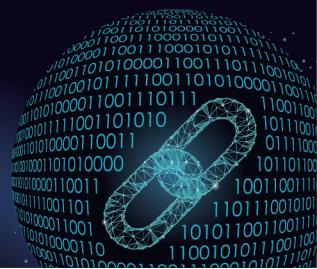




中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于规则聚类和参数学习的扩展置信规则库推理模型

杨隆浩, 陈江鸿, 叶菲菲, 王应明

引用本文:

杨隆浩, 陈江鸿, 叶菲菲, 王应明. 基于规则聚类和参数学习的扩展置信规则库推理模型[J]. 控制与决策, 2024, 39(8): 2685–2693.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.0195>

您可能感兴趣的其他文章

Articles you may be interested in

CART决策树方法在煤电厂节能降耗中的应用

Application of CART decision tree model in reducing coal consumption in coal power plant

控制与决策. 2021, 36(5): 1232–1238 <https://doi.org/10.13195/j.kzyjc.2019.1272>

基于聚类簇结构特性的自适应综合采样法在入侵检测中的应用

Toward intrusion detection via cluster structure-based adaptive synthetic sampling approach

控制与决策. 2021, 36(8): 1920–1928 <https://doi.org/10.13195/j.kzyjc.2019.1672>

基于DST融合多视图模糊推理赋值的三维目标检测

3D object detection based on DST fusion multi-view fuzzy reasoning assignment

控制与决策. 2021, 36(4): 867–875 <https://doi.org/10.13195/j.kzyjc.2019.0434>

基于SRCSAC评价框架挖掘的跨语言查询译后扩展

Cross language query post-translation expansion based on the SRCSAC evaluation framework mining

控制与决策. 2020, 35(11): 2787–2796 <https://doi.org/10.13195/j.kzyjc.2018.1647>

基于不变网络模型和故障注入的分布式信息系统故障溯源方法

Fault source location algorithm for distributed information system based on invariant network and fault injection

控制与决策. 2020, 35(11): 2723–2732 <https://doi.org/10.13195/j.kzyjc.2019.0214>

基于规则聚类和参数学习的扩展置信规则库推理模型

杨隆浩¹, 陈江鸿¹, 叶菲菲^{2†}, 王应明¹

(1. 福州大学 经济与管理学院, 福州 350116; 2. 福建师范大学 文化旅游与公共管理学院, 福州 350117)

摘要: 扩展置信规则库(EBRB)中的规则数量和参数取值共同影响 EBRB 推理模型的决策准确性和计算效率。基于此,提出一种基于规则聚类和参数学习的改进 EBRB 推理模型,称为RCPL-EBRB 模型。所提出模型的基本原理如下:首先,依据密度聚类分析对 EBRB 进行规则聚类来识别 EBRB 中无效的扩展置信规则和优化传统 EBRB 的建模过程;然后,以聚类所得到的规则簇(即 Sub-EBRB)进行参数学习和规则推理,保证激活规则集合的一致性,从而提高 RCPL-EBRB 模型的决策准确性和计算效率;最后,引入非线性函数拟合和基准分类问题数据集开展模型的有效性检验和参数灵敏度分析。实验结果表明,所提出 RCPL-EBRB 模型比现有 EBRB 推理模型和传统机器学习方法具有更高的决策准确性。

关键词: 扩展置信规则库; 规则聚类; 参数学习; 规则约减; 建模; 灵敏度分析

中图分类号: TP18

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.0195

引用格式: 杨隆浩, 陈江鸿, 叶菲菲, 等. 基于规则聚类和参数学习的扩展置信规则库推理模型 [J]. 控制与决策, 2024, 39(8): 2685-2693.

Extended belief rule base inference model based on rule clustering and parameter learning

YANG Long-hao¹, CHEN Jiang-hong¹, YE Fei-fei^{2†}, WANG Ying-ming¹

(1. School of Economics and Management, Fuzhou University, Fuzhou 350116, China; 2. School of Cultural Tourism and Public Administration, Fujian Normal University, Fuzhou 350117, China)

Abstract: The number of rules and parameter values in extended belief rule base (EBRB) affect the accuracy and computing efficiency of the EBRB inference model. Therefore, this paper proposes an improved EBRB inference method based on rule clustering and parameter learning, called RCPL-EBRB model. The principles of the proposed model include: The density clustering analysis is firstly used to perform the rule clustering of the EBRB, so as to identify invalid extended belief rules and improve the modeling process of the traditional EBRB. Then, the rule clusters obtained by clustering, namely sub-EBRB, are used as basic units for parameter learning and rule reasoning, so as to improve the accuracy and computing efficiency of the RCPL-EBRB model. Finally, the datasets of nonlinear function fitting and benchmark classification problems are introduced to verify the effectiveness of the proposed model and carry out parameters sensitivity analysis. Results show that the RCPL-EBRB model has higher accuracy than the existing EBRB inference model and traditional machine learning methods.

Keywords: extended belief rule base; rule clustering; parameter learning; rule reduction; modeling; sensitivity analysis

0 引言

为了应对复杂建模问题中同时存在的多种类型不确定性信息, Yang 等^[1]在产生式规则、模糊集理论和 D-S 证据理论的基础上提出了置信规则库(BRB)推理模型。该模型以 BRB 为核心, 能够在解决实际问

题时表现出优于传统决策方法的特性, 包括更高的决策准确性、推理过程可见和专家可参与等。然而, 由于 BRB 的建模过程中需要遍历每个前提属性的所有参考等级, 导致 BRB 中的规则数量存在“组合爆炸”问题^[2]。为此, 国内外学者提出了众多改进的

收稿日期: 2023-02-22; 录用日期: 2023-08-02.

基金项目: 国家自然科学基金项目(72001043, 72301071, 61773123); 福建省自然科学基金项目(2020J05122, 2022J01178); 教育部人文社科项目(20YJC630188).

责任编辑: 梁樑.

†通讯作者. E-mail: 13075810934@163.com.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

BRB推理模型。其中:最具代表性的是扩展置信规则库(EBRB)推理模型^[3],该改进模型在继承BRB推理模型优点的基础上,还具有高效简洁的EBRB建模方法。目前,EBRB推理模型已成功应用于机械故障诊断^[4]、基坑变形预测^[5]、锂电池健康状态预测^[6]等领域。然而,对于传统的EBRB推理模型,其在建模和推理过程中存在多处不足。为此,国内学者开展了大量的研究工作,相关的研究包括以下3方面。

1)针对“规模膨胀”问题的研究。“规模膨胀”问题是建模过程因缺少必要的规则约减,导致EBRB存在大量的规则。在该问题的早期研究中,Yang等^[7]分别引入了数据包络分析(DEA),提出了规则约减方法和Wang-Mendel机制提出的规则合成方法,以删减EBRB中无效和相似规则。基于相似的建模思路,Zhang等^[8]引入了密度聚类算法,提出了EBRB的规则约减方法,并在回归和分类数据集中验证了该方法的有效性;Gao等^[9]先根据规则相似性建立候选规则集合,再以贪心策略筛选最优的规则;相似地,Bi等^[10]同样通过贪心策略对EBRB进行了迭代搜索来剔除相似的规则。

2)针对基础参数赋值的研究。基础参数与EBRB推理模型的准确性密切相关,为了提高EBRB推理模型在实际问题中的准确性,Yang等^[11]首次提出了EBRB推理模型的参数学习模型,并在数值为连续型和离散型的问题中验证了该参数学习模型的有效性;Huang等^[12]在EBRB推理模型的集成建模过程中引入了参数学习模型,提升了EBRB推理模型的准确性。随后,兼备参数学习模型的EBRB推理模型被应用于解决实际中不同的复杂决策问题,包括桥梁风险评估^[13]、环境治理成本预测^[14]、海盗袭击风险预测^[15]等。

3)针对规则推理优化的研究。该类型研究是EBRB推理模型相关研究中最早被学者所关注的方向之一,重点优化推理过程中激活规则集合的一致性和检索激活规则的复杂度。其中:与一致性相关的研究成果包括动态规则激活(DRA)方法^[16]、基于改进相似性的规则激活方法^[17]、基于近邻传播的规则激活方法^[18]等;与复杂度相关的研究成果包括多维索引框架^[19]、基于随机聚类森林的规则检索方法^[20]等。这些研究成果在一定程度上降低了EBRB推理模型的计算复杂度并提高了其准确性。

上述研究结果在一定程度上完善了传统EBRB推理模型的建模和推理过程,但是,在面对复杂的实际问题时仍然有以下几个问题需要注意:1)现有的

“规模膨胀”研究通常涉及规则合成或删减,这一过程易导致EBRB中的信息丢失以及模型准确性的下降;2)现有基于参数学习的基础参数赋值方法以EBRB中所有规则作为共同体,导致参数学习所需的时间易在规则数量增多时急剧增加;3)避免信息的丢失往往意味着EBRB中存在大量的相似规则,这会增加在规则推理过程中优化一致性和复杂度的难度。因此,如何进一步完善EBRB推理模型的建模和推理过程仍然是值得深入研究的问题。

针对上述问题,本文通过引入规则聚类和参数学习改进EBRB建模中的规则生成和参数学习过程,从而构建改进的EBRB推理模型,即RCPL-EBRB模型。首先,基于密度聚类分析提出基于规则聚类的Sub-EBRB构建方法,其中Sub-EBRB是指经规则聚类后生成的扩展置信规则簇;然后,基于参数学习提出Sub-EBRB优化方法,考虑到EBRB推理模型的传统参数学习方式均是建立单一的参数学习模型,导致参数学习效率易受EBRB中规则规模的影响,因此,所提出方法采用分治的思想以Sub-EBRB作为基本单位,实行分布式的Sub-EBRB优化过程,提升参数学习效率;接着,借助Sub-EBRB作为基本单位的优势,在RCPL-EBRB模型的规则推理过程中,优化规则的激活过程和提升规则的检索效率;最后,本文通过非线性函数拟合问题和多个常见的分类数据集进行方法比较,以及灵敏度分析,验证所提出建模方法的可行性和有效性。

1 EBRB推理模型与问题提出

EBRB推理模型是基于IF-THEN规则的数据驱动模型,属于可解释性人工智能技术的代表之一,主要由3部分组成:EBRB、建模方法和推理方法。为了进一步增强EBRB推理模型的可适用性,本节回顾其组成部分。

1.1 EBRB的表示与构建方法

EBRB是EBRB推理模型的规则库,由一系列扩展置信规则组成。假设有 M 个前提属性 U_i ($i = 1, 2, \dots, M$)和1个结果属性 D 。其中:第 i 个前提属性包含 J_i 个参考等级,结果属性包含 N 个参考等级 D_n ($n = 1, 2, \dots, N$)。则EBRB中的第 k 条扩展置信规则可表示为

$$\begin{aligned} R_k : & \text{if } U_1 \text{ is } \{(A_{1,j}, \alpha_{1,j}^k); j = 1, 2, \dots, J_1\} \wedge \dots \wedge \\ & U_M \text{ is } \{(A_{M,j}, \alpha_{M,j}^k); j = 1, 2, \dots, J_M\}, \\ & \text{then } D \text{ is } \{(D_n, \beta_n^k); n = 1, 2, \dots, N\}, \\ & \text{with } \theta_k \text{ and } \{\delta_1, \delta_2, \dots, \delta_M\}. \end{aligned} \quad (1)$$

其中: $\alpha_{i,j}^k$ 和 $\beta_{i,j}^k$ 表示第 k 条规则在第 i 个前提属性的参考等级 $A_{i,j}$ 和结果属性的参考等级 D_n 上的置信度, θ_k 为第 k 条规则的权重, δ_i 为第 i 个前提属性的权重。这里需要特别说明的是: 根据 Yang 等^[21] 的研究成果, 当用于构建 EBRB 的训练数据足够多时, 每条规则的规则权重近似于 1。

1.2 EBRB 推理模型的建模方法

在 EBRB 基本表示形式的基础上, 可通过 EBRB 推理模型的建模方法将训练数据集转换为如式(1)所示的扩展置信规则, EBRB 推理模型的建模方法主要包含以下两个步骤:

step 1: 确定基础参数取值。在生成扩展置信规则时, 需要依赖专家知识事先确定 EBRB 推理模型在建模过程中的基础参数, 包括: M 个前提属性的权重 $\{\delta_i; i = 1, 2, \dots, M\}$ 、 M 个前提属性的 J_i 个效用值 $\{u(A_{i,j}); j = 1, 2, \dots, J_i, i = 1, 2, \dots, M\}$ 。

step 2: 计算分布式置信度。假设有 L 组输入输出数据 $\{\langle x_k, y_k \rangle; k = 1, 2, \dots, L\}$ 。其中: $x_k(x_{k,i}; i = 1, 2, \dots, M)$ 为第 k 个输入向量, $x_{k,i}$ 为第 i 个前提属性上的第 k 个输入数据; y_k 为结果属性上第 k 个输出数据。通过基于效用的信息转换方法可将 L 组数据转换为分布式置信度, 其中第 i 个前提属性的分布式置信度如下所示:

$$S(x_{k,i}) = \{(A_{i,j}, \alpha_{i,j}^k); j = 1, 2, \dots, J_i\}. \quad (2)$$

这里

$$\alpha_{i,j}^k = \frac{u(A_{i,j+1} - x_{k,i})}{u(A_{i,j+1}) - u(A_{i,j})}, \quad \alpha_{i,j+1}^k = 1 - \alpha_{i,j}^k,$$

$$u(A_{i,j}) \leq x_{k,i} \leq u(A_{i,j+1}); \quad (3)$$

$$a_{i,t}^k = 0, \quad t = 1, 2, \dots, J_i, \quad t \neq j, j+1. \quad (4)$$

同理, 由输出值 y_k 可计算得到结果属性的分布式置信度如下所示:

$$S(y_k) = \{(D_n, \beta_n^k); n = 1, 2, \dots, N\}. \quad (5)$$

1.3 EBRB 推理模型的推理方法

根据第 1.2 节构建所得到的 EBRB 推理模型的基础上, 对于任意给定输入数据, 可通过 EBRB 推理模型的推理方法计算相应的输出值, EBRB 推理模型的推理方法主要包含以下 3 个步骤:

step 1: 计算个体匹配度。假设输入数据的向量为 $\mathbf{x} = (x_i; i = 1, 2, \dots, M)$, 根据 EBRB 推理模型建模过程中的式(2)~(4), 可将输入数据转化为分布式置信度, 其中第 i 个输入数据的分布式置信度表示如下所示:

$$S(x_i) = \{(A_{i,j}, \alpha_{i,j}^k); j = 1, 2, \dots, J_i\}. \quad (6)$$

随后, 计算第 k 条扩展置信规则中第 i 个前提属性上的个体匹配度, 有

$$S^k(x_i, U_i) = 1 - \sqrt{\frac{\sum_{j=1}^{J_i} (\alpha_{i,j}^k - \bar{\alpha}_{i,j}^k)^2}{2}}. \quad (7)$$

step 2: 计算激活权重。根据 step 1 计算得到的个体匹配度 $\{S^k(x_i, U_i); k = 1, 2, \dots, L; i = 1, 2, \dots, M\}$, 并使用规则权重 $\{\theta_k; k = 1, 2, \dots, L\}$ 和属性权重 $\{\delta_i; i = 1, 2, \dots, M\}$, 可计算 EBRB 中 L 条扩展置信规则的激活权重, 其中第 k 个规则的激活权重计算公式如下所示:

$$w_k = \frac{\theta_k \prod_{i=1}^M S^k(x_i, U_i)^{\bar{\delta}_i}}{\sum_{l=1}^L \theta_l \prod_{i=1}^M S^l(x_i, U_i)^{\bar{\delta}_i}}, \quad \bar{\delta}_i = \frac{\delta_i}{\max_{j=1,2,\dots,M} \delta_j}. \quad (8)$$

step 3: 合成激活规则。计算激活权重后, 选出激活权重大于 0 的扩展置信规则作为激活规则, 并使用证据推理解析算法^[1]。合成激活规则的结果属性置信度分布。为了方便下文叙述, 假设 L 条扩展置信规则均是激活规则, 则相应的合成公式如下所示:

$$\begin{aligned} \beta_n = & \left(\prod_{k=1}^L \left(w_k \beta_n^k + 1 - w_k \sum_{i=1}^N \beta_i^k \right) - \right. \\ & \left. \prod_{k=1}^L \left(1 - w_k \sum_{i=1}^N \beta_i^k \right) \right) / \left(\sum_{i=1}^N \prod_{k=1}^L \left(w_k \beta_i^k + 1 - \right. \right. \\ & \left. \left. w_k \sum_{j=1}^N \beta_j^k \right) - (N-1) \prod_{k=1}^L \left(1 - w_k \sum_{j=1}^N \beta_j^k \right) \right). \end{aligned} \quad (9)$$

2 基于规则聚类和参数学习的新推理模型

为了解决 EBRB 推理模型中现有研究的不足^[22], 本节引入规则聚类和参数学习提出新的 EBRB 推理模型, 称为 RCPL-EBRB 模型。其中: 第 2.1 节介绍 RCPL-EBRB 模型的核心框架, 第 2.2 节~第 2.4 节介绍 RCPL-EBRB 模型的具体组成部分。

2.1 RCPL-EBRB 模型的核心框架

本节所提出的 RCPL-EBRB 模型如图 1 所示, 其核心框架中主要包含了 RCPL-EBRB 模型的建模方法和 RCPL-EBRB 模型的推理方法, 相应的功能分别是利用训练数据集生成 EBRB 和基于 EBRB 生成输入数据的推理结果。

2.2 基于规则聚类的 Sub-EBRB 构建方法

DBSCAN 算法^[23] 是聚类分析算法中的经典算法之一, 且在已有研究中表现出了卓越的信息提取能力^[24-25], 围绕 DBSCAN 算法的核心思想, 本节根据文

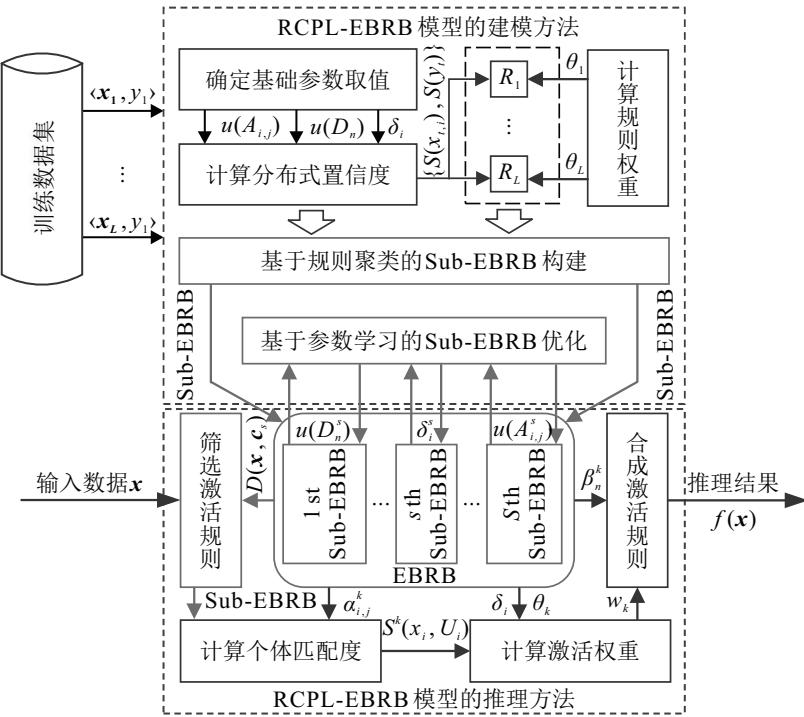


图1 RCPL-EBRB模型的核心框架

献[16]中关于扩展置信规则在空间中的表示方式,将EBRB中的所有规则映射为空间中超元组,其中超元组的定义如下。

定义1 扩展置信规则的超元组表示。假设EBRB中第 k 条扩展置信规则如式(1)所示,且 M 个前提数据的效用值表示为 $\{u(A_{i,j}); j = 1, 2, \dots, J_i; i = 1, 2, \dots, M\}$,则第 k 条扩展置信规则的超元组表示形式如下所示:

$$R_k : \langle u_1^k, u_2^k, \dots, u_M^k \rangle. \quad (10)$$

其中: u_i^k 为第 k 条规则在第 i 个维度(前提属性)上的超元组值,其计算公式如下所示:

$$u_i^k = \sum_{j=1}^{J_i} u(A_{i,j}) \alpha_{i,j}^k + \frac{u(A_{i,1}) + u(A_{i,J_i})}{2} \times \left(1 - \sum_{j=1}^{J_i} \alpha_{i,j}^k\right). \quad (11)$$

根据扩展置信规则的超元组表示,进一步将扩展置信规则间的空间距离定义如下。

定义2 扩展置信规则的分布密度。假设EBRB中 L 条扩展置信规则的超元组表示形式如定义1所示,则第 k 条规则 $R_k(k = 1, 2, \dots, L)$ 的分布密度表示为 $\langle L, \max_{l=1,2,\dots,L} \{D(R_k, R_l)\}\rangle$ 。其中: $D(R_k, R_l)$ 为第 k 条与第 l 条规则间的空间距离,即

$$D(R_k, R_l) = \sqrt{\sum_{i=1}^M (u_i^k - u_i^l)^2}. \quad (12)$$

step 1: 利用输入输出数据构建EBRB。根据EBRB推理模型的传统建模方法,将 T 组输入输出数

据生成 T 条扩展置信规则,包括确定基础参数取值和计算置信度分布,详见第1.2节中的step 1和step 2,其中第 k ($k = 1, 2, \dots, T$)条扩展置信规则 R_k 如式(1)所示。

step 2: 对扩展置信规则进行规则聚类。首先根据定义1将EBRB中 T 条扩展置信规则转换为超元组的表示形式,其中第 k ($k = 1, 2, \dots, T$)条扩展置信规则 R_k 的超元组表示记为 $\langle u_1^k, u_2^k, \dots, u_M^k \rangle$;然后,根据专家经验给定扩展置信规则的最小分布密度和最大邻域半径,记为 $\langle L_{\min}, D_{\max} \rangle$,以此将EBRB中 T 条扩展置信规则聚类成若干个Sub-EBRB。

2.3 基于参数学习的Sub-EBRB优化方法

为了更好地介绍所提出Sub-EBRB优化方法,给出如下假设:通过第2.2节中的方法可构建 S 个Sub-EBRB;有 T_s 条训练数据用于第 s 个Sub-EBRB的参数学习,其中Sub-EBRB中包含 M 个前提属性和1个结果属性,每个前提属性包含 J_i 个参考等级,结果属性包含 N 个参考等级;第 l 条训练数据表示为 $\langle x_l^s, y_l^s \rangle$ ($l = 1, 2, \dots, T_s$), $x_l^s = (x_{l,1}^s, x_{l,2}^s, \dots, x_{l,M}^s)$ 。根据这些假设,基于参数学习的Sub-EBRB优化方法可分为以下3个步骤。

step 1: 初始化各Sub-EBRB中的基础参数取值。首先,通过训练数据获取每个前提属性中输入数据的最小值 $x_{i,\min}^s$ 和最大值 $x_{i,\max}^s$ 。然后,可以确定第 i 个前提属性的效用值取值范围为 $[x_{i,\min}^s, x_{i,\max}^s]$,以及根据该取值范围计算第 i 个前提属性效用值的 J_i 参考等级效用值,其中第 j ($j = 1, 2, \dots, J_i$)个参考等级效用

值的计算公式为

$$u(A_{i,j}^s) = x_{i,\min}^s + (j-1) \frac{x_{i,\max}^s - x_{i,\min}^s}{J_i - 1}. \quad (13)$$

最后,以同样的方式获取结果属性的最大值和最小值,记为 y_{\max}^s 和 y_{\min}^s ,以及计算结果属性 N 个参考等级效用值,记为 $\{u(D_n^s); n=1, 2, \dots, N\}$.

step 2: 构建各 Sub-EBRB 的参数学习模型. 通过 step 1, 第 s 个 Sub-EBRB 的参数优化模型可表示为

$$\min \text{MAE}\{\delta_i^s, u(A_{i,j}^s), u(D_n^s)\} = \sum_{t=1}^T |y_t^s - f(\mathbf{x}_t^s)|. \quad (14)$$

$$\text{s.t. } 0 < \delta_i^s \leq 1, i = 1, 2, \dots, M; \quad (15)$$

$$u(A_{i,j}^s) \leq u(A_{i,j+1}^s), i = 1, 2, \dots, M, \\ j = 1, 2, \dots, J_i - 1; \quad (16)$$

$$u(A_{i,1}^s) = x_{i,\min}^s, u(A_{i,J_i}^s) = x_{i,\max}^s, \\ i = 1, 2, \dots, M; \quad (17)$$

$$u(D_1^s) = y_{\min}^s, u(D_N^s) = y_{\max}^s. \quad (18)$$

其中 δ_i^s 为第 s 个 Sub-EBRB 中第 i 个前提属性的属性权重.

step 3: 利用优化算法进行参数学习. 为了获得 S 个 Sub-EBRB 的参数最优取值, 需要在 step 2 的基础上对这些 Sub-EBRB 进行参数学习.

2.4 RCPL-EBRB 模型的规则推理方法

通过第2.3节中所提出方法实现 S 个 Sub-EBRB 中基础参数的参数学习后, 本节给出关于 RCPL-EBRB 模型的推理方法, 具体步骤如下.

step 1: 筛选激活规则. 相比于第1.3节中介绍的 EBRB 模型的推理方法, 该步骤是一个新的步骤, 旨在以 Sub-EBRB 为基本单位筛选激活规则, 从而提升规则激活过程的计算效率和激活规则集合的一致性, 具体步骤如下:

step 1.1: 计算 Sub-EBRB 的中心值. 假设第 s 个 Sub-EBRB 中含有 L_s 条扩展置信规则, 则该 Sub-EBRB 中心值的计算公式如下所示:

$$\mathbf{c}_s = (c_{s,1}, c_{s,2}, \dots, c_{s,M}) = \\ \left(\sum_{l=1}^{L_s} u_i^{s,l} / L_s, \dots, \sum_{l=1}^{L_s} u_M^{s,l} / L_s \right). \quad (19)$$

其中: \mathbf{c}_s 为第 s 个 Sub-EBRB 的中心向量; $c_{s,i}$ 为第 s 个 Sub-EBRB 在第 i 个前提属性上的中心值; $u_i^{s,l}$ 表示第 s 个 Sub-EBRB 中第 l 条扩展置信规则在第 i 个前提属性上的超元组值, 其计算公式参见定义1.

step 1.2: 计算输入数据与 Sub-EBRB 的距离. 假设输入数据的向量表示为 $\mathbf{x} = (x_i; i = 1, 2, \dots, M)$, 则由此可计算输入数据到各 Sub-EBRB 的距离, 其中

输入数据向量 \mathbf{x} 与第 s 个 Sub-EBRB 的距离计算公式如下所示:

$$D(\mathbf{x}, c_s) = \sqrt{\sum_{i=1}^M (x_i - c_{s,i})^2}. \quad (20)$$

step 1.3: 确定 Sub-EBRB 的激活优先级. 根据 S 个 Sub-EBRB 与输入数据间的空间距离 $D(\mathbf{x}, c_s)$ ($s = 1, 2, \dots, S$), 排列这 S 个 Sub-EBRB 的优先级, 其中空间距离最小的 Sub-EBRB 具有最高优先级, 即该 Sub-EBRB 中的规则需要最先被激活.

step 1.4: 确定激活规则的最终集合. 通过专家经验给定的空间距离阈值 D_{\min} , 当第 s 个 Sub-EBRB 的空间距离满足 $D(\mathbf{x}, c_s) \leq D_{\min}$ 时, 该 Sub-EBRB 中的扩展置信规则均被激活. 这里需要特别说明的是: 空间距离阈值 D_{\min} 越大, 激活的扩展置信规则越多, 尤其当 $D_{\min} = \max_{s=1,2,\dots,S} D(\mathbf{x}, c_s)$ 时, S 个 Sub-EBRB 中所有扩展置信规则均需被激活; 反之, 激活的扩展置信规则越少.

step 2: 生成输入数据的推理结果. 该步骤与 EBRB 推理模型的推理方法一致, 旨在为输入数据向量 \mathbf{x} 生成相应的推理结果. 具体流程如下: 在 step 1 确定的激活规则集合的基础上, 利用第1.3节中 EBRB 推理模型的推理方法, 包括计算激活规则的个体匹配度和激活权重以及合成激活规则, 最终生成输入数据向量 \mathbf{x} 的推理结果 $f(\mathbf{x})$.

3 实验分析

为了验证 RCPL-EBRB 模型的有效性, 引入一个非线性函数拟合数据集和 UCI 数据库中 8 个分类数据集作为建模数据, 对比 RCPL-EBRB 模型和其他现有方法的性能. 此外, 还通过灵敏度分析探究规则聚类对 RCPL-EBRB 模型的影响.

3.1 非线性函数拟合

本节通过一个非线性函数拟合的问题, 介绍如何通过训练数据构建 RCPL-EBRB 模型, 以及如何应用 RCPL-EBRB 模型生成给定输入数据的推理结果. 首先, 给出非线性函数的具体公式为

$$y = x \cdot \sin x, \quad (21)$$

其中 x 的定义域为 $[0, \pi]$.

为了构建 RCPL-EBRB 模型, 首先在 x 的定义域中随机选取 1400 组输入输出数据, 并将这 1400 组数据中的 1200 组数据用作训练数据集, 200 组数据作为测试数据集. 其中: 训练数据集中 1000 组数据用于生成扩展置信规则和 200 组数据用于参数学习, 以下称这两类数据集分别为规则生成数据集和参数

学习数据集。此外,规则聚类时设定规则分布密度为 $\langle L_{\min} = 10, D_{\max} = 0.023 \rangle$ 。根据上述参数设定,RCPL-EBRB模型的构建步骤如下。

step 1: 根据第2.2节中基于规则聚类的Sub-EBRB构建方法,将规则生成数据集中1 000组输入输出数据转换为1 000组分布式置信度,并由此构建由1 000条扩展置信规则组成的EBRB;在此基础上,利用EBRB的规则聚类算法对这1 000条规则进行规则聚类;根据规则分布密度,可聚类为7个Sub-EBRB并筛选出8条无效规则,其中7个Sub-EBRB的规则数量如图2所示。

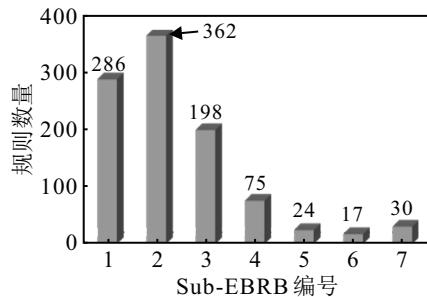


图2 7个Sub-EBRB中的规则数量

step 2: 根据第2.3节中基于参数学习的Sub-EBRB优化方法,为7个Sub-EBRB生成相应的基础参数取值,以及与7个Sub-EBRB相对应的参数学习模型;再利用参数学习数据集中200组输入输出数据和Matlab优化工具箱中的遗传算法对这7个Sub-EBRB进行独立的参数学习,以获得7个Sub-EBRB中基础参数的最优取值。

step 3: 根据第2.4节中RCPL-EBRB模型的规则推理方法,可生成相应的中心值,分别为2.2095、0.5729、1.4803、2.9077、1.1579、3.099、2.6954;再依据这些中心值,生成测试数据集中200组输入输出数据的推理结果。随后,根据以上实验结果可画出该条曲线在EBRB推理模型(记为O-EBRB模型)、仅基于规则聚类的EBRB推理模型(记为RC-EBRB模型)以及仅基于参数学习的EBRB推理模型(记为PL-EBRB模型)和RCPL-EBRB模型中的拟合图,图3为各EBRB模型的曲线拟合结果。

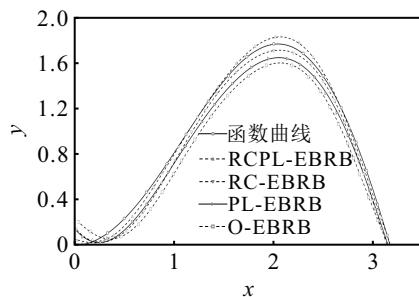


图3 不同EBRB推理模型拟合效果对比

由图3可知:与O-EBRB模型的拟合效果相比,其余3种改进EBRB推理模型的拟合效果更接近函数曲线,由于RCPL-EBRB模型结合了PL-EBRB模型和RC-EBRB模型各自的优点,RCPL-EBRB模型的拟合效果最佳,这进一步表明了RCPL-EBRB模型在曲线拟合问题上的有效性。

3.2 UCI数据集分类

为了进一步表明RCPL-EBRB模型的有效性和可行性,从UCI数据库中选取8个基准分类数据集,数据集的信息统计如表1所示。在围绕这些分类数据集构建RCPL-EBRB模型时,基础的建模设定如下:1)采用五折交叉验证方法划分训练和测试数据集,即在每一折验证中有80%的数据作为训练数据集和20%的数据作为测试数据集,其中训练数据集中按照3:1的比例进一步分化为75%的数据用于生成扩展置信规则(即规则生成数据集)和25%的数据用于参数学习(即参数学习数据集);2)建模过程中相关参数设定如下:通过第2.3节中step 1对基础参数赋初值并将 L_{\min} 和 D_{\max} 作为规则分布密度的参数取值。基于上述数据集,本文分别对现有EBRB推理模型以及传统机器模型进行比较,对比结果如表1所示。

表1 UCI数据集的详细信息

名称	样本数	属性数	类别数	L_{\min}	D_{\max}
Iris	150	4	3	1.0	4
Seeds	210	7	3	1.1	6
Wine	178	13	3	10.0	25
Diabetes	768	8	2	25.0	8
Cancer	569	30	2	30.0	10
Glass	214	9	6	1.7	12
Transfusion	748	4	2	250	50
Yeast	1 484	8	10	0.5	4

1)与现有EBRB推理模型的性能比较。

在与现有EBRB推理模型的性能比较中,引入了O-EBRB模型、基于动态规则激活的EBRB推理模型^[16](记作DRA-EBRB模型)、基于数据包络分析的EBRB推理模型^[7](记作DEA-EBRB模型)、基于一致性分析规则激活的EBRB推理模型^[26](记作CABRA-EBRB模型)和基于MVP树的推理EBRB模型^[11](记作MVP-EBRB模型),以及使用分类准确率(ACC)、规则遍历率(VRR)作为评价指标。实验结果如表2所示。

由表2可知:与现有方法相比,RCPL-EBRB模型在上述数据集中的准确率均有良好的表现。如对于Seeds、Wine、Cancer、Diabetes、Yeast、Cancer数据集,RCPL-EBRB模型的准确率均高于其他模型,此外,需要注意的是,RCPL-EBRB模型的准确率并不总是低

表2 与其他EBRB推理模型的比较分析

模型类型	指标	Iris	Seeds	Wine	Diabetes	Cancer	Glass	Transfusion	Yeast	平均排名
O-EBRB	ACC	95.33(4)	91.33(5)	81.16(4)	73.44(3)	94.59(3)	67.85(6)	76.14(4)	45.61(5)	4.25
	VRR	100(4)	100(2)	100(4)	100(2)	100(4)	100(4)	100(4)	100(4)	3.5
DRA-EBRB	ACC	95.50(2)	92.02(3)	83.76(3)	71.44(6)	94.61(2)	69.65(4)	76.57(3)	54.13(3)	3.25
	VRR	100(4)	100(2)	100(4)	100(2)	100(4)	100(4)	100(4)	100(4)	3.5
CABRA-EBRB	ACC	95.20(6)	87.04(6)	96.32(2)	73.39(4)	94.59(3)	72.90(1)	72.07(5)	52.70(4)	3.88
	VRR	100(4)	100(2)	100(4)	100(2)	100(4)	100(4)	100(4)	100(4)	3.5
DEA-EBRB	ACC	95.40(3)	91.67(4)	—	74.17(2)	—	69.44(5)	—	—	3.5
	VRR	92.26(3)	—	89.49(3)	—	90.64(3)	92.26(3)	—	—	3
MVP-EBRB	ACC	95.87(1)	92.38(2)	—	72.59(5)	—	72.06(3)	80.36(1)	57.49(2)	2.33
	VRR	81.88(1)	—	69.52(2)	—	72.90(1)	81.88(1)	42.63(2)	41.76(2)	1.5
RCPL-EBRB	ACC	95.33(4)	92.86(1)	97.22(1)	74.68(1)	96.49(1)	72.09(2)	77.12(2)	59.10(1)	1.63
	VRR	82.91(2)	58.88(1)	45.30(1)	63.54(1)	80.34(2)	82.91(2)	30.51(1)	35.82(1)	1.37

于其他方法。如对于 Iris 数据集: RCPL-EBRB 模型的准确率排名第 4。但是在平均排名中, RCPL-EBRB 模型拥有比其他方法更高的排名。在规则推理的过程中, RCPL-EBRB 模型在 Iris、Wine、Diabetes 等数据集上能够遍历更少的规则并达到更高的准确率。由此可知, 该模型可以在访问更少规则的前提下达到更好的准确率, 也表明了该模型在规则约减方面能够起到更加有效的作用。

2) 与其他传统机器学习方法的比较

为了更加充分地讨论 RCPL-EBRB 模型的有效性, 本文还引入了传统机器学习模型进行比较, 其中包括 K 近邻(KNN)算法、支持向量机(SVM)算法、人工神经网络(ANN)算法、朴素贝叶斯(NB)算法。具体比较结果如表 3 所示。

表3 与传统机器学习模型分类准确率比较分析

数据集	KNN	SVM	ANN	NB	RCPL-EBRB
Iris	93.33(3)	92.00(4)	97.33(1)	84.67(5)	95.33(2)
Seeds	85.24(3)	83.80(4)	70.00(5)	88.10(2)	92.86(1)
Wine	84.31(3)	55.56(4)	42.22(6)	96.11(2)	97.22(1)
Diabetes	68.13(4)	69.20(3)	58.40(5)	73.20(2)	74.68(1)
Cancer	94.02(3)	62.74(5)	96.31(2)	93.15(4)	96.49(1)
Glass	66.85(2)	49.91(5)	65.76(3)	57.74(4)	72.78(1)
Transfusion	76.20(3)	75.27(5)	76.34(2)	75.40(4)	77.12(1)
Yeast	58.22(3)	43.26(5)	59.03(2)	57.61(4)	59.10(1)
平均排名	3	4.38	3.25	3.38	1.13

由表 3 可知, 所提出模型在 Seeds、Wine、Diabetes、Glass、Transfusion、Yeast、Cancer 上的准确率均高于传统的机器学习模型。虽然在 Iris 数据集上, RCPL-EBRB 未排名第 1, 但是在平均排名中, 所提出模型仍然排名第 1。此外, 虽然所提出模型可以达到普遍良好的结果, 但是可以得出结论: 没有一种通用的方法可以达到所有数据集的最佳精度, 其内部结构和噪声数据等因素可能会影响分类精度。

3.3 规则聚类的灵敏度分析

考虑到规则聚类是 RCPL-EBRB 模型中的一个重要环节, 本节使用表 3 中的 Iris、Seeds、Wine、

Diabetes、Cancer、Glass 共 6 个分类数据集对规则聚类算法中的两个关键参数进行灵敏度分析, 这两个关键参数分别为最大邻域半径 D_{\max} 和最小分布密度 L_{\min} , 相应的灵敏度分析过程如下。

1) 关于最大邻域半径 D_{\max} 的灵敏度分析。在对最大邻域半径进行灵敏度分析时, 为了保证变量单一, 对于最小分布密度均使用同样的取值。而对于最大邻域半径的取值则通过对数据集的分布进行分析从而确定最大邻域半径的上界和下界, 记为 $\langle f_{\min}, f_{\max} \rangle$ 。其中: 上界的取值为聚类后仍为一个簇的临界值, 下界的取值为聚类后簇的数量过多而导致精确度降低的临界值。因此, D_{\max} 的取值为 $D_{\max} = f_{\min} + e_1 \times (f_{\max} - f_{\min})$ 。其中: e_1 为灵敏度分析因子, 其取值范围在区间 $[0, 1]$ 内。随后依次增大 e_1 的取值, 并

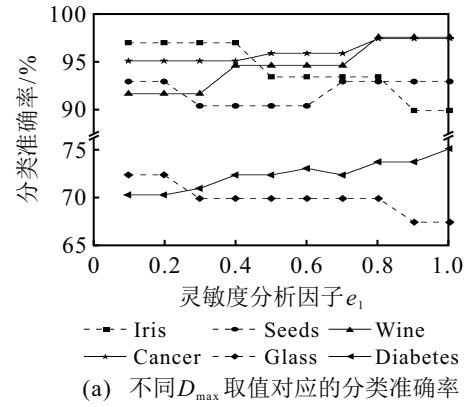
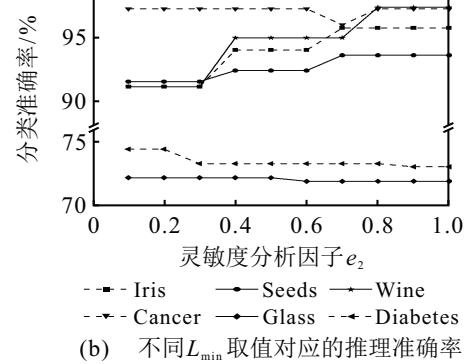
(a) 不同 D_{\max} 取值对应的分类准确率(b) 不同 L_{\min} 取值对应的推理准确率

图 4 RCPL-EBRB 模型的灵敏度分析

得到模型的分类准确率,如图4(a)所示。由图4(a)可见:RCPL-EBRB模型的理想邻域半径并非是一个固定值,其与规则聚类后的聚类效果密切相关,其中聚类效果可理解为聚类后规则簇中含有相同结果属性分布式置信度的规则数量。以Diabetes数据集为例,当灵敏度分析因子 e_1 在[0, 0.3]时,通过规则聚类后规则簇中共有237条规则。其中:152条规则具有同一结果属性分布式置信度,占比64.14%。类似地,当 e_1 在[0.7, 1]时,规则聚类后的规则簇中共有258条规则。其中:223条规则具有同一结果属性分布式置信度,占比86.43%,即 e_1 在[0, 0.3]上的聚类效果不及[0.7, 1],因此前者的分类准确性也比不上后者。综上可知,在确定合适的 D_{\max} 时,可先给定一个初始的 D_{\max} ,然后再比较减小和增大 D_{\max} 时的聚类效果。若减少 D_{\max} 后聚类效果更差,则增加 e_1 的取值可提高分类准确性;反之,若增加 D_{\max} 后聚类效果更差,则减少 e_1 的取值可提高分类准确性。

2)关于最小分布密度 L_{\min} 的灵敏度分析。在对最小分布密度进行灵敏度分析时,为了控制变量的单一性,对于最大邻域半径均使用同样的取值。同样地,对于最小分布密度的取值需要找到每个数据集所对应的上下界,记为 $\langle g_{\min}, g_{\max} \rangle$,其上界仍然是聚类后为一个簇的临界值,下界为聚类后簇的数量过多而导致精确度降低的临界值。因此, L_{\min} 的取值为 $L_{\min} = g_{\min} + e_2 \times (g_{\max} - g_{\min})$ 。其中: e_2 为灵敏度分析因子,其取值范围在区间[0, 1]内。随后依次增大 e_2 的取值,并得到模型的分类准确率,如图4(b)所示。由图4(b)可见:与 D_{\max} 的取值相似, L_{\min} 的取值与最高的推理准确性同样与规则聚类后的聚类效果密切相关。如对于Seeds数据集:当灵敏度分析因子 e_2 在[0, 0.3]时,规则聚类后的簇中共有84条规则。其中:42条规则具有同一结果属性分布式置信度,占比50%。当 e_2 在[0.7, 1]时,规则聚类后簇中有72条规则。其中:56条规则具有同一结果属性分布式置信度,占比77.78%,即 e_2 在[0, 0.3]上的聚类效果不及[0.7, 1],因此前者的分类准确性也比不上后者。综上,在确定合适的 L_{\min} 时,可先给定一个初始的 L_{\min} ,然后再比较减小和增大 L_{\min} 时的聚类效果,若减少 L_{\min} 后聚类效果更差,则增加 e_2 的取值可提高分类准确性;反之,若增加 L_{\min} 后聚类效果更差,则减少 e_2 的取值可提高分类准确性。

4 结 论

本文通过规则聚类和参数学习提出了一种改进的EBRB推理模型,即RCPL-EBRB模型。相比于传统

的EBRB推理模型,所提出模型具有以下改进之处:首先,依据规则聚类算法解决EBRB的“规模膨胀”问题,同时将相似规则聚类于同一个簇中形成Sub-EBRB;然后,以Sub-EBRB为单位建立了彼此独立的参数学习模型和实现分布式的参数学习;最后,同样在Sub-EBRB的基础上提出了相对应的规则推理方法,实现了准确且快速的决策过程。在实验分析中,运用非线性函数拟合和UCI数据分类问题验证了所提出模型的有效性和可行性。实验结果表明,RCPL-EBRB模型不仅能够减少规则数量和降低人为因素的影响,同时能够保证决策的准确性。在未来的研究中,还可以与结构学习、使用新的个体匹配度以及激活权重的计算方法相结合,从而进一步提升EBRB推理模型的性能和在实际问题中的适用性。

参 考 文 献(References)

- [1] Yang J B, Liu J, Wang J, et al. Belief rule-base inference methodology using the evidential reasoning approach-RIMER[J]. IEEE Transactions on Systems, Man, and Cybernetics—Part A: Systems and Humans, 2006, 36(2): 266-285.
- [2] 常雷雷, 李孟军, 鲁延京, 等. 基于主成分分析的置信规则库结构学习方法[J]. 系统工程理论与实践, 2014, 34(5): 1297-1304.
(Chang L L, Li M J, Lu Y J, et al. Structure learning for belief rule base using principal component analysis[J]. Systems Engineering—Theory & Practice, 2014, 34(5): 1297-1304.)
- [3] Liu J, Martinez L, Calzada A, et al. A novel belief rule base representation, generation and its inference methodology[J]. Knowledge-Based Systems, 2013, 53: 129-141.
- [4] Chen M L, Zhou Z J, Zhang B C, et al. A novel combination belief rule base model for mechanical equipment fault diagnosis[J]. Chinese Journal of Aeronautics, 2022, 35(5): 158-178.
- [5] 魏道江, 李业学, 肖耀廷, 等. 基于扩展置信规则库的基坑变形预测方法[J]. 数学的实践与认识, 2021, 51(16): 153-163.
(Wei D J, Li Y X, Xiao Y T, et al. Prediction of wall deflections in deep excavations based on extended belief rule-base[J]. Mathematics in Practice and Theory, 2021, 51(16): 153-163.)
- [6] 文斌成, 肖明清, 杨召, 等. 基于CDPSO-EBRB的锂离子电池健康状态估计[J]. 空军工程大学学报: 自然科学版, 2021, 22(2): 27-33.
(Wen B C, Xiao M Q, Yang Z, et al. An estimation for the health status to lithium ion batteries based on CDPSO-EBRB[J]. Journal of Air Force Engineering University: Natural Science Edition, 2021, 22(2): 27-33.)
- [7] Yang L H, Wang Y M, Lan Y X, et al. A data

- envelopment analysis (DEA)—Based method for rule reduction in extended belief-rule-based systems[J]. *Knowledge-Based Systems*, 2017, 123: 174-187.
- [8] Zhang A, Gao F, Yang M, et al. A new rule reduction and training method for extended belief rule base based on DBSCAN algorithm[J]. *International Journal of Approximate Reasoning*, 2020, 119: 20-39.
- [9] Gao F, Zhang A, Bi W H, et al. A greedy belief rule base generation and learning method for classification problem[J]. *Applied Soft Comput*, 2021, 98: 106856.
- [10] Bi W H, Gao F, Zhang A, et al. A framework for extended belief rule base reduction and training with the greedy strategy and parameter learning[J]. *Multimedia Tools and Applications*, 2022, 81(8): 11127-11143.
- [11] Yang L H, Liu J, Wang Y M, et al. New activation weight calculation and parameter optimization for extended belief rule-based system based on sensitivity analysis[J]. *Knowledge and Information Systems*, 2019, 60(2): 837-878.
- [12] Huang H Y, Lin Y Q, Su Q, et al. An ensemble approach for extended belief rule-based systems with parameter optimization[J]. *International Journal of Computational Intelligence Systems*, 2019, 12(2): 1371-1381.
- [13] 杨隆浩, 叶菲菲, 王应明. 基于扩展置信规则库联合优化的桥梁风险评估[J]. 系统工程理论与实践, 2020, 40(7): 1870-1881.
(Yang L H, Ye F F, Wang Y M. Bridge risk assessment based on extended belief rule base with joint optimization[J]. *Systems Engineering—Theory & Practice*, 2020, 40(7): 1870-1881.)
- [14] 叶菲菲, 杨隆浩, 王应明. 基于不同联合学习方法的扩展置信规则库环境治理成本预测[J]. 系统科学与数学, 2021, 41(3): 705-729.
(Ye F F, Yang L H, Wang Y M. Environmental management cost prediction by extended belief rule-based system based on the different join learning methods[J]. *Journal of Systems Science and Mathematical Sciences*, 2021, 41(3): 705-729.)
- [15] 吕婧, 齐海迪, 李宝德. 基于扩展置信规则库的海盗袭击事件风险预测[J]. 交通运输系统工程与信息, 2022, 22(3): 247-254.
(Lv J, Qi H D, Li B D. Extended belief rule based system for risk prediction of pirate attacks[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2022, 22(3): 247-254.)
- [16] Calzada A, Liu J, Wang H, et al. A new dynamic rule activation method for extended belief rule-based systems[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2015, 27(4): 880-894.
- [17] 林燕清, 傅仰耿. 基于改进相似性度量的扩展置信规则库规则激活方法[J]. 中国科学技术大学学报, 2018, 48(1): 20-27.
(Lin Y Q, Fu Y G. A rule activation method for extended belief rule base based on improved similarity measures[J]. *Journal of University of Science and Technology of China*, 2018, 48(1): 20-27.)
- [18] Fu C, Hou B B, Xue M, et al. Extended belief rule-based system with accurate rule weights and efficient rule activation for diagnosis of thyroid nodules[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2023, 53(1): 251-263.
- [19] Yang L H, Wang Y M, Su Q, et al. Multi-attribute search framework for optimizing extended belief rule-based systems[J]. *Information Sciences*, 2016, 370/371: 159-183.
- [20] Chen N N, Gong X T, Wang Y M, et al. Random clustering forest for extended belief rule-based system[J]. *Soft Computing*, 2021, 25(6): 4609-4619.
- [21] Yang L H, Liu J, Wang Y M, et al. A micro-extended belief rule-based system for big data multiclass classification problems[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2021, 51(1): 420-440.
- [22] Wen B C, Xiao M Q, Chen X. Extended belief rule base parameter optimization based on differential evolution algorithm[C]. *IEEE International Conference on Artificial Intelligence and Computer Applications*. Piscataway: IEEE, 2021: 1013-1017.
- [23] Ester M, Kriegel H P, Sander J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise[C]. *Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining*. New York: ACM, 1996: 226-231.
- [24] 陈寿宏, 易木兰, 张雨璇, 等. 基于优化DBSCAN聚类算法的晶圆图预处理[J]. 控制与决策, 2021, 36(11): 2713-2721.
(Chen S H, Yi M L, Zhang Y X, et al. Wafer map preprocessing based on optimized DBSCAN clustering algorithm[J]. *Control and Decision*, 2021, 36(11): 2713-2721.)
- [25] 廖纪勇, 吴晟, 刘爱莲. 基于相异性度量选取初始聚类中心改进的K-means聚类算法[J]. 控制与决策, 2021, 36(12): 3083-3090.
(Liao J Y, Wu S, Liu A L. Improved K-means clustering algorithm for selecting initial clustering centers based on dissimilarity measure[J]. *Control and Decision*, 2021, 36(12): 3083-3090.)
- [26] Yang L H, Wang Y M, Fu Y G. A consistency analysis-based rule activation method for extended belief-rule-based systems[J]. *Information Sciences*, 2018, 445/446: 50-65.

作者简介

- 杨隆浩(1990—), 男, 副教授, 博士, 从事证据推理、规则库推理等研究, E-mail: more026@hotmail.com;
- 陈江鸿(1999—), 男, 硕士生, 从事规则库推理、聚类分析等研究, E-mail: 752375452@qq.com;
- 叶菲菲(1991—), 女, 讲师, 博士, 从事规则库推理、成本预测等研究, E-mail: 13075810934@163.com;
- 王应明(1964—), 男, 教授, 博士生导师, 从事规则库推理、数据包络分析等研究, E-mail: mysmwang@hotmail.com.