

控制与决策

Control and Decision

融合邻域粗糙集与SA的多模态三支决策模型及其在疾病诊断中的应用

王景瑞, 孙秉珍, 包强, 刘极倩, 楚晓丽

引用本文:

王景瑞, 孙秉珍, 包强, 等. 融合邻域粗糙集与SA的多模态三支决策模型及其在疾病诊断中的应用[J]. *控制与决策*, 2026, 41(3): 613–625.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0626>

您可能感兴趣的其他文章

Articles you may be interested in

[嵌入重采样技术的C4.5决策树集成分类算法的临床医学预测](#)

Clinical prediction of C4.5 decision tree classification algorithm with embedded resampling technique
控制与决策. 2021, 36(6): 1342–1350 <https://doi.org/10.13195/j.kzyjc.2019.1247>

[基于策略权重的模糊多属性决策方法](#)

Strategic weight manipulation in fuzzy multiple attribute decision making
控制与决策. 2021, 36(5): 1259–1267 <https://doi.org/10.13195/j.kzyjc.2019.0542>

[基于16方向24邻域改进蚁群算法的移动机器人路径规划](#)

Mobile robots path planning based on 16-directions 24-neighborhoods improved ant colony algorithm
控制与决策. 2021, 36(5): 1137–1146 <https://doi.org/10.13195/j.kzyjc.2019.0600>

[基于分解的多目标多因子进化算法](#)

A multiobjective multifactorial evolutionary algorithm based on decomposition
控制与决策. 2021, 36(3): 637–644 <https://doi.org/10.13195/j.kzyjc.2019.0525>

[基于TOPSIS方法改进的多属性决策模型:最小化偏好反转](#)

Modified MCDM model based on TOPSIS method: Minimizing preference reversal
控制与决策. 2021, 36(1): 216–225 <https://doi.org/10.13195/j.kzyjc.2019.0536>

融合邻域粗糙集与SA的多模态三支决策模型 及其在疾病诊断中的应用

王景瑞¹, 孙秉珍^{1†}, 包强¹, 刘极倩¹, 楚晓丽²

(1. 西安电子科技大学 经济与管理学院, 西安 710126; 2. 广州中医药大学
第二附属医院中医证候全国重点实验室/中医药大数据研究团队, 广州 510120)

摘要: 在医疗领域向数据驱动转型的进程中, 疾病诊断面临多模态数据融合与不确定决策的难题. 对此, 提出一种融合邻域粗糙集与模拟退火算法(SA)的自适应阈值优化多模态三支决策模型. 首先, 定义多模态混合决策信息系统, 结合模态感知的属性邻域划分实现多模态数据统一表征. 其次, 通过信息增益驱动的客观赋权方法刻画属性权重, 并结合跨模态加权融合机制构建多模态加权邻域决策粗糙集. 最后, 融合SA与多层感知机(MLP)构建自适应阈值优化两阶段序贯三支决策模型, 动态优化决策阈值, 解决单阶段决策中边界域样本滞留问题, 形成“数据积累 → 不确定性消解”的正向循环. 在真实临床数据上的实验结果表明, 所提出的模型能有效处理多模态医疗数据, 显著提升多模态疾病诊断中不确定性决策的准确性, 能够为医生提供数据驱动的辅助诊断依据.

关键词: 多模态; 邻域决策粗糙集; 模拟退火算法; 信息增益; 三支决策; 多层感知机

中图分类号: TP18 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0626

引用格式: 王景瑞, 孙秉珍, 包强, 等. 融合邻域粗糙集与SA的多模态三支决策模型及其在疾病诊断中的应用[J]. 控制与决策, 2026, 41(3): 613-625.

Multimodal three-way decision model fusing neighborhood rough set and SA and its application in disease diagnosis

WANG Jing-rui¹, SUN Bing-zhen^{1†}, BAO Qiang¹, LIU Ji-qian¹, CHU Xiao-li²

(1. School of Economics and Management, Xidian University, Xi'an 710126, China; 2. State Key Laboratory of Traditional Chinese Medicine Syndrome/Department of TCM Big Data Research, The Second Affiliated Hospital of Guangzhou University of Chinese Medicine, Guangzhou 510120, China)

Abstract: In the transformation toward data-driven healthcare, disease diagnosis faces challenges in multimodal data fusion and uncertain decision-making. To address this, this paper proposes an adaptive threshold-optimized multimodal three-way decision model integrating neighborhood rough sets with simulated annealing (SA). First, a multimodal hybrid decision information system is defined, achieving unified representation of multimodal data through modality-aware attribute neighborhood partitioning. Second, attribute weights are characterized using an information gain-driven objective weighting method, combined with a cross-modal weighted fusion mechanism to construct a multimodal weighted neighborhood decision rough set. Finally, integrating SA and multi-layer perceptron (MLP) constructs a two-stage sequential three-way decision model with adaptive threshold optimization that dynamically optimizes decision thresholds, solves the boundary domain sample retention issue in single-stage decision-making, and forms a positive cycle of ‘data accumulation → uncertainty resolution’. Experimental results on real clinical data show that the proposed model effectively handles multimodal medical data, significantly improves the accuracy of uncertain decisions in multimodal disease diagnosis, and provides data-driven auxiliary diagnostic support for physicians.

Keywords: multimodal; neighborhood decision rough set; simulated annealing; information gain; three-way decision; multi-layer perceptron

收稿日期: 2025-06-12; 录用日期: 2025-09-16.

基金项目: 陕西省杰出青年科学基金项目(2023-JC-JQ-11); 中央高校基本科研业务费专项资金项目(ZYTS25004); 国家自然科学基金项目(72071152, 72301082); 西安电子科技大学学科交叉拓展特支计划项目(TZJHS202505); 广东省中医院中医药科学技术研究专项资助项目(YN2022QN33); 广州市重点研发计划项目(202206010101); 广州中医药大学“筑峰造尖”行动计划专项项目(GZY2025GB1207); 中医证候全国重点实验室项目(QZ2023ZZ07).

责任编辑: 冯俊娥.

†通信作者. E-mail: bzsun@xidian.edu.cn.

0 引言

目前, 医疗领域正经历着从经验驱动型医学向数据驱动型精准医学的范式转型. 多模态数据 (包括医学影像 (MRI、CT)、临床实验室检测结果、电子健康记录、体征信息、生理信号监测等) 的深度融合与协同分析, 为疾病早期筛查、个性化诊疗和疗效评价开辟了全新路径. 但多模态医疗数据的异构性特征显著增加了其应用难度, 不同模态的数据具有差异化的数据结构与语义特征, 这使得传统模型难以实现跨模态特征对齐与知识迁移^[1]. 因此, 如何处理多模态数据中的异构性特征以及蕴含的不确定性信息, 是构建多模态疾病预测模型的关键.

粗糙集理论^[2]作为处理不确定信息的有力工具, 在处理模糊知识与不精确推理方面具有独特优势. 传统粗糙集理论主要适用于离散型数据, 为克服这一局限, 学者们提出了多种改进的粗糙集模型, 如邻域粗糙集^[3]、复合粗糙集^[4]、基于核的粗糙集^[5]以及多粒度粗糙集^[6]. 目前, 粗糙集理论已被广泛应用于医疗领域^[7-9]. 然而, 在疾病诊断实践中, 真实的临床场景往往需要处理多模态与高维度的临床数据, 这使得经典粗糙集模型及其扩展难以适应从复杂数据空间评估决策对象的实际需求. 针对此类复杂数据的处理瓶颈, Hu 等^[10]提出邻域粗糙集对于处理多属性异构数据具有重要作用, 其邻域划分机制可有效适配不同类型数据的特征差异, 为解决上述问题提供了关键技术思路. 在此基础上, 一些学者围绕邻域粗糙集在处理复杂数据上的应用展开研究. 张腾飞等^[11]在经典邻域粗糙集的基础上, 提出一种改进的邻域空间构造方法, 用于高维混合数据的特征选取; Chu 等^[12]针对痛风相关的异构数据, 构建了基于邻域粗糙集的三向聚类模型, 对潜在的痛风患者进行分类与识别; Zhao 等^[13]针对多模态医疗数据, 构建了多粒度邻域粗糙集模型来进行属性约简, 但是该研究覆盖的数据场景主要集中在结构化或半结构化数据, 尚未涉及医学影像的特征处理. 冀俊忠等^[8]针对脑功能连接数据连续性和高噪声的特点, 提出基于邻域决策粗糙集的方法, 用于处理从功能磁共振成像 (fMRI) 中提取的脑功能链接特征, 该研究证实了邻域粗糙集在处理医学影像特征数据中的有效性, 但仍局限于单一模态的数据处理, 未涉及与其他模态数据的融合建模. 基于上述分析, 本研究结合神经网络模型定义了包含图片模态的多模态混合属性信息系统, 并通过模态感知的属性邻域划分机制, 构建了多模态场景下邻域粗糙集模型.

多模态邻域粗糙集模型解决了疾病诊断中异构数据的协同表征问题, 但多模态属性对决策对象的贡献度存在显著差异. 若采用均等权重, 可能导致关键特征被噪声淹没, 或次要属性干扰决策可靠性. 数据驱动的权重计算方法为应对这一问题提供了解决路径. 近年来, 该类方法被广泛应用于疾病诊断智能决策领域^[12-13]. 例如, 李志远等^[14]针对小样本医疗数据, 提出基于属性权重 Shapley 值分配的粗糙集决策模型, 通过“信息区分量”刻画属性对决策的影响程度. 在诸多数据驱动的赋权方法中, 信息增益作为一种重要的数据驱动赋权方法, 通过量化属性对分类结果不确定性的降低程度, 能够客观评估其决策价值^[15]. Cui 等^[16]提出模糊邻域决策树模型, 通过条件信息熵计算信息增益来筛选关键特征, 验证了信息增益在量化属性贡献度上的有效性. 基于此, 本文针对多模态数据场景下的贡献度分配问题, 引入信息增益思想, 合理分配属性贡献度, 并进一步结合跨模态融合机制构建多模态加权邻域决策粗糙集模型, 为后续的三支决策奠定了理论基础.

在解决了多模态数据的协同表征问题与贡献度分配问题后, 需要进一步处理疾病诊断中普遍存在的模糊状态问题. 在实际的临床疾病诊断中, 许多患者的症状和检测结果可能并不能明确地指向患病或未患病, 此时若按照传统的非黑即白的二支决策模型将对象划分为患病或未患病两类, 则很容易导致误判. 针对模糊状态问题, Yao^[17]提出了三支决策模型 (TWD), 用于解决决策过程中的不确定性. 三支决策模型引入了待观察区域来处理不确定状态, 可以在信息不足或不准确的情况下有效降低决策风险. 三支决策中的核心思想是使三区域划分后引起的损失最小, 降低错误分类成本^[18]. 目前, 学者们围绕三支决策的决策阈值和损失函数等方面展开研究. Liu 等^[19]提出了一种结合逻辑回归来计算阈值和条件概率值的方法; Jia 等^[20]基于遗传算法以决策成本最小为目标优化阈值; 李兆彬等^[21]在粗糙 K -均值聚类中引入变异萤火虫算法, 实现了初始中心与决策阈值的动态优化; 李小南等^[22]提出了一种基于加权信息熵的直觉模糊三支决策模型, 通过构造相似度函数并最大化加权信息熵来确定决策阈值; Wang 等^[23]针对淋巴造影数据, 提出了一种基于容差优势关系的三支决策方法, 通过结合损失函数与收益函数构建净收益函数来优化决策阈值; Jia 等^[24]通过获取从评价值得出的相对损失函数, 提出了一种区间值直觉模糊三支决策 (IVIF3WD) 模型; Ye 等^[25]提出了一

种新的模糊度量来计算非加性条件概率; Zhang 等^[26]针对直觉模糊数据的犹豫性特征, 提出基于直觉模糊 β -覆盖的三支决策方法, 利用改进的理想正度从原始数据中计算出条件概率和损失函数. 尽管上述研究在三支决策理论方面取得了丰富成果, 但其阈值优化方法大多聚焦于单模态数据或采用基于主观因素的决策阈值调整方案, 在面对多模态临床决策场景时具有一定局限, 难以适应数据高维度、非线性耦合分布的特征, 误判风险较大. 此外, 传统三支决策通常为单阶段决策, 边界域样本可能因信息不足, 始终处于边界域, 无法得到精准分类. 考虑上述困境, 本研究通过多模态加权邻域决策粗糙集引入三支决策, 构建了自适应阈值优化的序贯三支决策框架.

针对上述在构建多模态疾病诊断模型中出现的融合、贡献度分配、阈值优化以及不确定决策等问题, 本文基于多粒度粗糙集中“分层融合”的思想, 提出了一种多模态数据下融合邻域粗糙集与 SA 算法的两阶段序贯三支决策模型. 本文首先通过构建多模态混合决策信息系统与模态感知的属性邻域划分机制, 实现复杂多模态异构数据的协同表征与语义对齐; 然后, 离散化处理属性邻域信息, 通过信息增益驱动的客观赋权机制分配属性权重; 之后结合基于杰卡德距离的跨模态加权融合机制构建多模态数据下的加权邻域决策粗糙集模型; 最后, 在多模态加权邻域决策粗糙集的基础上, 融合 SA 与多层感知机 (MLP) 构建自适应阈值优化两阶段序贯三支决策模型, 通过全局搜索, 动态调整决策阈值, 克服了传统阈值计算的主观性, 并解决了单阶段三支决策的样本滞留问题.

本文的结构如下: 第 1 节详细阐述本文所提出的多模态混合决策信息系统的定义, 以及在其基础上构建的加权邻域决策粗糙集; 第 2 节介绍在多模态加权邻域决策粗糙集上构建的融合 SA 与 MLP 的自适应阈值优化两阶段序贯三支决策模型; 第 3 节从实际的医学决策问题出发, 将模型应用于真实的类风湿性关节炎临床样本, 验证其有效性; 第 4 节提供总体结论.

1 基于多模态信息的加权邻域决策粗糙集

在真实的临床诊疗场景中, 多模态数据 (如医学影像、实验室指标、临床记录) 的深度融合是实现精准诊断的关键突破口. 然而, 这类数据的结构异构性与语义贡献度非均衡性构成了双重建模难题. 针对这些问题, 本文提出多模态混合决策信息系统 (MDIS), 通过多模态属性的差异化邻域度量、信息

增益驱动的客观赋权机制和加权邻域动态建模, 形成基于邻域决策粗糙集的多模态数据处理框架, 为后文构建自适应阈值优化的多模态两阶段序贯三支决策模型提供数据与理论基础.

1.1 多模态混合决策信息系统

在大数据时代的背景下, 一些学者在传统信息系统基础上提出混合型信息系统, 用以处理包含离散型属性与连续型属性的复杂信息^[27]. 然而, 当面对实际决策场景中日益复杂的数据类型时, 混合型信息系统无法有效处理激增的多模态数据. 考虑到这一困境, 本文在混合型信息系统的基础上, 构建了图片特征向量型属性、连续型属性、离散类别型属性并存的多模态决策混合信息系统.

定义 1 MDIS = $(U, C^r, C^c, C^{im}, D, f^D)$ 表示多模态混合决策信息系统. $U = \{x_1, x_2, \dots, x_n\}$ 是 MDIS 的对象集合; $\{C^r, C^c, C^{im}\}$ 是多模态条件属性集, C^r, C^c, C^{im} 分别表示连续型属性集、离散类别型属性集、图片特征向量型属性集; D 是决策属性, $D = \{d_0, d_1\}$; $f^D: U \rightarrow D$ 表示对象与决策属性之间的映射关系. $U/D = \{D_0, D_1\}$, $D_j = \{u | f^D(u, D) = d_j, j = 0, 1\}$.

定义 2 针对图片模态数据, 目前已有学者采用 VGG 模型进行医学图像的特征提取^[28]. 但是传统卷积网络在深层网络中易出现梯度消失问题, 导致特征提取能力随网络深度增加而退化. 考虑到这一问题, 在 MDIS 中, 本文利用预训练的 ResNet50 模型进行特征提取. ResNet50 模型是一种深度卷积神经网络, 具有强大的图像特征提取能力. 医学影像 (如 RA 的关节彩超) 的关键诊断特征 (骨侵蚀) 往往隐藏在低对比度区域, 需要深层网络捕捉细微差异. ResNet50 的残差块 (Residual Block) 通过“跳跃连接”缓解梯度消失, 确保深层网络仍能有效学习这类弱特征. 通过 ResNet50 模型中的卷积层与池化层等组件, 本文将得到的高维向量作为图像的特征表示, 这些特征包含了图像中病变的位置、形状等重要信息. 当 $a_h \in C^{im}$ 时, 图片模态数据的特征提取定义为

$$a_h(x) = \text{ResNet50}(I_x) \in R^{2048}. \quad (1)$$

表 1 展示了一个多模态混合决策信息系统. 其中: $U = \{x_1, x_2, x_3, x_4, x_5\}$ 表示 5 位病人, C^r 表示连续型数值数据 (年龄、CRP、ESR 等), C^c 表示离散型类别数据 (关节部位、粗糙程度等), C^{im} 表示图片型特征 (图片特征向量). 通过构建多模态混合属性信息系统, 将不同模态的数据整合在统一的框架内,

为后续的距离度量、属性权重计算以及决策提供数据基础。

表1 多模态混合决策信息系统

U	C^r			C^c				C^{im}	D
	a_1	\dots	a_{10}	a_{10}	a_{11}	\dots	a_{21}	a_{22}	
x_1	0.18	\dots	0.07	12	0	\dots	1	[0.036, 0.015, \dots , 0.287]	1
x_2	0.48	\dots	0.24	11	1	\dots	0	[0.325, 0.387, \dots , 0.056]	1
x_3	0.46	\dots	0.22	43	1	\dots	1	[0.049, 0.004, \dots , 0.163]	1
x_4	0.49	\dots	0.10	17	1	\dots	0	[0.016, 0.826, \dots , 0.436]	0
x_5	0.20	\dots	0.01	18	0	\dots	0	[0.432, 0.302, \dots , 0.006]	0

1.2 加权邻域决策粗糙集

邻域粗糙集^[10]是一种能够有效处理连续型和离散型混合数据的方法,它通过定义邻域关系来扩展传统粗糙集的等价类概念,从而更好地适应实际数据的复杂性.然而,当面对多模态数据,如医学领域中融合了医学影像、实验室指标与临床记录的综合数据集时,现有的基于混合型信息系统的邻域粗糙集难以有效处理多模态数据并捕捉各模态特征所蕴含的不确定性.针对此问题,本文在多模态混合信息系统的基础上对邻域粗糙集进行改良,构建了能够同时融合数值、类别与图片的多模态邻域决策粗糙集.该方法通过属性邻域的模态感知划分、信息增益驱动的贡献度分配和基于杰卡德距离的跨模态加权融合机制,实现了多模态数据的深度融合,为后续自适应阈值优化两阶段序贯三支决策模型的构建提供了数据基础.具体构建过程如下所述.

1.2.1 属性邻域

邻域的精准划分是邻域粗糙集模型捕捉对象相似性的基础.多模态数据中不同模态属性的数据结构、物理意义和不确定性特征存在本质差异,传统的统一邻域划分方法会导致语义混淆与特征扭曲,因此本文采用模态感知的差异化属性邻域划分策略,使每个属性的邻域既能保留自身数据特性,又能为跨模态融合提供标准化接口.

定义3 $MDIS = (U, C^r, C^c, C^{im}, D, f^D)$ 表示多模态混合决策信息系统, $U = \{x_1, x_2, \dots, x_n\}$ 是MDIS的对象集合, $\{C^r, C^c, C^{im}\}$ 是多模态条件属性集. C^r 表示连续型数值数据,对于 $\forall a_h \in C^r$,连续型数据的距离度量方式定义为

$$\text{dis}_h(x_i, x_j) = (|a_h(x_i) - a_h(x_j)|^2)^{1/2}, \quad (2)$$

其中 $a_h(x_i)$ 表示决策对象 x_i 在 C^r 属性集合中 a_h 属性上的数值.

定义4 针对离散类别型属性,本研究采用基于汉明距离的度量方法.对于 $\forall a_h \in C^c$,类别型数据的

距离度量方式定义为

$$\text{dis}_h(x_i, x_j) = \begin{cases} 0, & |a_h(x_i) - a_h(x_j)| = 0; \\ 1, & |a_h(x_i) - a_h(x_j)| \neq 0. \end{cases} \quad (3)$$

定义5 在特征提取后图片数据转化为特征向量.针对图片特征向量,本研究采用基于余弦相似度的度量方法.对于 $\forall a_h \in C^{im}$,该属性下的差异度量方法定义为

$$\text{dis}_h(x_i, x_j) = 1 - \left| \frac{a_h(x_i) \cdot a_h(x_j)}{\|a_h(x_i)\| \times \|a_h(x_j)\|} \right|. \quad (4)$$

完成多模态混合属性的差异化距离度量方法定义后,本文引入邻域关系,构建模态感知的多模态属性邻域划分机制.考虑到不同属性存在不同的数据分布与数据特征,采用固定邻域半径法可能会影响属性邻域信息的提取,本文针对多模态混合属性的属性邻域提出了数据驱动的邻域半径设定机制.

定义6 针对多模态属性, $a_h \in \{C^r, C^c, C^{im}\}$, $x_i \in U$, x_i 在属性 a_h 上的邻域定义为

$$\delta_{a_h}(x_i) = \{x_j \in U \mid \text{dis}_h(x_i, x_j) \leq \delta_h\}. \quad (5)$$

$$\delta_h = \begin{cases} \frac{\text{std}(a_h)}{\sigma}, & a_h \in C^r \cup C^{im}; \\ 0, & a_h \in C^c. \end{cases} \quad (6)$$

其中: δ_h 表示邻域划分半径; σ 为属性邻域调节参数, $\sigma \in [\max(\text{std}(a_h) \mid a_h \in C^r \cup C^{im}), +\infty)$,用于控制属性 a_h 邻域粒度; $\text{dis}_h(x_i, x_j)$ 为距离度量方法,当属性 a_h 属于不同模态时,需要依据式(2)~(4)采取不同的距离度量方法.

1.2.2 贡献度分配

多模态数据以不同数据结构承载差异化的诊断信息,其对决策的贡献程度存在显著差异.若对多模态数据采用等权重或主观赋权方式,则容易导致关键信息稀释或噪声干扰.为此,本文在第1.2.1节的基础上,引入信息增益理论,通过离散化属性邻域来量化属性对决策不确定性的降低能力,从而构建数据驱动的客观赋权机制.信息增益是信息论与机器学习中的核心概念,主要用于衡量特征对分类任务的贡献程度,是特征选择的重要指标^[15].

定理1 $MDIS = (U, C^r, C^c, C^{im}, D, f^D)$ 表示多模态混合决策信息系统. $U = \{x_1, x_2, \dots, x_n\}$ 是MDIS的对象集合; D 是决策属性, $D = \{d_0, d_1\}$.则决策属性的信息熵计算公式为

$$H(D) = - \sum_{i=0}^1 P_D(d_i) \log_2 P_D(d_i). \quad (7)$$

其中: $P_D(d_0)$ 表示决策属性为 d_0 的概率, $P_D(d_1)$ 表示决策属性为 d_1 的概率.

定义 7 $MDIS = (U, C^r, C^c, C^{im}, D, f^D)$ 表示多模态混合决策信息系统, $N_{a_i} = \{\delta_{a_i}^1, \delta_{a_i}^2, \dots, \delta_{a_i}^{e_i}\}$ 表示属性 a_i 下的邻域类别集合, 其中 e_i 表示邻域类别的数量. 每个邻域类别 $\delta_{a_i}^j \in N_{a_i}$, 其对应的邻域所包含的对象数量为 $n_{a_i}^j$. 对于属性 $a_i \in \{C^r, C^c, C^{im}\}$, 其条件熵定义为

$$H(D|a_i) = \sum_{j=1}^{e_i} \frac{n_{a_i}^j}{|U|} H(D|\delta_{a_i}^j), \quad (8)$$

$$H(D|\delta_{a_i}^j) = - \sum_{l=0}^1 P_A(d_l|\delta_{a_i}^j) \log_2 P_A(d_l|\delta_{a_i}^j), \quad (9)$$

其中 $P_A(d_l|\delta_{a_i}^j)$ 表示邻域类别 $\delta_{a_i}^j$ 中决策属性为 d_l 的概率.

定义 8 完成信息熵与条件熵的定义后, 对于属性 $a_i \in \{C^r, C^c, C^{im}\}$, $C = \{C^r \cup C^c \cup C^{im}\}$ 信息增益的计算公式为

$$IG(a_i) = H(D) - H(D|a_i). \quad (10)$$

接下来, 结合信息增益计算公式, 提出属性 a_i 的归一化权重计算公式:

$$w_i = \frac{IG(a_i)}{\sum_{a_i \in C} IG(a_i)}. \quad (11)$$

1.2.3 跨模态加权邻域融合机制

在邻域决策粗糙集中, 决策对象的邻域划分是连接底层多模态异构信息协同表征与上层决策逻辑的关键环节. 因此, 在多模态邻域决策粗糙集的构建过程中, 决策对象的邻域划分需突破单一模态限制. 在第 1.2.1 节属性邻域与第 1.2.2 节贡献度分配中, 已实现邻域视角下的多模态信息协同表征与跨模态贡献度的量化. 在此基础上, 本文通过跨模态加权融合策略, 构建多模态加权邻域决策粗糙集.

定义 9 $MDIS = (U, C^r, C^c, C^{im}, D, f^D)$ 表示多模态混合决策信息系统, $U = \{x_1, x_2, \dots, x_n\}$ 是 MDIS 的对象集合; $C = \{C^r \cup C^c \cup C^{im}\}$, $a_i \in C$, $x, y \in U$. 本文以杰卡德 (Jaccard) 距离为基础, 结合属性邻域提出了跨模态加权距离度量方法, x 与 y 之间的多模态加权距离定义为

$$d_w(x, y) = \sum_{a_i \in C} w_i d_{a_i}(x, y) = \sum_{a_i \in C} w_i \left(1 - \frac{|\delta_{a_i}(x) \cap \delta_{a_i}(y)|}{|\delta_{a_i}(x) \cup \delta_{a_i}(y)|} \right), \quad (12)$$

其中 $|\cdot|$ 表示集合中的元素数量.

推论 1 $U = \{x_1, x_2, \dots, x_n\}$ 是 MDIS 的对象集合. $x, y \in U$, 定义 9 提出的 x 与 y 之间的加权距离

$d_w(x, y)$ 满足下列性质:

- 1) $d_w(x, y) \geq 0$;
- 2) $d_w(x, y) = d_w(y, x)$;
- 3) $d_w(x, y) \leq d_w(x, z) + d_w(z, y)$.

证明 $a_i \in \{C^r, C^c, C^{im}\}$, 根据定义 9, 属性 a_i 下的对象 x 与 y 之间的距离计算公式均符合杰卡德距离的定义, 因此, 对象 x 与 y 之间的多模态加权距离 $d_w(x, y)$ 显然满足推论 1 提出的性质. \square

例 1 $MDIS = (U, C^r, C^c, C^{im}, D, f^D)$ 表示多模态混合决策信息系统. 假设 $U = \{x_1, x_2, \dots, x_5\}$, 每个模态包含 1 个属性, 分别是连续型属性 a_1 、离散型属性 a_2 、图片特征向量属性 a_3 . 属性权重分别为 $w_1 = 0.4, w_2 = 0.3, w_3 = 0.3$. 设定决策对象 x_1, x_2 在不同属性下的属性邻域分别为

$$\begin{aligned} \delta_{a_1}(x_1) &= \{x_1, x_2, x_4\}, \quad \delta_{a_1}(x_2) = \{x_1, x_2, x_3\}, \\ \delta_{a_2}(x_1) &= \{x_1, x_3\}, \quad \delta_{a_2}(x_2) = \{x_2, x_3\}, \\ \delta_{a_3}(x_1) &= \{x_1, x_3, x_4\}, \quad \delta_{a_3}(x_2) = \{x_2, x_3, x_5\}. \end{aligned}$$

由属性邻域信息易得决策对象 x_1, x_2 在不同属性下的距离为 $d_{a_1}(x_1, x_2) = 0.5, d_{a_2}(x_1, x_2) = 0.667, d_{a_3}(x_1, x_2) = 0.8$. 根据定义 9, 结合属性权重, 决策对象 x_1, x_2 的多模态加权距离为

$$\begin{aligned} d_w(x_1, x_2) &= \\ &0.4 \times d_{a_1}(x_1, x_2) + 0.3 \times d_{a_2}(x_1, x_2) + \\ &0.3 \times d_{a_3}(x_1, x_2) = 0.64. \end{aligned}$$

定义 10 $D_{x_i}^{\text{sorted}}$ 表示所有样本的集合, 该集合中所有样本按照与对象 x_i 之间的多模态加权距离进行升序排序. 从 $D_{x_i}^{\text{sorted}}$ 中选取前 k 个样本构建新的集合 $D_{x_i}^{\text{sorted}}(k)$, 该集合构成了对象 x_i 的邻域 $\delta_k(x_i)$ 为

$$\delta_k(x_i) = \{x | x \in D_{x_i}^{\text{sorted}}(k)\}. \quad (13)$$

定义 11 $P(D_j|\delta_k(x_i)) = \frac{|\delta_k(x_i) \cap D_j|}{|\delta_k(x_i)|}$ 表示对象 x_i 属于 D_j 的条件概率, D_j 表示决策属性为 d_j 的样本集合. 给定阈值 (α, β) , 则 $\delta_k(x)$ 的上下近似集为

$$\begin{cases} \underline{N}_k(D_j) = \{x_i | P(D_j|\delta_k(x_i)) \geq \alpha\}, \\ \bar{N}_k(D_j) = \{x_i | P(D_j|\delta_k(x_i)) \geq \beta\}. \end{cases} \quad (14)$$

结合上下近似集, 可以得到正域、负域以及边界的表示:

$$\begin{aligned} \text{POS}(D_j) &= \underline{N}_k(D_j), \\ \text{NEG}(D_j) &= U - \bar{N}_k(D_j), \\ \text{BND}(D_j) &= \bar{N}_k(D_j) - \underline{N}_k(D_j). \end{aligned}$$

2 多模态信息系统上自适应阈值优化的两阶段序贯三支决策模型

在实际的医疗决策场景中, 经常会遇到样本影像学特征不典型、实验室指标临界等处于“不确定

状态”的问题,在面临这类信息不足的决策问题时,传统二支决策模型(如支持向量机)采用非黑即白的分类方式,会引发更高的误诊风险,给患者带来极大损失.三支决策理论通过“正域、负域、边界域”三域划分,引入延迟决策(边界域),有助于降低误判成本.目前,三支决策理论已被广泛应用于疾病诊断领域^[8-9, 12-13].本节在所提出的多模态加权邻域决策粗糙集的基础上引入三支决策思想,融合SA算法与MLP构建了自适应阈值优化的两阶段序贯三支决策模型.

2.1 基于SA的阈值优化机制

在三支决策中,决策阈值 α (接受阈值)与 β (拒绝阈值)的设定直接影响分类的精确性与可靠性.现有的研究中,决策阈值计算方案多聚焦于单模态数据空间或依赖于基于主观因素的决策阈值调整方案(如专家经验、决策偏好).在面对多模态疾病诊断的复杂场景时,这类方法往往难以适应多模态医疗数据的异质性、动态分布与非线性特征.基于此,本文提出一种数据驱动的自适应阈值优化方案.该方案以均方误差(MSE)损失函数为基础,构建了融合决策错误损失与延迟决策损失的多模态加权邻域决策粗糙集损失函数,并引入模拟退火(SA)算法,以该损失函数作为优化目标,通过最小化目标函数实现阈值的迭代寻优.

定义 12 MDIS = $(U, C^r, C^c, C^{im}, D, f^D)$ 表示多模态混合决策信息系统, $U = \{x_1, x_2, \dots, x_n\}$ 是MDIS的对象集合; D 是决策属性, $D = \{d_0, d_1\}$.不同决策属性类型样本数量的指示函数可定义为

$$\delta_D(y_i, t) = \begin{cases} 1, & y_i = t; \\ 0, & y_i \neq t. \end{cases} \quad (15)$$

其中: $t \in \{0, 1\}$, y_i 表示对象 x_i 在决策属性 D 上的取值.

定义 13 $P(D_j | \delta_k(x_i))$ 表示样本 x_i 属于 D_j 的条件概率,其中 $\delta_k(x_i)$ 表示样本 x_i 的邻域.给定一对阈值 (α, β) ,通过阈值 α 和 β 进行三域划分的指示函数 $I_{\text{POS}}^{(\alpha, \beta)}(y_i)$ 、 $I_{\text{NEG}}^{(\alpha, \beta)}(y_i)$ 与 $I_{\text{BND}}^{(\alpha, \beta)}(y_i)$ 定义为

$$\begin{cases} I_{\text{POS}}^{(\alpha, \beta)}(y_i) = \begin{cases} 1, & P(D_1 | \delta_k(x_i)) \geq \alpha; \\ 0, & P(D_1 | \delta_k(x_i)) < \alpha. \end{cases} \\ I_{\text{NEG}}^{(\alpha, \beta)}(y_i) = \begin{cases} 1, & P(D_1 | \delta_k(x_i)) \leq \beta; \\ 0, & P(D_1 | \delta_k(x_i)) > \beta. \end{cases} \\ I_{\text{BND}}^{(\alpha, \beta)}(y_i) = \begin{cases} 1, & \beta < P(D_1 | \delta_k(x_i)) < \alpha; \\ 0, & \text{otherwise.} \end{cases} \end{cases} \quad (16)$$

定义 14 MDIS = $(U, C^r, C^c, C^{im}, D, f^D)$ 表示多模态混合决策信息系统, \hat{y}_i 表示预测结果.将对

象划分入正域的损失函数 L_{PP} 、 L_{PN} 定义为

$$\begin{cases} L_{\text{PP}}^{(\alpha, \beta)} = \frac{\sum_{i=1}^{|U|} \delta_D(y_i, 1) \cdot I_{\text{POS}}(y_i) \cdot (y_i - \hat{y}_i)^2}{|U|}, \\ L_{\text{PN}}^{(\alpha, \beta)} = \frac{\sum_{i=1}^{|U|} \delta_D(y_i, 0) \cdot I_{\text{POS}}(y_i) \cdot (y_i - \hat{y}_i)^2}{|U|}. \end{cases} \quad (17)$$

将对对象划分如边界域的损失函数 L_{BP} 、 L_{BN} 定义为

$$\begin{cases} L_{\text{BP}}^{(\alpha, \beta)} = \frac{\sum_{i=1}^{|U|} \delta_D(y_i, 1) \cdot I_{\text{BND}}(y_i) \cdot (y_i - \hat{y}_i)^2}{|U|}, \\ L_{\text{BN}}^{(\alpha, \beta)} = \frac{\sum_{i=1}^{|U|} \delta_D(y_i, 0) \cdot I_{\text{BND}}(y_i) \cdot (y_i - \hat{y}_i)^2}{|U|}. \end{cases} \quad (18)$$

将对对象划分入负域的损失函数 L_{NP} 、 L_{NN} 定义为

$$\begin{cases} L_{\text{NP}}^{(\alpha, \beta)} = \frac{\sum_{i=1}^{|U|} \delta_D(y_i, 1) \cdot I_{\text{NEG}}(y_i) \cdot (y_i - \hat{y}_i)^2}{|U|}, \\ L_{\text{NN}}^{(\alpha, \beta)} = \frac{\sum_{i=1}^{|U|} \delta_D(y_i, 0) \cdot I_{\text{NEG}}(y_i) \cdot (y_i - \hat{y}_i)^2}{|U|}. \end{cases} \quad (19)$$

结合定义 14, 三支决策模型的损失函数为

$$\text{MSE}(\alpha, \beta) = L_{\text{PP}}^{(\alpha, \beta)} + L_{\text{PN}}^{(\alpha, \beta)} + L_{\text{BP}}^{(\alpha, \beta)} + L_{\text{BN}}^{(\alpha, \beta)} + L_{\text{NP}}^{(\alpha, \beta)} + L_{\text{NN}}^{(\alpha, \beta)}. \quad (20)$$

完成三支决策框架下的损失函数定义后,本研究引入SA算法,将式(20)作为目标函数,通过全局搜索动态调整 α 和 β ,以实现分类损失函数的最小化,进而获取最优的决策阈值.模拟退火算法的邻域解生成策略为

$$\begin{cases} \alpha'_s = \text{Min}(1, \alpha_s + \Delta\alpha_s), \\ \beta'_s = \text{Max}(0, \beta_s + \Delta\beta_s), \end{cases} \quad (21)$$

其中 $\Delta\alpha_s, \Delta\beta_s \sim N(0, 0.05)$.为确保 $\alpha'_s \geq \beta'_s$,采用投影修正,即

$$\begin{cases} \alpha'_s = \text{Max}(\alpha'_s, \beta'_s + \epsilon), \\ \beta'_s = \text{Min}(\beta'_s, \alpha'_s - \epsilon), \end{cases} \quad (22)$$

其中 $\epsilon = 10^{-3}$ 为最小间隔阈值,用于避免 α 与 β 过于接近.

给定模拟退火算法的初始温度 $T_0 = 1000$,终止温度 $T_{\text{end}} = 10^{-5}$,温度衰减率 $\gamma = 0.99$,初始解 (α_0, β_0) 为 $(1, 0)$,最优阈值为 (α^*, β^*) (初始最优阈值为 $\alpha^* = \alpha_0, \beta^* = \beta_0$).

根据当前阈值 $[\alpha_s, \beta_s]$, 进行三域划分, 并计算此时的 $MSE(\alpha_s, \beta_s)$. 之后生成邻域解 (α'_s, β'_s) , 计算邻域解的 $MSE'(\alpha'_s, \beta'_s)$, 并根据 Metropolis 准则决定是否接受新解.

1) 若 $MSE'(\alpha'_s, \beta'_s) \leq MSE(\alpha_s, \beta_s)$, 则无条件接受新解, $(\alpha_{s+1}, \beta_{s+1}) = (\alpha'_s, \beta'_s)$.

2) 若 $MSE'(\alpha'_s, \beta'_s) \leq MSE(\alpha^*, \beta^*)$, 则更新最优阈值, $(\alpha^*, \beta^*) = (\alpha'_s, \beta'_s)$.

3) 若 $MSE'(\alpha'_s, \beta'_s) > MSE(\alpha_s, \beta_s)$, 则以概率 $P = \exp\left(-\frac{MSE'(\alpha'_s, \beta'_s) - MSE(\alpha_s, \beta_s)}{T_s}\right)$ 接受劣解, 更新阈值 $(\alpha_{s+1}, \beta_{s+1}) = (\alpha'_s, \beta'_s)$; 若不接受劣解, 则 $(\alpha_{s+1}, \beta_{s+1}) = (\alpha_s, \beta_s)$.

每完成一次迭代后, 按指数策略更新温度:

$$T_{s+1} = \gamma \cdot T_s. \quad (23)$$

$s = s + 1$, 当 $T_s < T_{end}$ 时终止优化算法, 输出最优阈值 (α^*, β^*) , 至此实现模型的决策阈值优化.

2.2 两阶段序贯三支决策

三支决策模型引入了延迟决策的理念, 是在信息不足或不准确的情况下有效降低决策风险的方法. 但是, 由于引入了延迟决策, 传统的三支决策模型在处理多模态医疗数据时, 可能会导致部分对象始终处于边界域 (BND) 而无法获得最终分类标签. 为解决这一问题, Qin 等^[29] 提出了多阶段三支迭代分类模型. 基于此, 本文结合第 2.1 节提出的基于 SA 的阈值优化机制与多层感知机 (MLP), 建立了基于多模态加权邻域决策粗糙集的自适应阈值优化两阶段序贯三支决策模型. 模型的两阶段序贯三支决策框架流程如图 1 所示.

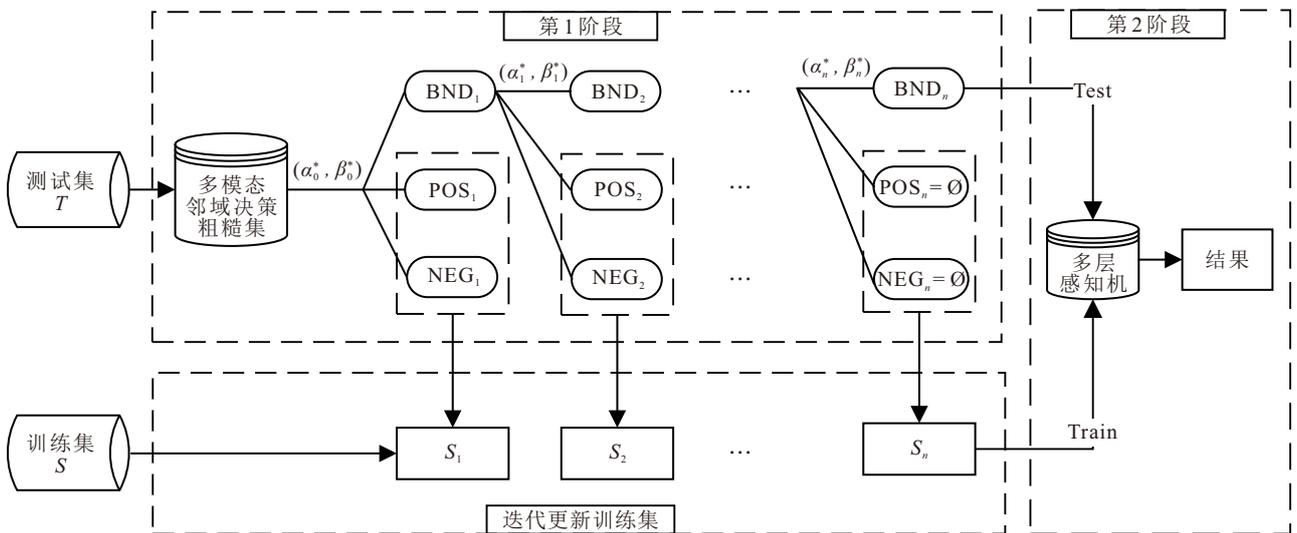


图1 两阶段序贯三支决策模型流程

第 1 阶段, 数据划分为训练集 S 与测试集 T . 结合基于 SA 的阈值优化机制训练模型, 获取初始最优决策阈值 (α^*, β^*) . 根据初始最优阈值可以将测试集中的样本划入为 3 个集合: 正域 $POS(D)$ 、负域 $NEG(D)$ 和边界域 $BND(D)$. 为了进一步处理处于边界域的不确定样本, 将正域与负域样本并入训练集 S , 更新数据集以增强模型对确定性模式的学习能力, 剩余边界域样本作为下一轮迭代的测试集. 训练集与测试集的样本更新策略具体为

$$\begin{cases} S = S \cup POS(D) \cup NEG(D), \\ T = BND(D). \end{cases} \quad (24)$$

获取更新后的训练集 S 与测试集 T 之后, 结合基于 SA 的阈值优化机制, 重复上述阈值优化与样本划分过程, 每完成一次三支决策, 对训练集与测试集的样本进行更新, 直至测试集划分出的正域与负域均为

空集, 形成“数据积累-不确定性消解”的正向循环.

在第 2 阶段, 将第 1 阶段边界域中剩余的未分类样本作为测试集, 使用第 1 阶段迭代更新后的训练集中的数据对 MLP 进行训练. 之后应用基于 MLP 的分类模型对剩余边界域中的对象进行二分类, 从而获取到测试集的预测结果, 并以此对整个模型的性能进行评估.

2.3 基于 SA 的阈值优化算法

结合前文, 构建基于多模态加权邻域决策粗糙集的融合 SA 的自适应阈值优化算法, 具体算法步骤如下.

算法 1 基于 SA 的阈值优化算法.

输入: $MDIS = (U, C^r, C^c, C^{im}, D, f^D)$, 初始阈值 $(\alpha_0, \beta_0) = (1, 0)$, 初始温度 $T_0 = 1000$, 终止温度 $T_{end} = 10^{-5}$, 温度衰减参数 $\gamma = 0.99$, 属性邻域调节

参数 σ , 邻域划分参数 k , $s = 0$;

输出: 最优阈值 (α^*, β^*) , 属性权重 ω .

step 1: 根据式 (5) 和 (6) 计算属性邻域 $\delta_{a_n}(x)$;

step 2: 根据式 (7) ~ (11) 进行属性权重 ω 分配;

step 3: 根据式 (12) 和 (13) 计算对象邻域 $\delta_k(x)$;

step 4: 根据式 (20) 计算三支决策损失 $MSE(\alpha_s, \beta_s)$;

step 5: 根据式 (21) 和 (22) 生成邻域解 (α'_s, β'_s) , 并计算邻域解分类损失 $MSE'(\alpha'_s, \beta'_s)$;

step 6: 根据 Metropolis 准则更新阈值 (α^*, β^*) 与 $(\alpha_{s+1}, \beta_{s+1})$, 更新温度 $T_{s+1} = \gamma \cdot T_s$, $s = s + 1$;

step 7: 若 $T_s \geq T_{end}$, 则回到 step 4, 否则输出最优阈值 (α^*, β^*) 、属性权重 ω .

2.4 两阶段序贯三支决策算法

结合第 2.1 节和第 2.2 节, 构建自适应阈值优化两阶段序贯三支决策算法, 具体算法步骤如下.

算法 2 基于多模态加权邻域决策粗糙集的自适应阈值优化两阶段序贯三支决策算法.

输入: $MDIS = (U, C^r, C^c, C^{im}, D, f^D)$, 初始阈值 $(\alpha_0, \beta_0) = (1, 0)$, 初始温度 $T_0 = 1000$, 终止温度 $T_{end} = 10^{-5}$, 温度衰减参数 $\gamma = 0.99$, $POS(D) = \emptyset$, $NEG(D) = \emptyset$, 属性邻域调节参数 σ 与邻域划分参数 k ;

输出: $POS(D)$, $NEG(D)$.

step 1: 划分训练集 S 与测试集 T , $n = 0$, $BND_0(D) = T$, $POS_0(D) = NEG_0(D) = \emptyset$;

step 2: 调用算法 1 使用训练集 S 进行训练, 获取最优决策阈值 (α_n^*, β_n^*) 与属性权重 ω ;

step 3: 依据最优决策阈值 (α_n^*, β_n^*) 与属性权重 ω 对 $BND_n(D)$ 进行三支决策, 获得 $POS_{n+1}(D)$ 、 $NEG_{n+1}(D)$ 与 $BND_{n+1}(D)$;

step 4: 更新 $POS(D) = POS(D) \cup POS_{n+1}(D)$, $NEG(D) = NEG(D) \cup NEG_{n+1}(D)$, 并生成新的训练集 $S = S \cup POS(D)_{n+1} \cup NEG(D)_{n+1}$;

step 5: 令 $n = n + 1$, 若 $BND_n(D) = \emptyset$ 或 $BND_n(D) = BND_{n-1}(D)$, 则终止第 1 阶段, 继续第 2 阶段 step 6, 否则回到 step 2;

step 6: 使用训练集 S 训练多层感知机模型, 并对 $BND_n(D)$ 进行二支决策, 将剩余边界域样本的分类结果更新至 $POS(D)$ 、 $NEG(D)$;

step 7: 输出 $POS(D)$ 、 $NEG(D)$.

3 类风湿性关节炎实例分析

本节使用多模态混合决策信息系统来处理真实的类风湿性关节炎诊断数据, 并将构建的自适应阈

值优化两阶段序贯三支决策模型应用于类风湿性关节炎的辅助诊断中. 通过实验, 系统评估模型在类风湿性关节炎辅助诊断中的有效性与稳健性.

3.1 问题描述

类风湿性关节炎 (RA) 是一种常见的自身免疫性疾病. 然而, 其诊断过程面临诸多挑战, 如症状的多样性和复杂性、相关指标的不确定性等. 在 RA 的初期, 症状往往极为轻微且不典型, 易与其他关节疾病或身体不适相混淆. 目前还没有单一的实验室检测可以直接诊断类风湿性关节炎, 甚至一部分患者的部分检查结果表现为“血清阴性”或早期影像学改变不典型, 形成疾病诊断中的不确定样本. 而传统二支决策模型在面对此类样本时, 其强制分类的机制易导致误诊 (如将早期 RA 误判为骨关节炎). 而且, 不同 RA 患者的症状表现存在较大个体差异, 有的患者可能主要以小关节 (如手指、脚趾关节) 受累为主, 而有的患者则可能累及大关节 (如膝关节、肘关节). 此外, RA 还可能伴随全身症状, 如发热、乏力、体重下降等, 这些全身性症状进一步增加了诊断的复杂性, 使得难以仅依据单一症状表现就准确判断是否为 RA. 2024 年中国类风湿性关节炎诊疗指南指出, RA 的诊断需综合考虑患者的临床表现、实验室检查以及影像学检查结果^[30].

基于上述分析, RA 的诊断可以抽象为一个多模态异构信息下的复杂不确定决策问题. 针对 RA 诊断中存在的多模态临床信息, 本研究提出基于多模态混合信息系统的加权邻域决策粗糙集, 实现多模态医疗数据的表征统一与信息融合. 考虑到部分 RA 患者症状不典型易导致误判, 本研究进一步引入序贯三支决策, 构建基于 SA 的自适应阈值优化两阶段序贯三支决策模型, 通过“边界域延迟决策”机制应对不确定样本, 同时结合 SA 算法动态优化决策阈值, 从而实现对 RA 诊断中不确定性的科学建模与精准决策, 为患者提供初步的智能诊断结果以辅助医生决策.

3.2 数据描述

本研究的实验数据源自某三甲医院类风湿性关节炎 (RA) 的诊疗数据库, 共包含 1089 例临床样本. 患者年龄分布跨越 18 岁至 89 岁年龄段, 覆盖青年、中年及老年群体. 实验数据包括关节彩超图像、实验室检测结果以及体征信息, 具体描述如表 2 所示. 针对连续型数据, 本文采用 Min-Max 进行标准化预处理, 通过该处理实现特征尺度统一, 消除量纲影响. 对于离散类别型数据, 本文使用标签编码法进行处

表2 数据描述

属性集	数据类型	属性集合
C^r	连续型数据	年龄
		CRP
		ESR
		RF
		CR
		AST
		ALT
		积液深度
		滑膜增厚
		C^c
关节疼痛		
关节肿胀		
滑膜血流		
外表显示		
光滑		
连续		
不规则		
粗糙		
流血信号		
C^{im}	图片数据	破坏
		间隙变窄
		彩超

理. 针对 RA 的关节彩超影像数据, 本文通过预训练的 ResNet50 深度卷积神经网络模型将彩超影像数据转化为蕴含病变位置、形状等高层语义信息高维特征向量.

3.3 结果分析

样本数据以 7 : 3 的比例分为训练集 S 和测试集 T . 针对属性邻域调节参数 σ , 本研究参考了类风湿性关节炎临床数据的统计特征, 类风湿性关节炎数据中连续型数据属性与图片模态属性的标准差均小于 0.3. 结合式 (6), 易知 σ 取值需大于 0.3. 同时考虑到, 若 σ 过小, 则易引入过多噪声; σ 过大, 则影响模型的信息提取与稳定性, 故设定属性邻域的调节参数 σ 为 0.55. 邻域划分参数 k 主要用于控制决策对象邻域所包含的样本数, k 值的选择需与样本量匹配. 考虑到, 若 k 过小, 则邻域样本数量不足, 易受个体异常值影响, 导致邻域划分偏向局部噪声而非整体分布特征; 若 k 过大, 则邻域会包含过多非相似样本, 稀释跨模态加权融合后的相似性信息, 故模型设定邻域划分参数 $k = 7$. 此外, 模型设定正域预测标签为 1, 负域预测标签为 0, 边界域预测标签为 0.5. 首先, 构建多模态混合决策信息系统 (MDIS) 处理类风湿性关节炎数据. 之后通过属性邻域的模态感知划分、数据驱动的客观赋权机制及跨模态加权融合方法,

实现多模态数据的深度融合, 并构建多模态加权邻域决策粗糙集. 在此基础上, 按照第 2 节提出的方法, 进一步引入模拟退火算法 (SA) 与多层感知机 (MLP), 构建自适应阈值优化的两阶段序贯三支决策模型, 实现决策阈值动态优化与边界域样本精细化分类.

第 1 阶段: 首先结合第 2.3 节提出的优化算法获取初始训练集 S 的最优决策阈值, 进而完成测试集 T 的三域划分; 之后按照序贯三支决策的原则, 每次迭代后, 将位于正域 (POS) 与负域 (NEG) 的样本并入训练集. 在进行了 4 次迭代后, 边界域不再改变, 如图 2 所示. 边界域样本占比降至约 8%, 体现出“数据积累-不确定性消解”的正向循环.

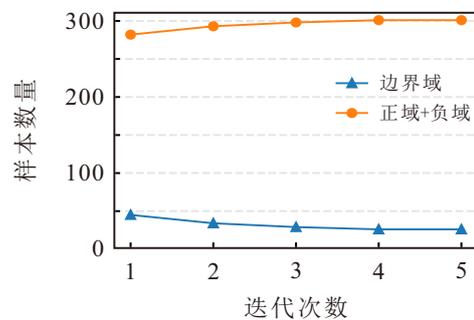


图2 随迭代次数增加样本数量变化

第 1 阶段完成后, 通过算法 1 得到了各模态的权重分布, 如图 3 所示. 其中: 连续型数值模态权重最高 (0.4062), 因 CRP、ESR 等炎症指标是类风湿性关节炎 (RA) 临床诊断的核心客观依据, 赋权结果符合临床对生化指标的依赖逻辑; 离散类别模态 (0.3409) 与图片模态 (0.2529) 也为 RA 的诊断贡献了重要的判别信息, 是 RA 诊断的重要辅助参考.

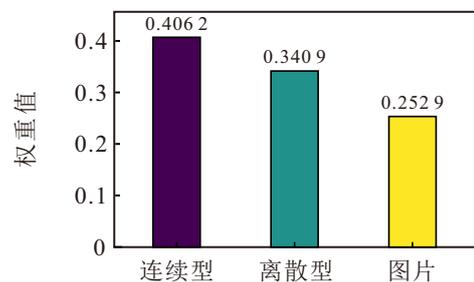


图3 模态贡献柱状图

第 2 阶段: 针对第 1 阶段剩余的边界域样本, 采用三层 MLP 神经网络进行二支决策, 以有效解决传统单阶段三支决策中边界域样本“滞留”问题, 将第 2 阶段 MLP 模型对边界域样本的分类结果与第 1 阶段已明确分类结果的正域、负域样本进行整合, 形成测试集的完整预测结果. 实验获得的混淆矩阵如图 4 所示.

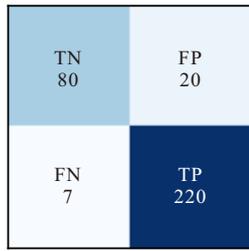


图4 混淆矩阵

3.3.1 分类效果分析

为了进一步评估本文模型在复杂医疗诊断场景的有效性与创新性, 本文将研究模型与常见的分类模型以及 Qin 等^[29] 提出的加权概率核多粒度三支决策模型 (WKMG-TWD integrating GRA) 进行了对比实验. 常见的分类模型包括支持向量机 (SVM)、 K -近邻算法 (KNN)、神经网络 (Neural Network) 以及逻辑回归 (LR). 实验以准确率、精确率、召回率以及 F1-score 为核心评估指标, 结果如表 3 所示. 对比模型 (如 SVM、KNN 等传统模型) 因处理多模态异构数据与不确定性样本的能力有限, 性能显著受限. 相较之下, 本文模型通过属性邻域的模态感知划分机制、数据驱动的客观赋权机制以及跨模态加权融合方法, 实现了多模态异构数据的协同处理与深度融合, 准确率较传统模型提升超 10%. 神经网络模型虽能实现数据非线性特征的提取, 但因二支决策机制, 导致处于模糊状态的样本被强制分类, 准确率只

能达到 84.40%; WKMG-TWD 模型虽然引入三支决策避免了对不确定样本的强制分类, 一定程度上降低了因信息不足导致的误判风险, 但其性能在本任务中仍逊于本文模型. 本文模型通过基于 SA 的动态阈值优化与两阶段序贯三支决策, 将边界域比例压缩至 8%, 再结合第二阶段 MLP 对边界域的精细化分类, 最终使准确率达到 91.74%. 通过对比实验充分验证了本文模型的科学性与有效性.

表3 对比实验

模型	Accuracy	Precision	Recall	F1-score
our model	0.9174	0.9167	0.9692	0.9422
SVM	0.8165	0.8553	0.8855	0.8701
KNN	0.8104	0.8767	0.8481	0.8610
Neural Network	0.8440	0.8636	0.9207	0.8913
LR	0.7859	0.8127	0.8987	0.8536
WKMG-TWD	0.8685	0.8802	0.9383	0.9083

为了进一步衡量模型在正负样本识别中的稳健性与优越性, 本文绘制了所有模型的 ROC 曲线. 如图 5 所示, 本文模型的 AUC 值为 0.938, 显著高于 SVM(0.856)、KNN(0.897)、神经网络 (0.899)、逻辑回归 (0.837) 和 WKMG-TWD(0.905). 这表明在不同决策阈值下, 本文模型对正样本和负样本的区分能力更优, 验证了模型在复杂多模态医疗数据中的泛化能力.

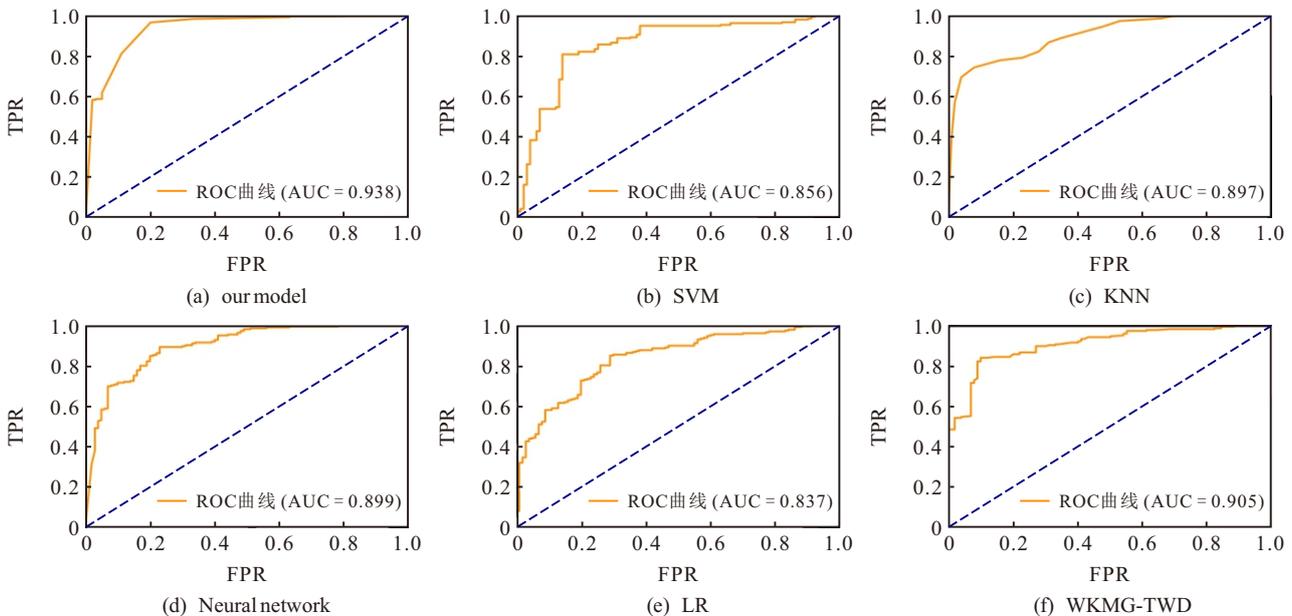


图5 ROC 曲线

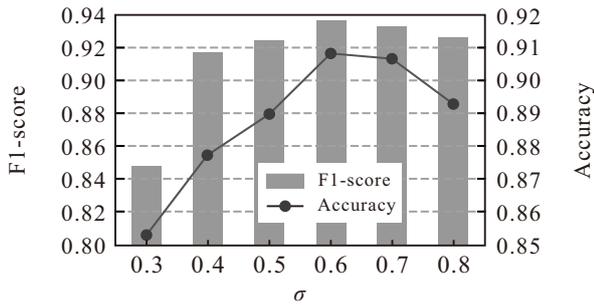
3.3.2 敏感性分析

为了进一步研究模型对关键参数的鲁棒性, 本文对属性邻域调节参数 σ 与决策对象的邻域划分参数 k 进行了敏感性分析, 探讨了参数采用不同值时模

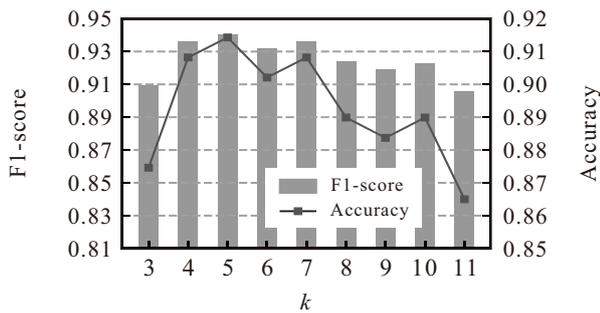
型分类效果的变化.

由第 3.3 节中的模型参数的设定分析易知, 参数 σ 的取值需大于 0.3, 故参数 σ 的初始值选择 0.3. 后续敏感性分析实验中发现参数 σ 大于 0.8 后, 模型效

果下降较多,故设定敏感性分析中参数 σ 的分析范围为0.3~0.8.图6展示了邻域半径计算参数 σ 的敏感性分析结果.当 σ 较小时,邻域半径过大,易引入过多噪声样本;随着 σ 增大,邻域半径缩小,模型逐步过滤噪声,当 σ 处于0.6左右时,模型可以较好地平衡有效样本与噪声干扰,此时准确率与F1-score达到峰值;若 σ 继续增大,则邻域半径过小,样本信息不足,准确率与F1-score随之下降.这表明, σ 参数通过调控邻域粒度影响模型的分类型鲁棒性,实际应用中需规避极端取值.



(a) 不同参数 σ 下的模型分类效果



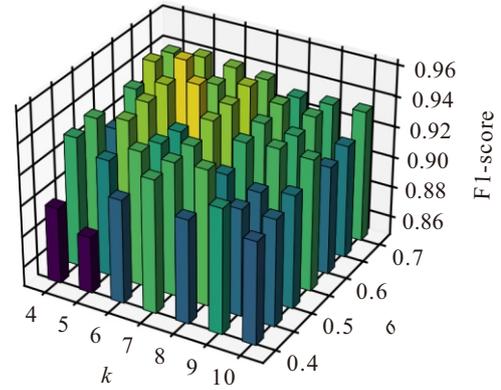
(b) 不同参数 k 下的模型分类效果

图6 单参数敏感性分析

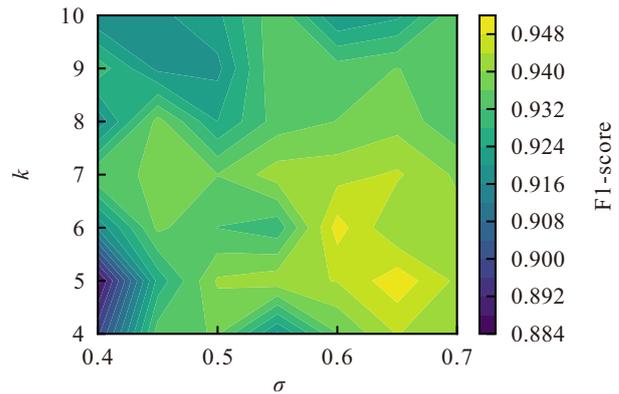
对于参数 k 的取值,本研究从模型的分类型与稳健性出发,考虑到 k 值过小($k < 3$),会导致模型出现过拟合现象; k 值过大($k > 11$)时,引入过多噪声,模型分类精度明显下降.综合考虑,设定敏感性分析中参数 k 的分析范围为3~11.图6展示了 $\sigma = 0.5$ 时随着 k 值变化,模型的F1-score与准确率的变化情况.整体来看,随着参数 k 从3变化到11,F1-score和准确率呈现出相同的波动趋势.当参数 k 的取值过大或过小时,两个指标均出现一定程度的下降.这表明参数 k 对模型的F1-score和准确率存在一定影响,在模型的实际应用时需依据数据特性,选择合适的 k 值,以平衡样本代表性与噪声容忍度.

图7展示了针对模型F1-score的双参数敏感性分析结果.通过双参数敏感性分析可知, k 和 σ 对模型的分类型效果存在显著的耦合影响.模型的高性能区域集中在图7(b)右下部的参数组合,当 $k \in [5, 6]$,

$\sigma \in [0.6, 0.65]$ 时,模型分类效果最好,此时邻域划分能够有效平衡局部相似性与全局代表性.当参数偏离该区域,尤其是两者同时取较大或较小值时,F1-score呈下降趋势.在实际应用中,应避免极端参数值,在一个合适的参数空间内寻找 k 和 σ 的最佳组合,使模型适应训练数据,辅助医生提高疾病的早期诊断准确率.



(a) 双参数敏感性分析柱状图



(b) 双参数敏感性分析热力图

图7 双参数敏感性分析

3.3.3 消融实验

为了进一步分析彩超图片特征提取的合理性并评估本文模型的有效性,将所提出的模型与原始模型1(采用均等权重)、原始模型2(采用传统邻域划分方法)以及原始模型3(去除图片模态特征)进行分类效果对比,结果如图8所示.从图8可以清晰地看到,在准确率与F1-score上,本文模型均显著优于原始模型,表明原始模型1与原始模型2在训练过程中,对于多模态数据特征的学习效果较差;同时进一步表明了本文模型采用RESNET50模型对彩超图片进行特征提取的合理性与有效性.在真实的疾病预测场景中,原始模型可能会引发更高概率的误判,将健康人群判定为患病或将患病人群判为健康.综合上述分析,本文提出的自适应阈值优化两阶段三支迭代决策模型的整体分类效果要优于3个原始模

型,更适合应用于疾病诊断中多模态数据混合的复杂场景。

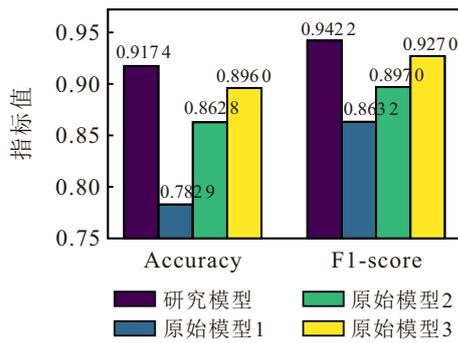


图8 消融实验

4 结论

医疗领域多模态数据的快速增长为疾病诊断模型提供了丰富信息,但随之而来的多模态数据异构性与决策不确定性也成为了决策模型实际应用的关键瓶颈.针对这些问题,本文提出了融合邻域粗糙集与模拟退火算法的自适应阈值优化多模态三支决策模型.该模型以多模态混合决策信息系统为基础,通过模态感知的属性邻域、信息增益驱动的客观赋权机制以及跨模态加权融合策略,实现了跨模态语义对齐,解决了传统赋权导致的特征稀释问题.在此基础上,本文模型构建融合 SA 与 MLP 的两阶段序贯三支决策架构,通过全局优化机制实现决策阈值的动态优化,同时系统性解决传统单阶段三支决策的样本滞留难题.实验结果表明,该方法可以有效提升多模态复杂医疗场景下不确定决策的分类准确率,实现对复杂多模态异构数据的有效处理与语义对齐,能够准确识别不同模态属性的分类贡献度并动态优化决策阈值,为医生提供数据驱动的辅助诊断依据.此外,本研究仍存在一定局限性,当前模型预测标签与参数的设定具有一定主观性,优化仍依赖人工调参,跨病种泛化能力待验证.下一步工作将聚焦基于深度学习的数据驱动参数学习机制,并拓展模型在癌症、痛风等疾病的多场景应用.

参考文献 (References)

[1] 徐曼,沈江,余海燕.数据驱动的医疗与健康决策支持研究综述[J].工业工程与管理,2017,22(1):1-13.
(Xu M, Shen J, Yu H Y. A review on data-driven healthcare decision-making support[J]. Industrial Engineering and Management, 2017, 22(1): 1-13.)

[2] Pawlak Z. Rough sets[J]. International Journal of Computer & Information Sciences, 1982, 11(5): 341-356.

[3] Bai J C, Sun B Z, Chu X L, et al. Neighborhood rough set-based multi-attribute prediction approach and its

application of gout patients[J]. Applied Soft Computing, 2022, 114: 108127.

- [4] Ye J, Sun B Z, Zhan J M, et al. Variable precision multi-granulation composite rough sets with multi-decision and their applications to medical diagnosis[J]. Information Sciences: An International Journal, 2022, 615(C): 293-322.
- [5] Wang T, Sun B Z, Jiang C. Kernel similarity-based multigranulation three-way decision approach to hypertension risk assessment with multi-source and multi-level structure data[J]. Applied Soft Computing, 2023, 144: 110470.
- [6] Qian Y H, Zhang H, Sang Y L, et al. Multigranulation decision-theoretic rough sets[J]. International Journal of Approximate Reasoning, 2014, 55(1): 225-237.
- [7] Liu J Q, Sun B Z, Ye J, et al. Hybrid deep-learning prediction model based on kernel multi-granularity fuzzy rough sets and its application in the diagnosis and treatment of chronic kidney disease[J]. Engineering Applications of Artificial Intelligence, 2025, 147: 110297.
- [8] 冀俊忠,龙腾,杨翠翠.基于邻域决策粗糙集的脑功能连接生物标记物识别[J].控制与决策,2023,38(4):1092-1100.
(Ji J Z, Long T, Yang C C. Identifying brain functional connectivity biomarkers based on neighborhood decision rough set[J]. Control and Decision, 2023, 38(4): 1092-1100.)
- [9] 张萌,孙秉珍,王婷,等.融合粗糙集与 GRA 的异构信息多准则三支推荐及其在医疗推荐中的应用[J].控制与决策,2022,37(7):1883-1893.
(Zhang M, Sun B Z, Wang T, et al. Multi-criteria three-way recommendation of heterogeneous information based on rough set and GRA and its application in medical recommendation[J]. Control and Decision, 2022, 37(7): 1883-1893.)
- [10] Hu Q H, Yu D R, Liu J F, et al. Neighborhood rough set based heterogeneous feature subset selection[J]. Information Sciences, 2008, 178(18): 3577-3594.
- [11] 张腾飞,张宇迪,马福民.基于改进邻域空间的高维混合数据特征选择算法[J].控制与决策,2024,39(3):929-938.
(Zhang T F, Zhang Y D, Ma F M. Improved neighborhood space based feature selection algorithm for high dimensional mixed data[J]. Control and Decision, 2024, 39(3): 929-938.)
- [12] Chu X L, Sun B Z, Li X, et al. Neighborhood rough set-based three-way clustering considering attribute correlations: An approach to classification of potential gout groups[J]. Information Sciences, 2020, 535: 28-41.
- [13] Zhao X X, Sun B Z, Chu X L, et al. A decision-making approach under uncertainty based on ensemble learning model with multimodal data and its application in medical diagnosis[J]. Expert Systems with Applications, 2025, 265: 125983.
- [14] 李志远,刘思峰,杜俊良,等.小样本条件下基于属性

- 权重 Shapley 值分配的粗糙集决策模型[J]. 控制与决策, 2022, 37(10): 2677-2684.
(Li Z Y, Liu S F, Du J L, et al. Rough set decision-making model based on shapley value assignment of attribute weight under the condition of small sample[J]. Control and Decision, 2022, 37(10): 2677-2684.)
- [15] Raheem S, Al Shehabi S, Mohi Nassief A. MIGR: A categorical data clustering algorithm based on information gain in rough set theory[J]. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 2022, 30(5): 757-771.
- [16] Cui X Y, Wang C Z, An S, et al. Adaptive fuzzy neighborhood decision tree[J]. *Applied Soft Computing*, 2024, 167: 112435.
- [17] Yao Y Y. Three-way decisions with probabilistic rough sets[J]. *Information Sciences*, 2010, 180(3): 341-353.
- [18] 成淑慧, 武优西. 基于序贯三支神经网络的个性化推荐[J]. 控制与决策, 2024, 39(3): 1012-1020.
(Cheng S H, Wu Y X. Personalized recommendation based on sequential three-way decisions with single feedforward neural network[J]. Control and Decision, 2024, 39(3): 1012-1020.)
- [19] Liu D, Li T R, Liang D C. Incorporating logistic regression to decision-theoretic rough sets for classifications[J]. *International Journal of Approximate Reasoning*, 2014, 55(1): 197-210.
- [20] Jia X Y, Tang Z M, Liao W H, et al. On an optimization representation of decision-theoretic rough set model[J]. *International Journal of Approximate Reasoning*, 2014, 55(1): 156-166.
- [21] 李兆彬, 叶军, 周浩岩, 等. 变异萤火虫优化的粗糙 K -均值聚类算法[J]. 山东大学学报: 工学版, 2023, 53(4): 74-82.
(Li Z B, Ye J, Zhou H Y, et al. A rough K -means clustering algorithm optimized by mutation firefly algorithm[J]. Journal of Shandong University: Engineering Science, 2023, 53(4): 74-82.)
- [22] 李小南, 赵璐, 易黄建. 基于加权信息熵的直觉模糊信息系统的三支决策[J]. 控制与决策, 2022, 37(10): 2705-2713.
(Li X N, Zhao L, Yi H J. Three-way decision of intuitionistic fuzzy information systems based on the weighted information entropy[J]. Control and Decision, 2022, 37(10): 2705-2713.)
- [23] Wang W J, Zhan J M, Ding W P, et al. A three-way decision method with tolerance dominance relations in decision information systems[J]. *Artificial Intelligence Review*, 2023, 56(7): 6403-6438.
- [24] Jia F, Liu P D. Multi-attribute three-way decisions based on ideal solutions under interval-valued intuitionistic fuzzy environment[J]. *International Journal of Approximate Reasoning*, 2021, 138: 12-37.
- [25] Ye J, Sun B Z, Bai J C, et al. A preference-approval structure-based non-additive three-way group consensus decision-making approach for medical diagnosis[J]. *Information Fusion*, 2024, 101: 102008.
- [26] Zhang H D, Selang D. A three-way decision based multi-attribute decision-making with intuitionistic fuzzy β [J]. *Applied Soft Computing*, 2023, 139: 110231.
- [27] 杨臻, 邱保志. 混合信息系统的动态变精度粗糙集模型[J]. 控制与决策, 2020, 35(2): 297-308.
(Yang Z, Qiu B Z. Dynamic variable precision rough set model of mixed information system[J]. Control and Decision, 2020, 35(2): 297-308.)
- [28] Sun B Z, Zhao X X, Qian Y H, et al. Dynamic decision-making paradigm for multi-modal information in a human-computer interaction perspective: Fusing composite rough set and incremental learning[J]. *Information Fusion*, 2025, 124: 103411.
- [29] Qin X Y, Sun B Z, Wu S M, et al. Weighted probability kernel multi-granularity three-way decision integrating GRA and its application in medical diagnosis[J]. *Information Sciences*, 2024, 669: 120574.
- [30] 姜楠, 田新平, 曾小峰. 《2024 中国类风湿关节炎诊疗指南》解读[J]. 协和医学杂志, 2025, 16(1): 28-34.
(Jiang N, Tian X P, Zeng X F. Interpretation on the 2024 Chinese guidelines for the diagnosis and treatment of rheumatoid arthritis[J]. Medical Journal of Peking Union Medical College Hospital, 2025, 16(1): 28-34.)

作者简介

王景瑞 (2002-), 男, 硕士生, 主要研究方向为医疗智能决策, E-mail: jrwang0528@163.com;

孙秉珍 (1979-), 男, 教授, 博士生导师, 主要研究方向为人工智能驱动的决策分析、数据驱动的医疗决策、应急管理决策, E-mail: bzsun@xidian.edu.cn;

包强 (1995-), 男, 博士生, 主要研究方向为机器学习与智能决策, E-mail: jonbao1028@gmail.com;

刘极倩 (2001-), 女, 硕士生, 主要研究方向为数据挖掘与智能决策, E-mail: jiqianliu186@163.com;

楚晓丽 (1985-), 女, 博士, 硕士生导师, 主要研究方向为大数据与人工智能驱动的临床疗效评价、机器学习与智能决策及其在医疗决策中的应用, E-mail: xlchu85@126.com.