

房颤患者死亡风险预测模型研究进展

雷 洲, 唐 正, 李欣悦, 汪劫宇, 张浩轩, 殷跃辉*

重庆医科大学附属第二医院心血管内科, 重庆

收稿日期: 2026年4月26日; 录用日期: 2026年5月21日; 发布日期: 2026年5月28日

摘 要

心房颤动(atrial fibrillation, AF)是最常见的持续性心律失常, 其患者的心血管死亡和全因死亡风险均显著升高, 疾病负担日益加重。准确识别高危人群并进行死亡风险分层, 对改善患者预后具有重要意义。目前国内外已建立了多种用于预测房颤患者死亡风险的临床模型, 主要包括基于传统临床变量的风险评分(如CHA₂DS₂-VASc评分及其改良版本)、整合生物标志物的风险评分以及基于大型前瞻性真实世界研究的预测模型。近年来, 随着机器学习与深度学习方法的不断进展, 新型预测模型不断涌现。本文旨在介绍不同房颤死亡风险预测模型, 以期为临床医护人员提供参考。

关键词

心房颤动, 死亡风险, 预测模型

Advances in Mortality Risk Prediction Modeling for Atrial Fibrillation

Zhou Lei, Zheng Tang, Xinyue Li, Jieyu Wang, Haoxuan Zhang, Yuehui Yin*

Department of Cardiology, The Second Affiliated Hospital of Chongqing Medical University, Chongqing

Received: April 26, 2026; accepted: May 21, 2026; published: May 28, 2026

Abstract

Atrial fibrillation (AF) is the most common sustained cardiac arrhythmia, which is associated with a markedly elevated risk of cardiovascular and all-cause mortality, thereby imposing the growing burden of society. Precise risk stratification and early identification of high-risk individuals are critical for optimizing prognostic management and improving clinical outcomes. Currently, various predictive models for mortality risk in AF patients have been established, including risk scores based on clinical variables (such as the CHA₂DS₂-VASc score and its modified versions), risk scores

*通讯作者。

文章引用: 雷洲, 唐正, 李欣悦, 汪劫宇, 张浩轩, 殷跃辉. 房颤患者死亡风险预测模型研究进展[J]. 临床医学进展, 2026, 16(5): 2856-2862. DOI: 10.12677/acm.2026.1652098

incorporating biomarkers, and predictive models derived from large-scale prospective real-world studies. In recent years, with the advancement of machine learning and deep learning, novel predictive models have emerged. In this paper, we will introduce different risk prediction models for mortality in AF patients, providing a practical reference for clinical decision-making.

Keywords

Atrial Fibrillation, Mortality Risk, Prediction Model

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

心房颤动(atrial fibrillation, AF)是最常见的持续性心律失常。一项基于全球疾病负担数据的研究显示, 2021 年全球房颤新发病例为 448.49 万例, 患病总人数达 5255 万例, 较 1990 年增长 137% [1]。据《中国心血管健康与疾病报告 2022》, 我国房颤患者共 487 万 [2], 且随着人口老龄化与房颤多种危险因素如高血压、心衰等的发病风险增加, 房颤的疾病负担逐渐加重 [3]。房颤不仅影响患者的生活质量, 还与卒中、心力衰竭、痴呆等并发症密切相关, 导致死亡率显著升高 [4]-[6]。一项纳入 104 项队列研究、近 969 万受试者的荟萃分析显示, 房颤患者的心血管死亡风险(RR = 2.03, 95% CI: 1.79~2.30)和全因死亡风险(RR = 1.46, 95% CI: 1.39~1.54)显著增加, 表明房颤为严重威胁民众健康的心血管疾病之一 [7], 给社会医疗体系带来巨大的经济负担 [8], 这也表明了风险分层的重要性。CHA₂DS₂-VASc 评分虽被指南推荐用于房颤卒中风险评估 [9], 但也有研究证实其与死亡风险显著相关 [10]。随后又有研究者提出仅针对房颤患者死亡风险预测的 ABC 死亡风险评分 [11]。近年来随着机器学习与深度学习不断发展, 新型预测模型不断涌现 [9] [12]。据此, 本文旨在回顾现有房颤患者死亡风险预测模型的研究进展, 以期为临床医护人员提供参考。

2. 房颤死亡风险预测模型

2.1. CHA₂DS₂-VASc 评分

2010 年 Lip 等人提出 CHA₂DS₂-VASc 评分, 其中包括心力衰竭、高血压、年龄、糖尿病、卒中、性别、血管疾病等变量, 细化了房颤患者卒中风险评估 [13]。该评分随后在 2010 年欧洲心脏病学会房颤管理指南中得到推荐, 且在临床中得以广泛应用 [9]。此后, 研究者们又开始探索该评分对于死亡风险的预测价值。2015 年 Apiyasawat 等人基于泰国全国医保数据库开展了一项回顾性队列研究, 该研究共纳入 8981 例房颤住院患者, 旨在明确房颤患者死亡风险及其预测因素, 并评估 CHA₂DS₂-VASc 评分是否为死亡的独立预测指标。结果显示, 在平均随访 46 个月后, 共有 3948 例(44.0%)患者死亡, CHA₂DS₂-VASc 评分与死亡风险呈正相关。多因素 Cox 回归分析显示, CHA₂DS₂-VASc 评分 ≥ 6 分是死亡的最强预测因素之一(HR = 2.2, 95% CI: 1.4~3.7, P = 0.002) [10]。该研究是将 CHA₂DS₂-VASc 评分从卒中风险评分拓展为全因死亡评分的重要研究, 其证明了该评分不仅可以评估血栓栓塞风险, 还能多维度评估心血管疾病负担。然而, 该研究也存在局限性, 如未报告 CHA₂DS₂-VASc 评分预测死亡的具体区分度指标如 C 指数, 仅通过回归分析显示了评分的独立预测作用, 难以直接量化其预测准确性。后续一项 meta 分析纳入 50 项研究, 共涉及 669,217 例患者, 对 CHA₂DS₂-VASc 评分预测全因死亡的能力进行了更全面的量化,

结果显示 C 指数为 0.62 (95% CI: 0.61~0.64), 表明其对识别高风险患者能力有限, 但该评分在随访一年、三年和五年时其阴性预测值持续高达 94% 以上, 这表明该评分排除低风险人群能力较强[14]。

2.2. R₂-CHA₂DS₂-VASc 评分

肾功能不全是房颤患者死亡的独立危险因素[15], 基于此, 研究者在 CHA₂DS₂-VASc 评分基础上纳入肾功能指标, 构建了 R₂-CHA₂DS₂-VASc 评分, 通过整合肾功能指标实现了对房颤患者死亡风险的精准分层。2017 年 Fu 等人纳入了 219 例中国老年房颤患者, 同时采用肌酐清除率(CrCl)和肾小球滤过率(GFR)公式评估肾功能, 其中肾功能不全计 2 分, 结果显示肾功能不全(GFR < 60 mL/min/1.73m²)是全因死亡的独立危险因素(P < 0.001)。为避免单一 GFR 估算公式可能带来的偏移, 该研究采用 4 种 GFR 估算方法进行肾功能评估, 以验证结果的稳定性和一致性, 结果仍提示肾功能下降可显著增加房颤患者死亡风险。基于 GFR 改良评分的 C 指数为 0.718~0.723 (P < 0.05), 预测效能均优于 CHA₂DS₂-VASc 评分(0.633, 95% CI: 0.546~0.720)及基于 CrCl 的改良版本(0.665, 95% CI: 0.581~0.748)。且 4 种 R₂(GFR)-CHA₂DS₂-VASc 评分之间的 C 指数未见统计学差异[16]。该研究是首个在中国老年房颤患者中验证了 R₂改良评分的死亡预测效能, 具有明确的临床指导价值, 但该研究样本量小、随访期短以及缺乏外部验证, 这些因素均限制了结论的稳健性和推广价值。后续需要大样本、长随访的外部验证研究来进一步确认其临床应用的可靠性。

2.3. ABC 死亡风险评分

2018 年 Hijazi 等人提出了一个专门用于预测接受抗凝治疗的房颤患者的死亡风险工具: ABC (age, biomarkers, clinical history)死亡风险评分, 该评分包含的变量包括年龄、氨基末端 B 型钠尿肽前体(NT-pro BNP)、高敏肌钙蛋白 T (cTnT-hs)、生长分化因子 15 (GDF-15)以及心力衰竭。其中建模队列来自 ARIS-TOTLE 研究, 共纳入 14,611 例房颤患者, 外部验证队列来自 RE-LY 研究, 共纳入 8548 例房颤患者。研究指出该评分在建模队列与验证队列中的 C 指数均为 0.74, 显著高于基于所有临床变量的评分与 CHA₂DS₂-VASc, 同时评分校准度良好[11]。该评分将多种生物标志物(NT-pro BNP、cTnT-hs、GDF-15)与临床变量结合, 将心肌应激、心肌损伤以及细胞衰老与炎症等信息纳入风险评估中, 这可能是导致该模型在死亡风险预测方面表现优于仅基于临床变量模型的原因[17] [18]。然而该评分需要同时检测 NT-pro BNP、cTnT-hs、GDF-15, 在资源有限地区难以普及。同时该评分主要基于临床试验人群开发, 其在真实世界房颤患者中的适用性需进一步验证。

2.4. GARFIELD-AF 模型

GARFIELD-AF 模型是 2017 年 Fox 等人基于 GARFIELD-AF 研究数据开发的可同时评估新诊断房颤患者在随访期内的全因死亡、缺血性卒中/系统性栓塞和严重出血风险的预测模型[19]。GARFIELD-AF 研究是一项多中心、前瞻性观察研究, 于 2010 年 3 月至 2015 年 7 月纳入来自 35 个国家的 38,984 例新诊断房颤患者, 其涵盖了不同地域、种族和抗凝策略的真实世界患者群体, 使得模型具有良好的外推基础[20]。研究显示 GARFIELD-AF 模型预测房颤患者 1 年内全因死亡的 C 指数为 0.77 (95% CI: 0.76~0.78), 相比之下, CHA₂DS₂-VASc 评分预测死亡的 C 指数仅为 0.66 (95% CI: 0.64~0.67)。在低风险人群中 (CHA₂DS₂-VASc 中男性 0~1 分, 女性 1~2 分), CHA₂DS₂-VASc 评分的 C 指数为 0.50 (95% CI: 0.45~0.55), 而 GARFIELD-AF 模型的 C 指数为 0.69 (95% CI: 0.64~0.75), 提示 GARFIELD-AF 模型预测能力更佳[19]。该模型随后在多个独立的外部数据如 ORBIT-AF 研究、CPRD 数据库中进行外部验证。在 ORBIT-AF 外部验证中, 该模型预测房颤患者 1 年全因死亡的 C 指数为 0.75 (95% CI: 0.73~0.77) [19]。基于 CPRD 数据库的外部验证显示该模型预测 1 年全因死亡的 C 指数为 0.747 (95% CI: 0.744~0.751), 显著优于

CHA₂DS₂-VASc 评分的 0.635 (95% CI: 0.631~0.639) [21]。2021 年 Fox 再次基于 GARFIELD-AF 研究数据验证了该模型在预测房颤患者 2 年内全因死亡、缺血性卒中/系统性栓塞以及严重出血风险的效能均优于 CHA₂DS₂-VASc 评分,且在低风险人群中(CHA₂DS₂-VASc 中男性 0~1 分,女性 1~2 分),仍保持良好的区分能力[22]。GARFIELD-AF 模型可通过 GARFIELD-AF Risk Calculator 在线平台使用,输入年龄、收缩压、心力衰竭、口服抗凝药情况等变量信息后快速生成个体化风险预测结果[22]。该模型是首个能同时预测全因死亡、缺血性卒中和严重出血三种重要临床结局的房颤风险分层工具,使临床医生可以在一个界面内完成多种风险评估。

2.5. COOL-AF 模型

针对亚洲房颤人群,2023 年 Krittayaphong 等人基于泰国的 COOL-AF 研究构建了可同时评估非瓣膜性房颤患者全因死亡、缺血性卒中/系统性栓塞和大出血风险的预测模型,即 COOL-AF 模型,弥补了基于西方人群构建的 GARFIELD-AF 模型在亚洲人群中的适用性不足的问题。研究显示 COOL-AF 模型预测房颤患者 1 年内全因死亡的 C 指数为 0.727 (95% CI: 0.712~0.742),显著优于 CHA₂DS₂-VASc 评分的 0.669 (95% CI: 0.653~0.685)以及 GARDIELD Refitted 模型的 0.639 (95% CI: 0.623~0.655) [23]。随后 Bucci 等人利用基于亚洲人群的 APHRS 研究与基于欧洲人群的 EORP-AF 研究数据对 COOL-AF 模型进行不同人群的外部验证,结果显示,在 APHRS 研究数据中,COOL-AF 模型对房颤患者 1 年内全因死亡预测的 C 指数为 0.77 (95% CI: 0.71~0.83),而在 EORP-AF 研究数据中,其 C 指数仅为 0.68 (95% CI: 0.65~0.70),这提示 COOL-AF 模型在亚洲人群中的预测效能显著优于欧洲人群,具有明显的地区适用性差异[24]。

2.6. 机器学习与深度学习模型

不同于 Logistic 回归或 Cox 比例风险模型预设自变量与结局变量之间存在线性关系,机器学习与深度学习模型可以捕捉变量间的非线性及交互作用,例如年龄与死亡风险的关系不再是每增加 1 岁,死亡风险固定增加一定比例,而是依据数据特征分析出不同年龄段对应不同程度的死亡风险增加,这使得处理临床预测问题时具有更强的灵活性[25]。近年来,随着机器学习与深度学习方法不断进展,其在构建房颤患者死亡风险预测模型方面也得以广泛研究。Wang 等人基于 MIMIC-IV 数据库中 26,365 例房颤患者,采用 XGBoost 模型进行变量筛选,构建了 CRAMB 评分(Charlson 合并症指数、再入院状态、年龄、转移性实体瘤、最高血尿素氮浓度)。该评分在预测房颤患者一年死亡风险时的 C 指数为 0.765 (95% CI: 0.753~0.776),显著优于 CHA₂DS₂-VASc 评分(AUC = 0.617, 95% CI: 0.603~0.630) [12]。此外,基于 GLORIA-AF 研究中 26,183 例非瓣膜性房颤患者数据, Jodrell 等人分别构建了线性判别分析、逻辑回归、神经网络、XGBoost、朴素贝叶斯共 5 种模型,用于预测 1 年和 3 年的全因死亡风险,结果表明线性判别分析模型表现最优,预测 1 年内全因死亡率的 C 指数为 0.734 (95% CI: 0.721~0.747),预测 3 年内全因死亡率的 C 指数为 0.742 (95% CI: 0.729~0.755),均优于 CHA₂DS₂-VASc 评分[26]。然而,模型的外部验证不足,有待进一步的大规模前瞻性研究和多中心验证来推动其临床应用。

尽管机器学习与深度学习模型分析处理临床变量能力更强,但其算法可解释性不足的“黑箱”问题阻碍了其临床应用[27]。为解决这一问题,近年来涌现出多种可解释性方法。SHAP (Shapley Additive Explanations)通过计算每个变量对预测结果的边际贡献,为每例患者生成个性化的特征重要性图谱,帮助临床医生理解与死亡风险升高相关的主要因素[28]。LIME (局部可解释模型)则在预测点附近拟合一个简单的线性模型来近似黑箱模型的局部行为[29]。上述方法有助于临床医生理解模型决策,从而推动其在临床实践中的普及与应用。然而,将模型真正纳入日常临床实践(如电子病历系统)仍面临多重挑战。首先,不同医院的电子病历系统在变量命名、单位等数据特征上存在差异,模型难以被直接使用[30];其次,临床

医生对“风险报警疲劳”同样存在担忧，若模型频繁输出中高风险但缺乏明确的干预建议，医生可能逐渐忽略其提醒[31]；此外，前瞻性验证较为缺乏，目前大多数模型仅完成了回顾性队列的区分度和校准度评估，缺乏前瞻性研究证明使用这些模型能真正改善患者预后[32]。后续仍需加强模型的多中心外部验证、前瞻性临床效用评估，并结合明确的干预建议纳入到电子病历系统，以推动临床应用。

3. 总结与展望

综上，房颤死亡风险预测模型经历了从传统卒中评分的拓展与改良，到整合生物标志物的临床风险评分、再到基于机器学习与深度学习算法的综合预测模型的演变过程。尽管现有研究在模型性能和临床应用方面取得了进展，但该领域仍存在许多需要解决的问题。首先，除传统心血管危险因素外，衰弱、用药依从性、社会支持等非传统因素同样发挥重要作用，却较少被纳入预测模型中；其次，生物标志物的纳入虽有效提高了模型的预测性能，但在基层医疗单位难以常规开展，亟需卫生经济学评价明确其成本效益；再者，目前许多模型基于单次就诊的基线数据建立，而房颤患者的死亡风险随病程进展、合并症演变、治疗方案调整而动态变化，关注临床变量的动态变化，构建动态预测模型有望实现风险预警的实时化和个体化。基于上述问题，未来研究应继续寻找与房颤死亡风险增加相关的非传统风险因素，并增加多中心外部验证以提高模型的普适性，同时应充分利用电子病历时序数据构建动态预测模型，推动预测工具从算法研究走向床旁决策，真正实现个体化、精细化风险分层。

参考文献

- [1] Cheng, S., He, J., Han, Y., Han, S., Li, P., Liao, H., *et al.* (2024) Global Burden of Atrial Fibrillation/Atrial Flutter and Its Attributable Risk Factors from 1990 to 2021. *Europace*, **26**, euae195. <https://doi.org/10.1093/europace/euae195>
- [2] 中国心血管健康与疾病报告 2022 概要[J]. 中国循环杂志, 2023, 38(6): 583-612.
- [3] Di Carlo, A., Bellino, L., Consoli, D., Mori, F., Zaninelli, A., Baldereschi, M., *et al.* (2019) Prevalence of Atrial Fibrillation in the Italian Elderly Population and Projections from 2020 to 2060 for Italy and the European Union: The FAI Project. *EP Europace*, **21**, 1468-1475. <https://doi.org/10.1093/europace/euz141>
- [4] Weber, C., Hung, J., Hickling, S., Li, I., Murray, K. and Briffa, T. (2023) Emergent Readmission and Long-Term Mortality Risk after Incident Atrial Fibrillation Hospitalisation. *Heart*, **109**, 380-387. <https://doi.org/10.1136/heartjnl-2022-321560>
- [5] Gu, H., Yang, K., Zhao, X., Wang, Y., Liu, L., Li, Z., *et al.* (2024) Preexisting Heart Disease Spectrum and In-Hospital Outcomes for Patients with Acute Ischemic Stroke. *Stroke: Vascular and Interventional Neurology*, **4**, e001517. <https://doi.org/10.1161/svin.124.001517>
- [6] Reinhardt, S.W., Chouairi, F., Miller, P.E., Clark, K.A.A., Kay, B., Fuery, M., *et al.* (2021) National Trends in the Burden of Atrial Fibrillation during Hospital Admissions for Heart Failure. *Journal of the American Heart Association*, **10**, e019412. <https://doi.org/10.1161/jaha.120.019412>
- [7] Oduyayo, A., Wong, C.X., Hsiao, A.J., Hopewell, S., Altman, D.G. and Emdin, C.A. (2016) Atrial Fibrillation and Risks of Cardiovascular Disease, Renal Disease, and Death: Systematic Review and Meta-Analysis. *BMJ*, **354**, i4482. <https://doi.org/10.1136/bmj.i4482>
- [8] Buja, A., Rebba, V., Montecchio, L., Renzo, G., Baldo, V., Cocchio, S., *et al.* (2024) The Cost of Atrial Fibrillation: A Systematic Review. *Value in Health*, **27**, 527-541. <https://doi.org/10.1016/j.jval.2023.12.015>
- [9] Camm, A.J., Kirchhof, P., Lip, G.Y., Schotten, U., Savelieva, I., Ernst, S., *et al.* (2010) Guidelines for the Management of Atrial Fibrillation: The Task Force for the Management of Atrial Fibrillation of the European Society of Cardiology (ESC). *European Heart Journal*, **31**, 2369-2429.
- [10] Apiyasawat, S., Tangcharoen, T., Wisaratapong, T., Yamwong, S., Wiboonpolprasert, S. and Sritara, P. (2015) CHA2DS2-VASc Scores Predict Mortality after Hospitalization for Atrial Fibrillation. *International Journal of Cardiology*, **185**, 293-296. <https://doi.org/10.1016/j.ijcard.2015.03.180>
- [11] Hijazi, Z., Oldgren, J., Lindbäck, J., Alexander, J.H., Connolly, S.J., Eikelboom, J.W., *et al.* (2018) A Biomarker-Based Risk Score to Predict Death in Patients with Atrial Fibrillation: The ABC (Age, Biomarkers, Clinical History) Death Risk Score. *European Heart Journal*, **39**, 477-485. <https://doi.org/10.1093/eurheartj/ehx584>
- [12] Wang, B., Jin, F., Cao, H., Li, Q. and Zhang, P. (2024) Development of a Risk Score for Predicting One-Year Mortality

- in Patients with Atrial Fibrillation Using XGBoost-Assisted Feature Selection. *Polish Heart Journal*, **82**, 941-948. <https://doi.org/10.33963/v.phj.101842>
- [13] Lip, G.Y.H., Nieuwlaat, R., Pisters, R., Lane, D.A. and Crijns, H.J.G.M. (2010) Refining Clinical Risk Stratification for Predicting Stroke and Thromboembolism in Atrial Fibrillation Using a Novel Risk Factor-Based Approach: The Euro Heart Survey on Atrial Fibrillation. *Chest*, **137**, 263-272. <https://doi.org/10.1378/chest.09-1584>
- [14] Proietti, M., Farcomeni, A., Romiti, G.F., Di Rocco, A., Placentino, F., Diemberger, I., *et al.* (2020) Association between Clinical Risk Scores and Mortality in Atrial Fibrillation: Systematic Review and Network Meta-Regression of 669,000 Patients. *European Journal of Preventive Cardiology*, **27**, 633-644. <https://doi.org/10.1177/2047487318817662>
- [15] Wang, H., Li, K., Li, J., Lin, K., Shi, Y., Wang, H., *et al.* (2019) Moderate Chronic Kidney Disease and Left Atrial Enlargement Independently Predict Thromboembolic Events and Mortality in Elderly Patients with Atrial Fibrillation: A Retrospective Single-Center Study. *Journal of International Medical Research*, **47**, 4312-4323. <https://doi.org/10.1177/0300060519858151>
- [16] Fu, S., Zhou, S., Luo, L. and Ye, P. (2017) $R_{2(GFR)}CHADS_2$ and $R_{2(GFR)}CHA_2DS_2VASC$ Schemes Improved the Performance of $CHADS_2$ and CHA_2DS_2VASC Scores in Death Risk Stratification of Chinese Older Patients with Atrial Fibrillation. *Clinical Interventions in Aging*, **12**, 1233-1238. <https://doi.org/10.2147/cia.s138405>
- [17] Niederdöckl, J., Simon, A., Schnaubelt, S., Schuetz, N., Laggner, R., Sulzgruber, P., *et al.* (2019) Cardiac Biomarkers Predict Mortality in Emergency Patients Presenting with Atrial Fibrillation. *Heart*, **105**, 482-488. <https://doi.org/10.1136/heartjnl-2018-313145>
- [18] Nopp, S., Königsbrügge, O., Kraemmer, D., Pabinger, I. and Ay, C. (2021) Growth Differentiation Factor-15 Predicts Major Adverse Cardiac Events and All-Cause Mortality in Patients with Atrial Fibrillation. *European Journal of Internal Medicine*, **88**, 35-42. <https://doi.org/10.1016/j.ejim.2021.02.011>
- [19] Fox, K.A.A., Lucas, J.E., Pieper, K.S., Bassand, J., Camm, A.J., Fitzmaurice, D.A., *et al.* (2017) Improved Risk Stratification of Patients with Atrial Fibrillation: An Integrated GARFIELD-AF Tool for the Prediction of Mortality, Stroke and Bleed in Patients with and without Anticoagulation. *BMJ Open*, **7**, e017157. <https://doi.org/10.1136/bmjopen-2017-017157>
- [20] Bassand, J., Apenteng, P.N., Atar, D., Camm, A.J., Cools, F., Corbalan, R., *et al.* (2021) GARFIELD-AF: A Worldwide Prospective Registry of Patients with Atrial Fibrillation at Risk of Stroke. *Future Cardiology*, **17**, 19-38. <https://doi.org/10.2217/fca-2020-0014>
- [21] Apenteng, P.N., Prieto-Merino, D., Hee, S.W., Lobban, T.C., Caleyachetty, R. and Fitzmaurice, D.A. (2023) Optimising Prediction of Mortality, Stroke, and Major Bleeding for Patients with Atrial Fibrillation: Validation of the GARFIELD-AF Tool in UK Primary Care Electronic Records. *British Journal of General Practice*, **73**, e816-e824. <https://doi.org/10.3399/bjgp.2023.0082>
- [22] Fox, K.A.A., Virdone, S., Pieper, K.S., Bassand, J., Camm, A.J., Fitzmaurice, D.A., *et al.* (2022) GARFIELD-AF Risk Score for Mortality, Stroke, and Bleeding within 2 Years in Patients with Atrial Fibrillation. *European Heart Journal - Quality of Care and Clinical Outcomes*, **8**, 214-227. <https://doi.org/10.1093/ehjqcco/qcab028>
- [23] Krittayaphong, R., Kanjanarutjawiwat, W., Wisaratapong, T. and Lip, G.Y.H. (2023) Improving Risk Prediction for Death, Stroke and Bleeding in Asian Patients with Atrial Fibrillation. *European Journal of Clinical Investigation*, **53**, e13886. <https://doi.org/10.1111/eci.13886>
- [24] Bucci, T., Shantsila, A., Romiti, G.F., Teo, W., Chao, T., Shimizu, W., *et al.* (2024) External Validation of COOL-AF Scores in the Asian Pacific Heart Rhythm Society Atrial Fibrillation Registry. *JACC: Asia*, **4**, 59-69. <https://doi.org/10.1016/j.jacasi.2023.09.011>
- [25] Yang, C., Peng, C., Huang, L., Chen, F.Y., Kuo, C., Wu, C., *et al.* (2023) Comparison between Multiple Logistic Regression and Machine Learning Methods in Prediction of Abnormal Thallium Scans in Type 2 Diabetes. *World Journal of Clinical Cases*, **11**, 7951-7964. <https://doi.org/10.12998/wjcc.v11.i33.7951>
- [26] Joddrell, M., El-Bouri, W., Harrison, S.L., Huisman, M.V., Lip, G.Y.H. and Zheng, Y. (2024) Machine Learning for Outcome Prediction in Patients with Non-Valvular Atrial Fibrillation from the GLORIA-AF Registry. *Scientific Reports*, **14**, Article No. 27088. <https://doi.org/10.1038/s41598-024-78120-z>
- [27] Ali, S., Akhlaq, F., Imran, A.S., Kastrati, Z., Daudpota, S.M. and Moosa, M. (2023) The Enlightening Role of Explainable Artificial Intelligence in Medical & Healthcare Domains: A Systematic Literature Review. *Computers in Biology and Medicine*, **166**, Article ID: 107555. <https://doi.org/10.1016/j.compbiomed.2023.107555>
- [28] Lundberg, S. and Lee, S.I. (2017) A Unified Approach to Interpreting Model Predictions. arXiv: 1705.07874.
- [29] Ribeiro, M., Singh, S. and Guestrin, C. (2016) "Why Should I Trust You?": Explaining the Predictions of Any Classifier. *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Demonstrations*, San Diego, June 2016, 97-101. <https://doi.org/10.18653/v1/n16-3020>
- [30] van Maurik, I.S., Doodeman, H.J., Veeger-Nuijens, B.W., Möhringer, R.P.M., Sudiono, D.R., Jongbloed, W., *et al.* (2024)

Targeted Development and Validation of Clinical Prediction Models in Secondary Care Settings: Opportunities and Challenges for Electronic Health Record Data. *JMIR Medical Informatics*, **12**, e57035-e57035. <https://doi.org/10.2196/57035>

- [31] Baron, J.M., Huang, R., McEvoy, D. and Dighe, A.S. (2021) Use of Machine Learning to Predict Clinical Decision Support Compliance, Reduce Alert Burden, and Evaluate Duplicate Laboratory Test Ordering Alerts. *JAMIA Open*, **4**, ooab006. <https://doi.org/10.1093/jamiaopen/ooab006>
- [32] Reddy, R.G., Danford, D.A. and Kutty, S. (2025) Silencing the Monitor That Cried Wolf: A Role for Artificial Intelligence. *JACC: Advances*, **4**, Article ID: 101997. <https://doi.org/10.1016/j.jacadv.2025.101997>