

# 第 1 章 绪 论

## 1.1 研究背景与意义

当今,复杂系统的运行状态通常是由若干个不同类型的传感器节点监控的,使用这些传感器来捕捉如系统状态的温度、压力、流量、振动、图像甚至视频流等异构状态监控数据。无线传感器网络(wireless sensor network, WSN)是一种分布式无线通信技术,以某种形式将若干个传感器节点进行组合,形成一个自组织和多跳的网络系统,用于监控某个区域或某个系统的状态数据<sup>[1]</sup>。典型的 WSN 通信体系结构<sup>[2]</sup>如图 1.1 所示。




图 1.1 WSN 通信体系结构

WSN 传感器节点是由数据采集模块、数据处理模块、无线通信模块和电源供给模块等模块组成<sup>[3]</sup>,如图 1.2 所示。数据采集模块负责对监测区域内的信息进行采集和转换;数据处理模块负责处理所有节点和定位装置的路由协议和管理任务;无线通信模块负责以无线方式发送和接收采集的数据信息;为减少传感器节点占用面积,电源供给模块通常选择微型电池。




图 1.2 传感器节点结构

WSN 包含多种类型的传感器,如声音、光度、温度、湿度、气压、压力、振幅、电磁、土壤成分、斜率和频率等传感器。WSN 广泛应用于物联网<sup>[4]</sup>、军事<sup>[5]</sup>、航天<sup>[6]</sup>、救灾<sup>[7]</sup>、医疗<sup>[8]</sup>、保健<sup>[9]</sup>和环保<sup>[10]</sup>等工程领域。

本书的“复杂环境”是指 WSN 工作环境和网络结构的复杂性: WSN 通常被部署在不易靠近的区域或无人值守的复杂工作环境中<sup>[11]</sup>,用来记录数据或者感知某些事件的发生,可能无法及时对故障节点进行维护; WSN 是具有大规模、高维特征,以非确定或非规则的方式连接在一起,特别是带有非线性、时变发展形式,甚至带有不同时间或空间尺度等特征的复杂网络结构<sup>[12]</sup>。一旦出现了诸如硬件故障、软件故障、能源故障、传输故障或者攻击者入侵节点故障等,将导致 WSN 的有效性降低,甚至产生网络故障和瘫痪。目前 WSN 系统的健康维护仍是以人工定期检查维护为主,这种方式不仅难度大、人力资源高,而且效率和准确率较低,无法满足复杂环境下 WSN 健康评估决策的要求。因此,有必要采取相应措施来提高 WSN 的可靠性和安全性<sup>[13-14]</sup>。

在实际工程应用中,WSN 的健康状态直接影响系统监测数据的准确度和可信度<sup>[15]</sup>,一旦健康状态出现问题且没有及时维护,轻则会导致网络系统失效,重则会造成人员伤亡和财产损失等严重后果<sup>[16]</sup>。复杂环境下 WSN 健康管理的目标是构建健康管理模型,利用计算机技术提供自动化工具和方法,为 WSN 在不同的运行和退化条件下设计最优维护策略,以最低成本实现高可用性。

本书将基于置信规则库(belief rule base, BRB),融合监测信息和领域专家知识,对 WSN 系统健康状态进行评估,以及给出最优维护决策时机。

## 1.2 研究现状

### 1.2.1 复杂系统健康管理研究现状

健康管理是复杂系统智能运维的重要组成部分,旨在预测系统或组件发生故障的可能性和时间点,从而最大限度地减少复杂系统意外的停机时间<sup>[17]</sup>。系统状态监测和网络通信技术的快速发展,可以收集大量监测数据并将其转换为有意义的信息,从而支持维护决策过程。网络物理系统(cyber physical system, CPS)是物理和软件组件相互交织,可以在不同的时间和空间上运行,展示出多种差异化的行为方式,并且随着环境的变化彼此交互。健康管理技术在实施 CPS 的过程中发挥重要作用,它可以使 CPS 及其组件保持适当的状态。同时,基于 CPS 的健康管理提供了一种有效的解决方案,使机器和生产系统达到最大可用化。

健康管理是采取智能化、自动化和数字化等技术,实现对复杂系统健康状态的采集、评估和预测,以及提供最优维护决策时机等,并且完成健康状态的可视化<sup>[18]</sup>。健康管理是包括系统健康监测、特征提取、故障隔离、故障诊断、估算剩余使用寿命、预测故障以及维护决策等功能于一体的综合性智能技术<sup>[19]</sup>。由于系统的高复杂性和不确定性,将健康管理应用于工程实践是具有挑战性的。尤其是中小型企业,由于缺乏内部专业知识、研发资源和

时间,在健康管理的应用方面遇到诸多困难。

近年来,国内外众多学者对复杂系统健康管理进行了大量的理论研究和工程实践,包括故障诊断、故障隔离、故障容忍、健康评估、健康预测及维护决策等<sup>[20-26]</sup>。

(1) 故障诊断:要求在嘈杂的测量、高相关度的数据、大量的输出症状和故障之间复杂的相互作用等极端条件下,确定故障的种类、大小、位置和发生时间,换句话说就是确定失控状态的根源。

(2) 故障隔离:通过硬件和软件方面的设计,建立隔离系统。当系统出现故障,及时找到问题根源,将操作分为多个区域和组件来完成,对不正常运行的区域和组件进行隔离和单独监控,从而保障系统运行。

(3) 故障容忍:提供健壮的系统硬件结构和软件机制,允许系统不仅可以在正常状态时运行,也可以在特定的故障情况下实现特定的目标,即能在特定的故障情况下实现特定的目标。

(4) 健康评估:接收来自不同状态监测模块,或者其他健康评估模块的指标数据,评估被监测系统和组件当前的健康状态,从而产生故障诊断记录,并评估故障发生的可能性。健康状态评估等级是基于各种健康状态领域专家知识、历史数据、工作状态以及历史维护数据等建立的一个离散型的健康参数,该参数可以有效地描述获取当前测量值时的系统工作状态。

(5) 健康预测:综合利用领域专家知识、历史数据、工作状态以及历史维护数据等,预测被监测系统未来一段时间区间内的健康状态,包括下一段时间的健康状态和剩余寿命等。

(6) 维护决策:接收到来自故障诊断、健康评估和健康预测等部分的数据,给出组件更换和系统维护等建议措施,在被监测系统或组件发生故障之前获得最优的维护时机,其准确性直接影响系统的可靠性和安全性。

健康管理最先被用于美国第五代战斗机 F-35 上,达到降低战斗机的维修保养次数和故障频率的目的。时至今日,健康管理在航空航天领域不断革新,代表着健康管理的前沿水平<sup>[27-28]</sup>。Bai 等利用了自认知动态系统,采用前馈神经网络作为智能单元,与卡尔曼滤波器集成以跟踪电池系统动态,构造电池健康管理系统<sup>[29]</sup>;Lee 等利用 5S 方法,将数据转换为预测信息,针对机械系统和组件的健康管理技术开展深入研究<sup>[30-32]</sup>;Pecht 等使用顺序概率比测试和交叉验证程序来检测异常、评估退化和预测故障,针对传感器系统进行了健康管理研究<sup>[33-36]</sup>。

在 WSN 系统中,根据系统的历史和当前工作状态数据,建立物理模型和数学模型是比较复杂的。因为自然环境、网络环境、传感器节点的个体差异等诸多因素都会对模型产生影响,所以有效地针对某个或某类系统建立一个合适有效的 WSN 健康管理模型十分具有挑战性。虽然健康管理在 WSN 系统中的应用相对较少,但是可以借鉴其他领域的相关研究成果。当前,以数据驱动方式实现健康管理已经成为研究热点之一<sup>[37]</sup>,获得了国内外众多科研机构的高度重视,而 WSN 系统中有大量的可用于状态监测的测量数据。

本书利用采集到的 WSN 相关监测数据,分析与系统健康性能特征相关的参数,再结合专家经验知识和其他系统信息,通过算法模型对 WSN 系统的运行状态进行健康评估和

维护决策<sup>[38]</sup>,进而为 WSN 系统的智能运维提供保障。

## 1.2.2 无线传感器网络健康管理研究现状

随着信息通信技术的迅猛发展,WSN 已被广泛应用于工程实践中,为系统的维护决策采集关键特征的监测数据。WSN 的可靠性和稳定性将直接影响监测系统健康评估的准确性,因此有必要提升 WSN 的可靠性和稳定性<sup>[39-42]</sup>。

对 WSN 进行健康管理是提高系统可靠性和稳定性的重要手段之一,监测数据和专家知识被融合后,可以生成 WSN 的健康状态和其他特征<sup>[43-46]</sup>。Shih(2001)等提出了节能无线传感器网络的物理层驱动协议和算法设计<sup>[47]</sup>;Mani(2008)等提出了一种利用不确定概率数据进行故障诊断的鲁棒性传感器网络<sup>[48]</sup>;乐英高(2016)提出基于极限学习机的 WSN 数据融合算法<sup>[49]</sup>;Sabet(2016)等在 WSN 中构建了一种能量高效的多级路由自组织感知聚类算法<sup>[50]</sup>;胡冠宇(2016)利用优化的 DAG-BRB 模型设计了一种网络故障诊断模型<sup>[39]</sup>;贺维(2018)利用 BRB 模型设计 WSN 故障诊断模型<sup>[16]</sup>;Swain(2018)等提出了由聚类、故障检测和故障分类三个阶段组成的 WSN 异构故障诊断协议,用于诊断 WSN 中的异构故障节点<sup>[51]</sup>;Gao(2019)等研究了传感器网络上带乘性噪声时变系统的故障诊断问题<sup>[52]</sup>;石琼(2020)对 WSN 在恶劣环境下的生存技术进行了研究<sup>[53]</sup>;Zhang(2020)等将离散学习策略和阈值限制技术应用于 WSN 故障诊断<sup>[54]</sup>;Sah(2020)等针对 WSN 能量健康评估技术,讨论了最大化传感器节点能量收获的预测和处理能量收集系统的能力<sup>[55]</sup>;Surya(2020)等提出了混合节点故障发现方法,以便在具有许多障碍的无线环境中提供可靠的通信<sup>[56]</sup>;WANG(2020)等提出了一种基于分类的风力发电机传感器故障检测方法<sup>[57]</sup>;Swain(2021)等提出了一种基于神经网络的 WSN 故障诊断算法,用于处理复合故障环境<sup>[58]</sup>;马立玲(2021)等采用卷积神经网络提取若干个传感器之间的关系和特征<sup>[59]</sup>;李英华(2021)等根据方向介数定义了网络负载,创建了受到链路容量和节点容量限制的 WSN 故障检测模型<sup>[60]</sup>;Chen(2021)等提出了一种基于超网格的自适应故障检测方法来识别传感器数据中的三类故障数据<sup>[61]</sup>;Choudhary(2022)等分析了故障诊断和分类过程利用数据中存在的相关性,并处理由于事件随距离衰减时传感器节点位置与事件位置的差异导致的测量变化问题<sup>[62]</sup>;陈俊杰(2022)等针对 WSN 故障检测问题,提出了由输入层、时空处理层和输出层组成的 GCN-GRU 故障检测模型<sup>[63]</sup>。

### 1. WSN 健康管理已取得的研究成果

WSN 健康管理已取得的研究成果可以分为三类,即基于定性知识的方法、基于监测数据的方法以及基于半定量信息(专家知识+监测数据)的方法<sup>[64-65]</sup>。

(1) 基于定性知识的方法。通过对系统进行机理分析,通过专家知识建立健康管理模型,主要包括专家系统、Petri 网、故障树等。这些方法不受观测信息的影响,但由于专家知识的不确定性和局限性,模型建模精度低。

(2) 基于监测数据的方法。通过分析系统状态的监测信息,结合系统辨识和最优化理论,建立健康管理模型,主要包括贝叶斯网络、神经网络、粒子滤波器、时间序列、深度学习、极限学习机等。这些方法不需要了解系统内部机制,但对系统的监测数据质量要求比较高,当样本数量少或者样本数量不对等时,难以建立精确的管理模型。同时,这种模型属于

黑箱建模,模型建模过程不具备可解释性。

(3) 基于半定量信息的方法。将定性知识和定量信息相结合的方式建立健康管理模型,主要包括马尔可夫、模糊神经网络等。这些方法能够在样本不完备、知识不准确的情况下构建预测模型,但是模型建模难度高、模型训练困难。

WSN 健康管理具有不确定性、非线性、并发性的特性;系统状态信息包含多数据源的不同类型数据,这些信息会被采用定性或者定量方式进行描述;受到环境变化、电磁干扰因素的影响,WSN 的定性信息和定量信息中带有模糊不确定、概率不确定性问题。因此,基于半定量信息的健康管理方法更适合对 WSN 进行健康建模。

## 2. WSN 健康管理研究存在的问题

虽然众多学者在 WSN 健康管理研究中取得了一定成绩,但由于工作环境复杂、自然条件恶劣,容易出现诸如硬件、软件、能源、传输或者攻击者入侵节点等故障,导致 WSN 的可靠性降低,若不能及时维护,将产生网络故障,甚至系统瘫痪。WSN 健康管理研究至少存在以下三个问题亟待解决。

(1) 采集故障数据较少。对于 WSN 健康管理而言,监测数据的质量是构建模型的基础和保障。但由于现代机械制造业工艺的高可靠性,WSN 在实际工程应用中,传感器发生故障的概率较低,可采集的故障数据较少,导致 WSN 采集的监测数据大多是来自标准样本数据,无法为准确地构建健康评估模型提供足够的故障数据,进而需要额外的信息进行 WSN 健康评估。基于数据的健康评估模型是建立在大量监测数据的基础上进行统计分析的,而小样本故障数据是无法提供足够的信息来建立一个精确的健康评估模型,这是第一个要解决的问题。

(2) 专家知识使用难度大。WSN 被用于监测复杂系统的运行状态,传感器安装位置广泛,实际应用中会有多种干扰因素影响 WSN 的健康状态。传感器之间进行数据传递时,会产生相互影响,而专家提供的知识是通过自然语言形式呈现的,自然语言的不确定性和模糊性增加了健康评估人员使用专家知识的难度,所以仅凭专家提供的模糊性和不确定性的自然语言描述是无法建立精确的数据模型的,也很难直接使用的。专家知识的不确定性、不完整性和模糊性增加了使用专家知识的难度,在利用专家知识的同时必须使用其他信息,这是第二个要解决的问题。

(3) 工作环境存在多种干扰因素。在工程实践中,WSN 采集的系统信息会受到环境的干扰,监测数据中存在噪声,即监测数据不能准确地反映系统的状态,存在未知的不确定性数据。而且采集到的数据是通过无线方式传递的,对环境的干扰非常敏感。一旦受到环境干扰的影响,监测数据可能会出现丢失的情况,从而增大 WSN 健康管理难度。在实际工作环境中还存在静电感应干扰、电磁感应干扰、漏电流感应干扰、射频干扰、机械干扰、热干扰和化学干扰等多种因素的影响,导致监测数据的波动会比较剧烈,不能简单地通过监测数据来评估健康状态,这是第三个要解决的问题。

综上,针对 WSN 健康管理中存在的问题,本书基于能够有效处理半定量信息的 BRB 模型对 WSN 健康管理进行研究,以减少 WSN 发生故障对其所监督系统的安全性、经济性和可靠性造成的破坏。

### 1.2.3 置信规则库研究现状

#### 1. 置信规则库

置信规则库(belief rule base, BRB)是由若干条置信规则组成的一种专家系统,它能够适当地处理信息中的各种不确定性因素,进而构建一个合理的从输入到输出的非线性模型。

2006年,英国曼彻斯特大学 Jianbo Yang 教授等<sup>[66]</sup>提出基于置信规则的证据推理方法(rule-based inference methodology using the evidential reasoning, RIMER)。BRB模型在常规 IF-THEN 专家规则库的基础上,将置信度引入评估结果中,并能够根据证据理论的推理算法,综合利用定性知识与定量数据,使它能够描述包含更多类型的不确定数据。RIMER 包含知识的表达和知识的推理:知识的表达是通过 BRB 来描述的;知识的推理是通过 ER(evidential reasoning)算法实现的,能够阐述数据的概率不确定性和模糊不确定性,可以对非线性特征数据进行建模。BRB 模型架构如图 1.3 所示。

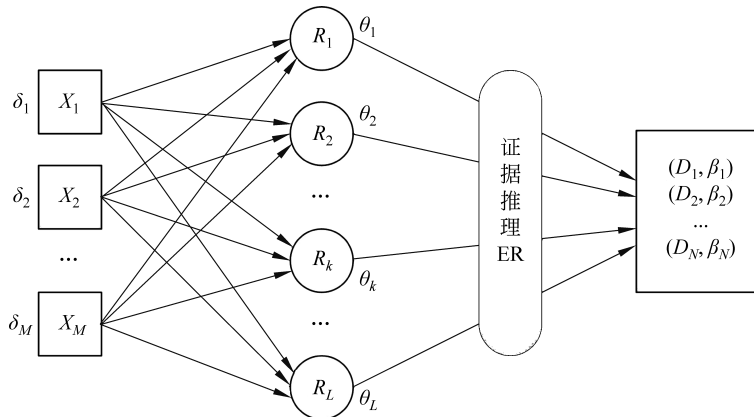


图 1.3 BRB 模型架构

以输油管道泄漏建模问题为例进行说明。

#### (1) 常规规则。

If FlowDiff is Large and PressDrop is Medium

Then LeakSize is VeryLarge

#### (2) 置信规则

If FlowDiff is Large and PressDrop is Medium

Then LeakSize is  $\{(VeryLarge, 80\%), (Medium, 20\%)\}$

BRB 模型是在常规 IF-THEN 规则库、模糊推理、决策理论、D-S 证据理论<sup>[67-68]</sup> (也称为 Dempster/Shafer 证据理论,由 Dempster 于 1968 年首先提出,并由他的学生 Shafer 在 1976 年进一步优化形成的一种不精确推理理论)的基础上发展起来的。

BRB 能够解决复杂系统建模精度不高和监测数据不足的问题,融合定量数据和定性知识,从而解决定性知识存在的不确定性弊端。

传统的贝叶斯模型(Bayesian model)无法利用定性知识,存在描述模糊不确定性。传

统的证据理论方法虽然运用了定性知识与定量数据,但仍然存在描述模糊不确定性。传统 If-Then 规则虽然运用了定性知识与定量数据,以及可描述模糊不确定性,但无法描述概率的不确定性。而在 BRB 模型中,置信度相对于贝叶斯概率,被看作一般化的概率,在使用半定量数据的同时,能够很好地描述各种不确定性信息,并且能够解决因为先验知识的欠缺所出现的无知性问题。

BRB 模型是由若干条置信规则和若干个前提属性构成的,其中每条规则和每个前提属性都具有权重值,每个输出的评价等级通过置信度来表示结论的可信程度,以及无知程度。当 BRB 中的规则可覆盖全部的前提属性的所有参考级别时,则称 BRB 模型是完整的。

$$R_k: \text{If } (x_1 \text{ is } A_1) \wedge (x_2 \text{ is } A_2) \wedge \cdots \wedge (x_m \text{ is } A_m) \\ \text{Then } \{(D_1, \beta_{1,k}), (D_2, \beta_{2,k}), \dots, (D_N, \beta_{N,k})\} \left( \sum_{j=1}^N \beta_{j,k} \leq 1 \right), \quad (1.1)$$

With rule weight  $\theta_k$ , And attribute weight  $\delta_1, \dots, \delta_m$

式中,  $R_k (k=1, \dots, N)$  是 BRB 模型中的第  $k$  条规则,  $N$  表示规则数量;  $x_i (i=1, \dots, m)$  是  $m$  个输入样本中的第  $i$  个前提属性的值;  $A_i (i=1, \dots, m)$  是在第  $k$  条规则中  $m$  个前提属性中第  $i$  个前提属性的参考值;  $\wedge$  表示逻辑与运算;  $D_j (j=1, \dots, N)$  是评估结果的第  $j$  个评价等级;  $\beta_{j,k} (j=1, \dots, N)$  是在第  $k$  条规则中第  $j$  个评价等级的置信度;  $\sum_{j=1}^N \beta_{j,k} \leq 1$  表示评估结果中可能存在无知概率;  $\theta_k$  表示第  $k$  条规则的规则权重;  $\delta_i (i=1, \dots, m)$  表示第  $i$  个前提属性的权重值。

BRB 模型的相关研究成果已经在传感器网络、发动机故障、风险评估、安全评估、惯导系统、传感器故障、治理成本、网络安全、社交媒体、突发事件评估、股价预测和碳排放等领域得到了较好的工程应用。其中, Espinilla(2017)等提出基于扩展信念规则的推理方法(RIMER+)的适应性,使得在传感器发生故障的情况下,仍能保持结果的准确性<sup>[69]</sup>; 贺维(2018)针对 WSN 的节点故障诊断问题,通过节点特征分析,提出分层 BRB 的 WSN 故障诊断方法<sup>[16]</sup>; 鱼蒙(2019)等为保证 BRB 模型能在输入信息缺失的条件下执行,分析特征属性分布情况,利用分层抽样得到候选值,最后利用证据推理算法进行融合<sup>[70]</sup>; Yang(2019)等基于随机子空间置信规则库,对研发项目风险进行评估<sup>[71]</sup>; 傅仰耿(2019)等通过最小化系统复杂性和均方根误差来计算近似 Pareto 最优值,构建了混合进化策略的 M-PAES-BRB<sup>[72]</sup>; Chang(2020)等提出了一种新的六步析取 BRB 扩展方法来处理缺失信息问题<sup>[73]</sup>; Feng(2020)等为了确保建模的透明性和可追溯性,提出基于 BRB 的安全评估模型<sup>[74]</sup>; 董昕昊(2021)等针对 INS 系统健康评估存在的指标多、样本缺失和复杂机理等问题,基于 HBRB 给出 INS 系统评估策略<sup>[75]</sup>; Yang(2021)等提出扩展置信规则库模型来实现传感器故障识别<sup>[76]</sup>; 叶菲菲(2021)等将不同联合学习方法的 EBRB 模型用于环境治理成本预测<sup>[77]</sup>; Gao(2021)等利用选择和约简策略执行 BRB 学习过程,实现从候选规则中搜索和选择最优规则,并去除噪声和冗余规则<sup>[78]</sup>; 刘永裕(2022)等提出通过不完整数据集生成不完整置信规则,并通过衰减因子修正,对不完整规则进行信息融合<sup>[79]</sup>; Zhou(2022)等提出了一种基于证据推理规则并考虑扰动的隐藏行为预测模型,该模型是一种半定量信息的方

法,可以处理多个隐藏行为<sup>[80]</sup>;Kabir(2022)等提出了将 CNN 与基于 BRB 的专家系统集成的数学模型<sup>[81]</sup>;Li(2022)等提出了一种新的集成 BRB,用于海上突发事件的场景演化分析<sup>[82]</sup>;Chang(2022)等提出了将云模型与 BRB 相结合,解决 BRB 模型的可解释性问题<sup>[83]</sup>;You(2022)等提出了一个具有高精度可解释性权重的优化 BRB 框架<sup>[84]</sup>;Hossain(2022)等提出了一种新的机器学习技术,使用 BRBES 进行技术分析,并结合布林带的概念来预测未来五天的股价<sup>[85]</sup>;Ye(2022)等提出了一种新的基于扩展置信规则库推理模型的数据驱动的碳排放预测决策模型<sup>[86]</sup>;CHEN(2022)等提出了一种基于有向无环图(DAG)结构的组合置信规则库(C-BRB)模型<sup>[87]</sup>。

BRB 模型的研究成果存在组合爆炸、属性可靠度下降、属性数据冗余和隐含行为数据等问题,可以通过分层 BRB、考虑属性可靠度的 BRB、考虑属性关系的 BRB、隐含 BRB 和析取 BRB<sup>[88]</sup>等方式解决。

(1) 分层 BRB(hierarchical BRB)。在多属性决策问题中,直接使用所有相关属性构造 BRB 是不可行的,大量的规则将产生组合爆炸问题。因此,可以使用自底向上结构的分层 BRB 来解决这样的问题。图 1.4 给出了简单的分层 BRB 模型,分层 BRB 中 A、B、C、D、E、F、G、H 表示复杂系统的若干个前提属性。较低级别的前提属性的输出被融合以生成作为较高级别 BRB 的输入,信息是从底层的前提属性传播到顶层评估。各个子规则库中的前提属性彼此独立,与此同时相同级别的子规则也相互独立。所有子规则库构成一个复合 BRB 规则库。分层 BRB 为解决具有四个及以上前提属性的复杂系统提供了一种有效方案,能够较好地避免 BRB 模型的组合爆炸问题。

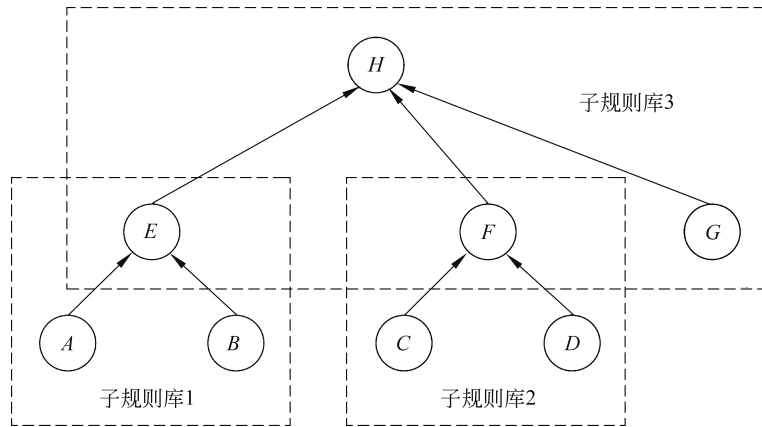


图 1.4 简单分层 BRB 模型

(2) 考虑属性可靠度的 BRB(BRB with attribute reliability, BRB-r)。在实际工程环境中,监测信息可能会受到许多因素的影响,如环境中的噪声和各种干扰因素等。受此影响,监测信息可能是不可靠的,甚至可能存在一些错误信息。为了量化不可靠监测信息的影响,在 BRB-r 模型中考虑了前提属性可靠度权重。属性可靠度表示其反映目标系统真实信息的能力,同时取决于实际输入数据和专家经验,反映了环境和系统内部干扰因素的影响程度。

(3) 考虑属性关系的 BRB(BRB with considering attributes' correlation, BRB-c)。系

统的机理信息是由所有前提属性共同表示的,因此,若干个前提属性之间可能具有一些重叠信息会影响建模精度。前提属性和系统机理有着直接的联系。为了解决前提属性之间存在的相关性问题,建立一种考虑前提属性相关性的 BRB-c 模型,其中相关属性通过解耦矩阵进行处理。BRB-c 模型是由解耦矩阵、BRB 模型以及优化模型三部分组成,比传统的 BRB 模型具有更高的精确度。

(4) 隐含 BRB(hidden BRB, HBRB)。在复杂系统中,部分行为特征是无法直接监测到的,称为隐含行为,建立隐含行为的预测模型是比较困难的。为了预测这些隐含行为,需要相应的可监测指标。然而,BRB 模型往往忽略了其他必要因素,如综合利用定性知识和定量数据,以及有效表达各种类型的不确定性。HBRB 建立了当前时间和未来时间的隐含行为之间的关系。尽管 HBRB 考虑了各种类型的不确定性,包括随机不确定性、模糊不确定性和无知不确定性,但其存在忽略了局部无知的问题。

(5) 析取 BRB(disjunctive BRB, DBRB)。传统 BRB 在前提属性和参考值数量过多时,存在组合爆炸问题。要解决这一挑战,可以构造一个析取 DBRB,其中最小 DBRB 模型由参考值的数量决定。DBRB 的前提属性之间是逻辑“或”关系,即系统中的每个前提属性都对评估结果起主导作用。与传统 BRB 的前提属性之间是逻辑“与”的关系不同,DBRB 只要有一个前提属性被激活,析取规则便成立。

## 2. 证据推理

置信规则库只负责知识的描述和表达,而知识的推理则是通过推理机实现的。证据推理(evidential reasoning, ER)模型被作为 BRB 模型的推理工具。为解决 Dempster 组合规则存在的“反直觉”和组合爆炸问题,ER 算法在贝叶斯的联合概率推理的基础上应运而生。ER 模型融合了被不同类型信息所激活的置信规则,计算出评估结果的置信度。

证据推理主要围绕信任函数和置信分布两大分支进行研究,如图 1.5 所示。

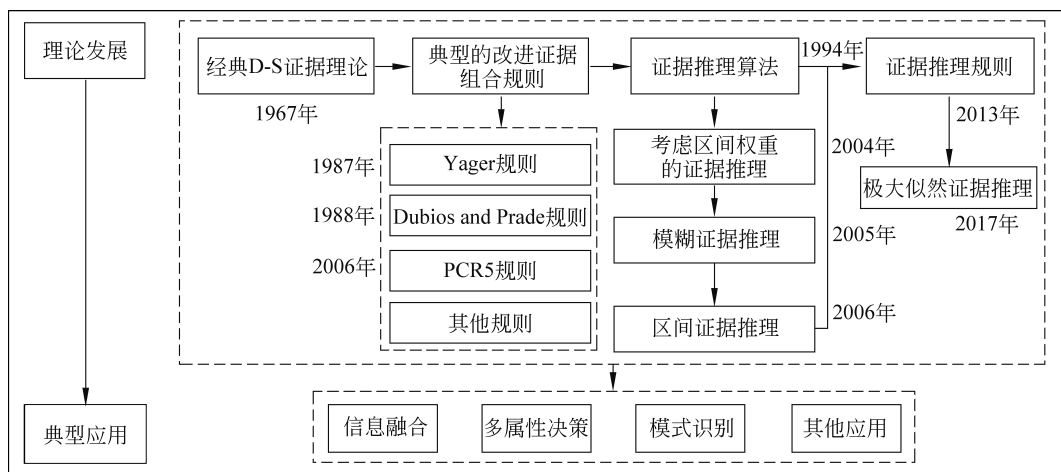


图 1.5 证据推理的发展历程

ER 模型有以下两种推导方式。

(1) ER 解析模型: Wang 和 Yang 利用解析表达式,得到结论的置信度,适用于 BRB

模型的优化过程<sup>[89]</sup>。

(2) ER 迭代模型: Yang 和 Xu 将置信度转换成基本概率质量,再采用 Dempster 准则对规则进行组合,计算出结论的基本概率设置,转换成置信度,该置信度等同于一般化的概率<sup>[90]</sup>。

虽然两个模型的推导结果是相同的,却适用于解决不同的问题场景。ER 解析模型适合于 BRB 模型的参数优化和训练;ER 迭代模型适合于不需要训练的 BRB 推理,通过 BRB 和 ER 直接得出结论。

ER 模型与传统的 D-S 证据推理方法相比,计算过程是线性的,计算复杂度较小,可以处理带有冲突的证据,以及包含各种不确定性及未知性的信息。

证据推理能够描述带有不确定性的输入信息,并实现证据的定量表达,即

输入信息  $x_i \rightarrow$  置信分布

置信分布可以描述为

$$S(x_i) = \{(H_n, \beta_{n,i}), n = 1, \dots, N, i = 1, \dots, L\} \quad (1.2)$$

式中, $S(x_i)$ 是输入信息为  $x_i$  时的置信分布; $x_i$  是第  $i$  个输入信息,可以是定量信息、定性信息或符号信息等; $H_n$  是第  $n$  个评估等级; $\beta_{n,i}$  是第  $i$  个输入信息相对于第  $n$  个评估等级的置信度; $N$  是评估等级的数量; $L$  是输入信息的数量。

如果评估方案是由  $L$  条独立证据  $e_i (i = 1, \dots, L)$  构成的,辨识框架  $\Theta = \{\theta_1, \dots, \theta_N\}$  是由  $N$  个评估等级  $\theta_n (n = 1, \dots, N)$  构成的,则第  $i$  条证据的置信分布描述为

$$e_i = \{(\theta_n, \beta_{n,i}), n = 1, \dots, N; (\Theta, \beta_{\Theta,i})\} \quad (1.3)$$

式中, $e_i$  表示第  $i$  条证据的置信分布; $\theta_n$  表示第  $n$  个评估等级; $\beta_{n,i}$  表示第  $i$  条证据的第  $n$  个评估等级的置信度; $N$  表示评估等级的数量; $\beta_{\Theta,i}$  表示全局无知的置信度。

式(1.3)需满足:

$$0 \leq \beta_{n,i} \leq 1, \quad \sum_{n=1}^N \beta_{n,i} \leq 1 \quad (1.4)$$

任意  $\beta_{n,i} > 0$  时, $(\theta_n, \beta_{n,i})$  称为证据  $e_i$  的一个焦点。

如果证据的权重表示为  $\omega_i (i = 1, \dots, L)$ ,符合  $0 \leq \omega_i \leq 1, \sum_{i=1}^L \omega_i = 1$  约束条件,则可以使用如下公式表示证据  $e_i$  的基本概率质量。

$$m_{n,i} = \omega_i \beta_{n,i} \quad (1.5)$$

$$m_{\Theta,i} = \omega_i \beta_{\Theta,i} \quad (1.6)$$

$$m_{p(\Theta),i} = 1 - \omega_i, \quad n \in [1, \dots, N] \quad (1.7)$$

式中, $m_{n,i}$  表示第  $i$  个证据的第  $n$  个等级的基本概率质量; $m_{\Theta,i}$  表示全局无知的基本概率质量,表示单证据不完整性; $\beta_{\Theta,i}$  表示第  $i$  个证据的全局无知的置信度; $m_{p(\Theta),i}$  表示除证据  $e_i$  外,其余证据对评估等级的基本概率质量。

近年来,众多学者对 ER 证据推理模型进行了深入研究。AbuDahab(2016)等用证据推理规则代替证据推理方法进行证据组合<sup>[91]</sup>;孙伟(2020)等融合证据推理和视觉里程计匹配置信度,提高惯性/视觉里程计组合导航精度<sup>[92]</sup>;Sachan(2020)等通过分层置信规则库和证据推理实现贷款承销过程的自动化方法<sup>[93]</sup>;Chen(2021)等基于系统的结构和工作