



协和医学杂志

Medical Journal of Peking Union Medical College Hospital

ISSN 1674-9081, CN 11-5882/R



## 《协和医学杂志》网络首发论文

题目：融合知识驱动和数据驱动的混合决策模型构建：以室性心动过速病因诊断为例

作者：王敏，胡兆，徐晓巍，郑思，李姣，姚焰

收稿日期：2024-06-01

网络首发日期：2024-11-21

引用格式：王敏，胡兆，徐晓巍，郑思，李姣，姚焰. 融合知识驱动和数据驱动的混合决策模型构建：以室性心动过速病因诊断为例[J/OL]. 协和医学杂志.  
<https://link.cnki.net/urlid/11.5882.R.20241120.1710.002>



**网络首发：**在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

**出版确认：**纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

## 论 著

## 融合知识驱动和数据驱动的混合决策模型构建：以室性心动过速病因诊断为例

王敏<sup>1</sup>, 胡兆<sup>2</sup>, 徐晓巍<sup>1</sup>, 郑思<sup>1</sup>, 李姣<sup>1</sup>, 姚焰<sup>2</sup><sup>1</sup>中国医学科学院 北京协和医学院医学信息研究所, 北京 100020<sup>2</sup>国家心血管病中心 中国医学科学院阜外医院心律失常中心, 北京 100037

通信作者: 李姣, E-mail: jiao.li@pumc.edu.cn

姚焰, E-mail: ianyao@263.net.cn

**【摘要】目的** 构建一个融合知识驱动和数据驱动的混合决策模型, 并将其应用于室性心动过速的病因诊断。**方法** 检索 2018—2023 年心律失常疾病领域的临床实践指南、专家共识和医学文献作为知识源, 并回顾性收集 2013—2023 年中国医学科学院阜外医院室性心动过速 (ventricular tachycardia, VT) 患者的电子病历信息作为数据集。采用基于知识规则的方法构建临床路径作为知识驱动模型; 基于真实世界数据构建 VT 病因诊断三分类机器学习模型, 并选取其中的最佳模型作为数据驱动模型代表。以临床路径为基本框架, 将机器学习模型以自定义运算符的形式嵌入临床路径的决策节点中, 作为混合模型。评价 3 种模型的精确率、召回率和 F1 分数。**结果** 共纳入 3 部临床实践指南作为知识驱动模型的知识源; 收集了 1305 条患者数据作为数据集, 构建了 5 种机器学习模型, 其中 XGBoost 模型最佳。混合模型采用知识驱动的决策思维, 分别将 XGBoost 模型嵌入 2 层分类的决策节点中。3 种模型的精确率、召回率和 F1 分数如下: 知识驱动模型为 80.4%、79.1%和 79.7%; 数据驱动模型分别为 88.4%、88.5%和 88.4%; 混合模型分别为 90.4%、90.2%和 90.3%。**结论** 融合知识与数据驱动的混合模型展现出更高的准确性, 且混合模型的所有决策结果均基于循证证据, 这更接近临床医生的实际诊断思维。未来需更严格地验证混合模型广泛应用于医学领域的可行性。

**关键词** 室性心动过速; 知识驱动; 数据驱动; 混合模型; 决策支持**【中图分类号】** R541.7; TP35 **【文献标识码】** A

DOI: 10.12290/xhyxzz.2024-0381

基金项目: 中国医学科学院医学与健康重大协同创新项目“医学知识管理与智能化知识服务关键技术研究”(2021-I2M-1-056); 中国医学科学院阜外医院高水平医院临床科研业务费项目“心律失常数字化诊疗关键技术与智能系统研发”(2022-GSP-GG-25)

---

# Constructing a Knowledge-driven and Data-driven Hybrid Decision Model for Etiological Diagnosis of Ventricular Tachycardia

WANG Min<sup>1</sup>, HU Zhao<sup>2</sup>, XU Xiaowei<sup>1</sup>, ZHENG Si<sup>1</sup>, LI Jiao<sup>1</sup>, YAO Yan<sup>2</sup>

<sup>1</sup>Institute of Medical Information, Chinese Academy of Medical Sciences & Peking Union Medical College, Beijing, 100020, China

<sup>2</sup>Arrhythmia Center, Fuwai Hospital, Chinese Academy of Medical Sciences & Peking Union Medical College, National Center for Cardiovascular Diseases, Beijing, 100037, China

Corresponding authors: LI Jiao, E-mail: jiao.li@pumc.edu.cn

YAO Yan, E-mail: ianyao@263.net.cn

**【Abstract】 Objective** Constructing a trustworthy and highly accurate hybrid decision model incorporating knowledge-driven and data-driven model, and applying it to the field of healthcare. **Methods** We collected authoritative clinical practice guidelines, expert consensus and medical literature in the field of cardiovascular diseases from 2018 to 2023 as knowledge sources and retrospectively collected electronic medical record information of patients with ventricular tachycardia (VT) at Fu Wai Hospital from 2013 to 2023 as a dataset. The knowledge-driven model constructs a clinical pathway using a knowledge rule-based approach, and the data-driven model constructs a multi-classification machine learning model for etiological diagnosis of VT based on real-world data. The hybrid model's uses the clinical pathway as the basic framework, and the machine learning model is embedded as a custom operator into the decision node of the process. The comparison metrics of the three models are precision, recall and F1 score. **Results** A total of three clinical guidelines were included as knowledge sources for the knowledge-driven models, as well as collected 1,305 patient data as the dataset. A total of five machine learning models were constructed and the best model was XGBoost model. The hybrid model adopts the knowledge-driven thinking, embedding the machine learning model into the decision-making node of the two layers of classification, respectively. The precision, recall and F1-scores for the knowledge-driven model were 80.4%, 79.1% and 79.7%; for machine learning model were 88.4%, 88.5%, and 88.4%; for hybrid model were 90.4%, 90.2% and 90.3%. **Conclusion** The results show that the strategy of integrating knowledge-driven and data-driven clinical decision-making models is feasible. Compared to the pure knowledge-driven and data-driven models, the hybrid model demonstrated higher accuracy, and all the decision-making results of the model were based on evidence-based

---

evidence, which was closer to the actual diagnostic thinking of clinicians. The future requires more stringent validation of the hybrid model for feasibility in a broader range of medical fields.

**【Key words】** ventricular tachycardia; knowledge-driven; data-driven; hybrid model; decision-making

**Funding:** CAMS Innovation Fund for Medical Sciences (2021-I2M-1-056); National High Level Hospital Clinical Research Funding (2022-GSP-GG-25)

随着医学科学和信息技术的发展,临床决策在临床实践中扮演着关键角色。临床决策是指临床医生在面对患者时,基于现有的医学知识、患者具体情况以及可用的医疗资源,进行疾病分析、诊断推理和治疗方案制定等一系列复杂过程<sup>[1-2]</sup>。临床决策支持系统(clinical decision support system, CDSS)作为辅助临床决策的重要工具,根据其运行机制分为知识驱动型和数据驱动型<sup>[3]</sup>。

知识驱动型临床决策支持系统(knowledge-driven clinical decision support system, KDCDSS)基于权威的临床实践指南、专家共识和医学文献等知识资源而构建,能够通过内置的规则引擎和算法提供诊疗建议,确保医疗决策严格遵循最佳循证证据<sup>[4-5]</sup>。然而,传统的知识驱动 CDSS 多基于一般性或群体平均水平构建,无法涵盖所有病情变化,限制了其应对复杂临床情境的灵活性<sup>[6]</sup>。数据驱动型临床决策支持系统(data-driven clinical decision support system, DDCDSS)则利用大数据和 AI 技术,通过深度挖掘,识别疾病的潜在规律和个性化诊疗模式<sup>[7-8]</sup>。但数据驱动模型的“黑箱”特性,即决策过程不透明<sup>[9]</sup>,降低了临床医生对模型决策结果的信任度,从而导致数据驱动 CDSS 在临床应用中的利用率较低<sup>[10-11]</sup>。

由此可见,当前数据驱动型和知识驱动型 CDSS 各有其优势和局限性,临床决策领域亟需能够兼具二者优势的混合驱动模型的诞生<sup>[12-13]</sup>。2017年,美国国防部高级研究项目局提出了整合基于知识与数据这两种决策策略的倡议,旨在通过结合传统知识驱动模型中严谨的逻辑规则与数据驱动模型的强大学习能力,开发知识与数据双驱动的混合模型,构建更为透明且高效的 CDSS<sup>[14-15]</sup>。许多研究也开始初步探索融合知识与数据驱动的策略,包括优化知识规则引擎<sup>[16]</sup>、案例基础推理<sup>[17]</sup>、概率图模型<sup>[18]</sup>、逻辑推理与神经网络结合<sup>[19]</sup>等。

心律失常领域的临床决策支持应用前景广阔。根据世界卫生组织的数据,每年约有1700万人死于心血管疾病,约占全球死亡人数的三分之一。其中,室性心动过速(ventricular tachycardia, VT)是一种常见心律失常类型<sup>[20]</sup>。有关 VT 管理的临床实践指南已发布并不断更新,强调对持续性或非持续性 VT 患者进行病因诊断的重要性。在先前的工作中,本研究团队完成了一项针对中国 687 名心内科医生关于 VT 诊断知识和临床实践的需求调查,共分析了 567 份问卷,结果显示,大多数中国心内科医生(60.7%)表示会选择 CDSS 作为辅助工具<sup>[21]</sup>。

基于以上挑战,本文旨在构建一个融合知识驱动和数据驱动的可信赖、高精度的混合决策模型,并将其应用于室性心动过速的病因诊断。

## 1 方法

### 1.1 知识驱动模型构建

本研究采用已开发的一种数字化临床实践指南表示工具<sup>[22-23]</sup>,该工具主要定义了信息输

入节点、决策节点、动作节点、复合节点和解释节点，目的是将指南转化为计算机可解读格式，目前已成功用于相对简单的指南。核心步骤如下：（1）知识获取。知识源纳入标准：适用于临床场景；在定义的知识领域和子领域内；发布源文档实体；可操作的临床建议；临床专家对建议的相关性、潜在影响和范围的看法，以优先选择建议。（2）知识抽取。利用自然语言处理技术和大预言模型接口完成对文本格式指南知识进行识别和关键临床概念的抽取。

（3）知识表示。使用数字化指南表示工具定义的不同形状的节点表示不同类型路径节点。

（4）临床路径构建。基于抽取和表示的知识，为每个决策节点开发明确的规则或条件。临床路径中的规则通过 if-then 结构编写，并通过布尔逻辑运算符连接。最后，不同类型的节点图和逻辑关系被可视化为易于理解的临床路径流程图，包括所有关键决策点和可能的分支。

（5）规则绑定。将制定的规则绑定到相应的临床路径以实现计算机可执行的临床路径模型。本研究通过系统检索 PubMed、Web of Science、中国知网数据库，将 2018—2023 年发布的心律失常疾病领域的临床实践指南、专家共识和医学文献作为知识源，并在必要时使用其他数据源（如系统评价和荟萃分析）作为补充信息，以加强指南未完全覆盖某些方面的临床建议。根据知识源绘制临床路径原型，并使用数字化指南表示工具构建知识驱动模型。

## 1.2 数据驱动模型构建

### 1.2.1 数据收集与处理

为构建室性心动过速病因诊断的机器学习模型，本研究连续纳入 2013 年 1 月 1 日—2023 年 9 月 1 日就诊于中国医学科学院阜外医院心律失常中心的 1305 例室性心动过速患者。纳入标准：出院诊断包括“室性心动过速”或“室速”。排除标准：无可诊断为室性心动过速的电生理检查结果、12 导联标准心电图或 24 h 心电监测报告。室性心动过速的诊断标准为电生理检查、12 导联标准心电图或 24 h 心电监测见室性心动过速波形<sup>[24-26]</sup>。从电子病历系统中回顾性提取患者住院期间的临床资料，包括基本信息、出院诊断、病史、生命体征、目前用药、心电图/超声心动图和实验室检查等，共纳入 66 项患者特征信息进行分析。根据 VT 的病因，可分为 3 种疾病病因类型，即缺血性心脏病、非缺血器质性心脏病和特发性室性心动过速。缺血性心脏病引起的 VT 定义为诊断包含“心肌梗死”或“心肌缺血”的患者。非缺血器质性心脏病引起的 VT 包括“心肌炎”“心脏淀粉样变性”“心脏结节病”“非致密性心肌病”“心肌病”。特发性 VT 根据出院诊断定义为“特发性室性心动过速”。所有病因诊断标签均由心内科医生审查。

在特征选择阶段，采用 3 种方法筛选特征。首先，通过统计测试方法找出与目标变量显著相关的特征，使用随机森林模型中的基尼重要性，并选择排名前的基尼系数特征。同时，采用最大信息系数（maximal information coefficient, MIC）量化特征之间的相关性和冗余性，MIC 值接近 0 表示关联性较弱，根据 MIC 结果，与目标变量的 MIC 值超过设定阈值的特征被选择。最后，通过这 3 种方法筛选出的特征集合作为一个连接集合，结合多种特征选择方法的优势，尽可能全面地覆盖对模型有重要影响的所有特征。

### 1.2.2 模型构建

本研究先构建 5 种室速病因诊断的机器学习模型，包括：（1）逻辑回归；（2）随机森林<sup>[27]</sup>；（3）XGBoost<sup>[28]</sup>：一种提升方法，在许多决策树的集成上提供梯度提升；（4）轻量梯度增强机<sup>[29]</sup>：在传统梯度提升决策树的基础上引入了 2 种新技术，即梯度单边采样和独立特征合并；（5）支持向量机<sup>[30]</sup>：在 2 个类别之间创建一个决策边界，能够从一个或多个特征向量预测标签。以上 5 种模型已被广泛验证和应用于心血管领域，并有高质量研究证明其在预

---

测任务中的有效性和可靠性<sup>[31-33]</sup>。模型使用 GridSearchCV 优化超参数，考虑到 VT 病因诊断的指标，模型性能评估采用十折交叉验证得到的精确率 (Precision)、召回率 (Recall)、F1 分数 (F1-score)，选取其中性能最优的机器学习模型作为数据驱动模型。

### 1.3 混合模型构建

混合模型以临床路径为基本框架，结合知识驱动和数据驱动的优势，尝试将机器学习模型嵌入路径的决策节点，在对应的节点增加备注声明，使用对应的自定义算子，最终形成混合模型。在设计混合策略的过程中，本研究参考了 2012 年美国医疗保健信息与管理信息系统协会提出的 CDS five Rights 框架，旨在诊疗流程中采用正确的决策点以正确的方式提供给用户正确的信息。具体构建步骤包括：(1) 确定融合策略。明确知识与数据融合的策略，决定何时以及如何如何在知识驱动的诊疗路径中融入机器学习模型。(2) 整合知识驱动模型。确保临床实践指南、专家共识及临床路径已充分结构化和模块化，以便于与机器学习模型结合，每个决策节点应清晰定义其输入/输出及触发条件。(3) 设计机器学习模型决策节点。选择合适的决策节点，使机器学习模型能够作为自定义算子无缝嵌入到知识驱动模型中。(4) 嵌入机器学习模型。在临床路径的关键决策节点上集成机器学习模型，根据预设的规则和条件触发模型运行。触发的必要条件是在决策节点上需要符合知识模型（基于循证证据）的规则且现有的规则无法满足准确的决策时，才能触发机器学习模型。(5) 结果输出。在决策节点，输出知识驱动的规则判定与机器学习模型的预测结果，决策的优先顺序是先根据知识驱动模型结果，再根据机器学习模型结果。(6) 模型验证与优化。使用独立的患者数据集对混合模型进行验证，评估其性能指标如准确率、召回率、F1 分数等。根据反馈调整融合策略、机器学习参数或知识规则，进行迭代优化。

在本研究中，混合模型以心律失常临床诊疗路径作为基础框架，将 VT 病因诊断性能最优的机器学习模型作为自定义运算符嵌入关键的决策节点中。单独数据驱动的机器学习模型在进行室速病因诊断时，采用三分类方法进行 VT 病因诊断。而在知识驱动的临床路径中，考虑到 VT 的多源病因，系统地分类为缺血性心脏病、非缺血器质性心脏病和特发性 VT。前 2 类属于结构性心脏病的范畴，而特发性 VT 则是指在无结构性心脏病的情况下发生的 VT。临床实践中常用的 2 种鉴别诊断策略可指导后续管理，这也符合实际临床医生的思维方式。因此，混合模型在整合知识驱动和数据驱动模型时，采用知识驱动的思维方式，第一层先根据病因分类为缺血性和非缺血性，第二层在分类为特发性和非特发性（器质性），分别将机器学习模型嵌入到两层分类的决策节点中，最终分类为缺血性心脏病、非缺血器质性心脏病和特发性 VT。

### 1.4 统计学处理

采用 Python (version 3.9) 编程语言基于 sklearn (version 1.1.0) 的机器学习工具包进行统计学分析。为严格比较 3 种模型的性能并验证混合模型的有效性，将数据集 ( $n=1305$ ) 随机划分为测试集 ( $n=783$ ) 和验证集 ( $n=522$ )。随后，根据 VT 病因诊断结果，评估精确率、召回率和 F1 分数。

## 2 结果

## 2.1 知识驱动模型

本研究共纳入三部指南作为知识源<sup>[24-26]</sup>，绘制的临床路径原型见图 1。为有效评估该知识驱动模型的有效性，并与其他模型进行比较，利用可用的患者数据 ( $n=522$ ) 对该模型进行了评估，结果显示，精确率、召回率和 F1 分数分别为 80.4%、79.1%和 79.7%。

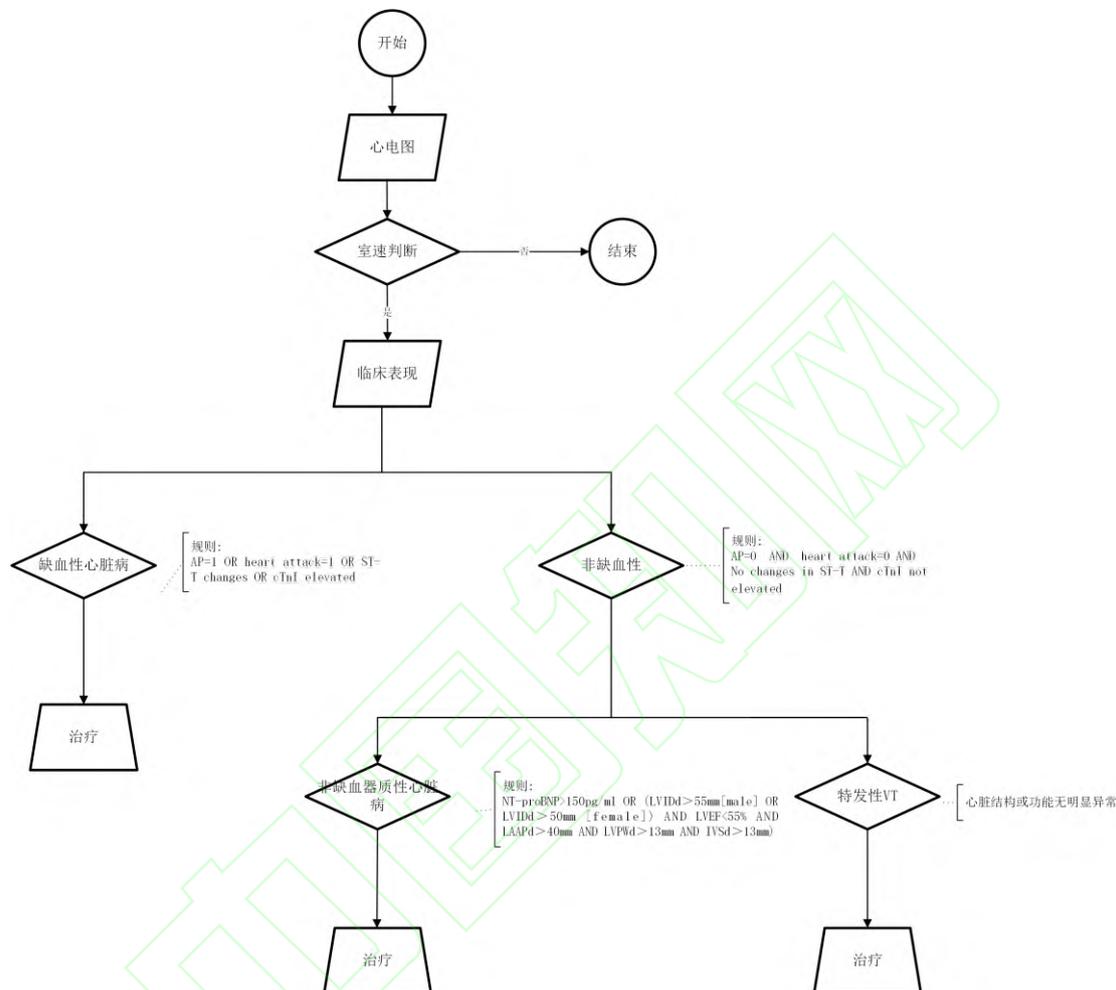


图 1 基于知识驱动的临床路径

Fig. 1 Knowledge-driven clinical pathway

AP (angina pectoris): 心绞痛; cTnI (cardiac troponin): 肌钙蛋白; NT-proBNP (N-terminal pro-B-type natriuretic peptide): N 末端 B 型钠尿肽前体; LVIDd (left ventricular internal diameter in diastole): 左心室舒张期内径; LAAPd (left atrial anteroposterior diameter): 左房前后径; LVEF (left ventricular ejection fraction): 左心室射血分数; IVSd (interventricular septum thickness in diastole): 室间隔厚度

## 2.2 数据驱动模型

VT 病因诊断机器学习模型的性能如表 1 所示。在建立的 5 种机器学习模型中, XGBoost 模型在精确率、召回率和 F1 分数上模型性能表现更好, 分别达到了 89.7%、76.9%和 94.1%。从模型整体性能结果来看, XGBoost 模型也是性能最佳模型 (精确率、召回率和 F1 分数为 88.4%、88.5%、88.4%)。

表 1 机器学习模型性能比较(%)

Tab.1 Comparison of machine learning model performances(%)

模型	缺血性心脏病			非缺血器质性心脏病			特发性 VT			整体		
	精确率	召回率	F1 分数									
Logistic Regression	73.5	80.0	76.6	56.2	36.0	43.9	76.4	82.4	82.4	70.9	72.2	71.0
Random Forest	88.4	88.4	88.4	74.6	70.7	72.6	93.4	<b>97.1</b>	<b>95.2</b>	87.1	87.2	87.1
XGBoost	<b>87.9</b>	<b>91.6</b>	<b>89.7</b>	80.9	<b>73.3</b>	<b>76.9</b>	<b>95.0</b>	93.1	94.1	<b>88.4</b>	<b>88.5</b>	<b>88.4</b>
LightGBM	87.9	91.2	89.5	<b>81.5</b>	70.7	75.7	93.3	95.1	94.2	88.1	88.3	88.1
SVM	84.0	87.9	85.9	82.3	68.0	74.5	84.8	87.3	86.0	83.9	83.9	83.7

### 2.3 混合模型

融合知识驱动和数据驱动的混合模型如图 2 所示。当面对 VT 患者时，混合模型会根据知识驱动的临床路径逐步进行推理，当路径进行到关键决策节点时，系统首先根据知识规则作出决策，如果规则未能覆盖患者的所有信息，则触发机器学习模型进行决策。临床路径中的每个决策节点上的输出至少是基于知识驱动的结果标签（或知识与数据双驱动），然后从该标签对应的分支继续执行规则路径，直至最终节点，完成心律失常诊疗。最终混合模型的输出结果是融合了知识与数据双驱动模型决策结果，以及对应的治疗方案作为系统推荐的治疗方案。性能评价结果显示，混合模型的精确率、召回率和 F1 分数分别为 90.4%、90.2% 和 90.3%。

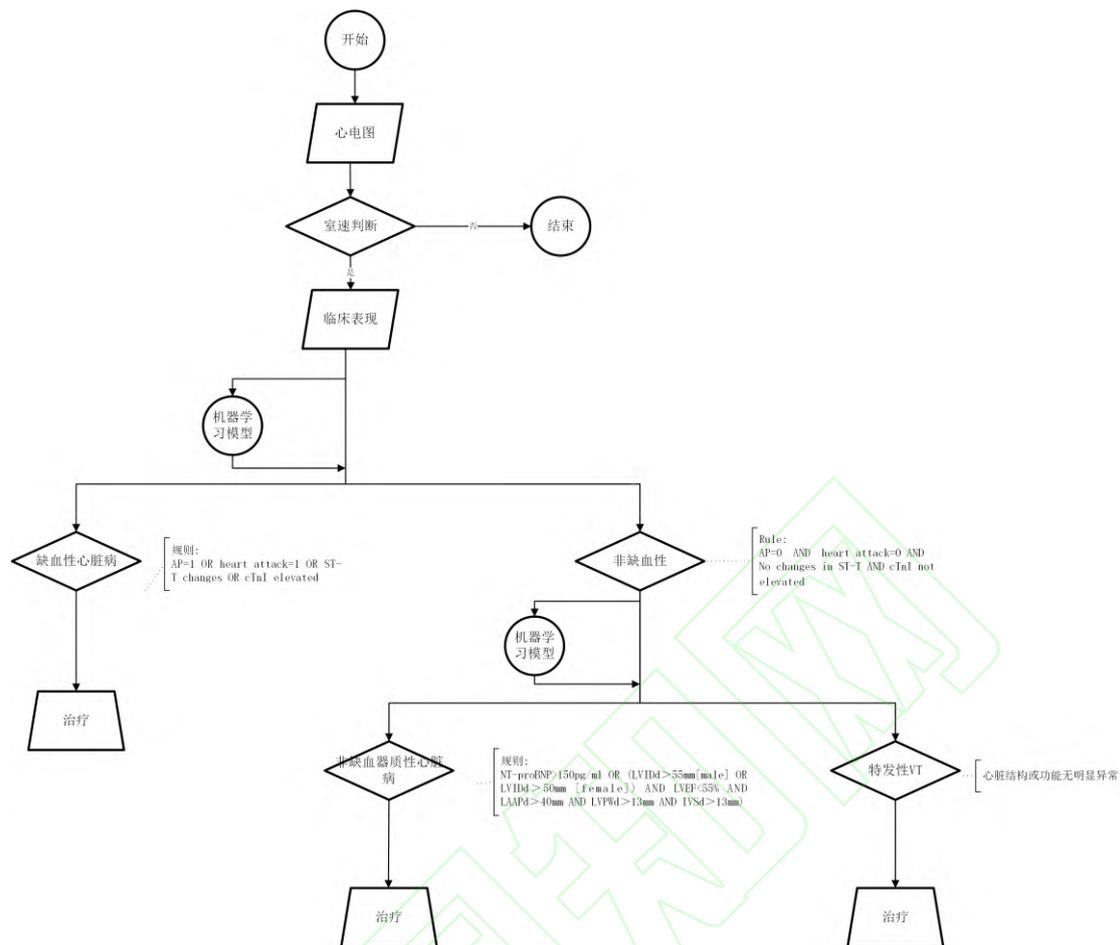


图 2 基于混合驱动的临床路径

Fig. 2 Hybrid-driven clinical pathway

AP、cTnI、NT-proBNP、LVIDd、LAAPd、LVEF、IVSd: 同图 1

### 3 讨论

本研究以知识驱动的临床路径作为基本框架，嵌入了机器学习模型，构建了一种混合决策模型，性能评价结果显示，混合决策模型的精确率、召回率和 F1 分数分别为 90.4%、90.2% 和 90.3%，优于知识驱动模型以及数据驱动模型。

尽管临床决策领域中 CDSS 的可用性不断提高，但其在临床实践中的应用仍然有限，尚未实现广泛普及<sup>[34-35]</sup>。知识驱动型 CDSS 的核心在于将医学专家的知识经验和临床实践指南和最新研究成果转化为计算机能够理解执行的规则或算法。这种基于知识规则的方法由于致力于模仿人类专家，构建以人为中心的决策过程，因此具有更好的循证性和可信性。然而，尽管具有可解释性，规则的获取和更新过程需要相当的时间和成本。此外，基于指南、专家共识和医学文献制定的规则通常是静态的和笼统的，这可能导致模型在决策能力上不够灵活<sup>[36]</sup>。随着临床场景的复杂性增加，知识驱动模型可能需要构建大量复杂的规则，这不仅增加了系统的运行负担，也使得系统维护更加困难。相反，数据驱动型 CDSS 很好地弥补了知识驱动模型的局限性，数据驱动模型能够处理大规模数据集，并使用 AI 技术提供更灵活的决策支持。然而，数据驱动模型最大的挑战是其可解释性差，缺乏决策的循证证据，这也是数据驱动型 CDSS 尚未被广泛采用的主要原因<sup>[37]</sup>。对于临床医生而言，比起 CDSS 的内部工作原理和实施细节，他们更加关心系统能否提供以人为中心

的人工智能（human-centered artificial intelligence, HCAI）技术，这些技术能够在实际的临床场景中辅助决策支持<sup>[38-39]</sup>。

鉴于知识驱动和数据驱动模型各自的优势和局限性，二者的结合被认为具有互补性，其协同效应已经得到证明<sup>[40]</sup>。近年来，在心血管疾病领域，研究人员开始探索结合知识驱动和数据驱动的决策支持方法。一项关于心血管疾病 CDSS 的韩国研究，采用混合知识获取方法（专家驱动和机器学习驱动）构建知识库，并证明了此种混合模型在协助临床医生进行心力衰竭诊断方面具有较大潜力<sup>[36]</sup>。

本研究构建的混合模型以知识驱动模型为基础框架，将机器学习模型作为自定义运算符嵌入临床路径的决策节点中，用于补充难以形式化或量化的知识驱动模型，并将其应用于 VT 病因诊断分类。但本研究仍存在如下局限性：（1）在知识驱动模型的构建过程中，临床概念的模糊性或定义的不明确性可能导致其难以被精确地转化为知识规则。（2）本研究仅对准确性这一核心指标对不同模型进行了对比。在临床决策中，准确性是评估 CDSS 性能的最常用指标<sup>[41]</sup>，然而，系统的可信赖性或可解释性也是评估的核心因素<sup>[42]</sup>。

综上，本文有效融合知识驱动和数据驱动临床决策模型，构建了可信赖的混合决策模型，结果表明，这种融合策略不仅可行，且与单独的知识驱动和数据驱动模型相比，混合模型展现出更高的准确性。混合模型的所有决策结果均基于循证证据，这更接近临床医生的实际诊断思维。这种新一代的基于 HCAI 混合模型不仅能提高医疗保健服务的质量和效率，还能为临床医生提供可靠的决策支持，最终推动医疗行业的现代化和智能化发展。未来需要更严格地验证这种融合策略更广泛应用于医学领域的可行性。

**作者贡献：**王敏负责研究设计、数据分析及论文撰写；胡兆负责数据收集、论文修订；徐晓巍、郑思负责论文修订；李姣、姚焰提供研究思路，负责论文修订。

**利益冲突：**所有作者均声明不存在利益冲突

## 参考文献

- Bal M, Amasyali MF, Sever H, et al. Performance Evaluation of the Machine Learning Algorithms Used in Inference Mechanism of a Medical Decision Support System[J]. The Scientific World Journal, 2014, 2014:137896.
- 陆瑶, 刘佳宁, 王冕, 等. 人工智能在医患共同决策中的应用[J/OL], <http://kns.cnki.net/kcms/detail/11.5882.R.20230821.1709.004.html> (2024-05-19).
- Oliva G, Hak F, Guimarães T, et al. Towards effective clinical decision support systems: A systematic review[J]. Plos One, 2022, 17(8):e0272846.
- 郑锐, 于广军. 临床辅助决策支持系统研究综述[J]. 中国数字医学, 2023, 18(11): 70-77.
- 张山, 崔薇, 吴瑛. 以智能化谘询护理临床决策辅助支持系统为例探讨规则驱动的临床护理决策支持系统的基本组成[J]. 护理研究, 2022, 36(24): 4464-4468.
- 周祎灵, 石清阳, 陈向阳, 等. 本体在糖尿病临床决策支持系统中的应用[J]. 四川大学学报(医学版), 2023, 54(1): 208-216.
- Rajula HSR, Verlato G, Manchia M, et al. Comparison of Conventional Statistical Methods with Machine Learning in Medicine: Diagnosis, Drug Development, and Treatment[J]. Medicina, 2020,

---

56(9):455.

8. Tutun S, Johnson ME, Ahmed A, et al. An AI-based Decision Support System for Predicting Mental Health Disorders[J]. *Information Systems Frontiers*, 2022, 25: 1261-1276.

9. 王敏, 胡兆, 徐晓巍, 等. 面向心律失常疾病的临床决策支持系统交互性研究与实现[J]. *医学信息学杂志*, 2024, 45(4): 70-77.

10. 龚欢欢, 柯晓伟, 王爱民, 等. 可解释机器学习模型预测心脏骤停患者院内死亡风险: 基于 MIMIC-IV2.0 数据库[J]. *协和医学杂志*, 2023, 14(3): 528-535.

11. Lu HH-S, Trottet C, Vogels T, et al. Modular Clinical Decision Support Networks (MoDN)—Updatable, interpretable, and portable predictions for evolving clinical environments[J]. *PLOS Digital Health*, 2023, 2(7):e0000108.

12. Buschmeyer K, Hatfield S and Zenner J. Psychological assessment of AI-based decision support systems: tool development and expected benefits[J]. *Frontiers in Artificial Intelligence*, 2023, 6:1249322.

13. Phillips-Wren G and Adya M. Decision making under stress: the role of information overload, time pressure, complexity, and uncertainty[J]. *Journal of Decision Systems*, 2020, 29:213-225.

14. Rosen S and Saban M. Can ChatGPT assist with the initial triage? A case study of stroke in young females[J]. *International Emergency Nursing*, 2023, 70: 101340.

15. Rosen S and Saban M. Evaluating the reliability of ChatGPT as a tool for imaging test referral: a comparative study with a clinical decision support system[J]. *European Radiology*, 2023.

16. Hussain M, Afzal M, Ali T, et al. Data-driven knowledge acquisition, validation, and transformation into HL7 Arden Syntax[J]. *Artificial Intelligence in Medicine*, 2018, 92: 51-70.

17. Brown D, Aldea A, Harrison R, et al. Temporal case-based reasoning for type 1 diabetes mellitus bolus insulin decision support[J]. *Artificial Intelligence in Medicine*, 2018, 85:28-42.

18. Jiao Y, Zhang Z, Zhang T, et al. Development of an artificial intelligence diagnostic model based on dynamic uncertain causality graph for the differential diagnosis of dyspnea[J]. *Frontiers of Medicine*, 2020, 14: 488-497.

19. Vilhena J, Rosário Martins M, Vicente H, et al. An Integrated Soft Computing Approach to Hughes Syndrome Risk Assessment[J]. *Journal of Medical Systems*, 2017, 41(3):40 .

20. Roberts-Thomson KC, Lau DH and Sanders P. The diagnosis and management of ventricular arrhythmias[J]. *Nature Reviews Cardiology*, 2011; 8: 311-321.

21. Hu Z, Wang M, Zheng S, et al. Clinical Decision Support Requirements for Ventricular Tachycardia Diagnosis Within the Frameworks of Knowledge and Practice: Survey Study[J]. *JMIR Human Factors*, 2024, 11:e55802.

22. 覃露, 徐晓巍, 丁玲玲, 等. 面向决策支持的临床指南知识表示方法研究[J]. *中华医学图书情报杂志*, 2020, 29(2): 1-8.

23. 闵令通, 段会龙, 吕旭东. 基于 openEHR 的医疗信息建模方法[J]. *中华医学图书情报杂志*, 2018, 27(3): 1-4.

24. Pedersen CT, Kay GN, Kalman J, et al. EHRA/HRS/APHRS expert consensus on ventricular arrhythmias[J]. *Europace*, 2014; 16: 1257-1283.

25. Zipes DP, Camm AJ, Borggrefe M, et al. ACC/AHA/ESC 2006 Guidelines for Management of Patients With Ventricular Arrhythmias and the Prevention of Sudden Cardiac Death[J]. *Journal of the American College of Cardiology*, 2006, 48: e247-e346.

26. Zeppenfeld K, Tfelt-Hansen J, de Riva M, et al. 2022 ESC Guidelines for the management of patients with ventricular arrhythmias and the prevention of sudden cardiac death[J]. *European Heart*

---

Journal, 2022, 43: 3997-4126.

27. L B. Random Forests[J]. Mach Learn, 2001; 45: 5–32.
28. GC CT. XGBoost: a scalable tree boosting system[C]. Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining-KDD. San Francisco, CA, USA., 2016.
29. Ke G L MQ, Finley T, et al. LightGBM: a highly efficient gradient boosting decision tree[C]. Proceedings of the 31st International Conference on Neural Information Processing Systems. NY USA: Curran Associates Inc, 2017.
30. N W. What is a support vector machine[J]? Nat Biotechnol, 2006, 24(12): 1565-1567.
31. Boeddinghaus J, Doudehis D, Lopez-Ayala P, et al. Machine Learning for Myocardial Infarction Compared With Guideline-Recommended Diagnostic Pathways[J]. Circulation, 2024, Apr 2;149(14):1090-1101.
32. Zhao K, Zhu Y, Chen X, et al. Machine Learning in Hypertrophic Cardiomyopathy: Nonlinear Model From Clinical and CMR Features Predicting Cardiovascular Events[J]. JACC Cardiovasc Imaging, 2024, Aug;17(8):880-893.
33. D'Ascenzo F, De Filippo O, Gallone G, et al. Machine learning-based prediction of adverse events following an acute coronary syndrome (PRAISE): a modelling study of pooled datasets. Lancet. 2021 Jan 16;397(10270):199-207.
34. Sutton RT, Pincock D, Baumgart DC, et al. An overview of clinical decision support systems: benefits, risks, and strategies for success[J]. npj Digital Medicine, 2020, 3:17.
35. Khairat S, Marc D, Crosby W, et al. Reasons For Physicians Not Adopting Clinical Decision Support Systems: Critical Analysis. JMIR Medical Informatics 2018, 6(2):e24.
36. Shoaip N, El-Sappagh S, Abuhmed T, et al. A dynamic fuzzy rule-based inference system using fuzzy inference with semantic reasoning[J]. Scientific Reports, 2024, 14(1):4275.
37. 张知非, 杨郑鑫, 黄运有, 等. 医学大数据与人工智能标准体系: 现状、机遇与挑战[J]. 协和医学杂志, 2021, 12(5): 614-620.
38. Tjoa E and Guan C. A Survey on Explainable Artificial Intelligence (XAI): Toward Medical XAI[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32: 4793-4813.
39. Zheng J-X, Li X, Zhu J, et al. Interpretable machine learning for predicting chronic kidney disease progression risk[J]. Digital Health, 2024, 10:20552076231224225.
40. Fan F-L, Xiong J, Li M, et al. On Interpretability of Artificial Neural Networks: A Survey[J]. IEEE Transactions on Radiation and Plasma Medical Sciences, 2021, 5:741-760.
41. Park S, Lee SJ, Weiss E, et al. Intra- and Inter-Fractional Variation Prediction of Lung Tumors Using Fuzzy Deep Learning[J]. IEEE Journal of Translational Engineering in Health and Medicine, 2016, 4:1-12.
42. Lobach DF, Johns EB, Halpenny B, et al. Increasing Complexity in Rule-Based Clinical Decision Support: The Symptom Assessment and Management Intervention[J]. JMIR Medical Informatics, 2016, 4(4):e36 .

(收稿: 2024-06-01 录用: 2024-09-02)

(本文编辑: 李 娜)