

DOI: 10.19650/j.cnki.cjsi.J2107434

# 基于贝叶斯网络的磨煤机过程异常工况诊断 模型实时更新方法\*

常玉清, 康孝云, 王福利, 赵炜炜

(东北大学信息科学与工程学院 沈阳 110819)

**摘要:**磨煤机作为火电厂制粉系统的核心设备,依靠新磨煤机投入使用后仅有的少量异常工况数据,建立其异常工况诊断模型,对整体系统安全运行有着重要的意义。本文首先针对磨煤机三个典型异常工况建立异常工况诊断模型,并提出新的基于节点辨识的贝叶斯网络模型实时更新方法。将已有磨煤机成熟的异常工况诊断模型作为源域模型,利用目标域磨煤机仅有的少量新数据信息,搜索源域模型与新数据信息不匹配的节点。在保留源域模型有用信息的前提下,通过局部更新,依据新的数据信息完成目标域模型的更新补足。为了验证方法的有效性,将所提方法应用于磨煤机异常工况诊断过程,实验结果表明,更新得到的模型具有良好的性能,平均诊断正确率超过98%。

**关键词:**磨煤机;异常工况诊断;贝叶斯网络;实时更新;局部更新;节点辨识

**中图分类号:** TP181 TH165.3 TM621.7 **文献标识码:** A **国家标准学科分类代码:** 510.80

## Real-time updating strategy for Bayesian network-based coal mill process abnormality diagnosis model

Chang Yuqing, Kang Xiaoyun, Wang Fuli, Zhao Weiwei

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

**Abstract:** Coal mill is the core equipment of coal pulverizing system in the thermal power plant. It is of great significance for system safety to formulate the abnormality diagnosis model based on a small amount of data when the new coal mill is into production. In this paper, the diagnosis model based on three typical abnormalities in the process of coal mill is firstly established. A new real-time updating strategy for the Bayesian network (BN) model based on node identification is proposed. Taking the abnormality diagnosis BN of existing coal mills as the source domain model and using the small amount of new data of the coal mill in the target domain, the nodes that do not match the new information could be found out. Retaining the useful information of the source domain model, the target domain model will be updated and supplemented according to the new data through local updating. To verify the proposed method, the method is applied to the diagnosis process of abnormality. Experimental results show that the updated model has good performance, and the average correct rate of diagnosis is more than 98%.

**Keywords:** coal mill; abnormality diagnosis; Bayesian network; real-time updating; local updating; node identification

## 0 引言

磨煤机是火电厂制粉系统的核心设备,用来将煤块压碎并碾磨成煤粉,由一次风输送至炉膛供给燃烧。在工业过程中,磨煤机存在长时间高负荷运转、运行环境恶劣、系统结构复杂等情况,这些都大大增加了磨煤机故障

发生的概率,故障一旦发生,将直接影响整个火电系统的运行。因此能够在故障发生之前,通过异常工况诊断,提早发现问题,处理问题,防患于未然,对系统的安全运行有着重要意义。取决于磨煤机工作环境、运行时间、煤料质量等,异常工况的发生具有一定的随机性,同时由于异常工况的发生往往会带来巨大的安全威胁,电厂也不会主动模拟异常工况来获得数据,这些都使得异常工况数

收稿日期:2021-01-26 Received Date: 2021-01-26

\* 基金项目:国家自然科学基金(61873053)项目资助

据获取困难。特别是对于新投入使用的磨煤机设备,仅依靠新设备有限数据建立的异常工况诊断模型无法满足实际工业要求。

目前,在磨煤机安全控制领域,一些研究成果被相继提出。Wei 等<sup>[1]</sup>、Gao 等<sup>[2]</sup>、Cortinovis 等<sup>[3]</sup>通过对磨煤机过程进行精确的机理建模,实现了对磨煤机运行监测以及行为预测,然而在异常工况和故障诊断领域,工况的复杂多样使得基于机理的方法应用难度增大。李晓彬等<sup>[4]</sup>、Jian 等<sup>[5]</sup>和 Han 等<sup>[6]</sup>分别采用基于深度神经网络和模糊决策聚类的方法实现了磨煤机故障预警、故障诊断,杨耀权等<sup>[7]</sup>基于 LSSVM 算法通过混合建模的方法对磨煤机过程变量的预测进行了研究。这些基于数据驱动的方法<sup>[4-7]</sup>能够在故障、异常数据充足的情况下有着良好的表现,然而对于缺少历史数据的新磨煤机设备,上述方法依然难以适用。

在类似情境下,闫浩等<sup>[8]</sup>提出一种基于贝叶斯网络(Bayesian network, BN)的参数迁移学习方法,将多个源域的完备模型与目标域有限数据信息相结合,得到目标域模型参数,实现对电熔镁炉异常工况的识别。相比于其他机器学习方法,BN 除了拥有良好的数据学习能力外,对专家知识以及工作经验等也有着极高的利用率,可以完全依靠先验知识以及专家知识确定模型的初步结构和参数,在数据不完备的情况下,有着广泛的应用<sup>[9-11]</sup>。然而,这种基于 BN 的参数迁移学习方法只能根据已知信息完成目标域模型结构的搭建,对目标域未知的、潜在的连接关系则是无法获得。因此如何依靠少量数据获得目标域模型潜在的、特有的结构成为要解决的关键问题。

BN 模型更新包括参数更新和结构更新两部分,其中结构更新是现如今 BN 研究的重点。Li 等<sup>[12]</sup>提出了一种新的混合增量学习算法,改进了 BIC 评分函数并给出了网络进行增量学习的评价准则。实验结果表明,增量学习可以大幅提高算法效率,同时减少存储空间。Hu 等<sup>[13]</sup>提出了一种样本分布发生变化时的 BN 结构更新方法,突破了算法对固定底层数据分布的依赖。然而,这些方法都忽视了已有模型对新模型建立的积极作用。Li 等<sup>[14]</sup>提出一种基于节点辨识的模型结构局部更新方法,在保留模型中能够适应新环境的结构的同时,对不能适应环境变化的节点进行结构更新。受该方法的启发,结合迁移学习,本文给出在仅有少量目标域异常工况数据的情况下,基于节点辨识局部更新的 BN 模型实时更新方法,具体包括针对性设计了基于 KL 散度的节点辨识函数以及相应的节点更新学习方法等。这些方法能够实现对目标域模型参数的获取和潜在结构关系的确定,在保留源域模型有用信息的情况下,实现目标域模型的结构补足和参数的更新。同时通过动态的模型评价标准实现对模型更新的跟踪和监督,促进更优模型的获得。

经过比较和筛选,本文选取一组典型异常工况作为研究对象,结合异常工况可能的原因、现象以及异常工况数据得到 BN 异常工况诊断模型。进一步,对本文提出的 BN 更新策略进行仿真验证。仿真结果显示,本文提出的 BN 更新方案实现了在少量数据情况下目标域磨煤机异常工况诊断模型的实时更新,同时,更新后的模型有着很好的异常工况诊断性能。

## 1 磨煤机异常工况诊断的贝叶斯网络模型

### 1.1 贝叶斯网络

贝叶斯网络又称信念网、概率依赖图等,是目前不确定知识表达和推理领域最有效的模型之一<sup>[15]</sup>,现已被广泛应用到多个领域<sup>[14,16-18]</sup>。BN 通过有向无环图来表示,如图 1 所示。

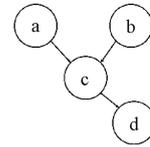


图 1 BN 网络简单结构图

Fig. 1 Simple BN model

图 1 中节点代表事件,弧表示事件之间的因果关系,将条件概率分布表(conditional probability table, CPT)给定节点,用于表示相关节点之间的互相影响程度。将新的信息作为证据输入到网络中,通过 BN 推理机制,参考式(1),可以得到目标事件的后验概率。

$$P(c|a,b,d) = \frac{P(a)P(b)P(c|a,b)P(d|c)}{P(a)P(b)P(d)}$$

$$\frac{P(c|a,b)P(d|c)}{P(d)} \quad (1)$$

### 1.2 KL 散度

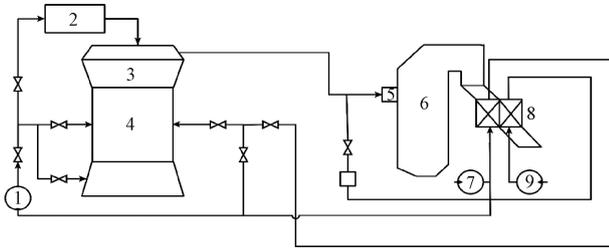
KL 散度(Kullback-Leibler divergence),又称相对熵、信息散度,是对同一随机事件  $x$  的两个独立概率分布  $P_x$  和  $Q_x$  间差异的非对称衡量,事件  $x$  的 KL 散度  $D_x(P_x \| Q_x)$  计算方式如下:

$$D_x(P_x \| Q_x) = \sum_{k=1}^{r_x} P_{xk} \ln \left( \frac{P_{xk}}{Q_{xk}} \right) \quad (2)$$

式中:  $r_x$  表示事件  $x$  的状态数;  $P_{xk}$  和  $Q_{xk}$  分别表示概率分布  $P_x$  和  $Q_x$  中事件  $x$  第  $k$  个状态的概率。在本文中  $P$  和  $Q$  分别代表实时数据统计得到的概率分布和 BN 网络中已有的概率分布,基本思想是借助基于 KL 散度设计的记分函数来搜索模型中与实时数据不匹配度较大的节点,对这些节点进行更新最终实现模型与数据的匹配。

### 1.3 磨煤机故障分析

本文以 MPS-HP-II 型中速磨煤机为研究对象,图 2 中给出了该型磨煤机所属的正压直吹式制粉系统,该系统以磨煤机为核心,配备有给煤机、送风机、粗粉分离器



- 1. 密封风机 2. 给煤机 3. 粗粉分离器 4. 磨煤机 5. 燃烧器
- 6. 锅炉炉膛 7. 一次风机 8. 空气预热器 9. 送风机

图 2 正压直吹式制粉系统结构

Fig. 2 Structure of positive pressure direct fired pulverizing system

一次风是输送煤粉进入炉膛供给燃烧的载体,同时还起到干燥煤粉、驱散磨煤仓热量的作用,是影响磨煤机安全运行的重要因素。通过调节冷、热风阀门的开度,可以实现对一次风风量以及风温的调节。风煤比表示实时的一次风量与给煤量的比例,当系统处于低风煤比时会导致煤粉输送效率下降、煤粉干燥不充分、煤粉管煤粉沉积、磨煤仓热量堆积等,若长期处于低风煤比环境,不进行相应的维护处理,将加剧异常工况的程度甚至导致磨煤机故障的发生。本文选取风煤比相关的 3 个典型异常工况为研究对象,来建立 BN 异常工况诊断模型。通过对磨煤机过程的机理分析,得到该典型异常工况的可能发生原因及现象,如图 3 所示。

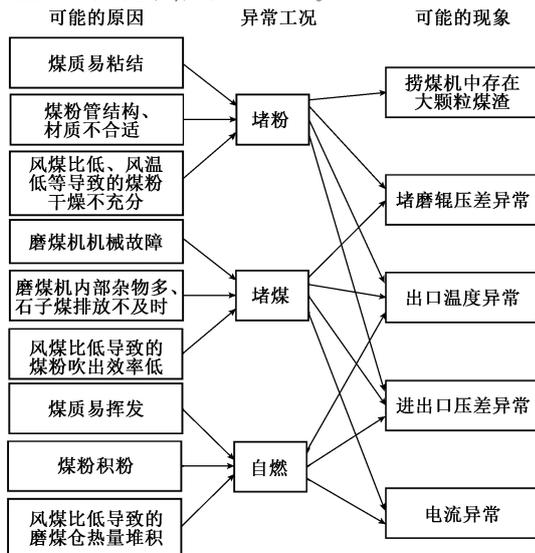


图 3 磨煤机典型异常工况原因、现象关联图

Fig. 3 Cause and phenomenon correlation diagram of typical abnormalities of coal mill

### 1.4 基于贝叶斯网络的磨煤机异常工况诊断模型

磨煤机常年处于高负荷的运行状态,运行时间长且工作环境恶劣,会出现轴承、碾磨件的磨损断裂,风管积粉,气密性下降等问题,这些问题和隐患会导致新投入使用磨煤机(目标域磨煤机)与现有磨煤机(源域磨煤机)异常工况诊断模型存在局部结构差异。结合对异常工况原因及现象的分析,本文以风煤比作为源域模型与目标域模型的差异点,分别构建了以低风煤比为主的中低风煤比环境下的源域磨煤机异常工况诊断 BN 模型,和以正常风煤比为主的中高风煤比环境下的目标域磨煤机异常工况诊断 BN 模型。

参考 Gao 等<sup>[19]</sup>、Hu 等<sup>[20]</sup>的研究成果,结合实际项目中磨煤机机理信息及实例数据,我们团队搭建了磨煤机机理模型,该模型可以在机理分析和实际数据的基础上,对磨煤机运行过程、异常工况及自愈控制等真实生产过程进行模拟,实现对磨煤机过程的优化控制、运行过程信息监测等。

利用机理模型给出的相关数据分别对构建的源域和目标域模型进行充分训练。图 4、5 分别给出了源域磨煤机和目标域磨煤机的异常工况诊断模型结构。表 1 为两模型各节点的物理含义及其划分等级。

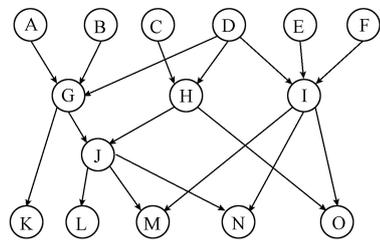


图 4 源域磨煤机异常工况诊断模型

Fig. 4 BN-based diagnosis model under the abnormality in source domain of coal mill

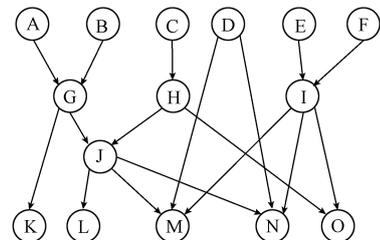


图 5 目标域磨煤机异常工况诊断模型

Fig. 5 BN-based diagnosis model under the abnormality in target domain of coal mill

表 1 节点的物理含义及划分的等级

Table 1 Physical meanings and the grades of nodes

贝叶斯网络节点	节点物理含义	节点等级划分
A	一次风风温	1. 较低 2. 正常 3. 较高
B	煤质是否易粘结	1. 易粘结 2. 非易粘结
C	排渣阀阀门开度	1. 低开度 2. 其他
D	风煤比	1. 较低 2. 正常 3. 较高
E	煤质是否易挥发	1. 易挥发 2. 非易挥发
F	磨煤机内部是否存在积粉	1. 存在积粉 2. 不存在积粉
G	堵粉	1. 发生 2. 不发生
H	堵煤	1. 发生 2. 不发生
I	自燃	1. 发生 2. 不发生
J	堵煤或者堵粉	1. 发生 2. 不发生
K	捞煤机中是否存在大颗粒煤渣	1. 存在大颗粒煤渣 2. 不存在大颗粒煤渣
L	磨煤机磨辊压差	1. 较低 2. 正常 3. 较高
M	磨煤机进出口压差	1. 较低 2. 正常 3. 较高
N	磨煤机出口温度	1. 较低 2. 正常 3. 较高
O	磨煤机电机电流	1. 较低 2. 正常 3. 较高

## 2 BN 模型的实时更新方法

### 2.1 一种新的 BN 模型迁移学习方法

由于目标域模型与源域模型存在很多相似之处,通常仅有参数和部分结构不同,因此本文提出一种新的 BN 模型迁移学习方法,在源域模型基础上,依靠实时获得的少量目标域数据信息以及已有的专家知识,通过对源域模型的局部更新来获得目标域模型。具体实时更新步骤如下:

步骤 1:将目标域过程变量数据样本依次添加到样本池中,若到异常工况识别周期,转到步骤 2,否则继续收集数据。

步骤 2:将样本池中的数据输入到现有模型中进行推理,对异常工况加以识别,并统计识别正确率,判断识别正确率是否合格,如果合格转到步骤 1,如果不合格,判断是否需要进行结构更新,需要执行步骤 3,不需要执行步骤 4。

步骤 3:BN 结构更新学习,结构更新方法见节 2.3,结构更新后转到步骤 4。

步骤 4:BN 参数更新学习,参数更新方法见节 2.2,参数更新后转到步骤 5。

步骤 5:用更新得到的 BN 模型替代现有的模型,转到步骤 1。

### 2.2 贝叶斯网络参数循环更新学习方法

BN 模型的参数是指模型中事件的条件概率分布表,当新的数据信息可以利用时,可以使用新的数据信息更新现有的参数。本文提出循环更新代替批量更新的方法完成对网络的参数更新,进而实现 BN 的渐进更新。该方法一方面可以避免过程数据的延迟使用导致的过程数据信息利用率下降的问题,另一方面可以避免由于 BN 的延迟更新导致的长期诊断准确率不高的问题。参数学习更新方法具体步骤如下:

步骤 1:收集目标域过程数据;

步骤 2:辨识现有模型中不适应目标域数据环境的节点作为参数更新的目标节点;

本文在 KL 散度函数的基础上,给出了参数不匹配节点的辨识函数如下:

$$scoreKL(X_i) = \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} P_{ijk} \ln \left( \frac{P_{ijk}}{Q_{ijk}} \right) \quad (3)$$

式中:  $P_{ijk} = m_{ijk} / \sum_{k=1}^{r_i} m_{ijk}$ ,  $m_{ijk}$  表示满足第  $i$  个节点的父节点状态为  $j$ ,自身状态为  $k$  的数据的个数。 $P_{ijk}$  和  $Q_{ijk}$  分别是来自数据统计和模型中的第  $i$  个节点在父节点状态为  $j$  时自身状态为  $k$  的条件概率; $q_i$  代表第  $i$  个节点的父节点的备选状态组合个数; $r_i$  代表第  $i$  个节点的状态个数;设定阈值为  $\delta$ ,当  $\Delta scoreKL(X_i) < \delta$  时,说明节点  $X_i$  的现有

参数与新的数据信息相匹配,节点不需要参数更新,可以保留现有参数;当  $\Delta score_{KL}(X_i) \geq \delta$  时,说明节点  $X_i$  的现有参数与新的数据信息不匹配,节点需要进行参数更新,以记分最大的节点为目标更新节点,执行步骤3。

基于小样本进行参数更新时,追求暂时的 BN 参数与数据信息完全匹配是没有必要的,从长期来看参数必然也是不准确。辨识函数的设定方式体现的是对模型参数与数据信息一致性的期望,同时为未来可能的结构更新服务。

因此,当所有节点在该数据集下的 KL 散度都小于设定的阈值  $\delta$  时,即满足一致性期望时,转到步骤4。

步骤3:利用新数据信息对目标节点进行参数更新;

局限于样本池内新数据的数量,不能直接使用从新数据中统计得到的  $P_{ijk}$  替换模型中的  $Q_{ijk}$ ,本文通过引入遗忘因子,在模型参数  $Q_{ijk}$  的基础上通过加权的方式,不断修正模型的参数,直到满足 KL 散度的阈值要求,参数更新函数如下:

$$Q'_{ijk} = \alpha P_{ijk} + (1 - \alpha) Q_{ijk} \quad (4)$$

式中:  $Q'_{ijk}$  是用于参数更新的由新旧参数加权得到的概率;  $\alpha$  为遗忘因子,  $\alpha \in (0, 1)$ 。该方法相比完全替代的方案,采用的是一种相对温和保守的方法,在小样本池概率分布不准确的情况下,这种方法对错误有较高的容忍度。在遗忘因子  $\alpha$  的数值设定时需要考虑  $Q'_{ijk}$  的数值的构成。在节点经历  $l$  次参数更新后,模型原有参数  $Q_{ijk}$  所占的数值比重降为  $(1 - \alpha)^l$ , 当  $(1 - \alpha)^l$  趋近于 0 时,  $Q'_{ijk}$  的数值将完全由新数据信息构成,遗忘因子  $\alpha$  的数值设定表现了我们希望通过对目标节点的  $l$  次参数更新实现对新数据信息的匹配。

一次参数更新循环周期结束,转到步骤2。

步骤4:参数更新结束。

### 2.3 贝叶斯网络结构学习方法

本节将介绍提出的 BN 结构更新学习方法,其目的在于利用仅有的少量数据信息在源域模型的基础上,补足目标域模型结构,具体步骤如下:

步骤1:基于数据集数据,辨识模型中不适应目标域数据环境的节点作为结构更新目标节点;

不同于参数更新,结构更新的节点辨识函数对辨识的准确性和有效性有着较高的要求。在参数更新的节点辨识式(3)的基础上,给出了新的结构更新节点辨识函数,具体改进原因如下:1)对于式(3),节点条件概率的数量会对记分数值产生很大影响,这一情况在小数据集背景下尤为明显;2)由于小数据集数据不完备,某些极低概率父节点状态组合所对应的条件概率数值会发生较大的数值波动。因此,为抑制以上不利影响,改进记分函数为如下形式:

$$\Delta score_{KL}(X_i) = \frac{1}{q_i} \sum_{j=1}^{q_i} e^{\mu Q_{ij}} \sum_{k=1}^{r_i} P_{ijk} \ln \left( \frac{P_{ijk}}{Q_{ijk}} \right) \quad (5)$$

式中:  $Q_{ij}$  表示模型中节点  $i$  第  $j$  个父代组合的发生概率;  $\mu$  为常数。这种设计方法一方面通过均值的方式平衡了不同体量条件概率节点之间的差异;另一方面在抑制可能出现的波动的同时,尊重小概率事件的概率波动,通过调节常数  $\mu$  可以实现二者的均衡。设定结构更新阈值  $\omega$ ,取超过阈值的记分最大的节点进行更新。若暂时无记分超过阈值,暂时无法进行更新,则结构更新结束。

步骤2:利用可用的专家知识和工作经验确定目标节点的可选父节点集。

当有可用的专家知识和工作经验时,可以提前确定目标节点的备选父节点集,缩小算法的搜索范围,方便快捷搜索。

步骤3:利用新的数据信息搜索最佳的网络结构。

本文采用 BIC 记分函数来衡量备选结构与新数据信息的匹配程度,以 Zhu 等<sup>[21]</sup>的研究成果为基础,给出完全面向目标域新数据信息的 BIC 记分函数如下:

$$score_{BIC}(X_i) = \frac{1}{q_i} \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} P_{ijk} \ln P_{ijk} - \beta q_i (r_i - 1) \ln m \quad (6)$$

记分函数包含两个部分,前一项是目标节点的备选结构与实时数据匹配程度的衡量,后一项是对模型结构复杂程度的惩罚。其中  $\beta$  为常数,用来调节目标函数期望与结构记分在数值上的差别。记分函数的值越大,搜索得到的备选结构与新数据信息的匹配越好。

步骤4:如果搜索到记分更高的结构,选取记分最高的备选结构对源域模型结构进行补足,并替代现有结构;若不存在,认为本次学习无效。结构更新结束。

### 2.4 模型动态推理参考正确率设计方法

在本文中,仿真过程由模型更新过程和模型异常情况诊断应用过程组成。在应用过程中,设定最低模型推理正确率标准,低于该标准说明数据信息与模型不匹配;在更新过程中,同样设定一个参考推理正确率作为更新的参考,监督更新过程,促使模型更新更加高效。

为了让方案能够搜索到更优的模型结构,充分发挥模型的性能,梯度函数式(7)给出更新过程中的模型推理正确率参考值,具体函数如下:

$$Rsta\_up = \gamma * (R_k - Rsta_{k-1}) * e^{-|R_k - Rsta_{k-1}|} \quad (7)$$

式中:  $Rsta_k, R_k$  分别指模型更新过程中第  $k$  个模型周期时推理正确率的参考值和推理正确率的值,  $\gamma$  为常数。  $Rsta_k = Rsta_{k-1} + Rsta\_up, Rsta_0 = 1$ 。模型更新过程中,模型推理正确率的合格标准为  $|R_k - Rsta_{k-1}| \leq \tau, \tau$  为一个较小的常数,当模型连续几个周期的正确率都能够合格时,判定更新得到现有条件下最优的贝叶斯网络模型。更新结束时,最终的模型推理正确率将作为模型的理论

推理正确率。

推理应用过程中,模型推理正确率的合格标准为模型推理正确率大于等于最低推理正确率。因此在模型更新结束时,将现有样本池数据按一定数量随机等分为多份进行推理并统计正确率,将最低正确率作为新的最低推理正确率。

### 3 仿真分析

#### 3.1 基于 Asia 网络的仿真研究

为了验证方法的有效性,本节使用经典的 Asia 网络<sup>[22]</sup>进行理论上的仿真验证。用于更新学习的源域 Asia 网络模型如图 6 所示。为了模拟模型更新学习过程,本实验设计生成目标域数据的 BN 模型如图 7 所示,源域模型的数据由图 6 采样产生。Asia 网络中,仅将节点 E 设定为目标推理节点,其他直接或间接节点作为证据节点服务于节点 E 的推理,并无实际物理意义。

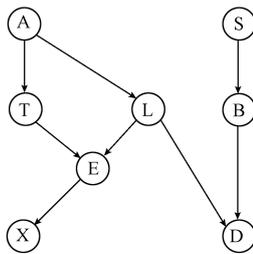


图 6 源域 Asia 网络

Fig. 6 Source domain Asia network

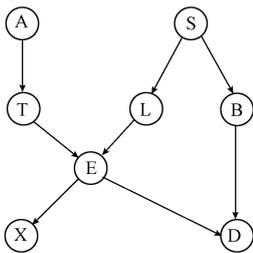


图 7 目标域 Asia 网络

Fig. 7 Target domain Asia network

实验中,将数据依次放入样本池,每累积固定数量的数据作为一个更新周期,进行一次模型推理。仿真过程由 3 个连续的时间段组成,第 1 时间段是展示源域模型在源域数据信息下稳定运行的推理应用过程如图 8 横坐标 0~10;第 2 时间段是模型在目标域的新数据信息下进行模型更新学习的过程如图 8 横坐标 11~32;第 3 时间段是更新学习结束,新模型在新数据信息下稳定运行的推理应用过程如图 8 横坐标 33~60。不同于 1、3 阶段只针对当前周期新数据进行推理正确率统计,第 2 阶段是用上一周期更新得到的模型,对从模型更新开始后的完整数据集进行的推理正确率统计。图 8 中给出了一次仿真过程中模型推理正确率的变化情况。

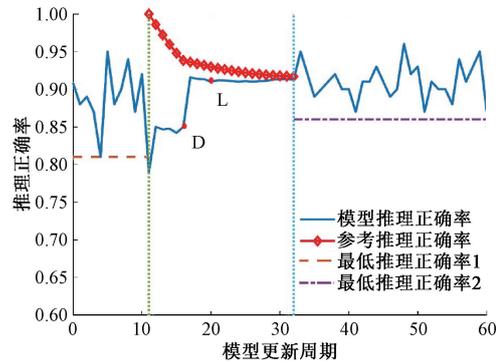


图 8 模型更新周期内模型推理正确率变化情况

Fig. 8 Change of reasoning accuracy rate in the process of model updating

表 2 给出了目标域数据信息下模型第一次参数更新,对应图 8 横坐标为 11 的节点时。几个循环周期里各节点的 KL 散度记分情况。这里设定参数更新阈值  $\delta = 0.001$ ,每次循环仅取记分最大的节点更新,其他节点参数不做更新,表中对每次进行更新的节点进行了加粗标记。前 9 个循环周期都是对节点 D 的参数更新,随着更新节点 D 与当前数据的匹配度逐渐上升,记分逐渐减小,直到第 10 个循环周期节点 L 成为当前记分最大节点并进行参数更新。

表 3 中给出了第二个模型更新周期对应图 8 横坐标为 12 的节点时触发第二次参数更新后,两次参数更新循环周期里各个节点的 KL 散度记分情况。明显,相比于

表 2 第 1 次参数更新过程中节点的 KL 散度记分变化

Table 2 KL divergence scores of different nodes in the first parameter updating process

事件节点	A	S	T	L	B	E	X	D
第 1 次记分	0.000 3	0.002 6	0.042 1	0.662 1	0.005 2	0.114 7	0.031 8	<b>3.411 9</b>
第 2 次记分	0.000 3	0.002 6	0.042 1	0.662 1	0.005 2	0.114 7	0.031 8	<b>2.579 8</b>
第 3 次记分	0.000 3	0.002 6	0.042 1	0.662 1	0.005 2	0.114 7	0.031 8	<b>2.039 9</b>
第 10 次记分	0.000 3	0.002 6	0.042 1	<b>0.662 1</b>	0.005 2	0.114 7	0.031 8	0.584 0
第 11 次记分	0.000 3	0.002 6	0.042 1	0.480 1	0.005 2	0.114 7	0.031 8	<b>0.584 0</b>

表3 第2次参数更新过程中节点的KL散度记分变化

Table 3 KL divergence scores of different nodes in the second parameter updating process

事件节点	A	S	T	L	B	E	X	D
第1次记分	0.001 7	0.000 3	0.002 7	0.066 2	0.006 1	0.140 5	0.016 4	<b>1.241 9</b>
第2次记分	0.001 7	0.000 3	0.002 7	0.066 2	0.006 1	0.140 5	0.016 4	<b>0.421 3</b>

表1中第一次参数更新触发时的记分情况,已有部分节点记分数值有了明显的减少,这说明了第一次参数更新的有效性,同时也说明第一次参数更新由于数据数量少导致的参数更新的不完备和局部过拟合问题。进一步,结合图8,可以看出在横坐标11~16(D)的这段时间里,通过参数更新,模型对新数据信息已经有了一定的适应,推理正确率也有了一定的提升。

在经过几次参数更新以及样本池有了一定的数据积累之后,在第6、10次模型更新时触发对模型结构的两次有效更新。表4给出了某两次结构更新时,各个节点的记

分情况。本文提出的算法,在整个更新周期内,会有多次结构更新触发,由于数据信息的不确定性,每次筛选得到的目标节点也会有所不同,不过,由于数据信息导致筛选出的错误节点也无法搜索得到可以替换旧结构的更好的结构。设定结构更新阈值 $\omega = 0.1$ ,被更新的节点依次为D、L。结合图8对于D、L两节点结构更新时间的标注,可以看出,在经历两次有效的结构更新之后,模型推理性能有了显著的提升,具体体现在推理正确率的提升以及正确率稳定性的提升两方面,说明本文提出的基于遗传算法的节点最优结构搜索方法能够实现对最优结构的搜索。

表4 两次结构更新过程中节点的KL散度记分变化

Table 4 KL divergence scores of different nodes in twice structure updating process

事件节点	A	S	T	L	B	E	X	D
1次记分	0.082 5	0.006 6	0.042 7	0.051 4	0.008 6	0.034 9	0.018 4	<b>0.162 5</b>
2次记分	0.060 2	0.024 2	0.014 4	<b>0.139 9</b>	0.013 9	0.014 3	0.028 0	0.026 1

由于方法的局限性,以及小数据集的背景设定,只能在源域模型上进行边结构的补足,无法进行删减。因此,该方法能够得到的最好网络结构如图9所示。

图9中黑色加粗虚线为在源域Asia网络基础上,通过更新学习目标域数据信息得到的新的边。

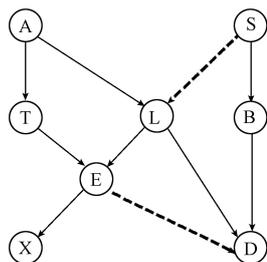


图9 更新得到的目标域Asia网络

Fig. 9 Target domain Asia network after updating

综上所述,基于经典Asia网络,本文提出的算法对于实现新环境的下模型的更新以及模型寻优有着良好的效果。

### 3.2 基于磨煤机运行数据的仿真研究

设置仿真实验,以1.4节的中低风煤比情境下的磨煤机BN异常工况诊断模型作为源域模型,利用机理模型给出的正常风煤比情境下的异常工况数据,按照3.1

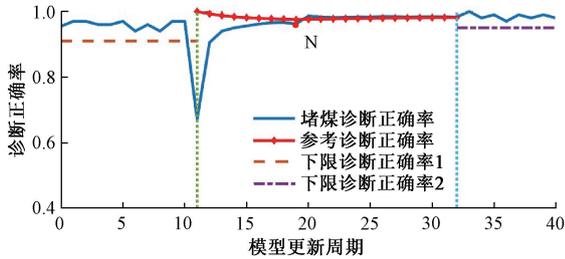
节中的仿真流程,进行目标域的BN模型的更新学习。并将更新得到的模型与1.4节中给出的经过足够数据训练得到的目标域模型进行比较。

由于本小节模型更新过程同Asia网络的理论验证过程类似,这里仅对结构更新部分进行说明。应用在本文提出的BN模型结构更新方法,通过式(5)搜索结构更新的目标节点,得到一次有效结构更新时的节点记分情况如表5所示(设定上,根节点以及节点I不进行结构更新)。设定结构更新阈值 $\omega = 0.5$ ,同时按照搜索规则,每次取记分最大的节点,则搜索到的结构更新节点N。通过对磨煤机运行机理以及常见故障现象的分析,可以确认可选父节点为A、B、C、D、E、F、I和J。进一步,使用基于式(6)的启发式遗传算法搜索节点的最优父节点组合。图10给出了一次仿真测试过程中磨煤机异常工况诊断正确率的变化情况,图10(a)是堵煤诊断正确率变化情况,图10(b)是堵粉诊断正确率变化情况,图10(c)是自然诊断正确率变化情况。以图中“N”标记处(横坐标19),即对节点N进行结构更新的时刻为分界点。分界点前,随着新数据信息的增加,在无有效结构更新,仅靠参数更新的情况下,模型对堵煤、堵粉、自燃的诊断能力都有了下降的趋势,终于在“N”标记处触发对节点N的一次有效结构更新;更新后,总体推理正确率有了明显的提升,曲线总体逐渐趋向于稳定,最终在第22次更

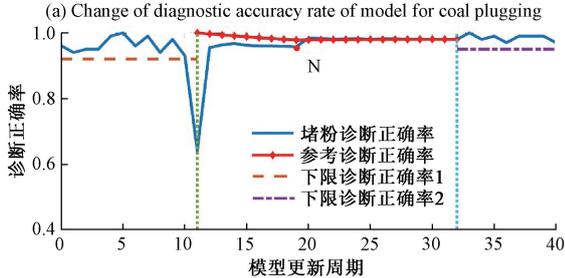
表 5 两次结构更新过程中节点的 KL 散度记分变化

Table 5 KL divergence scores of different nodes in twice structure updating process

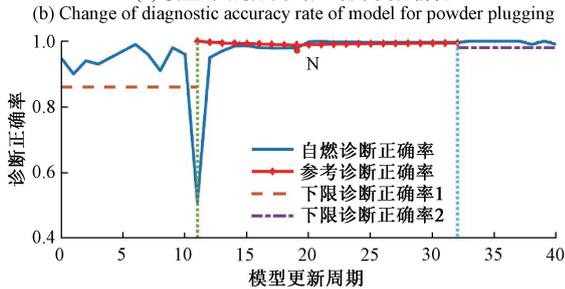
事件节点	G	H	I	K	L	M	N	O
M 更新时	0.360 7	0.028 2	0.091 9	0.023 0	0.072 4	0.155 1	<b>1.287 4</b>	0.047 2



(a) 模型对堵煤的诊断正确率变化情况



(b) 模型对堵粉的诊断正确率变化情况



(c) 模型对自燃的诊断正确率变化情况

(c) Change of diagnostic accuracy rate of model for spontaneous combustion

图 10 模型更新周期内模型异常工况诊断正确率变化情况

Fig. 10 Change of diagnostic accuracy rate of abnormalities in the process of model updating

新结束后(横坐标 32)模型满足了更新完成标准,模型更新结束。并于之后的推理应用中,始终保持良好的推理性能。

为了进一步验证方法的有效性,在模型更新结束后,用 1.4 节给出的目标域诊断模型对用于更新学习的数据集进行推理并统计正确率。取不同数据集进行 10 次 BN 更新学习的仿真实验,记录每次更新得到模型的理论推理正确率及目标域模型的推理正确率,计算平均值,记录在表 6 中。可以看出,两种模型的对相同数据集的推理性能基本一致,说明本文方法更新得到的诊断模型,在其学习数据集所处的信息环境下,拥有着良好的推理性能。

表 6 仿真得到的模型与给定目标域模型诊断正确率比较

Table 6 Comparison of diagnosis accuracy between simulation model and given target domain model

异常工况	堵煤	堵粉	自燃
仿真得到的模型的平均诊断正确率	0.967 7	0.968 6	0.985 6
给定目标域模型的平均诊断正确率	0.958 4	0.972 9	0.973 8

因此,使用本文提出的基于节点辨识的新的 BN 模型更新方法,能够在仅有少量目标域异常工况数据的情况下,通过对源域异常工况诊断模型的局部更新,得到目标域的异常工况诊断模型,同时,更新得到的模型拥有良好的性能。

### 3.3 实际数据测试

为了进一步验证本文方法的实用性,从某火电厂获取新旧两个磨煤机的历史异常工况数据用于实验验证,分别设定为源域(旧)和目标域磨煤机(新),同时利用专家知识和较充足的源域数据获得源域诊断模型。取目标域磨煤机时间相近的 2 000 组异常工况数据,均分为 20 个模型更新周期进行实验。图 11 给出了实验过程中每个模型更新周期的更新前模型对当前周期 100 组数据的异常工况诊断正确率变化情况。从图 11 中可以看出,经历了 1~10 的 10 个周期的更新后,模型已能够保持一个稳定的诊断正确率,每个周期 3 个工况的诊断正确率均超过 97%。之后,针对当前 2 000 组数据,计算得到新模型对堵煤、堵粉、自燃 3 个异常工况的诊断正确率分别为 98.60%、98.15%、98.40%。说明本文所提方法在实际应用中是有效的。

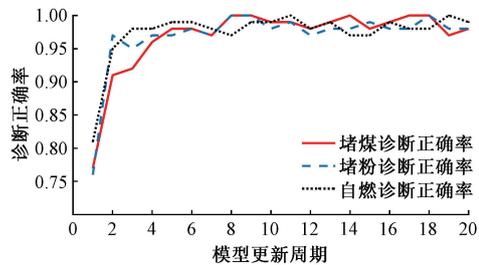


图 11 基于实测数据的模型更新内诊断正确率变化情况

Fig. 11 Change of diagnostic accuracy rate in the process of model updating based on measured data

## 4 结 论

如何在仅有少量异常工况数据情况下,实现磨煤机异常工况诊断模型建立的问题,本文提出了一种基于节点辨识的BN模型的更新策略。本文首先对磨煤机异常工况进行了分析,结合数据信息,建立了源域和目标域两个不同环境下的异常工况诊断模型用于仿真实验。之后,本文详细介绍了提出的BN模型更新策略,包括参数、结构更新学习方法,动态模型推理参考正确率等。在仿真测试过程中,首先使用经典Asia模型对提出的策略进行验证,结果表明,所提出的更新策略是有效的,具有较好的模型精度。进一步,将本文所提出的贝叶斯网络模型更新策略应用于磨煤机异常工况诊断模型的更新,仿真和实际应用结果均表明,该策略能够依靠少量数据,在源域模型的基础上,实现对目标域异常工况诊断模型的有效更新,更新得到的模型具有良好的诊断能力,与Asia网络的仿真结果相符合。

### 参考文献

- [ 1 ] WEI J L, WANG J, WU Q H. Development of a multisegment coal mill model using an evolutionary computation technique [ J ]. IEEE Transactions on Energy Conversion, 2007, 22(3): 718-727.
- [ 2 ] GAO Y K, ZENG D L, LIU J ZH. Modeling of a medium speed coal mill [ J ]. Powder Technology, 2017, 318: 214-223.
- [ 3 ] CORTINOVIS A, MERCANGÖZ M, MATHUR T, et al. Nonlinear coal mill modeling and its application to model predictive control [ J ]. Control Engineering Practice, 2013, 21(3): 308-320.
- [ 4 ] 李晓彬,牛玉广,葛维春,等.基于改进堆叠自编码网络的电站辅机故障预警[J].仪器仪表学报,2019,40(6):39-47.  
LI X B, NIU Y G, GE W CH, et al. Early fault warning of power plant auxiliary engine based on improved stacked autoencoder network [ J ]. Chinese Journal of Scientific Instrument, 2019, 40(6): 39-47.
- [ 5 ] JIAN Y F, QING X G, ZH Y, et al. Application of model-based deep learning algorithm in fault diagnosis of coal mills [ J ]. Mathematical Problems in Engineering, 2020, DOI:10.1155/2020/3753274.
- [ 6 ] HAN X, JIANG X. Fault diagnosis of pulverizing system based on fuzzy decision-making fusion method [ J ]. Fuzzy Information and Engineering, 2009, 22: 1045-1056.
- [ 7 ] 杨耀权,刘建兵.基于混合建模的磨煤机一次风量预测算法研究[J].仪器仪表学报,2016,37(8):1913-1919.
- [ 8 ] 闫浩,王福利,孙钰洋,等.基于贝叶斯网络参数迁移学习的电熔镁炉异常工况识别[J].自动化学报,2020,DOI:10.16383/j.aas.c200104.  
YAN H, WANG F L, SUN Y F, et al. Abnormal condition identification based on Bayesian network parameters transfer learning for the electro-fused magnesia [ J ]. Acta Automatica Sinica, 2020, DOI: 10.16383/j.aas.c200104.
- [ 9 ] 李荟,王福利,李鸿儒.电熔镁炉熔炼过程异常工况识别及自愈控制方法[J].自动化学报,2019,DOI:10.16383/j.aas.c180333.  
LI H, WANG F L, LI H R. Abnormal condition identification and self-healing control scheme for the electro-fused magnesia smelting process [ J ]. Acta Automatica Sinica, 2019, DOI: 10.16383/j.aas.c180333.
- [ 10 ] OJHA R, GHADGE A, TIWARI M K, et al. Bayesian network modelling for supply chain risk propagation [ J ]. International Journal of Production Research, 2018, 56(17): 5795-5819.
- [ 11 ] BRAHIM I B, ADDOUCHE S A, MHAMED I A E, et al. Build a Bayesian network from FMECA in the production of automotive parts: Diagnosis and prediction [ C ]. Berlin: IFAC Conference on Manufacturing Modelling, Management and Control MIM, 2019, 53(13): 2572-2577.
- [ 12 ] LI S, ZHANG J, SUN B, et al. An incremental structure learning approach for Bayesian network [ C ]. Changsha: Proceedings of the Twenty Sixth Chinese Control and Decision Conference (CCDC), 2014: 4817-4822.
- [ 13 ] HU J Q, ZHANG L B, TIAN W H, et al. DBN based failure prognosis method considering the response of protective layers for the complex industrial systems [ J ]. Engineering Failure Analysis, 2017, 79: 504-519.
- [ 14 ] LI H, WANG F L, LI H R, et al. The updating strategy for the safe control Bayesian network model under the abnormality in the thickening process of gold hydrometallurgy [ J ]. Neurocomputing, 2019, 338(C): 237-248.
- [ 15 ] YAN H, WANG F L, HE D K, et al. Bayesian network-based modeling and operational adjustment of plantwide flotation industrial process [ J ]. Industrial & Engineering Chemistry Research, 2020, 59(5): 2025-2035.

- [16] CABRERA D, GUAMÁN A, ZHANG SH H, et al. Bayesian approach and time series dimensionality reduction to LSTM-based model-building for fault diagnosis of a reciprocating compressor [J]. *Neurocomputing*, 2020, 380: 51-66.
- [17] 刘旭明,唐求,邱伟,等. 基于 ZINB 层次贝叶斯智能电能表的可靠性预估[J]. *电子测量与仪器学报*, 2019, 33(7):28-36.
- LIU X M, TANG Q, QIU W, et al. Reliability evaluation and prediction of smart meters based on ZINB hierarchical Bayesian [J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 33(7):28-36.
- [18] 朱坚民,张雷,翟东婷,等. 基于声音多特征贝叶斯网络融合的话者识别研究[J]. *仪器仪表学报*, 2013, 34(9): 2058-2067.
- ZHU J M, ZHANG L, ZHAI D T, et al. Speaker recognition research based on voice multi-feature Bayesian network fusion [J]. *Chinese Journal of Scientific Instrument*, 2013, 34(9): 2058-2067.
- [19] GAO Y K, ZENG D L, LIU J ZH. Modeling of a medium speed coal mill[J]. *Powder Technology*, 2017, 318: 214-223.
- [20] HU Y, PING B Y, ZENG D L, et al. Research on fault diagnosis of coal mill system based on the simulated typical fault samples [J]. *Measurement*, 2020, 161: 107864.
- [21] ZHU Y, LIU D, CHEN G, et al. Mathematical modeling for active and dynamic diagnosis of crop diseases based on Bayesian networks and incremental learning [J].

*Mathematical and Computer Modelling*, 2013, 58(3-4): 514-523.

- [22] LAURITZEN S L, SPERGELHALTER D J. Local computations with probabilities on graphical structures and their application to expert systems[J]. *Journal of the Royal Statistical Society*, 1998, 50(2): 157-224.

### 作者简介



常玉清,分别在 1998 年和 2002 年于东北大学获得硕士和博士学位,现为东北大学教授,主要研究方向为复杂工业过程建模、监测、运行状态评价及过程优化等。

E-mail: changyuqing@ise.neu.edu.cn

**Chang Yuqing** received her M. Sc. and Ph. D. degree both from Northeastern University in 1998 and 2002, respectively. She is currently a professor at Northeastern University. Her main research interests include the field of industrial process modeling, monitoring, operation performance evaluation, and optimization, etc.



康孝云(通信作者),2019 年于东北大学获得学士学位,现为东北大学硕士研究生,主要研究方向为复杂工业过程的建模控制与优化。

E-mail: kxy1451@163.com

**Kang Xiaoyun** (Corresponding author) received his B. Sc. degree from Northeastern University in 2019. He is currently a master student at Northeastern University. His main research interests include modeling control and optimization of complex industrial processes.