(19)国家知识产权局

(12)发明专利

(10)授权公告号 CN 112115306 B
(45)授权公告日 2023.04.07

(21)申请号 202010445662.5

(22)申请日 2020.05.22

(65)同一申请的已公布的文献号
申请公布号 CN 112115306 A

(43)申请公布日 2020.12.22

(30)优先权数据
16/448273 2019.06.21 US

(73)专利权人 帕洛阿尔托研究中心公司
地址 美国加利福尼亚州

(72)发明人 D·钟

(74)专利代理机构 中国专利代理(香港)有限公司 72001
专利代理师 吕传奇 陈岚

(51)Int.Cl.
G06F 16/901(2019.01)
G06F 16/906(2019.01)
G06F 18/23213(2023.01)
H04L 67/12(2022.01)
G16Y 10/25(2020.01)
G16Y 20/10(2020.01)
G16Y 20/20(2020.01)
G16Y 40/20(2020.01)

(56)对比文件
US 2015280969 A1,2015.10.01
US 2015280969 A1,2015.10.01
US 2012005532 A1,2012.01.05
US 2018211171 A1,2018.07.26
US 2017228277 A1,2017.08.10
US 2015074035 A1,2015.03.12
CN 104809205 A,2015.07.29
CN 105745604 A,2016.07.06
Sarah Nadi等."DRACA: decision support for root cause analysis and change impact analysis for CMDBs".《https://uwspace.uwaterloo.ca/bitstream/handle/10012/4889/NADI_SARAH.pdf》.2009,
Sarah Nadi等."DRACA: decision support for root cause analysis and change impact analysis for CMDBs".《https://uwspace.uwaterloo.ca/bitstream/handle/10012/4889/NADI_SARAH.pdf》.2009, (续)

审查员 高添

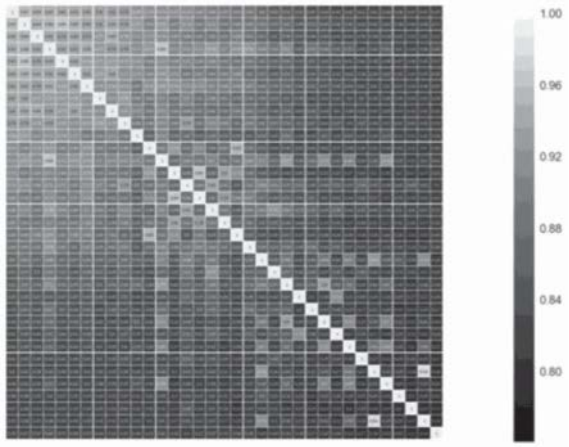
权利要求书3页 说明书11页 附图11页

(54)发明名称

用于执行高维传感器数据中的异常事件的自动根本原因分析的方法和系统

(57)摘要

本发明题为"用于执行高维传感器数据中的异常事件的自动根本原因分析的方法和系统"。本发明的一个实施方案可以提供一种用于识别一个或多个机器的操作中的异常事件的根本原因的系统。在操作期间,该系统可以:从与一个或多个机器相关联的一组传感器获得传感器数据;将该传感器数据转换成一组传感器状态;基于该一组传感器状态来构建最佳DAG以对因果依赖性进行建模;在给定直接相邻传感器的状态的情况下通过使用该DAG来确定目标传感器的异常状态的概率;以及通过追溯DAG中的异常状态来确定与目标传感器相关联的异常事件的根本原因。



CN 112115306 B

[转续页]

[接上页]

(56)对比文件

Chen Su等.“Association Mining Analysis of Alarm Root-Causes in Power System with Topological Constraints”.《ICIT 2017: Proceedings of the 2017 International Conference on Information Technology》.2017,

王杭州等.“基于贝叶斯网络的报警系统管理方法”.《计算机与应用化学》.2017,第34卷(第5期),

1.一种用于识别一个或多个机器的操作中的异常的根本原因的方法,所述方法包括:

从与所述一个或多个机器相关联的一组传感器获得传感器数据;

将所述传感器数据转换成一组传感器状态;

基于所述一组传感器状态通过下述步骤来构建所述一组传感器的优化的有向无环图(DAG)以对因果依赖性进行建模:

基于一组输入和所述一组传感器状态来构建一组DAG;以及

通过使用贝叶斯网络发现技术来从所述一组DAG搜索所述优化的DAG;

基于直接相邻传感器的状态通过使用所述DAG来确定目标传感器的异常状态的概率;以及

通过追溯所述DAG中的所述异常状态来确定与所述目标传感器相关联的所述异常状态的根本原因,其中将所述传感器数据转换成一组传感器状态包括:

将数据预处理技术应用于所述传感器数据以使所述传感器数据与统一全局参考时间时间对准,其中所述统一全局参考时间包括一组时间间隔;以及

将数据汇总技术应用于所述预处理的传感器数据,

其中将所述数据汇总技术应用于所述预处理的传感器数据包括:

应用数据变换技术来生成与所述统一全局参考时间相关联的每个时间间隔的一组度量;以及

基于所述一组度量,通过使用聚类技术来将与所述一组传感器相关联的一组属性中的类似的属性即强连通分量进行分组以将每个强连通分量缩减到单个元节点;以及

基于一组元节点,构造元图作为所述元节点的DAG。

2.根据权利要求1所述的方法,其中应用所述数据预处理技术还包括:

将数据内插技术应用于所述时间对准的传感器数据以替换丢失的传感器数据样本。

3.根据权利要求1所述的方法,其中所述一组输入包括以下项中的一者或多者:

天气数据;

用户指定的黑名单;和

用户指定的白名单。

4.根据权利要求1所述的方法,其中通过使用K均值算法来获得所述一组传感器状态。

5.根据权利要求1所述的方法,其中所述一组传感器的所述DAG包括:

一组节点,其中所述图中的每个节点表示一组传感器集群中的一个传感器;和

一组有向边,其中所述一组边中的每个有向边表示在所述图中的两个节点之间的因果依赖性。

6.一种用于识别一个或多个机器的操作中的异常的根本原因的装置,包括:

一个或多个处理器;

一组传感器,所述一组传感器嵌入所述一个或多个机器中;和

存储器,所述存储器存储指令,所述指令在由所述一个或多个处理器执行时使所述装置:

从与所述一个或多个机器相关联的一组传感器获得传感器数据;

将所述传感器数据转换成一组传感器状态;

基于所述一组传感器状态通过下述步骤来构建所述一组传感器的优化的有向无环图

(DAG)以对因果依赖性进行建模：

基于一组输入和所述一组传感器状态来构建一组DAG;以及

通过使用贝叶斯网络发现技术来从所述一组DAG搜索所述优化的DAG;

基于直接相邻传感器的状态通过使用所述DAG来确定目标传感器的异常状态的概率;以及

通过追溯所述DAG中的所述异常状态来确定与所述目标传感器相关联的所述异常状态的根本原因,其中将所述传感器数据转换成一组传感器状态包括：

将数据预处理技术应用于所述传感器数据以使所述传感器数据与统一全局参考时间时间对准,其中所述统一全局参考时间包括一组时间间隔;以及

将数据汇总技术应用于所述预处理的传感器数据,

其中将所述数据汇总技术应用于所述预处理的传感器数据包括：

应用数据变换技术来生成与所述统一全局参考时间相关联的每个时间间隔的一组度量;以及

基于所述一组度量,通过使用聚类技术来将与所述一组传感器相关联的一组属性中的类似的属性即强连通分量进行分组以将每个强连通分量缩减到单个元节点;以及

基于一组元节点,构造元图作为所述元节点的DAG。

7.根据权利要求6所述的装置,其中应用所述数据预处理技术还包括：

将数据内插技术应用于所述时间对准的传感器数据以替换丢失的传感器数据样本。

8.根据权利要求6所述的装置,其中所述一组输入包括以下项中的一者或多者：

天气数据;

用户指定的黑名单;和

用户指定的白名单。

9.根据权利要求6所述的装置,其中所述一组传感器状态通过使用K均值算法来获得。

10.根据权利要求6所述的装置,其中所述一组传感器的所述DAG包括：

一组节点,其中所述图中的每个节点表示一组传感器集群中的一个传感器;和

一组有向边,其中所述一组边中的每个有向边表示在所述图中的两个节点之间的因果依赖性。

11.一种非暂态计算机可读存储介质,所述非暂态计算机可读存储介质存储指令,所述指令在由计算机执行时使所述计算机执行用于识别一个或多个机器的操作中的异常的根本原因的方法,所述方法包括：

从与所述一个或多个机器相关联的一组传感器获得传感器数据;

将所述传感器数据转换成一组传感器状态;

基于所述一组传感器状态通过下述步骤来构建所述一组传感器的优化的有向无环图(DAG)以对因果依赖性进行建模：

基于一组输入和所述一组传感器状态来构建一组DAG;以及

通过使用贝叶斯网络发现技术来从所述一组DAG搜索所述优化的DAG;

基于直接相邻传感器的状态通过使用所述DAG来确定目标传感器的异常状态的概率;以及

通过追溯所述DAG中的所述异常状态来确定与所述目标传感器相关联的所述异常状态

的根本原因,其中将所述传感器数据转换成一组传感器状态包括:

将数据预处理技术应用于所述传感器数据以使所述传感器数据与统一全局参考时间时间对准,其中所述统一全局参考时间包括一组时间间隔;以及

将数据汇总技术应用于所述预处理的传感器数据,其中将所述数据汇总技术应用于所述预处理的传感器数据包括:

应用数据变换技术来生成与所述统一全局参考时间相关联的每个时间间隔的一组度量;以及

基于所述一组度量,通过使用聚类技术来将与所述一组传感器相关联的一组属性中的类似的属性即强连通分量进行分组以将每个强连通分量缩减到单个元节点;以及

基于一组元节点,构造元图作为所述元节点的DAG。

用于执行高维传感器数据中的异常事件的自动根本原因分析的方法和系统

背景技术

技术领域

[0001] 本公开整体涉及用于执行异常事件的根本原因分析的系统和方法。更具体地，本公开涉及从高维传感器数据识别隐藏的异常事件的根本原因。

[0002] 相关技术

[0003] 随着在众多工业应用(例如，数字制造)中越来越多地使用支持物联网(IoT)的设备，大量传感器数据是易得的。在许多网络物理系统(CPS)应用中，传感器数据从配备IoT的设备连续地生成。此类传感器数据包括可用于优化工厂机器的操作效率的可采取行动的信息。特别地，优化操作效率并降低CPS中的故障事件的风险已经成为立即地应用这些技术以减少工厂停工时间并提高制造工艺的生产率的最追求的目标中的一个。然而，当传感器数据的维数和大小增长时，手动地研究和识别在传感器间的因果关系以识别在工厂布局中的机器的操作期间的异常事件的根本原因很快地成为成本极昂贵的任务。

[0004] 为了很好地适应真实世界应用，根本原因分析工作流程需要自动化，以从传感器数据中发现在传感器间的因果关系。

发明内容

[0005] 根据本发明的一个实施方案，提供了识别一个或多个机器的操作中的异常的根本原因的系统。在操作期间，该系统可以：从与机器相关联的一组传感器获得传感器数据；将传感器数据转换成一组传感器中的每个传感器的一组传感器状态；基于一组传感器状态来构建在一组传感器间的最佳有向无环图(DAG)以对因果依赖性进行建模；在给定直接相邻传感器的状态的情况下确定用户指定的目标传感器的异常状态的概率；以及通过追溯图结构中的异常状态来确定与目标传感器相关联的异常状态的根本原因。

[0006] 在本实施方案的一个变型中，将传感器数据转换成一组传感器中的每个传感器的一组传感器状态包括：将数据预处理技术应用于传感器数据以使传感器数据与统一全局参考时间时间对准，其中统一全局参考时间包括一组时间间隔；以及将数据汇总技术应用于预处理的传感器数据。

[0007] 在本实施方案的另一个变型中，应用数据预处理技术还包括：将数据内插技术应用于时间对准的传感器数据以替换丢失的传感器数据样本。

[0008] 在本实施方案的另一个变型中，将数据汇总技术应用于预处理的传感器数据包括：应用数据变换技术来生成与统一全局参考时间相关联的每个时间间隔的一组度量；以及基于一组度量，通过使用聚类技术来将与一组传感器相关联的一组属性中的类似的属性即强连通分量进行分组以将每个强连通分量缩减到单个元节点；以及基于一组元节点，构造元图作为元节点的DAG。有向图的强连通分量是强连通的子图。如果有向图中的子图中的每个节点都可从子图中的每一个其他节点到达，则子图可以是强连通的。一组类似的属性

可以表示为有向图中的强连通分量。

[0009] 在该实施方案的一个变型中，基于一组传感器状态来在一组元节点间构建最佳DAG结构包括：基于一组输入和一组传感器状态来构建一组DAG结构；以及通过使用贝叶斯网络发现技术来从一组图结构搜索最佳DAG结构。

[0010] 在该实施方案的另一个变型中，一组输入包括以下项中的一个或多个：天气数据；用户指定的黑名单；和用户指定的白名单。

[0011] 在另一个变型中，一组传感器状态通过使用K均值算法来获得。

[0012] 在该实施方案的一个变型中，在一组传感器间的DAG结构包括：一组节点，其中图结构中的每个节点表示一组传感器集群(即，元节点)中的一个传感器；和一组有向边，其中一组边中的每个有向边表示在图结构中的两个节点之间的因果依赖性。

附图说明

[0013] 专利或申请文件含有至少一张彩色绘图。专利局将根据请求提供本专利或专利申请公开的带有彩色附图的副本并支付必要费用。

[0014] 图1A示出了根据本发明的一个实施方案的示例性数据相关性图。

[0015] 图1B示出了根据本发明的一个实施方案的示例性数据质量图。

[0016] 图2示出了根据本发明的一个实施方案的示例性根本原因分析系统架构。

[0017] 图3A示出了根据本发明的一个实施方案的用于模拟的定期事件的聚类拓扑的图。

[0018] 图3B示出了根据本发明的一个实施方案的用于模拟的非定期事件的聚类拓扑的图。

[0019] 图4示出了根据本发明的一个实施方案的基于每小时的平均数据来将模拟的传感器数据映射到三元状态的示例。

[0020] 图5示出了根据本发明的一个实施方案的DAG模型结构的先验数据模型。

[0021] 图6示出了根据本发明的一个实施方案的用于图2中的架构的根本原因分析系统设计。

[0022] 图7A示出了根据本发明的一个实施方案的示例性有向依赖性图。

[0023] 图7B示出了根据本发明的一个实施方案的使用有向依赖性图的根本原因分析的示例性结果。

[0024] 图8呈现了根据本发明的一个实施方案的例示用于执行异常事件的根本原因分析的示例性过程的流程图。

[0025] 图9示出了根据本发明的一个实施方案的促成根本原因分析系统的示例性计算机系统。

[0026] 图10示出了根据本发明的一个实施方案的促成根本原因分析系统的示例性装置。

[0027] 在附图中，类似的附图标记是指相同的附图要素。

具体实施方式

[0028] 以下描述被呈现来使本领域的任何技术人员能够制造和使用实施方案，并且在特定应用及其要求的上下文中提供。对所公开的实施方案的各种修改对本领域的技术人员将是显而易见的，并且在不脱离本公开的实质和范围的情况下，本文中定义的一般原理可以

应用于其他实施方案和应用。因此，本发明不限于所示出的实施方案，而是应被赋予与本文所公开的原理和特征一致的最广范围。

[0029] 概述

[0030] 在许多现实世界工业CPS应用中，在一个或多个机器的操作期间记录的传感器数据数量很大并通常包括异构类型的传感器，这些传感器会生成不可靠的测量。例如，在CPS应用中，工厂能量管理系统(FEMS)可以周期性地从与多个工厂变电站相关联的大量传感器接收数据，例如，每分钟从600个传感器接收到的数据。传感器可以包括：用于测量能量、电流、电压等的电表、用于测量温度、湿度、CO2等的环境传感器、以及用于测量气流、冷却设定点等的控制状态传感器。这些传感器可以安装在工厂布局中的各个级别处。

[0031] 来自各种传感器的记录的传感器数据可以包括以下不规则性。首先，传感器数据可以包括具有完全地不同的格式和物理含义的异构数据。例如，异构数据可以包括温度和功率计读数。对于这种异构数据，数据处理系统用统一框架来无缝地变换所有变量以在根本原因分析工作流程中进行进一步处理是有挑战性的。其次，由于在传感器与基站之间的通信信道不稳定，因此传感器数据可能稀疏且容易出错。因此，需要的是能够在产生可靠且准确的分析结果的同时容忍所有类型的错误的数据处理系统。第三，由于CPS中的大量传感器和其他数据源不断地将更新推送到数据服务器，因此数据服务器在短时间段内会充斥着这些更新。为了应对如此大量的数据，数据处理系统可以在对数据服务器中的聚积数据执行任何种类的分析之前采用数据汇总和压缩技术。

[0032] 图1A示出了根据本发明的一个实施方案的示例性数据相关性图。数据相关性图基于从来自FEMS的馈送器收集的数据。在图1A中，较亮区域指示在两个传感器测量之间的较高相关性。在一对传感器测量之间的这种相关性可能是由于它们的安装位置和传感器的类型。此外，随着要分析的传感器的数量的增加，有可能有数量更多的传感器是相关的。传感器数据中如此高的相关性的存在可能招致在计算中不必要的开销。

[0033] 图1B示出了根据本发明的一个实施方案的示例性数据质量图。数据质量可以被定义为正常数据样本与在给定单位时间段的情况下要接收的数据样本总数的比率。在图1B中，计算在1小时时间窗口内的数据质量，其中深色区域指示正常样本，而较亮区域指示传感器数据中的相关或随机损失。

[0034] 常规的自动根本原因分析方法没有考虑传感器数据中固有的不规则性。换句话说，它们基于对数据的质量、类型和格式的假设，因此它们的自动化能力受限于数据集的特性。本文所描述的实施方案解决了与执行高维传感器数据中的异常事件的自动根本原因分析相关联的上述技术问题。

[0035] 更具体地，根本原因分析系统可以获得传感器数据并对传感器数据进行预处理以处理采样率的不规则性和丢失的传感器读数。然后，系统仅选择相关的传感器数据进行进一步处理。具体地，系统将预处理的传感器数据变换成紧凑且信息化的数据表示。此外，系统确定一组传感器中的每个传感器的一组传感器状态。然后，系统努力基于一组状态来构建在一组传感器集群(即，元节点)间的最佳DAG结构。通过使用DAG结构，系统可以确定与用户指定的目标传感器相关联的异常事件的根本原因。具体地，系统在给定直接相邻传感器的状态的情况下确定目标传感器的异常状态的概率，然后通过追溯DAG结构中的异常状态来确定目标传感器中的异常事件的根本原因。

[0036] 本文所描述的根本原因分析系统提供以下优点:该系统在尺寸上可扩展,因为该系统可以随可用于分析的传感器数量而很好地扩展;该系统具有通用性,因为它可以使用从天气、时间和传感器数据学习到的因果模型来执行各种形式的异常事件的根本原因分析任务;并且该系统是稳健的,因为它可以对损坏、嘈杂和损失的传感器数据执行分析。

[0037] 系统架构

[0038] 图2示出了根据本发明的一个实施方案的示例性根本原因分析系统架构。根本原因分析系统200可以包括传感器数据库202、天气数据库204和三个处理阶段。第一阶段可以包括数据预处理模块214,第二阶段可以包括数据汇总模块220,并且第三阶段可以包括模型发现模块228。数据预处理模块214还可以包括数据检索模块206、数据标准化模块208、异常值检测模块210和数据内插模块212。数据汇总模块220还可以包括数据变换模块216和传感器聚类模块218。模型发现模块228还可以包括自动状态分类模块222、贝叶斯网络结构发现模块224和分析模块226。

[0039] 传感器数据库202存储从嵌入工厂布局中的一个或多个机器中的多个传感器收集的传感器数据。传感器数据可以表示为多变量时间序列,例如,传感器数据可以含有在不同的时间戳上的一大组变量的记录。天气数据库204是可公开地获得的数据库,其可以包括与天气相关联的数据,例如温度、露点、湿度等。数据检索模块206周期性地查询传感器数据库202和天气数据库204,并且存储和/或更新以二进制数据格式保存在本地分析服务器中的对应的数据记录。

[0040] 在本发明的一个实施方案中,用户可以设置两个时间戳,即T_s到T_e,以指示覆盖所有观察结果的时间间隔。例如,时间间隔可以被设置为一年。该时间间隔可以被称为分析周期。分析周期可以表示为一对(T_s、T_e),并且系统可以自动地设置分析周期以支持周期性更新,除非用户明确地指定。

[0041] 在一个实施方案中,数据标准化模块208可以假定:T_s和T_e是预定义的且不变的;以及与多个传感器相关联的所有收集到的属性按索引$i \in \{1,\cdots,N\}$排序,其中N表示由数据检索模块206收集来用于分析的属性的总数。术语"属性"也可以用数据库中的等效术语"列"来指代。数据标准化模块208可以将所有收集到的属性划分为两个组。第一组$S \subset \{1, \cdots, N\}$包括由传感器数据库收集的属性。第二组$W \subset \{1, \cdots, N\}$含有来自公共数据库的天气相关的属性。此外,数据标准化模块208可以将S中的属性分类为两个类。第一类可以包括主传感器的一组属性索引$S_P \subset S$,该组属性索引是针对异常事件的,该异常事件例如来自功率计测量的异常功率消耗。第二类可以包括剩余的传感器属性,该剩余的传感器属性由$S_{/P}$或$S-S_P$表示。

[0042] 在本发明的一个实施方案中,数据标准化模块208可以通过基于列(或属性)按时间序列变换所有检索到的传感器数据样本来提高传感器数据的后续分析的效率,并且可以将结果保存在列存储数据库系统中。数据标准化模块208可以将每个第i个属性的列矢量构造为$\boldsymbol{a}_i = \left(a_{(i,j)}\right)_{j=1,\cdots,n_i}$,其中$n_i$表示在分析周期($T_s$,$T_e$)期间收集到的样本总数。令$\boldsymbol{t}_i = \left(t_{(i,j)}\right)_{j=1,\cdots,n_i}$表示$a_i$的对应的时间戳阵列,其中对于$i \in \{1,\cdots,N\}$和$j \in \{1,\cdots,N\}$,$T_s \leqslant t_{(i,j)} \leqslant T_e$。

[0043] 由于在传感器与基站之间的数据通信信道的不稳定性,在两个连续的时间戳之间

的差异可能不是恒定的。为了解决采样率中的任何不规则性，数据标准化模块208可以将所有采本映射到统一全局参考时域。数据标准化模块208可以将统一全局参考时间划分为以秒为单位的相等长度间隔Δ，例如，间隔长度可以是一小时。

[0044] 令$\tilde{t}_{k\in\{1,\cdots,K\}}$表示第k个时间间隔的起始时间，其中K表示分析周期(T_s,T_e)内的统一全局参考时间的时间间隔总数。起始时间符号$\tilde{t}_k$可以用于传感器属性S和天气属性W两者。$\tilde{t}_k$的状态可以表示为时间相关参数表示三元组，即$\theta^T=(\theta_m,\theta_d,\theta_h)$。在三元组中，$\theta_m$,$\theta_d$,和$\theta_h$分别代表一年中的月份、一周中的日期和一天中的小时。在数据标准化模块208将所有的时间戳映射到统一全局参考时间间隔之后，它将生成每个属性的新列矢量。

[0045] 异常值检测模块210可以将每个属性分类为三种通用值类型(即，连续值、离散值和常数值)中的一种。然后，异常值检测模块210分析列矢量的模式。如果属性在所有全局参考时间间隔内保持恒定，则可能不包括这些常数类型属性来进行进一步分析，因为它们可能不会在根本原因分析工作流程中生成任何可能的结果。

[0046] 数据内插模块212可以聚合在时间间隔内带有时间戳的所有样本以计算与含有数值的特定属性相关联的均值和方差，使得在该时间间隔内存在至少一个有效样本。否则，数据内插模块212可以基于相邻间隔的聚合结果来运行内插算法。如果属性含有分类值，例如{高、中、低}，则数据内插模块212可以应用随机散列以将具体值映射到整数域，并且在映射之后将属性处理为连续数值。例如，数据内插模块212可以通过将线性内插用于连续值类型、将最近邻内插用于离散值类型来替换丢失的传感器读数。

[0047] 与在数据内插模块212的输出处可用的传感器数据和天气数据相关联的属性可以包括各种各样的属性类型。为了消除属性类型多样性和大量属性的负面影响，数据汇总模块220可以将属性变换成紧凑且信息化的数据表示。数据汇总模块220可以执行两个不同的操作：数据变换(通过数据变换模块216)和传感器聚类(通过传感器聚类模块218)。

[0048] 在一个实施方案中，数据变换模块216可以将每个时间间隔中的样本汇总为两个不同的特征；即分别是定期事件和非定期事件的平均特征和方差特征。然后，数据变换模块216构造特征矩阵，其中时间间隔和属性分别表示在矩阵的行和列中。平均特征可以捕获周期性地发生的事件，例如，每日或每周正弦曲线周期。周期性地发生的事件可以被称为定期事件。方差特征能够捕获非周期性地发生的事件，这也可以量化属性样本值的波动。非周期性地发生的事件可以被称为非定期事件。

[0049] 对于每个时间间隔k，数据变换模块216可以计算传感器数据的所有属性的平均和方差特征。令$n_{i,k}$表示在时间间隔k期间与属性i相关联的样本数量，而$s_{i,k}$表示在时间间隔k的起点的属性i的样本索引，即，$s_{i,k}=1+\sum_{r=1}^{k-1}n_{i,r}$。然后，按以下计算平均和方差特征：

[0050] $$\bar{a}_{i,k}=\frac{\sum_{j=s_{i,k}+1}^{s_{i,j}+n_{i,k}}a_{i,j}}{n_{i,k}} \quad (1)$$

[0051] $$\dot{a}_{i,k}=\frac{\sum_{j=s_{i,k}+1}^{s_{i,j}+n_{i,k}-1}\left|a_{i,j+1}-a_{i,j}\right|}{n_{i,k}-1} \quad (2)$$

[0052] 其中$\bar{a}_{i,k}$和$\dot{a}_{i,k}$表示时间间隔k的属性i的平均和方差特征。

[0053] 传感器聚类模块218考虑到传感器测量通常是高度相关的并且这种高相关性可以产生秩亏特征矩阵。因此，需要的是在类似的属性的组内选择有限数量的代表性属性(即，特征矩阵的列矢量)。在对类似的属性进行分组之前，传感器聚类模块218执行以下操作以消除属性特征的不一致单位和标度对分组/聚类的影响。首先，传感器聚类模块218可以针对单位长度和零中心归一化每个属性的特征矢量(即，特征矩阵的列矢量)。然后，传感器聚类模块218可以将每个特征矢量等效地映射到单位K维球面的表面上。

[0054] 在本发明的一个实施方案中，传感器聚类模块218可以使用亲和力聚类算法。亲和力聚类算法可以用于对一组最相关的属性进行分组，以使其中每一组具有对应的单个代表性属性(其可以被称为示范例)，而该组中的剩余的属性可以被称为随从例。对于每个示范例，传感器聚类模块218可以构造两个特征矩阵，即，平均特征矩阵和变化特征矩阵。在数据传感器聚类模块218中执行的数据处理操作可以通过消除大量相关属性来减少模型发现模块228中的搜索空间。此外，亲和力聚类算法通过经由消息传递并使用在数据点之间的距离度量来构造集群来提供处理大数据集的快速且可靠的方式。

[0055] 在以下部分中，将进一步详细地描述传感器聚类模块218的工作。在本发明的一个实施方案中，传感器聚类模块218可以分别根据等式(1)和(2)来计算属性i的平均和方差特征矢量。平均特征矢量可以表示为$\bar{\mathbf{a}}_{i.}=\left(\bar{a}_{i,1},\cdots,\bar{a}_{i,K}\right)$，而方差特征矢量可以表示为$\dot{\mathbf{a}}_{i.}=\left(\dot{a}_{i,1},\cdots,\dot{a}_{i,K}\right)$。可以将平均特征矢量$\bar{\boldsymbol{a}}_{i.}$变换成零中心且单位长度的矢量，其用$\bar{\mathbf{x}}_{i.}$表示，使得$\bar{\mathbf{x}}_{i.}=(\bar{\mathbf{a}}_{i.}-\bar{\bar{\mathbf{a}}}_{i.})/\|\bar{\mathbf{a}}_{i.}-\bar{\bar{\boldsymbol{a}}}_{i.}\|_{l_2}$，其中$\bar{\bar{\mathbf{a}}}_{i.}=\sum_k \mathbf{a}_{i,k}/K$。类似地，方差特征矢量$\dot{\mathbf{a}}_{i.}$也可以进行变换。在属性i和j之间的平均特征的相异性可以通过欧几里得距离来测量为$d_{ij}^{avg}=\left|\bar{\mathbf{x}}_{i.}-\bar{\mathbf{x}}_{j.}\right|_{l_2}$。类似地，可以测量方差特征矢量$\dot{\mathbf{a}}_{i.}$的相异性并将其表示为$d_{ij}^{var}$。

[0056] 平均特征矢量的相异性度量也可以被定义为$d_{ij}^{avg}=\sqrt{2\left(1-\rho_{ij}^{avg}\right)}$，其中$\rho_{ij}^{avg}$是属性i和j之间的平均特征的相关系数。此外，平均特征矢量的相异性度量由一组实数$0\le d_{ij}^{avg}\le 2$界定，并且平均特征矢量的类似性度量可以被定义为$s_{ij}^{avg}=2-d_{ij}^{avg}$。可以将方差特征矢量的类似性度量定义为$s_{ij}^{var}=2-d_{ij}^{var}$。

[0057] 然后，如果满足以下条件，则传感器聚类模块218可以确定平均和方差特征矢量的零方差属性：

[0058] $$Var(\bar{\mathbf{x}}_{i.})\le\delta_{avg} \qquad (3)$$

[0059] $$Var(\dot{\mathbf{x}}_{i.})\le\delta_{var} \qquad (4)$$

[0060] 其中$Var(\bar{\mathbf{x}}_{i.})$表示归一化平均特征矢量的方差，而$Var(\dot{\mathbf{x}}_{i.})$表示归一化方差特征矢量的方差，$\delta_{avg}$和$\delta_{var}$是相应的阈值，其中$\delta_{avg}=\delta_{var}=10^{-2}$。令$C_{avg}^{zero}$和$C_{var}^{zero}$分别表示平均和方差特征矢量的零方差属性的索引的组(或集群)。在一个实施方案中，传感器聚类模块218可以使用亲和力聚类算法来计算平均特征和方差特征的集群。亲和力聚类算法分别针对所有非零方差属性$i,j\notin C_{avg}^{zero}$和$i,j\notin C_{var}^{zero}$使用类似性度量s_{ij}^{avg}和s_{ij}^{var}。然后，

可以由特征矩阵$\mathbf{X}^{avg}=[\bar{\mathbf{x}}_{i.}]_{i\in C_{avg}^{exmp}}$和$\mathbf{X}^{var}=[\dot{\mathbf{x}}_{i.}]_{i\in C_{var}^{exmp}}$紧凑地表示示范例属性的平均和方差特征，其中$C_{avg}^{exmp}$和$C_{var}^{exmp}$分别是平均和方差特征的示范例的属性索引。

[0061] 图3A示出了根据本发明的一个实施方案的用于模拟的定期事件的示范例和随从例传感器的聚类拓扑的图。图3B示出了根据本发明的一个实施方案的用于模拟的非定期事件的示范例和随从例传感器的聚类拓扑的图。图3A和图3B中的拓扑已经通过将亲和力聚类算法用于模拟的定期和非定期事件来获得。

[0062] 返回图2，模型发现模块228还通过使用以下数据处理模块来进一步处理由传感器聚类模块218输出的数据：自动状态分类模块222、贝叶斯网络结构发现模块224和分析模块226。模型发现模块228的目标是通过在给定观察到的传感器数据和天气数据的情况下搜索最佳贝叶斯网络(BN)结构来找到在属性间的因果依赖性的简单图形表示作为DAG。

[0063] 自动状态分类模块222可以使用具有拐点检测的K均值算法，其中可以通过在K与在给定K的情况下模型的对数似然之间的拐点折衷来确定最佳数量的集群K。由此，用分别由三元状态(例如，高、低和非峰)和二进制状态(例如，规则和不规则变化)表示的定期事件和非定期事件简化BN结构的状态配置。图4示出了根据本发明的一个实施方案的基于模拟的传感器数据的每小时平均值来将模拟的传感器数据映射到三元状态的示例。图4中的图(a、)示出了目标传感器测量的功率消耗曲线、即功率计数据的示例。该功率计数据可以首先变换成15分钟平均值，这样的平均功率计数据显示在图(b)中。然后，自动状态分类模块222可以将平均功率计数据转换成三元状态，例如，高、低和非峰(在图(c)中示出)。

[0064] 表1(如下所示)示出了由自动状态分类模块222执行的传感器测量的事件分类。表1还提供了在平均和变化特征的特性之间的比较。

[0065]

事件类型	定期事件（平均值）	非定期事件（微分值）
特性	周期性的	非周期性的
时间窗口	由用户设置（默认 15 分钟）	
信号特征	样本平均	总变化
状态分类	三元状态（低、高或非峰）	二进制状态（规则或不规则变化）
方法	带有拐点检测的 K 均值	

[0066] 表1:传感器测量的事件分类

[0067] 返回图2，贝叶斯网络结构发现模块224然后可以基于由节点之间的有向边表示为DAG的属性间具有因果依赖性的特征矩阵来找到一组最可能的图形结构。图形结构中的每一个可以包括：一组节点，其中每个节点对应于与传感器相关联的属性；和在节点之间的一组有向边。

[0068] 在以下部分中，将进一步详细地描述贝叶斯网络结构发现模块224和分析模块226的工作。常规的系统需要探索指数级搜索空间以识别最佳BN结构，而对BN结构和状态没有任何约束。即使常规的系统能够在有限时间内找到最佳BN结构，所得的结构也可能对初始起点高度敏感并因此不可靠。此外，如果未正确地定义BN结构中的状态，则用于学习BN结构的算法可能会以无限慢的速率收敛到最终解。

[0069] 为了克服上述问题，本发明的一个实施方案建立用于BN结构的先验数据模型来指导搜索，图5示出了这样的先验数据模型。图5示出了根据本发明的一个实施方案的DAG模型结构的先验数据模型。先验数据模型对BN结构上的天气属性502、时间参数506和传感器属

性(其包括目标传感器测量508和非目标传感器测量504)强加因果关系的基本约束。仅允许因果关系的一个方向,例如从时间参数506到天气属性502,但不从天气属性502到时间参数506。这种因果关系约束可以定义普遍地适于任何种类的传感器和天气数据的基本BN结构。该系统可以通过使用单独属性的由图2中的自动状态分类模块222学习的隐藏参数来表示因果关系模型。在一个实施方案中,图2中的自动状态分类模块222可以找到属性的特征的连续状态的最佳离散状态,即,隐藏参数,这等同于找到连续状态的最佳量化。然后,用户可以基于他们对传感器的已知依赖性知识来提供黑/白名单510,以进一步约束BN结构。

[0070] 在一个实施方案中,符号X用于表示X^{avg}和X^{var}两者。符号$X_{,i}$表示X的第i个列矢量并表示属性i的观察到的特征样本。目标传感器测量属性的特征矩阵可以由$\mathbf{X}^{S_P}$表示,并且$\mathbf{X}^{S_P} = (\mathbf{X}_{,i})_{i\in S_P}$。以类似的方式,可以分别定义非目标传感器测量属性504和天气属性502的$\mathbf{X}^{S/P}$和X^{W}。在一个实施方案中,观察到的特征样本$x_{i,k}$可以取决于潜在或隐藏的离散状态θ_i,即,$P(x_{i,k}|X,(\theta_j)_{j=1,\cdots,N}) = P(x_{i,k}|\theta_i)$。另选地,$\theta_i$可以被解释为在量化之后连续随机变量$x_{i,k}$的离散状态表示。符号$\theta^{S_P}$表示$\mathbf{X}^{S_P}$的隐藏状态,而$\theta^{S/P}$表示$\mathbf{X}^{S/P}$的隐藏状态,类似地,天气和时间属性的隐藏状态可以分别用θ^{W}和θ^{T}表示。通过使用图5所示出的DAG,可以由一组隐藏参数$\Theta = (\theta^{S_P}, \theta^{S/P}, \theta^{W}, \theta^{T})$来紧凑地表示在属性间的因果依赖性。在图5中,在节点之间的箭头表示因果依赖性,并且每个图块仅示出在具有相同属性的节点间的单个示例。没有进一步假设在图块中的节点间的依赖性结构。

[0071] 返回图2,贝叶斯网络结构发现模块224力求找到θ^{S_P}的紧凑概率描述,使得在给定图5中的图形模型和特征矩阵X的情况下$P(\theta^{S_P}|\,\theta^{S/P}, \theta^{W}, \theta^{T})$。该目标可以通过采用BN框架来实现,该BN框架便于在给定X和图5中的模型的情况下系统地搜索θ^{S_P}的最佳图形结构。

[0072] 令G=(N,E)表示DAG,其中节点N=$\{\theta_i \in \Theta\}$,并且边E表示在变量之间的直接依赖性。此外,另外的变量可以如下定义:

[0073]

变量	定义
$\prod_{\theta_i}$	G中的θ_i的一组父元素
$D_{\prod_{\theta_i}}$	$\prod_{\theta_i}$中的变量的联合域
θ_{ik}	θ_i的第K个值
w_{ij}	$\prod_{\theta_i}$的第J个配置
z_{ijk}	$z_{ijk} = P(\theta_i = \theta_{ik}\|\prod_{\theta_i} = w_{ij})$
Z	$Z = \{z_{ijk}\}_{i\in 1\cdots n, j\in D_{\prod_{\theta_i}}, k\in D_i}$

[0074] n维BN可以被定义为三元组B=(Θ,G,z),并且在Θ上的唯一联合概率分布如下给出:

[0075] $$P_B(\theta_1,\cdots,\theta_n) = \prod_{i=1}^{n} P_B(\theta_i|\prod_{\theta_i}) \qquad (5)$$

[0076] 具有n个变量的一组所有贝叶斯网络可以用B_n表示。在一个实施方案中,贝叶斯网络结构发现模块224可以通过搜索最大化值Φ(B,D_0)的贝叶斯网络B∈B_n来学习贝叶斯网络,其中Φ表示评分函数,并且D_0表示从X中找到的隐藏状态θ的样本。在一个实施方案中,贝叶斯网络结构发现模块224可以使用贪婪爬坡方法来通过贝叶斯信息准则(BIC)分数来

搜索B_n。

[0077] 贝叶斯网络结构发现模块224可以使用贝叶斯网络框架来描述非定期事件和定期事件的依赖性模型。在给定图5所示出的基本依赖性模型的情况下，贝叶斯网络结构发现模块224可以自动地学习非定期事件和定期事件的完整依赖性结构(BN结构)。然后，在给定完整依赖性结构的情况下，贝叶斯网络参数估计算法可以用于计算定期事件和非定期事件的依赖性概率(即，BN分布)。在本发明的一个实施方案中，贝叶斯网络结构发现模块224可以从传感器测量、天气数据(例如，温度、露点、湿度、事件和条件)和时间戳(月、周、日、小时)学习BN。此外，该系统还可以使用户能够手动地向图5中的学习模型提供输入(例如，黑名单和白名单)。

[0078] 然后，分析模块226通过连续地计算(6、)中的以下动态等式来执行根本原因分析，直到节点i是叶节点(即，没有子元素的节点)为止。

[0079] $$\theta_{J_i}^{k} \leftarrow arg\max_{\theta_{J_i}} P_B\left(\theta_i = \theta_{J_i}^{k} \middle| \theta_{J_i}\right), \qquad \theta_{J_i}^{0} \leftarrow \theta_t^{*} \qquad (6)$$

[0080] 其中J_i表示节点i的父节点，θ_{J_i}表示节点i的父节点的状态，并且θ_t^*表示目标传感器的异常状态。

[0081] 图6示出了根据本发明的一个实施方案的用于图2中的架构的根本原因分析系统设计。图6示出了两个独立地运行的系统：用于训练的系统612和用于推断的系统614。在一个实施方案中，训练系统612可以从来自数据库服务器的批量数据流602以及工厂布局618的先验知识学习贝叶斯网络结构606。推断系统614可以使用训练数据集608中可用的贝叶斯网络结构的最新更新并在给定用户定义的目标传感器616的情况下执行根本原因分析任务610。消息队列604可以适当地控制在数据库、训练系统612和推断系统614间的数据流。

[0082] 图7A示出了根据本发明的一个实施方案的示例性有向依赖性图。节点702至732表示不同传感器，而连接节点的有向边表示在节点之间的连接。图7B示出了根据本发明的一个实施方案的使用有向依赖性图的根本原因分析的示例性结果。在给定目标传感器710(黑色阴影圆圈)的情况下，系统使用图7B所描绘的有向依赖性图来执行根本原因分析。在一个实施方案中，根本原因分析是通过使用等式(6、)来计算的。例如，如果给定目标传感器710的异常状态被设置为“空闲”状态，则通过使用等式(6、)，系统可以断定传感器710中的“空闲”状态最有可能因在以下机器中存在的条件而发生：当与传感器720相关联的机器也空闲时，当在与传感器716相关联的机器的输入处没有可用输入时，以及当与传感器712相关联的机器的节拍时间比平常长时。而且异常的最可能的原因是传感器716的“无输入”状态，该状态的最可能的原因是传感器716和730中的传感器730的关闭状态。因此，给定目标传感器710中的异常状态的根本原因可以追溯到传感器730的特定关闭条件。

[0083] 图8呈现了根据本发明的一个实施方案的例示用于执行异常事件的根本原因分析的示例性过程的流程图。在操作期间，系统可以获得存储在传感器数据库中的传感器数据(操作802)。传感器数据与嵌入工厂布局中的一个或多个机器中的多个传感器相关联。

[0084] 在工业IoT应用中，由于传感器的数量增加，所收集的传感器数据的量可能很大。此外，传感器数据通常含有大量病态数据，包括丢失、损坏、嘈杂和高度相关的值。当使用这种质量差的传感器数据执行根本原因分析时，结果可能不正确并因此不可靠。此外，由于大量传感器数据，根本原因分析的计算复杂性可能显着地增加。为了提供传感器数据的紧凑

且信息化的表示，系统将传感器数据转换成一组传感器状态(操作804)。

[0085] 在操作804之后，系统可以通过使用一组传感器状态并选择最可能的BN结构来连续地学习BN结构以构建最佳DAG结构(操作806)。然后，系统可以针对最佳DAG结构，确定在给定图中的直接相邻者中的一些的状态的情况下用户指定的目标传感器的异常状态的概率(操作808)。然后，系统可以通过追溯DAG的异常状态来确定目标传感器的异常状态的最可能的原因(操作810)。

[0086] 示例性计算机系统和装置

[0087] 图9示出了根据本发明的一个实施方案的促成根本原因分析系统的示例性计算机系统。计算机系统900包括处理器902、存储器904和存储设备906。计算机系统900可以耦接到显示设备910、键盘912和指向设备914，并且还可以经由一个或多个网络接口耦接到网络908。存储设备906可以存储操作系统918和根本原因分析系统920。

[0088] 根本原因分析系统920可以包括指令，该指令在由计算机系统900执行时可以使计算机系统900执行本公开中描述的方法和/或过程。根本原因分析系统920还可以包括用于接收与一个或多个传感器相关联的传感器数据的指令(传感器数据接收模块922)、用于执行传感器数据预处理的指令(传感器数据预处理模块924)和用于在数据预处理阶段之后进一步处理传感器数据的指令(数据汇总模块926)。此外，根本原因分析系统920可以包括用于找到最可能的图形结构和用于确定用户指定的目标传感器中的异常的根本原因的指令(模型发现模块928)。

[0089] 图10示出了根据本发明的一个实施方案的促成无监督的异常检测系统的示例性装置。装置1000可以包括多个单元或装置，这些单元或装置可以经由有线、无线、光量子或电通信信道彼此通信。装置1000可以使用一个或多个集成电路来实现，并且可以包括比图10所示出的那些少或多的单元或装置。此外，装置1000可以集成在计算机系统中，或被实现为能够与其他计算机系统和/或设备通信的单独设备。具体地，装置1000可以包括单元1002至1010，包括：传感器数据接收单元1002、传感器数据预处理单元1004、数据汇总单元1006和模型发现单元1008，这些单元执行与图9的计算机系统900的模块920至928类似的功能或操作。装置1000还可以包括通信单元1010。

[0090] 一般来讲，本发明的实施方案提供了方法和系统来使用DAG来跟踪高维传感器数据的异常事件的根本原因。已经以使用传感器数据发现工厂机器操作中的异常的根本原因为例。在实践中，该解决方案不限于检测与工厂机器相关联的异常。该解决方案也可以用于检测其他类型的设备或机械中的异常。

[0091] 在具体实施方式部分中描述的方法和过程可实施为代码和/或数据，其可存储在如上所述的计算机可读存储介质中。当计算机系统读取和执行存储在计算机可读存储介质上的代码和/或数据时，计算机系统执行体现为数据结构和代码并且存储在计算机可读存储介质内的方法和过程。

[0092] 此外，上述方法和过程可包括在硬件模块或装置中。硬件模块或装置可包括但不限于专用集成电路(ASIC)芯片、现场可编程门阵列(FPGA)、在特定时间执行特定软件模块或一段代码的专用或共享处理器，以及现在已知的或稍后开发的其他可编程逻辑设备。当硬件模块或装置被激活时，它们执行包括在其中的方法和过程。

[0093] 已经仅出于例示和描述目的而呈现了本发明的实施方案的前述描述。这些实施方

案并不旨在是穷举性的或将本发明限制为所公开的形式。因此，许多修改和变化对本领域的技术人员将是显而易见的。附加地，以上公开内容并非旨在限制本发明。本发明的范围由所附权利要求书限定。

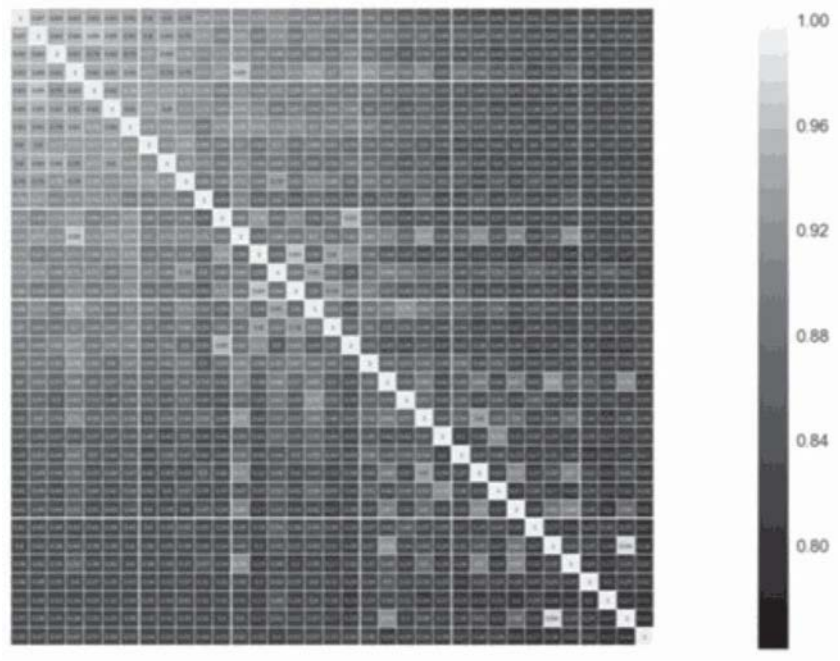


图1A

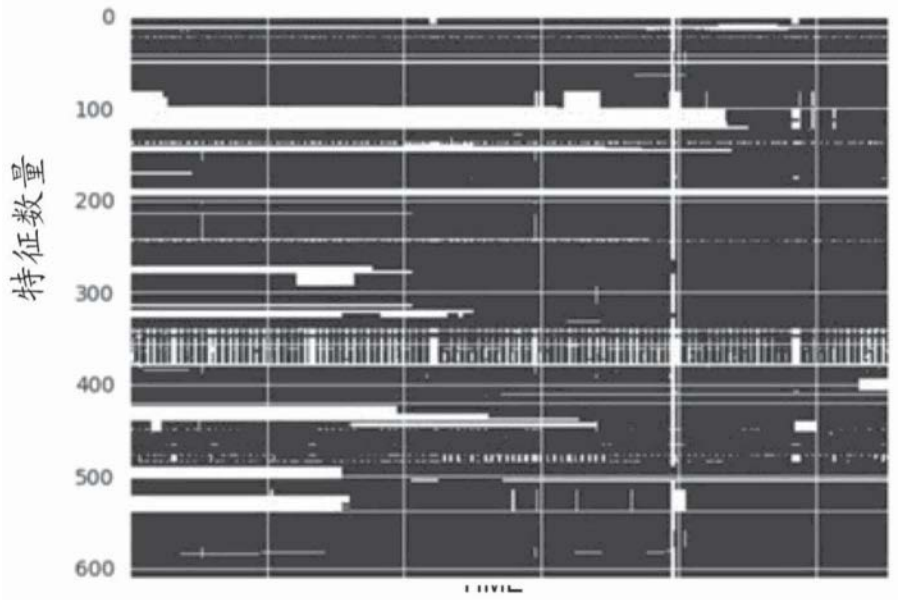


图1B

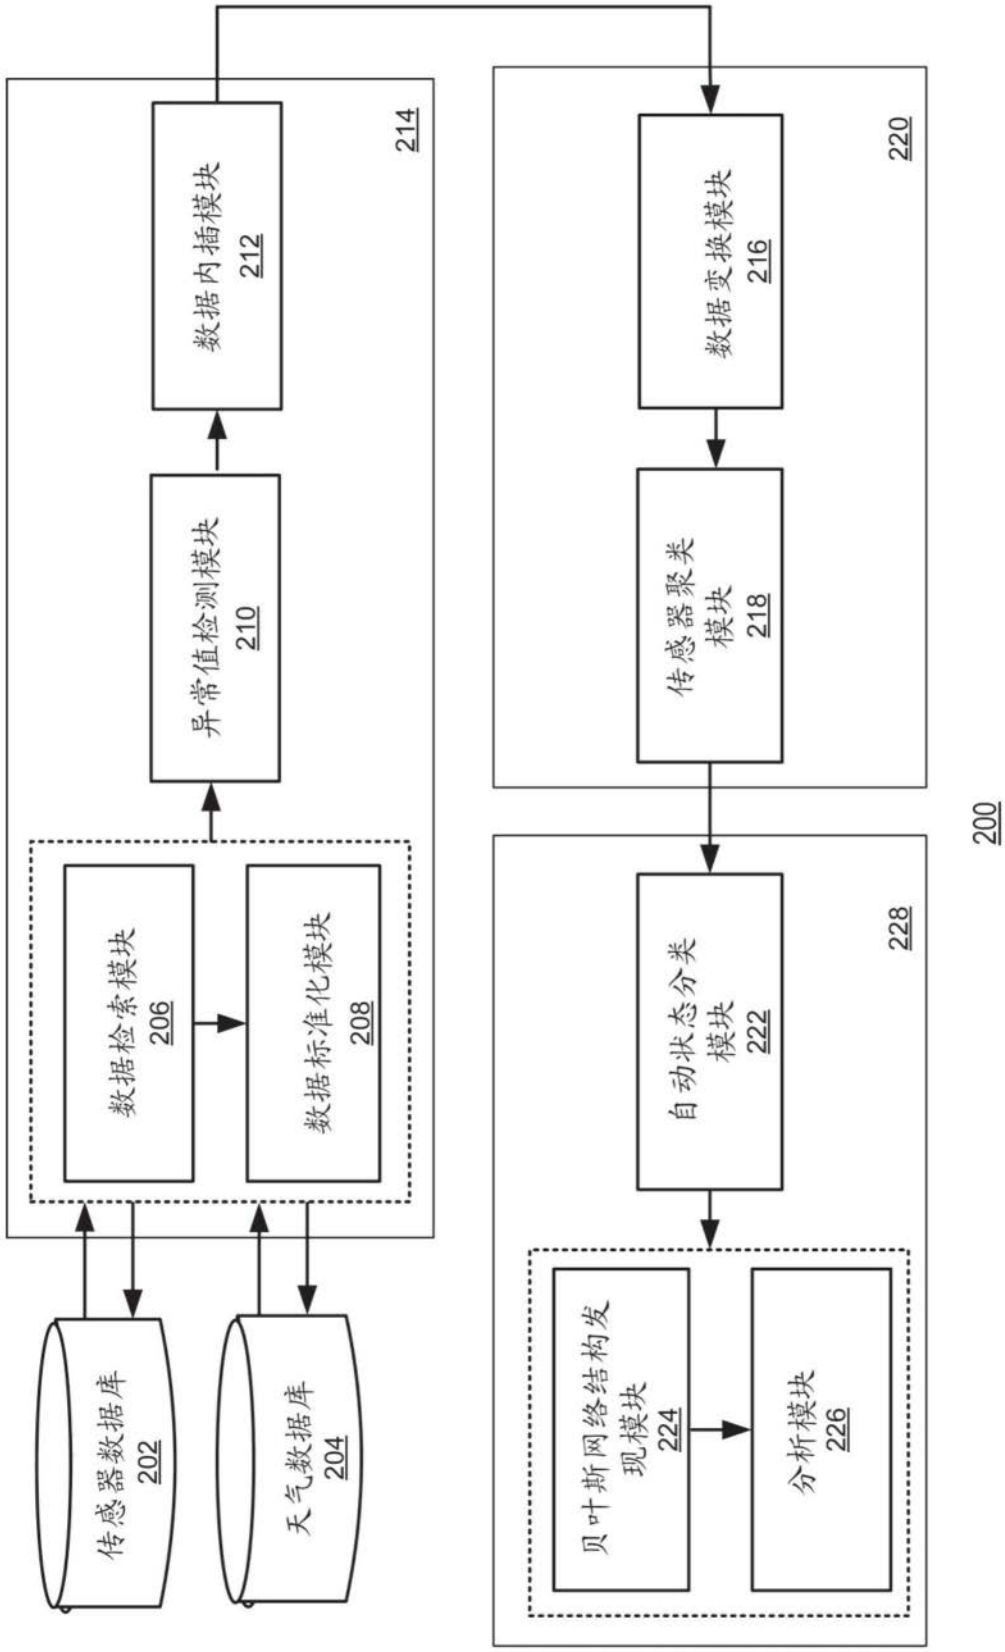

200
214
数据内插模块
212
异常值检测模块
210
数据检索模块
206
数据标准化模块
208
传感器数据库
202
天气数据库
204
220
数据变换模块
216
传感器聚类
模块
218
228
自动状态分类
模块
222
贝叶斯网络结构发
现模块
224
分析模块
226

图2

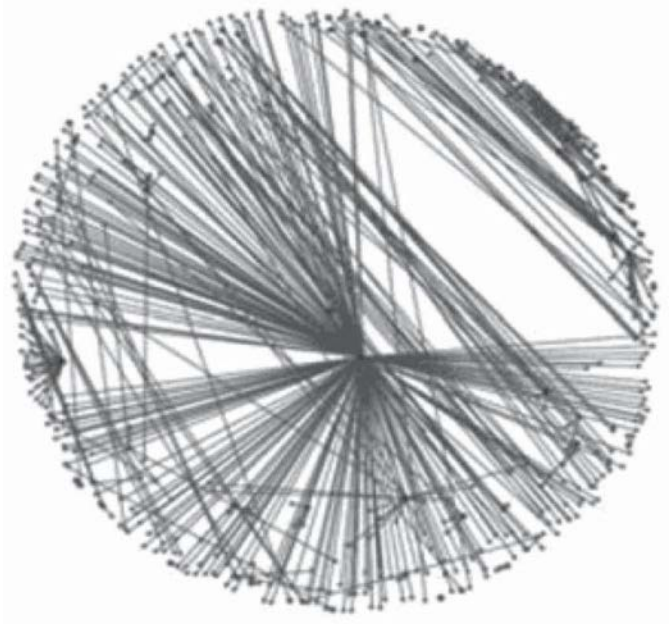


图3A

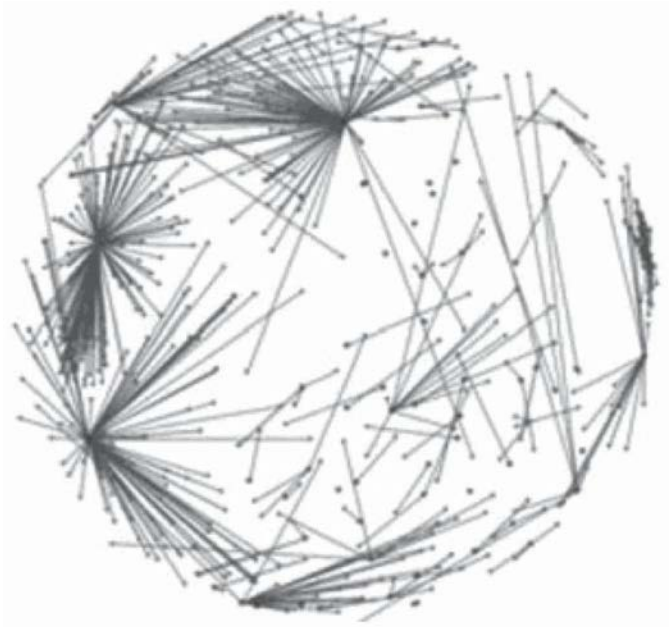


图3B

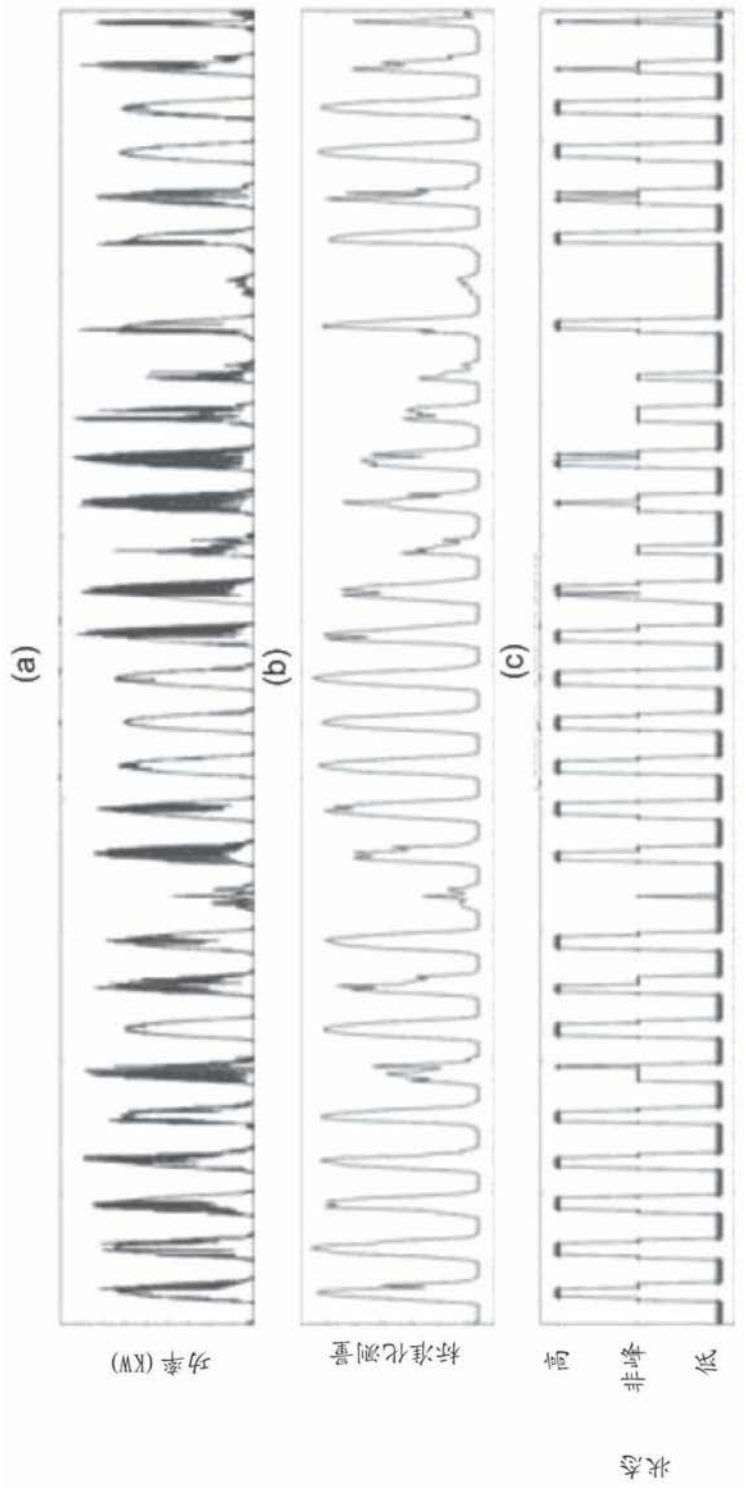


图4

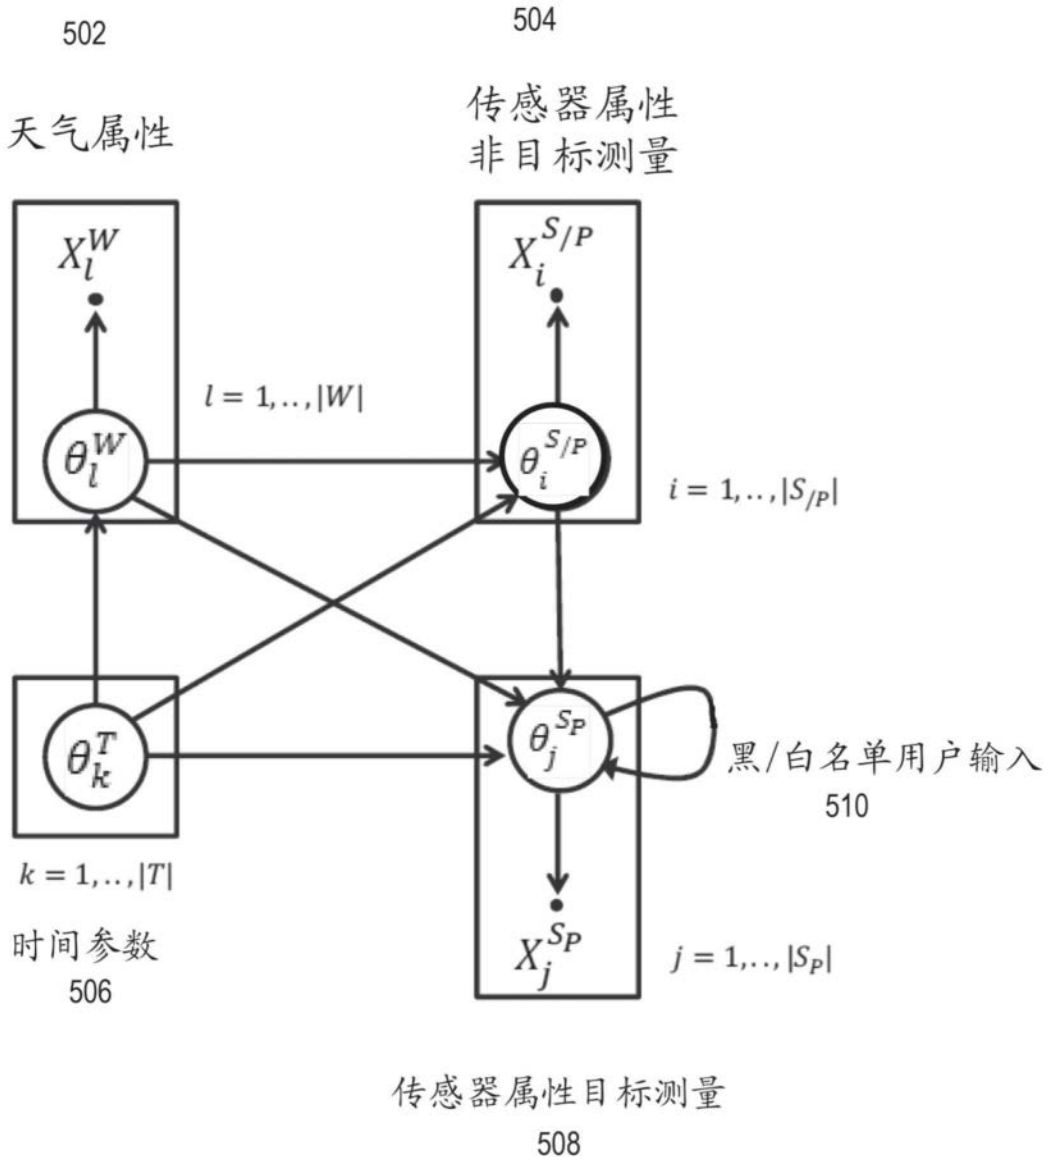

502
504
天气属性
传感器属性
非目标测量
X_l^W
$X_i^{S/P}$
$l = 1,..,|W|$
θ_l^W
$\theta_i^{S/P}$
$i = 1,..,|S_{/P}|$
θ_k^T
$\theta_j^{S_P}$
黑/白名单用户输入
510
$k = 1,..,|T|$
时间参数
506
$X_j^{S_P}$
$j = 1,..,|S_P|$
传感器属性目标测量
508

图5

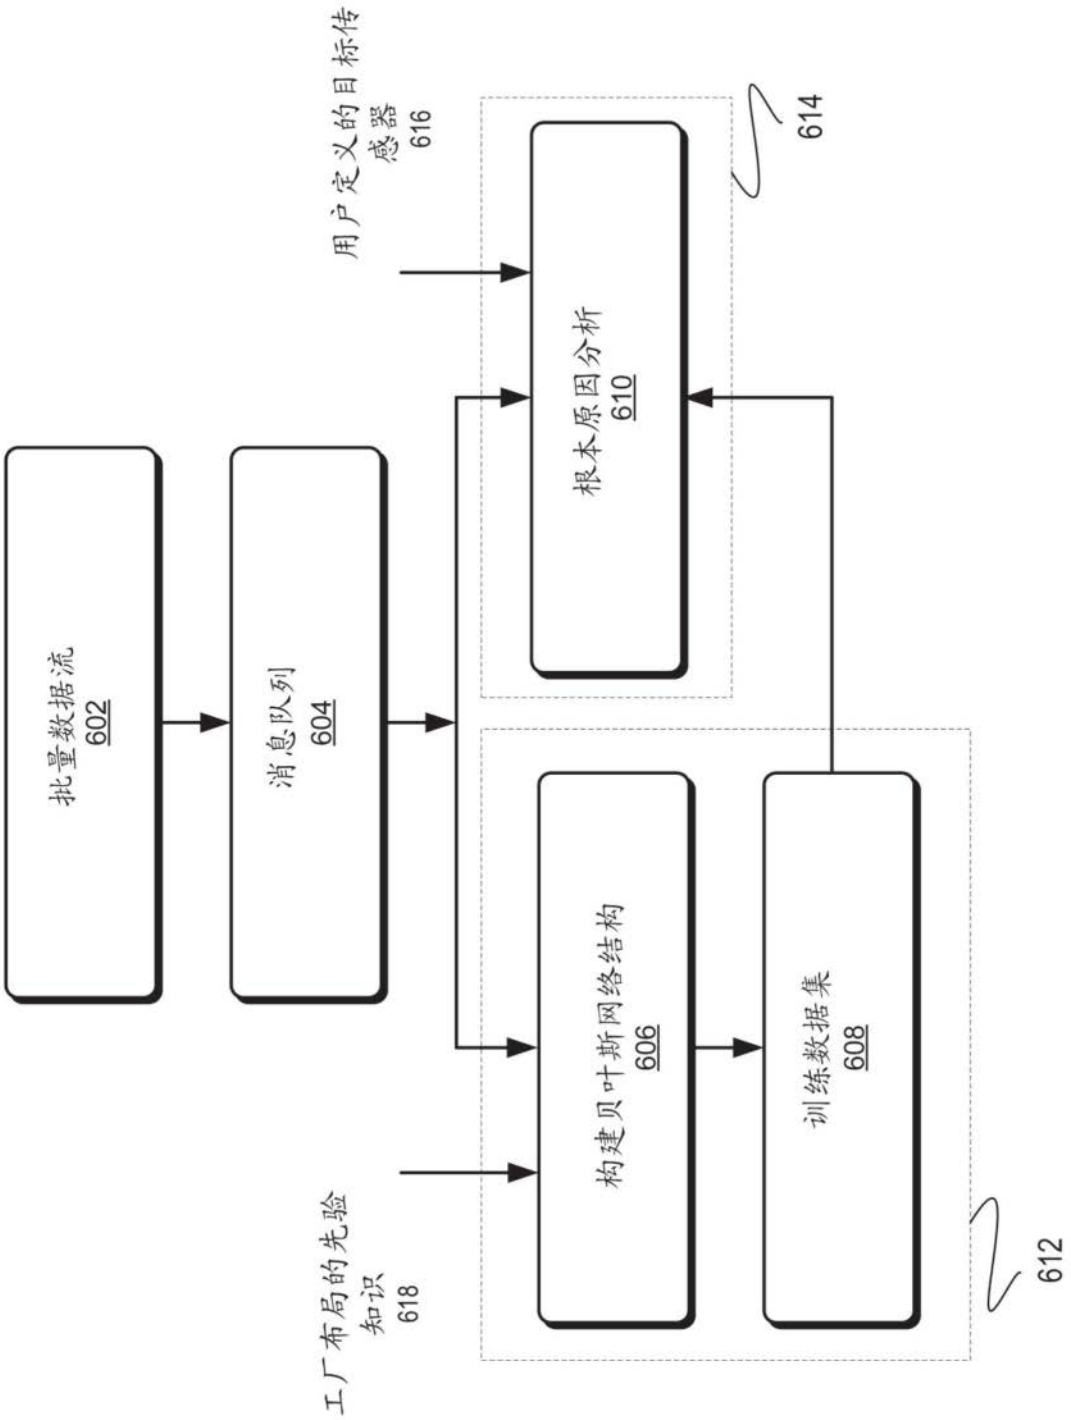

批量数据流
602
消息队列
604
用户定义的目标传感器
616
根本原因分析
610
614
构建贝叶斯网络结构
606
训练数据集
608
612
工厂布局的先验知识
618

图6

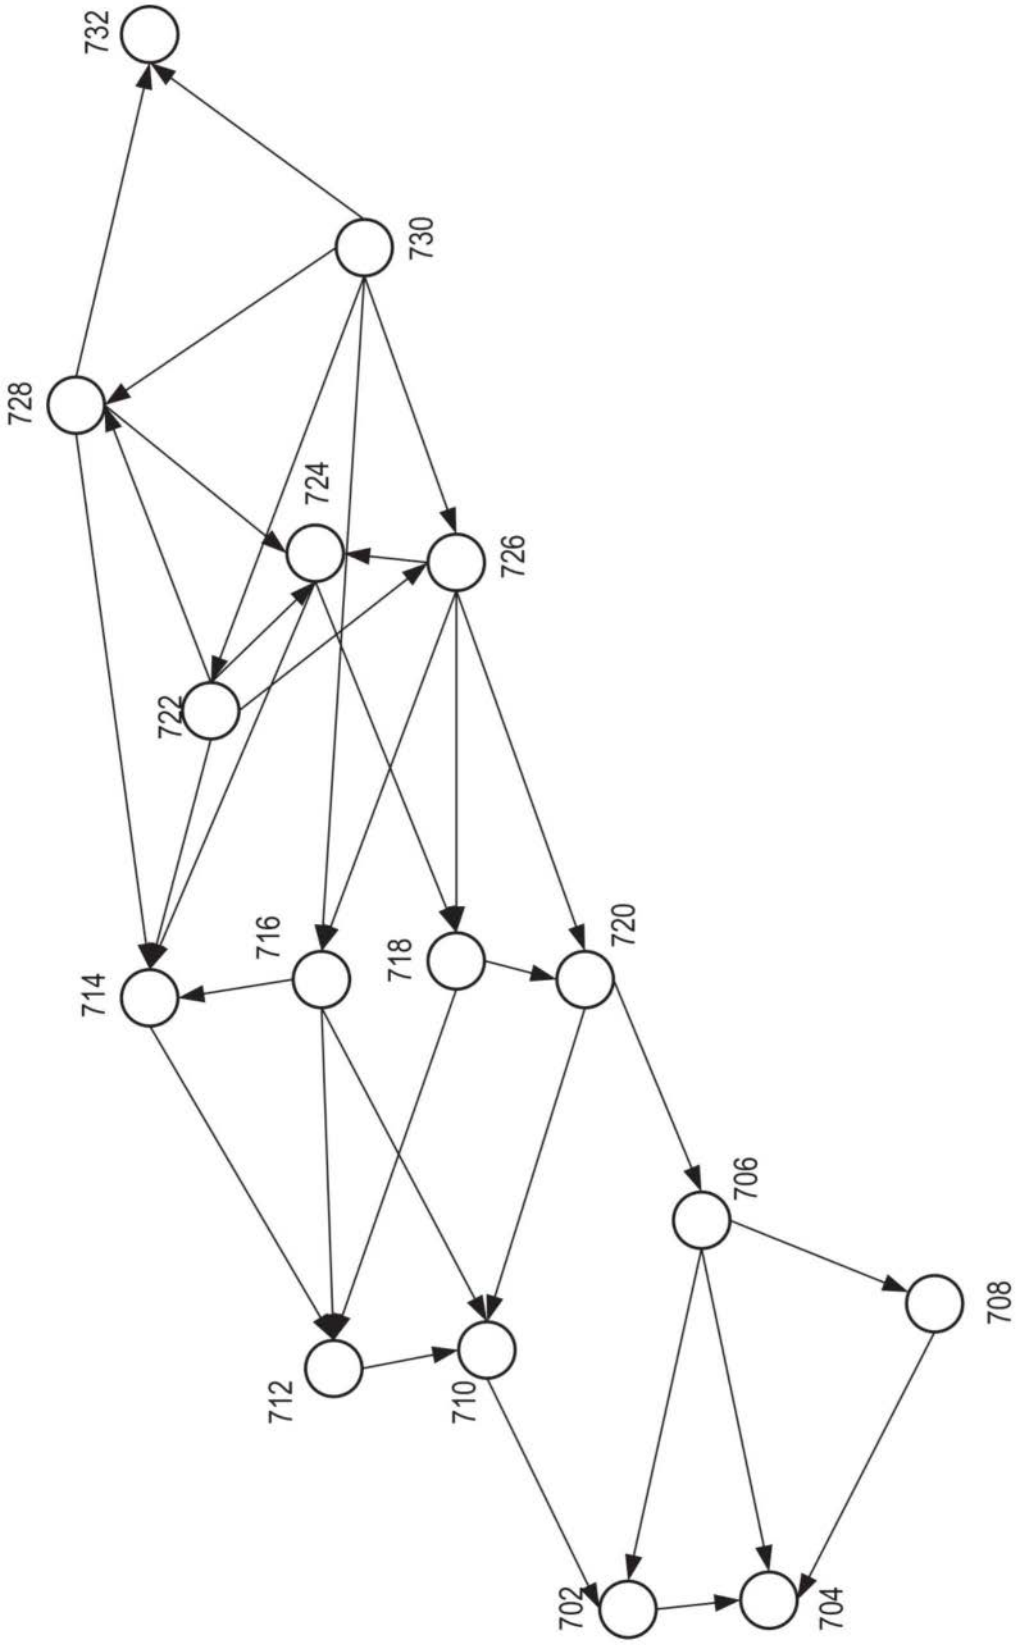


图7A

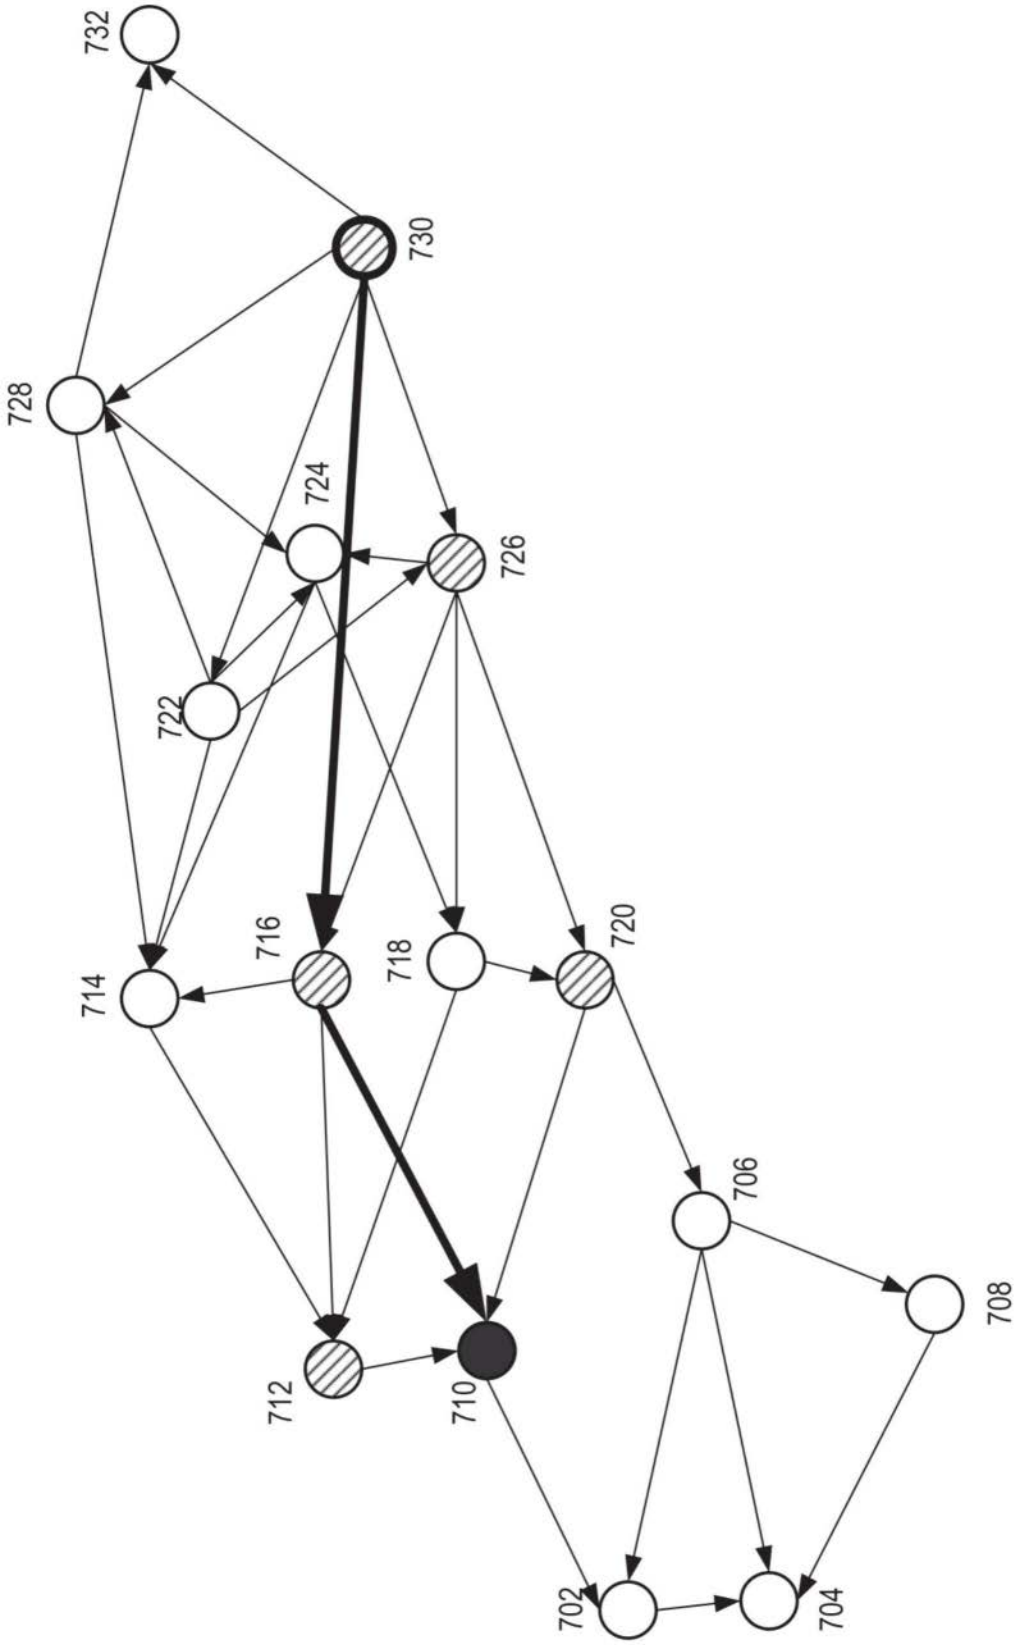


图7B

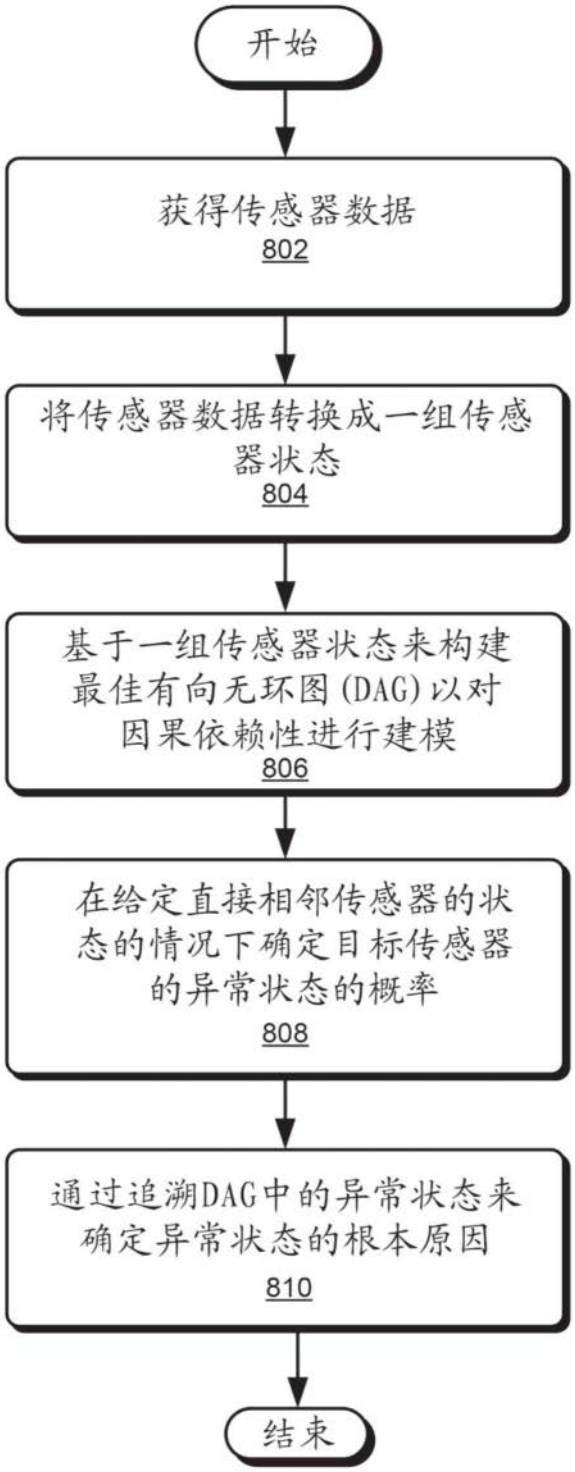

开始
获得传感器数据
802
将传感器数据转换成一组传感器状态
804
基于一组传感器状态来构建最佳有向无环图(DAG)以对因果依赖性进行建模
806
在给定直接相邻传感器的状态的情况下确定目标传感器的异常状态的概率
808
通过追溯DAG中的异常状态来确定异常状态的根本原因
810
结束

图8

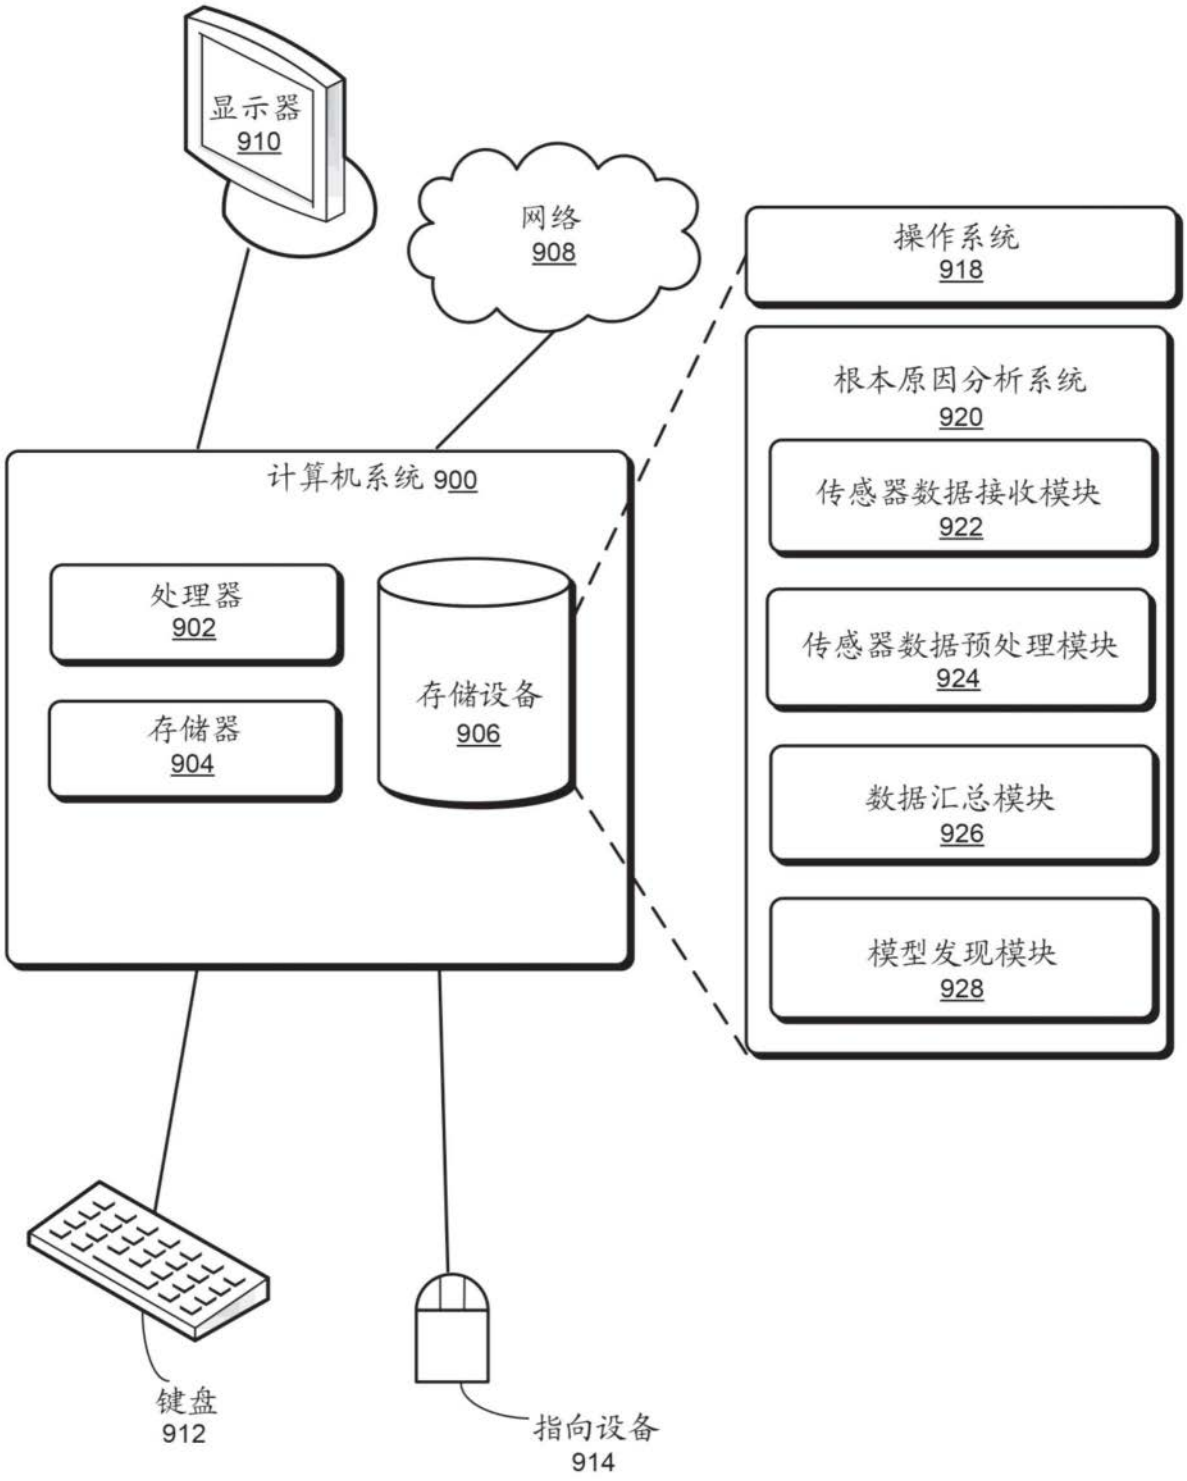

显示器
910
网络
908
操作系统
918
根本原因分析系统
920
传感器数据接收模块
922
传感器数据预处理模块
924
数据汇总模块
926
模型发现模块
928
计算机系统 900
处理器
902
存储器
904
存储设备
906
键盘
912
指向设备
914

图9

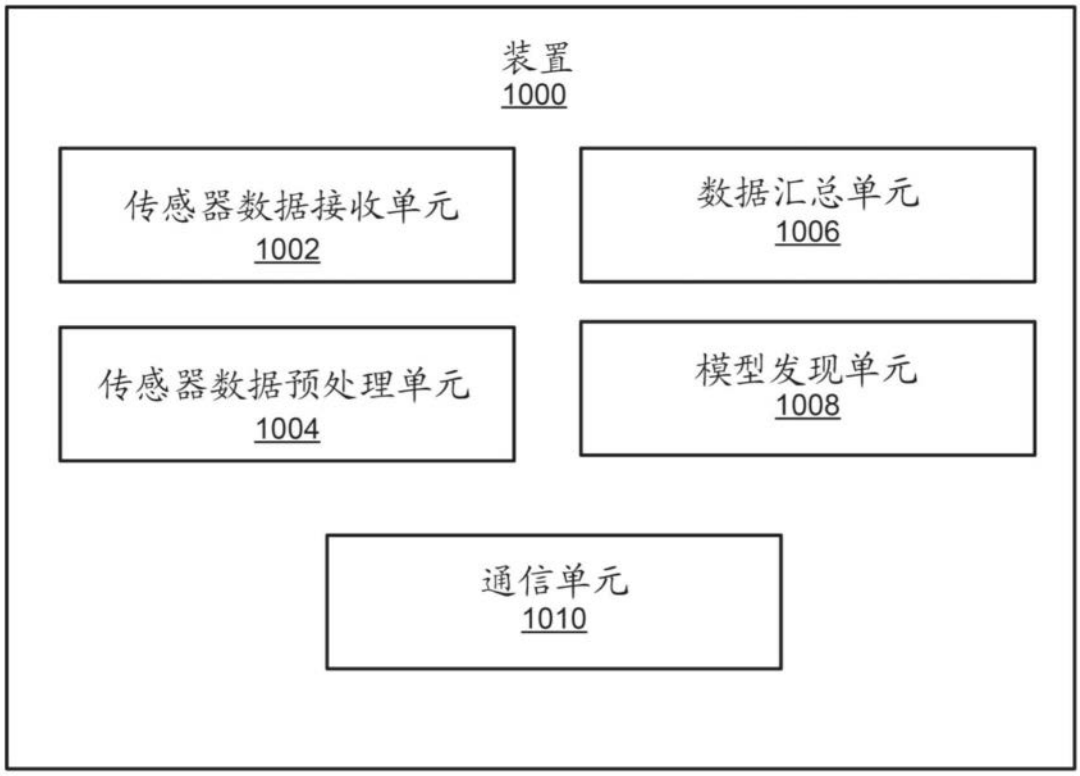

装置
1000
传感器数据接收单元
1002
数据汇总单元
1006
传感器数据预处理单元
1004
模型发现单元
1008
通信单元
1010

图10