

本文引用格式：陈其琛,杨其宇.粗糙集与径向基函数神经网络融合的除颤结果预测算法[J].自动化与信息工程,2025,46(2):48-53.

CHEN Qichen, YANG Qiyu. Defibrillation outcome prediction algorithm integrating rough set and radial basis function neural network[J]. Automation & Information Engineering, 2025,46(2):48-53.

## 粗糙集与径向基函数神经网络融合的除颤结果预测算法

陈其琛 杨其宇

(广东工业大学, 广东 广州 510006)

**摘要:** 多种室颤心电特征组合虽然可以提高除颤结果预测的准确率,但当算法部署在硬件条件有限的嵌入式设备上时,计算资源紧张;此外,室颤心电特征之间可能存在冗余,造成计算资源浪费。为此,提出一种粗糙集与径向基函数(RBF)神经网络融合的除颤结果预测算法。首先,从室颤心电波形数据集中提取室颤心电特征;然后,利用基于属性重要度的约简算法对室颤心电特征进行属性约简;最后,采用约简后的室颤心电特征数据集训练RBF神经网络,实现除颤结果预测。实验结果表明,该算法可有效降低模型占用空间,提高除颤结果预测的速度与准确率。

**关键词:** 粗糙集; 径向基函数神经网络; 除颤结果预测; 室颤心电特征; 属性约简

中图分类号: R318.04; TP391.4

文献标志码: A

文章编号: 1674-2605(2025)02-0007-06

DOI: 10.12475/aie.20250207

开放获取

## Defibrillation Outcome Prediction Algorithm Integrating Rough Set and Radial Basis Function Neural Network

CHEN Qichen YANG Qiyu

(Guangdong University of Technology, Guangzhou 510006, China)

**Abstract:** Multiple combinations of ventricular fibrillation electrocardiogram features can improve the accuracy of defibrillation outcome prediction. However, when algorithms are deployed on embedded devices with limited hardware resources, computational capacity becomes constrained. Additionally, there may be redundancy among ventricular fibrillation electrocardiogram features, leading to inefficient use of computational resources. To address these issues, this study proposes a defibrillation outcome prediction algorithm that integrates rough set theory and a radial basis function (RBF) neural network. First, ventricular fibrillation electrocardiogram features are extracted from the ventricular fibrillation electrocardiogram waveform dataset. Then, an attribute reduction algorithm based on attribute importance is applied to reduce redundant features. Finally, the reduced ventricular fibrillation electrocardiogram feature dataset is used to train the RBF neural network for defibrillation outcome prediction. Experimental results demonstrate that this algorithm effectively reduces model storage requirements while improving prediction speed and accuracy.

**Keywords:** rough set; radial basis function neural network; defibrillation outcome prediction; ventricular fibrillation electrocardiogram features; attribute reduction

### 0 引言

中国每年心脏骤停的患者约有 55 万人,死亡率高达 99%<sup>[1]</sup>,其中,院外心脏骤停是导致死亡的主要原因之一。院外心脏骤停常见的初始心律是心室颤动(简称室颤),其特征为心肌细胞快速且无组织地收

缩,心电波形难以辨别。

目前,常用的自动体外除颤仪包含了心电图分析算法,主要用于判断心脏骤停患者是否需要电除颤(简称除颤)。除颤是指通过向患者心脏输送适当强度的电流来消除心肌的电异常,是逆转室颤并恢复

心肌有组织电活动的最佳治疗方法<sup>[2]</sup>。尽管除颤已被证明有助于提高心脏骤停患者的存活率<sup>[3-4]</sup>，但对于持续性室颤患者立即除颤的有效性仍存在争议。随着室颤未经治疗的持续时间延长，成功除颤的可能性迅速降低，这是因为在持续性室颤期间，心肌需氧量增加，导致心肌能量耗尽并引发酸中毒状态。在这种状态下对心脏除颤，心肌较难恢复有组织的电活动<sup>[5]</sup>。此外，通过心肺复苏也可以改善心肌状况。临床数据表明，在未经治疗的室颤持续时间内，患者存活率每分钟下降 7%~10%；如果提供有效的心肺复苏，患者存活率每分钟仅下降 3%~4%<sup>[6]</sup>。因此，在除颤前进行心肺复苏，可以提高心肌恢复有组织电活动的可能性。然而，院外心脏骤停患者室颤的发作时间通常无法准确评估，导致难以确定心肺复苏或立即除颤的优先顺序。此外，重复不成功的高能量除颤，会损害已经缺血的心肌，并可能导致室颤恶化为心搏停止或无脉性电活动，从而难以复苏<sup>[7]</sup>。因此，通过除颤结果预测来确定除颤的最佳时机已成为当前的研究热点。

近年来，在对心电波形的定量分析中，时域特征、频域特征常被用来预测除颤结果，且多种特征的组合具有更好的预测性能。文献[8]将幅度谱面积（amplitude spectral area, AMSA）和呼气末二氧化碳组合，利用支持向量机（support vector machine, SVM）分类模型进行除颤结果预测，其特征曲线下面积（area under characteristic curve, AUC）为 0.71，预测性能优于采用单一特征的预测算法。文献[9]采用 SVM 算法组合 10 个心电特征和 3 个患者变量对除颤结果进行预测，AUC 为 0.77，预测性能略优于文献[8]。然而，提取过多的特征会大幅降低预测效率，延误最佳除颤时机，且多特征之间可能存在冗余，降低预测模型的准确率。

粗糙集是一种处理不确定性、不完整性数据的数学工具，可在缺少先验知识的情况下，约简冗余数据属性。本文融合粗糙集和径向基函数（radial basis function, RBF）神经网络实现除颤结果预测，利用基于属性重要度的约简算法约简冗余属性，提高预测效率；通过 RBF 神经网络模型组合多种室颤心电特征，

提高预测准确率。

## 1 相关理论基础

### 1.1 基于粗糙集的属性约简

在粗糙集理论<sup>[10]</sup>中，知识表达系统  $S$  可表示为

$$S = \langle U, C, D, V, f \rangle \quad (1)$$

式中： $U$  为论域； $C = \{c_i\}$  为条件属性集， $D = \{d\}$  为决策属性集， $C \cup D = A$  为属性集合； $V = \bigcup_{r \in A} V_r$  为属性集合， $V_r$  为属性  $r \in A$  的属性值范围； $f : U \times A \rightarrow V$  为信息函数，其指定了  $U$  中每个对象的属性值  $c$ 。

特别地，若条件属性集  $C$  和决策属性集  $D$  的交集为  $\phi$ ，则该知识表达系统  $S$  称为决策表。

### 1.2 基于属性重要度的约简算法

对于某个决策表  $S = \langle U, A \rangle$ ，其条件属性集  $C$  与决策属性集  $D$  的交集为空集，则条件属性集  $C$  中某一条属性  $\alpha$  的属性重要度计算公式为

$$\text{sig}(\alpha, C; D) = \gamma_C(D) - \gamma_{C-\alpha}(D) \quad (2)$$

式中： $\gamma_C(D)$  为条件属性集  $C$  的近似分类质量， $\gamma_{C-\alpha}(D)$  为去除某一条属性  $\alpha$  后的条件属性集的近似分类质量。

基于属性重要度的约简算法根据属性重要度从大到小排序决策表中的条件属性，并依次将重要度最大的属性加入约简属性集中，直至约简属性集达到最简，即为最终约简结果，具体步骤如下：

- 1) 根据给定知识库创建决策表；
- 2) 利用基于信息熵的离散化算法<sup>[11]</sup>对决策表中的数据进行离散化；
- 3) 将所有满足  $\gamma_C(D) \neq \gamma_{C-\alpha}(D)$  的条件属性  $\alpha$  构成该决策表的核  $\text{core}_D(C)$ ，并将约简属性集  $B$  设为  $\text{core}_D(C)$ ；
- 4) 判断正域  $\text{pos}_B(D) = \bigcup \{Y \in U/B \mid Y \subseteq D\}$ ，是否等于正域  $\text{pos}_C(D) = \bigcup \{Y \in U/C \mid Y \subseteq D\}$ ，若不

相等, 从当前未入选的属性  $C - B$  中, 选取对决策结果影响最大的属性加入约简属性集  $B$  中, 并重复步骤 4); 若相等, 属性约简完成, 输出最终约简属性集  $B$ 。基于属性重要度的约简算法流程如图 1 所示。

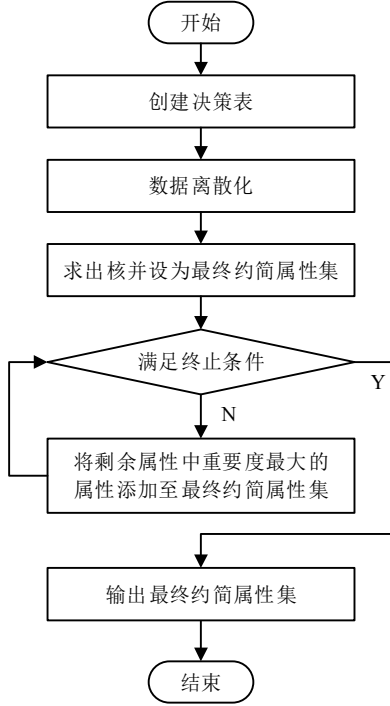


图 1 基于属性重要度的约简算法流程图

### 1.3 基于信息熵的离散化算法

粗糙集主要用于处理不确定性的离散型数据, 对于连续型数据需先对其进行离散化处理。基于信息熵的离散化算法的核心思想是使离散后数据集的信息熵最小。

对于随机变量  $A$ , 其信息熵  $H(A)$  的计算公式为

$$H(A) = -\sum_{a \in A} \log p(a) \cdot p(a) \quad (3)$$

式中:  $p(a)$  为出现  $A = a$  的概率,  $\log$  的底一般选为 2 或  $e$ 。

若数据集  $X$  的条件属性集为  $C$ 、划分阈值为  $T$ 。划分阈值  $T$  将数据集  $X$  分成 2 个子集  $X_1$  和  $X_2$ 。其中, 子集  $X_1$  由数据集  $X$  中小于等于划分阈值  $T$  的数据组成; 子集  $X_2$  由数据集  $X$  中大于划分阈值  $T$  的数据组成。该划分阈值  $T$  关于条件属性集  $C$  的类信息熵值为

$$H(C, T; X) = \frac{X_1}{X} H(X_1) + \frac{X_2}{X} H(X_2) \quad (4)$$

为了直观描述数据集  $X$  的信息熵因分割而发生的变化, 定义信息熵变化量  $gain(C, T; X)$  为

$$gain(C, T; X) = H(X) - H(C, T; X) \quad (5)$$

为避免过多地分割数据集  $X$ , 当信息熵变化量  $gain(C, T; X)$  满足以下结束条件时, 离散化完成, 停止划分数数据集。结束条件为

$$gain(C, T; X) < \frac{\log_2(N-1)}{N} + \frac{\Delta(C, T; X)}{N} \quad (6)$$

式中:  $N$  为数据集  $X$  的数据总数量,  $\Delta(C, T; X)$  的计算公式为

$$\Delta(C, T; X) = \log_2(3^g - 2) - [g \cdot H(X) - g_1 \cdot H(X_1) - g_2 \cdot H(X_2)] \quad (7)$$

式中:  $g$ 、 $g_1$ 、 $g_2$  分别为数据集  $X$ 、子集  $X_1$ 、子集  $X_2$  的分类类别数。

## 2 算法设计

### 2.1 数据集

本实验数据来自公开的室颤心电波形数据集<sup>[12]</sup>。该数据集包含 260 名心脏骤停患者的心电波形数据, 根据除颤结果分为成功 (56 例)、不成功 (195 例) 和不确定 (9 例) 3 类。

本文截取每名心脏骤停患者第一次除颤前 4 s 的室颤心电波形数据进行分析 and 特征提取。为了方便计算, 统一对室颤心电波形数据进行 250 Hz 的重采样。为了抑制噪声, 采用窗宽为 350 ms 的中值滤波器消除基线漂移; 通过 IIR 三阶带阻滤波器滤除工频干扰, 截止频率分别设为 49.5 Hz 和 50.5 Hz; 利用四阶低通滤波器去除肌电干扰, 截止频率设为 55 Hz。

### 2.2 室颤心电特征提取

本文选取了临床研究中除颤结果预测性能较好的 15 种室颤心电特征<sup>[12-13]</sup> (时域特征、频域特征和

非线性动态特征)，对除颤前 4 s 的室颤心电波形数据进行除颤结果预测性能分析。

时域特征包括中值斜率、平均斜率、信号积分、平均峰-峰振幅、振幅范围和均方根值共 6 种特征。

频域特征包括 AMSA、功率谱密度分析、峰值功率频率、能量、质心频率和功率最大值共 6 种特征。

非线性动态特征包括庞加莱图的中值步进增量、拟合的椭圆面积和赫斯特指数共 3 种特征。

### 2.3 RBF 神经网络

本文采用的室颤心电波形数据集较小、数据维度较低，且本文提出的粗糙集与 RBF 神经网络融合的除颤结果预测算法需要部署在硬件条件有限的体外除颤仪上。因此，选择结构较简单、参数较少的 RBF 神经网络作为分类器。与传统的神经网络相比，RBF

神经网络具有训练速度快、稳定性好和泛化能力强等特点，尤其适合资源受限的嵌入式医疗设备场景。

RBF 神经网络主要包括输入层、隐藏层和输出层等 3 层。其中，隐藏层神经元的激活函数采用 RBF，输出层激活函数采用线性函数。

RBF 神经网络的训练过程如下：

1) 在无监督学习中，通过聚类或随机给定的方式从室颤心电波形数据中选择隐藏层神经元的中心点和宽度；

2) 在有监督学习中，通过最小二乘法确定 RBF 神经网络权值。

### 2.4 算法步骤

粗糙集与 RBF 神经网络融合的除颤结果预测算法流程如图 2 所示。




图 2 粗糙集与 RBF 神经网络融合的除颤结果预测算法流程图

粗糙集与 RBF 神经网络融合的除颤结果预测算法具体步骤如下：

1) 对室颤心电波形数据进行预处理，抑制残留的基线漂移、工频干扰和肌电干扰；

2) 提取室颤心电波形数据的时域特征、频域特征和非线性动态特征，构建室颤心电特征数据集，并通过该数据集构建室颤心电特征决策表；

3) 采用基于属性重要度的约简算法删除室颤心电特征决策表中的冗余属性，获得约简后的室颤心电特征数据集；

4) 利用约简后的室颤心电特征数据集训练 RBF 神经网络，并进行除颤结果预测。

## 3 实验结果及分析

实验硬件环境：Intel Core i5 -12400F 处理器，Windows 10 操作系统，内存 48 GB；软件环境：MATLAB R2021b，Python 3.6。

### 3.1 室颤心电特征数据集的属性约简

通过室颤心电特征数据集构建的室颤心电特征决策表  $S_{VF} = \langle U, A \rangle$  如表 1 所示。其中，条件属性集  $C = \{c_1, c_2, \dots, c_{65}\}$  中， $c_1 \sim c_{15}$  为 15 种室颤心电特征， $c_{16} \sim c_{65}$  为室颤心电频谱图上 0~49 Hz 各频率对应的幅度值；决策属性集  $D = \{0, 1\}$  中，0 表示除颤失败，1 表示除颤成功。

表 1 室颤心电特征决策表

数据样本	条件属性							决策属性
	$c_1$	$c_2$	...	$c_{15}$	$c_{16}$	...	$c_{65}$	
$u_1$	6.25	0.10	...	0.26	0.01	...	0.01	0
$u_2$	3.90	0.07	...	0.25	0.02	...	0.00	0
$u_3$	10.12	0.263	...	0.31	0.01	...	0.01	0
...	...	...	...	...	...	...	...	...
$u_{250}$	17.43	0.60	...	0.13	0.01	...	0.02	1
$u_{251}$	10.04	0.25	...	0.16	0.02	...	0.00	1

利用基于信息熵的离散化算法对室颤心电图特征决策表的数据进行离散化，结果如表 2 所示。

表 2 离散化后的室颤心电图特征决策表

数据样本	条件属性							决策属性
	$c_1$	$c_2$	...	$c_{15}$	$c_{16}$	...	$c_{65}$	
$u_1$	0	0	...	1	5	...	3	0
$u_2$	0	0	...	1	5	...	0	0
$u_3$	1	1	...	1	5	...	2	0
...	...	...	...	...	...	...	...	...
$u_{250}$	1	1	...	2	3	...	2	1
$u_{251}$	1	1	...	0	5	...	2	1

利用基于属性重要度的约简算法对离散化后的室颤心电图特征决策表进行属性约简。

1) 通过基于属性重要度的约简算法得到室颤心电图特征决策表的核为  $core_{VF} = \{c_1, c_2, c_3, c_6, c_7, c_9, c_{13}, c_{16}, c_{17}, c_{23}, c_{25}, c_{26}, c_{32}, c_{34}, c_{49}, c_{51}, c_{59}, c_{64}, c_{65}\}$ ;

2) 进一步求室颤心电图特征决策表的约简为  $red_{VF} = \{c_1, c_2, c_3, c_6, c_7, c_9, c_{10}, c_{11}, c_{12}, c_{13}, c_{16}, c_{17}, c_{19}, c_{20}, c_{22}, c_{23}, c_{25}, c_{26}, c_{32}, c_{34}, c_{49}, c_{51}, c_{52}, c_{54}, c_{59}, c_{64}, c_{65}\}$ ，删除表 2 中的 37 个冗余属性，保留 28 个条件属性，从而降低了除颤结果预测过程中特征提取的计算量，提升了数据集的质量。

属性约简前后室颤心电图特征决策表的属性变化情况如表 3 所示。

表 3 属性约简前后室颤心电图特征决策表的属性变化情况

属性数	原决策表	约简后决策表
决策属性数	1	1
条件属性数	65	28
删除冗余属性数	—	37

### 3.2 评价指标

本文采用 AUC、敏感度 (sensitivity, Sen)、特异性 (specificity, Spec) 和准确率 (accuracy, ACC) 作为除颤结果预测性能的评价指标，计算公式分别为

$$S_{Sen} = \frac{TP}{TP + FN} \quad (8)$$

$$S_{Spec} = \frac{TN}{FP + TN} \quad (9)$$

$$R_{Acc} = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

式中:  $TP$ 、 $TN$ 、 $FP$ 、 $FN$  分别为真阳性、真阴性、假阳性、假阴性，其中阳性代表除颤成功，阴性代表除颤失败。

### 3.3 实验结果分析

RBF 神经网络模型隐藏层节点数为 10，采用 Adam 优化器更新参数，损失函数为二分类交叉熵函数，激活函数为高斯函数，初始化学习率为 0.005，训练 600 个 epoch，批量大小为 32。

为验证本文算法的性能，将其与 AMSA (准确预测除颤结果的标准方法)、PAREA (单一特征)、SVM<sup>[9]</sup> (10 个心电图特征和 3 个患者变量)、随机森林<sup>[14]</sup> (15 个心电图特征)、约简前 RBF 神经网络模型 (15 个心电图特征) 进行对比实验。实验采用十折交叉验证方法，结果如表 4 所示。

表 4 6 种算法除颤结果预测性能指标对比

算法	AUC	Sen/%	Spec/%	ACC/%
AMSA	0.727	73.68	67.01	68.13
PAREA	0.764	71.93	71.65	71.71
SVM	0.770	—	—	—
随机森林	0.828	<b>90.30</b>	75.40	82.80
约简前 RBF 神经网络模型	0.825	86.89	78.18	82.76
本文算法	<b>0.853</b>	86.89	<b>83.64</b>	<b>85.34</b>

由表 4 可知: 利用约简后的室颤心电图特征数据集训练的 RBF 神经网络模型，相比 AMSA、PAREA、SVM、约简前 RBF 神经网络模型，各项性能指标均更高; 相比随机森林<sup>[14]</sup>，尽管敏感度稍低，但其余性能指标均更高，表明采用约简后的室颤心电图特征数据集训练的 RBF 神经网络模型的除颤结果预测性能更好。

约简前后 RBF 神经网络模型的占用空间和预测速度对比如表 5 所示。其中，预测速度单位 obj/s 是

指该神经网络模型在十次交叉验证过程中,每秒可以预测的平均样本数。

表 5 约简前后 RBF 神经网络模型占用空间及预测速度

网络模型	占用空间/kB	预测速度/(obj/s)
约简前 RBF 神经网络	24	4 739
约简后 RBF 神经网络	14	7 305

由表 5 可知,采用约简后的室颤心电图特征数据集进行除颤结果预测,RBF 神经网络模型的占用空间减少了 41.7%,同时预测速度提高了 54.1%。

## 4 结论

为了提高除颤结果的预测准确率,本文提出了一种粗糙集与 RBF 神经网络融合的除颤结果预测算法。首先,利用基于属性重要度的约简算法对室颤心电图特征数据集进行约简,去除冗余属性,提高数据集质量;最后,通过对比实验,验证了该算法具有更好的预测性能,且占用空间更小,预测速度更快。未来需要在临床环境中进行前瞻性评估,以确定该算法是否可以提高患者存活率。

©The author(s) 2024. This is an open access article under the CC BY-NC-ND 4.0 License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>)

## 参考文献

- [1] 杨凡,马青变.2020 年心肺复苏领域研究进展[J].中国急救医学,2021,41(7):593-595.
- [2] STERNBACH G L, VARON J, FROMM R E. The resuscitation greets. Claude Beck and ventricular defibrillation[J]. Resuscitation, 2000,44(1):3-5.
- [3] WHITE R D, ASPLIN B R, BUGLIOSI T F, et al. High discharge survival rate after out-of-hospital ventricular fibrillation with rapid defibrillation by police and paramedics[J]. Annals of Emergency Medicine, 1996,28(5):480-485.
- [4] CAPUCCI A, ASCHIERI D, PIEPOLI M F, et al. Tripling survival from sudden cardiac arrest via early defibrillation

## 作者简介:

陈其琛,男,1997 年生,硕士研究生,主要研究方向:模式识别、机器学习、生物信号处理。E-mail: 709332530@qq.com  
杨其宇,男,1977 年生,博士研究生,副教授,主要研究方向:生物信号处理。E-mail: yangqiyu@gdut.edu.cn

without traditional education in cardiopulmonary resuscitation [J]. Circulation, 2002,106(9):1065-1070.

- [5] JOHNSON B A, WEIL M H, TANG W, et al. Mechanisms of myocardial hypercarbic acidosis during cardiac arrest[J]. Journal of Applied Physiology, 1995,78(4):1579-1584.
- [6] LINK M S, ATKINS D L, PASSMAN R S, et al. Part 6: electrical therapies: automated external defibrillators, defibrillation, cardioversion, and pacing: 2010 American Heart Association Guidelines for Cardiopulmonary Resuscitation and Emergency Cardiovascular Care[J]. Circulation, 2010, 122(18 Suppl 3): S706-19.
- [7] STROHMENGER H U. Predicting defibrillation success[J]. Current opinion in critical care, 2008,14(3):311-316.
- [8] FRIGERIO L, BALDI E, ARAMENDI E, et al. End-tidal carbon dioxide (ETCO<sub>2</sub>) and ventricular fibrillation amplitude spectral area (AMSA) for shock outcome prediction in out-of-hospital cardiac arrest. Are they two sides of the same coin?[J]. Resuscitation, 2021,160:142-149.
- [9] COULT J, REA T D, BLACKWOOD J, et al. A method to predict ventricular fibrillation shock outcome during chest compressions[J]. Computers in Biology and Medicine, 2021,129: 104136.
- [10] PAWLAK Z. Rough sets[J]. International Journal of Computer & Information Sciences, 1982,11:341-356.
- [11] FAYYAD U M, IRANI K B. On the handling of continuous-valued attributes in decision tree generation[J]. Machine Learning, 1992,8:87-102.
- [12] BENINI S, IVANOVIĆ M D, SAVARDI M, et al. Cardially-ECG waveform dataset for predicting defibrillation outcome in out-of-hospital cardiac arrested patients[J]. Mendeley Data, 2020.
- [13] SEM M, MASTRANGELO E, LIGHTFOOT D, et al. The ability of machine learning algorithms to predict defibrillation success during cardiac arrest: A systematic review[J]. Resuscitation, 2023:109755.
- [14] IVANOVIĆ M D, RING M, BARONIO F, et al. ECG derived feature combination versus single feature in predicting defibrillation success in out-of-hospital cardiac arrested patients [J]. Biomedical Physics & Engineering Express, 2018,5(1): 015012.