



(12) 发明专利

(10) 授权公告号 CN 113287072 B

(45) 授权公告日 2024. 08. 09

(21) 申请号 201980088345.8

(22) 申请日 2019.11.07

(65) 同一申请的已公布的文献号
申请公布号 CN 113287072 A

(43) 申请公布日 2021.08.20

(30) 优先权数据
62/758,054 2018.11.09 US

(85) PCT国际申请进入国家阶段日
2021.07.08

(86) PCT国际申请的申请数据
PCT/IL2019/051217 2019.11.07

(87) PCT国际申请的公布数据
W02020/095303 EN 2020.05.14

(73) 专利权人 奥格瑞系统有限公司
地址 以色列海法市

(72) 发明人 奥里·内格里 丹尼尔·巴尔斯基
盖尔·班-海姆
萨尔·约斯科维茨 盖尔·肖尔

(74) 专利代理机构 上海翼胜专利商标事务所
(普通合伙) 31218
专利代理师 翟羽

(51) Int. Cl.
G05B 23/02 (2006.01)
G01M 99/00 (2011.01)
G01R 31/34 (2006.01)
G05B 23/00 (2006.01)

(56) 对比文件
US 6199018 B1, 2001.03.06
US 2002046006 A1, 2002.04.18
US 2018005107 A1, 2018.01.04

审查员 和晟姣

权利要求书3页 说明书19页 附图16页

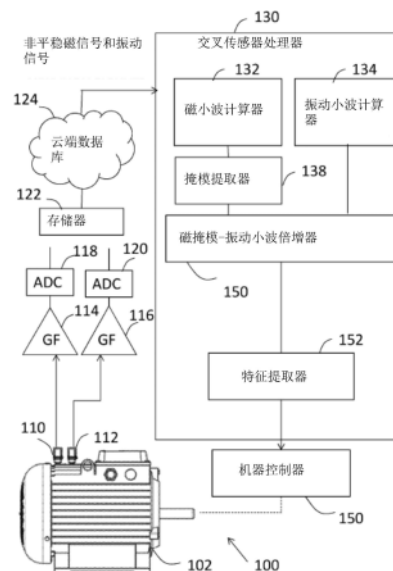
(54) 发明名称

非平稳机器性能的自动分析

(57) 摘要

一种用于监测至少一机器的方法,包括使至少一第一传感器在至少一操作时间帧期间从以非平稳方式操作的至少一机器获取至少一第一非平稳信号,所述至少一第一传感器提供至少一第一非平稳输出,使至少一第二传感器在操作时间帧期间从至少一机器获取至少一第二非平稳信号,所述至少一第二传感器提供至少一第二非平稳输出,将所述至少一第一非平稳输出与至少一第二非平稳输出融合以产生一融合输出,基于融合输出提取所述第一非平稳信号和第二非平稳信号中的至少一个的至少一特征,分析至少一特征以确定至少一机器的一健康状态,并基于所述分析发现的所述健康状态,执行所述至少一机器的维修操作、维护操作和操作参数修改中的至少一项。

CN 113287072 B



1. 一种用于监测至少一机器的方法,其特征在于:所述方法包括:

使至少一第一传感器在至少一操作时间帧期间从被监测的并以一非平稳操作方式的至少一机器获取至少一第一非平稳信号,所述至少一第一传感器提供至少一第一非平稳输出;

使至少一第二传感器在所述操作时间帧期间从被监测的所述至少一机器获取至少一第二非平稳信号,所述至少一第二传感器提供至少一第二非平稳输出;

将所述至少一第一非平稳输出与所述至少一第二非平稳输出融合,以产生一融合输出;

基于所述融合输出提取所述第一非平稳信号和第二非平稳信号中的至少一个的至少一特征,所述提取包括:

i) 训练一第一神经网络以从与被监测的所述至少一机器共享至少一共同特征的至少一机器中提取融合平稳输出的数据集的特征,所述至少一机器与以一平稳方式操作的被监测的所述至少一机器共享至少一共同特征;

ii) 在所述第一神经网络的所述训练之后,训练一第二神经网络以从被监测的所述至少一机器中提取融合输出的数据集的特征,所述第二神经网络已经通过相对于所述第一神经网络迭代地适应而被训练,以便最小化由所述第二神经网络提取的特征与来自所述第一神经网络监测的和提取的所述至少一机器的对应的平稳输出的特征之间的差异;

iii) 在所述第二神经网络的所述训练之后,将所述融合输出提供给经过训练的所述第二神经网络,作为所述第二神经网络的所述训练的结果,经过训练的所述第二神经网络可操作用于从所述融合输出中提取所述至少一特征;

分析所述至少一特征以确定被监测的所述至少一机器的一健康状态;以及

基于所述分析发现的所述健康状态,执行被监测的所述至少一机器的维修操作、维护操作和操作参数修改中的至少一项。

2. 如权利要求1所述的用于监测至少一机器的方法,其特征在于:所述至少一特征对被监测的所述机器的所述非平稳操作的一平稳水平不敏感。

3. 如权利要求1或权利要求2所述的用于监测至少一机器的方法,其特征在于:所述融合包括基于所述至少一第二非平稳输出修改所述至少一第一非平稳输出。

4. 如权利要求1所述的用于监测至少一机器的方法,其特征在于:所述至少一第一非平稳信号表示被监测的所述机器的一机械状态,所述至少一第二非平稳信号表示被监测的所述机器的一操作状态。

5. 如权利要求3所述的用于监测至少一机器的方法,其特征在于:所述融合包括对所述第一非平稳输出和所述第二非平稳输出应用一小波变换,所述修改包括将所述第一非平稳输出和第二非平稳输出中的一个的所述小波变换乘以所述第一非平稳输出和第二非平稳输出中的另一个的所述小波变换的二进制掩模。

6. 如权利要求2所述的用于监测至少一机器的方法,其特征在于:所述融合采用一深度学习。

7. 如权利要求6所述的用于监测至少一机器的方法,其特征在于:所述深度学习包括将所述至少一第一非平稳输出和第二非平稳输出组合成具有一个或多个维度的一向量。

8. 如权利要求6所述的用于监测至少一机器的方法,其特征在于:所述融合包括以一交

织排列组合所述至少一第一非平稳输出和第二非平稳输出,所述交织排列包括交替的所述第一非平稳输出和第二非平稳输出,所述深度学习包括采用一RNN网络进行时间序列预测。

9.如权利要求1所述的方法,其特征在于:所述提取包括直接从所述融合输出中提取所述至少一特征。

10.如权利要求1所述的方法,其特征在于:所述至少一机器包括执行一联产过程的一组机器。

11.一种用于监测至少一机器的系统,其特征在于:所述系统包括:

一第一传感器,用于在至少一操作时间帧期间从被监测的并以一非平稳操作方式的至少一机器获取至少一第一非平稳信号,所述至少一第一传感器提供至少一第一非平稳输出;

一第二传感器,用于在所述操作时间帧期间从被监测的所述至少一机器获取至少一第二非平稳信号,所述至少一第二传感器提供至少一第二非平稳输出;

一信号处理器,用于将所述至少一第一非平稳输出与所述至少一第二非平稳输出进行融合以产生一融合输出;

一特征提取器,用于基于所述融合输出提取所述第一非平稳信号和第二非平稳信号中的至少一个的至少一特征,并分析所述至少一特征以确定被监测的所述至少一机器的一健康状态,所述特征提取器包括:

一第一神经网络,预先被训练为从至少一机器提取融合平稳输出的数据集的特征,所述至少一机器与被监测的所述至少一机器共享至少一共同特征,所述至少一机器与以一平稳方式操作的被监测的所述至少一机器共享至少一共同特征;

一第二神经网络,被训练以从被监测的所述至少一机器提取融合输出的数据集的特征,所述第二神经网络已经通过相对于所述第一神经网络迭代地适应而被训练,以便最小化由所述第二神经网络提取的特征与来自所述第一神经网络监测的和提取的所述至少一机器的对应的平稳输出的特征之间的差异;

其中,一旦所述第二神经网络已经被训练,所述融合输出就被提供给所述第二神经网络,所述第二神经网络可操作以从所述融合输出中提取所述至少一特征;以及

一机器控制模块,用于基于所述健康状态控制所述至少一机器的维修操作、维护操作和操作参数修改中的至少一项的性能。

12.如权利要求11所述的用于监测至少一机器的系统,其特征在于:所述至少一特征对被监测的所述机器的所述非平稳操作的一平稳水平不敏感。

13.如权利要求11或12所述的用于监测至少一机器的系统,其特征在于:所述信号处理器用于基于所述至少一第二非平稳输出修改所述至少一第一非平稳输出。

14.如权利要求11所述的用于监测至少一机器的系统,其特征在于:所述至少一第一非平稳信号表示被监测的所述机器的一机械状态,所述至少一第二非平稳信号表示被监测的所述机器的一操作状态。

15.如权利要求13所述的用于监测至少一机器的系统,其特征在于:所述信号处理器用于对所述第一非平稳输出和所述第二非平稳输出应用一小波变换,并将所述第一非平稳输出和第二非平稳输出中的一个的所述小波变换乘以所述第一非平稳输出和第二非平稳输出中的另一个的所述小波变换的二进制掩模。

16. 如权利要求12所述的用于监测至少一机器的系统,其特征在于:所述信号处理器用于采用深度学习。

17. 如权利要求16所述的用于监测至少一机器的系统,其特征在于:所述深度学习包括将所述至少一第一非平稳输出和第二非平稳输出组合成具有一个或多个维度的一向量。

18. 如权利要求16所述的用于监测至少一机器的系统,其特征在于:所述信号处理器用于将所述至少一第一非平稳输出和第二非平稳输出组合成一交织排列,所述交织排列包括交替的所述第一非平稳输出和第二非平稳输出,所述深度学习包括基于所述交织排列使用一RNN网络进行时间序列预测。

19. 如权利要求18所述的系统,其特征在于:所述至少一特征直接从所述融合输出中提取。

20. 如权利要求19所述的系统,其特征在于:被监测的所述至少一机器包括执行一联产过程的一组机器。

非平稳机器性能的自动分析

[0001] 相关申请

[0002] 本申请在此主张于2018年11月9日提交的美国临时申请案申请号为62/758,054的优先权,标题为非平稳机器自动诊断的系统和方法,其公开内容通过引用并入本文作为参考。

技术领域

[0003] 本发明总体上是有关于一种机器性能的分析,并且更具体地是有关于一种非平稳机器的性能的自动分析。

背景技术

[0004] 用于自动机器分析的各种类型的系统在本领域中是已知的。

发明内容

[0005] 本发明寻求提供新颖的系统和方法,用于对具有非平稳特性的机器的性能进行高度精确的自动化分析,从而能够对此类机器的操作参数进行预防性维护和优化。

[0006] 因此,根据本发明的优选实施例提供了一种用于监测至少一机器的方法,所述方法包括:使至少一第一传感器在至少一操作时间帧期间从以一非平稳操作方式的至少一机器获取至少一第一非平稳信号,所述至少一第一传感器提供至少一第一非平稳输出;使至少一第二传感器在所述操作时间帧期间从所述至少一机器获取至少一第二非平稳信号,所述至少一第二传感器提供至少一第二非平稳输出;将所述至少一第一非平稳输出与所述至少一第二非平稳输出融合,以产生一融合输出;基于所述融合输出提取所述第一非平稳信号和第二非平稳信号中的至少一个的至少一特征;分析所述至少一特征以确定所述至少一机器的一健康状态;以及基于所述分析发现的所述健康状态,执行所述至少一机器的维修操作、维护操作和操作参数修改中的至少一项。

[0007] 根据本发明的优选实施例,所述至少一特征对所述机器的所述非平稳操作的一平稳水平不敏感。

[0008] 优选地,所述融合包括基于所述至少一第二非平稳输出修改所述至少一第一非平稳输出。

[0009] 优选地,所述至少一第一非平稳信号表示所述机器的一机械状态,所述至少一第二非平稳信号表示所述机器的一操作状态。

[0010] 根据本发明的一个优选实施例,所述融合包括对所述第一非平稳输出和所述第二非平稳输出应用一小波变换,所述修改包括将所述第一非平稳输出和第二非平稳输出中的一个的所述小波变换乘以所述第一非平稳输出和第二非平稳输出中的另一个的所述小波变换的二进制掩模。

[0011] 附加地或可替代地,所述融合采用深度学习。

[0012] 优选地,所述深度学习包括将所述至少一第一非平稳输出和第二非平稳输出组合

成具有一个或多个维度的一向量,并训练一神经网络以自动对所述向量进行分类。

[0013] 优选地,所述训练所述神经网络包括训练所述神经网络,以基于来自与被监测的所述至少一机器共享至少一共同特征的至少一机器的对应的平稳输出来分类所述非平稳输出。

[0014] 可替代地,所述融合包括以一交织排列组合所述至少一第一非平稳输出和第二非平稳输出,所述交织排列包括交替的所述第一非平稳输出和第二非平稳输出,所述深度学习包括采用一RNN网络进行时间序列预测。

[0015] 优选地,所述提取包括直接从所述融合输出中提取所述至少一特征。

[0016] 优选地,所述至少一机器包括执行一联产过程的一组机器。

[0017] 根据本发明的另一个优选实施例,更提供了一种用于监测至少一机器的方法,所述方法包括:使至少一第一传感器在至少一操作时间帧期间从以一非平稳操作方式的至少一机器获取至少一第一非平稳信号,所述至少一第一传感器提供至少一第一非平稳输出;使至少一第二传感器在所述时间帧期间从所述机器获取至少一第二非平稳信号,所述至少一第二传感器提供至少一第二非平稳输出;基于所述至少一第二非平稳输出修改所述至少一第一非平稳输出以提取所述第一非平稳输出的至少一特征;分析所述至少一特征以确定所述机器的一健康状态;以及基于所述分析发现的所述健康状态,执行所述机器的维修操作、维护操作和操作参数修改中的至少一项。

[0018] 根据本发明的优选实施例,所述至少一特征对所述机器的所述非平稳操作的一平稳水平不敏感。

[0019] 优选地,所述至少一第一非平稳信号表示所述机器的一机械状态,所述至少一第二非平稳信号表示所述机器的一操作状态。

[0020] 优选地,所述修改包括将所述第一非平稳输出和第二非平稳输出中的一个的一小波变换乘以所述第一非平稳输出和第二非平稳输出中的另一个的所述小波变换的二进制掩模。

[0021] 附加地或可替代地,所述修改和分析采用深度学习。

[0022] 优选地,所述深度学习包括将所述至少一第一非平稳输出和第二非平稳输出组合成具有一个或多个维度的一向量,并训练一神经网络以自动对所述向量进行分类。

[0023] 优选地,所述训练所述神经网络包括训练所述神经网络,以基于来自与被监测的所述至少一机器共享至少一共同特征的至少一机器的对应的平稳输出来分类所述非平稳输出。

[0024] 可替代地,所述修改和所述分析包括以一交织排列组合所述至少一第一非平稳输出和第二非平稳输出,所述交织排列包括交替的所述第一非平稳输出和第二非平稳输出,并且采用一RNN网络进行时间序列预测

[0025] 优选地,所述至少一机器包括执行一联产过程的一组机器。

[0026] 根据本发明的又一优选实施例,还提供了一种用于监测至少一机器的系统,所述系统包括:一第一传感器,用于在至少一操作时间帧期间从以一非平稳操作方式的至少一机器获取至少一第一非平稳信号,所述至少一第一传感器提供至少一第一非平稳输出;一第二传感器,用于在所述操作时间帧期间从所述至少一机器获取至少一第二非平稳信号,所述至少一第二传感器提供至少一第二非平稳输出;一信号处理器,用于将所述至少一第

一非平稳输出与所述至少一第二非平稳输出进行融合以产生一融合输出；一特征提取器，用于基于所述融合输出提取所述第一非平稳信号和第二非平稳信号中的至少一个的至少一特征，并分析所述至少一特征以确定所述至少一机器的一健康状态；以及一机器控制模块，用于基于所述健康状态控制所述至少一机器的维修操作、维护操作和操作参数修改中的至少一项的性能。

[0027] 根据本发明的优选实施例，所述至少一特征对所述机器的所述非平稳操作的一平稳水平不敏感。

[0028] 优选地，所述信号处理器用于基于所述至少一第二非平稳输出修改所述至少一第一非平稳输出。

[0029] 优选地，所述至少一第一非平稳信号表示所述机器的一机械状态，所述至少一第二非平稳信号表示所述机器的一操作状态。

[0030] 优选地，所述信号处理器用于对所述第一非平稳输出和所述第二非平稳输出应用一小波变换，并将所述第一非平稳输出和第二非平稳输出中的一个的所述小波变换乘以所述第一非平稳输出和第二非平稳输出中的另一个的所述小波变换的二进制掩模。

[0031] 附加地或可替代地，所述信号处理器可操作以采用深度学习。

[0032] 优选地，所述深度学习包括将所述至少一第一非平稳输出和第二非平稳输出组合成具有一个或多个维度的一向量，并训练一神经网络以自动对所述向量进行分类。

[0033] 优选地，所述训练所述神经网络包括训练所述神经网络，以基于来自与被监测的所述至少一机器共享至少一共同特征的至少一机器的对应的平稳输出对所述非平稳输出进行分类。

[0034] 可替代地，所述信号处理器用于将所述至少一第一非平稳输出和第二非平稳输出组合成一交织排列，所述交织排列包括交替的所述第一非平稳输出和第二非平稳输出，所述深度学习包括基于所述交织排列使用一RNN网络进行时间序列预测。

[0035] 优选地，所述至少一特征直接从所述融合输出中提取。

[0036] 优选地，所述至少一机器包括执行一联产过程的一组机器。

[0037] 根据本发明的再一优选实施例，还提供了一种用于监测至少一机器的系统，所述系统包括：一第一传感器，用于在至少一操作时间帧期间从以一非平稳操作方式的至少一机器获取至少一第一非平稳信号，所述至少一第一传感器提供至少一第一非平稳输出；一第二传感器，用于在所述时间帧期间从所述至少一机器获取至少一第二非平稳信号，所述至少一第二传感器提供至少一第二非平稳输出；一信号处理器，用于基于所述至少一第二非平稳输出修改所述至少一第一非平稳输出，提取修改后的所述第一非平稳输出的至少一特征，并分析所述至少一特征以确定所述至少一机器的一健康状态；以及一控制模块，用于基于所述健康状态控制所述至少一机器的维修操作、维护操作和操作参数修改中的至少一项的性能。

[0038] 根据本发明的优选实施例，所述至少一特征对所述机器的所述非平稳操作的一平稳水平不敏感。

[0039] 优选地，所述至少一第一非平稳信号表示所述机器的一机械状态，所述至少一第二非平稳信号表示所述机器的一操作状态。

[0040] 优选地，所述信号处理器用于将所述第一非平稳输出和第二非平稳输出中的一个

的一小波变换乘以所述第一非平稳输出和第二非平稳输出中的另一个的一小波变换的二进制掩模。

[0041] 附加地或可替代地,所述信号处理器可操作以采用深度学习。

[0042] 优选地,所述深度学习包括将所述至少一第一非平稳输出和第二非平稳输出组合成具有一个或多个维度的一向量,并训练一神经网络以自动对所述向量进行分类。

[0043] 优选地,所述训练所述神经网络包括训练所述神经网络,以基于来自与被监测的所述至少一机器共享至少一共同特征的至少一机器的对应的平稳输出对所述非平稳输出进行分类。

[0044] 可替代地,所述信号处理器用于将所述至少一第一非平稳输出和第二非平稳输出组合成一交织排列,所述交织排列包括交替的所述第一非平稳输出和第二非平稳输出,并且基于所述交织排列使用一RNN网络进行时间序列预测。

[0045] 优选地,所述至少一机器包括执行一联产过程的一组机器。

附图说明

[0046] 结合附图,通过以下详细描述将更充分地了解和理解本发明,其中:

[0047] 图1是根据本发明的优选实施例构造和操作的用于非平稳机器性能的自动分析的一系统的简化的部分示意图、部分框图说明;

[0048] 图2A、图2B和图3分别是示出在图1所示出类型的一系统内操作的非平稳机器发出的信号的特征示意图;

[0049] 图4是根据本发明的另一个优选实施例构造和操作的用于非平稳机器性能的自动分析的一系统的简化的部分示意图、部分框图说明;

[0050] 图5A、图5B和图5C是分别示出了构成图4所示类型系统的一部分的机器学习网络的训练和操作中的步骤的简化示意图;

[0051] 图6是一个简化的流程图,示出了提取在图1或图4所示类型的系统内运行的非平稳机器产生的信号的特征所涉及的步骤示意图;

[0052] 图7是根据本发明的又一优选实施例构造和操作的用于非平稳机器性能的自动分析的一系统的简化示意图;

[0053] 图8、图9、图10和图11分别是显示在图7所示类型的系统中运行的非平稳机器产生的信号的特征的曲线示意图

[0054] 图12A、图12B和图12C是分别示出形成图7所示类型的系统的一部分的机器学习网络的训练和操作中的步骤的简化示意图;以及

[0055] 图13是一个简化的流程示意图,结合说明了在分析由在图7所示类型的系统中运行的非平稳机器产生的信号的特征所涉及的步骤。

具体实施方式

[0056] 在参考图1,图1是根据本发明的优选实施例构造和操作的用于非平稳机器性能的自动分析的一系统的简化的部分示意图、部分框图说明。如图1所示,提供了一种用于监测和自动分析非平稳机器性能的一系统100,这里仅作为示例,具体化为以非平稳方式运行的马达102。马达102优选地是在其操作期间产生非平稳信号的非平稳机器。如本文所用术语

非平稳机器是指执行具有至少一个随时间变化的特性的过程的机器,从而在其操作期间产生非平稳信号。这种非平稳机器可以包括由时变输入驱动的机器,例如,由驱动器控制的伺服马达,随着时间的推移改变输入功率的频率和幅度;驱动移动设备的马达,如电梯和起重机,随着时间的推移提供不同的驱动力;在其输出端经历时变负载的机器,例如在其操作期间经受负载变化和摩擦变化的CNC加工机器,以及安装在移动基座上的机器,例如安装在制造机器人上的马达。

[0057] 值得注意的是,传统的机器监测和诊断技术不太适合于此类非平稳机器的监测和分析,这是由于其显示的非平稳信号特征。举例来说,基于在机器操作期间产生的振动信号的频谱分析的传统机器诊断不适合于分析非平稳信号,这是因为非平稳信号的频谱内容的时间变化是由操作参数的变化引起的,诸如速度和负载等操作参数的变化。例如,在马达102的情况下,马达102可以显示非平稳时变转速及其谐波。转速频率及其谐波的振动幅度,通常与机器状况和机器故障相关,因此会出现时间变化,因此无法根据采样信号的常规频谱分析准确提取。进一步举例来说,马达102可以显示非平稳时变轴承频率或线路频率。这些频率的振动幅度通常与机器状况和机器故障相关,因此会出现时间变化,因此无法基于对采样信号进行常规频谱分析来准确提取。

[0058] 根据本发明的优选实施例,提供了新颖的系统和方法,用于非平稳机器的监测和自动状态分析,基于由多个传感器在至少一个操作时间帧期间对非平稳机器的监控,并将多个传感器的各个非平稳输出融合成融合的或组合的输出。特别优选地,所述融合包括通过所述传感器中的至少另一个传感器测量并输出的非平稳信号来修改所述传感器中的至少一个传感器测量并输出的非平稳信号。这种修改可以用于提取信号特征,这些特征可以通过适用于静态信号分析的传统信号分析方法进行准确分析,而不会损失准确性。对信号特征的分析可以产生机器的当前健康状态,所述健康状态可以包括与机器性能、机器效率、可能产生中的故障和机器未来性能的预测有关的信息。附加地或替代地,此类方法可以应用于其他类型的分析。

[0059] 如图1所示,非平稳机器102优选地由多个传感器监控,这里作为示例的实施例为包括测量机器102产生的振动的第一振动传感器110和测量机器102产生的磁通量的第二磁传感器112。应当理解的是,由于机器102固有的非平稳操作方式,由机器102产生并且可由第一传感器110和第二传感器112测量的振动和磁通量信号优选地是非平稳信号,而不管机器102的健康状况如何。

[0060] 应当理解的是,振动传感器110和磁传感器112仅作为示例示出,并且附加或替代的传感器类型可用于监测从机器102发出的信号,包括但不限于电流传感器、电磁传感器、声学传感器、温度传感器、压力传感器和流体流量传感器。进一步理解的是,用来监测机器102的多个传感器可包括测量相同类型信号的多个传感器,例如多个振动传感器或多个磁传感器,其中传感器彼此不同及/或安装在相对于机器102的不同位置,因此,尽管测量了从机器102发出的相同类型的信号,但仍会产生稍微不同的输出。

[0061] 另外应当理解的是,监测机器102的多个传感器可以是接触式或非接触式传感器。在本发明的某些实施例中,由于难以将传感器安全地连接到移动的非平稳设备上,非接触传感器的使用可能是优选的。多个传感器,例如传感器110和112,优选地在机器102的相同的至少一个操作时间帧期间监视机器102,使得多个传感器各自的非平稳输出代表机器运

行的相同周期或多个周期。在本发明的一个优选实施例中,多个传感器,例如监测机器102的传感器110和112,是相互同步采样的。采样可以在 $dt \approx 0.01/f$ 量级的时间窗口 dt 内同步,其中 f 是感兴趣的频率,例如RPM频率。在本发明的另一个优选实施例中,在 $dt \approx 0.01/f$ 量级的时间窗口 dt 内对多个传感器,例如监测机器102的传感器110和112进行相互同步采样,其中 f 为传感器采样频率。举例来说,传感器110和112可以以20kHz的采样频率操作并且因此传感器被同步采样的时间帧 dt 由0.5微秒给出。值得注意的是,这里选择0.01的值以将同步采样中的误差限制为1%。但是,可以根据所需的误差限值选择其他值。

[0062] 优选地,由振动传感器110提供的第一非平稳输出和由磁传感器112提供的第二非平稳输出被各自提供给增益滤波器(GFs)114和116,其依次向仿真数字转换器(ADC)118和120提供相应的信号。ADCs 118和120输出的数字化信号优选地提供给诸如CPU之类的存储器组件122并且可选地提供给云端数据库124。应当理解的是,根据系统100的操作规范,由传感器110和112获取的同步采样数据可以被传输到完全基于云端的系统、本地硬件系统或包括本地组件和基于云端的组件的系统。还应理解,本文所示的特定处理组件,包括GFs 114和116、ADCs 118和120以及CPU 122,仅通过示例的方式进行详述,并且可以在本发明的系统中采用任何合适的信号处理组件。

[0063] 由振动传感器110和磁传感器112分别输出的优选地同步采样的第一非平稳输出和第二非平稳输出优选地提供给交叉传感器信号处理器130,所述信号处理器130可包括在云端数据库124中或可包括本地处理组件。

[0064] 优选地,信号处理器130可操作来接收由至少一第一传感器和第二传感器提供的第一非平稳输出和第二非平稳输出,这里具体化为振动传感器110和振动传感器112,以及通过至少基于第二非平稳输出,例如来自磁传感器112的输出,修改第一非平稳输出,例如来自振动传感器110的输出,来组合输出,以便提取第一非平稳输出的至少一特征,在这种情况下是振动输出。

[0065] 信号处理器130优选地以自动方式操作。在本发明的一个优选实施例中,如图1所示,信号处理器130可以自动地对非平稳磁和振动数据执行小波分析以提取其特征。在本发明的另一个优选实施例中,参照图4和图5以及下文所述,信号处理器可以采用深度学习以提取输入到其的非平稳信号的特征。

[0066] 信号处理器130可以包括磁小波计算器132和振动小波计算器134。磁小波计算器132优选地将小波变换应用于来自磁传感器112的非平稳磁数据,以便提取磁数据的特征。振动小波计算器134优选地对来自振动传感器110的非平稳振动数据应用小波变换,以便提取振动数据的特征。磁和振动数据的小波变换产生相应磁和振动频谱内容的时间相关性,从而避免由于机器102生成的信号的非平稳性质而导致的频谱分析中的限制。应当理解的是,由磁小波计算器132和振动小波计算器134执行的磁小波计算和振动小波计算是用于从传感器110和112获取的非平稳数据中提取特征的操作的特别优选示例。然而,应当理解,可以实施替代数据操作以提取由传感器110和112获取的非平稳数据的特征。

[0067] 图2A中示出了噪声滤波的磁小波图像的简化示意,例如可以由磁小波计算器132输出。可以理解,在图2A中,磁小波标度被校准并且参考伪频率被绘制。为了显示清晰,图2A中的信号幅度相对于归一化的任意单位标度示出。

[0068] 由磁小波计算器132输出的磁小波优选地提供给掩模提取器138。掩模提取器138

优选地采用图像处理算法,以便基于全磁小波图像提取磁小波掩膜,但仅包含特定频率的时间相关性,并且所有其他频率都被滤除。举例来说,由掩模提取器138提取的磁小波掩膜可以仅包含RPM频率的时间相关性,过滤掉所有其他频率。由掩模提取器138提取的磁小波掩膜优选为二进制小波矩阵,其中RPM标度可转换为伪频率。WO/2018/198111中描述了可用于创建这种小波掩膜的示例性优选算法,其已转让给与本发明相同的受让人并通过引用并入本文。图2B示出了二进制磁小波掩膜的简化示例,所述掩膜仅包含从图2A的全磁小波提取的RPM频率,例如可以由掩模提取器138输出。

[0069] 进一步举例来说,由掩模提取器138提取的磁小波掩膜主要仅包含RPM频率和线路频率及其谐波的时间相关性。这些频率可对应于各种机器故障,例如在RPM频率及其谐波的情况下的机械松动和不平衡,以及在线路频率及其谐波的情况下的电气故障。

[0070] 由掩模提取器138提供的二进制磁小波掩模和由振动小波计算器134提供的全振动小波优选地提供给小波倍增器150。小波倍增器150优选地用于将二进制磁小波掩模乘以包含所有频率和幅度的全振动小波图像。全振动小波与磁小波掩模相乘用于从全振动小波中滤除与掩模频率无关的那些频率。例如,在磁小波掩膜仅包含RPM频率的情况下,二进制小波掩模与全振动小波相乘产生仅包含RPM频率的一振动小波图像。图3示出了仅包含RPM频率的振动小波图像的简化示意,例如可以由小波倍增器150生成。

[0071] 进一步举例来说,在基于RPM和线路频率及其谐波生成磁小波掩膜的情况下,掩模可与全振动小波相乘。在这种情况下,可以将掩模作为逆掩模应用于全振动小波,使得仅保留通过将RPM频率和线路频率及其谐波乘以全振动小波而获得的频率以外的频率。这些频率可称为异步频率,并与轴承频率或其他机器部件相关的频率密切相关。

[0072] 然后可以对仅包含RPM频率的振动小波图像执行数值求和,以便根据下式提取振动信号的RPM幅度:

$$[0073] \quad A_{vib}(RPM) = \sum M_{mag}^w(f_{rpm}, t) \cdot V_{vib}^w(f, t) \quad (1)$$

[0074] 其中M是二进制磁小波矩阵,其中RPM频率设置为1,所有其他频率设置为零,作为掩模提取器138的输出,V是振动信号的总小波变换,作为振动小波计算器134的输出。方程式(1)中表示的求和可由特征提取器152执行。方程式(1)的乘积A表示RPM频率的振幅。如上所述,所述参数与机器状况和故障高度相关。可以理解,特征提取器152可以用于从滤波后的振动小波图像中提取任何相关特征,包括线路频率或其谐波的振动幅度。可以分析由特征提取器152输出的RPM频率的振动幅度,以便确定机器102的健康状态。这种分析的结果可以提供给控制器154,基于该控制器154可以自动修改机器102的操作参数、启动或安排机器102上的维修操作或者启动或安排机器102上的维护操作。附加地或替代地,这种分析的结果可以以人类可理解的形式呈现给至少一位人类专家,人类专家可以基于所述结果来评估机器状态并相应地启动维护、修理或操作参数改变。附加地或替代地,可以例如通过特征跟踪算法随时间跟踪提取的特征。

[0075] 可以理解,本文描述的信号处理器130的各种操作表示计算操作的特别优选实施例,其中基于第二非平稳信号修改第一非平稳信号,以便提取第一非平稳输出的至少一个特征。这里,举例来说,从第一非平稳振动信号导出的全振动小波被从第二非平稳磁信号导出的RPM二进制掩膜修改,以提取第一振动信号的RPM幅度,为了找到机器状态,可以分析所

述RPM幅度。

[0076] 还应了解, 通过从非平稳磁信号中提取的特征来修改非平稳振动信号, 以导出振动信号的特征, 这与对从振动和磁传感器110和112获得的数据进行简单的比较分析根本不同。根据本发明的优选实施例, 从一种传感器 (例如磁传感器112) 的数据的特征被用作来自另一类型传感器 (例如振动传感器110) 的数据的校准输入。这种交叉传感器校准基于以下理解: 尽管各种类型的信号, 例如振动信号和磁信号本身并不固定, 但信号之间的关系是这样的, 可以使用来自一类型信号的特征来校准另一类型的信号。

[0077] 应当理解, 本发明不限于应用于关于特定频率的小波变换的使用, 例如RPM频率, 而是可以应用于关于非平稳信号频谱内容的任何相关部分的其他操作。此外, 应当理解, 尽管在关于图1描述的示例中, 第一信号 (作为示例是振动信号) 基于从第二信号 (作为示例是磁信号) 提取的特征而被修改, 反过来也是可能的, 由此可以基于从第一信号 (例如振动信号) 中提取的特征来修改第二信号 (例如是磁信号)。

[0078] 还应理解, 信号处理器130的各种自动信号处理部件, 包括磁小波计算器132、振动小波计算器134、掩模提取器138、小波倍增器150和特征提取器152, 为了便于解释其各自的功能, 本文将它们表示为各个组件。然而, 信号处理器130的组件执行的各种功能不一定按照本文描述的顺序执行, 也不一定被分为如本文所示的单独模块。

[0079] 图4中示出了信号处理器130的替代实施例。如图4所示, 信号处理器130可以由包括基于机器学习操作的振动-磁信号融合器450的信号处理器430代替。振动-磁信号融合器450优选地可操作以采用机器学习来自动融合振动传感器和磁传感器110和112的非平稳输出, 例如, 通过基于至少一第二非平稳输出 (例如由磁传感器112输出的非平稳磁信号) 修改至少一第一非平稳输出 (例如由振动传感器110输出的非平稳振动信号), 以便提取对机器102的非平稳操作的平稳水平不敏感的第一非平稳输出的至少一特征。由振动-磁信号融合器450提取的至少一个特征随后可通过常规信号分析技术进行分析, 所述常规信号分析技术适合于分析平稳信号的特征, 以便产生机器102的状况并检测其操作中的异常。可以理解, 因此, 可以有利地基于标准信号分析技术分析从机器102发出的非平稳信号并准确地找到机器102的状况, 尽管机器102的操作方式是非平稳的, 由于提取了对机器102的操作的平稳性水平不敏感的非平稳输出的至少一个特征。

[0080] 在振动-磁信号融合器450中采用的机器学习技术的一个特别优选的实施例示于图5A至图5C。然而, 应当理解, 在振动-磁信号融合器450中采用的机器学习技术不限于图5A至图5C中所示的那些。并且可以包括任何合适的机器学习技术, 所述机器学习技术可以被实现以便自动地融合从机器102发出的各种非平稳信号, 以便从中提取对非平稳机器102的操作的平稳水平不敏感的多个信号特征。然后, 可以使用常规信号分析技术来自动分析提取的信号特征, 常规信号分析技术被设计成对平稳信号特征进行分类, 但是可以精确地应用于从机器102发出的非平稳信号。

[0081] 现在转向图5A, 示出了振动-磁信号融合器450的操作中的初始训练步骤500。平稳数据集502优选地被提供作为初始训练步骤500的输入。数据集502优选地包括来自多个传感器 S_1 - S_n 的数据, 这里多个传感器作为示例具体化为振动传感器110和磁传感器112。然而, 应当理解, 数据集502可以包括来自附加或替代类型的传感器的数据, 例如电流传感器、电磁传感器、声学传感器、压力传感器、流体流量传感器和温度传感器。数据集502可以包括当

以平稳方式操作并产生平稳信号时从机器102发出的数据。附加地或替代地,数据集502可以包括从与机器102共享共同特征的一组机器发出的数据,尽管不一定与其相同并且以平稳方式操作以生成平稳信号。共享可以从中获取数据集502的共同特征的所述组机器可以包括或不包括机器102。

[0082] 多个传感器,例如传感器110和112,优选地在机器102的相同的至少一个操作时间帧期间监控所述机器102,使得传感器的各自非平稳输出表示机器操作的相同周期或多个周期。在本发明的一个优选实施例中,多个传感器,例如监测机器102的传感器110和112,是相互同步采样的。采样可以在 $dt \approx 0.01/f$ 量级的时间窗口 dt 内同步,其中 f 是感兴趣的频率,例如RPM频率。在本发明的另一个优选实施例中,在 $dt \approx 0.01/f$ 量级的时间窗口 dt 内对多个传感器,例如监测机器102的传感器110和112进行相互同步采样,其中 f 为传感器采样频率。举例来说,传感器110和112可以以20kHz的采样频率操作并且因此传感器被同步采样的时间帧 dt 由0.5微秒给出。值得注意的是,这里选择0.01的值以将同步采样中的误差限制为1%。但是,可以根据所需的误差限值选择其他值。

[0083] 数据集502优选地提供给第一传感器融合运算器510。第一传感器融合运算器510优选地将来自传感器1-n的数据组合成组合的单个数据集,这里具体化为振动传感器110和磁传感器112。根据本发明的一个实施例,第一传感器融合运算器510可以将振动和磁信号组合成一维向量,所述向量还包括数据的对数函数,使得由第一传感器融合运算器510输出的组合的单个数据集包括原始传感器数据及其对数函数。然而,应当理解,第一传感器融合运算器510不限于包括输入传感器数据的对数函数,而是可以附加地或替代地对数据执行其他数学运算,包括例如求出数据的倒数或求出数据的平方。此外,第一传感器融合运算器510可操作以根据本领域已知的其它方法融合来自多个传感器的数据,例如将振动数据和磁数据及其对数相加并创建二维向量,其中第二维表示传感器的数量,或者对振动数据和磁场数据进行小波变换。

[0084] 由传感器融合运算器510输出的组合的单个数据集优选地输入到第一神经网络NN1,这里由附图标记512表示。NN1 512优选地体现为多层感知(MLP)网络。NN1优选地可操作以自动提取输入到其中的平稳数据的特征,这里表示为 X_s 。应当理解,由NN1提取的特征优选地基于来自传感器1-n的数据的融合,这里体现为振动传感器和磁传感器110和112。特别优选地,NN1可用于从一组信号中提取一个或多个特征,基于提取的特征修改第二组信号,然后从第二组修改后的信号中提取一个或多个特征。应当理解,对数数据到NN1的输入有助于NN1学习来自各种传感器类型的数据相对于彼此的乘法和除法运算,从而允许通过另一信号的特征来修改一个信号。

[0085] 由NN1提取的特征优选地提供给第一分类器,分类器1,由附图标记514指示。分类器1优选地用于对NN1输出的特征进行分类,以便找到生成分析信号的机器的状况。由分类器1输出的机器条件优选地提供给一损失计算器516,在那里得到一损失函数。损失函数可以是任何合适的损失函数。举例来说,损失函数可以表示由分类器1提供的信号特征的分类与人类分析提供的信号特征的分类之间的差异,例如交叉熵损失函数。

[0086] 然后,最好将损失函数反馈给NN1和分类器1,以便使用反向传播和梯度下降算法以迭代过程进一步更新NN1内的权重,从而训练NN1和分类器1以更准确地提取相关特征并对这些特征进行分类。可以继续所述迭代过程,直到损失计算器516找到的损失函数低到可

接受的程度,这意味着NN1和分类器1被认为是经过训练的,可以与人类专家相比,以可接受的准确度水平提取和分类平稳信号的信号特征。

[0087] 举例来说,在由第一传感器融合运算器510输出的组合的单个数据集包括一维向量的情况下,所述一维向量包括具有长度L的信号及其对数,NN1可以包括一个完全连接的网络,所述网络包括多个隐藏层,其确切数量取决于信号长度L和要提取的所需特征数量。假设L远远大于40,输入层中的神经元数量可以与L的值相对应,第二层为L/4,在第三层对应于L/10,最后一层对应于L/40。非线性激活函数可以包含在层之间,例如Relu或sigmoid函数,以允许网络学习传感器数据点之间的非线性关系。

[0088] 进一步举例来说,在由第一传感器融合算子510输出的组合的单个数据集包括振动和磁数据的二维向量及其总长度 $L > 40$ 的对数的情况下,则NN1可由卷积神经网络CNN代替,例如,包括五个内核过滤器,其中最初的两个内核具有长度为L/20的宽维度以捕获低频传感器融合内容,并且最后的三个内核具有大小分别为L/80、L/200和L/400的窄维度以捕获高频传感器融合内容。为了降低数据集的维度,CNN中可以在最大池化为4和2的卷积层之间包括池化层。激活函数优选为Relu、Sigmoid或tanH函数,以便允许CNN学习传感器数据之间的非线性关系。在卷积层之后,可以提供分类器1,优选地包括大小等于CNN的输出层的大小的完全连接的网络,以便将特征划分为等级。这些等级可以代表机器操作中特定故障的严重性或机器总体健康状态的严重性。例如,在多等级分类的情况下,最后一层可以包含softmax激活函数,而在二元分类的情况下,可以使用sigmoid函数。批量归一化可以包含在CNN的层之间,以提高CNN训练的性能。

[0089] 现在转向图5B,示出了振动-磁信号融合器450的操作中的附加训练步骤520,优选在图5A的训练步骤500之后。

[0090] 如图5B中所见,优选地提供源自诸如机器102的给定机器的成对的平稳数据和非平稳数据。数据对优选地包括用于机器102的随机配对的平稳数据,包括来自多个传感器1-n的平稳数据,以及来自机器102的非平稳数据,包括来自多个传感器1-n的非平稳数据。可以理解,尽管数据对是随机配对的,但是要求平稳和非平稳配对数据都对应于相同的机器健康状态,所述状态可以是健康的或不健康的。这些对优选地被打乱以便混合,同时满足每对的组成对应于相同的机器健康状态的要求。

[0091] 可以理解,为了对平稳数据执行第一训练步骤500并且为了对平稳数据和非平稳数据执行第二训练步骤520,有必要区分平稳数据和非平稳数据。根据本发明的优选实施例,可以基于平稳性测试来区分平稳数据和非平稳数据。这种测试可以由机器学习分类器执行,经过训练以基于数据标记将数据分类为平稳或非平稳。或者,这样的测试可以由基于信号处理的分类器来执行,用于分析产生数据的机器的运行状态。举例来说,这样的分类器可用于对磁信号执行小波变换以确定主频率峰值是恒定的还是非恒定的,从而分别指示机器运行的平稳特性或非平稳特性。进一步举例来说,这样的分类器可用于使用过零算法分析磁信号的时间波形以确定主频率峰值是恒定的还是非恒定的,从而分别指示机器运行的平稳特性或非平稳特性。

[0092] 分类为平稳数据的数据优选地提供给第一传感器融合运算器510,分类为非平稳数据的数据优选地提供给第二传感器融合运算器524。第一和第二传感器融合运算器510和524优选地分别将从传感器1-n向其输入的数据组合成组合的单个数据集,其中传感器1-n

在这里具体化为振动传感器110和磁传感器112。此外,传感器融合运算器510和524优选地分别计算来自传感器1-n的数据的对数函数,使得传感器融合运算器510和524输出的组合的单个数据集分别包括原始传感器数据及其对数函数。应当理解,传感器融合算子510和524不限于计算输入传感器数据对数函数,而是可以附加地或替代地对数据执行其他数学运算,包括例如求出数据的倒数或求出数据的平方。此外,第一和第二传感器融合运算器510和524可用于根据本领域已知的其他方法融合来自多个传感器的数据,例如将振动数据和磁数据及其对数相加并创建二维向量,其中,第二维度表示传感器的数量,或者对振动数据和磁数据执行小波变换。

[0093] 优选地将包括由第一传感器融合运算器510基于平稳数据输出的对数函数的组合的单个数据集优选地提供给NN1 512。应当理解,作为在图5A所示的第一训练步骤500中对NN1 512进行训练的结果,NN1 512已经被训练成从由第一传感器融合运算器510输出的平稳数据集中提取相关特征。由NN1提取的平稳数据的特征在这里表示为 X_s 。

[0094] 优选地将包括由第二传感器融合运算器524基于非平稳数据输出的对数函数的组合的单个数据集优选地提供给一第二NN,这里表示为NN2 530。NN2530优选地具有与NN1大致相同的架构,但是在NN的层内具有不同的权重。NN2优选地用于从由第二传感器融合运算器524输出的非平稳数据集提取相关特征。应当理解,由NN2提取的特征优选地基于来自传感器1-n的非平稳数据的融合,这里体现为振动传感器和磁传感器110和112。可以理解,对数数据输入到NN2有助于NN2学习来自各种传感器类型的数据的乘法和除法运算。NN2提取的非平稳数据集的特征在此表示为 X_{ns} 。

[0095] 为了针对NN1训练NN2,由NN1发现的平稳特征 X_s 和由NN2发现的非平稳特征 X_{ns} 优选地提供给损失计算器532,其中找到了代表平稳特征和非平稳特征之间差异的损失函数。任何合适的损失函数可由损失计算器532计算。优选地,所计算的损失是根据 $(X_s - X_{ns})^2$ 计算的MSE损失。然后,优选地将损失函数反馈给NN2,以便进一步更新NN2内的权重,以便训练NN2自动准确地从非平稳数据集中提取特征,这些特征与从平稳数据集中提取的那些特征差别很小。可以继续所述迭代过程直到损失计算器532找到的损失函数低到可接受的程度,这意味着与从同一台机器或类似一组机器获取的平稳信号的信号特征相比,NN2被认为经过训练以可接受的精度水平提取非平稳信号的信号特征。

[0096] 现在转到图5C,图5C是振动-磁信号融合器450的操作中的操作步骤540,优选在图5A和图5B的训练步骤500和520之后。

[0097] 如图5C所示,在机器102以非平稳方式操作期间,从机器102发出的非平稳信号542由多个传感器S1-Sn测量,这里通过示例实现为振动传感器110和磁传感器112。非平稳信号542优选地提供给第二传感器融合运算器524,其向NN2 530提供组合的传感器数据集。可以理解,NN2 530已经根据第二训练步骤520被训练为从非平稳数据中提取特征,这些特征与来自相同或相似机器的平稳数据的特征的区别在于最小损失函数。结果,由于这些非平稳信号特征和平稳信号特征之间的共同性,NN2从融合的非平稳传感器信号中提取的特征可以提供给分类器1514,以便基于这些特征对机器102的状况进行分类,基于在第一个训练步骤500中训练的分类器1。应当理解,NN2因此优选地可操作以提取第一非平稳输出的至少一个特征,所述特征对机器102的非平稳操作的平稳水平不敏感并且因此可以由分类器1准确地分类,尽管分类器1已被训练对平稳信号的特征进行分类。

[0098] 分类器1在步骤540内执行的分类结果可提供给控制器154,控制器154可基于所述结果自动修改机器102的操作参数,启动或安排机器102上的维修操作,或启动或安排机器102上的维护操作。附加地或替代地,这种分类的结果可以以人类可理解的形式呈现给至少一位人类专家,人类专家可以基于所述结果来评估机器状态并相应地启动维护、修理或操作参数改变。应当理解,分类器1可以在第一训练步骤500中被训练以允许对机器102中的特定故障进行分类,例如轴承磨损。附加地或替代地,分类器1可以以非特定于故障的方式进行训练,以允许将机器102的状态分类为健康或不健康,其中机器102的异常操作的性质不是由分类器1指定的。

[0099] 应当理解,在图5A至图5C中,来自多个传感器 S_1-S_n 的初始输入信号可以包括由多个传感器获取的原始数据或者可以包括基于原始数据的处理数据,其中原始数据在被网络进一步处理之前被转换。

[0100] 现在参考图6,其是一个简化的流程图,示出了在图1或图4所示类型的系统内运行的非平稳机器产生的信号的提取所涉及的步骤。

[0101] 如图6所示,用于提取来自非平稳机器的信号的特征的方法600可以从第一步骤602开始,其中在非平稳机器的操作期间从非平稳机器获取至少第一和第二组信号。

[0102] 第一组信号和第二组信号优选地在机器102的相同的至少一个操作时间帧范围获得,使得传感器的相应非平稳输出代表机器操作的相同周期或多个周期。在本发明的一个优选实施例中,多个传感器相互同步采样。采样可以在 $dt \approx 0.01/f$ 量级的时间窗口 dt 内同步,其中 f 是感兴趣的频率,例如RPM频率。在本发明的另一个优选实施例中,在 $dt \approx 0.01/f$ 量级的时间窗口 dt 内对多个传感器进行相互同步采样,其中 f 为传感器采样频率。值得注意的是,这里选择0.01的值以将同步采样中的误差限制为1%。但是,可以根据所需的误差限值选择其他值。

[0103] 由于由其监测的机器的非平稳运行,第一和第二组信号优选地具有非平稳特性。

[0104] 可以理解,第一组信号和第二组信号可以分别是不同类型的信号,例如振动信号和磁信号。或者,第一组信号和第二组信号可以是相同类型的信号,例如都是磁信号或都是振动信号,但是由不同类型的传感器获取并且因此在其某些方面不同。

[0105] 如第二步骤604所示,优选地从第一组信号中提取一个或多个特征。举例来说,可以从磁传感器输出的非平稳磁信号或振动传感器输出的非平稳振动信号中提取一个或多个特征。举例来说,可将磁小波变换应用于非平稳磁信号以导出仅包含与非平稳机器的RPM相关的频率的二进制磁小波掩模,如上文参考图1所述。进一步举例来说,NN可从由磁传感器输出的非平稳磁信号或从由振动传感器输出的非平稳振动信号自动提取一个或多个特征,如上文参考图4至图5C所述。

[0106] 如在第三步骤606看到的,第二组信号优选地使用在第二步骤604从第一组信号提取的特征来修改。因此,在从第二组信号中进一步提取特征之前,第一组信号用于转换或校准第二组信号。举例来说,在第二步骤604中导出的二进制磁小波掩模可用于通过将二进制磁小波掩模乘以基于振动信号的振动小波来校准振动信号,以便从振动小波中滤除与非平稳机器转速频率相关的频率以外的所有频率。进一步举例来说,NN可以基于从另一种类型的非平稳信号提取的特征来自动修改一种类型的非平稳信号。

[0107] 如在第四步骤608所示,然后优选地从如在第三步骤606所修改的第二组信号中提

取一个或多个特征。举例来说,可以对在第三步骤606导出的修正振动小波进行求和,以便提取RPM频率的振动幅度。进一步举例来说,NN可以自动提取由此修改的非平稳信号的特征。如在第五步骤610看到的,可以分析提取的一个或多个特征以便找到被监控的非平稳机器的健康状态。应当理解,通过方法600提取的一个或多个特征优选地代表机器健康并且对机器操作的平稳性水平不敏感。举例来说,在通过NN提取信号特征的情况下,可以对提取的特征进行分类,并基于使用从以平稳而不是非平稳方式操作的相同或类似机器获取的数据训练的分类器来导出机器状况。

[0108] 如第六步骤612所示,可基于在第五步骤610中确定的机器的健康状态,对机器执行或计划执行修理或维护操作,或更改机器的操作参数。应当理解,第六步骤612可以通过与被监控的机器耦合的控制器以自动化方式执行。附加地或替代地,被监控的机器的健康状态可以以人类可感知的形式传达给人类专家,并且人类专家可以参与指导被监控的机器的修理、维护或操作改变。

[0109] 现在参考图7,其是根据本发明的又一优选实施例构造和操作的用于非平稳机器性能的自动分析的一系统的简化的部分示意图、部分框图。

[0110] 如图7所示,提供了一种用于监测和自动分析非平稳机器的性能的系统700,这里仅作为示例实施,作为按照嵌入机器的控制器704中的可编程操作模式或配方操作的机器人702或伺服电机。由于控制器704对机器参数(例如输入功率和转速)的时变修改,机器702以非平稳方式操作。

[0111] 值得注意的是,传统的机器监测和诊断系统不太适合监测和分析这种非平稳机器,这是由于其显示的是非平稳信号的特征。根据本发明的优选实施例,提供了新颖的系统和方法,用于根据时变配方操作的非平稳过程的机器的监测和自动状态分析。这种状态分析优选地基于多个传感器对非平稳机器的监测,在配方间隔上融合传感器的非平稳输出,以便创建融合输出,并提取反映根据配方操作的机器状态的信号特征,基于融合输出。

[0112] 在本发明的某些实施例中,在找到配方间隔之后,根据找到的配方间隔调整多个传感器的采样特性可能是有利的。然后可以提取信号特征并且自动学习在配方间隔期间与机器相关联的信号特征。这种学习可用于在配方间隔期间建立机器性能的基线模型。随后可将从机器产生的信号中提取的后续信号特征与机器性能的基线模型进行比较,以便检测指示机器健康状态变化的异常和偏差。可根据发现的异常情况采取适当的整改措施,如机器维修、维护或更改运行参数。

[0113] 如图7所示,机器人702优选地由多个传感器监控,这里通过示例实现为测量例如从驱动机器人702的臂的马达711发出的振动的第一振动传感器710和测量从马达711发出的磁通量的第二磁传感器712。应当理解,由于机器人702的非平稳操作方式,无论机器人702的健康状态如何,从机器人702的马达711发出并由第一传感器和第二传感器710和712测量的振动信号和磁通量信号优选为非平稳信号。

[0114] 由传感器710和712测量的表示由诸如机器人702的加工机器产生的振动和磁信号的示例性数据示于图8和图9中。图8显示了在两个不同时间段内操作的机器人702的马达711的四秒记录期间的两个振动波形的数据。图9显示了与图8所示的两个振动波形同步获得的两个磁波形的数据。从图8和图9中可以看出,机器人702根据具有三个操作区域的配方进行操作,三个操作区域在图8和图9中分别表示为A、B和C,每个操作区域都与增加的振动

和磁信号相关。配方内的这三个操作区域A、B和C由于不同的输入参数而产生不同的信号，如由机器702的控制器704修改的。

[0115] 值得注意的是，振动传感器和磁传感器710和712仅以示例的方式示出，并且可以使用附加或替代传感器类型来监控机器702的性能，包括但不限于电流传感器、电磁传感器、声学传感器和温度传感器。还应理解，监控机器702的多个传感器可包括测量相同类型信号的多个传感器，例如多个振动传感器或多个磁传感器，其中传感器彼此不同，因此，尽管测量了机器702的相同参数，但仍会产生略有不同的输出。

[0116] 还应了解，监控机器702的多个传感器可以是接触式或非接触式传感器。在本发明的某些实施例中，由于难以将传感器安全地连接到移动的非平稳设备上，非接触式传感器的使用可能是优选的。

[0117] 多个传感器，例如传感器710和712，优选地在机器702的相同的至少一个操作时间帧期间监控机器702，使得传感器的各自非平稳输出表示机器操作的相同周期或多个周期。在本发明的一个优选实施例中，多个传感器，例如传感器710和712监测机器702，是相互同步采样的。采样可以在 $dt \approx 0.01/f$ 量级的时间窗口 dt 内同步，其中 f 是感兴趣的频率，例如RPM频率。在本发明的另一个优选实施例中，在 $dt \approx 0.01/f$ 量级的时间窗口 dt 内对多个传感器，例如传感器710和712监测机702进行相互同步采样，其中 f 为传感器采样频率。举例来说，传感器110和112可以以20kHz的采样频率操作并且因此传感器被同步采样的时间帧 dt 由0.5微秒给出。值得注意的是，这里选择0.01的值以将同步采样中的误差限制为1%。但是，可以根据所需的误差限值选择其他值。如下文详述，传感器采样频率可以在找到配方间隔之后根据配方间隔进行调整。

[0118] 优选地，由振动传感器710提供的第一非平稳输出和由磁传感器712提供的第二非平稳输出被各自提供给增益滤波器(GFs)714和716，其依次向仿真数字转换器(ADC)718和720提供相应的信号。ADCs 718和720输出的数字化信号优选地提供给诸如CPU之类的存储器组件722并且可选地提供给云端数据库724。应当理解的是，根据系统700的操作规范，由传感器710和712获取的同步采样数据可以被传输到完全基于云端的系统、本地硬件系统或包括本地组件和基于云端的组件的系统。还应理解，本文所示的特定处理组件，包括GFs 714和116、ADCs 718和120以及CPU 722，仅通过示例的方式进行详述，并且可以在本发明的系统中采用任何合适的信号处理组件。

[0119] 振动传感器710和磁传感器712分别输出的同步采样的第一非平稳输出和第二非平稳输出优选地提供给机器配方分析器730，所述机器配方分析器730可以包括在云端数据库724中，或者可以包括本地处理组件。

[0120] 优选地，机器配方分析器730包括配方间隔查找器760，用于查找控制机器人机器702的操作的配方间隔。配方间隔查找器760可基于检测传感器710和712的输出中的重复间隔来查找配方间隔。优选地，尽管不一定，配方间隔查找器760可采用交叉传感器融合，如上文参考图1至图6所述，以便在机器702产生的融合磁信号和振动信号中找到重复信号特征。

[0121] 图8的两组振动数据之间的交互关联水平表示配方间隔，如图10所示。可以在多个时间间隔应用交互关联算法，并且根据本发明基于由转速加权的相关幅度给出分级

$$[0122] \quad \frac{1}{S_{tot}} \int \frac{1}{W(f_{rpm}, t)} S_1^*(t) \cdot S_2(t + \tau) dt \quad (2)$$

[0123] 其中 S_i 表示来自任何类型传感器(例如振动传感器或磁传感器)的传感器数据, S_{tot} 是两个传感器的能量大小的乘积之和, W 是RPM加权函数。

[0124] 配方间隔查找器760可选择性地向传感器710和712提供反馈控制,以便在确定配方间隔之后,配方间隔查找器760可自动操作,以根据由此找到的配方间隔重新配置传感器710和712的采样参数。举例来说,在确定配方间隔之后,可以调整传感器710和712中的一个或两个的采样持续时间及/或频率,以便允许传感器710和712在整个配方间隔期间监视机器人702,在配方间隔内的定义周期内或配方间隔的多个周期内。

[0125] 在配方间隔查找器760查找配方间隔并对传感器710和712的采样参数进行相应的调整之后,可以对传感器710和712在配方间隔上获取的数据进行处理,以便在配方间隔上获取的信号内检测感兴趣的区域或区块,如配方间隔查找器760所发现的。这些区域可以基于特别代表机器性能而选择,并且可以作为示例,对应于包括增加的振动或增加的磁通量信号的区域。

[0126] 区域检测可基于对配方间隔内的数据应用希尔伯特变换并分析其包络函数来执行。希尔伯特变换可应用于来自各个传感器的数据或来自各个传感器的数据的交叉传感器处理中提取的数据。或者,可以基于具有高斯函数的卷积掩蔽来执行区域检测,以便捕获与振动区域相关联的指数信号上升和下降。图11中示出了划分为区域的振动信号的示例。如图11中所示,虚线780代表应用于区域检测的拟合算法并且各个区域由垂直线782描绘。

[0127] 优选地分析在配方间隔内由传感器710和712获取的数据,以便提取其特性特征并且因此学习在配方间隔内执行配方的机器的特性。在执行区域检测的情况下,可以逐个区域、每个特定区域而不是在整个配方间隔上逐个区域地计算信号特征。多个区域可以基于其特性特征进行分类,例如区域能量、区域持续时间和区域内的力矩变化。可以理解的是,将配方间隔划分为代表性区域以及在每个区域而不是整个配方间隔上发现信号特征是非常有利的,因为在整个配方间隔内的特征提取通常会导致低分辨率、低代表性的特征,这是因为配方间隔内的操作模式变化很大。然而,应当理解,在本发明的某些实施例中,如果配方间隔内的变化具有足够小的规模以使得这种区域划分不必要,则可以不需要将配方间隔划分为区域。

[0128] 另外或替代地,在配方间隔内由传感器710和712获取的数据的分析可以基于其他机器学习算法。从数据中提取的特征可以包括统计特征,例如数据的概率密度函数矩、累积量或熵;运行特性,如速度和输入功率;主要波形成分、波形功率谱、信号能量、信号完整性等特征;机器性能特征,例如机器效率,例如基于W0/2018/198111中描述的类型信号分析算法;以及与可从外部传感器获取的环境特征相关联的特征,例如,在涉及流体流动的机器的情况下,可将外部温度传感器获取的环境温度与机器温度和机器压力进行比较。

[0129] 与执行配方的机器702相关联的信号特征,优选地包括区域特征,可通过配方学习算法790学习。与配方相关联的信号特征的自动学习可以通过外部数据的输入来增强,例如,作为示例,来自控制器704的数据。控制器数据可以与来自传感器710和712的数据相关,以便提供与机器702操作所依据的配方相关的附加信息,从而提高配方间隔检测的准确性。

[0130] 在配方学习算法790发现配方特性和特征之后,可以建立机器702在配方执行期间的性能模型。这样的模型可以由配方模型建构器792构建并且可以构成表示给定配方范围内的机器性能的基线模型。所述模型可以存储在数据库中,例如云端数据库724。所述模型

可以用作基础,在配方执行期间由机器702生成的信号的后续特征可以与该基础进行比较以便检测异常和偏差。举例来说,机器性能的异常可由异常检测器794检测。配方特性的异常可能是由于,例如,由于机器退化。或者,异常可能是由于机器操作中的恶意干预造成的,例如在为了修改机器配方而安装在控制器704上的恶意安全漏洞的情况下。可以输出由异常检测器794检测到的异常,并且基于这些异常,可以发现机器702的健康状态或恶意干预。然后可以自动地或基于人为干预来执行适当的纠正措施,例如改变机器操作参数、停止机器操作或修理机器,例如通过机器控制模块796。

[0131] 由配方模型建构器792构建的模型可以包括来自耦合到机器702的低功率传感器的数据,所述低功率传感器以的功率操作比传感器710和712低但与其相关。这种低功率传感测可针对机器702而不是在特定配方间隔内连续地执行,并且可用于在配方执行期间从机器性能模型检测传感器读数中的实时异常。在发现这种异常的情况下,较低功率的传感器可以激活较高功率的传感器,例如传感器710和712,以便收集额外的数据,基于这些数据,异常检测器794可以应用更先进的异常检测算法。

[0132] 配方学习算法790,配方模型建构器792和异常检测器794对应于机器学习算法的一个优选实施例,机器学习算法用于自动构建执行给定配方的机器702的操作模型,并将从机器702发出的信号与该模型进行比较,以评估机器702的操作中的异常。

[0133] 根据本发明的特别优选实施例,配方学习算法790、配方模型建构器792和异常检测器794可以采用深度学习,并且特别优选可以采用递归NN(RNN),例如长-短期存储器(LSTM)网络,以便在由此产生的配方的执行期间从机器702发出的非平稳信号中发现异常。

[0134] 图12A、图12B和图12C中示出了可在机器配方分析器730内使用的LSTM网络的可能实现的特别优选实施例。现在转到图12A,诸如由机器702生成的非平稳配方数据集8100被视为包括多个信号,这里具体化为包括随时间变化的振动信号的第一信号集 S_1 和包括随时间变化的磁信号的第二信号集 S_2 。可以理解,振动信号和磁信号的时间序列优选地跨越整个配方间隔并且可以跨越多个配方间隔,如配方间隔查找器760优选地发现的。还应理解,第一和第二信号集 S_1 和 S_2 可包括原始传感器数据,但更优选地包括从原始数据提取的特征,例如线路频率或RPM或区域特征。例如,第一信号集 S_1 可以包括马达711的振动水平,第二信号集 S_2 可以包括马达的当前线路频率,尽管不一定在区域上。应当理解,虽然马达711的振动水平代表马达711的机械状态,但是基于磁信号的马达711的线路频率与电机速度直接相关,从而与电机的运行状态直接相关。

[0135] 信号集 S_1 和 S_2 优选地提供给传感器融合时间序列操作器8102。传感器融合时间序列操作器8102优选地将不同类型的信号融合成单个组合信号,所述组合信号包括根据时间排列的信号类型中的交替信号。因此,磁信号 M_{i-1} 与相应的同步振动信号 V_{i-1} 穿插,随后是磁信号 M_i 与相应的同步振动信号 V_i 穿插,依此类推。在信号 S_1 和 S_2 分别对应于表示机器的机械和操作状态的信号的情况下,传感器融合时间序列运算器8102可操作以融合这些信号。

[0136] 由传感器融合时间序列操作器8102输出的穿插数据集,其可以包括表示机器机械状态和机器操作状态的穿插数据,优选地被提供给LSTM网络8104。参考示出LSTM网络8104的示意性表示的图12B,可以最好地理解LSTM网络8104的一种可能的操作模式。如图12B所示,LSTM网络8104接收交织的磁信号和振动信号。在每个神经元8105处,LSTM网络预测相应

的移位信号,使得每个LSTM神经元可操作以预测融合时间序列中的相邻下一数据点。

[0137] 然后在损失函数模块8106将预测的信号值与所述信号的实际测量值进行比较。损失函数模块8106优选地用于将预测信号值与实际对应的测量信号值进行比较,并且迭代地更新LSTM网络8104的权重,以便最小化预测值与实际值之间的差异。LSTM网络8104使用反向传播和梯度下降算法对损失函数进行迭代训练,所述损失函数表示LSTM网络804预测的时间序列与真实时间序列之间的差异。举例来说,损失函数模块8106可以找到MSE损失。

[0138] 根据本发明的另一个优选实施例,LSTM网络8104可以是LSTM自动编码器,其可操作以对穿插数据集进行编码并将信号特征输出到损失函数模块8106。LSTM网络8104输出的信号特征优选地基于输入信号的融合,在这种情况下体现为磁信号和振动信号,以及基于此的特征提取。损失函数模块8106优选地用于将LSTM网络8104输出的解码信号特征与输入穿插数据集进行比较。解码信号特征和穿插输入数据集之间的差异然后被反馈到LSTM网络8104,编码器的权重用反向传播和梯度下降算法迭代调整,直到损失函数小到可以接受并且LSTM网络8104被认为是经过训练将穿插数据集编码到可接受的精度水平。

[0139] 现在转到图12C,在图12A和图12B中所示的LSTM网络8104的训练之后,可以将机器702在其操作期间在配方间隔内产生的磁信号 M_i 提供给经过训练的LSTM网络8104。LSTM网络8104优选地用于预测相应的振动信号 \hat{V}_i 对应于磁信号输入,基于根据图12A和图12B所示的过程学习振动信号和磁信号之间的对应关系。

[0140] 预测振动信号 \hat{V}_i 可以与与磁信号 M_i 同步测量的实际测量振动信号 V_i 进行比较。举例来说,实际振动信号和预测振动信号可由异常检测器8108进行比较,异常检测器8108可以是异常检测器794的特别优选实施例。在预测信号与实际测量信号相差超过给定阈值差的情况下,测量信号被认为是异常的,并且指示机器702的不正常操作状态。

[0141] 值得注意的是,本文所描述的用于对按照给定配方操作的过程机器进行有条件监控的系统和方法不限于单个机器的情况。相反的,本发明可以针对有助于共同过程的多个机器来实现。这种过程可以是并行配方过程,其中多个机器在同一时间点共享相同的操作模式,也可以是串联配方过程,其中机器串联操作,一个机器的输出以串联方式形成另一个机器的输入。

[0142] 在多个机器参与共同过程的情况下,信号最好由耦合到多个机器中的每台机器的多个传感器同步获取。优选地,在单个机器702的情况下,如上所述提取配方特征,包括配方间隔、配方区域和配方区域特征,以及以及配方基线模型,是在执行所述过程的所有或部分机器上构建的,而不是针对单个机器。

[0143] 在多个机器的情况下,为了建立配方间隔而进行的交互关联通常可以如上文所述在单台机器的情况下进行,但是对于跨越多个机器的多个传感器,更具体地说,对于对应耦合到多个机器的给定类型的传感器,根据下式:

$$[0144] \quad \sum_{i,j} \frac{1}{S_{tot}^n} \int \frac{1}{W_i(f_{rpm}, t)} S_i^{n*}(t) \cdot S_j^n(t + \tau) dt \quad (3)$$

其中n代表任何类型传感器的传感器类型,例如振动或磁性,i代表机器指数,j从i+1到 i_n 。其他参数如上文参考式(2)所述。

[0145] 值得注意的是,这种多个机器的过程模型可以是对所述过程中为每台机器(例如

机器人702)构建的单个基线模型的补充。这提高了识别机器性能异常的准确性,因为多机器过程异常检测可用于增强单个机器异常检测。

[0146] 分别耦合到多个机器的不同机器的相同或不同类型的传感器可以相互关联。如上文所述,这种相关性可用于找到由机器执行的处理的类型及其配方间隔,以便适当地配置传感器采样参数。

[0147] 如果在机器配方分析器730内使用LSTM网络来分析联合执行一个过程的多台机器的操作,则举例来说,从机器发出的信号可以组合成:包括来自所有多个机器的磁信号的总磁向量和包括来自所有多个机器的振动信号的总振动向量,所述振动信号相对于所述磁信号被同步地获取。然后通过传感器融合时间序列操作器8102将振动向量与磁向量交织,以便允许LSTM网络8104学习执行给定配方的一组机器的信号的特征,从而检测与之的偏差,如上所述。应当理解,附加地或替代地,来自联合执行过程的多个机器的信号可以被平均化或以其他方式组合,然后由传感器融合时间序列操作器8102融合并提供给LSTM网络8104。

[0148] 现在参考图13,其是一个简化的流程图,说明了提取在图7所示类型的系统中运行的非平稳机器产生的信号特征所涉及的步骤。

[0149] 如图13所示,用于提取根据配方执行过程的非平稳机器产生的信号的特征的方法1300可以从第一步骤1302开始,其中,从耦合到根据配方操作的至少一个非平稳机器的多个传感器同步获取信号。根据本发明的一个优选实施例,多个传感器可以耦合到执行嵌入在其控制器中的配方的单个非平稳机器。根据本发明的另一实施例,所述至少一个非平稳机器可包括有助于共同过程的一组非平稳机器,以串行或并行方式,并且多个传感器可以包括耦合到所述组非平稳机器中的每个机器的多个传感器。

[0150] 如在第二步骤1304所示,优选地找到由机器或一组机器执行的配方的配方间隔。如在第三步骤1306所示,可以基于在第二步骤1304找到的配方间隔来调整多个传感器的参数。举例来说,可以调整传感器采样频率或采样持续时间以允许传感器在整个配方中、在配方的多个周期内或多个周期内的给定时间点对机器或一组机器进行采样。

[0151] 如在第四步骤1310所示,可以基于发现的配方特性来构建在配方执行期间机器性能的基线模型。应当理解的是,可以为根据配方执行过程的单个机器、根据配方为共同过程做出贡献的一组机器或为这两者构建这样的基线模型。

[0152] 根据本发明的一个优选实施例,机器性能模型的建立可包括以不同传感器的数据时间点的穿插排列融合来自多个传感器的数据,并将穿插数据集提供给LSTM网络,用于学习数据点之间的关系。

[0153] 如在第五步骤1314所示,在配方执行期间创建机器性能模型之后,可以将机器或一组机器执行配方期间测量的后续机器信号特征与基线模型进行比较,以便检测与其相关的异常。这种异常可以指示机器的健康状态或机器的安全状态。

[0154] 在第四步骤1310使用LSTM网络来学习配方特征的情况下,第五步骤1314可涉及LSTM网络在一个时间点预测来自一种类型的传感器的信号,其预期对应于在基本上相同的时间点从不同类型的传感器获取的测量信号。然后将预测信号与实际测量信号进行比较,并在信号之间存在偏差的情况下识别异常。

[0155] 如在第六步骤1316所示,在检测到机器性能异常的情况下,可以针对机器或一组

机器执行操作,包括维修或维护活动以及机器操作参数的变化,包括机器停止操作。

[0156] 值得注意的是,方法1300优选是自动化的,这样可以自动创建机器性能模型,并且可以自动检测与其相关的机器特性中的异常,尽管所监控的机器或一组机器的操作是非平稳的。

[0157] 本领域技术人员将理解,本发明不限于上文具体示出和描述的内容。本发明的范围包括上述各种特征的组合和子组合及其修改,所有上述内容都不在现有技术中。

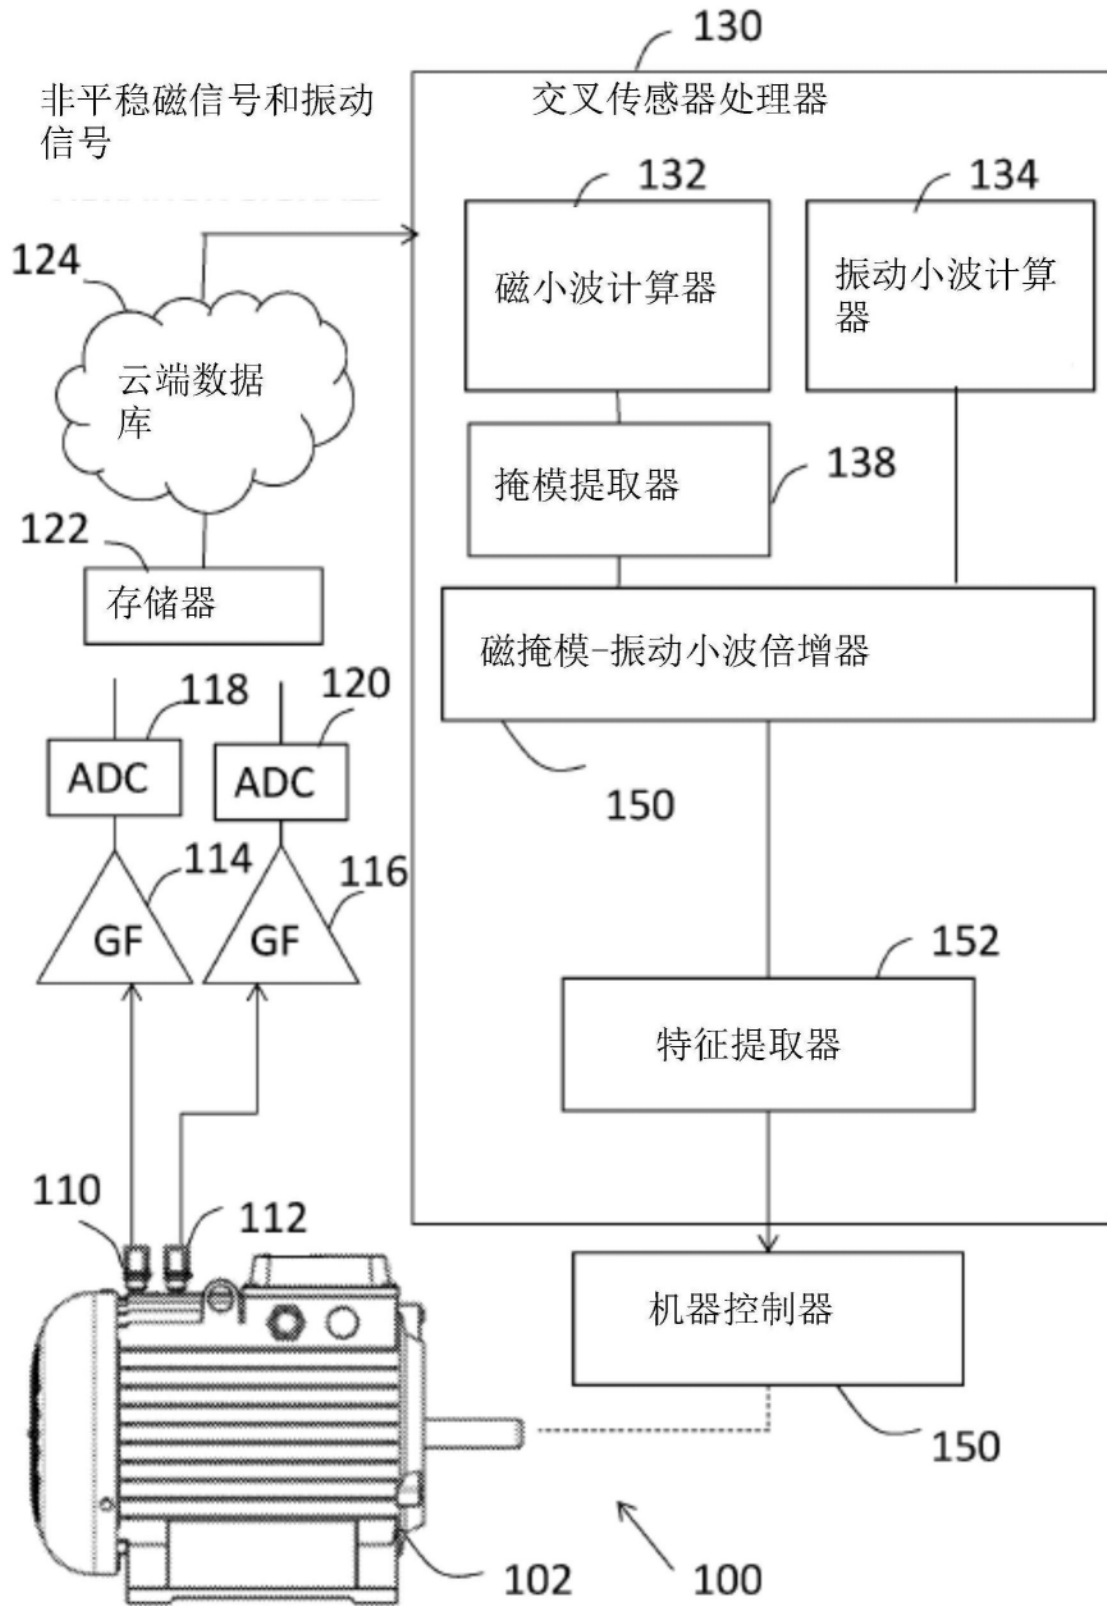


图1




图2A




图2B




图3

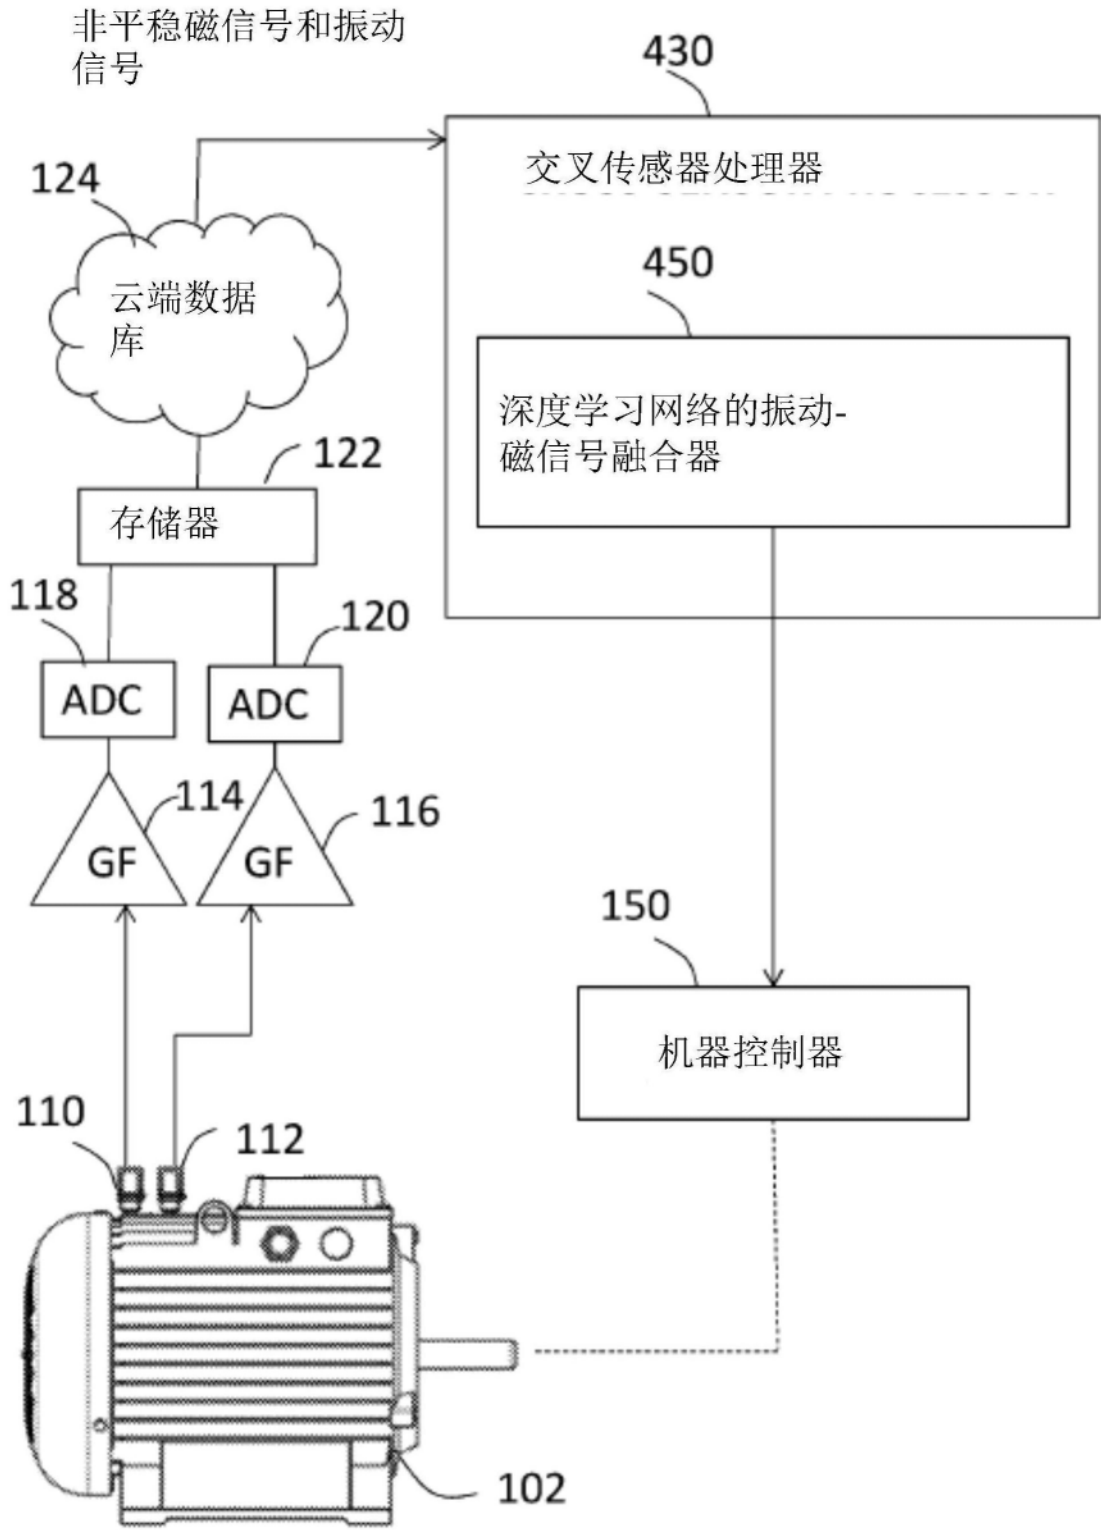


图4

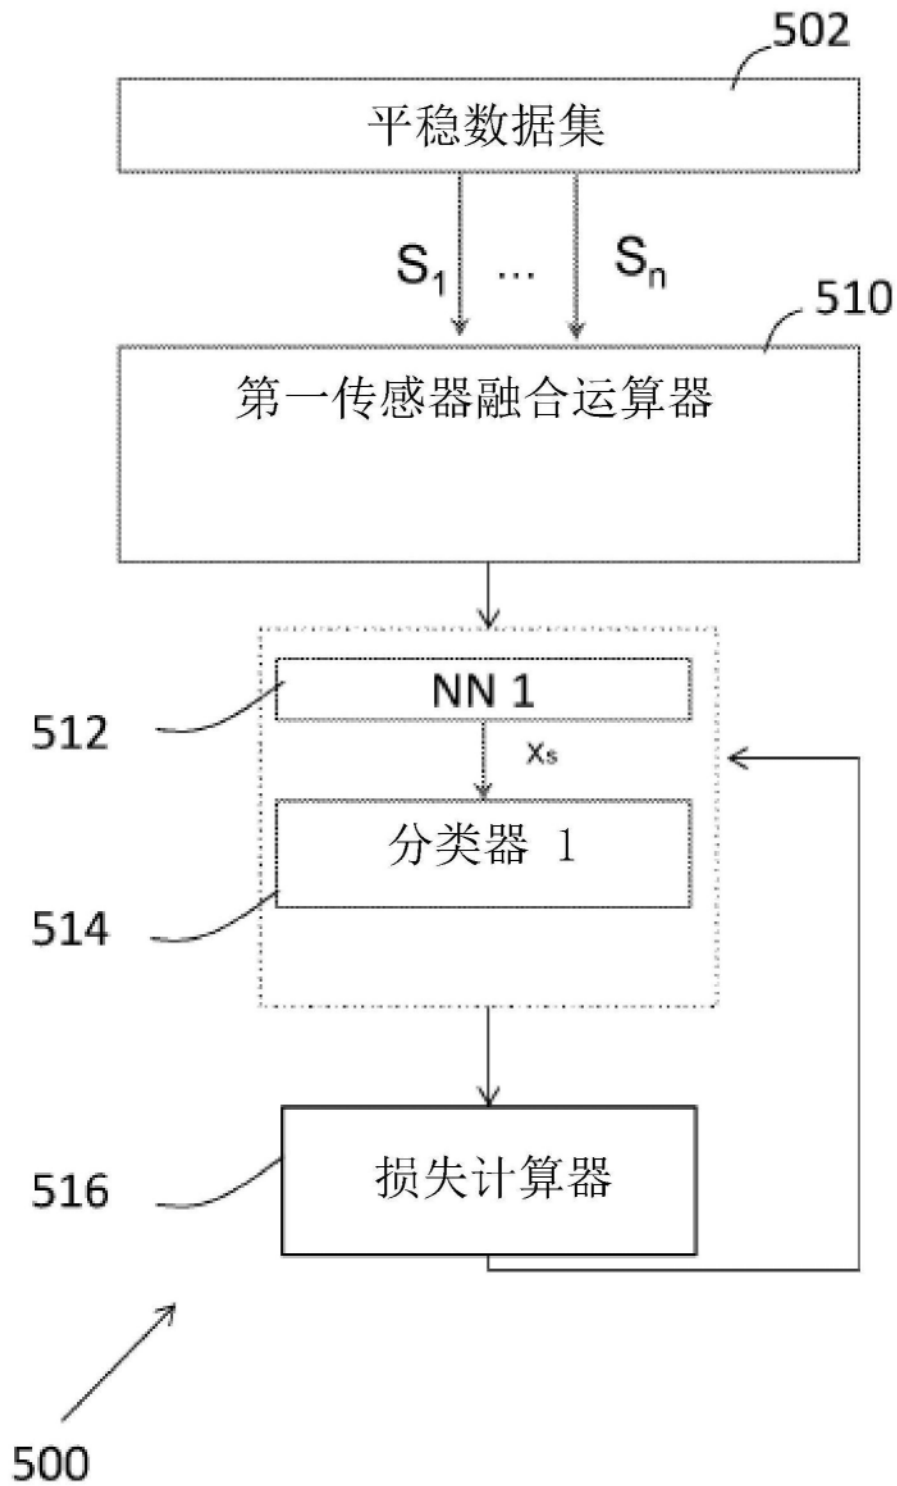


图5A

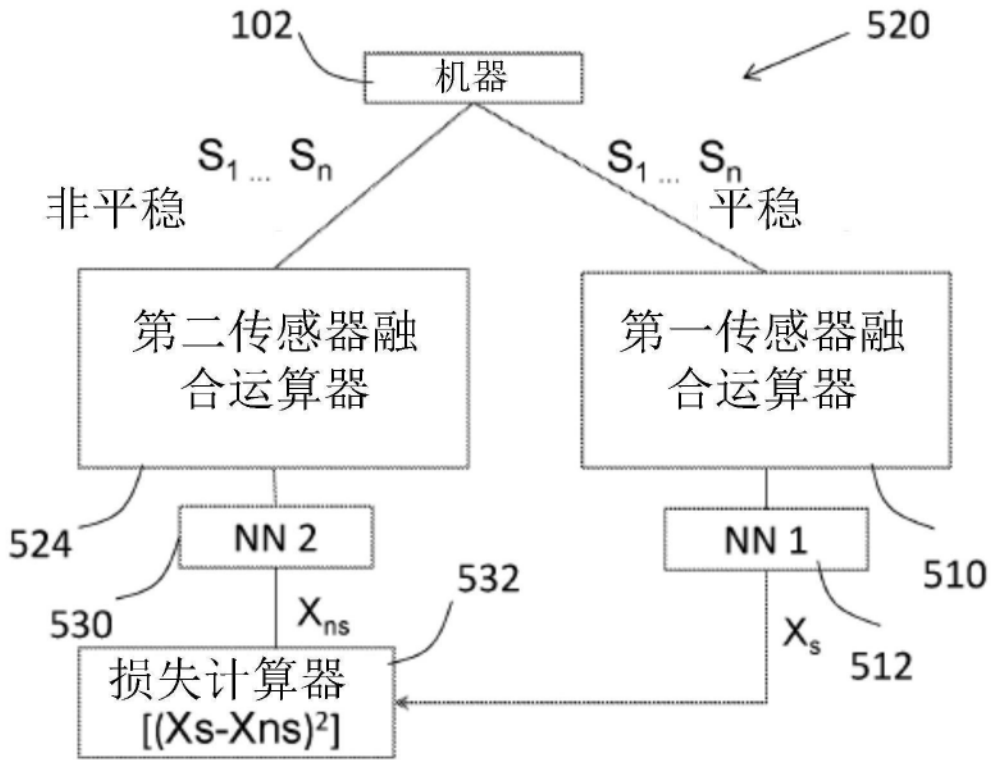


图5B

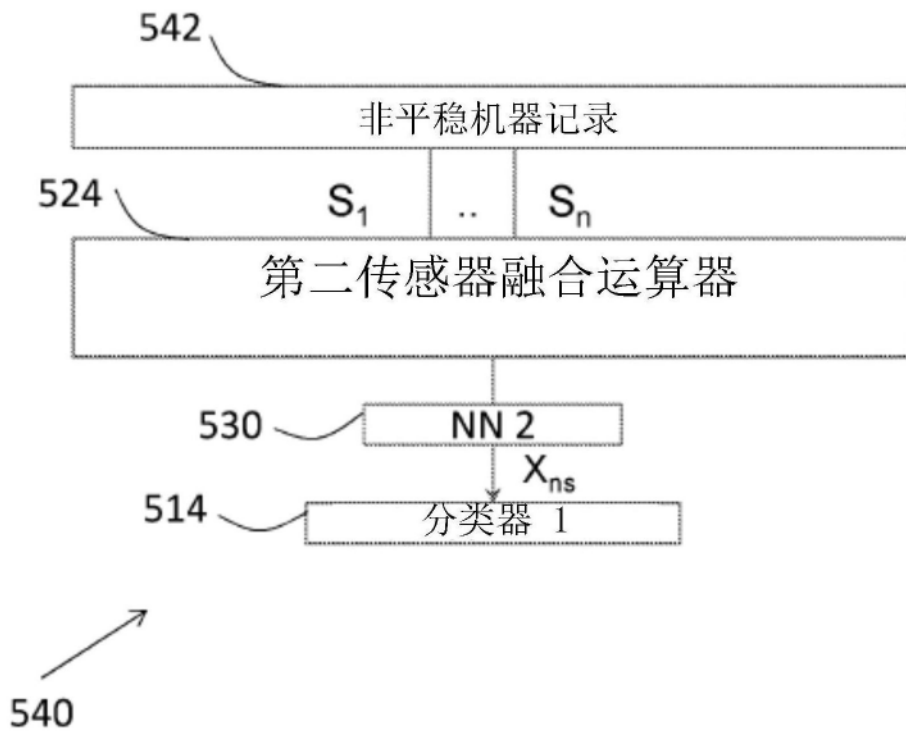


图5C

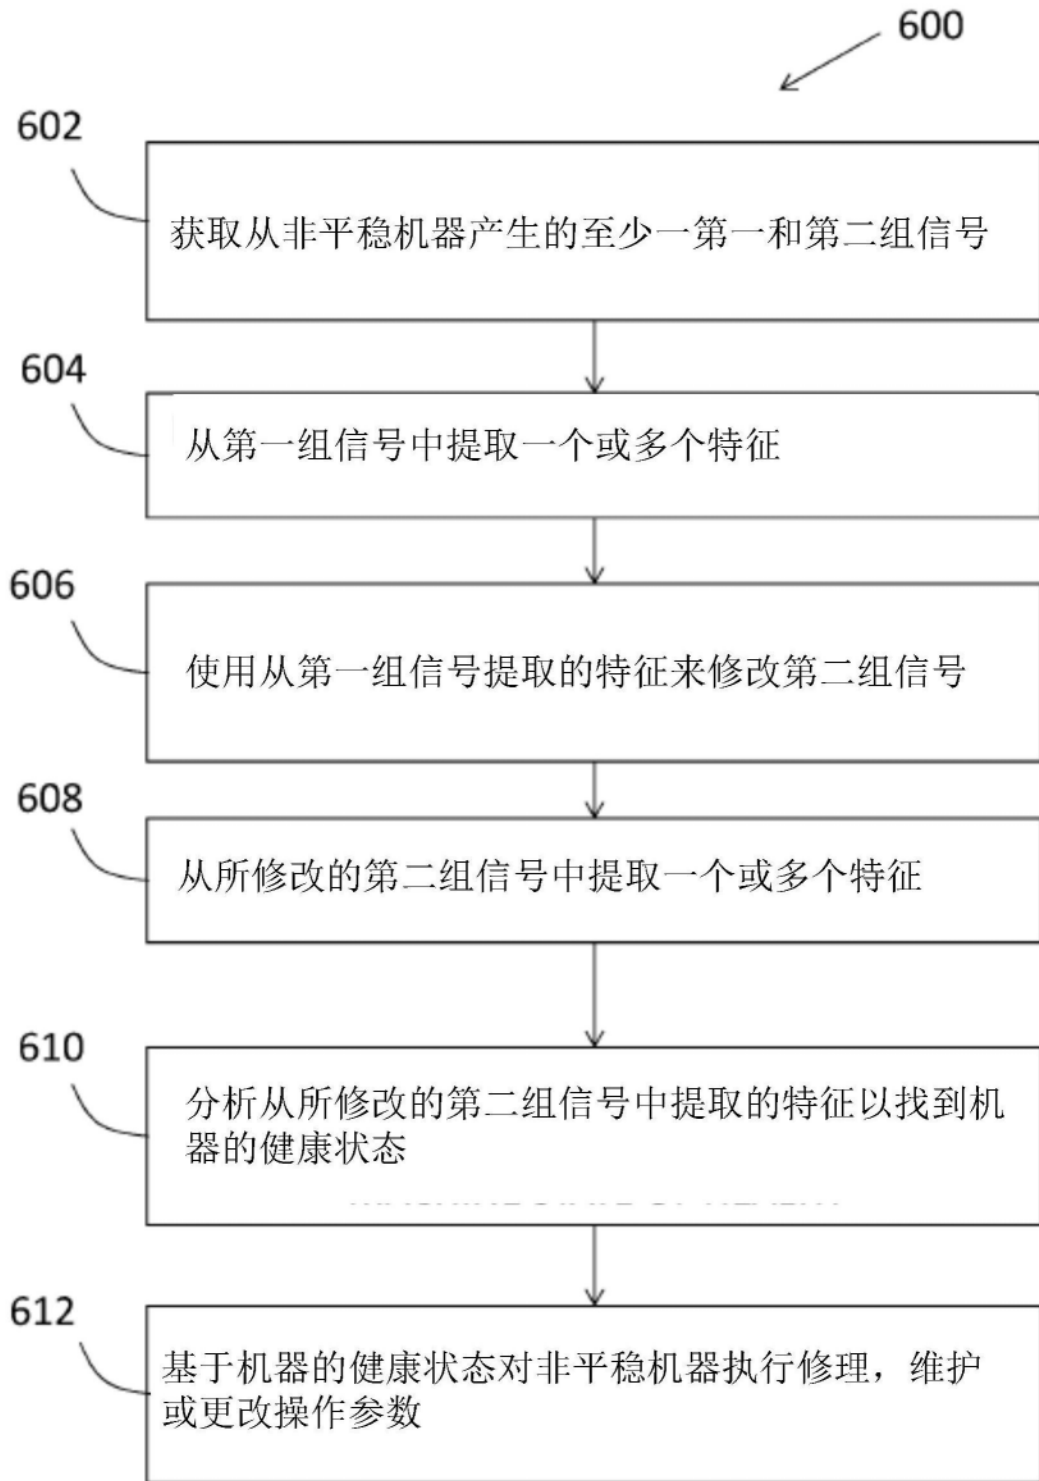


图6

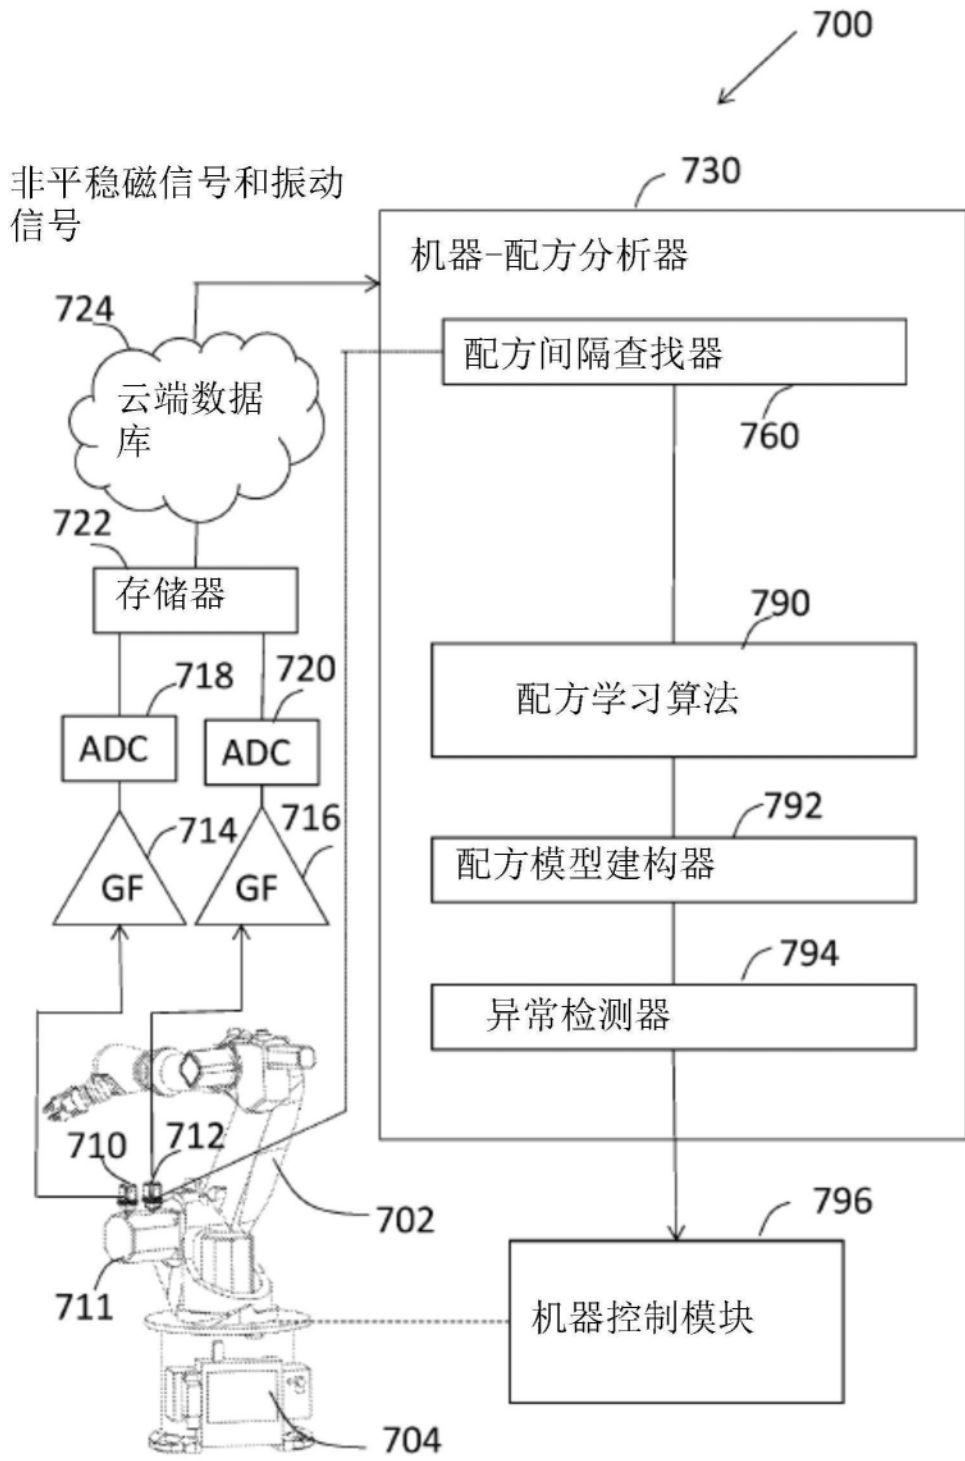


图7




图8




图9




图10




图11

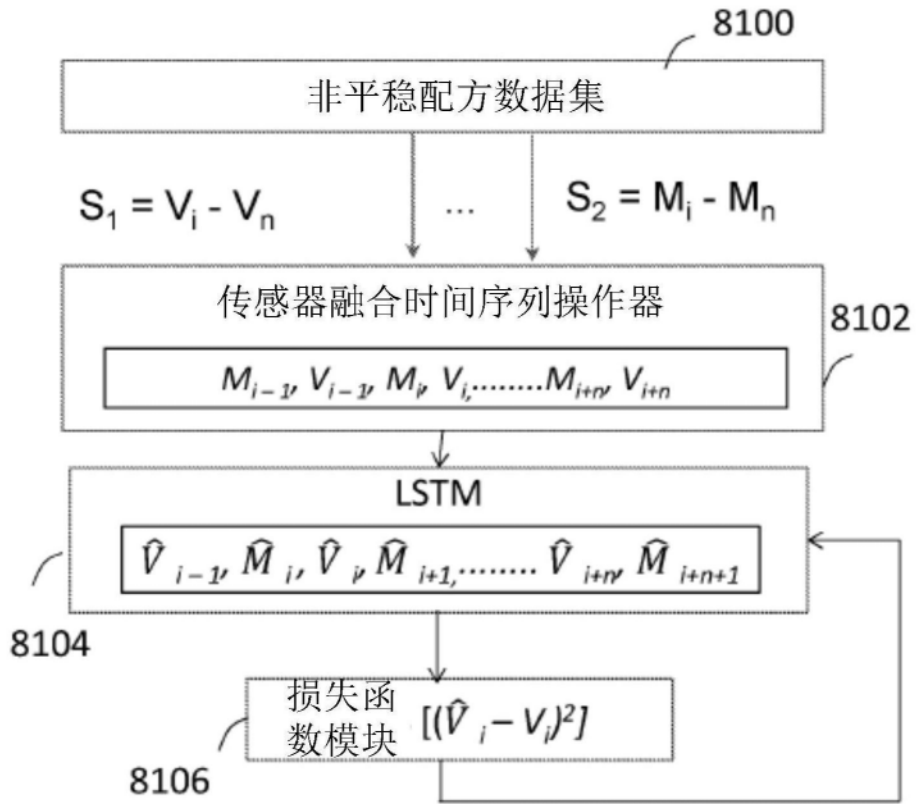


图12A




图12B

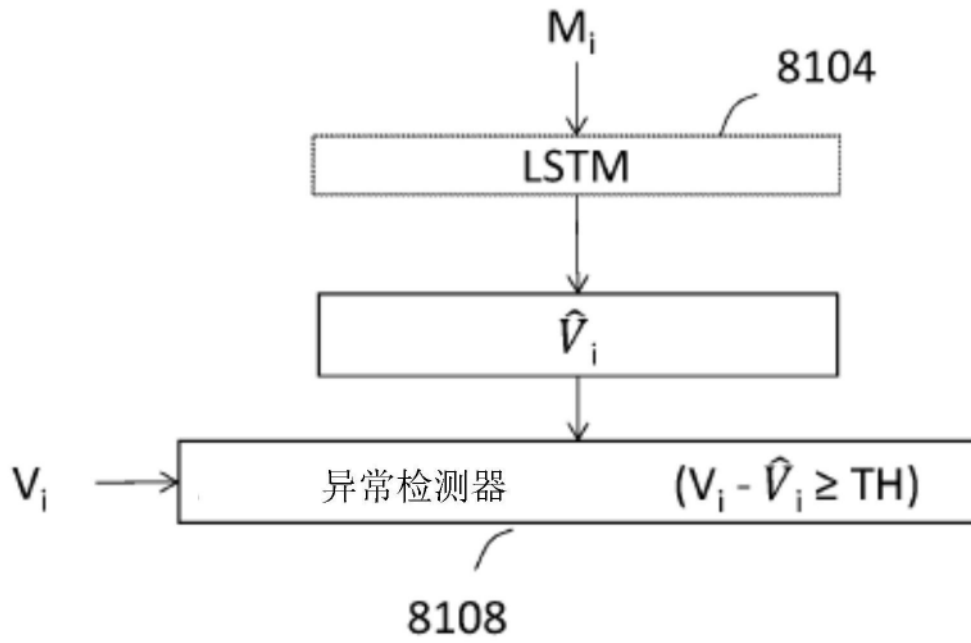


图12C

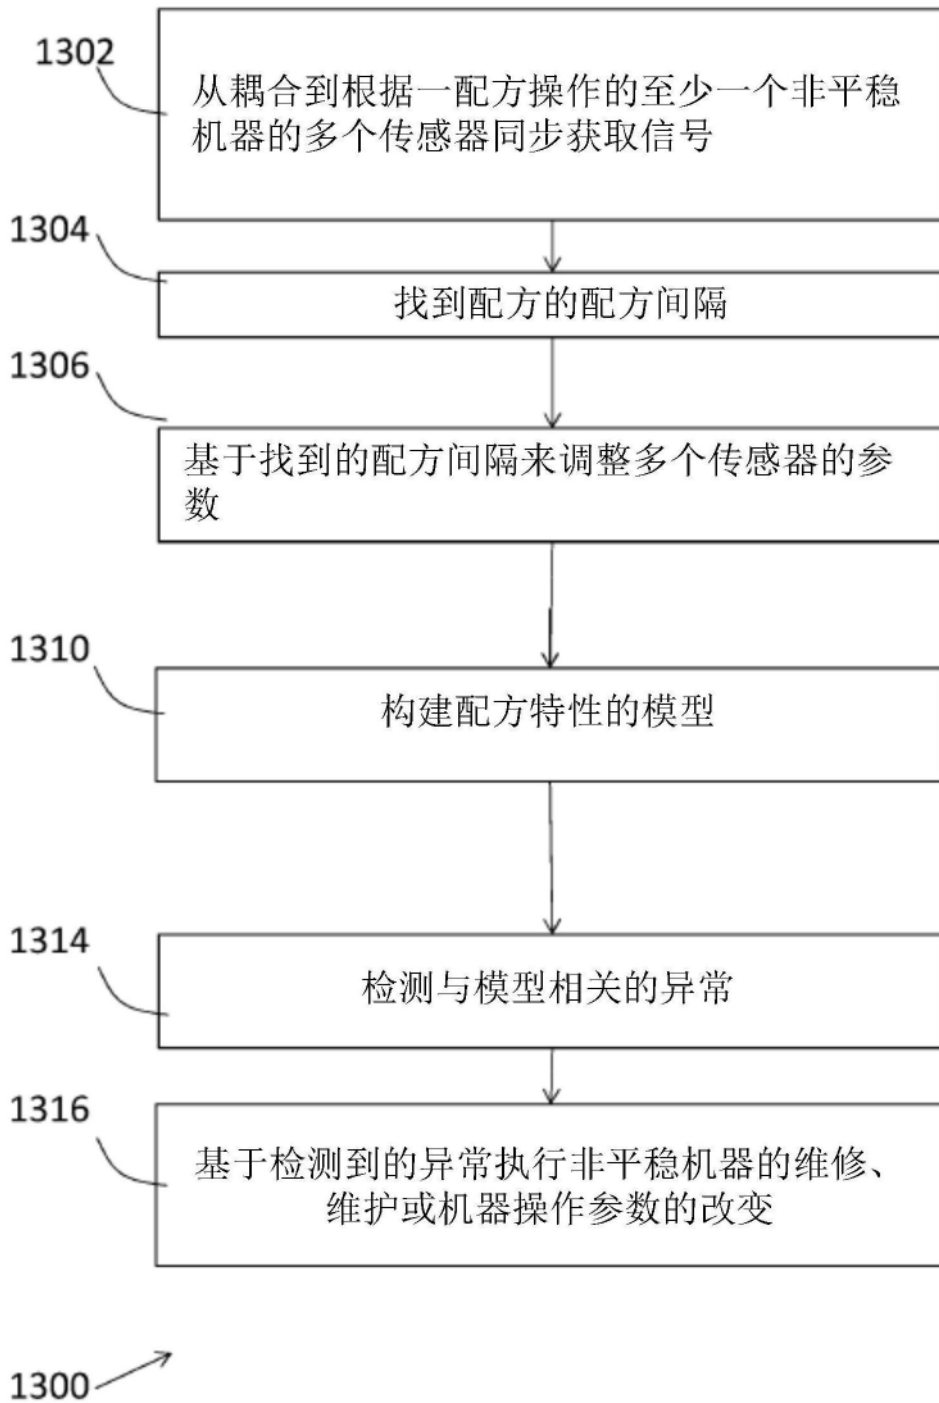


图13