

DOI: 10.19666/j.rlfed.202503025

# 基于贝叶斯网络的非均衡数据下 磨煤机故障诊断方法

张涛<sup>1</sup>, 邵毅<sup>1</sup>, 刘乐源<sup>2</sup>, 郝欣<sup>1</sup>, 胡绍宇<sup>1</sup>

(1. 辽宁东科电力有限公司, 辽宁 沈阳 110179;

2. 东北大学信息科学与工程学院, 辽宁 沈阳 110819)

**[摘要]** 针对燃煤电厂磨煤机制粉系统故障诊断中因数据分布不均衡导致的少数类故障诊断精度低、可解释性差的问题, 提出一种融合 SMOTE 数据增强、Dirichlet 先验平滑与贝叶斯网络的故障诊断方法。通过 SMOTE 技术对少数类故障样本进行特征空间扩展, 缓解数据稀缺性; 结合 Dirichlet 先验平滑优化贝叶斯网络条件概率估计, 解决样本缺乏导致的零概率问题; 构建分层贝叶斯网络架构, 融合领域知识与数据驱动结构学习, 实现故障节点快速推断与属性节点间接推断的双模式诊断策略。实验基于真实工业数据, 在非均衡数据场景下, 所提方法具有较高的诊断精度与可解释性, 为磨煤机故障诊断提供兼具实时性、准确性及透明性的解决方案。

**[关键词]** 贝叶斯网络; 故障诊断; 数据不平衡; 磨煤机

**[引用本文格式]** 张涛, 邵毅, 刘乐源, 等. 基于贝叶斯网络的非均衡数据下磨煤机故障诊断方法[J]. 热力发电, 2025, 54(11): 117-125. ZHANG Tao, SHAO Yi, LIU Leyuan, et al. A fault diagnosis method for coal mills based on Bayesian network under imbalanced data conditions[J]. Thermal Power Generation, 2025, 54(11): 117-125.

## A fault diagnosis method for coal mills based on Bayesian network under imbalanced data conditions

ZHANG Tao<sup>1</sup>, SHAO Yi<sup>1</sup>, LIU Leyuan<sup>2</sup>, HAO Xin<sup>1</sup>, HU Shaoyu<sup>1</sup>

(1. Liaoning Dongke Electric Power Co., Ltd., Shenyang 110179, China;

2. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China)

**Abstract:** To address the challenges of low diagnostic accuracy and poor interpretability for minority fault classes caused by imbalanced data distribution in coal mill pulverizing systems of coal-fired power plants, a fault diagnosis method integrating SMOTE data enhancement, Dirichlet prior smoothing, and Bayesian networks is proposed. The SMOTE technology expands the feature space of minority fault samples to alleviate data scarcity, while Dirichlet prior smoothing optimizes conditional probability estimation in Bayesian networks, resolving zero-probability issues caused by insufficient samples. A hierarchical Bayesian network architecture is constructed by incorporating domain knowledge and data-driven structure learning, enabling a dual-mode diagnosis strategy that combines rapid fault node inference with indirect attribute node analysis. The experimental results based on real industrial data demonstrate that the proposed method achieves high diagnostic accuracy and interpretability under imbalanced data scenarios. The solution provides real-time performance, precision, and transparency for coal mill fault diagnosis, offering significant engineering value.

**Key words:** Bayesian network; fault diagnosis; unbalanced data; coal mills

磨煤机制粉系统是燃煤电厂的重要辅助设备, 其运行状态直接影响锅炉燃烧效率和机组整体经

济性<sup>[1]</sup>。磨煤机一旦发生煤粉细度异常、设备振动或磨损等典型故障, 不仅会降低燃烧效率, 还可能

收稿日期: 2025-03-01

基金项目: 辽宁省“揭榜挂帅”项目(2023JH1/10400050)

Supported by: “Unveiling the List and Appointing the Leader” Project of Liaoning Province (2023JH1/10400050)

第一作者简介: 张涛(1981), 男, 硕士, 正高级工程师, 主要研究方向为电力系统安全稳定、新能源接入、智慧电厂, lobsterzt@163.com。

通信作者简介: 刘乐源(1996), 女, 博士研究生, 主要研究方向为工业过程故障诊断方法, liuleyuan\_NEU@163.com。

引发结渣、积灰、甚至锅炉灭火等恶性事故,严重威胁机组安全和经济运行<sup>[2-3]</sup>。研究表明,磨煤机故障会显著增加锅炉的能耗水平和污染物排放,对电厂安全、稳定运行构成重要隐患<sup>[4]</sup>。因此,研发高效、精准且具可解释性的磨煤机故障诊断方法,对保障电厂安全与经济性运行具有重要工程应用价值。

然而,工业现场采集的故障数据普遍存在显著类别不平衡特性,尤其是少数类(低频)故障数据极为稀缺<sup>[5]</sup>。由于设备具有较高的可靠性且严重故障数据采集难度大,在实际运行中正常工况或常见轻微故障数据占据绝大多数,严重故障数据则极为稀缺,从而导致数据极度偏斜<sup>[6]</sup>。此类不平衡特性易使传统数据驱动模型在训练过程中被多数类主导,少数类特征被“淹没”,导致模型难以有效识别低频故障,形成系统性诊断盲区<sup>[7]</sup>。尤其在磨煤机这类典型的复杂工业系统中,低频故障往往对应重大隐患,其漏检将带来巨大的经济损失和安全风险<sup>[8]</sup>。

针对不平衡数据下的故障诊断问题,国内外学者开展了大量研究,主要集中在深度学习优化、数据增强以及可解释建模等方向<sup>[9-10]</sup>。深度神经网络(DNN)、卷积神经网络(CNN)和循环神经网络(RNN)凭借强大的特征提取能力,广泛应用于机械设备故障诊断中,在提升诊断精度方面表现突出<sup>[11]</sup>。近年来,集成学习算法如LightGBM、XGBoost等因其高效性和鲁棒性,也在工业故障检测领域得到应用,展现出良好的性能<sup>[12-13]</sup>。

为解决样本不平衡问题,过采样技术成为主流手段。其中,SMOTE(synthetic minority over-sampling technique)通过在特征空间内插值生成少数类样本,显著改善了类别不平衡问题<sup>[14]</sup>。但研究发现,SMOTE及其变种(如Borderline-SMOTE、ADASYN)在高维特征空间易产生“模式偏移”现象,合成样本可能偏离真实分布,引入噪声,甚至导致模型性能下降<sup>[15-17]</sup>。

另一方面,随着对工业现场可解释性要求的提升,基于贝叶斯网络(Bayesian network, BN)的因果建模方法受到越来越多关注。贝叶斯网络通过有向无环图(DAG)刻画系统内各变量间的因果关系,具有良好的透明性和物理可解释性,能够融合专家知识与历史数据,适用于复杂系统的多故障诊断<sup>[18]</sup>。已有研究将贝叶斯网络应用于旋转机械、燃

气轮机等设备的健康管理与故障诊断,取得了较好的效果<sup>[19]</sup>。相比“黑箱”性质较强的深度模型,贝叶斯网络具备明确的推理路径和可解释性优势,更契合工业现场对安全可控诊断的实际需求<sup>[20-22]</sup>。

尽管如此,当前研究仍存在以下不足:1)深度学习与集成模型虽能提升诊断准确率,但模型结构复杂、可解释性弱,难以满足工业现场对透明决策的需求<sup>[9]</sup>;2)SMOTE类方法在处理高维特征空间时,易引入虚假样本,导致分类边界模糊,影响模型的泛化能力<sup>[14]</sup>;3)贝叶斯网络在小样本条件下易出现“零概率”问题,某些故障模式若历史中未被观测,则其条件概率为零,导致推理失效,且贝叶斯网络结构设计复杂,对专家知识依赖较强<sup>[18]</sup>。

基于上述分析,本文创新性地构建了融合数据增强、先验平滑与机理知识驱动的可解释贝叶斯网络故障诊断框架,形成一套完整的磨煤机典型故障诊断解决方案。所提方法在保持高诊断准确率的同时,显著提升低频故障识别性能和模型可解释性,为燃煤电厂磨煤机系统的智能化和可靠运行提供理论支撑与技术保障。

## 1 理论基础

### 1.1 贝叶斯网络

贝叶斯网络作为一种概率图模型,通过DAG与条件概率分布(CPD)的联合表征,为复杂工业系统的因果推理提供了数学框架<sup>[21]</sup>:

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | \text{Pa}(X_i)) \quad (1)$$

式中:Pa( $X_i$ )为节点 $X_i$ 的父节点集合; $P(X_i | \text{Pa}(X_i))$ 为在父节点条件下节点 $X_i$ 的条件概率分布。

贝叶斯网络的构建包含2个阶段:1)结构学习,确定DAG拓扑关系,基于先验知识或数据驱动完成;2)参数学习,估计条件概率表(CPT),通过频数统计或贝叶斯估计实现。

为缓解故障类别不平衡导致的零概率问题,本文引入Dirichlet先验平滑技术,在每个取值组合中引入适度的先验平滑系数<sup>[22]</sup>:

$$P(X_i | \text{Pa}(X_i)) = \frac{N(X_i, \text{Pa}(X_i)) + \alpha}{N(\text{Pa}(X_i)) + \alpha \cdot |X_i|} \quad (2)$$

式中: $N(X_i, \text{Pa}(X_i))$ 为 $X_i$ 与其父节点的联合频数; $\alpha$ 为先验平滑系数,代表平滑强度。

### 1.2 SMOTE小样本增强

SMOTE是一种面向类别不平衡问题的经典数

据增强方法，其核心机理是通过特征空间插值优化少数类样本分布<sup>[14]</sup>。利用 SMOTE 生成样本示意如图 1 所示。

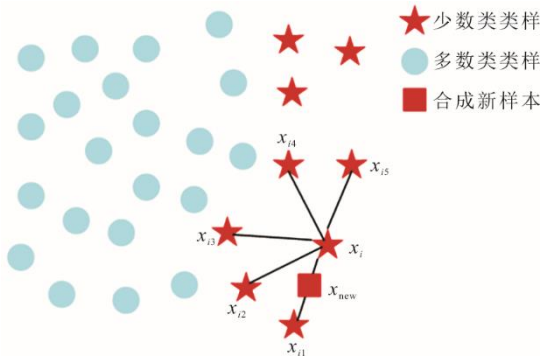


图 1 利用 SMOTE 生成样本示意

Fig.1 Schematic diagram of forming samples using SMOTE

具体步骤如下：  
 1) 对于每个少数类样本  $x_i$ ，找到其在特征空间中的  $k$  个最近邻样本；  
 2) 随机选择其中一个近邻样本  $x_j$ ，通过线性插值运算生成新样本  $x_{new}$ 。

$$x_{new} = x_i + \lambda(x_j - x_i), \lambda \sim U(0,1) \quad (3)$$

式中： $\lambda$ 用于控制插值强度。

## 2 基于贝叶斯网络的不平衡数据故障诊断

本文提出了一种基于贝叶斯网络的不平衡数据故障诊断方法，主要分为离线数据处理、离线知识融合、离线模型学习、在线故障诊断 4 个阶段，故障诊断流程如图 2 所示。

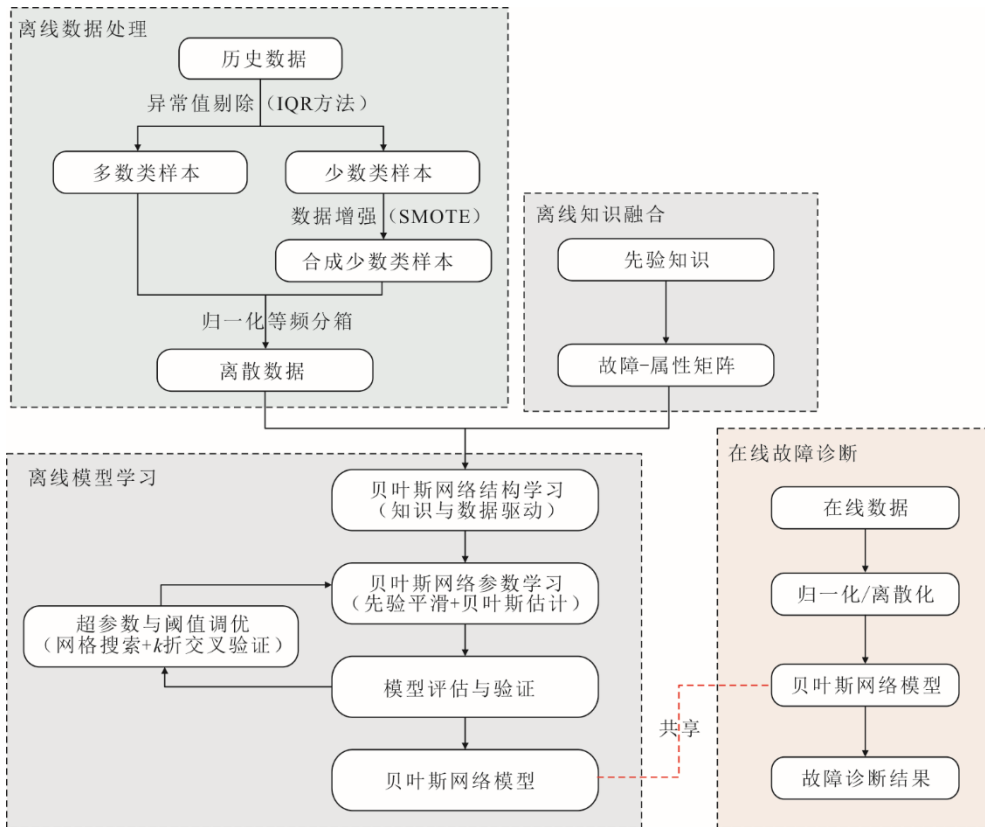


图 2 基于贝叶斯网络的不平衡数据故障诊断方法流程

Fig.2 Flowchart of fault diagnosis method for unbalanced data based on Bayesian network

### 2.1 离线数据处理

#### 2.1.1 数据清洗

根据完整性（缺失率<5%）、合法性（数值在物理量程内）和重复性（删除冗余记录）标准清理数据集，并对检测到的极端异常值采用四分位距法（IQR）剔除。

#### 2.1.2 不平衡数据增强

根据故障标签区分多数类和少数类样本，利用 SMOTE 对少数类样本进行增强，直至少数类样本数量与多数类样本数量相当。

#### 2.1.3 数据归一化和离散化

采用 Min-Max 归一化方法，将连续数据映射到

相同数值区间。基于等频分箱法将归一化数据划分为5个离散区间,确保每个区间样本量的均匀分布。

## 2.2 离线知识融合

工业过程具有一定的领域规则或先验知识可供挖掘,将这类经验融入故障建模中,有助于提高模型的解释性与收敛速度。

### 2.2.1 故障-属性矩阵

梳理常见故障对状态属性的影响,将其构建为故障-属性矩阵  $M$ 。

$$M = \begin{bmatrix} m_{11} & m_{12} & \cdots & m_{1m} \\ m_{21} & m_{22} & \cdots & m_{2m} \\ \vdots & \vdots & & \vdots \\ m_{M1} & m_{M2} & \cdots & m_{Mm} \end{bmatrix}, m_{ij} \in \{0,1\} \quad (4)$$

式中:矩阵的行表示故障类别,列表示相应属性; $m_{ij}=1$ 表示故障  $i(i=1, 2, \dots, M)$ 会引起属性  $j(j=1, 2, \dots, m)$ 的异常,否则记为0。

### 2.2.2 三层贝叶斯网络架构设计

通过融合领域内的先验知识,三层贝叶斯网络结构示意图如图3所示。

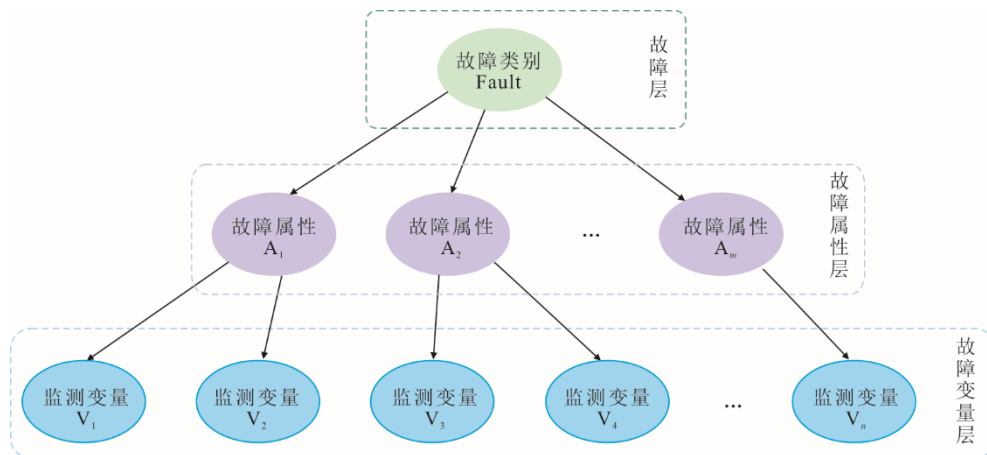


图3 三层贝叶斯网络结构示意图  
Fig.3 Structural diagram of Bayesian network

## 2.3 离线模型学习

### 2.3.1 结构学习

#### 1) 基于先验知识构建初始骨架

强制连接基于专家知识固定“故障节点→故障属性节点”的有向边(对应故障-属性矩阵);开放搜索允许数据驱动算法探索“故障属性节点→监测变量节点”以及属性/变量节点间的潜在因果关系。

#### 2) 基于历史数据进行结构搜索

采用 Hill-Climbing 算法对网络初始骨架进行迭代搜索,进行“增边、删边、反转边”操作,并使用贝叶斯信息准则(Bayesian information criterion, BIC)作为评分指标。

$$BIC(G|D) = \ln P(D|G) - \frac{1}{2} \ln N \cdot |\theta| \quad (5)$$

式中: $\ln P(D|G)$ 为对数似然; $|\theta|$ 为网络参数总量; $N$ 为样本数。并且在搜索过程中添加如下约束:

方向约束 禁止属性/变量节点反向指向故障节点;

白名单 强制保留工艺逻辑确定的有向边(如

属性  $A \rightarrow$  变量  $B$ );

黑名单 禁止物理上无关的节点间连接(如温度属性→振动变量)。

### 2.3.2 参数学习

首先基于数据计算节点与其父节点的联合分布频数,生成初始 CPT;其次采用 Dirichlet 先验平滑,在每个取值组合中引入适度的先验平滑系数(式(2)),以缓解零概率或小概率问题。

### 2.3.3 设定故障诊断策略

在完成贝叶斯网络结构及参数学习后,需要确定故障诊断策略和模型中涉及参数。设定双模式诊断策略如下:

1) 故障节点直接推断 输入实时监测变量证据,计算故障节点后验概率;若最大后验概率超过设定阈值  $\tau$ ,则输出对应故障类别;否则标记为“未知故障”。

2) 属性节点间接推断 输入实时监测变量证据,计算故障属性节点后验概率,二值化为异常模

式：与故障-属性矩阵进行相似度匹配（余弦相似度  $> \tau_2$ ），输出最匹配故障或“未知故障”。

2.3.4 参数联合优化

模型中的重要参数包括平滑系数  $\alpha$ 、故障判定阈值  $\tau_1$ 、相似度阈值  $\tau_2$ ，采用网格搜索结合 K 折交叉验证，对参数进行联合优化，以诊断准确率与误报率加权得分（F1 值）为优化目标，确定最优参数组合。

2.4 在线故障诊断

1) 数据预处理

实时观测的监测变量经归一化、分箱后映射为观测层节点取值  $v = \{v_1, v_2, \dots, v_n\}$ 。

2) 故障在线推断

故障节点直接推断 基于贝叶斯推理计算故障节点的后验概率为：

$$\{P(\text{Fault} = f_i | V = v)\} \quad (6)$$

当最大后验概率大于等于  $\tau_1$  时，输出对应故障类别；否则标记为“未知故障”。

属性节点间接推断 基于贝叶斯推理计算各属性节点的后验概率，并转换为属性异常模式；与故障-属性矩阵进行相似度匹配。当相似度大于等于  $\tau_2$  时，输出对应故障类别；否则标记为“未知故障”。

至此，建立了一套系统化的贝叶斯网络故障诊断流程，为最终运维决策提供重要参考。所提方法充分结合专家知识与数据驱动优势，避免全人工设定带来的主观性，提升了模型的自适应能力和工程可推广性，具有良好的智能诊断应用前景。

3 案例分析

3.1 实验背景

为验证本文所提方法的有效性，选取东北某超临界燃煤发电机组实际运行中的磨煤机数据作为实验对象。磨煤机制粉过程简化示意如图 4 所示，其核心任务是将原煤研磨成满足燃烧要求的煤粉，并通过一次风输送至锅炉。

实验所用数据由电厂 DCS（distributed control system）自动采集，涵盖磨煤机制粉系统的正常工况及多重典型故障工况，采样周期为 1 min，有效反映机组运行状态的动态变化，采集内容覆盖磨煤机运行过程中的关键参数和状态特征，数据全面、具有代表性。

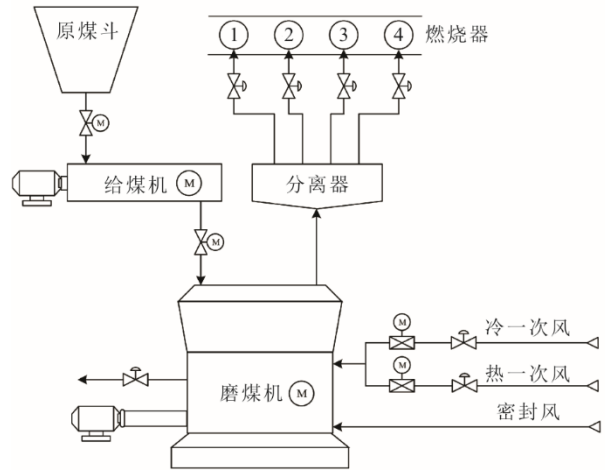


图 4 制粉过程简化示意  
Fig.4 Schematic diagram of a simplified coal pulverizing process

本研究共选取了 12 个关键监测变量，具体包括：V1 冷风阀开度（%）、V2 热风阀开度（%）、V3 进煤流量（t/h）、V4 原煤水分（%）、V5 一次风量（m<sup>3</sup>/h，标况）、V6 一次风温（℃）、V7 磨煤机内原煤量（t）、V8 磨煤机内煤粉量（t）、V9 磨煤机电流（A）、V10 吹出煤粉量（t/h）、V11 出口温度（℃）和 V11 煤粉中水分质量分数（%）。上述变量不仅准确反映制粉系统的运行状态，同时也具备较强的典型故障模式的表征能力，为建模提供了全面、有效的输入信息。

在此基础上，结合工程经验与专家知识，本文选取了 6 类典型磨煤机故障（表 1），并提炼出相应的 8 项故障属性（表 2），构建了完整的故障-属性矩阵（图 5）。该矩阵为模型结构设计和因果推理提供支撑。其中，“故障节点-故障属性节点”的关联由专家知识确定，“监测变量-故障属性”之间的依赖关系则通过贝叶斯网络结构学习算法自动生成，使得模型结构同时兼顾领域先验与数据驱动特性，更贴近工业现场的实际需求。

表 1 磨煤机故障类型及故障描述  
Tab.1 Fault types and descriptions of coal mills

编号	故障类型	故障描述
F1	磨辊磨盘磨损	磨煤能力下降、煤粉颗粒变粗、运行噪声增大
F2	轴承过热或损坏	轴承温度升高、设备振动异常、运行不稳定
F3	密封风泄漏	煤粉外逸、粉尘污染、设备磨损加剧
F4	磨煤机振动过大	设备运行振动幅度加剧、运行状态不稳定
F5	出粉管堵塞	出口压力升高、出力下降、煤粉堆积
F6	煤粉细度不达标	出粉细度不符合要求，影响燃烧效率

表 2 磨煤机故障属性描述  
Tab.2 Description of fault attributes of coal mills

编号	故障属性							
A1	磨煤机部件物理磨损情况							
A2	设备运行时的振动强度							
A3	设备轴承的工作温度							
A4	密封风系统的泄漏程度							
A5	磨煤机出口处的压力状态							
A6	设备运行时产生的噪声大小							
A7	输出煤粉颗粒的细度指标							
A8	磨盘上下或两侧的压差状态							

F1	1	1	0	0	0	1	1	0
F2	0	1	1	0	0	1	0	0
F3	1	0	0	1	1	0	0	0
F4	1	1	0	0	0	0	0	1
F5	0	0	0	0	1	0	1	1
F6	0	0	0	1	0	0	1	1
	A1	A2	A3	A4	A5	A6	A7	A8

图 5 磨煤机制粉过程故障-属性矩阵

Fig.5 fault-attribute matrix of the coal pulverizing process

### 3.2 实验设置

为提升模型的可复现性和工程实用性，在数据预处理过程中完成了完整性检测、异常值剔除及归一化处理，确保数据质量满足后续建模和算法验证需求。

为模拟工业现场中常见的故障数据不平衡情况，设计了典型的不平衡实验场景。训练集中，多数类故障样本数量为 480 条，而少数类故障仅为 20 条，样本比例达到 24:1，充分体现实际运行中低频故障的稀缺性。测试集则为平衡数据集，各类故障样本均为 480 条，可全面评估模型在低频故障识别方面的泛化能力与鲁棒性。

消融实验方面，固定 F6（煤粉细度不达标）为少数类故障，依次评估 SMOTE 增强、Dirichlet 先验平滑及两者联合应用的效果。同时，为进一步验证模型的稳健性与泛化能力，设定单类少数类与多类少数类等不同实验情境，评估模型在多样化不平衡结构下的表现。

实验性能评价指标包括准确率、精确率、召回率和 F1 值，其中召回率和 F1 值重点关注少数类故障的诊断效果，衡量模型对低频故障的识别能力。

此外，为全面对比验证本文方法的优势，选取完全基于专家知识构建的贝叶斯网络（Knowledge-based BN）、完全基于数据学习的贝叶斯网络（Data-based BN）、卷积神经网络（CNN）以及 XGBoost 等主流方法作为对比对象，在相同数据集与评估标准下展开性能对比，分析不同方法在极端不平衡场景下的表现。

### 3.3 实验结果与分析

#### 3.3.1 消融实验

消融实验结果见表 3。由表 3 可知，本文方法在消融实验中表现出明显优势。

表 3 消融实验结果  
Tab.3 Results of ablation experiments

对比方法	故障节点直接推断				属性节点间接推断			
	准确率	精确率	召回率	F1 值	准确率	精确率	召回率	F1 值
MLE	0.845 8	0.929 1	0.845 8	0.798 1	0.839 9	0.922 7	0.839 9	0.791 8
SMOTE+MLE	0.895 5	0.949 1	0.895 5	0.900 8	0.895 1	0.949 2	0.895 1	0.900 7
先验平滑	0.833 3	0.874 3	0.833 3	0.790 9	0.833 3	0.888 8	0.833 3	0.787 1
SMOTE+先验平滑	0.985 0	0.986 2	0.985 0	0.985 0	0.917 5	0.966 9	0.917 5	0.928 7

1) MLE 方法（无 SMOTE 和先验平滑）基础模型在少数类故障上的表现较差，召回率和 F1 值明显偏低（如 F1 值为 0.798 1），显示出传统方法难以应对数据不平衡场景；

2) SMOTE+MLE 方法引入 SMOTE 数据增强后，召回率和 F1 值显著提升（F1 值达到 0.900 8），

说明特征空间内插值生成的样本有效扩展了少数类样本的分布范围，增强模型学习能力；

3) Dirichlet 先验平滑方法单独应用先验平滑效果较为有限，F1 值提升幅度不大（F1 值为 0.790 9），表明其在样本稀缺下难以独立弥补数据分布问题；

4) SMOTE+Dirichlet 先验平滑两者联合应用

时, F1 值和召回率均达到 0.985 0, 说明增强与平滑的协同作用有效缓解了数据稀疏与零概率问题, 提升了模型对低频故障的识别能力。

### 3.3.2 多场景鲁棒性验证

表 4 展示了不同单一少数类故障情形下的诊断结果。无论以 F1、F4、F5 为少数类, 还是其他故障情形, 本文方法在准确率、精确率、召回率及 F1 值上均表现优异, 其中多项指标可达或接近 100%, 表明所提方法在多种少样本场景下具有一致性与稳定性。

进一步, 表 5 列出了 2 个或 3 个少数类故障共存的情形下的模型性能:

2 类少数类场景 模型依旧保持高准确率, F1 值维持在 0.98 以上, 显示其具备良好的扩展能力。

3 类少数类场景 在样本间无交互干扰的情况下, SMOTE 生成的各类故障样本被有效建模, 模型反而表现出更强的推理能力与因果判断能力, F1 值与单类情形基本持平甚至略有提升。

尽管“属性节点间接推断”模式在整体精度上略低于直接推断, 但其提供的属性级异常分析结果为故障定位与溯因分析提供了可解释支撑。在工程实践中, 该模式可辅助运维人员进一步判断故障根源与影响路径。

表 4 单一少数类故障诊断结果  
Tab.4 Diagnosis results of single minority class fault

少样本故障	故障节点直接推断				属性节点间接推断			
	准确率	精确率	召回率	F1 值	准确率	精确率	召回率	F1 值
1	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0
2	0.979 2	0.981 5	0.979 2	0.979 1	0.974 2	0.980 8	0.974 2	0.975 8
3	0.990 8	0.991 3	0.990 8	0.990 8	0.944 2	0.984 1	0.944 2	0.958 3
4	1.000 0	1.000 0	1.000 0	1.000 0	0.988 3	1.000 0	0.988 3	0.994 0
5	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0
6	0.985 0	0.986 2	0.985 0	0.985 0	0.917 5	0.966 9	0.917 5	0.928 7

表 5 多个少数类故障诊断结果  
Tab.5 Diagnosis results of multiple minority class fault

少样本故障	少样本故障数量	故障节点直接推断				属性节点间接推断			
		准确率	精确率	召回率	F1 值	准确率	精确率	召回率	F1 值
1/2	2	0.987 5	0.988 2	0.987 5	0.987 4	0.981 7	0.988 2	0.981 7	0.984 2
3/4		0.992 5	0.992 8	0.992 5	0.992 5	0.992 5	0.992 8	0.992 5	0.992 5
5/6		0.986 7	0.987 7	0.986 7	0.986 6	0.973 3	0.992 1	0.973 3	0.981 4
2/5		1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0
1/2/5	3	0.997 4	0.998 2	0.998 9	0.997 8	0.995 4	0.992 1	0.993 2	0.996 5
3/4/6		1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0
1/3/6		0.998 9	0.999 5	0.999 6	0.998 7	0.997 2	0.998 7	0.997 7	0.975 3

### 3.3.3 对比实验

为进一步验证本文方法在极端数据不平衡条件下的优越性, 选取 4 种代表性方法进行对比实验:

1) 完全基于专家知识构建的贝叶斯网络 (Knowledge-based BN); 2) 完全基于数据驱动的贝叶斯网络结构学习方法 (Data-based BN); 3) 典型深度学习模型—卷积神经网络 (CNN); 4) 主流集成学习模型 XGBoost。

上述方法均在相同的训练集 (极度不平衡) 与测试集 (各类均衡) 条件下进行实验评估, 评价指标包

括精确率、召回率、F1 值和准确率, 结果见表 6。

实验结果表明: Knowledge-based BN 在结构合理性方面具备优势, 精确率较高, 但因缺乏数据适应能力, 召回率明显偏低, 难以有效识别低频故障; Data-based BN 能够挖掘部分统计依赖关系, 但结构不稳定, F1 值波动较大; CNN 与 XGBoost 在多数类上表现良好, 整体准确率较高, 但在识别少数类故障时效果一般。相比之下, 本文所提出的方法在 4 项指标中均表现最优, 尤其在召回率和 F1 值上显著领先, 充分体现出其在低频故障识别中的鲁棒性与有效性。

表 6 对比实验结果  
Tab.6 Results of the comparative experiments

对比方法	精确率	召回率	F1 值	准确率
Knowledge-based BN	0.854 2	0.936 5	0.732 1	0.821 7
Data-based BN	0.881 4	0.912 8	0.768 4	0.834 0
CNN	0.895 7	0.917 5	0.792 3	0.850 6
XG-Boost	0.902 1	0.928 9	0.804 7	0.862 2
本文所提方法	0.985 0	0.986 2	0.985 0	0.985 0

综上，本文构建的融合 SMOTE 数据增强与 Dirichlet 先验平滑的三层贝叶斯网络模型，兼顾领域知识与数据驱动特性，具有良好的适应性和可解释性，在复杂工业场景中展现出突出的实用价值与推广潜力。

### 3.3.4 可解释性验证与工业应用价值

在本文所构建的三层贝叶斯网络结构中，属性节点不仅作为故障节点与监测变量之间的中介桥梁，还为模型提供了良好的可解释性基础。通过“属性节点间接推断”机制，模型可根据实时监测数据推断出故障属性的异常状态，并结合图 5 所示的故障-属性矩阵，实现对具体故障类型的归因推断。

例如：当属性 A3（轴承温度）被判定为异常时，模型倾向于判定为 F2（轴承过热或损坏），提示运维人员重点关注轴承润滑状态或冷却系统；当属性 A5（出口压力）与 A7（煤粉细度）同时异常，系统识别为 F5（出粉管堵塞），建议检查煤粉输送管道是否存在积灰或堵塞；若出现 A2（设备振动）与 A8（磨盘压差）异常，可能指向 F4（磨煤机振动过大），提示检查内部构件磨损或运行不平衡问题。

相比“故障节点直接推断”模式，间接推断在精度上略有下降，但可通过属性组合形成更丰富的物理归因路径，显著提升模型的透明性与可解释性。同时，对于误判情况，属性层输出也便于溯源分析。例如，在某次 F4 误判中，实际原因是 A8 压差波动异常，提示故障模式存在部分重叠，进一步验证了属性层的重要性。

综合来看，属性节点不仅提升了模型的多层推理能力，而且在工业实践中提供了面向专家的“诊断解释接口”，有助于实现从“结果预测”向“机制解释”的转变，满足智能诊断系统对可解释性的核心需求。

## 4 结论与展望

本文提出的融合 SMOTE 小样本增强和

Dirichlet 先验平滑的分层贝叶斯网络方法，有效提升了磨煤机少数类故障的识别能力和模型可解释性，验证了其在实际电厂数据下的工程适用性和推广价值。未来可结合在线监测系统，进一步优化模型实时诊断能力，拓展至其他复杂设备场景，并探索自适应更新机制，提升模型的长期鲁棒性与智能化水平。

### [参考文献]

- [1] 樊帅, 肖军. 锅炉制粉系统故障诊断方法[J]. 热力发电, 2015, 44(2): 13-17.  
FAN Shuai, XIAO Jun. Fault diagnosis method of pulverizing system in utility boilers[J]. Thermal Power Generation, 2015, 44(2): 13-17.
- [2] 钱虹, 张现涛. 基于 PCA-FINCH 的磨煤机故障诊断方法[J]. 热力发电, 2023, 52(9): 147-154.  
QIAN Hong, ZHANG Xiantao. Fault diagnosis method of coal mill based on PCA-FINCH[J]. Thermal Power Generation, 2023, 52(9): 147-154.
- [3] 姚天杨, 茅大钧, 韩万里. 基于 DPC-MND 和多元状态估计的磨煤机故障预警研究[J]. 控制工程, 2024, 31(5): 928-937.  
YAO Tianyang, MAO Dajun, HAN Wanli. Research on fault warning of coal mills based on DPC-MND and multivariate state estimation technique[J]. Control Engineering of China, 2024, 31(5): 928-937.
- [4] 袁存波, 田亮. 基于改进证据理论的中速磨煤机故障诊断[J]. 华北电力大学学报(自然科学版), 2022, 49(6): 84-91.  
YUAN Cunbo, TIAN Liang. Fault diagnosis of medium speed coal mill based on improved evidence theory[J]. Journal of North China Electric Power University (Natural Science), 2022, 49(6): 84-91.
- [5] JIANG X, ZHENG J, ZHUANG X, et al. Ensemble data augmentation for imbalanced fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-12.
- [6] 赵小强, 李森. 不平衡数据下的轻量化轴承故障诊断方法[J]. 电子测量与仪器学报, 2024, 38(10): 244-254.  
ZHAO Xiaoqiang, LI Sen. Fault diagnosis method for lightweight bearings under unbalanced data[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(10): 244-254.
- [7] 毕凤荣, 郭明智, 毕晓阳, 等. 数据不平衡情况下的柴油机故障诊断方法[J]. 天津大学学报(自然科学与工程技术版), 2024, 57(8): 810-820.

- BI Fengrong, GUO Mingzhi, BI Xiaoyang, et al. Diesel engine fault diagnosis method for imbalanced data[J]. Journal of Tianjin University (Science and Technology), 2024, 57(8): 810-820.
- [8] YUE Y, HAMID R K, LEN G, et al. MSIFT: a novel end-to-end mechanical fault diagnosis framework under limited & imbalanced data using multi-source information fusion[J]. Expert Systems with Applications, 2025, 274: 126947.
- [9] 李川, 伍依凡, 杨帅. 不平衡分布的数据驱动故障诊断的研究进展[J]. 仪器仪表学报, 2023, 44(8): 181-197. LI Chuan, WU Yifan, YANG Shuai. Research progress of fault diagnostics driven by imbalanced data distribution[J]. Chinese Journal of Scientific Instrument, 2023, 44(8): 181-197.
- [10] WANG C J, XU Z L. An intelligent fault diagnosis model based on deep neural network for few-shot fault diagnosis[J]. Neurocomputing, 2021, 456: 550-562.
- [11] ZHU J, JIANG Q, SHEN Y, et al. Application of recurrent neural network to mechanical fault diagnosis: a review[J]. Journal of Mechanical Science and Technology, 2022, 36(2): 527-542.
- [12] SABERI A N, BELAHCEEN A, SOBRA J, et al. LightGBM-based fault diagnosis of rotating machinery under changing working conditions using modified recursive feature elimination[J]. IEEE Access, 2022, 10: 81910-81925.
- [13] LIANG Z, ZHANG L, WANG X. A novel intelligent method for fault diagnosis of steam turbines based on T-SNE and XGBoost[J]. Algorithms, 2023, 16(2): 98.
- [14] 王晓霞, 李雷孝, 林浩. SMOTE 类算法研究综述[J]. 计算机科学与探索, 2024, 18(5): 1135-1159. WANG Xiaoxia, LI Leixiao, LIN Hao. Survey of research on SMOTE type algorithms[J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(5): 1135-1159.
- [15] DEY I, PRATAP V. A comparative study of SMOTE, borderline-SMOTE, and ADASYN oversampling techniques using different classifiers[C]//2023 3rd international conference on smart data intelligence (ICSMDI), IEEE, 2023: 294-302.
- [16] 周萱, 吴伟丽. 基于改进 SMOTE 不均样本处理和 IHPO-DBN 的变压器故障诊断方法研究[J]. 电力系统保护与控制, 2024, 52(11): 21-30. ZHOU Xuan, WU Weili. Transformer fault diagnosis method based on improved SMOTE unbalanced sample processing and IHPO-DBN[J]. Power System Protection and Control, 2024, 52(11): 21-30.
- [17] 刘云鹏, 和家慧, 许自强, 等. 基于 SVM SMOTE 的电力变压器故障样本均衡化方法[J]. 高电压技术, 2020, 46(7): 2522-2529. LIU Yunpeng, HE Jiahui, XU Ziqiang, et al. Equalization method of power transformer fault sample based on SVM SMOTE[J]. High Voltage Engineering, 2020, 46(7): 2522-2529.
- [18] HOU Y, YANG A, GUO W, et al. Bearing fault diagnosis under small data set condition: a Bayesian network method with transfer learning for parameter estimation[J]. IEEE Access, 2022, 10: 35768-35783.
- [19] 郑伟, 姚远, 刘乐源, 等. 基于贝叶斯网络的制粉系统安全控制方法[J]. 控制工程, 2023, 30(3): 560-569. ZHENG Wei, YAO Yuan, LIU Leyuan, et al. Safety operation control for the coal pulverizing system based on Bayesian network[J]. Control Engineering of China, 2023, 30(3): 560-569.
- [20] MINJIE F, HAIDONG S, MINGHUI S, et al. Utilizing Bayesian generalization network for reliable fault diagnosis of machinery with limited data[J]. Knowledge-Based Systems, 2024, 305: 112628.
- [21] DOOYOUL L, INU L, YOUNGCHAN K, et al. Sensor set optimization by functional model and Bayesian network for fault diagnosis of turbine generator lubrication system[J]. Engineering Applications of Artificial Intelligence, 2024, 138(B): 109416.
- [22] 张栋梁, 汪刘峰, 洪勤勤, 等. 基于模糊贝叶斯网络的汽轮机组故障诊断研究[J]. 计算机仿真, 2022, 39(7): 476-481. ZHANG Dongliang, WANG Liufeng, HONG Qinqin, et al. Research on fault diagnosis of turbo-generator set based on fuzzy Bayesian network[J]. Computer Simulation, 2022, 39(7): 476-481.

(责任编辑 邓玲惠)