



(12) 发明专利申请

(10) 申请公布号 CN 115769162 A

(43) 申请公布日 2023. 03. 07

(21) 申请号 202180046562.8

(22) 申请日 2021.06.29

(30) 优先权数据

20183283.9 2020.06.30 EP

(85) PCT国际申请进入国家阶段日

2022.12.29

(86) PCT国际申请的申请数据

PCT/EP2021/067918 2021.06.29

(87) PCT国际申请的公布数据

W02022/002977 DE 2022.01.06

(71) 申请人 西门子股份公司

地址 德国慕尼黑

(72) 发明人 托马斯·比尔魏勒

丹尼尔·拉比施 埃里安·西拉

(74) 专利代理机构 北京康信知识产权代理有限公司

11240

专利代理师 沈敬亭

(51) Int.Cl.

G05B 23/02 (2006.01)


权利要求书1页 说明书8页 附图8页

(54) 发明名称

用于在过程技术设施中进行错误原因分析的方法和系统

(57) 摘要

为了在过程技术设施 (1) 中进行错误原因分析, 设施 (1) 的、包含关于设施部件和其在设施 (1) 中的互联的信息的工程信息 (18) 以数字形式提供, 以由该工程信息 (18) 创建呈设施 (1) 的具有概率分布和先验变量的概率物理模型形式的推理模型 (30)。在推理模型 (30) 的诊断模式 (40) 中, 在使用来自设施 (1) 的测量数据的情况下执行错误概率的贝叶斯推理。



1. 一种用于在过程技术设施(1)中进行错误原因分析的方法,其中,所述设施(1)的工程信息(18)以数字形式提供,所述工程信息包括关于所述设施(1)中的设施部件以及所述设施部件的互连的信息,从所述工程信息(18)创建呈所述设施(1)的具有概率分布和先验变量的概率物理模型形式的推理模型(30),并且利用来自所述设施(1)的测量数据在所述推理模型(30)的诊断模式(40)中执行错误概率的贝叶斯推理。

2. 根据权利要求1所述的方法,其特征在于,在使用来自所述设施(1)的所述测量数据的情况下,在所述推理模型(30)的训练模式(39)中执行所述推理模型(30)的贝叶斯推理,其中,表示所述推理模型(30)中的先验的模型参数的估计被优化。

3. 根据权利要求1或2所述的方法,其特征在于,借助于键合图从所述工程信息(18)创建所述推理模型(30)。

4. 根据权利要求1、2或3所述的方法,其特征在于,通过采用模型库的模板(36),从所述设施(1)的所述工程信息、特别是R&I流程图(18)首先生成所述设施(1)的元模型(35),所述模型库包含针对所述设施(1)的每个部件类型的要用于实施所述贝叶斯推理的待生成的代码和推理变量,并且从所述元模型创建所述设施的所述推理模型(30)。

5. 一种用于在过程技术设施(1)中进行错误原因分析的系统,所述设施具有转换模块()和推理模型(30),所述转换模块设计用于从所述设施(1)的工程信息(18)创建呈所述设施(1)的具有概率分布和先验变量的概率物理模型形式的推理模型(30),其中,所述工程信息包含关于所述设施(1)中的设施部件以及所述设施部件的互连的信息,所述推理模型设计用于利用来自所述设施(1)的测量数据在所述推理模型(30)的诊断模式(40)中执行错误概率的贝叶斯推理。

6. 根据权利要求5所述的系统,其特征在于,所述推理模块(30)还设计用于执行所述推理模型(30)的贝叶斯推理,其中,表示所述推理模型(30)中的先验的模型参数的估计被优化。

7. 一种计算机程序产品(21),所述计算机程序产品被加载到计算机(4)的存储器中并且包括软件代码段,当产品在所述计算机上运行时,利用所述软件代码段实施根据权利要求1至4中任一项所述的方法。

用于在过程技术设施中进行错误原因分析的方法和系统

技术领域

[0001] 本发明涉及一种用于在过程技术设施中进行错误原因分析的方法。

[0002] 本发明此外还涉及一种用于在过程技术设施中进行错误原因分析的系统。

背景技术

[0003] 自动化技术用于技术过程的自动化。自动化的整体系统由其中运行过程的设施、自动化系统和操作人员组成。设施尤其能够是来自化学工业、饮料和食品技术、环境技术、制药工业或天然气和石油工业的过程技术或工艺技术设施。

[0004] 这种类型的(工业)设施通常包括多个各个互连的设施部件。工艺或过程技术设施的典型设施部件是容器、反应器、管道、配件等,例如在制造过程中的初始材料(尤其是流体)穿过他们来流动,并因此被改变或加工成最终产品。

[0005] 在自动化系统的近过程现场层级,在设施自动化的范畴中,执行本地分布式、分散式现场设备预设的功能,并且在此与自动化系统的更高层级的自动化部件交换过程、设施和/或设备相关的信息。现场设备包括以过程参数的测量值形式传输过程数据的传感器(例如用于液位、流量、压力和温度的变送器,用于气体或液体分析的分析仪,称重系统)和执行器(用于阀门的位置驱动器,位置调节器,其他分散式调节器和用于例如泵的电动驱动器的变频器),其包括以调节数据的形式的过程数据,以便影响过程。

[0006] 通常需要优化此类设施的经济效率,并减少各个过程参数的值与目标值并进而与设施的运行时间点的偏差,以便使设施运行平稳,更好地遵守质量要求,或者使过程接近其极限运行并提高产量。

[0007] 然而,某些关键偏差不能仅通过调节系统来消除,而是需要额外的对策。如果没有及时发现这些故障,可能会导致差的产品质量,甚至导致设施部件、设施部分甚至整个设施出现故障。

[0008] 自动错误诊断能够通过更快地识别错误情况及时引入对策,以便因此减少甚至防止停机时间。故障诊断(故障诊断(fault detection and isolation), FDI)的任务一方面包括故障的识别,另一方面包括对单个故障类型的隔离,以缩小故障原因的范围。

[0009] 故障诊断方法通常分为两类。一方面存在基于过程模型的方法,其在数学模型中使用测量信号并计算特征值。与此相反的是,的是基于信号的数据驱动方法,其基于历史数据创建设施的黑盒模型或分析相关性[1,第5-6页]。

[0010] 基于模型的方法在状态估计器中,例如在扩展的卡尔曼滤波器(Kalman-Filter)或未知输入观察器(UIO)中(其在状态空间中估计最可能的运行状态或错误状态)分为宇称方程,其利用附加传感器的分析冗余来生成特征化的残留签名,或分为参数估计方法,其确定偏差的参数值并将每个偏差分配给误差源[2,第9页]。

[0011] 基于信号的方法遵循不同的措施。对于简单的信号来说,极限值测试或振动信号模型就足够了,其单独检查信号的值或频率的偏差,相反,统计分类方法或人工智能则用于更复杂的系统。静态方法利用诸如主成分分析(PCA)的方法,通过确定最小数量的独立部件

的然后执行聚类分析来降低系统的阶数。另一方面,机器学习算法根据记录的训练数据优化神经网络或决策树的多个参数[3,第41-43页)。

[0012] 所提及的方法仅给出了主题领域的概述,因为尤其是近年来该领域中的文献已经采用了许多不同的措施。到目前为止,还没有一种方法被证明优于其他方法,这就是为什么以增加的趋势在多个方向上继续进行研究[4,第4-5页]。

[0013] 基于模型的方法需要广泛的系统理解,其在方法技术过程中常常是不存在的。所考虑的过程通常是非线性的、动态的、混合的和复杂的,这意味着,不仅建模成本而且计算成本都极大增加,尤其是在工业大型设施中[1.]。因此,不能简单地转移其他领域的解决方案。同样,测量中的强噪声会使结果失真。

[0014] 由于过程知识常常以测量数据的形式存在,因此在过程工业中更频繁地采用数据驱动方法。主成分分析 (PCA) 和潜在结构投影 (PLS) 在统计方法[5,第267页]以及人工神经网络 (ANN) 和支持向量机 (SVM) 的情况中作为学习方法[6,第4-5页]中尤为普遍。这里的优点是实施过程中涉及的耗费非常小,并且能够将其用作从测量值到错误类型的完整解决方案。

[0015] 然而,通常没有或只有很少关于错误情况的数据,设施操作员不想为了获得这些数据而将他们的设施置于危急情况中。在这种情况下,纯基于信号的模型会失败,因为即使他们能够识别到未知错误并将其与其他错误区分开来,也无法将错误分配给具体的构件或故障。

发明内容

[0016] 因此,本发明的目的在于,基于在混合方法中组合基于模型和基于信号的方法,以便最大化他们的优点并减少他们的缺点。

[0017] 根据本发明,该目的通过权利要求1中给出的方法和权利要求5中给出的系统来实现,其有利的改进方案在从属权利要求中给出。

[0018] 因此,本发明的主题是一种用于在过程技术设施中分析错误原因的方法,其中,设施的、包含关于设施部件及其在设施中的互连的信息的工程信息以数字形式来提供,并且从工程信息创建呈设施的具有概率分布和先验变量的概率物理模型形式的推理模型,并且利用来自设施的测量数据在推理模型的诊断模式中来执行错误概率的贝叶斯推理。

[0019] 本发明还涉及一种用于在过程技术设施中进行错误原因分析的系统,过程技术设施具有转换模块,该转换模块设计用于从设施的、包含关于设施部件及其在设施中的互连的信息的工程信息创建呈设施的具有概率分布和先验变量的概率物理模型形式的推理模型,该推理模型被设计为,利用来自设施的测量数据在推理模型的诊断模式中执行错误概率的贝叶斯推理。

[0020] 在此,工程信息是指过程技术设施的规划数据以及设施结构和部件数据,这些数据存储在设施规划软件(例如COMOS)中或能够从数据表中获取。工程信息尤其能够是机器可读的R&I流程图(管道和仪表流程图),其中包含作为图形对象的设施和自动化的所有相关组件。

[0021] 在推理模型的训练模式中,通过在使用来自设施的测量数据的情况下在推理模型的训练模式中执行推理模型的贝叶斯推理来优化模型参数的估计,其中,模型参数表示推

理模型中的先验。

[0022] 能够以有利的方式借助于键合图从工程信息创建推理模型。键合图适用于分析机电系统,因为他们提供了多个技术领域的统一表示。由于过程技术设施不仅由液压管道系统和机械执行器组成,而且还由电路和信息技术数据流组成,因此这种表示对于识别各种错误类型非常有利。此外,键合图理论为能够在自动运行的系统中使用的R&I流程图的分析提供了一种形式主义。

[0023] 首先,通过采用模型库的模板,能够由设施的工程信息,特别是R&I流程图生成设施的元模型,模型库包含对于设施的每个部件类型的待生成的代码和推理变量,需要对其实施贝叶斯推理。然后,例如能够通过递归函数从远模型创建设施的推理模型。

附图说明

[0024] 下面使用实施例并参考附图来解释本发明;图中详细示出:

[0025] 图1示出了其中执行器和传感器共同作用的技术设施的示例,

[0026] 图2示出了根据本发明的方法的示例性流程图,

[0027] 图3示出了转换模块的类图,

[0028] 图4以方块图示出了示意性简化的键合图,

[0029] 图5示出了元模型的设施结构,

[0030] 图6示出了因子图的简化示例,

[0031] 图7示出了推理模块的类图,

[0032] 图8示出了推理模块的基类的变量类型,

[0033] 图9示出了模型编程的示例,

[0034] 图10示出了推理模型训练期间的设施的因子图,以及

[0035] 图11示出了错误原因诊断中的因子图。

[0036] 相同的附图标记在不同的图中具有相同的含义。附图纯粹是示意性的,不代表任何尺寸比例。

具体实施方式

[0037] 图1以简化示意图示出了过程技术设施1的示例,其中,借助于自动化系统3来控制过程2。自动化系统3包含规划和工程系统4、操作和监控系统5、多个自动化设备6、7、8、9和多个现场设备10、11、12、13、14。规划和工程系统4、操作和监控系统5以及自动化设备6、7、8、9经由总线设施15相互连接。现场设备10、11、12、13、14以不同的方式例如直接经由现场总线或分散的外围设备连接到自动化设备6、7、8、9并承担在过程1中预设的测量功能、控制功能和调节功能,通过现场设备作为传感器识别过程变量的测量值并且作为执行器通过调节干预来影响过程。典型的传感器是用于液位、流量、压力和温度的变送器,用于气体或液体分析的分析仪和称重系统。典型的执行器是用于阀门的位置驱动器、位置调节器、其他分散式调节器和例如泵、加热器、冷却器等的电动驱动器的变频器。自动化设备6、7、8、9读写访问现场设备10、11、12、13、14,并且在此根据控制程序的规定控制过程2,该控制程序由分布在自动化设备上的多个交互的自动化功能模块16组成。

[0038] 规划和工程系统4包含规划和工程软件工具17,例如西门子股份公司的COMOS,借

助于他创建机器可读的R&I流程图(管道和仪表流程图)18,其中,设施1和自动化装置的所有相关组件都可识别为图形对象。对象的特性以属性的形式存储在数据库19中,同样地,对象之间的连接以材料流(例如管道)和信号流(例如测量值)的形式存储。此外,来自对于正常情况和已知的错误情况的设施1的生产操作的历史或模拟测量数据被提供在档案库20(例如云)中。

[0039] 为了分析过程设施1中的错误原因,软件工具21从设施1的现有工程信息(即设施的规划数据和设施结构和部件数据)自动创建设施1的可诊断的概率模型(推理模型),该工程信息存储在设施规划软件中或可从数据表中获取。该推理模型能够通过执行贝叶斯推理基于设施数据确定单个错误原因的发生概率并识别设施的故障部件或组件。软件工具21在这里是规划和工程系统4的组成部分,但也能够在单独的系统中运行。

[0040] 在图2中,示例性地在流程图中示出了根据本发明的用于分析错误原因的方法的基本顺序。该方法由在其中创建上述推理模型30的转换阶段和在其中执行贝叶斯推理的推理阶段,以便一方面训练推理模型并另一方面确定设施1中的单个错误元件的出现概率,并识别故障的设施部件和组件。

[0041] 在转换阶段,转换模块31在具有对于推理来说必要的源文本33和变量值34的推理模型30中实施设施1的R&I流程图18的模型转换32。在此,转换模块31读取存储在COMOS数据库19中的R&I流程图18,并且首先通过从模型库37接管模板36生成设施1的元模型35。模板36描述了设施1的各个部件(例如泵、阀、罐、管道等)的行为,并包含可能的错误原因(例如泄漏、堵塞、降低的泵性能等)。模型库37包含要为每个部件类型生产的代码和必要的推理变量,即需要为实施贝叶斯推理的变量,从而能够从元模型35生成设施1的推理模型30。推理代码基本上能够直接地并且在没有创建元模型的中间步骤的情况下生成。

[0042] 推理在单独的推理模块38中实施,并且例如能够访问Infer.NET框架的功能。Infer.NET是一个用C#编写的开源框架,具有一个推理引擎(“InferenceEngine”),其包含多个用于执行推理的算法。推理的基本原理是基于贝叶斯定理:

[0043] $P(A|B) = [P(B|A) \cdot P(A)] / P(B)$

[0044] A和B是分配给上面因子图中的随机变量的事件。这里B是一个可观察到的效果,并且A是一个隐藏的原因,其确切概率未知。因此,P(A)只是所求概率的先验估计,这就是为什么P(A)被称为先验概率的原因。P(B)是观察B出现的概率,能够通过反复实验来确定。P(B|A)是在A发生的情况下观察到B的条件概率。因此,P(B|A)是因子图中决定A和B之间关系的因子。结果P(A|B)是在观察到B的情况下A发生的条件概率。P(A|B)被认为是一次观察后P(A)的改进估计,这就是为什么他被称为A后验概率或后验概率的原因。随着进行更多的观察,后验概率接近原因A发生的实际概率。在错误诊断中,能够借助于最高的发生概率推断出最可能的错误原因。

[0045] 推理模块38具有两种操作模式,即训练39和诊断40,他们在两个相关类中,即训练41和诊断42类中实现。对于这两种操作模式,历史测量值43、推理源文本32和推理变量33必须首先导入并以合适的形式传递给相应的类。训练类41使用测量值43以优化推理模型31的模型参数(推理参数)的估计,推理模型表示先验(先验分布)。这些再次存储在推理模型30中,这就是推理变量34和推理源文本33被分开存储的原因。在诊断40中,代替地执行错误概率和参数的推断。结果44或者被输出或者被存储用于进一步处理。

[0046] 只有在模板36中限定的各个部件的错误原因才能被自动诊断。替代地,也能够将不仅影响一个部件的其他更复杂的错误原因添加到推理模型30,然而为此必须分析设施1的整体模型。

[0047] 下面更详细地解释通过转换模块31进行的自动模型转换。

[0048] 模型转换32只需要转换设施结构18一次,因此与错误原因分析39、40离线分开执行。图3示意性地示出了转换模块31的类图。转换由用于封装的类“TransformationModule”和用于设施1、设施的部件及其接口的元模型类“Plant”、“Asset”和“Port”组成。在一个与之分开的“AssetLibrary”(模型库37)中收集了管道、过程仪表、泵等各个构件的部件类。

[0049] 由转换模块31建立的元模型35的结构应该尽量地模仿R&I流程图18的结构,因此简化到推理模型30的转换。虽然通过XML出口从COMOS数据库19中获取的元素仅具有属性时,元模型35的类还包含用于代码生成和模型转换的方法。元模型35的属性也特别适合作为推理变量。

[0050] 虽然在R&I流程图18中部件之间的链接主要用于图形表示而不是用于信息交换,但是元模型35为了生成推理模型30需要链接,以便交换推理变量。在此,根据键合图理论,链接被视为双向键合,经由它能够交换任意数量的变量。键合图是可用于模拟能量流的有向图。如图4所示,根据示意性简化的键合图(左)和框图(右)示出,图的节点表示设施的部件A、B,边缘通过说明潜在变量e(原因或效果)和流量变量f(效果或流)限定能量流,他们相互乘法接合。半箭头说明能量流 $e \cdot f$ 的方向。

[0051] 元模型35检查能量方向和键合的类型,其中,确保只有相同类型的端口和输出才能与输入连接,因此避免误诊。借助于元模型类的不同的方法,能够将转换后的资产(部件)添加到设施中或从设施中删除;端口能够彼此连接或断开。例如,由此导致图5中所示设施1的元模型35的设施结构。

[0052] “Plant”、“Asset”和“Port”分别具有一个设施属性的集合,其能够同时转化为推理变量。设施属性包括设施1的,单个组件的和处理过的材料的物理和/或几何数据、测量变量、错误情况以及仅对于推断所需的变量。对于代码生成,部件类接收递归方法,该方法运行包含在模型库37中的资产并借助于模板36为每个资产创建相应的代码。在实施该方法之后,存在源文本文件33,其包括在推理模块38中并且包含特定于设施的推理模型30。代码生成后,所有收集的设施属性(推理变量)的列表被排序并导出到一个单独的文件34。

[0053] 变量是逻辑型(bool)、整型(int)和实数型(double)等数据类型的数学随机变量,取决于他是具有两个值的切换变量、离散(整数)变量还是连续(浮点)随机变量。对于变量能够采用的每个值范围或值,都有一个相关联的概率分布。可能的概率分布例如是连续变量的高斯或正态分布,如多个测量变量,只能取两个值的布尔变量的伯努利分布,用于建模概率(例如错误概率)的贝塔分布,他们本身代表具有分布函数的随机变量。在推理模型30中,随机变量经由因果关系或相关性相互关联,对此能够使用因子图来表示。图6中示例性示出的因子图表示形式为 $B = \text{Factor}(A)$ 的代码行,其中,随机变量A上的操作因子的结果分配给随机变量B。

[0054] 如上所述,在推理引擎38中实施推理,其中,访问Infer.NET框架的功能。为此目的,推理模块38自动将推理模型30映射到设施1的因子图中。

[0055] 下面更详细地解释推理模块38。

[0056] 推理模块38用作为错误原因分析的起点。推理模型30的训练和诊断40的实施能够根据需要离线或在线执行,因此,通过先前执行一次的完成的推理模型30的生成避免了开销。推理模块38基本上由四个类组成,他们在图7中的类图中被详细示出。类“InferenceModule”用于封装所有使用的函数并存储推理变量。基类“InferenceBase”包含所有的推理方法和模型限定,他形成推理模块38的核心并且是所有其他类基于其功能构建。诊断类“InferenceDiagnosis”和训练类“InferenceTraining”继承自这个类并且仅少量修改以适应他们相应的任务。

[0057] 基类包含Init()、CreateModel()、SetPriors()和Infer()四个方法,这些方法按该顺序实施。

[0058] Init()方法初始化所需的变量和Infer.NET的推理引擎。在模型中限定了图8中列出的多个满足不同的任务的变量类型。每种变量类型在训练和诊断中都有不同的功能。

[0059] 例如,常数在这两种情况下都保持不变,并且包括为推理运行指定的自然常数和设施参数。

[0060] 模型参数是描述设施1的正常操作所需要的编程的数学公式的系数并且是其特征。这些参数要么具有物理意义,因此在理论上能够计算,要么没有物理意义,仅作为自由度。Infer.NET能够执行推理而不管建模类型如何,并且因此也能够用作为机器学习方法。尤其在后一种情况中,可能需要使用现有测量数据进行训练,因为起始值通常是随机选择的,因此最初的结果很差。推理优化了训练期间参数的现有估计,以便他们更好地反映训练后的设施行为。在参数已经确定的情况下,如果对这些参数的信心足够高,则能够免除训练。模型参数的含义能够由程序员自由选择,对推理本身没有影响。

[0061] 与模型参数相反,误差参数描述了特定于误差的系数。由于在实际情况中,一个同样的错误可能有不同的程度,因此在训练和诊断中对这些参数实施推断是有意义的。相反,模型参数在诊断阶段应保持恒定。

[0062] 要识别的每个错误类型都有自己的变量和模型。未建模的故障类型在诊断期间无法识别到,并且可能被解释为其他故障类型的组合。每种类型的错误都有一个仅在诊断阶段计算的概率。在训练阶段,错误作为观察到的输入变量传递给系统,因为在历史数据的情况下应该识别已经发生的错误。否则,必须诊断该数据。

[0063] 在训练和诊断中,测量值都作为观察到的变量被输入。此外,应该知道每个测量值的测量准确度,因此能够在模型中为每个测量得出具有正确方差的高斯分布随机变量。

[0064] 内部变量是切换变量、整数或浮点变量或(bool、int、double)形式的中间变量。这些变量需要作为模型内部的中间结果或隐藏变量,用户无法直接访问他们。他们在推理过程中被认为是可变的,但不会反馈任何结果分布。

[0065] 在Init()中初始化之后,在基类的CreateModel()方法中发生模型限定,其中,创建设施1的因子图。模型限定能够在单独的源文本文件中硬编码,或者如上面已经解释的那样,由转换模块31创建。能够交换源文件33以实现不同的模型。能够考虑两种用于建模的方法,其在图9中示例性地示出。

[0066] 在第一个变体方案中,只有布尔变量A接收先验分布Bernoulli(0.5)。然后变量B被分配给变量A上的操作因子的结果。C被分配给B的因子的结果。这类似于传统编程,但相比之下,如果观察到C,则Infer.NET允许使用该限定计算A。如果A与C之间的关系只允许一

种可能的解决方案,那么在这种情况下,先验对A几乎没有影响。在第二个变体方案中,这种编程特性被更强烈地使用。A、B和C得到相同的先验分布,因此,特定解决方案没有偏差。然后,在模型限定中确定操作Factor (A) -B的结果为零,在下面的行中,类似地确定C的相同的条件。该表示等同于推理引擎的第一个变体方案,并且在两个方向的两种情况下都导致相似的结果。然而,与第一个变体方案相比,在第二个变体方案中能够交换行,这对于模型转换来说提供了巨大的优点,因为由此设施的部件能够以任何顺序附加他们的代码,并且不必确定用于运行设施的特殊算法。

[0067] 在SetPriors()方法中设置基于过去的训练运行或设施数据的所有先验分布。图8中的表格说明在哪个阶段分配哪些参数。标记为“常量”的类型在SetPriors()方法中被声明为观察,因为观察到的变量在推理过程中变为常量(参见2.3.3)。将其标记为“观察到”意味着此类变量恰好在Infer()方法中的推理请求之前不久被输入到设施中。每次Infer()调用都会重新观察这些变量类型,而SetPriors()中确定的常量对于每个推理请求保持不变,即他们提供恒定的观察。此外,SetPriors()将模型和误差参数的先验分布设置为由设施属性创建的高斯分布,并设置精度参数。

[0068] 推理模型38的许多任务在基类中实现。然而,在先验分配和模型创建阶段,训练和诊断彼此不同,因此,每个都实现其自己的CreateModel()和SetPriors()方法。在CreateModel()的开始,分别实施基类的初始化方法,然后初始化他们自己的变量并分配先验分布。最后,实施基类的CreateModel()方法。除了ModelParameter和FaultParameter数组,训练类中存在ModelPriors数组,基类中存在FaultPrior数组,诊断类中存在FaultProbs数组。这种划分的原因在根据图8的表中。错误概率仅在诊断期间存在,因为在训练阶段观察到错误的发生。训练期间错误概率的推断只会反映训练期间错误的相对频率。然而,这并不重要,这就是为什么没有针对训练得出概率的原因。同样地,模型参数的先验分布仅存在于训练阶段,因为模型参数是在诊断阶段被确定的。两个阶段都需要误差参数的先验分布,因此在基类中对这些参数实施推理。

[0069] 图10示出了设施1在训练期间的因子图。观察到的变量用灰色标记,而用白色标记的变量值在推理过程中能够发生变化。该因子图中的每个数量代表一组相同类型的变量。根据模型和误差参数的先验,借助于Variable.Random创建随机变量,虽然他们基于先验的值,但能够通过算法自由调整。观察到的错误作为FaultFlags输入到模型中。已发生的错误的被赋值为真(true),未发生的错误的被赋值为假(false)。设施的因子图是在基类的CreateModel()方法中创建的,其中包含由转换模块31创建的推理代码。此代码只能访问此处限定的变量,因此元模型35中的系统属性被分配固定变量类型并且不创建任何新变量。

[0070] 图11示出了诊断期间设施1的因子图,在此期间,模型参数与训练相比被观察并且不能由推理引擎调整。另一方面,错误有自己的模型。这些被视为具有概率FaultProbs的伯努利分布的随机变量。如上所述,概率本身被确定为贝塔(beta)分布并得到固定的先验。例如,在每次诊断之前,重置所有的概率,而推理引擎会被用来在一个方向或另一个方向上纠正这些概率。能够从时间间隔内的校正差异中推断出错误情况。因此,有意义的是,为了记录这种变化,所有概率最初都被视为是均匀分布的。沿0或1的方向校正得越大,关于是否发生错误的结论就越可靠。如果概率保持在0.5,则引擎无法对该错误做出任何结论,或者此

错误的存在对所做的观察没有影响。

[0071] Infer()方法实施推理模型30的推理。作为传输,此方法收到具有测量值和时间戳的数据结构。测量值、采样时间和测量次数作为相应模型变量的观测值被输入。在训练的情况下,还会观察到已经发生的错误。基类“InferenceBase”实施对错误参数的推理、训练类实施对模型参数的推理并且诊断类实施对错误概率的推理。之后,结果作为InferenceParameterSet返回。在训练之后,优化的参数被存储在变量数据库24中。

[0072] 在诊断期间,重新估计所有错误原因的概率。概率显著增加的所有错误原因都能够认为是实际原因。由于经常有很多原因,而比较起来只有几个测量变量,所以一般会输出几个原因,这是有意义的。诊断后,结果44要么经由控制台输出,要么以表格格式输出。

[0073] 根据本发明的方法具有几个优点,其结合了基于模型和基于信号的诊断方法。因此,基于模型的方法需要很高的模型质量,这在复杂的过程设施中很难实现。同样地,通常需要非常高的测量准确度,这会增加成本,如果测量值不准确,这也是这些方法的结果不正确的原因之一。在根据本发明的方法中建模耗费相对较低,并且能够通过训练数据或改变建模来进一步减少。概率编程允许以小的耗费将测量准确度包含在诊断中,因此,尽管数据库很小,但仍能够实现高诊断准确度。同样地,能够识别同时发生的故障和没有历史记录故障,这是基于信号的方法无法做到的。通常,与类似的基于信号的方法(例如神经网络)相比,所使用的方法需要的历史数据要少得多。

[0074] 建模耗费由此变得较低,主要因为不必精确地测量、计算或者以任何其他方式确定模型参数。相反,以正确的数量级设置不准确的初始估计就足够了。然后通过使用测量数据的几次训练迭代找到非常精确的过程参数。同时,Infer.NET专门研究随机变量,因此不需要像其他方法那样对测量误差进行额外建模。通过在建模中包含所有可能的错误状态,能够识别新错误或多个错误。

[0075] 能够为未知错误编程一个单独的类别。该方法比机器学习方法需要更少的历史数据,因为他具有更少的自由度,通常能够确定良好的近似值。

[0076] 本文引用了以下出版物:

[0077] [1.]M.Sayed-Mouchaweh,ed.,Fault Diagnosis of Hybrid Dynamic and Complex Systems,Douai:Springer International Publishing AG,2018

[0078] [2.]S.X.Ding,Model-based Fault Diagnosis techniques,Duisburg:Springer-Verlag Berlin Heidelberg,2008

[0079] [3.]G.Niu,Data-Driven Technology for Engineering System Health Management,Shanghai:Springer Nature,2017

[0080] [4.]C.Aldrich and L.Auret,Unsupervised Process Monitoring and Fault Diagnosis with Machine Learning Methods,Stellenbosch:Springer London Heidelberg New York Dordrecht,2013

[0081] [5.]R.Isermann,Fault-Diagnosis System,Darmstadt:Springer-Verlag Berlin Heidelberg,2006

[0082] [6.]C.Aldrich and L.Auret,Unsupervised Process Monitoring and Fault Diagnosis with Machine Learning Methods,Stellenbosch:Springer London Heidelberg New York Dordrecht,2013。




图1




图2



图3




图3A




图3B




图4




图5




图6




图7

变量模型	训练	诊断
常数 自然常数，设施数据	恒定的	恒定的
模型参数 描述正常情况中的参数	推理	恒定的
错误参数 描述错误特定的参数	推理	推理
错误类型 具有错误概率	观察的	推理
测量 测量变量的说明	观察的	观察的
内部变量 根据 bool-, int-, double-数据类型进行拆分	隐藏的	隐藏的

图8




图9




图10




图11