

# 术后新发心房颤动预测模型研究进展： 从静态评分到多模态智能矩阵

王晗哲, 王寅\*

华中科技大学同济医学院, 湖北 武汉

收稿日期: 2026年3月1日; 录用日期: 2026年3月24日; 发布日期: 2026年4月2日

## 摘要

术后新发心房颤动(POAF)是围手术期极具危害的并发症, 直接影响患者的远期预后。随着人工智能技术的迅猛发展, POAF的风险预警已实现从传统回归评分向集成机器学习(ML)与多模态深度学习(DL)架构的跨越。本文系统性地综述了2021年至2026年期间的关键技术演进, 论证了基于电生理异质性(如心房传导阻滞与非同步性)的特征选择逻辑, 深入剖析了Stacking集成架构与Transformer注意力机制在提升预测精度(AUC > 0.9)方面的数学优势。同时, 文章探讨了SHAP归因分析在重构临床信任、指导闭环干预路径中的转化价值。最后, 针对算法漂移及跨中心验证等临床转化瓶颈, 提出了持续学习与穿戴式实时监测的未来愿景, 旨在为构建高精度、可解释的围术期智慧决策平台提供理论支撑。

## 关键词

术后新发房颤, 预测模型, 机器学习, 深度学习, 风险分层, 人工智能, 可解释性分析

# Research Progress on Prediction Models for Postoperative Atrial Fibrillation: From Static Scoring Systems to Multimodal Intelligent Matrices

Hanzhe Wang, Yin Wang\*

Tongji Medical College, Huazhong University of Science and Technology, Wuhan Hubei

Received: March 1, 2026; accepted: March 24, 2026; published: April 2, 2026

## Abstract

Postoperative atrial fibrillation (POAF) is a critical perioperative complication that significantly

\*通讯作者。

文章引用: 王晗哲, 王寅. 术后新发心房颤动预测模型研究进展: 从静态评分到多模态智能矩阵[J]. 临床医学进展, 2026, 16(4): 1021-1030. DOI: 10.12677/acm.2026.1641334

impacts long-term patient prognosis. With the rapid evolution of artificial intelligence, POAF risk stratification is undergoing a fundamental paradigm shift from traditional regression-based scores to sophisticated ensemble machine learning (ML) and multimodal deep learning (DL) architectures. This review systematically evaluates key technological advancements from 2021 to 2026, elucidating the feature selection logic grounded in electrophysiological heterogeneity (e.g., conduction block and atrial asynchrony). We analyze the mathematical underpinnings of Stacking ensembles and Transformer-based Attention mechanisms in achieving superior predictive accuracy (AUC > 0.9). Furthermore, the clinical utility of SHAP-based explainability in reconstructing medical trust and guiding closed-loop intervention pathways is discussed. Finally, addressing the critical bottlenecks of clinical translation such as algorithm drift and multi-center validation, we propose future directions involving continual learning and wearable real-time monitoring to establish highly accurate, interpretable perioperative decision-support platforms.

## Keywords

Postoperative Atrial Fibrillation (POAF), Prediction Model, Machine Learning, Deep Learning, Risk Stratification, Artificial Intelligence, Explainability Analysis

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

术后新发心房颤动(Postoperative Atrial Fibrillation, POAF)是指既往无房颤病史的患者在手术后新发的房颤。在心脏外科手术(如 CABG、瓣膜置换)中,其发生率高达 25%~50% [1]-[3],而在非心脏大型手术(如肺叶切除、食管癌根治、腹主动脉瘤修复)中亦占 5%~15% [4] [5]。尽管预防性药物干预(如  $\beta$  受体阻滞剂)能够降低发生率,但过度治疗与预警滞后的矛盾依然突出。POAF 不仅仅是一个电生理异常,更是围手术期全身炎症反应、自主神经失衡及心脏结构损伤的综合表现。它被广泛且确凿地证实与一系列灾难性的级联并发症直接相关,包括 2~4 倍的中风风险、心力衰竭、ICU 及总住院时间延长、医疗费用增加,以及全因死亡率上升[6] [7]。早期的预测(如 20 世纪 90 年代的简单 Logistic 回归)多依赖于有限的临床参数[1],其辨别能力(AUC  $\approx$  0.60)难以支撑精准医疗需求。随着生物医学大数据与生成式 AI 技术的融合, POAF 预测正从“经验驱动”转向“高维数据驱动”,致力于构建具备实时动态性与临床可解释性的智慧决策系统。

## 2. 病理生理学基础: 变量选择的底层逻辑

预测模型的变量选择必须根植于其复杂的病理生理学基础[7]。根据最新的“多重打击”模型及电生理标测研究,模型变量的选取应遵循以下逻辑:

- 预设基质(Pre-existing Substrate): 主要涉及心房纤维化、心房扩大及年龄相关的电重构[6] [8]。心肌组织的纤维化改变了电传导的各向异性,为折返环的形成提供了物理基础。Kharbanda *et al.* (2021)通过术中心内-心外膜同步标测揭示,术后房性早搏(AES)不仅是触发器,更会显著增强心房传导阻滞区域并诱发非同步性。这一发现为模型引入“左房直径(LAD)”和“术前 P 波离散度”等变量提供了坚实的电生理基础[7]。
- 急性诱因(Acute Triggers): 手术应激导致的儿茶酚胺水平剧增、心房切开导致的电信号不连续性、术中缺血再灌注损伤[9]。这些诱因直接触发了心房肌细胞的早期后除极(EAD)或延迟后除极(DAD)。
- 炎症反应(Inflammatory Response): 术后全身炎症反应综合征(SIRS)导致细胞因子(如 IL-6, TNF-

$\alpha$ )释放。炎症因子通过改变离子通道(如 L-型钙通道)的表达, 导致心房电生理重构[10]。机器学习模型引入“中性粒细胞/白蛋白比值(NAR)”和“特定循环 miRNA”作为预测因子, 正是捕捉这一急性电重构的分子指标[11]。

- 氧化应激与电解质紊乱: 活性氧(ROS)的产生以及术后低钾、低镁状态, 显著降低了房性早搏触发房颤的阈值[12]。

### 3. 数据来源与特征工程: 从组学到电生理

#### 3.1. 数据来源的多维性

随着监测及数据收集技术的发展, 现代预测模型的数据源已从单一的电子病历(EMR)扩展至多模态数据集:

- 静态临床数据: 年龄、性别、BMI、基础病史(糖尿病、高血压、COPD)、药物使用情况(如  $\beta$  受体阻滞剂停药情况) [4] [13]。这些变量构成了风险评估的“底盘”。
- 实验室指标(连续变量): BNP/NT-proBNP (反映心房张力)、肌钙蛋白(反映心肌损伤)、电解质(钾、镁、钙)、肾功能指标(eGFR) [2]。
- 影像学特征: 经胸/经食管超声心动图提取的左房容积指数(LAVI)、左室射血分数(LVEF)、甚至斑点追踪成像(Speckle Tracking)提取的心房应变。最新的 Meta 分析显示, 心房应变能力的下降往往先于心房结构扩大, 是极佳的早期预测指标。
- 电生理信号: 术前/术中 12 导联 ECG 的原始波形、P 波离散度(P-wave dispersion)、P 波时程[8] [14]。
- 研究[14]表明, 深度学习可以从非房颤心电图捕捉到肉眼难以发现的电学脆弱性特征。
- 组学与遗传数据: 早期的探索性研究(Kolek *et al.*, 2015)开始尝试将单核苷酸多态性(SNPs)纳入特征空间, 探讨 4q25 染色体等区域的遗传易感性。多模态的数据来源为预测模型的建立提供了坚实的数据支持。

#### 3.2. 特征工程的数学严谨性

面对成百上千维的原始数据, 特征筛选至关重要, 现代计算机技术为特征工程提供了更完善的处理方法, 例如常用的两种方法:

- 递归特征消除(Recursive Feature Elimination, RFE): 在基于支持向量机(SVM)或随机森林构建模型时, RFE 通过反复构建模型并剔除权重最小的特征。其数学逻辑如下: 设特征集为  $F$ , 权重向量为  $w$ , 则准则函数  $J = \|w\|^2$ 。通过计算排名标准  $c_i = w_i^2$ , 逐步移除  $c_i$  最小的特征, 直到找到最佳子集。这种方法能够保留对模型贡献度最大的变量, 同时消除噪声[15]。
- 最小绝对收缩和选择算子(LASSO)回归: LASSO 是处理高维小样本数据的利器, 其通过 L1 正则化实现特征自动筛选:

$$\min_{\beta} \left\{ \sum_{i=1}^n \left( y_i - \sum_j x_{ij} \beta_j \right)^2 + \lambda \sum_j |\beta_j| \right\}$$

其中  $\lambda$  是罚项参数。当  $\lambda$  足够大时, 部分系数  $\beta_j$  会被压缩至零, 从而实现特征自动剔除。这在处理包含数百个实验室指标的数据集时尤为高效, 显著提高了模型在 POAF 预测中的鲁棒性[16]。

### 4. 算法演进: 从逻辑回归到集成架构

#### 4.1. 传统评分的局限性

在机器学习普及之前, 临床主要依赖简易评分系统: **POAF Score (Mariscalco *et al.*)**: 通过对年龄、

COPD、eGFR、手术类型等变量进行加权计分(0~2分/项)。**CHA2DS2-VASc 评分**: 虽然原用于评估非手术房颤的中风风险,但在某些研究中也借用于 POAF 预警。Pandey 等(2023)通过对 43 项研究的荟萃分析指出,这些评分系统在心脏手术人群中的 AUC 平均仅为 0.62 [6]。这些静态评分系统的失败源于其无法捕捉术中血流动力学的剧烈波动及炎症反应的动态演变。此外,这些模型多基于西方心脏手术人群开发,在非心脏手术场景及亚洲人群中的外推性能显著下降[5] [17]。

## 4.2. 逻辑回归(Logistic Regression, LR): 基准模型的持久力

尽管机器学习(ML)模型层出不穷,但逻辑回归因其卓越的可解释性,在 2023~2024 年的临床指南中仍被视为基准(Baseline) [16]。其概率映射函数(Sigmoid Function)为:

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

在 POAF 预测中,LR 的优势在于可以清晰地给出每个变量的赔率比(Odds Ratio, OR),这符合循证医学的直觉。临床医生可以通过回归系数直接判断某一风险因子的临床显著性。然而,LR 的局限性也十分明显:它难以捕捉变量间的非线性关系(如年龄与术后肌酐波动的交互作用)以及高阶交互效应,这导致其在处理复杂、高维的手术室监护数据时存在明显的“欠拟合”风险。

## 4.3. 树模型家族: 随机森林与梯度提升的崛起

集成学习(Ensemble Learning)通过组合多个弱学习器来构建强学习器,是目前 POAF 预测领域公认的最优解,自 2023 年以来,集成学习(Ensemble Learning)与梯度提升架构在 POAF 领域取得了实质性突破。

### 4.3.1. 随机森林(Random Forest, RF)

RF 通过自助采样法(Bootstrap Aggregating)构建多棵独立决策树。在处理 POAF 这种具有大量分类变量(如手术入路、麻醉药物种类)且存在数据缺失的数据集时,RF 表现出极强的鲁棒性。它通过计算基尼指数(Gini Index)下降量来评估特征重要性,为临床提供了直观的变量优先级排序[18]。

### 4.3.2. 极端梯度提升(XGBoost)与 LightGBM

这些算法代表了当前 POAF 风险预测的性能巅峰。其核心改进在于对目标函数进行了二阶泰勒展开,并引入了正则化项以防止过拟合:

$$obj^{(t)} \approx \sum_{i=1}^n \left[ g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t)$$

其中  $g_i$  和  $h_i$  分别是一阶和二阶导数。通过精确的正则化控制,XGBoost 在 2025 年多项针对瓣膜手术及大血管手术的研究中,AUC 均突破了 0.88。其能够敏锐捕捉到细微的围手术期生理波动,如术中平均动脉压(MAP)的瞬时下降[19]。

## 4.4. 堆叠架构(Stacking): 跨模型智能集成

Ma *et al.*提出了一种集成 11 个基学习器的 AI 堆叠模型(Stacking Model) [20] [21]。在针对冠状动脉旁路移植术(CABG)患者的外部验证中,该模型 AUC 达到了 0.931,远超传统 HATCH 评分(0.708)与 POAF 评分(0.667)。这种性能提升得益于算法对高维非线性特征交互的捕捉能力。Stacking 架构是一种“众议院式”的决策模型。

- **底层(Level-0)**: 使用多种异构算法(如 SVM 捕捉线性特征、KNN 捕捉局部相似性、RF 捕捉非线性关系)。

- **顶层(Level-1):** 通常使用一个简单的模型(如逻辑回归)对底层模型的预测结果进行加权融合。

Sau 等(2024)在 *The Lancet Digital Health* 发表的研究[22]显示, AIRE 平台在大规模外部验证集上的表现优于任何单一模型, 其 C-index 在不同队列中均表现稳健。这种架构通过捕捉多维电生理特征, 显著提升了模型在不同中心(不同手术风格、不同族群)应用时的稳定性。

## 5. 深度学习前沿: 多模态信号处理

### 5.1. 原始心电信号(Raw ECG)的端到端学习

传统的 POAF 预测高度依赖于医生手工提取的特征(如 P 波离散度、QT 间期)。而深度学习(Deep Learning, DL)彻底改变了这一现状, 这主要基于卷积神经网络(Convolutional Neural Network, CNN)和循环神经网络(Recurrent Neural Network, RNN)的进一步应用。

#### 5.1.1. 卷积神经网络(CNN)的空间特征提取

卷积神经网络(CNN)正被用于直接分析术前连续心电图(ECG)波形。对于一维 ECG 序列, 卷积运算能够自动捕捉隐藏在 P 波起始处的微弱电不稳定信号(Electrical Instability):

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau)g(t-\tau)d\tau$$

Tohyama 等(2023)的研究证明, 基于 CNN 的深度学习模型能够识别出心房微小的电重构特征, 这种端到端的学习模式在预警能力上显著优于传统临床评分[14] [23]。

#### 5.1.2. 循环神经网络(RNN)的时序建模

POAF 的发生是一个动态演进的过程, 术中生理参数的变化具有极强的时序依赖性。长短期记忆网络(Long Short-Term Memory, LSTM)通过引入“遗忘门”机制, 解决了长序列训练中的梯度消失问题:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

这使得模型能够“记忆”手术开始阶段的异常低血压波动如何通过后续的缺血再灌注损伤影响术后的心房节律, 实现真正的“全流程监控” [24]。

### 5.2. 注意力机制(Attention Mechanism)与多模态融合

2025~2026 年最前沿的技术是基于 Transformer 架构[25] [26]的多头注意力机制。模型不再局限于单一数据源, 而是构建了一个多模态融合矩阵:

- **静态层:** 基线病史、遗传多态性数据(SNPs)。
  - **动态层:** 术中监护仪实时产生的波形(血压、SpO<sub>2</sub>、呼气末 CO<sub>2</sub>)。
  - **文本层:** 收集语义特征, 如手术记录内容等文本信息, 识别手术记录中的定性描述等。
- 通过注意力权重公式:

$$Attention(Q, K, V) = \text{soft max} \left( \frac{QK^T}{\sqrt{d_k}} \right) V$$

允许模型根据患者状态动态调整不同因子的权重。例如, 在高龄患者中, 模型会自动聚焦于“电解质波动”特征, 这种动态加权机制极大地增强了模型的个性化预测能力。Han 等(2025)在针对心脏手术患者的研究中发现, 这种基于 AI-ECG 的多模态融合模型能够捕捉传统临床评分无法反映的心房电生理脆弱性[14], 显著提升了预测精度。

## 6. 预测模型的信任重构：评价体系与可解释性分析

### 6.1. 评价体系的多维化演进

在 POAF 这种样本高度不平衡的临床场景下，传统的 AUC 指标有时会给出过于乐观的估计。现代评价体系引入了更多维度的指标：

- **AUPRC (精度 - 召回率曲线下面积)**: AUPRC 更加关注对“阳性样本”（即发生 POAF 的患者）的捕获能力，是衡量模型在实际病房应用中是否会漏诊的关键指标。
- **校准度曲线(Calibration Curve)**: 评估模型预测的概率与临床实际发生率之间的吻合程度。一个完美的预测模型应分布在 45 度对角线上。
- **决策曲线分析(Decision Curve Analysis, DCA)**: DCA 能够告诉临床医生，在不同的风险阈值下，应用该模型相比于“对所有患者进行预防”或“不进行任何预防”能带来多少“净获益” [16]。

### 6.2. 破解“黑盒”：SHAP 与 LIME 的算法叙事

为解决“黑盒”模型在临床准入中的瓶颈，SHAP (SHapley Additive exPlanations)等归因分析工具已成为主流。通过量化个体患者中左房直径(LAD)、B 型利钠肽(BNP)等因子对预测结果的贡献度，ML 模型不仅提供了概率预测，更为临床医生提供了可理解的决策依据[27]。

- **SHAP (SHapley Additive exPlanations)**: 基于合作博弈论。它为每个特征分配一个“贡献值”。其核心公式为计算特征  $i$  的边际贡献：

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(n-|S|-1)!}{n!} [v(S \cup \{i\}) - v(S)]$$

通过 SHAP 力图(Force Plot)，医生可以看到：“这个患者被判定为高危，主要是因为其术后 BNP 升高贡献了+0.15，而其年龄贡献了+0.10。” [27]

- **LIME (Local Interpretable Model-agnostic Explanations)**: 通过在单个样本周围进行局部线性拟合，揭示模型在特定决策点的逻辑。

## 7. 临床转化：走向闭环干预与应对算法漂移

### 7.1. 现状解构：非选择性干预的效能滞后与潜在风险

预测模型的终极价值在于指导干预，传统的 POAF 预防高度依赖“非选择性(Non-selective)”的经验干预，如广泛使用胺碘酮或预防性心外膜起搏。然而，这种“一刀切”策略忽视了患者个体的病理生理异质性，不仅导致医疗资源利用率低下，更增加了心动过缓、低血压及器官毒性等医源性并发症风险。当前的临床瓶颈在于干预时机往往滞后于心房电生理的不可逆重构。因此，临床路径亟需从基于症状的“被动防御”转向基于精准分层的“主动拦截” [28]。

### 7.2. 基于决策曲线分析(DCA)的干预路径映射

将高维机器学习生成的概率(Probability)转化为可执行的临床指令(Instruction)是决策支持系统(Clinical Decision Support System, CDSS)的核心逻辑。我们主张利用决策曲线分析(Decision Curve Analysis, DCA)来量化不同风险阈值下的“净获益(Net Benefit)”，从而确定临床触发点，建立多重干预路径的动态映射。

- **动态映射机制**: 例如，当系统结合术中多模态数据(如体外循环撤机时的细微电生理波动、MAP 持续低于 60 mmHg 伴异常心房应变)计算出术后 48 小时内 POAF 概率极高时，CDSS 应无缝对

接电子病历(EMR)系统, 自动触发高危临床路径, 发出指令。

- **指令化操作:** 系统不仅发出警报, 应直接触发“高危临床路径”——包括在气管拔管前强制性优化内环境(如精准补镁, 使血镁维持在 $>1.0$  mmol/L)、向 ICU 自动推送预警简报, 并启动特级心电图遥测及预防性抗心律失常药物储备。

### 7.3. 未来展望: 构建“围术期数字孪生(Perioperative Digital Twin)”

未来的 CDSS 演进不再局限于术前单一时间点的静态评估, 而旨在构建“术前基质识别 - 术中电生理演变 - 术后动态分层”的全周期智能反馈环路。这一范式实质上映射为一种高特异性的“围术期数字孪生(Perioperative Digital Twin, PDT)” [29]: 该系统利用贝叶斯更新(Bayesian Updating)机制, 能够随逐搏血压、实时心电图特征流等连续生理信号的输入, 动态校准个体的风险轨迹[30]。这种具备极高时间分辨率的监测模式, 能够精准捕捉心房脆弱性的“瞬时窗口”, 从而将临床干预由被动补救转向主动精准预防。

然而, 构建高保真、实时动态的围术期数字孪生模型仍面临严峻的技术壁垒。首要挑战在于异构医疗数据流的深度集成, 手术室高频生理波形与非结构化临床记录在存储协议、时间粒度及语义描述上的巨大差异, 构成了严重的互操作性障碍, 亟需通过知识图谱等技术实现语义对齐[29] [30]。其次是实时计算效率与模型复杂度的博弈: 虽然高维深度学习(如图神经网络)能显著提升生理机制的可解释性, 但其庞大的计算负载与闭环预警的超低延迟要求存在固有冲突, 这使得算力下沉至边缘计算设备成为必然选择[31] [32]。最后是生物学一致性(Biological Consistency)的验证瓶颈: 确保虚拟模型预测符合人体复杂生理逻辑而非仅为统计学相关, 仍需建立跨学科、多中心的标准化验证方案及临床信任框架, 这也是实现从实验室到临床转化的核心门槛[33]。

### 7.4. 应对“算法漂移(Algorithm Drift)”

随着微创技术与围手术期管理的迭代, 基于历史数据训练的模型会出现效能衰减, 这就是算法漂移(Algorithm Drift)。未来的模型应具备“持续学习(Continual Learning)”能力, 通过实时反馈数据对权重矩阵进行在线微调, 以适配不断演进的临床实践。

### 7.5. 论证前瞻: 跨越临床转化的必然路径

单纯提高 AI 算法的辨别力(如  $AUC > 0.9$ )并不必然等同于患者预后的实际改善。预测模型跨越临床转化“死亡谷”的唯一途径, 是其卓越的工作流集成度(Workflow Integration)。未来的大型前瞻性研究不仅要验证模型的统计学精度, 更应致力于证明闭环设计下的 CDSS 能够有效克服“警报疲劳”(Alert Fatigue)。只有通过严密的随机对照试验(RCT)确立“AI 驱动的精准确干预”优于“标准护理”, 才能确立该系统在降低卒中发生率、缩短心脏监护室(CCU/ICU)滞留时间以及优化整体医疗资源分配上的确切临床净获益, 最终确立 AI 临床转化的地位。

## 8. 总结

经过 2023~2026 年的跨越式发展, 术后新发房颤预测模型已经完成了从“静态统计模型”向“动态智能预警系统”的蜕变。集成学习成功解决了临床变量间的复杂交互问题, 而深度学习和注意力机制的引入, 使得利用原始电生理信号进行端到端预测成为可能。这些技术共同将预测精度(AUC)从传统评分的 0.6 时代带入了 AI 的 0.9 时代。

尽管性能卓越, 但目前该领域仍面临四大瓶颈:

- **多中心泛化性壁垒:** 现有主干网络多基于单中心队列训练, 面对不同医疗机构在手术入路、麻醉路径及人群异质性上的差异, 模型在外部验证时常遭遇显著的性能衰减(Performance Degradation)。

- 临床演进中的算法漂移(Algorithm Drift) [17] [34]: 随着微创心脏外科技术的迭代与围术期管理策略的革新, 基于历史队列锚定的模型权重极易脱离当前临床实际, 导致预测效能的隐性退化。
- 前瞻性循证医学证据匮乏: 当前研究仍以回顾性验证为主, 亟需高质量的大规模前瞻性随机对照试验(RCT), 以确证“AI 驱动的风险分层”能否切实转化为卒中风险降低、重症监护室滞留时间缩短等硬性临床净获益。
- 算法复杂性与临床部署的博弈: 从简单评分到复杂 Transformer 架构, 精度在不断进化, 但模型复杂性的增加亦带来了副作用。Rudin 指出[35], 在高风险临床决策中, 盲目追求黑盒模型会牺牲决策的透明度, 应当遵循奥卡姆剃刀原则。此外, 高精度的深度学习架构对算力有极高依赖, 在资源受限的基础医疗机构往往难以部署[36]。更重要的是, 其庞大的参数逻辑难以映射为直观的生理学解释, 导致临床信任度下降[31]。因此, 在构建临床预警系统时, 不应盲目追求架构复杂性, 而应在保证足够区分度的前提下, 遵循奥卡姆剃刀原则, 优先选择轻量化、高透明度且易于集成的算法方案。

展望未来, 随着计算医学的不断拓展, POAF 的风险管理必将深度融入精准医疗的宏大图景。未来的研究重点或将聚焦于以下三个维度:

- **迁移学习(Transfer Learning)的下沉应用:** 依托大型医疗中心构建预训练基础大模型, 通过少量本地数据微调(Fine-tuning), 使算法能够低成本、高效率地适配不同规模的基层医院[19] [25]。
- **医疗级可穿戴设备的无缝集成[24]:** 将轻量化的风险预警算法嵌入柔性心电贴片或智能终端, 实现从 ICU 监护到居家康复的围术期全周期长程监测。实现从手术室到家庭的长程、无缝监测。
- **围术期数字孪生(PDT)与自动化闭环干预:** 这是 POAF 管理的终极范式。基于“风险计算 - 自动滴定”逻辑, 系统在感知到心房电生理脆弱阈值逼近时, 可联动微量泵精准释放抗心律失常药物或优化内环境参数。这种“感知 - 响应”闭环将真正践行“上医治未病”的预防医学理念。

## 参考文献

- [1] El-Sherbini, A.H., Shah, A., Cheng, R., Elsebaie, A., Harby, A.A., Redfearn, D., *et al.* (2023) Machine Learning for Predicting Postoperative Atrial Fibrillation after Cardiac Surgery: A Scoping Review of Current Literature. *The American Journal of Cardiology*, **209**, 66-75. <https://doi.org/10.1016/j.amjcard.2023.09.079>
- [2] Mariscalco, G., Biancari, F., Zanobini, M., Cottini, M., Piffaretti, G., Saccocci, M., *et al.* (2014) Bedside Tool for Predicting the Risk of Postoperative Atrial Fibrillation after Cardiac Surgery: The POAF Score. *Journal of the American Heart Association*, **3**, e000752. <https://doi.org/10.1161/jaha.113.000752>
- [3] Suero, O.R., Ali, A.K., Barron, L.R., Segar, M.W., Moon, M.R. and Chatterjee, S. (2024) Postoperative Atrial Fibrillation (POAF) after Cardiac Surgery: Clinical Practice Review. *Journal of Thoracic Disease*, **16**, 1503-1520. <https://doi.org/10.21037/jtd-23-1626>
- [4] Amar, D., Zhang, H., Tan, K.S., Piening, D., Rusch, V.W. and Jones, D.R. (2019) A Brain Natriuretic Peptide-Based Prediction Model for Atrial Fibrillation after Thoracic Surgery: Development and Internal Validation. *The Journal of Thoracic and Cardiovascular Surgery*, **157**, 2493-2499.e1. <https://doi.org/10.1016/j.jtcvs.2019.01.075>
- [5] Oh, A.R., Park, J., Shin, S.J., Choi, B., Lee, J., Yang, K., *et al.* (2023) Prediction Model for Postoperative Atrial Fibrillation in Non-Cardiac Surgery Using Machine Learning. *Frontiers in Medicine*, **9**, Article 983330. <https://doi.org/10.3389/fmed.2022.983330>
- [6] Pandey, A., Okaj, I., Ichhpuniani, S., Tao, B., Kaur, H., Spence, J.D., *et al.* (2023) Risk Scores for Prediction of Postoperative Atrial Fibrillation after Cardiac Surgery: A Systematic Review and Meta-Analysis. *The American Journal of Cardiology*, **209**, 232-240. <https://doi.org/10.1016/j.amjcard.2023.08.161>
- [7] Kharbanda, R.K., van Schie, M.S., Taverne, Y.J.H.J., de Groot, N.M.S. and Bogers, A.J.J.C. (2021) Novel Insights in Pathophysiology of Postoperative Atrial Fibrillation. *JTCVS Open*, **6**, 120-129. <https://doi.org/10.1016/j.xjon.2021.01.014>
- [8] Kolek, M.J., Muehlschlegel, J.D., Bush, W.S., Parvez, B., Murray, K.T., Stein, C.M., *et al.* (2015) Genetic and Clinical Risk Prediction Model for Postoperative Atrial Fibrillation. *Circulation: Arrhythmia and Electrophysiology*, **8**, 25-31. <https://doi.org/10.1161/circep.114.002300>

- [9] Li, J., Liu, S., Hu, Y., Zhu, L., Mao, Y. and Liu, J. (2022) Predicting Mortality in Intensive Care Unit Patients with Heart Failure Using an Interpretable Machine Learning Model: Retrospective Cohort Study. *Journal of Medical Internet Research*, **24**, e38082. <https://doi.org/10.2196/38082>
- [10] Lee, J.Y. (2023) Surrogacy: Beyond the Commercial/Altruistic Distinction. *Journal of Medical Ethics*, **49**, 196-199. <https://doi.org/10.1136/medethics-2021-108093>
- [11] Lee, J., Lee, H., Sherbini, A.E., Baghaie, L., Leroy, F., Abdel-Qadir, H., *et al.* (2024) Epigenetic MicroRNAs as Prognostic Markers of Postoperative Atrial Fibrillation: A Systematic Review. *Current Problems in Cardiology*, **49**, Article 102106. <https://doi.org/10.1016/j.cpcardiol.2023.102106>
- [12] Zhao, R., Wang, Z., Cao, F., Song, J., Fan, S., Qiu, J., *et al.* (2021) New-Onset Postoperative Atrial Fibrillation after Total Arch Repair Is Associated with Increased In-Hospital Mortality. *Journal of the American Heart Association*, **10**, e021980. <https://doi.org/10.1161/jaha.121.021980>
- [13] Collins, G.S., Reitsma, J.B., Altman, D.G. and Moons, K.G.M. (2015) Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or Diagnosis (TRIPOD): The TRIPOD Statement. *British Medical Journal*, **350**, g7594. <https://doi.org/10.1136/bmj.g7594>
- [14] Han, H., Zhang, J., Wang, X., Ge, W. and Qu, J.Z. (2025) Development of an Interpretable Machine Learning Model to Predict Short-Term Bleeding Risk in Patients Receiving Dual Antithrombotic Therapy Following Cardiac Surgery. *International Journal of Clinical Pharmacy*, **48**, 513-523. <https://doi.org/10.1007/s11096-025-02016-9>
- [15] Lu, Y., Chen, Q., Zhang, H., Huang, M., Yao, Y., Ming, Y., *et al.* (2023) Machine Learning Models of Postoperative Atrial Fibrillation Prediction after Cardiac Surgery. *Journal of Cardiothoracic and Vascular Anesthesia*, **37**, 360-366. <https://doi.org/10.1053/j.jvca.2022.11.025>
- [16] Steyerberg, E.W. (2019) *Clinical Prediction Models: A Practical Approach to Development, Validation, and Updating*. Springer.
- [17] Smith, L.A., Oakden-Rayner, L., Bird, A., Zeng, M., To, M., Mukherjee, S., *et al.* (2023) Machine Learning and Deep Learning Predictive Models for Long-Term Prognosis in Patients with Chronic Obstructive Pulmonary Disease: A Systematic Review and Meta-Analysis. *The Lancet Digital Health*, **5**, e872-e881. [https://doi.org/10.1016/s2589-7500\(23\)00177-2](https://doi.org/10.1016/s2589-7500(23)00177-2)
- [18] Breiman, L. (2001) Random Forests. *Machine Learning*, **45**, 5-32. <https://doi.org/10.1023/a:1010933404324>
- [19] Shakhgeldyan, K.I., Rublev, V.Y., Kuksin, N.S., Geltser, B.I. and Pak, R.L. (2026) Multilevel Predictors Categorization for Post-CABG Atrial Fibrillation Prediction. *Biology Methods and Protocols*, **11**, bpaf092. <https://doi.org/10.1093/biomethods/bpaf092>
- [20] Ma, W.J., Chen, S.J., Zhao, Y., *et al.* (2025) Machine Learning Models and Restricted Cubic Spline Were Employed to Analyze and Predict Postoperative Ischemic Stroke in Type A Aortic Dissection Patients. *BMC Cardiovascular Disorders*, **26**, Article 34.
- [21] Gong, Z., Haiarla, S., Shi, J. and Liu, X. (2025) Construction of a Risk Prediction Model for Postoperative Atrial Fibrillation in Lung Cancer Patients Based on Multi-Dimensional Feature Fusion and Ensemble Learning. *Frontiers in Cardiovascular Medicine*, **12**, Article 1679973. <https://doi.org/10.3389/fcvm.2025.1679973>
- [22] Sau, A., Pastika, L., Sieliwonczyk, E., Patlatzoglou, K., Ribeiro, A.H., McGurk, K.A., *et al.* (2024) Artificial Intelligence-Enabled Electrocardiogram for Mortality and Cardiovascular Risk Estimation: A Model Development and Validation Study. *The Lancet Digital Health*, **6**, e791-e802. [https://doi.org/10.1016/s2589-7500\(24\)00172-9](https://doi.org/10.1016/s2589-7500(24)00172-9)
- [23] Tohyama, T., Ide, T., Ikeda, M., Nagata, T., Tagawa, K., Hirose, M., *et al.* (2023) Deep Learning of ECG for the Prediction of Postoperative Atrial Fibrillation. *Circulation: Arrhythmia and Electrophysiology*, **16**, e011579. <https://doi.org/10.1161/circep.122.011579>
- [24] Zillner, L., Andreas, M. and Mach, M. (2024) Wearable Heart Rate Variability and Atrial Fibrillation Monitoring to Improve Clinically Relevant Endpoints in Cardiac Surgery—A Systematic Review. *mHealth*, **10**, Article 8. <https://doi.org/10.21037/mhealth-23-19>
- [25] Kaur, H., Chen, H., Catrip, J., Weitzel, N. and Liu, H. (2026) Predicting Postoperative Atrial Fibrillation: An Explainable Deep Learning Approach. *Journal of Biomedical Research*, **40**, 1. <https://doi.org/10.7555/jbr.39.20250387>
- [26] Vaswani, A., Shazeer, N., Parmar, N., *et al.* (2017) Attention Is All You Need. <http://arxiv.org/abs/1706.03762>
- [27] Lundberg, S.M. and Lee, S.I. (2017) A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems*.
- [28] Nguyen, V., Garg, S. and Mittal, R. (2025) Machine Learning Prediction of Intensive Care Unit Outcomes in Atrial Fibrillation Patients: A Rapid Review. *Cureus*, **17**, e99732. <https://doi.org/10.7759/cureus.99732>
- [29] Zhang, Y., Shi, K. and Li, B. (2025) A Brief History of Digital Twin Technology.

- [30] Nye, L. (2023) Digital Twins for Patient Care via Knowledge Graphs and Closed-Form Continuous-Time Liquid Neural Networks.
- [31] Mesinovic, M., Buhlan, M. and Zhu, T. (2025) Causal Graph Neural Networks for Healthcare.
- [32] Saxena, S. and Kovesdy, A. (2026) Real-World Applications of AI in LTE and 5G-NR Network Infrastructure.
- [33] Lyu, Y.L., Li, Z., Tran, V., *et al.* (2026) Building Digital Twins of Different Human Organs for Personalized Healthcare.
- [34] Liu, Y., Han, L., Li, J., Gong, M., Zhang, H. and Guan, X. (2017) Consumption Coagulopathy in Acute Aortic Dissection: Principles of Management. *Journal of Cardiothoracic Surgery*, **12**, Article No. 50. <https://doi.org/10.1186/s13019-017-0613-5>
- [35] Rudin, C. (2019) Stop Explaining Black Box Machine Learning Models for High Stakes Decisions and Use Interpretable Models Instead. *Nature Machine Intelligence*, **1**, 206-215. <https://doi.org/10.1038/s42256-019-0048-x>
- [36] Yang, Z., Raymond, O.I., Zhang, C., Wan, Y. and Long, J. (2018) DFterNet: Towards 2-Bit Dynamic Fusion Networks for Accurate Human Activity Recognition. *IEEE Access*, **6**, 56750-56764. <https://doi.org/10.1109/access.2018.2873315>