



(12) 发明专利申请

(10) 申请公布号 CN 113657604 A

(43) 申请公布日 2021.11.16

(21) 申请号 202110510866.7

(22) 申请日 2021.05.11

(30) 优先权数据

102020205962.4 2020.05.12 DE

(71) 申请人 罗伯特·博世有限公司

地址 德国斯图加特

(72) 发明人 M·席格 S·格尔温

(74) 专利代理机构 中国专利代理(香港)有限公司

72001

代理人 姬亚东 刘春元

(51) Int.Cl.

G06N 20/00 (2019.01)

G06F 17/18 (2006.01)


权利要求书1页 说明书9页 附图2页

(54) 发明名称

用于运行检查台的设备和方法

(57) 摘要

本发明涉及用于运行检查台的设备和方法,其中提供(200)机器的至少一个组件的系统模型的输入量的测量组,其中根据输入量在由所述系统模型表征的输出量方面的信息内容的度量来定义优化问题,其中根据所述输入量的测量组确定用于求解所述优化问题的梯度,其中根据所述梯度确定所述优化问题的解,所述解定义(206)了用于所述检查台的输入数据的设计,以用于在所述机器的至少一个组件上进行测量,其中在所述检查台上根据所述输入数据检测在所述机器的至少一个组件上的输出数据测量,其中根据所述输入数据和所述输出数据测量确定训练输入数据和训练输出数据的对,其中根据所述对来训练(212)所述机器的至少一个组件的系统模型。



1. 用于运行检查台的方法,其特征在于,提供(200)机器的至少一个组件的系统模型的输入量的测量组,其中根据输入量在由所述系统模型表征的输出量方面的信息内容的度量来定义优化问题,其中根据所述输入量的测量组确定用于求解所述优化问题的梯度,其中根据所述梯度确定所述优化问题的解,所述解定义(206)了用于所述检查台的输入数据的设计,以用于在所述机器的至少一个组件上进行测量,其中在所述检查台上根据所述输入数据检测在所述机器的至少一个组件上的输出数据测量,其中根据所述输入数据和所述输出数据测量确定训练输入数据和训练输出数据的对,其中根据所述对来训练(212)所述机器的至少一个组件的系统模型。

2. 根据权利要求1所述的方法,其特征在于,以迭代方式训练所述系统模型,其中在一次迭代中特别是仅使用来自该迭代先前的迭代的设计和测量的对来进行训练(212)。

3. 根据前述权利要求中任一项所述的方法,其特征在于,通过用于所述至少一个组件的输入数据集来定义所述训练输入数据。

4. 根据权利要求3所述的方法,其特征在于,训练输入数据通过空集或使用特别是从输入量的测量组中随机选择的训练输入数据来初始化。

5. 根据前述权利要求中任一项所述的方法,其特征在于,通过在所述至少一个组件上针对所述训练输入数据的输出量测量来定义所述训练输出数据。

6. 根据权利要求5所述的方法,其特征在于,所述训练输出数据通过空集或使用特别是从输出量的测量组中随机选择的训练输出数据来初始化。

7. 根据权利要求1至6中任一项所述的方法,其特征在于,所述输入量中的至少一个代表传感器的信号,所述信号表征所述至少一个组件的运行量的值。

8. 根据权利要求7所述的方法,其特征在于,所述信号是照相机、雷达传感器、LiDAR传感器、超声传感器、位置传感器、运动传感器、废气传感器或空气质量传感器的信号。

9. 根据前述权利要求中任一项所述的方法,其特征在于,所述输出数据测量定义所述系统模型的输出变量,所述输出变量代表机器的操控量、传感器信号或运行状态。

10. 根据权利要求9所述的方法,其特征在于,根据所述操控量、所述传感器信号和/或所述运行状态来操控特别是部分自主的车辆或机器人的执行器。

11. 根据前述权利要求中任一项所述的方法,其特征在于,在所述机器的至少一个组件上或在所述机器上为以这种方式训练的系统模型检测至少一个输入量,其中根据以这种方式训练的系统模型为所述机器的至少一个组件确定至少一个量,其中根据该量监视所述机器的至少一个组件或所述机器的运行,和/或其中根据该量确定所述机器的组件或所述机器的至少一个操控量。

12. 用于运行检查台的设备(100),其特征在于,所述设备(100)被构造为执行根据权利要求1至11中任一项所述的方法。

13. 计算机程序,其特征在于,所述计算机程序包括计算机可读指令,所述计算机可读指令在计算机上执行时运行根据权利要求1至11中任一项所述的方法。

## 用于运行检查台的设备和方法

### 技术领域

[0001] 本发明涉及用于运行检查台的设备和方法。

### 背景技术

[0002] 利用机器学习来运行检查台的一种方案是使用统计尝试计划,其中从预给定的输入量中确定要测量的一组输入点,在系统上针对这组选定的输入点进行测量。根据在所述测量中测量的输出数据来学习系统模型,利用该系统模型还可以为不同于所述选定的输入数据的其他输入数据确定与所述系统的真实行为尽可能好地一致的输出数据。

### 发明内容

[0003] 在下面的描述中提出了用于运行机动车辆或机动车辆的组件的检查台的方法和设备。这以用于机动车辆的废气后处理系统的检查台为例来描述。在该示例中,利用废气传感器测量所述机动车辆的发动机或废气后处理的排放。对所述机动车辆的其他系统可以使用其他传感器。主动学习是用于机器学习的方案。在该方案中使用回归模型来训练系统模型。在根据该主动学习方案的机器学习中,在该示例中生成至少一个信号,所述至少一个信号是用于检查台上的发动机或废气后处理组件的输入。对所述机动车辆的其他系统可以使用其他输入。在该示例中,在一次迭代中测量了关于排放的数据,所述排放是在利用所述输入激励所述发动机或所述废气后处理系统的组件时产生的。这些数据在下一次迭代中用作所述回归模型的训练数据。所述检查台的运行包括大量迭代,在这些迭代中确定特别好地适合的输入。在此,通过从随机变量中选择值或通过求解优化问题而确定值来生成用于所述输入的至少一个信号。在下面的描述中,术语“输入量”表示用于系统的可以被测量的信号,例如发动机的转速或负载。测量是输入量的值的时间序列。输入量的值的多个测量称为输入量的测量组。可以设置多个输入量。术语“输出量”表示用于所述系统的同样可以被测量的信号,例如发动机的排放。输出量的值的多个测量称为输出量的测量组。在示例性系统中,输出量根据一个输入量或根据多个输入量而变化。

[0004] 术语“输入数据”表示输入量的一次或多次赋值。术语“输出数据”表示输出量的一次或多次赋值。这些值是测量得到或任意选择的。这些值可以通过优化确定,可以将这些值在第二步骤中施加到所述系统,其中可以测量所属的输出量。因此,输入数据可以是输入量赋值的一个或多个时间序列。在一次测量中例如将发动机的转速序列和所述发动机的负载序列进行组合。一个测量组包括多个转速序列和多个负载序列,即多个测量。输入点通过输入量的赋值定义。可以通过测量或测量组来定义输入点。

[0005] 根据独立权利要求的方法和设备使得可以特别有效地学习特别好的系统模型并确定特别好地适合于测量的设计。

[0006] 用于运行检查台的方法规定,提供机器的至少一个组件的系统模型的输入量的测量组,其中根据输入量在由所述系统模型表征的输出量方面的信息内容的度量来定义优化问题,其中根据所述输入量的测量组确定用于求解所述优化问题的梯度,其中根据所述梯

度确定所述优化问题的解,所述解定义了用于检查台的输入数据的设计,以用于在所述机器的至少一个组件上进行测量,其中在所述检查台上根据所述输入数据检测在所述机器的至少一个组件上的输出数据测量,其中根据所述输入数据和所述输出数据测量,确定训练输入数据和训练输出数据的对,其中根据所述对来训练所述机器的至少一个组件的系统模型。机动车辆的至少一个组件可以是动态或静态的系统。输入量的第一测量是按照尝试计划在所述系统上进行的,利用所述尝试计划可以着重于输入空间的特定部分来进行系统模型的机器学习。还要执行的测量称为设计。所述设计预给定了在所述系统上的进一步测量中应当测量的输入量。确定所述设计的输入量是从所述输入空间中加权地选择输入点。将用于训练所述系统模型(所述系统模型例如通过高斯过程定义)的训练数据确定为以这种方式确定的输入数据和由此在所述系统上测量的输出数据的对。所述优化问题的解提供了以下输入数据,所述输入数据比其他输入数据以更大的概率在所述系统的运行中出现。在基于此的训练中,针对所述输入数据减少了所述系统模型相对于所述系统具有的不确定性。因此,所述训练可以有针对性地在所述输入空间的由所述设计预给定的部分中进行。

[0007] 优选地,以迭代方式训练所述系统模型,其中在一次迭代中特别是仅使用来自该迭代先前的迭代的训练输入数据和训练输出数据的对来进行训练。由此使用新的训练数据更新所述系统模型。

[0008] 可以通过用于所述至少一个组件的输入数据集来定义所述训练输入数据。这使得可以进行有效的训练。

[0009] 优选地,所述训练输入数据通过空集或使用特别是从输入量的测量组中随机选择的训练输入数据来初始化。这使得可以以定义的状态执行第一次迭代。

[0010] 可以通过在所述至少一个组件上的输出数据的测量集来定义所述训练输出数据。这使得可以成对地分配给输入数据集。

[0011] 优选地,所述训练输出数据通过空集或使用特别是从输出量的测量组中随机选择的训练输出数据来初始化。这使得可以以定义的状态执行第一次迭代。

[0012] 所述输入量中的至少一个可以代表传感器的信号,所述信号表征所述至少一个组件的运行量的值。传感器信号是特别容易检测的。由此可以将使用对应的传感器信号对所述系统的操控确定为用于要执行的测量的输入数据的设计。

[0013] 所述信号优选是照相机、雷达传感器、LiDAR传感器、超声传感器、位置传感器、运动传感器、废气传感器或空气质量传感器的信号。

[0014] 所述输出数据测量可以定义所述系统模型的输出变量,所述输出变量代表机器的操控量、传感器信号或运行状态。

[0015] 优选地,根据所述操控量、所述传感器信号和/或所述运行状态来操控特别是部分自主的车辆或机器人的执行器。

[0016] 优选地,在所述机器的至少一个组件上或在所述机器上为以这种方式训练的系统模型检测至少一个输入量,其中根据以这种方式训练的系统模型为所述机器的至少一个组件确定至少一个量,其中根据该量监视所述机器的至少一个组件或所述机器的运行,和/或其中根据该量确定所述机器的组件或所述机器的至少一个操控量。所述机器优选是车辆。

[0017] 用于机器学习的设备被构造为执行所述方法。

## 附图说明

[0018] 其他有利的实施方式从下面的描述和附图中得出。在附图中：  
图1示出了用于机器学习的系统的示意图，  
图2示出了用于机器学习的方法中的步骤。

## 具体实施方式

[0019] 下面描述用于机动车辆的至少一个组件的检查台。所述机动车辆的至少一个组件在下面称为系统。所述系统可以是动态的或静态的。在一个方面中示出了一种迭代主动学习方法，即代表性主动学习，其中从可能的输入数据中迭代地选择大量输入数据点，在这些输入数据点处对所述系统进行测量以获得输出数据点，这些输出数据点用于运行所述检查台以及用于由系统模型学习输入数据点向输出数据点的分配。所述系统模型在该示例中是回归模型。所描述的做法包括关于输入分布的知识，利用该知识提高所述学习方法的效率。最优值（即优化问题的解）表示在每次迭代中信息量最大的输入数据点和输出数据点，以减少关于所述系统模型的输出在所述系统的可能输入数据的相关范围中形成的不确定性。

[0020] 所描述的做法包括关于输入分布的知识，利用该知识提高所述学习方法的效率。从两个随机变量之间的互信息作为这些变量之间依赖性的度量，即关于一个变量在另一个变量方面的信息内容的度量出发，使用基于希尔伯特·施密特独立性标准的优化问题来测量这些变量之间通过所述分配引起的依赖性。最优值（即优化问题的解）表示在每次迭代中信息量最大的输入数据点和输出数据点，以减少关于所述系统模型的输出在所述系统的可能输入数据的相关范围中形成的不确定性。

[0021] 在下面描述的用于代表性主动学习的方案中，在针对实验的初始设计进行了输出量测量之后，有效地改善了所述系统模型的质量，其中迭代地确定一批输入数据点和输出数据点，一方面难以用瞬时的系统模型对这批输入数据点和输出数据点进行预测，并且另一方面这批输入数据点和输出数据点代表了输入数据点的估计分布。

[0022] 以下方法基于所述系统的系统模型  $p(y|x)$ 。该系统的输入数据  $x_1, \dots, x_d$  的特征是具有分布  $p^x$  和密度  $p(x)$  的随机变量  $X \in \mathbb{R}^d$ 。对随机变量  $X$  确定系统模型  $p(y|x)$  的输出变量  $Y \in \mathbb{R}$ ，在该示例中，该输出变量表征所述系统的标量输出数据  $y$ 。

[0023] 在统计尝试计划的学习步骤  $t$  中，将设计  $D_x^t \in \mathbb{R}^{b \times d}$  定义为所述系统的输入数据  $x_1, \dots, x_b$ ；  $x_i \in \mathbb{R}^d$  组，应当在所述尝试中针对这些输入数据进行测量。这意味着应当在所述尝试中在所述系统的所有可能位置  $(D_x^t) \in \mathbb{R}^{b \times d}$  中通过输入数据  $x_1, \dots, x_b$ ；  $x_i \in \mathbb{R}^d$  组定义的位置上进行测量，其中  $b$  是计划的测量点的数量，而  $d$  是输入变量的维数。系统模型  $p(y|x)$  在学习步骤  $t$  中根据设计  $D_x^t$  定义关于输出数据  $y$  的假设测量  $D_y^t$  的概率分布，所述输出数据可以在所述尝试中被测量。

[0024] 在图1中示意性地示出了用于机器学习的设备100。设备100包括至少一个计算装置102和至少一个存储器104。在该示例中，设备100被构造为检测至少一个传感器106的信号的测量。在该示例中，所述信号表征了机器（特别是机动车辆）的至少一个组件的运行量的值。在该示例中，设备100被构造为输出用于至少一个执行器108的操控量。至少一个执行

器108可以被构造为操控所述机器的至少一个组件或所述机器的其他组件。所述信号可以表征其他运行量,例如用于特别是部分自主的车辆或机器人的运行量。可以输出所述操控量以用于操控特别是部分自主的车辆或机器人。

[0025] 传感器106可以是照相机、雷达传感器、LiDAR传感器、超声传感器、位置传感器、运动传感器、废气传感器或空气质量传感器。

[0026] 所述机器的组件的示例是机动车辆的废气后处理系统。在一个示例中,利用废气传感器测量机动车辆的发动机或废气后处理的排放。在该示例中,所述系统模型是废气后处理系统的回归模型。利用所描述的方法生成信号,该信号表示针对所述发动机或废气后处理组件的用于功能检查的输入。对所述机动车辆的其他系统可以使用其他输入。在该示例中,在一次迭代中测量了在利用由所述回归模型确定的输入激励所述发动机或所述废气后处理系统的组件时产生的排放。在该示例中,这些数据表示功能检查的结果,并且在该示例中在下一次迭代中使用。

[0027] 在该示例中,随机变量  $X \in \mathbb{R}^d$  代表传感器的至少一个信号。该信号可以是照相机、雷达传感器、LiDAR传感器、超声传感器、位置传感器、运动传感器、废气传感器或空气质量传感器的信号。

[0028] 输出变量Y可以代表机器110的操控量、传感器信号或运行状态。

[0029] 例如,根据所述操控量、所述传感器信号和/或所述运行状态来操控至少一个执行器108。

[0030] 在所述尝试中,例如测量通过所述系统的输入数据  $x_1, \dots, x_b$ ;  $x_i \in \mathbb{R}^d$  组定义的每个传感器的信号。在该示例中,在所述尝试中检测应当在所述尝试中测量的输出数据y。

[0031] 下面参考图2描述用于机器学习的计算机实现的方法。

[0032] 可以规定:计划尝试集。在该示例中,根据互信息MMD的度量从设计  $D_x^t$  出发确定新的设计  $D_x^{t+1}$ 。在设计  $D_x^t$  方面对互信息MMD的度量进行优化。互信息MMD的度量量化了所述系统的输入和输出之间的相互信息。该度量取决于在位置  $(D_x^t) \in \mathbb{R}^{b \times d}$  处的假设测量。

[0033] 在学习步骤t中,根据通过设计  $D_x^t$  预给定的输入数据  $x_1, \dots, x_b$ ;  $x_i \in \mathbb{R}^d$  组确定互信息MMD的度量。在一个方面中,针对这些输入数据进行测量  $D_y^t$ 。利用测量  $D_y^t$  收集输出数据y。在这种情况下,根据测量  $D_y^t$  确定互信息MMD的度量。在另一方面中可以进行测量。在这种情况下用求平均代替所述测量。然而,如下所述与输出数据y的测量  $D_y^t$  无关地在学习步骤t中确定互信息MMD的度量。

[0034] 这意味着互信息MMD的度量是被优化的目标函数。该目标函数取决于实际测量  $D_y^t$  或与实际测量  $D_y^t$  无关。如果测量  $D_y^t$  是未知的,则考虑互信息MMD的估计,该估计可以与测量  $D_y^t$  无关地计算。在假设对设计  $D_x^t$  进行了测量,为此对测量  $D_y^t$  同样进行了测量并且在学习从输入到输出的新模型时考虑了这两者的条件下,所述估计提供输入数据的随机输入与输出数据的对应输出之间的互信息MMD的估计。互信息MMD的度量是输入量在通过所述系统模型表征的输出量方面的信息内容的度量。根据所述信息内容的度量来定义所述优化问题。

[0035] 在该方法中,在步骤200中提供输入数据组  $D_x$ ,该输入数据组通过输入数据  $x_1, \dots,$

$x_b$ ;  $x_i \in \mathbb{R}^d$  定义。

[0036] 在一个方面中,将这些输入数据确定为所述系统模型的随机变量  $X \in \mathbb{R}^d$  的概率分布  $\hat{p}_x$  中的独立且相同分布的样本。下面描述概率分布  $\hat{p}_x$  的确定。

[0037] 在另一方面中提供了所述系统的输入量的测量组。在该示例中,提供使用所述系统模型的随机变量  $X \in \mathbb{R}^d$  的输入数据  $x_1, \dots, x_N$  的测量。

[0038] 在这个方面,将“提供”理解为已经测量了输入数据  $x_1, \dots, x_N$ 。

[0039] 在这些方面中,通过输入量  $x_1, \dots, x_N$  来定义输入数据组  $D_x$ ,但不测量所属的输出数据。

[0040] 在另一方面中,提供带注释的输入数据  $x_1, \dots, x_N$ 。

[0041] 在此,“带注释”意味着将带注释的输入数据  $x_1, \dots, x_N$  分配给系统上的测量结果,即在所述系统上检测的相应测量。用于学习步骤  $t$  的带注释的输入数据  $x_1, \dots, x_N$  形成带注释的输入数据组  $D_x^t$ ,向该带注释的输入数据组分配测量组  $D_y^t$ ,这些测量是在所述系统上针对相应步骤的带注释的输入数据  $x_1, \dots, x_N$  检测的。

[0042] 例如,可以简单地例如在行驶期间针对带注释的输入数据  $x_1, \dots, x_N$  测量转速和车辆中的负载。相反,可以不测量或不在行驶期间测量感兴趣的输出量,例如所述车辆的排放。在这种情况下,可以将所述转速和所述负载作为测量提供,并从中计算出应当在具有所属的排放的检查台上测量出转速和负载的哪种组合。

[0043] 在这方面,输入数据组  $D_x$  通过这些带注释的输入量  $x_1, \dots, x_N$  定义。

[0044] 在随后的步骤 202 中,提供所述系统的随机变量  $X \in \mathbb{R}^d$  的概率分布  $\hat{p}_x$ ,该概率分布通过所述系统的输入数据组  $D_x$  定义。

[0045] 可以根据输入数据  $x_1, \dots, x_N$  确定随机变量  $X \in \mathbb{R}^d$  的概率密度  $\hat{p}_x$ 。例如,根据直至该学习步骤  $t$  确定的输入数据组  $D_x$ ,即先前学习步骤的相应输入数据组  $D_x$ ,来确定学习步骤  $t$  的概率分布  $\hat{p}_x$ 。

[0046] 在该示例中估计概率密度  $\hat{p}_x$ 。例如,通过以下等式给出该估计:

$$\hat{p}_x(x) = \frac{1}{N} \sum_i \frac{1}{\sqrt{2\pi}h} \exp\left(-\frac{1}{2} \frac{(x - x_i)^2}{h^2}\right)$$

在此, $h$  是高斯核的带宽并且通过所述输入数据的经验方差给出。

[0047] 所述方法可以规定,根据核密度估计来确定概率密度  $\hat{p}_x$ 。所述核密度估计例如利用核  $k$  和训练数据  $x_1, \dots, x_N$  进行。根据高斯过程的预给定预测方差  $c$  来定义核  $k$ ,所述高斯过程一并考虑了已经测量过的设计  $D_x^s, s \leq t$ ,并且基于初始核  $k_0$ :

$$\hat{p}_x(x) = \frac{1}{N} \sum_i c(x, x_i)$$

$$c(x, x') = k_0(x, x') - k_0(x, (D_x^1, \dots, D_x^t)) k_0((D_x^1, \dots, D_x^t), (D_x^1, \dots, D_x^t))^{-1} k_0((D_x^1, \dots, D_x^t), x')$$

这意味着上述高斯核可用于所述核密度估计。该高斯核可以通过引入先前的测量

来加以适配。也就是说,代替上面的高斯核,使用所述高斯过程的预测方差。

[0048] 可以规定,确定输入数据组  $D_x = \{x_i^*\}_{i=1,\dots,m}$ 。这些输入数据可以用作输入数据  $x_1, \dots, x_N$  的紧凑替代品。

[0049] 可以规定,对于所提供的输入数据集  $\{x_i\}_{i=1,\dots,N}$  的随机变量  $X$ ,确定比较小的输入数据集  $\{x_i^*\}_{i=1,\dots,m}$ ,该输入数据集最大化这些点在先前确定的概率密度  $\hat{p}_x$  方面的代表性的度量。这种代表性度量由下式给出:

$$\sqrt{\left(\frac{1}{m^2} \sum_i \sum_j k_p(x_i^*, x_j^*)\right)}$$

其中

$$k_p(x, x') = \nabla_x \cdot \nabla_{x'} k(x, x') + \nabla_x k(x, x') \cdot \nabla_{x'} \log \widehat{p}_x(x') + \nabla_{x'} k(x, x') \cdot \nabla_x \log \widehat{p}_x(x) + k(x, x') \nabla_x \log \widehat{p}_x(x) \cdot \nabla_{x'} \log \widehat{p}_{x'}(x')$$

由此为选定的核  $k$  确定了输入数据集  $\{x_i^*\}_{i=1,\dots,m}$ 。随机变量  $X$  的一种实现是测量  $x_i$ 。每个测量  $x_i$  是单个可能是多维的数据点。在该示例中,在一个方面中将输入量的测量组,即输入数据集  $\{x_i\}_{i=1,\dots,N}$  一起用于代表随机变量  $X$  的概率密度。输入数据集  $\{x_i\}_{i=1,\dots,N}$  和较小的输入数据集  $\{x_i^*\}_{i=1,\dots,m}$  分别是数据点,但是不同数量的数据点。在该示例中,为输入数据集  $\{x_i\}_{i=1,\dots,N}$  设置  $N$  个数据点。在该示例中,为较小的输入数据集  $\{x_i^*\}_{i=1,\dots,m}$  设置  $m$  个数据点,其中  $m < N$ 。 $x, x'$  表示在该示例中插入核  $k_p$  或  $k$  中的变量。这是确定输入量集的一种可能方式,使得该输入量集最大程度地代表分布  $\hat{p}_x$ 。在此,借助于待选择的核  $k$  来确定用于确定最大代表性集的代表性。

[0050] 在可选的步骤 204 中,确定输出数据组  $D_y$ ,该输出数据组通过输出数据  $y_1, \dots, y_n; y_i \in \mathbb{R}^d$  定义,这些输出数据被确定为所述系统的随机变量  $Y \in \mathbb{R}^d$  的概率分布  $N$  中的独立且相同分布的样本。

[0051] 概率分布  $N$  可以是正态分布。可以规定,在学习步骤  $t$  中根据直到该学习步骤  $t$  确定的输入数据组  $D_x$ ,特别是  $D_y \sim N(D_y | \mu(D_x), \sigma(D_x))$  来确定概率分布  $N$ 。

[0052] 在步骤 206 中,提供关于在所述系统上的测量结果的信息。根据输入数据组  $D_x$ ,通过所述系统的输出数据组  $D_y$  或所述系统的输出数据组  $D_y$  的平均值来定义所述测量结果。

[0053] 在步骤 208 中确定优化问题的解,所述解定义所述系统上测量  $D_y^*$  的设计  $D_x^*$ 。

[0054] 所述优化问题是针对设计  $D_x^*$  根据输入数据组  $D_x$  并且根据关于所述测量结果的信息来定义的。

[0055] 在一个方面中,输出数据组  $D_y$  定义关于所述测量结果的信息。

[0056] 在这方面,通过目标函数来定义所述优化问题,该目标函数根据输入数据组  $D_x$  确定输入数据组关于可能的输出数据的信息内容。

[0057] 所述目标函数例如被定义为:



$$\begin{aligned} \overline{MMD}[D_x] &= \frac{z(\lambda_y)}{N^2} \left( \|K_x^{XX} \odot \langle K_y^{YY} \rangle\|_1 - 2 \left\| K_x^{XX} \frac{1}{N} \langle K_y^{YY} \rangle \right\|_1 + \frac{1}{N} \|K_x^{XX}\|_1 \right. \\ &\quad \left. + \frac{1}{N} \|\langle K_y^{YY} \rangle\|_1 \right) \end{aligned}$$

具有逐元素乘积 $\odot$ 和长度标量 $\lambda_y$ 的RBF核 $k_y$ 的归一化常数 $z(\lambda_y) = \sqrt{\lambda_y} \sqrt{2\pi}$ 。所使用的矩阵 $K_x^{XX}, \langle K_y^{YY} \rangle$ 通过下式给出,其具有RBF核 $k_x$ ,所述RBF核具有可选或选定的长度标量 $h$ :

$$\begin{aligned} (K_x^{XX})_{ij} &= k_x(x_i, x_j) \\ (\langle K_y^{YY} \rangle)_{i,j} &= N(\mu(x_i)) |\mu(x_i) \lambda_y + \sigma(x_i, x_i) + \sigma(x_i, x_j) - 2 \\ &\quad + \sigma(x_i, D_x) \sigma(D_x, D_x)^{-1} \sigma(D_x, x_j)| \end{aligned}$$

在此, $\sigma(x_i, D_x)$ 通过所述系统模型的预测协方差定义。

[0058] 由此得到的优化问题被定义为:

$$D_x^t = \arg \max_{D_x} \langle \overline{MMD}[D_x] \rangle$$

为了求解所述优化问题,根据输入量的测量组来确定梯度。

[0059] 为了求解所述优化问题,可以使用诸如Broyden-Fletcher-Goldfarb-Shanno (BFGS)方法或有限存储器BFGS (LBFGS)的优化方法。因此,从这些信息中确定新的设计 $D_x^{t+1}$ 。

[0060] 根据梯度确定所述优化问题的解,该解定义用于检查台的输入数据的设计 $D_x^t$ ,以用于在所述机器的至少一个组件上进行测量。

[0061] 在该示例中,通过在数量 $T$ 个连续学习步骤 $t \in T$ 中重复步骤208,确定大量新设计 $D_x^{t+1}$ ,所述大量新设计根据相应的输入数据 $\{x_i^s\}_{i=1, \dots, m}$ 并且基于根据相应先前的设计 $D_x^t$ 和所属的已执行的测量 $D_y^t$ 学习的系统模型 $p(y|x)$ 来最大化互信息MMD的度量。这意味着既不执行针对设计 $D_x^t$ 的测量 $D_y^t$ ,又不将测量 $D_y^t$ 用于确定该设计 $D_x^t$ 。更确切地说,确定应当用于在所述系统上的下一次测量的设计 $D_x^t$ 。如下所述,利用按照设计 $D_x^t$ 的用于所述系统的输入数据和按照测量 $D_y^t$ 的输出数据来训练系统模型 $p(y|x)$ ,所述测量 $D_y^t$ 是利用按照设计 $D_x^t$ 的输入数据在所述系统上进行的。以此方式训练的系统模型 $p(y|x)$ 可以用于后续的迭代。

[0062] 在该示例中,从输入数据 $x_i^s, i = 1, \dots, m$ 和先前检测的数据 $D_x^s, D_y^s, s \leq t$ 且 $s \in T$ 出发并根据梯度来确定用于学习步骤 $t$ 之后的学习步骤 $t+1$ 的新设计 $D_x^{t+1}$ 。

[0063] 在随后的步骤210中,特别是在所述检查台上根据特别是用于所述检查台的输入

数据  $D_x^{t+1}$  来检测在所述系统上的输出数据  $y(D_x^{t+1})$  的测量。在所述检查台上,根据按照设计  $D_x^{t+1}$  的输入数据检测在所述机器的至少一个组件上的输出数据的测量  $D_y^{t+1}$ 。在该示例中,根据输入数据  $D_x^t$  和输出数据  $y(D_x^t)$  的测量来定义用于运行检查台的方法。从所述系统的输入量的测量出发,确定输入数据  $D_x^t$  的设计,利用这些输入数据在所述系统上进行输出量的测量,所述测量定义输出数据  $y(D_x^t)$ 。

[0064] 新的测量  $D_y^{t+1}$  通过以下测量确定:在该测量中在尝试时在所述系统上利用通过新设计  $D_x^{t+1}$  预给定的输入数据组来检测表征输出数据  $y$  的输出量。可以规定检测多个输出量。

[0065] 根据输入数据和输出数据  $y$  的测量  $D_y^{t+1}$ ,确定训练输入数据和训练输出数据的对。

[0066] 在该示例中,通过用于至少一个组件的输入数据集来定义所述训练输入数据。

[0067] 对于第一训练步骤,所述训练输入数据可以通过空集或使用特别是从输入量的测量组中随机选择的训练输入数据来初始化。

[0068] 在该示例中,通过在所述至少一个组件上针对所述训练输入数据的输出量测量来定义所述训练输出数据。

[0069] 对于第一训练步骤,所述训练输出数据可以通过空集或利用特别是从输出量的测量组中随机选择的训练输出数据来初始化。

[0070] 在步骤212中,根据设计  $D_x^{t+1}$  和新的测量  $D_y^{t+1}$  来为学习步骤  $t+1$  训练系统模型  $p(y|x)$ 。最初,即在第一学习步骤中,对系统模型  $p(y|x)$  采用高斯过程。根据所述对来训练所述机器的至少一个组件的系统模型  $p(y|x)$ 。

[0071] 可以规定,特别是仅利用设计  $D_x^{t=1}, \dots, D_x^t$  的先前检测的数据和相应的测量  $D_y^{t=1}, \dots, D_y^t$  来训练所述系统的系统模型  $p(y|x)$ 。

[0072] 在该示例中规定,随机变量  $X \in \mathbb{R}^d$  代表传感器106之一的信号  $x$ ,而输出变量  $Y$  代表执行器108之一的标量操控量  $y$ 。代替所述操控量,输出变量  $Y$  也可以代表虚拟传感器信号或机器100的运行状态。

[0073] 在这种情况下,例如利用代表传感器106的信号的训练数据将系统模型  $p(y|x)$  训练为输出标量操控量  $y$ 。在该示例中,利用标量操控量  $y$ ,根据所述传感器信号来操控执行器108。

[0074] 在数量  $s$  个连续的学习步骤之后执行的步骤214中,确定设计  $D_x^s$  和输出测量  $D_y^s$ ,所述设计特别有效地针对系统模型  $p(y|x)$  描述了所述系统的输入-输出行为。“有效”在此涉及要按照设计  $D_x^s$  进行的一定数量的测量和输出测量  $D_y^s$  以及由此实现的准确度。根据为了实现利用所述测量学习的系统模型  $p(y|x)$  的特定预测准确度而需要的测量数量来测量效率。

[0075] 所述方法可以规定,根据核密度估计来确定概率密度  $\hat{p}_x$ 。所述核密度估计例如利用核  $k$  和训练数据  $x_1, \dots, x_N$  进行。根据高斯过程的预给定预测方差  $c$  来定义核  $k$ ,所述高斯过

程一并考虑了已经测量过的设计  $D_x^s, s \leq t$ , 并且基于初始核  $k_0$ :

$$\hat{p}_x(x) = \frac{1}{N} \sum_i c(x, x_i)$$

$$c(x, x') = k_0(x, x') - k_0(x, (D_x^1, \dots, D_x^t)) k_0((D_x^1, \dots, D_x^t), (D_x^1, \dots, D_x^t))^{-1} k_0((D_x^1, \dots, D_x^t), x')$$

这意味着上述高斯核可以用于所述核密度估计。该高斯核可以通过引入先前的测量  $D_x^s$  来加以适配。也就是说, 代替上面的高斯核, 使用所述高斯过程的预测方差。

[0076] 利用在  $T$  次迭代之后以此方式训练的系统模型  $p(y|x)$ , 可以确定所述操控量、所述传感器信号和/或所述运行状态, 并且可以操控特别是部分自主的车辆或机器人的执行器。

[0077] 代替仅一次性地计划设计并对该设计进行测量, 通过以迭代的方式重复步骤 200 至 212。通过这种方法, 与使用仅一次设计的情况相比, 以这种方式训练的系统模型  $p(y|x)$  更准确, 因为将训练输入数据和训练输出数据迭代地添加到以下训练数据, 针对这些训练数据所述系统的系统模型  $p(y|x)$  不准确并且这些训练数据同时也是相关的。基于训练输入数据与输入量的测量组的共同信息 MMD 来测量所述相关性。通过所述优化问题的解, 在迭代  $t$  中确定最佳适合于该解的训练输入数据。

[0078] 在另一方面中, 在所述机器的至少一个组件上或在所述机器上为以这种方式训练的系统模型检测至少一个输入量, 其中将以这种方式训练的系统模型用于所述机器的组件或所述机器的运行。在该示例中, 根据以这种方式训练的系统模型为所述机器的至少一个组件确定至少一个量。

[0079] 例如, 在所述至少一个组件上为以此方式训练的系统模型测量至少一个输入量或不同输入量, 并且利用以这种方式训练的系统模型来预测所述系统模型的至少一个输出量。所述至少一个量可以是所述至少一个输出量, 或者可以根据至少一个操控量来加以确定, 所述操控量又根据以此方式训练的系统模型的至少一个输出量来加以确定。

[0080] 可以根据该至少一个量来监视所述机器或所述机器的至少一个组件的运行。作为所述监视的结果, 所述机器例如可以在识别出所述量与组件运行期间在所述机器的组件上测量的输出量之间存在偏差时识别出错误。可以规定, 如果所述偏差超过阈值则关闭所述机器。

[0081] 可以规定, 根据该至少一个量来确定用于所述机器的组件或用于所述机器的至少一个操控量。例如, 将这些量之一与组件运行期间在所述机器的组件上测量的测量量之间的偏差用于校正使用操控量的操控, 例如在调节回路中校正使用操控量的操控。

[0082] 在另一方面中, 可以使用以这种方式训练的系统模型为该系统模型的至少一个输入量或不同输入量预测至少一个输出量。可以规定, 预测大量的输出量, 这些输出量定义了大量可能的操控量。可以规定, 所述机器的运行策略根据满足条件的输出量来确定操控量。可以规定, 根据所述大量的输出量来确定大量的输出量, 并且从大量操控量中选择满足条件的操控量。在该示例中, 确定以下操控量, 在所述操控量的情况下所述大量的输出量在所述机器的预给定运行行为方面是最佳的。例如, 为所述机器的至少一个组件选择以下操控量, 在所述操控量的情况下所述机器产生最低的排放。




图 1




图 2