏/心肌等结构测量提供“标准化底座”^[15]，配合高效的参数适配器(如 Med-SA)，在不明显增加部署成本的前提下，实现模型的快速本地适配，便于在基层医院推广和持续应用^[16]。视觉-语言大模型把“影像-报告”对齐后纳入统一语义空间，例如 EchoCLIP 通过学习超声视频与临床报告的对应关系，实现了高精度的基于超声的病例检索、病症解读等多种任务^[10]。因此，患者管理与远程监测的技术路线可从单点预测升级为大模型驱动的纵向表型追踪+语义一致的随访报告生成/辅助解读，为慢性非传染性疾病的分层管理、复诊触发与个体化随访频率调整提供更具推广潜力的路径。总体而言，该路线的优势主要体现在提升效率和结果一致性：一方面可减少重复标注和集中读片带来的工作负担，另一方面也有助于统一多中心随访路径，并为异常触发和复诊决策提供相对清晰的数据支撑。但目前相关研究多停留在回顾性分析或原型系统验证阶段，其在临床实际运用的效果仍有待进行前瞻性评估。

4. 心血管疾病机制研究与生物标志物探索：相较于诊断与风险预测，心血管疾病的机制研究与生物标志物探索对数据与证据链的要求更高，不仅需要稳定、可复现的表型刻画，还需要将表型与病理过程、临床事件及治疗反应建立可解释关联。近期

大模型在心血管影像中的发展使影像表型有望成为可量化生物标志物。一方面，大模型通过在海量磁共振图像上自监督学习获得稳健特征，并将其用于磁共振图像分割、功能诊断和评估等下游任务，进而更准确地提取结构-功能相关的连续表型，如心腔容积、壁厚、收缩舒张功能指标等用于机制关联分析^[19]。另一方面，通用分割大模型(如 MedSAM 及其扩展)使跨中心、跨设备的结构化提取结果一致性更高，有利于构建大规模可比对的影像表型队列，并进一步支持表型分层与亚型划分^[17]。更重要的是，视觉-语言模型将影像与临床叙述对齐，把可量化表型与临床语义表征统一到同一空间，例如 Cardiac-CLIP 在三维心脏 CT 的图文对齐框架下展示了对复杂异常情况的表征和识别能力，为建立心脏影像的定量表型与临床语义(包括诊断、症状群及疾病亚型特征)之间的关联提供了新的思路^[20]。需要强调的是，机制与标志物的有效性评估通常不能仅依据单次相关性分析，而应至少完成外部队列复现、混杂控制/因果敏感性分析，并在纵向随访或干预前后验证其与临床结局或治疗反应的一致性。总体而言，本领域机制与标志物研究正在从依赖少数人工预设、可解释性强的量化指标(如左心室射血分数、心室尺寸等)与小样本相关性分析的传统范式，转向大模型驱动的大规模、可复现“表型抽取+语义对齐+迁移泛化”的组合路线，为后续与组学、病理与干预反应的跨模态机制验证奠定方法学基础。

二、大模型的技术优势

1. 多模态数据整合：现代的深度学习和混合深度学习架构能够将不同来源的数据(如心电、心脏影像、临床数据、检查结果、人口统计信息等)融合到一个统一的模型中。这种多模态数据的融合使得模型能够更全面、准确地进行疾病分类、风险评估和早期预警。近年来，许多研究尝试将心电数据与医学影像、临床及实验室数据结合起来，以构建更强大的心脏疾病分类模型。例如 Alsekait 等^[23]提出的 Heart-Net 多模态深度学习框架结合了心脏磁共振与心电数据，成功提升了心脏疾病的诊断精度。Zhao 等^[24]提出了一个专门结合心电信号和诊断报告的大型多模态模型 ECG-Chat，能够生成临床报告并支持多模态对话，这为基于心电的自动化诊断和报告生成提供了新思路。Yang 等^[25]系统梳理了磁共振、CT/冠状动脉 CT 血管成像与超声等心血管影像研究进展，指出单一模态模型多局限于单

任务,而多模态信息融合更贴近临床“多源信息综合判断”的工作思路,可提升疾病诊断与结局预测的稳定性与可解释性。

2. 高精度与泛化能力:大模型在处理复杂、高维、庞大的各类数据时表现出更高的准确性和自动化特征学习能力,在不同任务和数据集上的泛化能力都有所提升。SuPreME通过对心电报告进行监督预训练,能够在缺乏标签的情况下进行精准分类,展现了大模型在零样本学习中的强大潜力^[26]。尤其是在心脏磁共振图像分割与功能结构评估中,深度学习可实现标准化、自动化分析,适用于大规模临床研究。在四维血流磁共振成像中,深度学习算法已被用于左心室自动分割及血流、容积、血流动力学量化,精度与可重复性均达到较高水平^[27]。深度学习模型在CT、心脏磁共振、超声心动图、单光子发射计算机断层扫描等多种心血管成像模态下均能实现心肌疾病检测,说明其具有良好的跨模态泛化能力。此外,通过人工智能驱动的图像重建(去噪、运动伪影修正、超分辨率等)还可提高成像质量,诊断/分析精度高于传统成像。对于心电图,深度学习模型能够识别传统方法难以捕捉的微小但具有临床意义的信号变化,从而实现对病变的早期识别^[28]。

3. 可扩展性与临床大规模部署潜力:深度学习框架完成构建及验证后(包括数据预处理、模型训练、验证、测试和部署流程),便可高效扩展到大量心电、影像、电子健康记录数据。特别是对于检测设备和专业人员等资源有限的国家和地区,使用成熟的深度学习技术进行自动化诊断、预警和风险评估,可以明显提高疾病的诊断率与防控水平。以跨模态预训练模型为例,CardiacNets仅借助心电数据即可进行心脏结构和功能评估、病变筛查,这为在资源受限地区开展心血管疾病筛查及高危人群的基线评估提供了一种低成本、易获取的有效解决路径^[22]。对于扫描版或纸版心电图像,Wang等^[29]提出了基于合成数据增强的深度学习处理流程,可将纸质心电图像经标准化预处理后实现自动识别与分类,使得在缺乏原始数字心电信号的场景下也能开展自动化分析。因此,只要构建好标准化、可自动化的模型与工作流程,就可将深度学习技术应用于大规模、常规临床筛查^[30]。

三、挑战与前景展望

1. 数据方面:在当前人工智能技术飞速发展的时代,数据逐步成为提升模型性能最重要的因素,

尤其对于旨在实现高精度与强泛化能力的医学大模型。然而临床医用数据依然面临数据规模、数据质量及数据异构性等方面的挑战。数据规模方面,罕见病与长尾病例数据严重匮乏,导致模型难以充分学习相关特征,在面对真实复杂病例时性能下降^[31-32]。同时,高质量标注极度依赖专家经验,现有精细标注数据规模远小于原始数据,限制了模型向精准诊断的进化。数据质量方面,采集噪声(如心电信号中的基线漂移与工频干扰)及残留噪声会影响模型的特征提取^[33]。此外,不同医师对困难数据的判读差异导致标签不一致,这使模型决策边界模糊,损害其准确性与可靠性。数据异构性与隐私壁垒同样制约了大模型的发展。各机构设备、采样设置与操作习惯不同造成数据分布差异,导致模型跨中心应用时泛化能力下降^[34-35];同时,患者隐私与法规限制使数据无法自由流通,阻碍了构建超大规模统一数据集,限制了模型性能的进一步突破。

为应对数据方面的挑战,未来心血管人工智能大模型需要重点突破小样本学习与智能标注技术,解决数据规模瓶颈。通过迁移学习和元学习等范式,使模型具备从少量罕见病例中快速学习的能力^[36];同时开发人机协同的智能标注平台,利用主动学习策略优先选择价值最高的数据供专家标注,大幅提升标注效率。此外,探索构建融合医学知识的自适应去噪算法,不仅能消除噪声,还能保留具有临床价值的细微特征。通过建立标准化的标注规范,提升数据一致性。在数据异构性与隐私壁垒方面,在保证数据“不出院”的前提下实现对模型的多中心协同训练,提升其泛化能力。

2. 模型算法方面:不同于其他领域直接对通用大模型进行适当微调便可用于实际生产过程,在医学领域的应用需要更加严格的解释和验证,同时医学数据的建模和分析也需要符合医学常识和准则。在心血管疾病智能分析过程中,心电图等生理信号的病理特征需要在时间尺度上进行综合分析,因此时序依赖与长程上下文建模的效果直接影响后续疾病诊断、风险评估等相关任务性能^[37]。传统的Transformer架构在处理超长序列时,因其自注意力机制的计算复杂度随输入序列长度呈平方级增长,计算成本高昂。虽有学者采用线性注意力等技术以尝试降低负担,但其在捕捉心电信号等复杂时空关联方面的有效性仍有待验证。同时,临床心血管诊疗需要融合心电、影像、病史等多模态数据,但当前领域缺乏统一、原生的多模态大模型架

构^[38]。现有方案多采用独立编码器处理不同模态后进行简单拼接,难以深入挖掘模态间复杂的非线性关联。此外,心血管领域的知识体系具有高度的严谨性、复杂性与逻辑依赖性,而当前主流大模型采用“通用预训练+医学微调”的范式,容易在学习中产生事实性错误或逻辑不一致,难以稳定掌握该领域精确的概念体系与复杂的诊断推理路径。这种“黑箱”训练方式也容易在处理复杂问题时产生“幻觉”,输出违背医学原理的结果,制约了模型的可靠性与临床适用性。

因此,突破心血管人工智能大模型性能瓶颈仍然需要从时序数据建模、多模态信息融合和医学可解释性研究3个方向深入探索。在时序建模上,心电图数据同时包含毫秒级的局部波形特征(如P波形态)和跨越数秒甚至更久的心跳节律,为同时有效建模这两种尺度的依赖关系,采用结合层次化注意力机制^[39]与状态空间模型^[40]的新架构能在保证计算效率的同时,分别专注于局部细节的解析与全局节律动态的捕捉。在多模态融合方面,将开发原生多模态架构,通过统一的表示空间实现心电信号、医学影像与临床文本的深度交互,内嵌的跨模态对齐模块能自动挖掘不同模态间的关联。在知识融合与可信度层面,将转向知识与数据双驱动范式,通过将医学知识图谱作为结构性约束嵌入训练过程,并开发因果推理模块,确保模型输出符合医学原理^[41]。

3. 临床转化与监管方面:要将大模型转化为临床可用的工具,其开发与评估应遵循分层递进的临床评价范式,同时需要在确保其预期用途与潜在风险相匹配的前提下,逐步积累有效性与安全性证据,如国际医疗器械监管机构论坛为软件型医疗器械SaMD制定临床评价指南的过程^[42]。大模型的监管审批较为复杂,现有医疗器械审批框架难以评估不断迭代的大模型,其“黑箱”特性使得决策过程透明度不足,增加了监管难度。另外,医疗责任界定困难,当模型诊断建议与医师判断冲突或出现错误时,责任归属问题尚未明确。此外,还需要克服医疗数据隐私保护、不同医疗机构数据标准化差异以及与实际临床工作流程整合等系统性障碍。除上述制度与流程方面的阻碍,大模型在临床使用中还普遍面临:输出不符合医学事实、推理与部署的计算成本较高,以及由数据偏倚与隐私合规引发的伦理风险。

面对这些挑战,需要建立适应人工智能特性的

新型监管体系。监管机构应开发一个贯穿人工智能医疗产品研发与应用全过程的监管框架,全面涵盖数据质量、算法验证和临床评估等核心环节,并同步探索基于真实世界证据的审评新路径^[43-44]。在临床整合上应明确划定临床责任边界,人工智能系统的输出属于辅助建议与证据汇总,不能替代医师处方与临床最终决策,尤其不应在缺乏医师审核的情况下直接生成或执行治疗处方^[45-46]。针对“幻觉”风险,需在监管与临床规程以及算法与产品设计层面,遵循“人类监督与控制”的最终原则,例如优先部署输出易于被临床医师快速复核、验证或否决的辅助性任务(如提供结构化测量数据、生成报告草稿),同时配套提供置信度提示、决策依据追溯功能,并设立“遇不确定情况时主动拒答或转交人工”的强制机制。针对伦理风险,应在数据采集与训练阶段开展隐私保护与偏倚评估,明确知情同意与用途边界,并在真实世界使用中进行持续监测与审计。这些措施根本目的在于确保大模型在临床实践中始终处于辅助地位,并在严格界定的人机协同框架内发挥作用,共同推动大模型从技术概念转化为真正改善心血管疾病诊疗效果的临床工具。

利益冲突 所有作者声明无利益冲突

参 考 文 献

- [1] Global Burden of Disease. Leading causes of death [EB/OL]. (2025-09-09) [2026-01-10]. <https://archive.ourworldindata.org/20250909-093708/grapher/leading-cause-of-death.html>.
- [2] Zhou C, Dai P, Hou A, et al. A comprehensive review of deep learning-based models for heart disease prediction [J]. Artif Intell Rev, 2024, 57(10): 263. DOI: 10.1007/s10462-024-10899-9.
- [3] Hippisley-Cox J, Coupland C, Brindle P. Development and validation of QRISK3 risk prediction algorithms to estimate future risk of cardiovascular disease: prospective cohort study[J]. BMJ, 2017, 357:j2099. DOI: 10.1136/bmj.j2099.
- [4] SCORE2 working group and ESC Cardiovascular risk collaboration. SCORE2 risk prediction algorithms: new models to estimate 10-year risk of cardiovascular disease in Europe[J]. Eur Heart J, 2021, 42(25): 2439-2454. DOI: 10.1093/eurheartj/ehab309.
- [5] Yang X, Li J, Hu D, et al. Predicting the 10-year risks of atherosclerotic cardiovascular disease in Chinese population: the China-PAR Project (Prediction for ASCVD Risk in China) [J]. Circulation, 2016, 134(19): 1430-1440. DOI: 10.1161/CIRCULATIONAHA.116.022367.
- [6] Visseren F, Mach F, Smulders YM, et al. 2021 ESC Guidelines on cardiovascular disease prevention in clinical practice[J]. Eur Heart J, 2021, 42(34): 3227-3337. DOI: 10.1093/eurheartj/ehab484.

- [7] Hussein SH, Kako NA. Deep learning for cardiovascular disease detection: a review based on cardiac magnetic resonance imaging data[J]. *Sci J Koya Univ*, 2025, 13(2): 1-17. DOI:10.14500/aro.11971.
- [8] Tsampras T, Karamanidou T, Papanastasiou G, et al. Deep learning for cardiac imaging: focus on myocardial diseases, a narrative review[J]. *Hellenic J Cardiol*, 2025, 81:18-24. DOI: 10.1016/j.hjc.2024.12.002.
- [9] Li J, Aguirre AD, Moura V, et al. An electrocardiogram foundation model built on over 10 million recordings[J]. *NEJM AI*, 2025, 2(7)DOI: 10.1056/aioa2401033.
- [10] Christensen M, Vukadinovic M, Yuan N, et al. Vision-language foundation model for echocardiogram interpretation[J]. *Nat Med*, 2024, 30(5): 1481-1488. DOI: 10.1038/s41591-024-02959-y.
- [11] Zhang S, Du Y, Wang W, et al. ECGFM: a foundation model for ECG analysis trained on a multi-center million-ECG dataset[J]. *Inform Fusion*, 2025, 124: 103363. DOI: 10.1016/j.inffus.2025.103363.
- [12] Jin J, Wang H, Li H, et al. Reading your heart: learning ECG words and sentences via pre-training ECG language model [EB/OL]. (2025-02-15) [2026-01-10]. <https://arxiv.org/html/2502.10707v1>.
- [13] Tian Y, Li Z, Jin Y, et al. Foundation model of ECG diagnosis: diagnostics and explanations of any form and rhythm on ECG[J]. *Cell Rep Med*, 2024, 5(12): 101875. DOI: 10.1016/j.xcrm.2024.101875.
- [14] Xie Y, Li S, Lin T, et al. Heartcare suite: multi-dimensional understanding of ECG with raw multi-lead signal modeling[EB/OL]. (2025-06-10) [2026-01-10]. <https://arxiv.org/html/2506.05831v2>.
- [15] Ma J, He Y, Li F, et al. Segment anything in medical images [J]. *Nat Commun*, 2024, 15(1): 654. DOI: 10.1038/s41467-024-44824-z.
- [16] Wu J, Wang Z, Hong M, et al. Medical SAM adapter: adapting segment anything model for medical image segmentation[J]. *Med Image Anal*, 2025, 102: 103547. DOI: 10.1016/j.media.2025.103547.
- [17] Cheng J, Ye J, Deng Z, et al. SAM-Med2D[EB/OL]. (2023-08-31) [2026-01-10]. <https://arxiv.org/abs/2308.16184>.
- [18] Vukadinovic M, Chiu IM, Tang X, et al. Comprehensive echocardiogram evaluation with view primed vision language AI[J]. *Nature*, 2025. DOI: 10.1038/s41586-025-09850-x.
- [19] Jacob AJ, Borgohain I, Chitiboi T, et al. Towards a cardiovascular magnetic resonance foundation model for multi-task cardiac image analysis[J]. *J Cardiovasc Magn Reson*, 2025, 27(2): 101967. DOI: 10.1016/j.jcmr.2025.101967.
- [20] Hu Y, Zheng Y, Miao S, et al. Cardiac-CLIP: a vision-language foundation model for 3D cardiac CT images[EB/OL]. (2025-07-30) [2026-01-10]. <https://arxiv.org/abs/2507.22024>.
- [21] Ahsan MM, Siddique Z. Machine learning-based heart disease diagnosis: a systematic literature review[J]. *Artif Intell Med*, 2022, 128: 102289. DOI: 10.1016/j.artmed.2022.102289.
- [22] Ding Z, Li Z, Hu Y, et al. Translating electrocardiograms to cardiac magnetic resonance imaging useful for cardiac assessment and disease screening:a multi-center study AI for ECG to CMR translation study[EB/OL]. (2024-11-19) [2026-01-10]. <https://arxiv.org/abs/2411.13602>.
- [23] Alsekait DM, Shdefat AY, Nabil A, et al. Heart-net: a multi-modal deep learning approach for diagnosing cardiovascular diseases[J]. *Comput Mater Cont*, 2024, 80(3):3967-3990. DOI:10.32604/cmc.2024.054591.
- [24] Zhao Y, Kang J, Zhang T, et al. ECG-chat: a large ECG-language model for cardiac disease diagnosis [EB/OL]. (2024-08-16) [2026-01-10]. <https://arxiv.org/abs/2408.08849>.
- [25] Yang XY, Li YM, Wang JY, et al. Utilizing multimodal artificial intelligence to advance cardiovascular diseases [J]. *Precis Clin Med*, 2025, 8(3): pbaf016. DOI: 10.1093/pemed/pbaf016.
- [26] Cai M, Jiang J, Huang W, et al. SuPreME: a supervised pre-training framework for multimodal ECG representation learning[EB/OL]. (2025-09-19) [2026-01-10]. <https://arxiv.org/abs/2502.19668>.
- [27] Sun X, Cheng LH, Plein S, et al. Deep learning based automated left ventricle segmentation and flow quantification in 4D flow cardiac MRI[J]. *J Cardiovasc Magn Reson*, 2024, 26(1): 100003. DOI: 10.1016/j.jcmr.2023.100003.
- [28] Aarthy ST, Mazher Iqbal JL. A novel deep learning approach for early detection of cardiovascular diseases from ECG signals[J]. *Med Eng Phys*, 2024, 125: 104111. DOI: 10.1016/j.medengphy.2024.104111.
- [29] Wang X, Nadarajah R, Zhang Z, et al. A deep learning pipeline using synthetic data to improve interpretation of paper ECG images[EB/OL]. (2025-07-30) [2026-01-10]. <https://arxiv.org/abs/2507.21968>.
- [30] Davi S, Kumar M, Hanif ZM, et al. Deep learning for early detection of cardiovascular disease: a review[J]. *Cardiovasc Digit Health J*, 2025, 8(10): e71334. DOI: 10.1002/hrsr.271334.
- [31] Dhade P, Shirke P. Federated learning for healthcare: a comprehensive review[J]. *Eng Proc*, 2024, 59(1): 230. DOI: 10.3390/engproc2023059230.
- [32] Wu Z, Guo K, Luo E, et al. Medical long-tailed learning for imbalanced data: bibliometric analysis[J]. *Comput Methods Programs Biomed*, 2024, 247: 108106. DOI: 10.1016/j.cmpb.2024.108106.
- [33] Zhang W, Yang L, Geng S, et al. Self-supervised time series representation learning via cross reconstruction transformer[J]. *IEEE Trans Neural Netw Learn Syst*, 2024, 35(11): 16129-16138. DOI: 10.1109/TNNLS.2023.3292066.
- [34] Zhu X, Shi M, Yu X, et al. Self-supervised inter-intra period-aware ECG representation learning for detecting atrial fibrillation[J]. *Biomed Signal Proces Control*, 2025, 100:106939. DOI: 10.1016/j.bspc.2024.106939.
- [35] Yoon JS, Oh K, Shin Y, et al. Domain generalization for medical image analysis: a review[J]. *Proc IEEE*, 2024, 112(10):1583-1609. DOI: 10.1109/JPROC.2024.3507831.
- [36] Wang L, Ma Y, Zhang W, et al. Learning on sample-efficient and label-efficient multi-view cardiac data with graph transformer[J]. *Pattern Recogn Lett*, 2024, 180: 127-133. DOI:10.1016/j.patrec.2024.03.001.
- [37] Nolin-Lapalme A, Sowa A, Delfrate J, et al. Foundation models for generalizable electrocardiogram interpretation: comparison of supervised and

- self-supervised electrocardiogram foundation models [EB/OL]. (2025-03-05) [2026-01-10]. <https://doi.org/10.1101/2025.03.02.25322575v1>.
- [38] Moor M, Banerjee O, Abad Z, et al. Foundation models for generalist medical artificial intelligence[J]. Nature, 2023, 616(7956):259-265. DOI: 10.1038/s41586-023-05881-4.
- [39] Zhu D, Chhabra VK, Khalili MM. ECG signal denoising using multi-scale patch embedding and transformers [EB/OL]. (2024-07-12) [2026-01-10]. <https://arxiv.org/abs/2407.11065>.
- [40] Gu A, Goel K, Ré C. Efficiently modeling long sequences with structured state spaces[EB/OL]. (2022-08-05) [2026-01-10]. <https://arxiv.org/abs/2111.0039639>.
- [41] Lu Y, Tan G, Pu B, et al. SKGC: A general semantic-level knowledge guided classification framework for fetal congenital heart disease[J]. IEEE J Biomed Health Inform, 2024, 28(10): 6105-6116. DOI: 10.1109/JBHI.2024.3426068.
- [42] Sounderajah V, Ashrafiyan H, Golub RM, et al. Developing a reporting guideline for artificial intelligence-centred diagnostic test accuracy studies: the STARD-AI protocol [J]. BMJ Open, 2021, 11(6): e047709. DOI: 10.1136/bmjopen-2020-047709.
- [43] Pesapane F, Volonté C, Codari M, et al. Artificial intelligence as a medical device in radiology: ethical and regulatory issues in Europe and the United States[J]. Insights Imaging, 2018, 9(5): 745-753. DOI: 10.1007/s13244-018-0645-y.
- [44] Liu X, Cruz Rivera S, Moher D, et al. Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: the CONSORT-AI extension[J]. Lancet Digit Health, 2020, 2(10): e537-e548. DOI: 10.1016/S2589-7500(20)30218-1.
- [45] Martin DE, Harris D, Jha V, et al. Ethical challenges in nephrology: a call for action[J]. Nat Rev Nephrol, 2020, 16(10):603-613. DOI: 10.1038/s41581-020-0295-4.
- [46] Chu LC, Rowe SP, Fishman EK. Clinician-scientists: can they survive in the modern era? [J]. J Am Coll Radiol, 2021, 18(1 Pt B):192-197. DOI: 10.1016/j.jacr.2020.09.023.