



(12) 发明专利

(10) 授权公告号 CN 101776862 B

(45) 授权公告日 2014. 12. 17

(21) 申请号 200910148942. 3

(22) 申请日 2009. 05. 31

(30) 优先权数据

12/129632 2008. 05. 29 US

(73) 专利权人 通用电气公司

地址 美国纽约州

(72) 发明人 P·P·博尼索恩 J·E·赫尔希

R·J·小米切尔 R·V·苏布

A·V·塔瓦尔 胡晓

(74) 专利代理机构 中国专利代理(香港)有限公

司 72001

代理人 汤春龙 李家麟

(51) Int. Cl.

G06F 15/00(2006. 01)

G05B 13/02(2006. 01)

G05B 19/048(2006. 01)

(56) 对比文件

CN 88100520 A, 1988. 09. 28, 全文.

CN 1514928 A, 2004. 07. 21, 全文.

US 6539343 B2, 2003. 03. 25, 全文.

US 2004/0230368 A1, 2004. 11. 18, 全文.

US 2005/0114023 A1, 2005. 05. 26, 全文.

JP 特开平 7-13951 A, 1995. 01. 17, 全文.

审查员 李彦琴


权利要求书2页 说明书14页 附图35页

(54) 发明名称

用于对资产系统进行高级状况监视的系统和方法

(57) 摘要

本发明的名称为用于对资产系统进行高级状况监视的系统和方法,提供一种用于对资产系统进行高级状况监视的方法,包括使用多个自联想神经网络来确定多个工作状态的至少一个工作状态中的至少一个传感器感测的实际值的估算;从多个自联想神经网络的每一个自联想神经网络确定估算的感测值与至少一个传感器感测的实际值之间的残差;并使用模糊监控模型混合器组合残差;对所组合的残差执行故障诊断;以及通过分析组合的残差来确定资产系统的工作的变动。如果必要的话,提供告警。智能传感器系统(10)包括板载处理单元(11),板载处理单元(11)用于执行本发明的方法。



1. 一种用于对资产系统进行高级状况监视的方法,所述方法包括如下步骤:
将资产系统的工作空间分成多个工作状态;
使用多个自联想神经网络来确定多个工作状态中至少一个传感器感测的实际值的估算值;
基于来自所述多个自联想神经网络的每一个自联想神经网络的估算值与至少一个传感器感测的实际值之间的差确定多个残差;
使用模糊监控模型混合器来对所述多个残差执行加权求均值来确定综合总残差;
通过分析所述综合总残差来确定所述资产系统的工作条件的变动;以及
如果已确定所述资产系统的工作变动,则提供告警。
2. 如权利要求1所述的方法,其中所述自联想神经网络包括正切 s 状弯曲 tan-sigmoid(tansig) 类型的隐藏节点。
3. 如权利要求1所述的方法,其中所述自联想神经网络包括具有嵌入的线性变换函数的中央瓶颈层。
4. 如权利要求1所述的方法,其中所述告警步骤包括:通过从电缆、电力线传导、内联网、因特网和无线传输组成的组中选择的信息传输媒体来分发消息。
5. 如权利要求1所述的方法,其中当所述资产系统在所述多个工作状态的两个工作状态之间转变时执行在所述工作条件中确定所述变动的步骤。
6. 如权利要求1所述的方法,其中当所述资产系统在所述多个工作状态的两个工作状态之间转变时执行所述告警步骤。
7. 如权利要求1所述的方法,其中当所述资产系统在所述多个工作状态的其中之一中工作时执行在所述工作条件中确定所述变动的步骤。
8. 如权利要求1所述的方法,其中当所述资产系统在所述多个工作状态的其中之一中工作时执行所述告警步骤。
9. 如权利要求1所述的方法,其中所述模糊监控模型混合器在所述资产系统的所述多个工作状态上实现全局模型。
10. 如权利要求1所述的方法,其中所述至少一个传感器包括智能传感器。
11. 如权利要求10所述的方法,其中所述智能传感器连接到智能传感器系统。
12. 如权利要求11所述的方法,其中所述智能传感器系统包括板载处理单元,所述板载处理单元用于对所述资产系统进行高级状况监视。
13. 一种智能传感器系统(10),包括:
智能传感器(12),用于监视资产系统的工作状况,所述智能传感器经电缆(14)连接到输入端口(16);以及
板载处理单元(11),用于对所述资产系统进行高级状况监视,所述处理单元执行如下步骤:
将资产系统的工作空间分成多个工作状态;
使用多个自联想神经网络来确定多个工作状态中至少一个传感器感测的实际值的估算值;
基于来自所述多个自联想神经网络的每一个自联想神经网络的估算值与至少一个传感器感测的实际值之间的差确定多个残差;

使用模糊监控模型混合器来对所述多个残差执行加权求均值来确定综合总残差；
通过分析所述综合总残差来确定所述资产系统的工作条件的变动；以及
如果已确定所述资产系统的工作变动，则提供告警。

14. 如权利要求 13 所述的系统，还包括无线通信单元 (24)，所述无线通信单元用于以无线方式将信号从所述智能传感器系统 (10) 传送到外围处理设备 (26)。

15. 如权利要求 13 所述的系统，还包括显示和告警单元 (18)，所述显示和告警单元 (18) 用于显示来自所述处理单元 (11) 的计算结果。

用于对资产系统进行高级状况监视的系统和方法

技术领域

[0001] 本发明一般涉及基于状况的维护 (CBM), 具体来说涉及使用智能传感器对资产进行高级状况监视以改善资产维护的灵活性和响应度, 增加资产的运作可用性以及减少资产的生命周期总拥有成本。

背景技术

[0002] 有数十亿 (billion) 美元投入到固定厂房设备中, 这对支持工业和基础设施活动起着至关重要且时间迫切的作用。必不可少地, 应迅速地识别这些设备的退化, 以便在退化的设备失效且严重地影响它们所属的系统的效率, 甚至更严重地导致物理损伤大大延伸到失效设备之外前隔离或维修它们。

[0003] 多年以来, 维护不断发展, 从单纯对设备故障进行反应 (更正性维护), 到执行基于时间的预防性维护, 再到目前基于系统 / 资产的状况关注执行维护的需求 (基于状况的维护)。异常检测是设备监视、故障诊断和系统预测中的关键任务。它包括监视系统状态的变动以检测故障行为。对异常的早期检测将能够在潜在故障进一步发展, 导致继发损坏以及设备停机之前采取及时维护措施。现有的异常检测方法通常利用单变量技术来检测单个传感器测量中的变动。但是, 通常, 系统的状态由一起考虑的多种传感器测量值之间的相互作用和相互关系来表征。

[0004] 越来越需要基于状况的维护 (CBM) 以改进维护的灵活性和响应度, 增加运作可用性, 和减少寿命周期总拥有成本。

发明内容

[0005] 简言之, 一种用于对资产系统进行高级状况监视的方法包括如下步骤: 将资产系统的工作空间分成多个工作状态 (operating regime); 使用多个自联想神经网络 (AANN) 来确定多个工作状态的至少一个工作状态中至少一个传感器感测的实际值的估算; 从多个自联想神经网络的每一个自联想神经网络确定估算的感测值与至少一个传感器感测的实际值之间的残差 (residual); 以及使用模糊监控模型混合器组合这些残差; 对组合的残差执行故障诊断; 通过分析组合的残差确定资产系统的工作的变动; 以及如果已确定资产系统的工作的变动, 则提供告警。

[0006] 在本发明的另一个方面中, 一种智能传感器系统包括用于监视资产系统的工作状况的智能传感器, 该智能传感器经电缆连接到输入端口; 以及用于使用上一个段落引述的方法对资产系统进行高级状况监视的板载 (on-board) 处理单元。

附图说明

[0007] 当参考附图阅读下文的详细描述时, 将更好地理解本发明的这些和其他特征、方面和优点, 在所有这些附图中相似符号表示相似的部件, 其中:

[0008] 图 1 图示根据本发明的一个实施例的高级状况监视设备的示意图。

- [0009] 图 2 是操作员控制设定序列的流程图。
- [0010] 图 3A 是来自涡轮风扇发动机的归一化时间序列传感器数据,其中在序列结束时大修。
- [0011] 图 3B 表示用于对图 3A 的归一化时间序列应用的变动检测的 Hotelling T^2 统计的计算的输出。
- [0012] 图 4 图示使用峰度识别偏离正常。
- [0013] 图 5 图示 6 个系统监视器的仿真数据。
- [0014] 图 6 使用彩色编码图显示各个变量对 Hotelling T^2 的贡献。
- [0015] 图 7 示出使用熵和少数决定测量的异常值识别。
- [0016] 图 8 是传感器故障的数据生成的图表,其中左边图表中显示正常传感器测量,而右边图表中插进各个传感器故障(读数偏移),其中以红色箭头指示。
- [0017] 图 9(A) 是变量贡献矩阵的显示,其中突出显示的点指示对高 T^2 计分有责任的传感器。
- [0018] 图 9(B) 是 Hotelling T_2 统计的图表,其中尖峰 T_2 值指示传感器读数中的异常。
- [0019] 图 10 示出系统故障的数据生成,其中在系统故障的情况下生成虚线后的数据点。
- [0020] 图 11 是变量贡献矩阵的显示,其中突出显示的点指示对高 T_2 计分有责任的传感器。
- [0021] 图 12 是 Hotelling T_2 统计的图表,其中高的 T^2 值指示传感器测量中的异常。
- [0022] 图 13 是 7-5-3-5-7 自联想神经网络(AANN)的体系结构的示意图。
- [0023] 图 14 是使用 AANN 的异常检测范例的示意图。
- [0024] 图 15(A) 是典型原始传感器测量 $X_1(t), \dots, X_9(t)$ 的样本的显示。
- [0025] 图 15(B) 是与图 15(A) 的原始传感器测量 $X_1(t), \dots, X_9(t)$ 对应的残差值 $R_1(t), \dots, R_9(t)$ 的图表。
- [0026] 图 16 示出在测量第 5 个变量的传感器数据中插入大阶梯函数之后的残差值。
- [0027] 图 17 是使用飞行包络的不同工作状态的图示。
- [0028] 图 18(a)-(c) 示出来自不同工作状态的测试集上的不同 AANN 模型的残差。
- [0029] 图 19(a)-(c) 示出来自不同工作状态的测试集上的全局 AANN 模型的残差。
- [0030] 图 20(a) 和 20(b) 是系统工作状态的转变的图示。
- [0031] 图 21(a) 和 21(b) 分别是定义飞行工作状态的变量的飞行状态转变和模糊隶属函数的图示。
- [0032] 图 22 是通过模糊监控模型的 AANN 内插的方案示意图。
- [0033] 图 23(A) 和 23(B) 是飞行状态沿着图 20(A) 和图 20(B) 中定义的轨迹转变时来自 AANN_1 和 AANN_2 的残差的图表,以及图 23(C) 是来自模糊监控模型的残差的图表。
- [0034] 图 24 是在上方坐标轴系上将“当前”点与“过去”比较的时间序列故障检测的通用方法的图表,以及在下方坐标轴上未使用小的缓冲区(buffer)使差异更明显。
- [0035] 图 25(A)-(C) 是初始数据的置换(permutation)检验的图示;随机再贴标签(relabeling)的一种实现,分别用于 100000 个置换(实线)和原始排序(虚线)的检验统计量的分布。
- [0036] 图 26 是图示带有在红线处发生偏移变动的时序序列的单变量变动检测的示例的

图表,并且如果虚线是每种技术的告警阈值,则圆圈点是检测到变动的位置。部件列表 10 智能传感器系统 11 板载处理单元 12 智能传感器 14 电缆 16 输入端口 18 显示和告警单元 20 输出端口 22 局部控制 24 无线通信单元 26 外围处理设备 28 电源 30 输入端口

具体实施方式

[0037] 参考附图,在所有不同视图中完全相同的引用数字表示相同的组件,图 1 图示根据本发明实施例的智能传感器系统 10,该智能传感器系统 10 具有对一件或多件设备(未示出)(例如涡轮、电动机等)进行高级状况监视的一个或多个智能传感器 12。正如本文定义的,一件或多件设备包括资产系统(未示出)。在图示的实施例中,四个传感器 12 监视要由智能传感器系统 10 监视的资产系统的一件或多件设备的关注物理参数的工作状况。智能传感器系统 10 监视的工作状况包括但不限于压力、温度、振动等。将认识到,本发明不局限于传感器 12 的此数量,而是可以通过用于监视资产系统的任何期望数量的传感器来实施本发明。而且,还将认识到本发明不局限于监视关注物理参数的工作状况的传感器,而是可以通过监视具有可由传感器 12 测量的任何状况的任何装置、器件或系统的传感器来实施本发明。

[0038] 资产系统可以包括具有设备标签(未示出)的设备,设备标签识别正在被系统 10 监视的设备。产生来自传感器 12 的信号并由电缆 14 将其传输到智能传感器系统 10 的输入端口 16。对于多个传感器 12 可以有单个输入端口 16,或对于每个传感器 12 可以有单个输入端口 16。智能传感器系统 10 可以具有显示和告警单元 18,除了分析器设置外,显示和告警单元 18 上还可以显示计算结果或启动告警。计算结果也可通过输出端口 20 提供。智能传感器系统 10 还由一个或多个局部控制 22 来控制,一个或多个局部控制 22 可以由操作员手工设置。还可以通过经过输入端口 30 输入的指令来控制系统 10,并且还可以对系统 10 进行编程。系统 10 包括具有内置天线(未示出)的无线通信单元 24,用于以无线方式将来自智能传感器 10 的信号传送到外围处理设备 26(例如个人计算机等)。此特征使得能够通过因特网或其他有线或无线网络进行远程操作。系统 10 还包括电源 28,例如电池、能量收集器(energy harvester)等。多个这种智能传感器系统 10 以远程方式与外围处理设备 26 通信,可以采用分布式方式来部署以便在广泛分布式系统(例如,发电厂、基础设施资产)上实现高级状况监视。

[0039] 智能传感器系统包括板载(内置)处理单元 11,板载(内置)处理单元 11 包括计算硬件、存储器和传感器接口电路(例如模数转换器)。在一个实施例中,智能传感器系统 10 的板载处理单元对从传感器输入 16 得到的数据执行 Hotelling T^2 (T 平方)检验。正如信号分析领域中公知的,Hotelling T^2 检验是用于检验过程移位(process shift)(例如数据值簇的形心中的移位)的有效检验。对于要识别过程移位的 Hotelling T^2 检验,对初始监视活动遵循至少两个配置的其中之一是必不可少的。第一配置是有多个传感器且监视开始尝试基于多个数据簇之间的马哈拉诺比斯(Mahalanobis)距离来检测过程移位的情况。第二配置是有单个传感器的情况。对于此情况,利用来自单个传感器的数据本身的延迟版本处理该数据是必不可少的。

[0040] 可以通过两个不同的群体(party)来对智能传感器系统 10 编程以对资产系统进

行高级状况监视。第一群体是设备技术人员。设备技术人员设置控制：诸如但不以限制形式，采样率、样本的数量、分析窗口大小、后置滤波操作的选择和调节、数据输出格式化和传输类型以及结果的显示格式化。第二群体是设备操作员。操作员也设置控制：诸如且不以限制方式，要使用的传感器的数量和类型、感测的数据的数据延迟以及要执行的数据采集和处理的类型。图 2 中图示操作员控制设置序列 (control setting sequence) 的典型流程图。在步骤 S2.1 中，将设备标识符输入到高级状况监视系统 10 中。设备标识符驻留在设备标识标签上。设备标识符可以包括数字、字母和承载符号的其他信息，例如条形码（举例而非限制）。设备标识符还可以采用电子而不可视形式存在，例如 RFID 设备（举例而非限制）。将设备标识符输入到高级状况监视系统 10 可以通过多个途径的其中之一，例如（举例而非限制）操作员读取并输入可视标识标签、条形码读取器和 RFID 读取器。操作员控制设置序列然后进行到步骤 S2.2，其中操作员设置后续监视活动中要使用的传感器的数量。操作员控制设置序列然后进行到步骤 S2.3，其中操作员设置有关传感器输入的数据延迟。使用至少一个非零数据延迟的一个实施例包括存在单个传感器情况中的监视活动。如果在步骤 S2.2 中输入的传感器的数量是 1 且在步骤 S2.3 中输入非零数据延迟，则高级状况监视系统 10 将配置其处理，从而将利用单个传感器数据的延迟版本来处理该数据。操作员控制设置序列然后进行到步骤 S2.4，其中操作员被询问后续监视活动是否是比较运行。如果操作员输入“否”，则高级状况监视系统 10 将自行配置成执行 Hotelling T^2 统计而不包含或涉及相同设备标识符的先前监视活动的数据或结果，并且操作员控制设置序列进行到步骤 S2.8，高级状况监视系统 10 准备提取监视数据。如果操作员输入“是”，则操作员控制设置序列进行到步骤 S2.5，其中操作员被询问操作员是否要使用来自上次监视活动的已存储均值向量。如果操作员输入“是”，则操作员控制设置序列进行到步骤 S2.7，高级状况监视系统 10 加载或以其他方式访问相同设备标识符的上次监视活动的均值向量。操作员控制设置序列然后进行到步骤 S2.8，其中高级状况监视系统 10 准备提取监视数据。如果操作员输入“否”，则操作员控制设置序列进行到步骤 S2.6，其中认为操作员期望加载来自相同设备标识符的上次监视活动的实际工作数据。控制然后进行到 S2.8，高级状况监视系统 10 准备提取监视数据。

[0041] Hotelling T^2 技术过去是使用来自 GE90 航空发动机的真实监视数据检验的。图 3A 呈示在一段时间（包括由于磨损而在周期 2N 处进行大修时的时间）上从涡轮风扇发动机收集的一些示范传感器数据。示出的有三个轨迹对标记为周期 (#) 的横坐标。上方轨迹是废气温度 (EGT) 的轨迹。中间轨迹是燃油流速 (WFM) 的轨迹。下方轨迹是核速度 (core speed) (N2)。将认识到，随着发动机磨损不断进行，传感器测量中没有明显的移位趋势。图 3B 呈示包含图 3A 的数据计算 Hotelling T^2 检验的输出。将注意到，该 Hotelling T^2 统计从相对较低值的范围上升到远高得多的水平，远高得多的水平指示在本例中指示磨损的数据趋势 (data trend)。渐增的 T^2 统计反映系统状态偏离正常。

[0042] 一旦 Hotelling T^2 统计识别出复杂系统中的工作中的变动，则方法开始将驱使偏离正常工作的系统相关变量隔离。总的来说，Hotelling T^2 统计是简单但非常有效的技术，而且计算需求小。这些特征使得它适合于在线监视和手持设备中部署。如果复杂系统中的变动是由传感器导致的，则可以校正传感器故障。另一方面，如果复杂系统中的变动是系统相关的，则可以报告系统故障。

[0043] 对已发展的 Hotelling T^2 统计执行选择性的后处理是可能的,并且可以是非常实用的。这种后处理可以设计成反映例如统计量上升的速率、阈值交叉的时间以及数据趋势的持续时间等数据。后处理方法和技术包括(例如而非限制)基于 L1、L2 的曲线拟合或其他范数极小化技术、小波、模型拟合、中值滤波和其他降噪技术。

[0044] 多变量变动检测

[0045] 在复杂系统中,完全地装备并校准所有来自一组传感器的许多变量是不可能的。之所以这样是因为复杂系统将经历非常大数量的状态,而且将以非常大数量的模式工作,每种模式在状态空间中展现唯一的正常工作包络。

[0046] 因此,设想将反映复杂系统在运作上偏离正常的通用检验是极其困难并且或许是不可能的,但是由于与实现和部署大的复杂系统关联的成本的原因,将创新的工作扩展到更好地逼近用于正常偏离、这种偏离在时间上的位置以及驱使偏离正常工作的系统相关变量的识别的有效通用检验是必不可少的。还期望开发一种途径,将反映复杂系统的工作偏离正常中的显著且易于识别的变动,无需对多于额定数量的检验结果的最初分析,即,如果在单个检验结果中清晰地反映系统的工作状态中的任何显著变动,则这是理想的。

[0047] 本发明的方法的一个方面在于,使用复杂系统的监视数据的信号处理来确定复杂系统何时偏离正常工作。该方法还识别其数据指示偏离正常工作的系统相关监视变量。

[0048] Hotelling T^2 统计或 T^2 是信号处理领域中公知的。Harold Hotelling 首先提出的,它是马哈拉诺比斯距离(另一个统计领域中公知的技术)的平方,是多变量假设检验中使用的学生 t 统计的推广。它参照具有均值 $\mu = (\mu_1, \mu_2, \dots, \mu_p)$ 的一组 p 个变量 $x = (x_1, x_2, \dots, x_p)$ 和 $p \times p$ 的协方差矩阵 W,其中 W 是由取自系统相关变量的 n 个快照(snapshot)形成的
$$W = \sum_{i=1}^n (x_i - \mu_i)(x_i - \mu_i)' / (n-1)$$

[0049] Hotelling T^2 统计或 t^2 定义为 $t^2 = (x - \mu)' W^{-1} (x - \mu)$ 。Hotelling T^2 统计、 t^2 的期望行为是基于如下假设, $x = (x_1, x_2, \dots, x_p)$ 构成联合 p-变量高斯分布。在实践中,从未见过这种分布。但是,Hotelling T^2 统计和基于相同假设预测的许多其他统计可以对系统分析贡献了巨大价值。

[0050] 当使用 Hotelling T^2 统计时,利用从合理地确信系统处于稳定工作时期时观测系统相关变量的传感器获取的数据来提供训练周期一般是可取的。在此类时期期间,假设存在均值 $\mu = (\mu_1, \mu_2, \dots, \mu_p)$ 并可以通过求平均来得到。

[0051] 使得一维 Hotelling T^2 统计展示可检测的变动的是 P 维协方差矩阵 W 中的变动或均值 μ 中的变动。要利用多个测量的系统相关变量的维数减少到单个 Hotelling T^2 统计,以及要有效地产生两组快照上的 Hotelling T^2 统计中的变动 Δt^2 ,可以通过以下计算来完成此计算 $\Delta t^2 = (x^* - \mu^*)' W_2^{-1} (x^* - \mu^*) - (x - \mu)' W_1^{-1} (x - \mu)$ 其中 W_1 和 W_2 、x 和 x^* 以及 μ 和 μ^* 分别是在第一组和第二组快照上进行计算的。

[0052] 快照传感器数据是在一段时间(包括由于磨损而进行大修时的时间)上从涡轮风扇发动机收集的。图 3A 示出十一个变量中三个变量的归一化传感器测量值:废气温度 -EGT、燃油流速 -WFM 和核速度 -N2。从图 3A,可以看出随着发动机磨损,传感器测量值中没有明显趋势或移位。首先,使用来自前 1000 个飞行周期的数据(点)来估算样本均值和样本协方差。接下来,直接对所有数据(包括 EGT、WFM、N2 以及一些其他关键参数)计算 T^2

统计。在图 3B 中,可以见到 T^2 计分的上升趋势,随着逼近导致其大修的发动机磨损水平显示更高的值。

[0053] 计算 Hotelling T^2 统计中所涉及的主要任务是计算协方差矩阵。可以采用多种方式来估算此矩阵。这些方式包括(无隐含的限制)如下的直接方法:首先获取顺序的多组个体变量值,在获取的值上计算变量的均值,从各组变量减去均值,然后执行适合的成对相乘和样本量相除。还可以通过在不同变量对上形成最小体积(volume)椭圆体来形成该协方差矩阵的估算。此方法公认为在存在破坏的数据(corrupted data)的情况下为高度鲁棒性且适合于处理异常值和其他疑似破坏的数据,该方法将获得变量的均值和协方差矩阵的项的良好估算。估算协方差矩阵的另一种方式是通过在 n 个快照上构造连续的差值估算器。此估算器由 $x = (x_1, x_2, \dots, x_n)$ 构造为 $V_i = x_{i+1} - x_i$, $i = 1, 2, \dots, n-1$, 并用于形成

$$W = \frac{1}{2(n-1)} \sum_{i=1}^{n-1} V_i V_i'$$

[0054] 在系统退化的一些重要情况中,监视的系统相关变量的均值可以具有慢速线性漂移(linear drift)。如果用于构造协方差矩阵的估算的连续差值相隔距离大于 1,则 Hotelling T^2 统计将更可能揭示这些漂移。因此,包括样本数差值 δ 上形成连续差值 $V_i = x_{i+\delta} - x_i$ 其中 $\delta > 1$ 的处理方式选择是值得的。

[0055] 有许多种可能的技术用于确定一系列快照上的 Hotelling T^2 统计中的显著变动或一系列快照上 Hotelling T^2 统计的成对变动的位置。这些技术包括(举例且非限制)能量检验和较高阶弯矩检验,具体来说,通过将四阶累积量(fourth cumulant)除以方差的平方,然后减去三(3)计算的过多峰度的使用。图 4 示出样本 T^2 数据上宽 20 个样本的滑动窗口上计算的峰度的图表。注意,当第一个反常点在样本编号 55 处进入窗口时峰度突发。其他技术包括设置阈值。可以采用多种方式来设想适合的阈值。举例而非限制,可以通过分析在正常系统工作期间取得的历史数据并使用该历史数据的第一部分估算系统相关监视变量的均值和系统相关监视变量的协方差矩阵来选择阈值。可以使用历史数据的第二部分(与第一部分不重叠)来识辨描述 T^2 统计的行为的概率密度函数。然后可以采用多种方式来设置阈值。一种此类方式(举例而非限制)是,计算正常工作下误报告警的概率和误报告警的预期成本,并将阈值设置为使得正常工作下每个样本的成本将少于或等于强加的成本(imposed cost)。

[0056] 系统变动和变量含义

[0057] 一旦 Hotelling T^2 统计识别出复杂系统的工作中的变动,则方法开始将驱使偏离正常工作的系统相关变量隔离。执行此步骤的一种方式,首先依据其主成份(principal components, PCA)表达 Hotelling T^2 统计。为此,首先将 T^2 表示为:

$$T^2 = \sum_{a=1}^n \frac{t_a^2}{\lambda_a} = \sum_{a=1}^n \frac{t_a^2}{s_a^2} \quad \text{其中}$$

$\lambda_a, a = 1, 2, \dots, n$ 是协方差矩阵 W 的本征值, t_a 是根据主成份变换的计分。 s_a^2 是 t_a 的方差(主成份的方差是 W 的本征值)。每个计分 t_a 可以表示为:

$$t_a = p_a'(x - \mu) = \sum_{j=1}^n p_{a,j}(x_j - \mu_j)$$

其中 p_a 是 W 对应于 λ_a 的本征值,而 $p_{a,j}, x_j, \mu_j$ 是与第 j 个变量关联的对应向量的元素。通过这种表示,发现每个变量 x_j 对主成份 a 的计分的贡献是 $p_{a,j}(x_j - \mu_j)$ 。可以使用此信息来识别对 Hotelling T^2 度量所测量的异常具有最强影响的变量。

[0058] 下一步是, 计算归一化计分 $(t_a/s_a)^2$ 中出现的变量的贡献 $\text{cont}_{a,j}$ 。
有 $\text{cont}_{a,j} = (t_a/s_a^2)p_{a,j}(x_j - \mu_j)$ 。然后通过如下求和来计算变量 x_j 的总贡献:

$\text{CONT}_j = \sum_{a=1}^n (\text{cont}_{a,j})$ 现在可以按如下公式将 Hotelling T^2 统计写为所有计分上所有变量

的贡献之和: $t^2 = \sum_{a=1}^n \frac{t_a^2}{s_a^2} \sum_{j=1}^n p_{a,j}(x_j - \mu_j) = \sum_{j=1}^n \left\{ \sum_{a=1}^n \frac{t_a^2}{\lambda_a} [p_{a,j}(x_j - \mu_j)] \right\}$

[0059] 作为用于确定复杂系统何时偏离正常工作以及评估多个变量的贡献的技术示例而非限制, 可考虑有六个变量 $x_1, x_2, \dots, x_6$, 它们展示图 5 图表所示的顺序值。用于这六个变量 $x_1, x_2, \dots, x_6$ 的数据是从高斯随机变量生成器的独立采样得到的, 然后根据如下进行修改: $x_1(55) = +4x_2(60) = -4x_3(65) = +3x_4(65) = -3x_5(81:85) \leftarrow x_5(81:85) + 3x_6(81:85) \leftarrow x_6(81:85) + 3$

[0060] 对图 5 的数据计算 Hotelling T^2 统计、 T^2 , 其中使用六个变量的每个变量的前 50 个样本来估算协方差矩阵。下一步是说明在统计高于阈值的点处六个变量对 Hotelling T^2 统计的不同贡献。可以采用多种方式来执行此操作。举例而非限制, 在数据点 i 处第 j 个变量对主成份的计分的贡献的量值 $M_{i,j}$ 是 $M_{i,j} = |p_{i,j}(x_j - \mu_j)|$, 在该量值的所有变量贡献

上归一化的相对量值表示为 $M'_{i,j}$ 并计算为 $M'_{i,j} = \frac{M_{i,j}}{\sum_{j=1}^n M_{i,j}}$ 可以使用彩色编码来显示贡

献量值和相对量值, 以帮助操作员解释结果。图 6 使用彩色编码图示在所有 100 个点处六个变量对 Hotelling T^2 统计的不同贡献。彩色编码块网格示出横坐标上列出的六个变量 $x_1, x_2, \dots, x_6$ 在纵坐标上的相对贡献。

[0061] 在另一个实施例中, 还可以通过熵测量 E_i 和少数决定测量 m_i 分辨异常值 (例如如图 7 中识别的那些), 其中 $E_i = -(1/\ln(n)) \sum_{j=1}^n M'_{i,j} \ln(M'_{i,j})$ 以及 $m_i = 1 - \max_j (M'_{i,j})$ 。图 7 描绘超出阈值的那些 T^2 点的 E_i 和 m_i 。出于说明的目的, 考虑了两个不同的阈值。第一个阈值 (图 7 左边) 是导致 5 个 T^2 计算超过阈值的阈值。第二个阈值 (图 7 右边) 是导致 10 个 T^2 计算超过阈值的较低阈值。

[0062] 作为用于确定复杂系统何时偏离正常工作以及评估多个变量的贡献的技术示例而非限制, 可考虑 GE90 cyclodeck 模型中有九个关键传感器 $x_1, x_2, \dots, x_9$, 它们展示图 8 图表所示的顺序值。用于 9 个变量 $x_1, x_2, \dots, x_9$ 的数据是在不丢失效率和流的正常飞行状况下仿真 cyclodeck 时生成。我们可以将那些数据视为“无故障”数据。为了仿真传感器故障, 我们有意地在不同时间修改一些传感器读数: $\text{ZPCN25}(130) = 100\text{PS3}(150) = 170\text{T3}(170) = 1310\text{T49}(181:185) = 1770$

[0063] 下一步是图示九个变量对 Hotelling T^2 统计的不同贡献。可以采用多种方式来执行此操作。可以显示贡献量值和相对量值, 以帮助操作员解释结果。可以对该显示进行彩色编码。图 9A 示出按所指示的相对贡献量图。网格示出横坐标上列出的九个变量 $x_1, x_2, \dots, x_9$ 在纵坐标上的相对贡献。基于来自 9 个传感器的时间序列数据来计算 T^2 统计, 如图 9B 所示。 T^2 统计值中的峰值的位置对应于插入传感器故障所在的位置。具有高贡献

的传感器变量意味着 T^2 计分中的变动。有价值地,通过变量贡献分析识别的传感器恰恰是插入故障的传感器。

[0064] 为了仿真系统故障,重新配置 cycdeck 模型参数流和效率,从正常状况(“无故障”)工作到系统故障。如图 10 所示,虚线之后的点对应于系统故障。在图 12 中, T^2 统计从系统故障开始处 200 快速爬升。而且,贡献分析精确地识别出偏离正常的传感器,如图 11 所示。就某种程度而言,这是一种区分传感器故障和系统故障的方法,因为多个传感器同时有故障的可能性是非常低的。

[0065] 一旦检测到异常行为,可以通过多种方式将报告该分析结果的告警传送到系统监视负责人,包括但不限于电缆连接、经电力线传导(power line conduction)的信息传输、内联网、因特网或无线方式。

[0066] 传感器验证

[0067] 对于可靠的状况监视,具有精确的传感器信息是必不可少的。但是,传感器有时可能发生故障或甚至可能因故障或维护活动而变为不可用。因此传感器验证是状况监视的至关重要的部分。传感器验证的传统方法包括周期性仪器校准。这种校准在人力停歇和过程停机时间上来说均是成本高昂的。

[0068] 为了解决与传感器验证关联的问题,本发明使用基于自联想神经网络(AANN)的传感器验证模型,该模型可以执行平台部署的(platform-deployed)传感器的在线校准监视。该模型的特征允许通过将原始传感器测量(它是模型的输入)与传感器值的基于模型的对应估算比较来检测传感器漂移或失效。此外,对原始传感器测量或实际传感器测量与传感器估算之间的残差进行监控分析还可以帮助区分传感器故障和系统故障。按照定义,残差是实际测量的或感测的值与对应估算的值之间的差。残差向量是一组实际值与对应的一组估算值之间的差。小子集的传感器测量的残差中的显著偏差将指示传感器故障,而大子集传感器测量的残差中的显著偏差将指示系统故障。来自单个传感器的残差中的偏差通常是传感器故障的指示,而来自多个传感器的残差中的多个偏差通常是系统故障的指示。

[0069] 至 AANN 的输入经过维数缩减,因为在中间层中将它们的信息组合并压缩。例如,在图 13 中,在第二层(编码)中,将输入层中的七个节点减少到 5 个,然后在第三层(瓶颈)中减少到 3 个。然后,使用第三层中的节点、采用经过维数扩增的方式来重建原始输入(第四层,解码和第五层,输出)。在理想的情况中,AANN 输出应当与输入完全相同。在故障诊断判定执行 260 中使用它们的差值(图 14,残差)。

[0070] 实质上,此网络计算最大非线性主成份(NLPCA)-中间层中的节点-以便识别并去除变量之间的相关性。除了如本申请中所述的生成残差外,这种类型的网络还可以用维数缩减、可视化和探索性数据分析。要注意,PCA 仅识别变量之间的线性相关性,而 NLPCA 揭示线性相关性和非线性相关性两者,而对数据中存在的非线性特征没有限制。NLPCA 通过训练前馈神经网络以执行恒等映射来工作,其中在输出层再现网络输入。该网络包含内部“瓶颈”层(包含比输入或输出层少的节点)(这强制网络开发输入数据的紧凑表示)和两个附加的隐藏层。嵌入在隐藏节点中的非线性函数通常是 tansig (正切 s 状弯曲)类型的,而中央瓶颈层嵌入有线性变换函数。

[0071] 可以利用物理模型来生成不同工作状况下的传感器读数的标称值,由此可以将原始传感器测量与标称读数之间的残差(图 16)用于时间上的趋势变动。但是,当物理模型

不可用时,需要从原始测量直接推断标称传感器读数。先前,当测量中的信息在分析上来说是冗余的(就此意义而言如果一个测量丢失,可以采用来自其余有效传感器的估算替代它)时,使用自联想神经网络(AANN)来进行传感器验证。另一方面,本发明使用AANN来估算正常状况下的传感器测量,然后可以使用原始测量与正常测量之间的残差来推断传感器/系统中的异常状况。

[0072] 我们使用九个值的状态向量表示从GE90 cycledeck模型生成的航空发动机数据。使用此数据集,我们构建9-5-3-5-9 AANN,遵循图13所示的体系结构。图14中图示了用于估算传感器值的神经网络,其中本实施例的神经网络具有(仅举例的目的而非限制)7个输入、5个编码层节点、3个瓶颈层节点、5个解码层节点和7个输出。我们将这种神经网络体系结构称为 $7 \times 5 \times 3 \times 5 \times 7$ 。结构200显示实际传感器值(在框210中为图示方便而分在一组)以及至5级神经网络270的输入层215的输入。还将实际传感器值发送到组合器250。正如神经网络领域中公知的,输入层215的输出是编码层220的输入。编码层220的输出是瓶颈层225的输入。瓶颈层225的输出是到解码层230的输入。解码层230的输出是到输出层235的输入。解码层235的输出构成传感器值的估算(在框240中为图形化方便而分在一组)。将传感器值估算发送到组合器250,其中通过从估算的传感器值减去实际传感器值来形成残差255。将残差输入到模块260,模块260对残差执行判断,以便区分并报告任何推断的故障诊断。有两个可选输入至判定执行模块260。这些输入的第一个输入212来自内部信息模块211,并且包含已处理的内部信息。已处理的内部信息包括(举例而非限制)已知存在于实际传感器值210中间和之间的基于物理的模型和关系。将这些值从实际传感器值210输入到内部信息模块。这些输入的第二个输入214来自外部信息模块213,并且包含收集并处理的外部信息,该外部信息包括(举例而非限制)自动或手工输入的厂房信息,涉及操作员注释、厂房供电参数(例如电源质量)、设备工作点的临时变动、以及环境因素。故障诊断可以包括(举例而非限制)例如序贯概率比检验(SPRT)等公知的统计技术。

[0073] 图15(A)和15(B)图示当系统或传感器中不存在故障时图15(A)中的典型原始传感器测量及图15(B)中的它们的对应残差值。在这些情况下,残差通常比原始数据小两个数量级。然后我们在测量第5个变量(ZT49)的传感器中插入大阶梯函数,并注意到对应的残差展示最大影响,而其他残差显示小得多的变动。图16中说明了此情况。

[0074] 为了将检测过程自动化,我们建议使用原始数据测量的平均值,即 $E_i = \frac{R_i}{\bar{X}_i}$ 来将残差 R_i 归一化。

[0075] 然后我们可以计算例如 $FOM = \sqrt{\frac{1}{nm} \sum_{i=1}^n \sum_{j=1}^m \left(\frac{R_{ij}}{\bar{X}_i} \right)^2}$ 的品质因数来对残差的总量

值评估。如果FOM小于指定的阈值,则我们可以断言不存在异常。否则,检测到异常。当存在一个大(按百分比来说)残差值时,我们将异常识别为传感器故障。当所有残差大于基线但是对FOM的贡献大致相等时,则存在两种可能性:(1)这是系统故障;或(2)该AANN不适于生成残差(即,该AANN是在与提取当前原始数据所在的状态空间区域不同的状态空间区域中训练的)。

[0076] 用于不同工作状况的传感器验证

[0077] 当系统工作所在的工作状况或模式变动时,系统的特征可能相应地变动。例如,空气涡轮具有例如基本负载、部分负载和满负载等工作模式。在每种模式下,系统表现有所不同,且被系统输出(功率等)及其传感器测量(温度、压力、振动等)捕获到。在前一段中,我们调整(leverage)AANN模型以执行已知工作状态内的传感器验证。实质上,使用AANN模型来学习系统特征。当工作状态变动时,底层AANN模型也需要变动(或重新训练)。

[0078] 举例而非限制的方式,考虑监视的机械是正在根据高度(ALT)、环境温度(Tamb)和马赫数(Mach)来监视的喷气发动机,例如GE90航空发动机。考虑该发动机在三个不同工作状态中工作,并且已知何时工作状态之间转变是已知的。图17图示如下示例,其中三个工作状态表示为具有高度轴、马赫数轴和环境温度轴的三维空间中的体积的二维投影。图17中图示将体积投影到二维高度-环境温度空间上。所示关联的图表表示将体积投影到三个高度轴、马赫数轴和环境温度轴上。工作轨迹中、穿过工作轨迹以及在工作轨迹之间的喷气发动机工作的轨迹公知是飞行包络或FE。从每个工作状态随机地生成1000个正常工作点。对于生成的每个工作点,有九个值的状态向量与之对应。

[0079] 使用此数据集,我们分别为三个工作状态构建9-5-3-5-9AANN,遵循图13所示的体系结构。在每个AANN模型的训练阶段期间,使用900个数据点。其余100个数据点预留用于检验。图18(A)-(C)示出来自不同工作状态的测试集(test set)上的AANN模型的残差。因为AANN1是在工作状态1内训练的,其中提取测试集1,所以图18(A)中的残差小。对于图18(B)中的测试集3上的AANN3,情况相同。但是,当图18(C)中在测试集2(来自不同的工作状态)上检验AANN1时,残差通常比先前情况高一个或两个数量级。

[0080] 应对不同工作状态的另一个方式是在所有工作状态上构建全局模型。这样,当工作状态变动时,可以使用全局模型来捕获系统的行为。但是,因为该模型是在全部工作状态上构建的,所以在捕获局部状态中系统的特征时精确度较低。图19(A)-(C)示出来自不同工作状态的测试集上的全局AANN模型的残差。因为全局AANN模型是在所有三(3)个局部工作状态上训练的,所以测试集2上的残差(图19(C))远小于图18(C)中的残差。但是,图19(A)和(B)中的残差大于图18(A)和(B)中的残差。

[0081] 如果能够识别局部工作状态的话,就更好地捕获局部系统特征而言,构建局部模型优于构建全局模型。

[0082] 工作状态转变的模糊监控模型

[0083] 通常,工业资产或系统是在不同状况/模式下工作的。对应于不同的工作状态,系统表现有所不同。为了更好地表示不同工作状态下的传感器特征,需要多个传感器验证模型来捕获这些传感器之间的关系。如何自动地检测工作状况的变动,并确定适合的局部传感器验证模型成为问题所在。

[0084] 局部模型可以捕获其指定的工作状态内的系统动态特性。但是,在转变状态中,定制的局部模型都无法精确地捕获系统的动态特性。所以在转变阶段期间生成的残差将超过告警阈值,并导致误报的肯定告警(positive alarms)。目前针对此问题部署的一种常见解决方案是,如果我们知道系统经历工作状态的转变,则忽略生成的告警。此方法的缺点在于,使用局部模型的系统监视被中断,且存在遗漏转变阶段期间生成的一些真正的故障告警的风险。

[0085] 一般来说,本发明使用模糊监控模型混合器来基于工作状态变动来管理传感器验

证模型之间的转变以解决这些问题。确切地说,我们使用模糊逻辑 (FL) 来编写监控模型的规则以控制工作状态变动时局部模型的转变。有大量文献专门论述模糊逻辑及其在基于规则的近似推理中的应用。将具有适合数学结构的语言 IF-THEN 规则构建到监控模型中,以判定局部模型与当前工作状况的适合度。当对于来自局部模型的残差对合并的输出的贡献进行加权时,将不同局部模型的拟合度考虑进来。为了演示,使用 GE90 cyclodeck 仿真器生成数据。实验结果显示,利用控制局部传感器验证模型的转变的监控模型,传感器估算对于工作状态变动更精确和更具鲁棒性。

[0086] 模糊逻辑提供一种语言,我们可以利用其语法和局部语义 (local semantics) 解释有关要解决的问题的定性知识。具体来说,FL 允许使用语言变量 (linguistic variable) 来对动态系统建模。这些变量取模糊值,这些模糊值由标记 (label) (由语法生成的句子) 和含义 (meaning) (局部语义过程确定的隶属函数) 来表征。语言变量的含义可以解释为其值的弹性约束。基于广义取式推理,模糊推理运算传播这些约束。此推理机制具有其内插特性,它赋予 FL 针对系统参数中的变动、干扰等的鲁棒性,这是 FL 的主要特征之一。

[0087] 模糊规则库 R 的最常见定义是析取解释,并且在大多数模糊控制器应用中模糊规则库 R 的最常见定义为如下形式: $R = \bigcup_{i=1}^m r_i = \bigcup_{i=1}^m (\bar{X}_i \rightarrow Y_i)$ R 由 m 个规则的析取 (disjunction) 组成。每个规则定义模糊状态向量与对应的模糊动作之间的映射。笛卡尔积运算符表示每个规则。

[0088] 可以将 FC 的推理机定义为模糊产生性规则 (fuzzy production rules) 上工作的并行前链规则 (parallel forward-chainer)。输入向量 $\bar{I}$ 与每个 n 维状态向量 $\bar{X}_i$ 匹配,即规则 $(\bar{X}_i \rightarrow Y_i)$ 的左手边 (LHS)。匹配 λ_i 的程度指示可以将规则输出应用于整个 FC 输出的程度。FC 的主要推理问题是:模糊预测求值的定义 (这常常是概率测量); LHS 求值 (这通常是三角模); 结论分拆 (conclusion detachment) (这常常是三角模或实质蕴涵运算符); 以及规则输出汇总 (这常常是规则库的析取解释的余三角模 (triangular conorm) 或逻辑乘 (conjunctive) 情况的三角模)。在常用假设下,我们可以将模糊系统的输出描述为 $\mu_Y(y) = \text{Max}_{i=1}^m \{ \text{Min}[\lambda_i, \mu_{Y_i}(y)] \}$ 其中 λ_i 是规则 r_i 的适用度 $\lambda_i = \text{Min}_{j=1}^n \Pi(X_{i,j}, I_j)$ 以及 $\Pi(X_{i,j}, I_j)$ 是表示参考状态变量之间的匹配的概率测量值。这三个公式描述广义取式推理,是解释模糊规则集的基础。

[0089] 我们使用在前文描述的三个局部工作状态上构建的三个相同的局部 AANN 模型。仿真的系统的工作状态沿着图 20 (A) 所示的轨迹逐渐从飞行包络 FE 1 移位到 FE 3。图 20 (A) 和 20 (B) 是工作状态的转变的不同表示。

[0090] 设计模糊隶属函数,它使用定义工作状况的体积的轴。图 21 (A) 和 (B) 中图示了这一点,其中示出随着仿真的系统在不同的工作状态中转变的飞行包络变量的值。附图的左边上,我们见到飞行包络变量的“低”、“中”和“高”的隶属函数的定义。

[0091] 然后,我们可以指定三个模糊规则的模糊规则集,例如表 1 中描述的规则,其中描述在模糊项中定义的不同工作状态下的局部模型的适用度。

状态变量		高度	环境温度	马赫数	模型号
规则	R1	高	高	高	AANN-1
	R2	高	中	中	AANN-2
	R3	中	低	低	AANN-3

表 1. 模糊规则集, 描述不同工作状态下的模型适用度。

述不同工作状态下的模型适用度。

[0092] 在图 22 中, 示出以下方案, 即, 使用模糊监控模型来控制局部模型的开关并确保飞行状态转变时内插所导致的残差的平滑性。在附图的左边上, 我们见到将原始传感器测量分别呈交到三个局部 AANN 模型以生成残差。通过模糊规则集来馈送定义工作状态的状态变量以确定每个局部 AANN 模型的适用度。然后使用每个模型的归一化适用度来对来自每个个体局部模型的残差执行加权求均值以生成综合总残差。

[0093] 在图 23(A) 和 23(B) 中, 示出飞行状态沿着图 20(B) 中定义的轨迹转变时实际传感器测量与分别来自局部模型 AANN_1 和 AANN_2 的估算之间的残差的示例。显然, 局部模型只能将构建和训练该模型所对应的飞行状态内的残差最小化。但是, 模糊监控模型可以调整在构建各个局部模型所对应的飞行状态中对局部模型的监控, 并将这些局部模型合并以确保工作状态的转变期间残差的平滑性, 如图 23(C) 所示。

[0094] 单变量变动检测

[0095] 至此, 上文描述的所有技术基于如下假设: 每个资产有多于一个感测的变量。但是, 有范围广泛的现场部署的资产, 例如厂房资产的平衡, 通常每个资产只有一个感测的变量来监视它们的行为。对于这些资产, 多变量变动检测和状况监视方法将不适用。为了专门解决这种每个资产单个传感器的情况, 我们调整包括 Hotelling T2 统计、似然比检验、过多峰度的计算和等级 (rank) 置换变换方法的一系列技术来用于单变量变动检测。但是, 可以将这些资产的成对系列作为一组来使用多变量技术监视。

[0096] 等级置换变换 (RPT)

[0097] 等级置换变换 (RPT) 是针对时间序列设计的。这里用于时间序列中的故障检测的通用方法是, 将“当前”数据 (一些最近的数据点) 的检验统计与“过去”数据 (“当前”之前的一些通常较大数量的点) 比较, 可能是与中间未使用点的缓冲区比较产生更显著的差异, 如图 24 所示。

[0098] 使用等级而非绝对值解决了多个问题。首先, 大大地消除了异常值的未决的影响 (problematic effect)。采用等级变换在非参数统计中有巨大优势。可以预先计算给定数量的数据的等级分布, 使得运行时的实现非常快速 (这对于很少有计算能力空闲的实时嵌入式应用来说是一个重要的考虑)。

[0099] 图 25(A)-(C) 中图示要设计确切或近似确切发生概率的数据的随机置换的原理。图 25(A) 示出初始数据。零假设是, 从与先前句点 (dot points) 相同分布中提取最后 5 个星号点 (asterisk points)。如果零假设为真, 则为这些星号点计算的统计 (比方说均值) 应该与从所有数据中随机选择的任何 5 个点的相同统计大约相同。如果我们保持数据相同, 且对这些标记 (星号或句点) 随机地置换, 并计算“5 个星号点的均值”统计多次, 则得到图 25(C) 中所示的分布。此过程暗示, 从所有点随机地选择的任何 5 个点将具有与原 5 个

点一样大的均值,时间的仅 7.2%。相似地,可以将数据的任何样本与另一个样本比较(例如使用上文概述的现在对最近过去方法(now vs. recent past approach)),并且可以计算任何检验统计上样本不同的确切(到任意数量的有效数字)概率。

[0100] 同时考虑两个设想(使用等级而非原始数据以及置换分布),可以使用“等级置换变换”(RPT)来将原始(表现差)的时间序列变换成告知数据中的模式变动的特征(判定)。为了计算 RPT,必须首先定义小数量的点为“当前”集合以及定义(通常较大)数量的点为“过去”集合。首先将这两个集合的数据连在一起,并计算组合的数据的等级。计算“当前”数据的初始排序的等级之和(检验统计量)。确切地说,将数据标记(当前/过去)随机地置换,计算检验统计量;将此步骤重复多次(例如,5000 次)。将该数据的初始排序的检验统计量值与通过置换生成的值比较,并计算偶然地发生初始排序的概率。将 $\log_{10}$ 概率(RPT 的输出)的值取为侧重于稀少的事件。例如, $10(\log_{10}10^{-10})$ 的值意味着事件的稀少性为 100 亿中 1 次。计算 RPT 的算法在本领域中是公知的。

[0101] 对该情况的数据采用等级置换变换以生成检验统计量。当检验统计量超过预定阈值时,报告变动。

[0102] 似然比检验(LRT)

[0103] 似然比检验研究顺序数据中的分布的变动。为此,它非常适于时间序列中的变动检测,并已经得到很好的实践。如下阐述 LRT 的问题的一般形成。

[0104] 考虑标量时间序列 $x(t)$, 其中 t 是当前时间索引。当前时间索引 t 将时间序列分成两个子集 $x_1(t) = \{x(i)\}_{i=t-n_1 \dots t-1}$ (最近的过去)和 $x_2(t) = \{x(i)\}_{i=t \dots t+n_2-1}$ (最近的将来)。每个子集分别遵循某个概率密度函数(pdf), $p_1(\theta_1)$ 和 $p_2(\theta_2)$ 。令 t 为某个时间瞬间, LRT 是用于在如下两个假设之间判定的内曼-皮尔逊(Neyman-Pearson)检验:

$$\begin{cases} H_0: p_2 = p_1, & (\text{未发生改变}) \\ H_1: p_2 \neq p_1, & (\text{发生改变}) \end{cases}$$

[0105] 变动之前或变动之后的 pdf 的参数是未知的。变动点、时间 T 也是未知的。然而,可以在在时间 T 处发生变动的假定的假设 H_1 与 n 个样本内未发生变动的零假设 H_0 之间形成对数似然比: $LR = \ln\left(\frac{p_1(x_{T-n_1}^{T-1}; \theta_1') \cdot p_2(x_{T+n_2-1}^{T+n_2-1}; \theta_2)}{p_1(x_{T-n_1}^{T+n_2-1}; \theta_1)}\right)$ 其中 $n = n_1 + n_2$ 。注意 θ_1' 和 θ_1 之

间的差意味着在不同时间上估算它们。因为真正的参数集 θ_1 、 θ_1' 和 θ_2 是未知的,所以可以使用最大似然(ML)方法来提出直接从它们各自区域获取的它们的估算 $\hat{\theta}_1$ 、 $\hat{\theta}_1'$ 、 $\hat{\theta}_2$: $\{t-n_1, \dots, t+n_2-1\}$ 、 $\{t-n_1, \dots, t-1\}$ 和 $\{t, \dots, t+n_2-1\}$ 。当所得到的似然性 $LR|_{\hat{\theta}_1, \hat{\theta}_1', \hat{\theta}_2}$ 超过某个预定义的阈值,则宣告变动。

[0106] Hotelling T^2 统计

[0107] Hotelling T^2 统计是多变量假设检验中使用的学生 t 统计的推广。将其调整为用于单变量变动检测问题的一种方式是对单变量传感器测量引入时间延迟。即,原始单变量信号 $x(t)$ 获得延迟的 m 个样本点以生成 $x(t-m)$ 。相似地, $x(t-m)$ 可以获得延迟的另外 m 个样本点以生成 $x(t-2m)$ 。以此方式,可以生成伪多变量时间序列,例如, $[x(t), x(t-m), x(t-2m)]'$ 以按前文执行 Hotelling T^2 计算。

[0108] 在图 26 中,我们示出单变量时间序列数据,其中在红线处发生偏移变动。个别地

使用 RPT、LRT 和几个 Hotelling T^2 技术的变体以检测在哪里发生了变动。所有那些技术可以利用合理的延迟检测变动,当然触发每种技术的告警阈值是不同的。与 RPT 和 LRT 比较, Hotelling T^2 统计可能无法像它们一样快地检测到变动,但是它的行为在检验不同类型的变动时非常一致。Hotelling T^2 统计的这种特征使得它成为在真实监视系统中部署的潜在的优良候选。

[0109] 如上所述,本发明调整 Hotelling T^2 统计技术来估算多变量数据的正常状态。Hotelling T^2 统计使用结合多变量方差 - 协方差矩阵的统计距离。因此,它检测所感测的变量中间的平均移位和反关系 (counter-relationship)。

[0110] 本文编写的描述使用示例来公开本发明,包括最佳方式,并且还使得本领域技术人员能够实施和使用本发明。本发明的可专利范围由权利要求定义,并且可以包括本领域技术人员可想到的其他示例。如果此类其他示例具有并未与权利要求的字面语言不同的结构元素或如果它们包括与权利要求的字面语言无实质性不同的等效结构元素,它们理应在权利要求书的范围内。




图 1




图 2




图 3A




图 3B




图 4




图 5




图 6




图 7




图 8A

图 8A 图 8B

图 8




图 8B




图 9A




图 9B




图 10




图 11




图 12




图 13




图 14




图 15A




图 15B




图 16




图 17




图 18A




图 18B




图 18C




图 19A




图 19B




图 19C




图 20A




图 20B




图 21A




图 21B




图 22




图 23A




图 23B




图 23C




图 24




图 25A




图 25B




图 25C




图 26