心电信号中心律失常检测的优化混合特征工程：优化框架

Moirangthem Tiken Singh[a,*]、Manibhushan Yaikhom[b]

[a]迪布鲁加尔大学工程技术学院（*DUIET*）计算机科学与工程系，迪布鲁加尔大学，印度阿萨姆邦迪布鲁加尔[b]印度曼尼普尔邦因帕尔区域医学科学研究所物理医学与康复系

arXiv:2601.00192v1 [cs.LG] 1 Jan 2026

摘要

心血管疾病，尤其是心律失常，仍是全球主要死亡原因之一，因此亟需通过医疗物联网（IoMT）进行持续监测。然而，最先进的深度学习方法通常带来高昂的计算开销，使其不适用于资源受限的边缘设备。本研究提出一种资源高效、以数据为中心的框架，优先考虑特征工程而非模型复杂度。我们优化的处理流程使复杂、高维的心律失常数据实现线性可分。这是通过将时频小波分解与图论结构描述符（如 PageRank 中心性）相结合来实现的。随后，利用互信息和递归消除对这一结合小波分解与图论描述符的混合特征空间进行优化，从而实现可解释、超轻量级的线性分类器。在 MIT-BIH 和 INCART数据集上的验证表明，诊断准确率达到 98.44%，模型占用空间仅为 8.54 千字节。该系统在每次心搏 52 毫秒的处理流程中，实现了 0.46 μ秒的分类推理延迟，确保实时运行。这些成果相较于 KD-Light（25 千字节，准确率 96.32%）等压缩模型，效率提升了一个数量级，为无电池心脏传感器的发展提供了助力。

关键词： 心电图心律失常检测、混合特征工程、医疗物联网、线性可分性、图论描述符、边缘人工智能、实时监测、小波分解、线性分类器

rs

1. 引言

心血管疾病（CVD）仍是全球首要死因，2023年估计造成1920万人死亡，较1990年的1310万人显著增加，凸显了日益加重的公共卫生负担 [1]。尤其是心律失常，往往是缺血性卒中和心脏骤停等严重并发症的重要先兆 [2]。在人口老龄化和非传染性疾病风险上升的推动下，心律失常患病率持续攀升，进一步凸显了对可扩展诊断方案的需求。医疗物联网（IoMT）的兴起带来了变革性机遇，可将心脏监测从间歇性的Holter评估转变为持续的实时监测 [3]。然而，要实现这一

*通讯作者电子邮箱： tiken.m@dibru.ac.in（Moirangthem Tiken Singh）、mbyaikhom@gmail.com（Manibhushan Yaikhom）

潜力仍面临一个根本性的不对称问题：传感器硬件日益小型化、能效不断提升，而相应的信号解释算法却变得愈发复杂、计算密集，从而限制了其在资源受限平台上的部署 [4]。

高效的基于边缘的监测系统需要满足三项关键标准：诊断准确性可与专家临床判断相媲美；能耗符合微控制器的限制；可解释性足以建立临床信任。历来，研究侧重于诊断准确性，最终形成了以模型为中心的框架，并由先进的深度神经网络架构主导，包括卷积神经网络（CNN）和 Transformer [5]。尽管这些模型取得了较高的准确率指标，但其运作方式难以洞察，不仅会给边缘基础设施带来显著的功耗负担，仅推理的功耗就往往超过 100 mW，还缺乏医学验证所必需的透明决策机制。定量分析表明，与线性替代方案相比，这类架构可能会将延迟增加 10^3 至 10^4 倍，从而加剧长期监测场景中的电池耗电 [6]。传统的补救策略（例如通过量化进行模型压缩）往往需要以性能为代价，准确率通常会下降 1%–5%；同时，这些策略也无法弥补可解释性不足的问题，因为经过弱化处理的不透明模型依旧从根本上缺乏透明度 [7], 。这凸显了对替代范式的需求，以从根本上应对这些挑战。因此，为克服这些长期存在的局限，并满足对效率与可解释性的迫切需求，本研究提出有必要从根本上重新评估现有方法，将重点从架构复杂性转向以特征为中心的优化。

我们假设，通过系统化、基于领域知识的变换，可将多层面、高维的心律失常数据流形映射为线性可分表示，从而便于使用超轻量且可解释的线性分类器。为此，我们构建混合特征集成，将基于小波的时频分解 [8] 与图论结构指标[9], 相结合，从而将分类流形简化为基础线性求解器能够处理的形式，同时保留可分性指标。

为验证这一假设并指导研究，本研究探讨以下三个主要研究问题：

(1) 混合特征工程在多大程度上能够实现心律失常分类的线性可分性，从而以较低的计算开销实现高准确率诊断？(2) 与深度学习范式相比，在性能、模型大小和推理延迟方面有哪些可量化的权衡？(3) 该框架在不同数据集（包括单导联和多导联配置）上的稳健性如何？

针对这些问题，所提出的框架展现出稳健的性能优势，包括高准确率、计算效率和固有的可解释性。通过 MIT-BIH [10] 和 INCART [11], 等基准进行验证，结果证实，我们的可解释线性模型能够实现临床级

诊断，能够有效区分不同形态，为可信、低延迟的边缘人工智能铺平道路。

2. 文献综述

心律失常自动检测经历了变革性的发展，从基于启发式方法的信号处理转向高容量深度学习架构。本节将当前最先进方法划分为四个主题领域：深度学习范式、面向边缘端的模型压缩、混合特征工程，以及近期向轻量级线性可分性方法的转变。

近年来，心律失常分类领域的突破主要由卷积神经网络（CNN）和循环神经网络（RNN）推动。利用 MIT-BIH 数据库 [12] 开展的研究表明，一维卷积神经网络能够直接从原始心电信号中学习层次化形态学特征，准确率超过 99% [13, 14]。Manal Alghieth [5] 近期证明，基于 Transformer 的模型可利用自注意力机制捕捉长程时间依赖关系，从而进一步提高对罕见异位搏动的敏感度。同样，门控循环单元（GRU）在对长期动态心电图记录的序列特性进行建模方面也已证明有效 [15]。Reshad 等人 [16] 对 2022 至 2025 年的 30 项深度学习研究进行了全面综述，指出 CNN-RNN 混合模型的准确率最高可达 99.93%，但计算开销较大。Kim 等人 [17]提出了一种混合 CNN-Transformer 模型，无需识别 R 波峰即可检测心律失常，并在大型数据集中实现了 97.8% 的精确率。然而，这些模型通常需要数百万个可训练参数，因此需要高性能 GPU，并会产生显著的推理延迟，限制了其在边缘设备上的实用性 [18]。尽管这些深度学习模型的准确率令人瞩目，但其固有的高计算开销和庞大的参数量仍是部署到资源受限边缘设备上的重大瓶颈，因此亟需采用替代范式。

为弥合临床级准确率与边缘端可行性之间的差距，研究人员探索了多种模型压缩技术，例如 8 位量化和知识蒸馏。 [19] 中的作者利用 TensorFlow Lite 将 ResNet 和 MobileNet 架构压缩至约 70 千字节，同时保持了 93.7% 的准确率。同样，KD-Light 框架 [20] 采用知识蒸馏，生成了一个比教师模型小的学生模型 1242×，但性能显著下降至 96.32%。其他方法则侧重于硬件协同优化，利用基于 FPGA 的加速器 [21]降低量化深度卷积神经网络（DCNN）的功耗 [22]。An 等人 [23] 开发了轻量级融合 Transformer（LFT）模型，旨在应对处理来自可穿戴设备的含噪、动态心电信号所面临的挑战。与传统自注意力架构相比，该模型在参数量减少 72% 的同时，达到了 99.32% 的准确率。Jiang 等人 [24] 提出了 DCETEN，这是一种采用剪枝技术的轻量级 Transformer 网络，在 MIT-BIH 上以较低的资源需求实现了 99.84% 的准确率。这些方法体现了一种根本性的帕累托权衡：极端压缩往往会牺牲诊断精度，尤其是在区分形态相似的类别时

如室上性和正常心搏 [7]。

尽管模型压缩在一定程度上缓解了这一问题，另一条研究路线指出，如果通过领域知识引导的特征工程有效地展开底层数据流形，分类器的复杂度便可大幅降低，从而有望规避模型压缩固有的性能权衡。结合离散小波变换（DWT）进行频谱分析与统计矩（偏度、峰度）的混合方法，在构建稳健的特征表示方面展现出良好前景[25, 26, 27]。近期研究还引入了 PageRank 中心性等图论描述符，以量化心搏间相似性，将心电图记录视为结构网络，而非单纯的时序序列 [9]。Bian 等人 [28] 证明，在压缩感知域中对信号进行分类可以降低能耗，但代价是准确率下降。此外，浅层状态空间模型已成为一种抗噪的边缘监测替代方案，但在多分类场景中的表现有限 [29]。Mechichi 和 Benzarti [30] 提出了一种用于心电图分类的 CNN-BiLSTM-注意力混合模型，通过 SMOTE 平衡实现了 99.20% 的准确率。Varalakshmi 和 Sankaran [31] 开发了一种 BiLSTM-随机森林模型，准确率达到 98.84%，并采用主成分分析进行特征降维。Raunsay 等人 [32] 改进了一种混合 Transformer BERT-CNN，在不进行 R 峰检测的情况下，于 MIT-BIH 上达到 99% 的准确率。

现有文献为高准确率深度学习模型或超低功耗压缩感知提供了稳健的基础，但在能够以不足 10 KB 的内存占用实现临床级准确率（$> 98\%$）的框架方面，仍存在关键空白。目前大多数轻量级模型仍依赖浅层神经网络；即使经过量化，这些网络仍具有较大的计算深度和延迟[33, 34]。Pósfay 等人 [35] 提出了 LLT-ECG，这是一种基于线性定律的特征提取方法，使用简单分类器即可实现近似线性可分性，准确率达 96.4%。本研究提出一种混合特征增强策略，以弥补这一空白。与以模型为中心的最先进水平方法不同，我们将复杂性的重心从分类器转移至特征空间，并采用 2 导联配置，通过线性求解器实现微秒级的超快速推理。该策略旨在证明，严谨的特征工程能够达到深度网络的诊断效能，同时满足下一代心脏边缘设备最严格的硬件约束。

3. 方法

如图 1 所示，心电图分类流程旨在构建用于心律失常检测的稳健监督学习框架。该流程通过一系列经过优化的阶段，将原始多通道心电图记录转换为高维判别性特征矩阵，具体包括：预处理、R 波峰值检测、自适应分段、特征提取和数据增强。随后，通过特征选择、降维和类别平衡，为分类准备数据。每个组件均被 formulated 为一个优化问题，旨在最大化信号质量、信息保留或分类准确率，具体内容将在后续章节中详述。

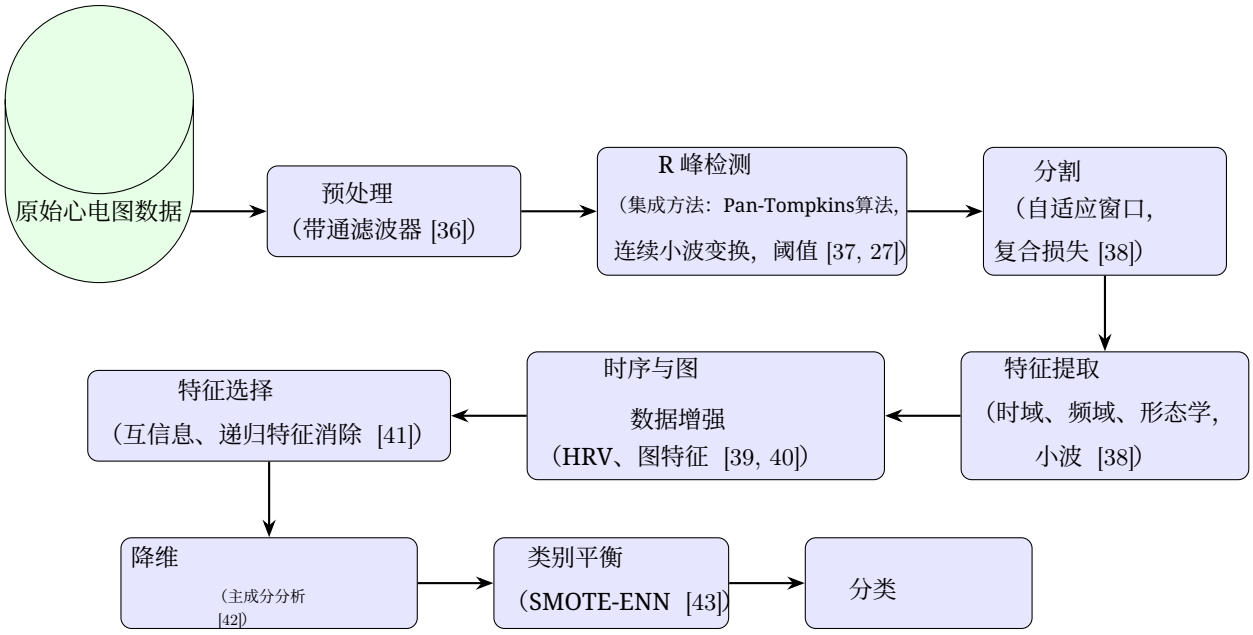

图 1：用于心律失常检测的心电图分类流程

初始阶段重点在于衰减基线漂移和高频噪声，因为这些因素可能掩盖 QRS 波群并降低检测准确率。为确保信号保真度，我们采用带通巴特沃斯滤波器，在严格保留 QRS 波群形态的同时，尽量减少带外能量。其通带与标准心电图频谱（0.5–40 Hz）保持一致，以捕获具有临床相关性的成分，同时滤除伪影 [36]。

在数字实现中，通过双线性变换从模拟原型推导出离散时间系数，以防止频率扭曲 [44]。滤波器采用二阶节（双二阶滤波器）级联实现，以增强数值稳定性，其传递函数如下：

$$H(z) = \prod_{k} \frac{b_{0k} + b_{1k} z^{-1} + b_{2k} z^{-2}}{a_{0k} + a_{1k} z^{-1} + a_{2k} z^{-2}} \tag{1}$$

其中，系数 b_{ik} 和 a_{ik} 经过优化，以最大限度地减少通带波纹。通过正向和反向应用实现零相位滤波，从而消除相位失真——这对于保留时域特征的时间信息至关重要。图2展示了这一阶段的有效性。

恢复信号保真度后，处理流程进入 R 峰检测阶段，这是准确定位心动周期的前提。我们采用集成方法，结合 Pan-Tompkins算法（微分和积分）、连续小波变换（墨西哥帽小波能量最大化）以及自适应阈值处理 [37, 27]。如图3所示，检测器根据基于峰度的信号质量指数（SQI）进行加权，优先处理高质量输入。检测到的峰值会在生理不应期容差范围内合并，以消除重复峰值。

后续分割可划分出各个心搏。为解决由心律不齐引起的 RR间期变异，

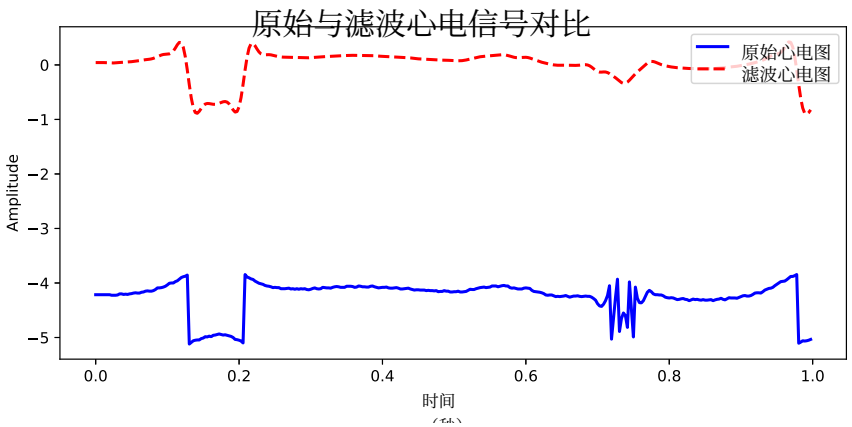

图2：C　　比较原始心电信号与预处理心电信号，展示滤波和噪声去除的效果　　al

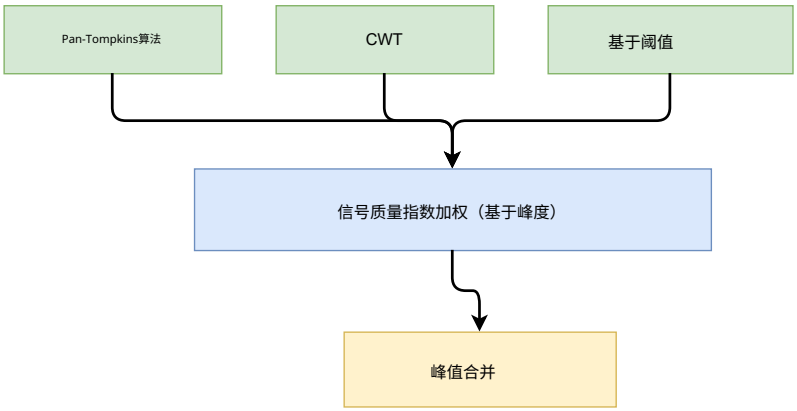

图3：采用信号质量指数加权的 R 峰检测集成方法

心律失常，我们采用　采用一种自适应窗化技术，为每个 R 波峰最小化复合损失函数　　：

$$L(\alpha, \beta) = w_e H + w_s(1 - \text{SNR}) + w_g(1 - E_r) + P_l \tag{2}$$

其中，　H 表示香农熵，SNR表示QRS频带能量比，　E_r 表示QRS能量与总能量之比，　P_l 是对不合适片段长度 [38]的惩罚项。通过四分位距滤波剔除异常值，并使用多相重采样将有效片段重采样至固定长度。

为识别细微的类间差异，我们提取了一个多维特征集，涵盖时域（统计矩、过零率）、频域（谱熵、频带功率）和形态学属性 [45]。频域特征通过离散傅里叶变换获得：

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi kn/N} \tag{3}$$

其中，　$x(n)$表示长度为 N的离散时域输入序列，　n 是样本索引，　$X(k)$表示频率箱 k处的谱分量。

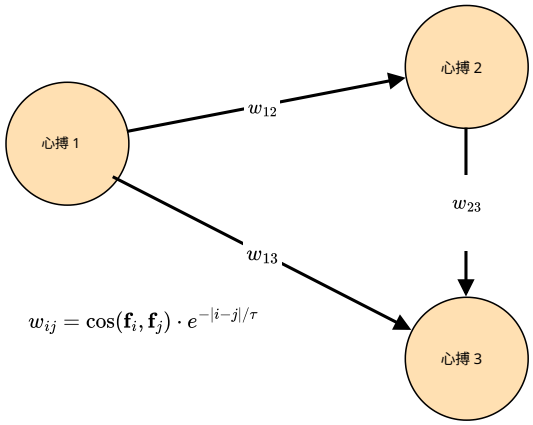

图 4：用于图增强的有向图。

形态学特征包括QRS 时限、T波振幅和ST段偏移，这些特征通过基于连续小波变换的波形界定获得。此外，使用Daubechies分解计算小波包能量。

由于心律失常通常表现为依赖序列的模式，而非孤立的心搏异常，因此我们采用时间增强和图增强来建模心搏间动态。时间增强在两个域中计算心率变异性（HRV）指标：

1. 时域：SDNN（NN间期的标准差）和 pNN50（间隔差异超过 > 50毫秒的百分比）直接根据 RR间期统计计算，以量化总体变异性。

2. 频域：使用 Welch 法估计 RR 序列的功率谱密度（PSD），并据此计算低频/高频比：

$$P(f) = \frac{1}{M} \sum_{m=0}^{M-1} |X_m(f)|^2 \tag{4}$$

其中， M 表示重叠片段的数量， $X_m(f)$表示第m个片段经过加窗后的傅里叶变换。与单个周期图相比，这种方法能够降低噪声方差。

作为时序分析的补充，图增强会构建一个有向图，其中节点表示心搏，边则编码相似度和时间邻近性。心搏 i与j 之间的边权重 w_{ij} 计算如下：

$$w_{ij} = \cos(f_i, f_j) \cdot e^{-|i-j|/\tau} \tag{5}$$

其中， f_i 和 f_j 分别表示提取的第 i个和第j个心搏的特征向量（形态学和频谱属性）， τ 为时间衰减常数。随后提取图论特征，以量化心搏序列的结构拓扑：

1. PageRank 中心性：该指标用于识别序列中最具“代表性”的心搏。它通过幂法迭代计算：

$$PR = (1-d)1 + dAD^{-1}PR \tag{6}$$

其中， PR 是中心性向量， d 是阻尼因子（通常为 0.85），1 是表示随机跳转概率的全 1 向量（确保遍历整个图）， A 是加权邻接矩阵，而 D^{-1} 用于对各列进行归一化，以生成随机转移矩阵。较高的 PageRank 值表示这些心搏与许多其他具有影响力的心搏具有较强的形态相似性，有助于模型区分稳定的心律与伪影。

2. 聚类系数：为衡量局部形态稳定性，我们计算每个节点的加权聚类系数 i [46]:

$$C_i = \frac{1}{s_i(k_i-1)} \sum_{j,h} \frac{w_{ij}+w_{ih}}{2} a_{ij}a_{ih}a_{jh} \tag{7}$$

其中， k_i 是节点 i的度， s_i 是节点强度（权重之和）， w_{ij} 表示边权重， a_{ij} 是二元邻接状态（连接时为 1，否则为 0 ）。该指标量化了一个心搏的两个邻居节点彼此相似的可能性，为检测不规则心律失常（如心房颤动）提供了稳健特征，因为此类心律失常会导致形态一致性受损。

为在保留细粒度细节和全局方差的同时处理增强特征空间的高维性，我们采用混合优化过程。首先，特征选择通过对互信息（MI）设置阈值来减少冗余 [47]:

$$I(X;Y) = \sum_{x\in X}\sum_{y\in Y} p(x,y)\log\frac{p(x,y)}{p(x)p(y)} \tag{8}$$

递归特征消除（RFE）对此进行了补充，通过迭代最小化分类误差来识别最显著特征的子集:

$$\min \sum (y-\hat{y})^2 \tag{9}$$

其次，我们将主成分分析（PCA）用作特征增强技术，而不是严格意义上的降维方法。PCA 应用于经 RFE 选定的子集，以提取能够最大化解释方差的前几个主成分:

$$\max \sum \lambda_i \tag{10}$$

其中， λ_i 表示协方差矩阵的特征值。随后，将这些成分与原始增强特征矩阵进行拼接。该策略生成了一个扩展特征向量，将具体且可解释的局部属性与紧凑、去噪的全局方差描述符相结合。

最后，为了解决心律失常数据集固有的类别不平衡问题，我们使用 SMOTE-ENN 合成少数类样本并清理决策边界 [43]。经平衡和扩充的特征矩阵用于训练一组可解释的线性分类器（例如逻辑回归、线性支持向量机 [48]）。最优参数 θ^* 通过最小化正则化经验风险 [49]获得:

$$\theta^* = \arg\min_{\theta} \frac{1}{N}\sum_{i=1}^{N} \ell\big(f_\theta(\mathbf{x}_i), y_i\big) + \alpha R(\theta) \tag{11}$$

其中， $\ell(\cdot)$ 表示损失函数， $R(\theta)$ 是正则化项， α 用于控制正则化强度。该公式通过按类别加权的损失函数，确保模型在所有心律失常类别上均能实现公平的性能。

4. 实验设置

所提出的心电图分类流程在一台高性能工作站上进行了实验验证，该工作站配备 Apple M4 芯片和 16 GB 统一内存，运行 Python 3.9 环境。实现过程中使用了一系列经过优化的科学计算库，包括用于数值运算的 NumPy 和 SciPy、用于信号分解的 PyWavelets，以及用于机器学习和图论分析的 scikit-learn、NetworkX 和 imbalanced-learn。这些工具有助于实现高效的数据处理和稳健的模型评估，并利用统一内存架构处理高维特征矩阵，且未增加延迟。

为评估该处理流程在不同临床背景下的稳健性，我们使用了来自 PhysioNet 的两个基准数据集：MIT-BIH 心律失常数据库和圣彼得堡 INCART 12 导联心律失常数据库 [10, 11]。作为主要标准数据集，MIT-BIH 数据库包含来自 47 名受试者的 48 段半小时双通道动态心电记录，采样频率为 360 Hz [12]。作为补充，INCART 数据库提供了来自 32 名冠状动脉疾病患者的 75 段记录，原始采样频率为 257 Hz [11]。这些信号经过重采样至 360 Hz，并提取 II 导联和 V1 导联，以符合 MIT-BIH 的双通道处理范式。加载数据时，对 INCART 记录中增益的差异（250–1100 ADC 单位/mV）进行了归一化。两个数据集均映射至医疗仪器促进协会（AAMI）规定的五个标准类别：正常（N）、室上性异位（S）、室性异位（V）、融合（F）和未知（Q）。为确保评估无偏，记录按 80/20 的比例划分为训练集和测试集，并按类别分层，以保持心律失常类型的原始分布。

信号处理流程受到严格的超参数约束，以确保可复现性。预处理采用四阶巴特沃斯带通滤波器（0.5–40 Hz），以二阶节级联方式实现，并通过零相位前向后向滤波在抑制噪声的同时保留 QRS 波群形态。R 峰检测采用 Pan-Tompkins算法、连续小波变换（CWT）和自适应阈值算法构成的动态集成方法，并根据基于峰度的信号质量指数（SQI）对各方法的贡献进行加权。在 0.05 s 的不应期容差内合并峰值。随后，采用自适应分割，最小化由熵（权重 0.5）、信噪比（0.3）和能量比（0.2）构成的复合损失函数，并针对 RR间期前比例 $\alpha \in [0.2, 0.6]$ 和 RR 间期后比例 $\beta \in [0.4, 0.8]$ 优化窗口参数。特征提取得到一个初始高维向量，其中包括时域统计量、频域频带功率，以及由 CWT 波形 delineation 得出的形态学属性。为捕捉搏间时序动态，数据增强还纳入了心率变异性（HRV）指标和图论特征（PageRank、聚类系数），这些特征由一个基于 k 个最近邻构建的图（$k = 4$,

$\tau = 1.0$）。特征空间经中位数插补和标准化后，通过结合互信息与递归特征消除（RFE）的混合选择流程进行精炼；该流程采用线性支持向量分类器，最终通过主成分分析（PCA）降低维度。

为确保系统能够部署在资源受限的医疗设备上，分类框架优先采用可解释的线性模型，而非不透明的深度学习架构。我们评估了三种分类器：逻辑回归（使用“liblinear”求解器）、决策树（预剪枝，最大深度为 5）以及线性支持向量机（平方合页损失，$C = 0.1$）。所有模型均采用平衡的类别加权，以抵消多数类占比过高的影响。我们使用准确率、精确率、召回率和加权 F1 分数来衡量性能，以考虑类别不平衡。此外，为明确优化诊断性能与计算成本之间的权衡，我们引入了自定义效率分数（E）：

$$E = \frac{0.6 \cdot F1 + 0.4 \cdot Acc}{0.4 \cdot T_{train} + 0.4 \cdot T_{infer} + 0.2 \cdot S_{model} + \epsilon} \tag{12}$$

其中，T_{train} 为训练时间（秒），T_{infer} 为每个样本的推理延迟（毫秒），S_{model} 为模型大小（千字节），$\epsilon = 10^{-6}$ 用于确保数值稳定性。该指标有助于确定单位计算资源所能实现最高诊断效能的模型。

4.1. 数据准备与处理分析

对数据转换流程进行定量评估，验证了特征增强和混合维度管理方案的有效性。分析表明，通过将原始高维属性与紧凑的方差表示相结合，该处理流程能够提升特征空间的判别能力。

对于 MIT-BIH 心律失常数据库（48 条记录），自适应分段得到了 1,173 个有效心搏。特征提取阶段生成了一个初始形状为 (1173，88) 的矩阵。经过时序和基于图的增强后，维度扩展至 197 个特征。为捕捉全局方差，同时保留细粒度信息，采用了一种混合策略：将通过互信息和递归特征消除识别出的前 50 个判别性特征投影到 5 个主成分上（解释了该子集中 71.1% 的方差）。随后将这些成分与增强后的矩阵拼接，得到长度为 202 的最终特征向量（$197 + 5$）。接着，SMOTE-ENN 平衡处理将数据集扩展至 2,569 个样本，类别分布稳健（$N \approx 454$，$S \approx 561$，$V \approx 557$，$F \approx 602$，$Q \approx 395$）。

相比之下，INCART 数据库（75 条记录）生成了规模大得多的数据集，共包含 64,062 个分段。该处理流程能够有效扩展，将特征空间扩展至 (64062，197)，并附加了从所选特征子集中提取的 5 个主成分（方差比：0.238、0.142、0.102、0.091、0.070）。最终得到形状为 (64062，202) 的矩阵。严格的类别平衡生成了包含 280,695 个样本的大型合成数据集，在全部五个心律失常类别中保持均衡（每类 $\sim$58,000 个样本）。

处理效率指标证实了该处理流程用于临床部署的可行性。MIT-BIH 的处理耗时为 73.30 秒（每条记录 1.5 秒）。规模更大的 INCART 数据集耗时 3,378.38 秒（每条记录 45 秒），延迟主要由密集 12导联数据的分割所致。值得注意的是，即使面对数据量庞大的 INCART 数据，特征增强和 PCA拼接阶段的计算开销仍然很低，平均每个文件仅耗时 4.53 秒。

表 1 概　述了两个数据集的关键维度变换和处理指标　　s.

表 1：处理流程处理结果对比摘要

指标	**MIT-BIH（48 条记录）**	**INCART（75 条记录）**
提取的片段	1,173	64,062
初始特征维度	88	88
增强后的维度	197	197
选定子集（用于主成分分析）	50（例如， std_ch0, $skew_ch0$）	50（例如， $mean_ch0$, std_ch0）
附加的主成分	5（方差：71.1%）	5（方差：64.3%）
最终特征维度	202 ($197 + 5$)	202 ($197 + 5$)
平衡数据集大小	2,569	280,695
分割时间	67.71 秒（1.41 秒/文件）	2,945.45 秒（39.27 秒/文件）
增强/选择/平衡时间	0.88 秒（0.04 秒/文件）	271.96 秒（4.53 秒/文件）
总执行时间	73.30 秒	3,378.38 秒

4.2. 超参数优化分析

为严格论证在各数据集上采用的分割参数，我们使用 MIT-BIH数据集对 RR 前（α）和 RR 后（β）窗口比例进行了网格搜索优化。图5展示了代表性心电图记录所对应的损失景观，突出了复合分割损失对这些超参数的敏感性。

α 与 β之间的交互关系如平均损失热图（图5，左上）所示，呈现出一条与 α轴平行的明显谷地。这种拓扑结构表明，分割损失对 β 的敏感性显著高于对 α的敏感性。横截面分析（图5，右上）证实了这一主导关系：对于几乎所有固定的 α 值，随着 β 从 0.30 增加，损失都会迅速下降，并在 $\beta \approx 0.367$ 附近达到全局低谷，随后趋于饱和。相反， α 的变化主要使损失曲线发生垂直平移，而不会改变最小值的位置，这表明 β 是决定分割质量的主要因素，而 α 则充当次要的微调参数。

我们在该空间中确定了两个不同的工作点。精确全局最小值（以红色星号标记）位于 $\alpha = 0.100$, $\beta = 0.367$，观测到的损失最低，为 1。960（心搏索引 91）。

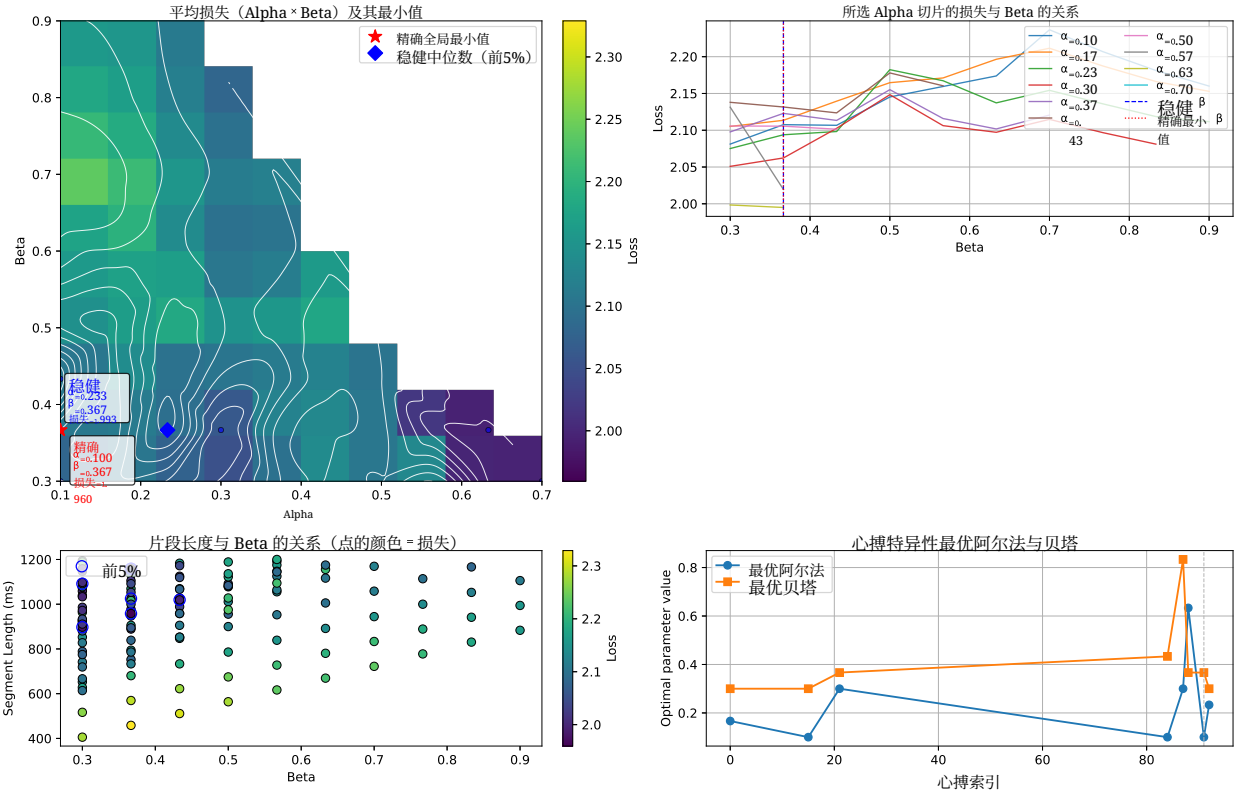

图5：自适应分段的超参数优化景观。**（左上）**针对RR前段（α）和RR后段（β）比例的平均损失热图，展示分段性能对 β的敏感性。精确全局最小值（红色星标）和稳健全局最优值（蓝色菱形）已标出。**（右上）**固定 α片段下损失随 β 变化的曲线，确认 $\beta \approx 0.37$附近存在一致的最小值。**（左下）** β 与片段长度（毫秒）之间的相关性；较低的损失（颜色较深的点）聚集在900–1200毫秒范围内。**（右下）**特定心搏的最优值，展示跨心动周期的 β （橙色）稳定性与 α （蓝色）方差。

然而，为了减轻对特定心搏伪影的过拟合，我们计算了稳健全局最优值（蓝色菱形），其定义为前5%表现最佳样本的参数集的中位数。该稳健点位于$\alpha = 0.233$，$\beta = 0.367$ （损失 ≈ 1.993），我们将其选作处理流程的默认配置。这一选择提供了保守的平衡：损失仅略有增加（$+0.033$），却能提升对不同心搏的泛化能力。

对 β 的优化具有直接的物理对应指标：片段时长。如片段长度相关图（图5，左下）所示，增大 β 会使片段长度线性延长。损失最低的样本紧密聚集在900–1,200毫秒的中等时长范围内，这验证了生理学预期：片段必须足够长，才能涵盖完整的P-QRS-T波群；同时又必须足够短，以排除相邻心搏干扰。虽然最优的 β 在大多数心搏中保持稳定（图5，右下），但针对特定心搏的 α 最优值方差更大。值得注意的异常值（例如第87次心搏，其偏好为$\beta = 0.833$）表明，少数不规则心搏可能受益于更长的时间上下文，这也提示未来可通过自适应逐心搏参数调优来改进。

4.3. 特征空间分析与流程效能

在优化分割参数后，我们通过分析主成分分析（PCA）成分的信息保留情况，以及提取属性的判别能力，验证了特征工程处理流程的有效性。

为评估混合降维策略的质量，我们分析了从递归特征消除筛选出的特征子集中提取的主成分的方差解释率。图 6 展示了 MIT-BIH 和 INCART 数据集的碎石图。对于 MIT-BIH 数据集（蓝色/橙色曲线），前五个主成分捕获的累积方差为 71.1%，其中仅第一个主成分就占近 30%。类似地，对于 INCART 数据集（绿色/红色曲线），前五个主成分保留了总方差的 64.3%。两个数据集在第三个主成分之后均出现明显的“肘部”，这证明选择 $n = 5$ 个主成分是合理的。这表明，将这些紧凑且高方差的描述符附加到增强特征向量中，可以高效编码全局信号属性，而无需承担使用完整特征集所需的计算成本。

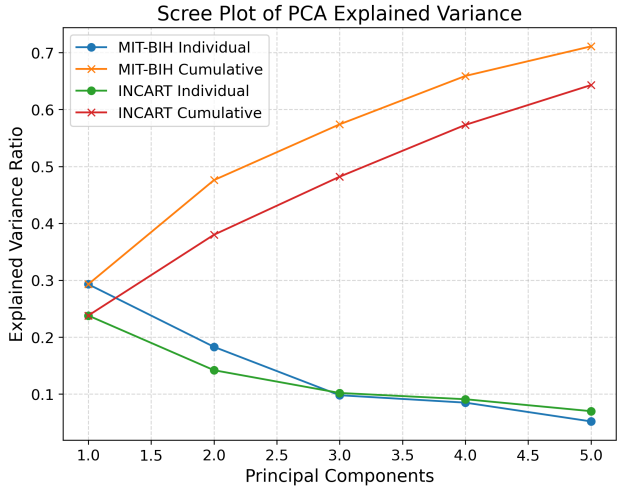

图 6：主成分分析解释方差碎石图。该图追踪了 MIT-BIH（蓝色/橙色）和 INCART（绿色/红色）数据集中前五个主成分各自的（实心圆）和累积的（叉号）方差解释率。较高的累积保留率（>64%）验证了这些主成分作为拼接特征向量中稳健全局描述符的有效性。

为验证提取的特征能否有效区分不同心律失常类别，我们考察了其统计分布。图 7 展示了 MIT-BIH数据集的分布。QRS 时限（‘qrs_dur_ms‘）等形态学特征呈现出明显的类间差异；与正常（N）心搏相比，室性（V）和融合（F）心搏的四分位距明显更宽，中位数也更高，这与心室除极延迟的临床预期相符。此外，图论加权度（‘wdeg‘）表现出显著的可分性，验证了心律失常心搏在相似性图中占据不同拓扑位置这一假设。

为确保这些　　这些发现并非特定于某个数据集，我们在 INCART 数据库中重复了该分析　　e

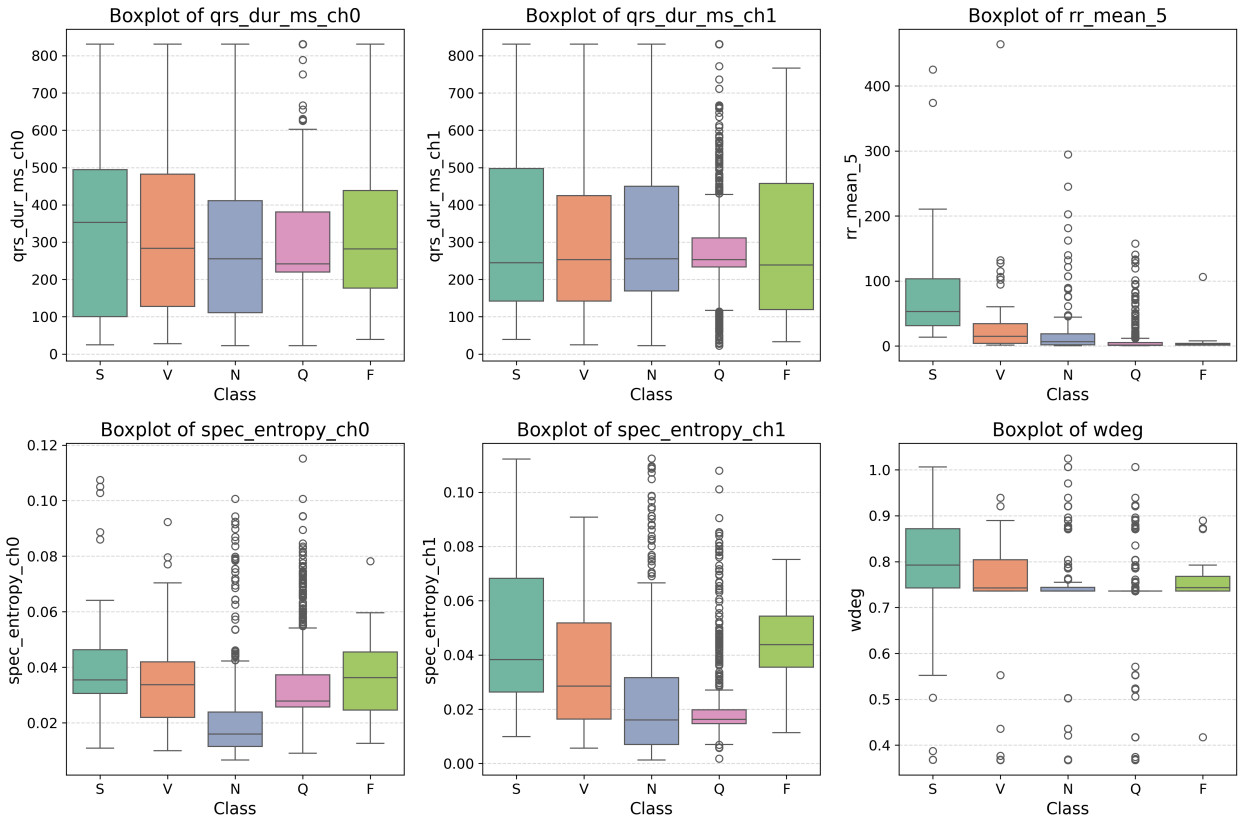

图 7：MIT-BIH 心律失常数据库的特征分布。**（顶行）**形态学和时间属性：QRS 时限在室性（V）和融合（F）类别中呈现明显扩展，而局部 RR 均值突出了时序不规则性。**（底行）**频谱和图论属性：谱熵捕捉信号复杂性，而图层中的加权度（'wdeg'）在正常心搏与异位搏动之间提供了显著区分。

（图 8）。频谱特征，尤其是谱熵（'spec_entropy'），在两个数据集中始终呈现出不同的频率复杂度特征，可区分噪声较多或不规则的心搏类型与稳定的窦性心律。这些分布的一致性证实，所提出的特征工程流程能够成功捕捉稳健多分类诊断所需的不同生理和结构特征。

4.4. 分类性能与资源效率

平衡后的增强特征矩阵采用三种可解释模型进行监督分类：逻辑回归（LR）、决策树（DT）和线性支持向量分类器（Linear SVC）。以下分析评估了两个不同数据集在诊断准确率与计算可行性之间的权衡。

4.4.1. 诊断准确率

在主要的 MIT-BIH 数据集上，线性支持向量分类器表现最佳，准确率达到 98.44%，加权 F1 分数为 0.9843（表 2）。其表现略优于逻辑回归

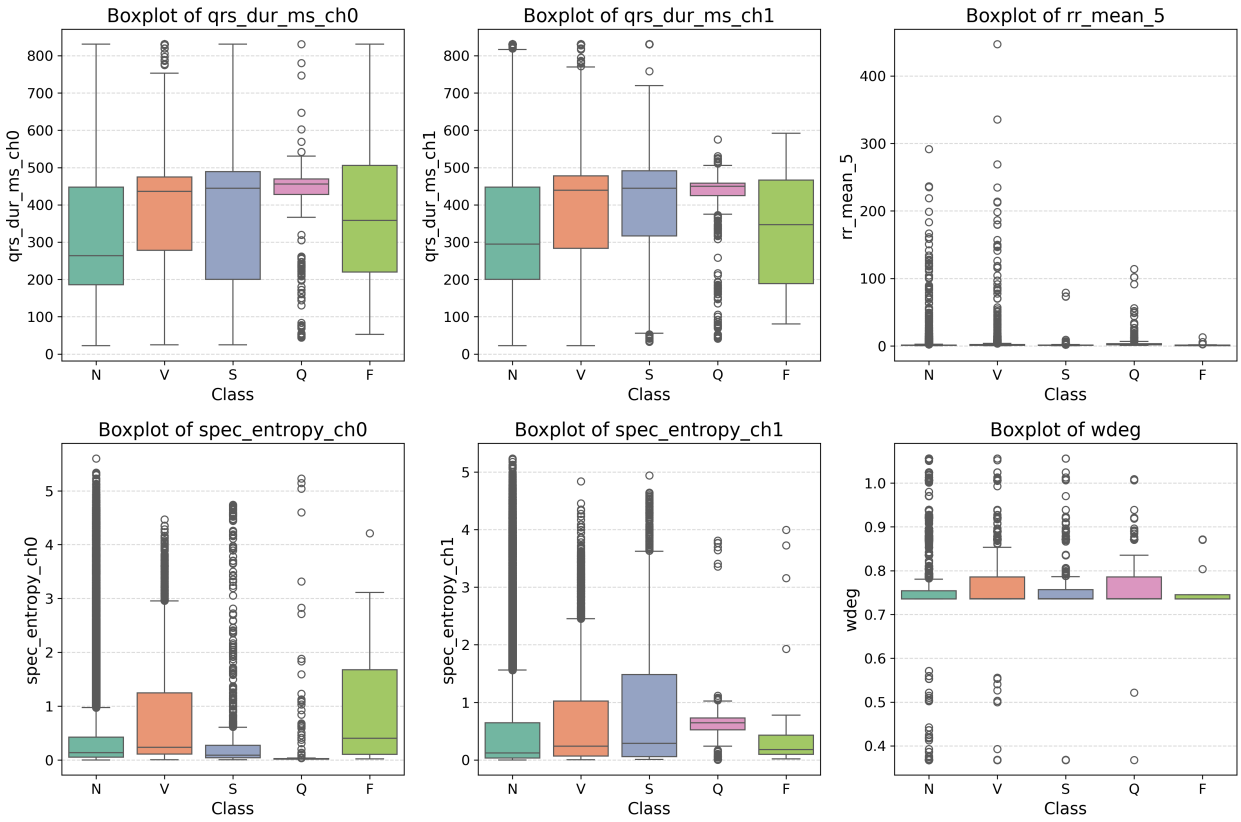

图 8：圣彼得堡 INCART 数据库的特征分布。这些分布与 MIT-BIH 中观察到的模式相一致，证实了处理流程的稳健性。请注意，在 INCART 的多样化患者群体中，谱熵（左下）始终具有良好的可分性，而 QRS 时限（左上）则呈现出 distinct 的形态学特征。

（F1：0.9824），验证了所提出的特征增强能够构建线性可分的决策空间这一假设。

该处理流程在扩展至规模庞大的 INCART数据集时展现出卓越的稳健性（表 3）。尽管数据量增加了 100 倍，且病理类型多样，逻辑回归仍取得最高性能（F1：0.9674），略高于线性支持向量分类器（F1：0.9672）。相比之下，决策树的表现始终落后（F1 $\approx$ 0.89），这证实了简单的轴对齐划分不足以捕捉多患者心律失常数据中复杂的决策边界。

表 2：性能与资源权衡分析（MIT-BIH）

模型	准确率（%）	F1（加权）	训练时间（秒）	推理时间（毫秒）	大小（千字节）	效率得分
逻辑回归	98.25	0.9824	0.302	5.45×10^{-4}	8.87	0.519
决策树	86.77	0.8562	**0.131**	5.86×10^{-4}	**4.71**	**0.866**
线性支持向量分类器	**98.44**	**0.9843**	0.177	$\mathbf{4.62 \times 10^{-4}}$	8.54	0.553

表 3：性能与资源权衡分析（INCART）

模型	准确率（%）	F1（W）	训练时间（秒）	推理时间（毫秒）	大小（千字节）	效率得分
逻辑回归	**96.76**	**0.9674**	348.89	$\mathbf{9.88 \times 10^{-5}}$	8.87	0.007
决策树	89.10	0.8913	**19.75**	1.59×10^{-4}	**5.32**	**0.099**
线性支持向量分类器	96.74	0.9672	113.22	1.05×10^{-4}	8.54	0.021

4.4.2. 计算资源分析与临床可行性

高诊断准确率必须与部署可行性相平衡。为评估临床实用性，我们分析了按单条患者记录（通常为 30 分钟的动态心电图记录）归一化后的计算开销。表 4 展示了端到端处理时间，并区分了信号处理流程（分割、特征提取、数据增强）与诊断分类的处理时间。

表 4：单患者计算特征：诊断耗时分析

数据集	记录时长（标准）	处理时间（每位患者）		实时可行性
		流水线阶段	分类	每搏延迟
MIT-BIH	30 分钟	1.53 秒	< 0.01 毫秒	≈ 52 毫秒
INCART	30 分钟	45.05 秒	< 0.01 毫秒	≈ 52 毫秒

注：“流水线阶段”涵盖分割、小波提取、图构建和降维，这些环节构成了主要的计算成本。“分类推理”仅指模型的前向传播（$< 1\mu$秒）。处理时间表示将原始*30*分钟记录转换为完整诊断报告所需的平均时长。

分析证实，所提出的框架对于标准临床工作流程具有很高的效率，尤其适用于快速离线分析。对于来自MIT-BIH 数据库的标准30分钟心电图记录，完整的“动态心电图至诊断”处理流程仅需1.53秒即可完成。即使面对更复杂的12导联INCART数据，系统处理一份完整患者记录也只需45.05秒。这一处理能力意味着，临床医生在数据上传后不到一分钟即可获得诊断结果，从而显著促进高负荷医院环境中的快速分诊。

此外，该系统展现出稳健的实时监测能力，适用于必须逐个处理心搏的可穿戴设备应用场景。在此情境下，关键指标是延迟；处理流程对每个心搏造成的平均延迟约为 52 毫秒，主要由特征提取阶段所导致。相较于约 800 毫秒的典型生理R-R间期，这一延迟很短，因此不会造成数据积压。结合线性模型几乎可以忽略不计的分类耗时（$< 1\mu s$），这表明该系统能够在边缘设备上高效运行，无需缓冲延迟，并确保及时为危重心律失常生成警报。

4.5. 统计显著性和可靠性

为验证线性模型表现更优并非随机划分数据造成的假象，我们基于两个数据集的五折分层交叉验证（CV）结果进行了统计显著性分析。我们使用 t 分布计算加权F1分数的 95% 置信区间（CI）：

$$CI_{95\%} = \mu \pm t_{n-1,0.975} \left(\frac{\sigma}{\sqrt{n}} \right) \tag{13}$$

其中， μ 为平均交叉验证得分， σ 为标准差， $n = 5$ 为折数。

对于MIT-BIH数据集，线性支持向量分类器的平均F1值为0.9634（$\sigma = 0.0094$），置信区间为 $[0.952, 0.975]$，表现稳健。相比之下，决策树的区间为 $[0.830, 0.915]$（平均值 0.8725 ± 0.034）。两者完全没有重叠，这证实线性模型的性能优势具有统计显著性（$p < 0.05$）。

同样，在INCART数据集中，线性方法也保持了优势。逻辑回归的平均F1值为0.9678，标准差极低（$\sigma = 0.0013$），置信区间为 $[0.966, 0.969]$，范围很窄。决策树的表现则明显落后，区间为 $[0.889, 0.893]$。与MIT-BIH相比，INCART区间的宽度极窄（< 0.004），这反映了其样本量更大，具有较高的统计功效，因此可以得出结论：在不同患者群体中，工程化特征空间本质上线性可分。

尽管全局指标显示总体准确率较高，但临床实用性最终取决于模型能否正确识别特定的罕见心律失常类型。为评估这一点，我们分析了按类别灵敏度（图9）。

灵敏度分析凸显了决策树分类器存在一个严重的安全缺陷。在MIT-BIH数据集上，它未能检测出近50%的室性异位搏动（召回率 ≈ 0.50），而是将其误分类为融合搏动或室上性搏动。相比之下，线性支持向量分类器对室性搏动保持了 $> 93\%$的灵敏度，对融合/未知搏动保持了$> 99\%$的灵敏度。这一差异进一步印证了工程化特征空间是线性可分的，也表明浅层决策树的“可解释”规则不足以在避免大量假阴性的情况下捕捉室性异位搏动的形态学细微差异。线性模型在所有类别中均保持较高召回率，证实其能够有效缓解不平衡医学数据集中常见的“准确率悖论”。

4.6. 模型可解释性与特征相关性

所选可解释分类器的一项独特优势，是能够通过分析特征贡献来验证决策边界的生物学相关性。图10对比了线性模型与非线性决策树的特征优先级排序，展现了心脏信号的两种互补“视角”。

线性架构（线性支持向量分类器和逻辑回归）始终优先考虑频域和时域生理标志物，验证了信号处理流程的有效性。如

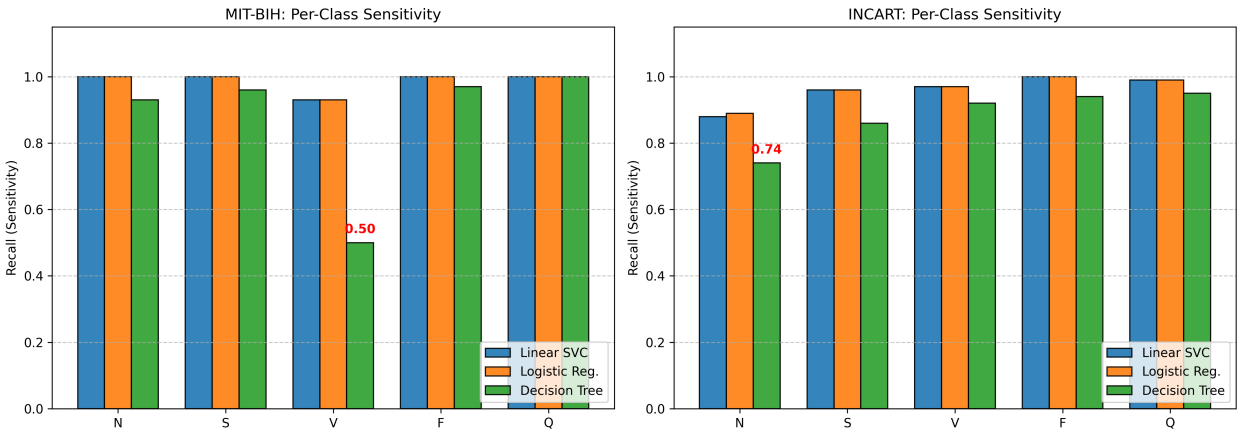

图9：跨数据集的分类灵敏度（召回率）分析。分组柱状图比较了三种分类器对各心律失常类别的诊断灵敏度（N：正常，S：室上性，V：室性，F：融合，Q：未知）。**（左）MIT-BIH：**线性支持向量分类器（蓝色）和逻辑回归（橙色）在所有类别上均保持稳健的灵敏度（$>$ 93%）。值得注意的是，决策树（绿色）在检测室性（V）心搏时表现出严重缺陷，漏检了近50%的病例（召回率 ≈ 0.50）。**（右）INCART：**尽管 INCART数据集中的噪声水平较高，线性模型对具有挑战性的正常（N）和室上性（S）类别仍保持较高的灵敏度（$>$ 88%）。决策树的性能显著下降，尤其是在占多数的正常类别上（召回率 0.74），这证实了它不适合稳健的临床部署。

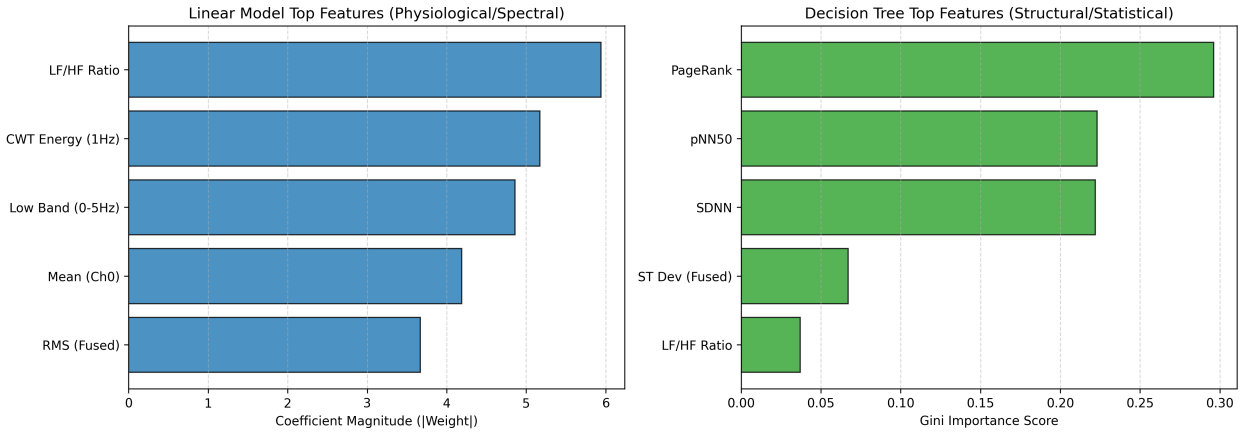

图10：不同模型架构在特征优先级排序上的差异。**（左）**线性模型（例如基于 INCART 的逻辑回归）优先考虑生理频带和心率变异性指标，例如低频/高频比（自主神经系统活动）和连续小波变换能量。**（右）**决策树（MIT-BIH）则高度依赖 PageRank 等结构图描述符以及统计离散度指标（pNN50、SDNN）来识别异常值，从而验证了混合特征工程方法。

图10（左）所示，mid_band_5_15Hz（系数：0.449）和low_band_0_5Hz等特征成为最具区分力的特征。这种与心脏生理学的一致性是意料之中的，因为不同的心律失常会在QRS波群（5–15 Hz）和T波（0–5 Hz）频段呈现不同的能量特征。此外，lf_hf比值（低频/高频比）是INCART数据集中的主导特征，其系数绝对值为5.94。

相比之下，非线性决策树利用结构和统计描述符来确定决策边界。值得注意的是，对于 MIT-BIH 数据集上的决策树而言，基于图论的 PageRank 特征是最重要的单一属性（重要性：0.296）（图10，右）。这表明，线性模型依赖形态学“形状”，而决策树则根据心搏在相似性图中的连通性来识别“异常值”；PageRank 较低的心搏在结构上与主导心律不同，因此很可能成为分裂节点。此外，决策树还大量利用偏度和峰度等统计矩，使其能够根据概率分布的不对称性而非原始振幅来区分心搏。特征依赖的这种差异凸显了所提出框架的优势：它提供了多样化的多视图表示（频谱、形态学、基于图），能够适应不同算法求解器各自的学习偏差。

4.7. 与最先进方法的比较分析

为严谨地将所提出的框架置于当前边缘人工智能的发展格局中，我们将其与明确报告了 MIT-BIH 心律失常数据库结果的代表性最先进水平（SOTA）方法进行了比较分析。将比较范围限定在共同基准上，可确保进行“同类对比”评估。表 5 总结了结果，突显了以模型为中心的深度学习方法与我们以数据为中心的混合特征增强策略之间截然不同的设计理念。

表 5：MIT-BIH 心律失常数据库上的架构与性能比较

模型／架构	核心策略	模型大小	准确率 (%)	推理延迟
所提出的线性支持向量分类器	**混合特征增强**	**8.54 千字节**	**98.44**	**0.46 μs***
提出的逻辑回归	**混合特征增强**	**8.87 千字节**	**98.25**	**0.55 μs***
提出的决策树	**混合特征增强**	**4.71 千字节**	**86.77**	**0.59 μs***
KD-Light (2025) [20]	知识蒸馏	25 千字节	96.32	19 毫秒
基于现场可编程门阵列的一维卷积神经网络（2025） [50]	硬件加速	13k 查找表	96.55	63 毫秒
CANet（2025） [51]	基于注意力的卷积神经网络	30 MB	94.41	56.7 毫秒
智能手表卷积神经网络 (2025) [52]	一维卷积神经网络架构	5 MB	99.57	Low
CCAL (2021) [28]	相关性辅助压缩	≈300 千字节	≈96	≈25–30 毫秒

注：所有准确率、模型大小和延迟数值均直接取自相应的引文文献。阴影行对应于本研究开发的模型。 *仅指分类推理延迟；完整处理流程延迟约为每个心搏 *52* 毫秒。

该比较凸显了优化目标之间的明显分歧。近期的深度学习模型（例如面向智能手表的一维卷积神经网络 [52], ）优先考虑表征能力和端到端学习，实现了较高的诊断准确率（99.57%），但代价是模型大小巨大（5 MB），超出了标准超低功耗微控制器的片上内存容量。同样，基于硬件加速的方案（例如基于现场可编程门阵列的 一维卷积神经网络 [50], ）成功缩短了运行时间，但引入了不可忽视的硬件开销（13k 个查找表）和更高的功耗。

相比之下，所提出的混合特征增强框架能够使用轻量级线性分类器，使推理延迟达到微秒级，模型大小低于 9 KB，

与甚至经过压缩的 KD-Light 模型（25 KB）相比，模型大小降低了一个数量级 [20]。尽管决策树模型的表现较差（86.77%），但这一结果具有启发意义：它表明，我们框架的判别能力主要源于工程化特征空间的几何结构，而线性分类器能够有效利用这一结构，而非源于分类器深度。

总体而言，结果表明，以数据为中心的混合特征设计能够在 MIT-BIH 基准数据集上实现具有临床竞争力的准确率，同时满足下一代无电池传感器所需的内存效率。

5. 讨论

可穿戴心脏监测设备的迅速普及，对算法提出了相互冲突的要求：既要具备精确的诊断能力，又要降低计算开销。本研究挑战了主流的“以模型为中心”范式——即依赖不断加深的深度神经网络来提取特征——转而提出一种“以数据为中心”的框架。研究结果验证了这一假设：严格的混合特征增强能够使心律失常数据的复杂流形实现线性可分，从而在不损害临床实用性的前提下使用超轻量级分类器。

最重要的发现是，所提出的线性支持向量分类器（准确率：98.44%）与复杂深度学习基线模型在 MIT-BIH 基准数据集上的性能相当。统计分析证实，这一表现并非方差造成的偶然结果（$p < 0.05$ 与决策树相比）。这支持了以下理论主张：通过小波时频分解、图论中心性和统计矩构建的特征空间，成功地将心电信号的非线性形态变化展开到高维超平面中。

相反，决策树（准确率：86.77%）的失败提供了一个关键的负面结果，可作为几何对照实验。尽管采用了相同的增强特征集，但决策树无法对斜决策边界进行建模（而是依赖轴对齐划分），因此在检测室性（V）异位搏动方面遭遇灾难性失败（召回率 $\approx 50\%$）。这一对比性失败表明，所提出系统的“智能”在于特征空间的几何结构，线性求解器能够有效利用这一结构，而递归划分方法则会低效地将数据碎片化。

我们的计算分析揭示了显著的分阶段计算不对称性，这种不对称性尤其有利于临床部署和嵌入式部署。上游特征提取流水线主导了端到端运行时间，每次心搏约耗时 52 毫秒。尽管这占据了大部分处理负载，但仍远低于心脏的生理不应期（≈ 250 毫秒），从而确保实时运行，并留有充足的时间余量（仅使用可用心动周期的 $\approx 20\%$）。

特征提取完成后，下游决策阶段几乎可瞬时完成。使用所提出的线性支持向量分类器进行分类推理仅需 0.46 μs，使决策逻辑稳稳处于微秒级。这种计算负载的分离，与端到端

深度学习模型形成鲜明对比：在这类模型中，特征提取与分类在结构上不可分割，而卷积网络的深度必然会带来毫秒级的推理延迟。对于资源受限设备，这种架构解耦使分类器在占空比的大部分时间内都可保持休眠状态；同时，模型占用空间较小（8.54 KB），使整个决策引擎能够驻留在低端微控制器的 L1 缓存中，从而消除内存读取开销。

尽管该框架具有稳健性，但仍存在两个关键局限。首先，对 INCART 数据库的分析显示，正常（N）心搏与室上性（S）心搏之间的混淆增加。这可能是由于本研究所采用的 2 导联配置空间分辨率较低所致；该配置虽然高效，但可能无法捕捉只有在完整 12 导联心电图中才能观察到的细微 P 波形态变化。其次，特征工程流程的计算成本目前占总处理时间的 90%，因此无法部署于超低功耗、无电池能量采集传感器上；这类传感器可能需要进行原始数据处理，以最大限度地缩短主动工作占空比。

6. 结论

本研究提出了一种新颖且资源高效的心律失常分类框架，有效弥合了先进信号处理理论与实际边缘人工智能部署之间的差距。通过构建融合频谱、形态学和图论域的混合特征空间，我们证明，简单的线性分类器能够达到与深度神经网络相当的性能，同时避免其相关计算开销。结果证实，所提出的线性支持向量分类器在 MIT-BIH数据集上取得了 98.44% 的诊断准确率，而模型占用空间仅为 8.54 千字节。此外，该框架展现出卓越的实时可行性：在总计约 52 毫秒的心搏处理流程中，分类推理延迟达到 0.46 μ秒，确保能够在心脏生理不应期内提供临床级诊断。除了原始性能指标，本研究还验证了所提框架的生物学可解释性和可扩展性。我们证明，与严重依赖结构图异常值的非线性树模型方法不同，线性决策边界会优先关注生理频谱带（5–15 Hz）和心率变异性（HRV）指标。这种“白盒”透明性消除了临床应用的一项关键障碍。此外，该框架在不同数据规模下均表现稳健，使用精简的 2 导联配置，在不到 46 秒内成功处理复杂的 12 导联 INCART 患者记录，从而助力高通量临床环境中的快速分诊。总体而言，这些发现表明，可穿戴健康监测的未来不必仅仅依赖日益复杂的深度神经网络。相反，回归严谨且由领域知识引导的特征工程，可以构建出准确、可解释且足够轻量的系统，使普及实时心脏监测成为现实。未来的工作将聚焦于利用 FPGA 架构对特征提取流水线进行硬件加速，以进一步降低预处理阶段的能耗，为实现完全自主、无需电池的心脏传感器铺平道路。

CRediT 作者贡献声明

Moirangthem Tiken Singh：概念化；方法；数据整理；正式分析；调查；可视化；验证；撰写初稿。Manibhushan Yaikhom：资源；验证；审阅与编辑；监督。

利益冲突声明

作者声明，他们不存在已知的可能影响本文所报告工作的经济利益冲突或个人关系。

参考文献

[1] 美国心脏病学会，报告：2023年心血管疾病导致全球每三人中就有一人死亡，https://tinyurl.com/4b2tdvna（2025年9月）。

[2]Z. I. Attia、S. Kapa、F. Lopez-Jimenez、P. M. McKie、D. J. Ladewig、G. Satam、P. A. Pellikka、M. Enriquez-Sarano、P. A. Noseworthy、T. M. Munger 等，利用人工智能心电图筛查心脏收缩功能障碍，《自然医学》25（1）（2019）70–74。

[3] B. Dowdeswell, R. Sinha, M. M. Kuo, B.-C. Seet, A. G. Hoseini, A. Ghaffarianhoseini, H. Sabit, 《非对称智能未来环境中的医疗保健：应用、挑战与待解决问题》，《电子学》13 (1) (2023年) 115。

[4] R. Dwivedi, D. Mehrotra, S. Chandra, 《医疗物联网（IoMT）应用构建智能医疗系统的潜力：系统综述》，《口腔生物学与颅面研究杂志》12 (2) (2022) 302–318。

[5] M. Alghieth, 《DeepECG-Net：一种用于实时心电图异常检测的混合型基于 Transformer 的深度学习模型》，《科学报告》15 (1) (2025) 20714。doi:10.1038/s41598-025-07781-1。

[6] M. Lin, Y. Hong, S. Hong, S. Zhang, 基于离散小波变换和 GCForest 的心电图分类：一种深度集成方法，《技术与医疗保健》32 (1_增刊) (2024) 95–105。

[7] N. Wang, J. Zhou, G. Dai, J. Huang, Y. Xie, 面向可穿戴设备的节能型智能心电监测，《IEEE 生物医学电路与系统汇刊》13 (5) (2019) 1112–1121。doi:10. 1109/TBCAS.2019.2930215。

[8] I. Daubechies, 《小波十讲》，工业与应用数学学会，1992。

[9] B. Andayeshgar, F. Abdali-Mohammadi, M. Sepahvand, A. Almasi, N. Salari, 基于图卷积网络的心律失常检测及一种用于心脏导联间通信的结构，BMC医学研究方法学 24 (1) (2024) 96。

[10] G. B. Moody, R. G. Mark，MIT-BIH 心律失常数据库的影响，IEEE《医学与生物学工程杂志》20 (3) (2001) 45–50。[11] A. L. Goldberger 等，圣彼得堡 INCART 12 导联心律失常数据库，https://physionet. org/content/incartdb/1.0.0/，访问日期：2025年12月23日 (2008)。doi:10.13026/C2H59M。[12] G. B. Moody, R. G. Mark，MIT-BIH 心律失常数据库，https://physionet.org/content/mitdb/ 1.0.0/，访问日期：2025年12月23日 (2005)。[13] A. Y. Hannun 等，使用深度卷积神经网络在动态心电图中实现心脏病学家级心律失常检测与分类，《自然医学》25 (1) (2019) 65–69。[14] S. Kiranyaz, T. Ince, M. Gabbouj，基于一维卷积神经网络的实时患者特异性心电图分类，IEEE《生物医学工程学报》63 (3) (2015) 664–675。[15] T. Li 等，使用门控循环单元和注意力机制的多导联心电图分类，Computers in Biology and Medicine 168 (2024) 107756。[16] A. I. Reshad, V. Nino, M. Valero，基于深度学习的心电信号心律失常检测：全面综述，Vascular Health and Risk Management (2025) 685–703。

[17] D. Kim, K. R. Lee, D. S. Lim, K. H. Lee, J. S. Lee, D.-Y. Kim, C.-B. Sohn，一种基于 Stockwell 变换、无需 R 峰识别的心律失常检测新型卷积神经网络-Transformer 混合模型，《科学报告》15（7817）（2025）。doi:10.1038/s41598-025-92582-9。

[18] M. Alghieth，《DeepECG-Net：一种用于实时心电图异常检测的基于 Transformer 的混合深度学习模型》，《科学报告》15 (1) (2025) 20714。[19] A. Ukil, I. Sahu, A. Majumdar, S. C. Racha, G. Kulkarni, A. D. Choudhury, S. Khandelwal, A. Ghose, A. Pal，面向可穿戴与植入式设备的资源受限型心血管疾病分类：基于单导联心电图，在：2021年第43届 IEEE 医学与生物学工程学会年度国际会议（EMBC），2021，第886–889页。doi:10.1109/EMBC46164.2021.9630348。[20] X. An, S. Shi, Q. Wang, Y. Yu, Q. Liu，面向可穿戴单导联心电图监测系统的基于知识蒸馏的轻量级心律失常分类模型研究，《传感器》24 (24) (2024)。doi:10.3390/s24247896。URL https://www.mdpi.com/1424-8220/24/24/7896[21] A. Muthuramalingam, S. Himavathi, E. Srinivasan，基于现场可编程门阵列的神经网络实现：问题与应用，《国际信息技术杂志》4 (2) (2008) 86–92。[22] V. Rawal, P. Prajapati, A. Darji，面向心电图心律失常分类的一维卷积神经网络架构硬件实现，《生物医学信号处理与控制》85 (2023) 104865。

[23] L. Meng, W. Tan, J. Ma, R. Wang, X. Yin, Y. Zhang，采用轻量级 Transformer 模型增强动态心电图心搏分类，《医学人工智能》124 (2022) 102236。doi:https: //doi.org/10.1016/j.artmed.2022.102236。URL https://www.sciencedirect.com/science/article/pii/S093336572200001X[24] F. Jiang, J. Xiao, L. Liu, C. Wang，DCETEN：一种基于 Transformer 模型的轻量级心电图自动分类网络，《数字通信与网络》（2024）。doi:10.1016/j.dcan.2024.1524。

[25] R. Singh, S. Gangwar, S. Bartwal, V. Tomar，基于小波的特征提取与循环卷积神经网络用于心电信号分类，载于：2023年物联网、通信与自动化技术国际会议（ICICAT），2023年，第1–6页。doi:10.1109/ICICAT57735.2023.10263710。

[26] R. J. Martis 等，使用主成分分析、线性判别分析、独立成分分析和离散小波变换进行心电图心搏分类，《生物医学信号处理与控制》8（5）（2013）437–448。

[27] A. Ghaffari, M. R. Homaeinezhad, M. Akraminia, M.Atarod, M. Daevaeiha，基于连续小波变换的新型数学方法QRS检测器，《计算机与电气工程》34（2）（2008）81–91。doi:10.1016/j.compeleceng.2007.10.005。

[28] X. Bian, W. Xu, Y. Wang, L. Lu, S. Wang，压缩域中的心电信号直接特征提取与诊断，《IEEE传感器期刊》21 (15) (2021) 17096–17106。doi:10.1109/JSEN.2021. 3081577。

[29] Z. Huang, L. F. Herbozo Contreras, L. Yu, N. D. Truong, A. Nikpour, O. Kavehei，S4D-ECG：一种用于心脏异常分类的浅层最先进方法，《心血管工程与技术》15 (3) (2024) 305–316。doi:10.1007/s13239-024-00716-3。URL https://doi.org/10.1007/s13239-024-00716-3

[30] N. Mechichi, F. Benzarti，一种结合卷积神经网络、双向长短期记忆网络和注意力机制的增强型混合模型，用于心电图片段分类，Biomed Eng Comput Biol 16 (2025) 11795972251341051。doi:10.1177/11795972251341051。

[31] P. Varalakshmi、A. P. Sankaran，《使用心电信号预测心律失常的改进型混合人工智能模型》，《生物医学信号处理与控制》80（2023年）104248。doi:10.1016/j.bspc.2022. 104248。

[32] G. E. Raunsay、S. Mandala，《使用混合BERT-CNN Transformer架构的双模态心电图心律失常分类》，载于：2025年IEEE网络、智能系统与物联网国际会议（ICONS-IoT），2025年，第55–61页。doi:10.1109/ICONS-IoT65216.2025.11211275。

[33] S. Lee, G. Zheng, J. Koh, H. Li, Z. Xu, S. P. Cho, S. I. Im, V. Braverman, I. C. Jeong，《使用一维卷积神经网络优化心律失常检测的逐搏输入：真实世界心电图

研究》，《生物医学中的计算机方法与程序》269 (2025) 108898。doi:10.1016/j.cmpb.2025.108898。[34] E. Kim, J. Kim, J. Park, H. Ko, Y. Kyung，《心电图监测嵌入式系统中的基于 TinyML 的分类》，《计算机、材料与持续发展》75 (1) (2023) 1751–1766。doi:10.32604/cmc.2023.031663。[35] P. Pósfay 等，《通过基于线性定律的特征提取实现轻量级心电信号分类》，《机器学习：科学与技术》6 (3) (2025) 035001。doi:10.1088/2632-2153/ade6c3。[36] I. W. Selesnick, C. S. Burrus，《广义数字巴特沃斯滤波器设计》，《IEEE 信号处理汇刊》46 (6) (1998) 1688–1694。doi:10.1109/78.678493。[37] J. Pan, W. J. Tompkins，《一种实时 QRS 检测算法》，IEEE《生物医学工程学报》32 (3) (1985) 230–236。doi:10.1109/TBME.1985.325532。[38] I. Romero, B. Gu, W. J. Wijns, C. Cyril，《使用卷积神经网络和混合质量标注数据集描绘心电图》，《科学报告》11 (1) (2021) 1–11。doi: 10.1038/s41598-020-79512-7。[39] P. Welch，《使用快速傅里叶变换估计功率谱：一种基于短时修正周期图时间平均的方法》，《IEEE 音频与电声学汇刊》15 (2) (1967) 70–73。doi:10.1109/TAU.1967.1161901。[40] L. Page, S. Brin, R. Motwani, T. Winograd，《PageRank 引文排名：为网络带来秩序》，技术报告，斯坦福信息实验室 (1999)。[41] B. F. Darst, K. C. Malecki, C. D. Engelman，《在随机森林中使用递归特征消除处理高维数据中的相关变量》，《BMC 遗传学》19 (1) (2018) 1–6。doi: 10.1186/s12863-018-0633-8。[42] I. T. Jolliffe, J. Cadima，《主成分分析：综述与近期进展》，《皇家学会哲学汇刊 A：数学、物理与工程科学》374 (2065) (2016) 20150202。doi:10.1098/rsta.2015.0202。[43] G. E. Batista, R. C. Prati, M. C. Monard，《多种机器学习训练数据平衡方法行为研究》，《ACM SIGKDD 探索通讯》6 (1) (2004) 20–29。doi: 10.1145/1007730.1007735。[44] A. V. Oppenheim, R. W. Schafer，《离散时间信号处理》，培生教育，上萨德尔河，新泽西州，1999。[45] F. A. Elhaj, N. Salim, A. R. Harris, T. T. Swee, T. Ahmed，《结合心电信号线性与非线性特征进行心律失常识别与分类》，《生物医学中的计算机方法与程序》127 (2016) 52–63。

[46] A. Barrat, M. Barthelemy, R. Pastor-Satorras, A. Vespignani, 《复杂加权网络的架构》，美国国家科学院院刊 101 (11) (2004) 3747–3752。[47] T. M. Cover, J. A. Thomas, 《信息论基础》，第2版，Wiley-Interscience，新泽西州霍博肯，2006。[48] C. Cortes, V. Vapnik, 《支持向量网络》，《机器学习》20 (3) (1995) 273–297。doi:10. 1007/BF00994018。[49] C. M. Bishop, 《模式识别与机器学习》，施普林格，纽约州纽约市，2006。[50] Z. Liu, X. Ling, Y. Zhu, 等, 《用于实时心律失常分类的基于FPGA的1D-CNN加速器》，《实时图像处理期刊》22 (2025) 66。doi:10.1007/s11554-025-01642-w。[51] Y. He, Y. Zhou, Y. Qian, J. Liu, J. Zhang, D. Liu, Q. Wu，Cardioattentionnet：通过高准确率、便携式深度学习模型推进心电图心搏表征，《心血管医学前沿》11 (2025) 1473482，原创研究文章，发表于2025年1月6日。doi:10.3389/fcvm.2024.1473482。URL https://www.frontiersin.org/journals/cardiovascular-medicine/articles/10.3389/fcvm.2024.1473482/full[52] H. A. H. Baca, F. d. L. P. Valdivia，利用智能手表心电图进行高效的基于深度学习的心律失常检测，《传感器》（巴塞尔）25 (17) (2025) 5244，在线发表于2025年8月23日。doi:10.3390/s25175244。URL https://www.mdpi.com/1424-8220/25/17/5244