(19)国家知识产权局

(12)发明专利申请

(10)申请公布号 CN 114600087 A
(43)申请公布日 2022.06.07

(21)申请号 202080075571.5

(22)申请日 2020.10.06

(30)优先权数据
62/911,346 2019.10.06 US

(85)PCT国际申请进入国家阶段日
2022.04.27

(86)PCT国际申请的申请数据
PCT/US2020/054431 2020.10.06

(87)PCT国际申请的公布数据
WO2021/071854 EN 2021.04.15

(71)申请人 PDF决策公司
地址 美国加利福尼亚州

(72)发明人 R·伯奇 J·D·大卫 朱青
本田智纪 L·L·郑

(74)专利代理机构 北京市铸成律师事务所 11313
专利代理师 王珺 段丹辉

(51)Int.Cl.
G06F 11/00(2006.01)
G06N 20/00(2006.01)

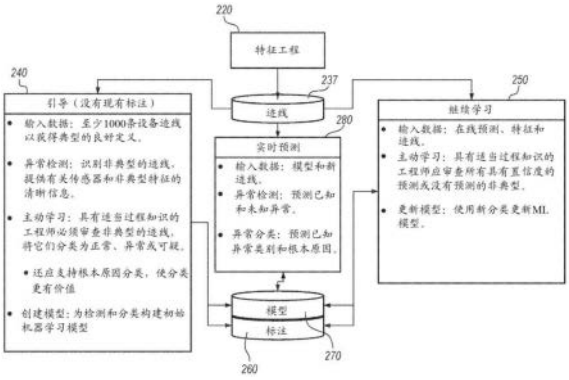
权利要求书2页 说明书5页 附图10页

(54)发明名称

异常设备迹线检测和分类

(57)摘要

一种半导体设备故障检测和分类方案。监测和处理传感器迹线以将已知的异常运行状况与未知的异常运行状况分开。特征工程允许关注目标特征的相关迹线。建立机器学习模型以基于异常的初始分类集进行检测和分类。随着更多的迹线被处理和学习,机器学习模型不断更新。



CN 114600087 A

1.一种用于对半导体设备迹线数据中的异常进行检测和分类的过程,其包括:

从相应半导体设备传感器接收多条原始迹线;

识别所述多条原始迹线的至少第一迹线集中的多个异常;

基于第一目标特征修改所述第一迹线集中的每条迹线;

从所修改的第一迹线集中的每条迹线生成特征基础集;

从所修改的第一迹线集和所述特征基础集创建多条重构迹线;以及

为所述多个异常中的每个异常分配分类。

2.根据权利要求1所述的过程,其还包括:

训练机器学习模型以基于所述第一原始迹线集、所修改的迹线和所重构的迹线对异常进行检测和分类;以及

在半导体设备操作环境中部署所述机器学习模型。

3.根据权利要求2所述的过程,其还包括:

从所述相应半导体设备传感器接收附加迹线;

识别第一附加迹线集中的附加异常;

修改所述附加迹线以移除统计特性基础集;

从所修改的附加迹线生成所述特征基础集;

从所修改的附加迹线创建重构的附加迹线;以及

基于所述第一原始迹线集、所修改的附加迹线和所重构的附加迹线更新所述机器学习模型。

4.根据权利要求1所述的过程,其还包括:

将所述多条原始迹线的所述第一集识别为与第一预定义目标特征具有有效相关性。

5.根据权利要求1所述的过程,其还包括:

将所述多条原始迹线的所述第一集识别为与多个预定义目标特征具有有效相关性。

6.根据权利要求1所述的过程,生成特征基础集的步骤还包括:

计算所述第一迹线集的统计特性集;

修改所述第一迹线集以移除所述统计特性集;

为所修改的第一迹线集计算算法解决方案;

其中所述算法解决方案和所述统计特性集形成所述特征基础集。

7.根据权利要求3所述的过程,其还包括:

将残差特征确定为在所述特征基础集中未捕获的未知迹线变化;

确定对所述第一目标特征具有已知影响的补充特征;以及

基于所述第一原始迹线集、所修改的附加迹线、所重构的附加迹线、所述特征基础集、所述残差特征和所述补充特征更新所述机器学习模型。

8.根据权利要求1所述的过程,其中所述多条原始迹线主要包括正常迹线,并且所述多个异常仅表示少数异常。

9.根据权利要求1所述的过程,其还包括:

提供图形用户界面,以用于查看选择的迹线异常;

从所述图形用户界面接收将与所选择迹线异常相关联的多个预定义类别中的一个类别作为第一输入;以及

从所述图形用户界面接收待分配给所选择迹线异常的多个预定义动作中的一个动作作为第二输入。

10.一种具有指令的非暂时性计算机可读介质,所述指令在由处理器执行时使所述处理器:

从相应半导体设备传感器接收多条原始迹线;

识别所述多条原始迹线中的至少第一迹线集中的多个异常;

基于第一目标特征修改所述第一迹线集中的每条迹线;

从所修改的第一迹线集中的每条迹线生成特征基础集;

从所修改的第一迹线集和所述特征基础集创建多条重构迹线;以及

为所述多个异常中的每个异常分配分类。

异常设备迹线检测和分类

[0001] 交叉引用

[0002] 本申请要求2019年10月6日提交的名称为“Equipment Trouble Prevention (ETP):An effective approach to Anomalous Equipment Trace Detection and Classification without Prior Labeling”的美国临时申请号62/911346的优先权,该申请通过引用整体并入本文。

技术领域

[0003] 本申请涉及半导体设备故障的检测和分类,并且更具体地涉及用于监测和处理传感器迹线以便对未知的异常设备运行状况进行检测和分类的方案。

背景技术

[0004] 通过监测设备传感器的时间迹线来检测设备故障是半导体制造中早为人知但非常困难的问题。故障检测和分类(FDC)的经典方法是计算来自传感器迹线的汇总统计数据(通常称为关键数字或指标),然后监测这些统计数据以识别异常,这主要基于工程知识。

[0005] 例如,在图1A中,垂直虚线之间的区域是显示来自半导体过程的一部分或步骤的四条不同设备传感器迹线101、102、103、104的过程窗口100。如图1B所示,通常针对迹线的每个步骤计算统计数据。然而,统计数据未能揭示图1A中从迹线104的图形中明显可见的异常110。因此,仅依赖统计过程控制技术可能会遗漏重要的异常。当然,统计过程控制方法的有效性各不相同,并且在很大程度上取决于汇总统计数据的质量。此外,计算汇总统计数据的例程需要随着过程的变化经常更新。因此,FDC汇总统计例程的构建和维护构成稀缺资源的大量投资。

[0006] 充分表示任何中等复杂过程步骤的传感器所需的统计数据数量可能达到数千甚至数万,这使得错误信号成为巨大的问题。基于产品数据分析和/或在线计量来选择相关统计数据的尝试已证明有助于减少错误信号,但是此类尝试需要足够的响应数据,而且仍无法预测先前未观察到的故障。

[0007] 另一种方法是使用迹线复制,例如,使用自动编码器神经网络,或像主成分一样简单的事物,识别可以准确地重构大部分迹线的有限的基向量集。具有高残差的迹线被假定为异常,并且残差平方和可用于检测异常。然而,虽然复制方法可以很好地识别许多迹线中的异常,但基向量通常没有明确的物理解释,这使得用户难以基于该信息对异常进行分类。

[0008] 机器学习的最新进展开创了增强基于异常传感器迹线的检测和分类的设备故障检测和分类的能力的新的机遇。然而,针对异常迹线检测和分类实现机器学习的障碍之一是难以获得标注的迹线数据。因此,任何真正有效的异常迹线检测和分类方法都必须实现有效的策略来进行不带任何标注的异常迹线识别,并且必须利用初始分类来收集标注以不断改进检测和分类。

附图说明

[0009] 图1A是示出四条设备传感器迹线的过程显示窗口。

[0010] 图1B是具有图1A中所示迹线的汇总统计数据的表格。

[0011] 图2是示出异常检测和分类系统的简化框图。

[0012] 图3是图2的一部分的详细表示。

[0013] 图4A和4B是引导示例的图形表示。

[0014] 图5A和5B是用于对迹线异常进行分类的系统的框图。

[0015] 图6是异常的预定义类别和对应的可能动作的表格。

[0016] 图7A和7B是用于对迹线异常的分类进行审查和更新的系统的框图。

具体实施方式

[0017] 如本文所用,术语“传感器迹线”是指在设备运行期间定期测量重要物理量的时间序列数据,而术语“迹线”或“设备迹线”是指针对处理实例识别的所有重要传感器的传感器迹线的集合。

[0018] 本公开解决的问题是半导体处理设备的异常运行。通过监测在处理期间采集的传感器数据,将已知的异常运行状况与未知的运行状况分开,以及对那些未知的运行状况进行分类以实现快速响应来识别设备的异常运行的能力,一直是一个早为人知的难题。因此,本公开的目的是通过描述识别与正常运行迹线相比显示出显著异常的任何设备传感器迹线的实时能力来解决这个问题。

[0019] 并行处理架构的出现和机器学习算法的进步促进了对这个问题的评估,机器学习算法允许用户在使此类方法相关且现实的速度下使用大量数据获得洞察并做出预测。机器学习是人工智能的一个分支,其涉及构建和研究可以从数据中学习的系统。这些类型的算法以及并行处理能力允许处理更大的数据集,并且更适合多变量分析。

[0020] 机器学习中的大部分能力是在嘈杂的高维空间中准确分类的能力。然而,可通过物理上有意义的特征工程来提高检测和分类方案的有效性。此外,良好的特征工程可以极大地帮助理解类似异常迹线背后的根本原因。用于异常迹线检测和分类的有效机器学习方法应促进主动学习并使用获得的信息来不断提高故障检测和分类两者的准确性。

[0021] 在生产环境中,异常迹线示例的先前标注通常是不可用的。因此,用于检测异常迹线的有效系统不能依赖于先前的标注。但是,如果可以最大限度地减少过程工程师提供标注的负担并证明其益处,则可以通过此类尝试获得对标注过程的有用输入。应包括对分类标注准确性的审查,并根据需要执行重新标注,以改进相关模型的检测和分类。

[0022] 图2示出了用于异常迹线检测和分类的系统200的简化概述。系统是基于计算机的,使得可以安装各种模块并在具有传统操作系统的最先进的独立台式计算机或等效物上运行,或者可通过托管服务提供给用户,所述托管服务可通过互联网或其他网络访问。

[0023] 在模块220中,执行“特征工程”以识别关键特征和相关的设备迹线数据集。特征工程220导致识别和使用模块237中对评估目标特征有用的迹线。在模块240中对迹线执行“引导”以主要基于在模块220中识别的关键特征创建分类标注。这导致将标注保存和存储在模块260。

[0024] 当在引导模块240中已收集到足够的标注并将标注保存到模块260中时,引导阶段

过渡到模块250中的连续学习阶段，其中异常检测和分类模型是最初构建的并将不断(或周期性地或有时)更新。根据需要对分类(标注)进行审查和更新。一旦建立了模型，就可以从模块270部署模型以在模块280中进行实时预测。

[0025] 特征工程模块220在图3中更详细地示出，并且包括两个主要处理阶段：阶段320中的自定义数据准备和阶段330中的标准特征工程。在理想情况下，特征工程不需要任何特定的过程知识；然而，在很多情况下这是不现实的。例如，在某些条件下，注入机将进入调优循环，在此期间传感器记录与正常运行有很大差异并且不会直接影响晶片的传感器值。因此，作为一个示例，在阶段320的自定义数据准备期间，识别关键特征为调优循环并将其与迹线的剩余部分分离，调整或修改迹线，并创建自定义特征集，在本示例中，所述自定义特征集表示晶片的调优周期数、调优持续时间以及调优前后每条迹线的变化。这些特征可以与阶段338中的修改的迹线相结合，以为检测和分类模型提供输入。

[0026] 这在图3中以图形方式表示，因为原始迹线324主要包含正常迹线324N和显示异常的少数迹线324A。在阶段320中对原始迹线324进行修改，并且修改的迹线326包括修改的正常迹线326N和少数修改的异常迹线326A。将修改的迹线326传递到阶段330，并且将识别的自定义特征发送到阶段338，作为用于检测和分类模型的完整特征集的一部分。

[0027] 在阶段330，检测和分类模型所需的大部分特征都是标准化的特征，并且这些标准化的特征的计算是在没有工程输入的情况下处理的。例如，在模块332中生成“基础集”特征。首先，计算每个步骤标识符(“步骤ID”)中的基础统计数据(中值和斜率)，并修改迹线以移除这些特性。然后，使用众所周知的算法解决方案(诸如主成分、自动编码器等)来通过算法计算修改的迹线的综合基础集。结合起来，这些特征(算法基础集特征、中值和斜率)形成基础集，因为给定这些基础集特征的完整列表，可以以可接受的准确性重构原始迹线。然而，以前未观察到的异常迹线将无法用这个基础集准确再现。

[0028] 在模块334中生成“补充”特征并且这些特征不用于迹线复制，但是对于理解异常的根本原因是有用的。可以生成补充特征以关注已知的有影响的度量，诸如标准偏差、步骤持续时间、白噪声等。

[0029] 使用在模块336中生成的基础集特征和“残差”特征将迹线337重构为原始迹线的近似物，以描述重构的准确性。残差特征捕获在基础集特征中未捕获的未知迹线变化。

[0030] 最后，来自模块332的基础集特征、来自模块334的补充特征和来自模块336的残差特征与原始迹线、修改的迹线和重构迹线组合，作为机器学习模型270的输入(参见图2)，所述机器学习模型被配置和训练用于对迹线异常进行检测和分类。模型识别异常迹线并基于用户反馈对这些迹线进行分类，并且可以使用两阶段方法来实现。

[0031] 返回到图2，引导阶段240用于生成初始标注，并且连续学习阶段260在累积历史标注时收集并应用新的学习。引导阶段240假设存在许多未标注的多传感器设备迹线作为输入，从几百到可能几千不等。虽然输入数据没有标注，但模型假设大部分迹线表示正常的工具运行。引导阶段的目标是主要基于从特征工程阶段220中的初始数据中识别的关键特征来识别单变量和多变量异常值。

[0032] 例如，图4A和4B示出了在所选过程步骤中的引导示例，其中原始迹线400包括第一迹线401、第二迹线402、第三迹线403、第四迹线404、第五迹线405和第六迹线406。除了此处将示出的四条异常迹线外，还将存在数百条(或更多)正常或典型迹线输入到引导模块。

[0033] 计算迹线的中值并一起显示在图形408处，其中很明显，迹线401是异常值，因此是不正常的。修改原始迹线401-406并显示为中值调整的迹线411-416。

[0034] 然后计算中值调整的迹线411-416的斜率并一起显示在图形418处，其中迹线413是异常的，并且迹线412和414是可疑的。再次修改迹线411-416并将其显示为斜率调整的迹线421-426。一旦中值和斜率已知，就可以计算算法的基础集特征，并选择捕获大部分剩余迹线变化的特征。在这个简单的示例中，仅重要的基础特征是中值和斜率。然后计算残差特征(通常是原始迹线与从基础集特征重构的近似迹线之间的平方误差之和)。从残余特征428清楚的是迹线424是异常的并且迹线422是可疑的。

[0035] 可以通过过滤其他标准来公开补充特征以用于根本原因分析。例如，针对修改的迹线421-426提取噪声特征形成图形429，其中迹线422显示为异常。

[0036] 在图5A和5B中示出了表示引导阶段240的系统500。原始迹线502主要包括正常迹线和少数异常，并被输入到特征工程模块504，在此对关键特征进行识别并保存到模块506。在模块508中，通过分析来自特征选择的关键特征的单变量和多变量分布来识别异常值迹线和特征。然后，用户在图形用户界面(GUI)510中对异常值进行分类。

[0037] 在这个示例中，GUI 510被配置为具有可用迹线的列表512，并且用户可以选择一条或多条迹线来查看。在这个查看中，四条迹线已被选择并显示为窗口514、515中的异常值迹线和窗口516、517中的参考迹线。按钮513使用户能够选择更多类似的迹线。窗口514显示了四条异常电流迹线，而窗口515显示了四条异常电压迹线。窗口516显示了六条参考电流迹线，并且窗口517显示了六条参考电压迹线。当前形状(算法基础集)特征显示在窗口518中，电压形状特征显示在窗口519中，电流残差特征显示在窗口520中，并且对于窗口514、515中显示的所有四条异常迹线，窗口521中显示的电压残差特征是异常的。

[0038] 可以使用按钮524对异常值进行分类，在这个示例中，按钮是下拉列表，从而允许用户选择若干预定义分类和相关动作之一，并经由按钮526将该分类/动作分配给这个特定异常。例如，图6是可以经由按钮524或其他等效模式实现的预定义类别和动作的表格。定义了三个类别：正常、可疑和异常。对于每个类别，都定义了动作。如果用户将异常值分类为正常，则没有必要进行动作，并且使用正常迹线来更新检测和分类模型中正常迹线的定义。

[0039] 如图6所示，如果用户将异常值分类为可疑或确定地分类为异常，则为分类提供关于异常值是否无害、是否需要监测或是否应触发即时警报状况的进一步指示。关于异常分类的最终决定通常将包括某种形式的专家审查。

[0040] 在将所有异常值分配给类别之后，使用所有处理过的迹线数据作为基于机器学习的模型的训练集在模块530中构建初始检测和分类模型。然后，所述模型可以用作独立或在线异常迹线检测和分类系统。

[0041] 在持续学习模块中，输入数据包括在线预测、工程特征和迹线数据(原始的和调整的)。交互式GUI有助于主动学习以建立准确的异常检测和分类模型。通过算法识别类似迹线的能力是高效主动学习的关键。

[0042] 具有适当过程知识的过程工程师应该优选地审查所有预测以建立可以并入模型中的置信水平因子。例如，图7A和7B与图5A和5B在示出用于分类审查的环境方面类似。GUI 710类似于GUI 510并允许审查者选择迹线，使用按钮724选择适当的类别和动作，使用按钮726分配该类别/动作，然后经由按钮726使用新的学习更新模块730中的模型。

[0043] 持续学习利用现有的检测和分类机器学习模型来预测每个晶片的最可能分类，而且还基于最近的训练数据和新迹线之间的相似性来预测置信度。最低置信度预测被标记用于强制审查，并且最可能是未知异常。

[0044] 尽管最基本的异常检测是单变量的(特征是否正常?)，但可使用多变量方法来识别不易从单变量分析中明显可见的附加异常。例如，某些设备故障可能更容易从多条传感器迹线的评估中观察到，诸如在发生温度和压力偏移两者的情况下，如果只考虑参数中的一个，则动作可能更有可能。相反，设备故障通常会在多个传感器上生成多个异常，并且多变量签名对于预测根本原因很重要。

[0045] 用于根本原因分类的适当机器学习算法优选地是数据特性和数据量的函数。例如，如果数据量非常低，则简单的最近邻算法可能会产生最佳结果。如果数据量适中并且主要数据变化被工程特征所捕获，那么一些复杂的基于树的方法(诸如极端梯度提升)可能是很好的选择。如果数据量足够，并且迹线中存在与根本原因相关的强残差效应，那么卷积神经网络可能是最佳选择。为了以最少的用户输入解决这个问题，使用基于交叉验证的模型选择例程来构建分类模型，并且在许多情况下，多个模型与用于将多个预测组合成单个预测的简单聚合模型一起使用。

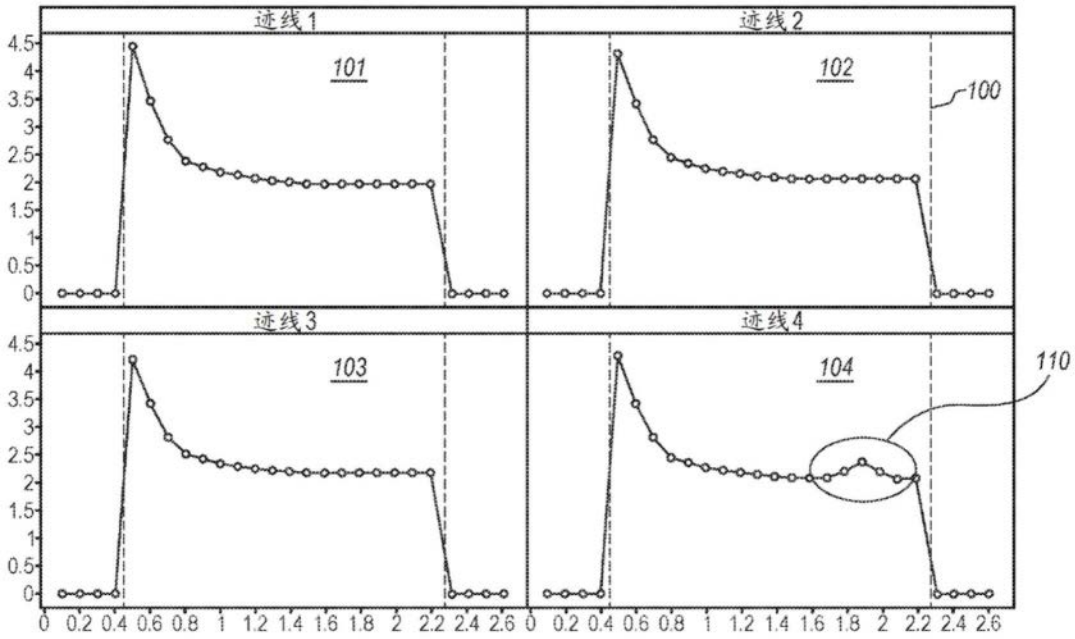


图1A

	迹线1	迹线2	迹线3	迹线4
均值	2.34	2.40	2.47	2.43
标准差	0.66	0.60	0.54	0.58
最大值	4.50	4.35	4.23	4.35
最小值	2.00	2.10	2.20	2.10

图1B

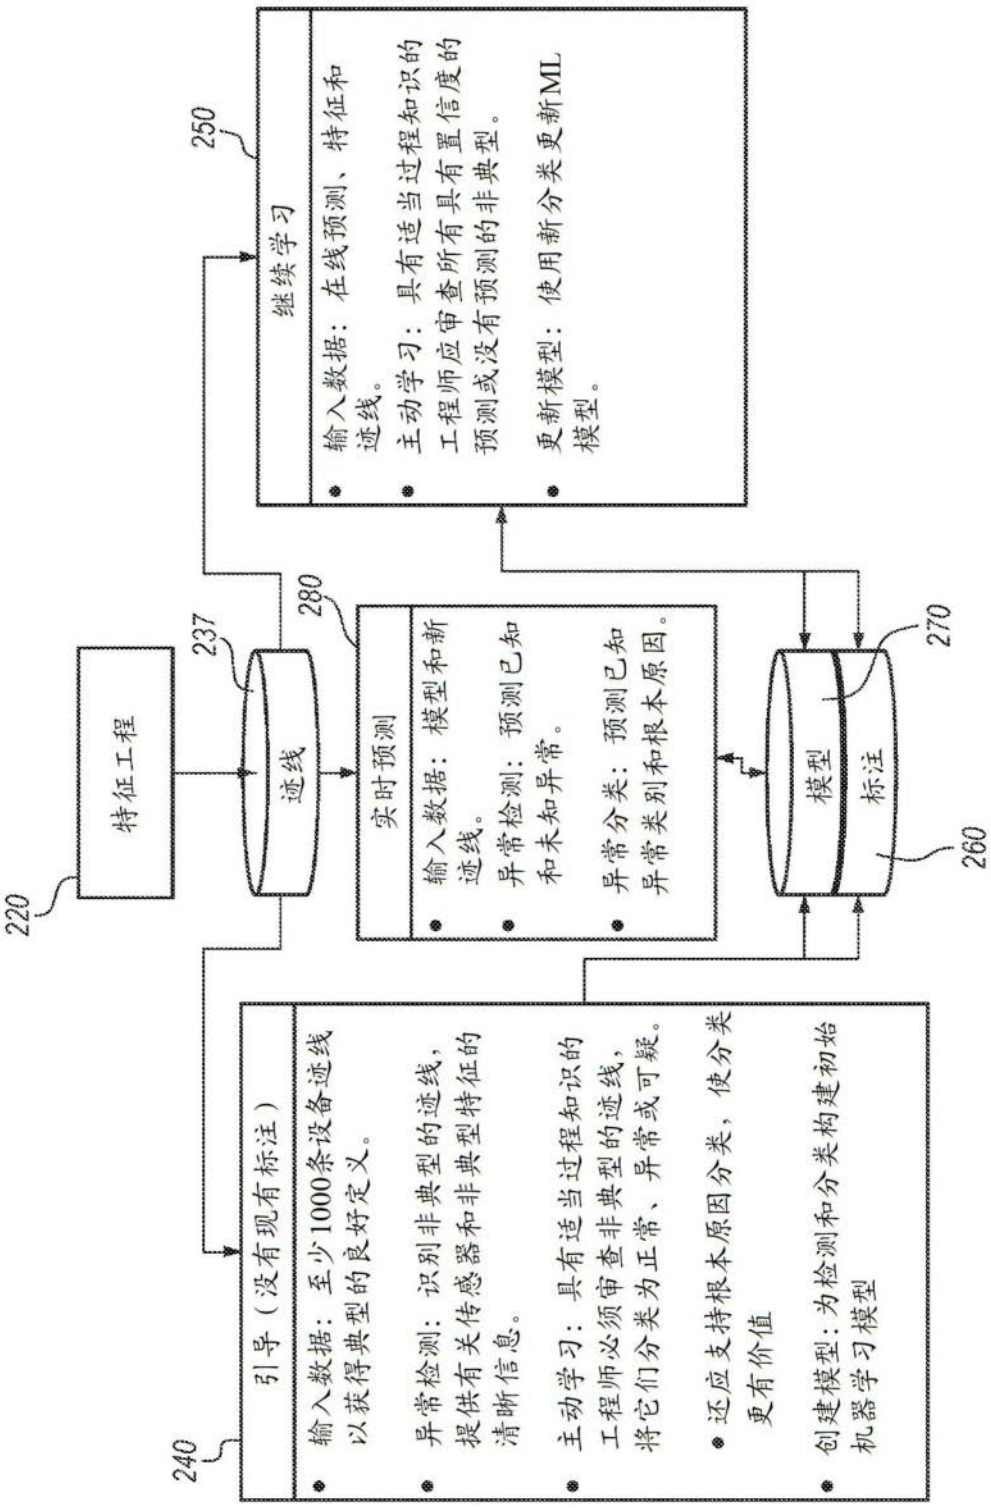

250
继续学习
输入数据：在线预测、特征和迹线。
主动学习：具有适当过程知识的工程师应审查所有具有置信度的预测或没有预测的非典型。
更新模型：使用新分类更新ML模型。
280
实时预测
输入数据：模型和新迹线。
异常检测：预测已知和未知异常。
异常分类：预测已知异常类别和根本原因。
237
迹线
特征工程
220
270
模型
标注
260
240
引导（没有现有标注）
输入数据：至少1000条设备迹线以获得典型的良好定义。
异常检测：识别非典型的迹线，提供有关传感器和非典型特征的清晰信息。
主动学习：具有适当过程知识的工程师必须审查非典型的迹线，将它们分类为正常、异常或可疑。
还应支持根本原因分类，使分类更有价值
创建模型：为检测和分类构建初始机器学习模型

图2

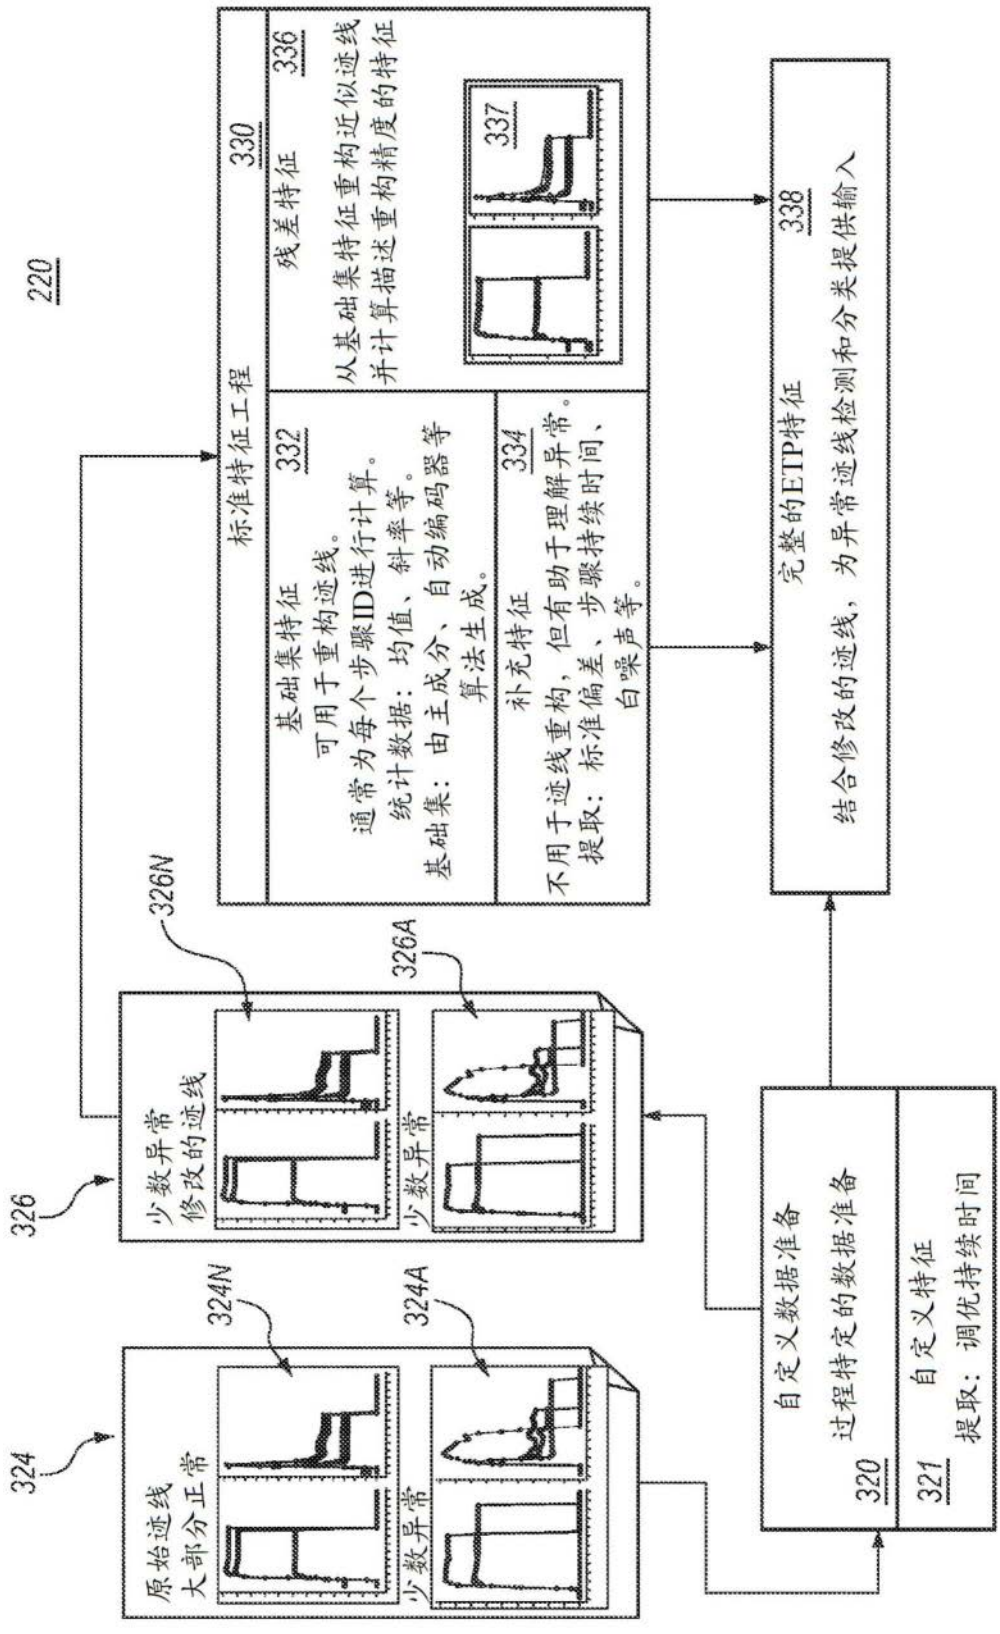

220
标准特征工程
330
基础集特征
332
可用于重构迹线。
通常为每个步骤ID进行计算。
统计数据：均值、斜率等。
基础集：由主成分、自动编码器等
算法生成。
残差特征
336
从基础集特征重构近似迹线
并计算描述重构精度的特征
337
补充特征
334
不用于迹线重构，但有助于理解异常。
提取：标准偏差、步骤持续时间、
白噪声等。
完整的ETP特征
338
结合修改的迹线，为异常迹线检测和分类提供输入
326N
326A
326
少数异常
修改的迹线
少数异常
324N
324A
324
原始迹线
大部分正常
少数异常
自定义数据准备
过程特定的数据准备
320
321
自定义特征
提取：调优持续时间

图3

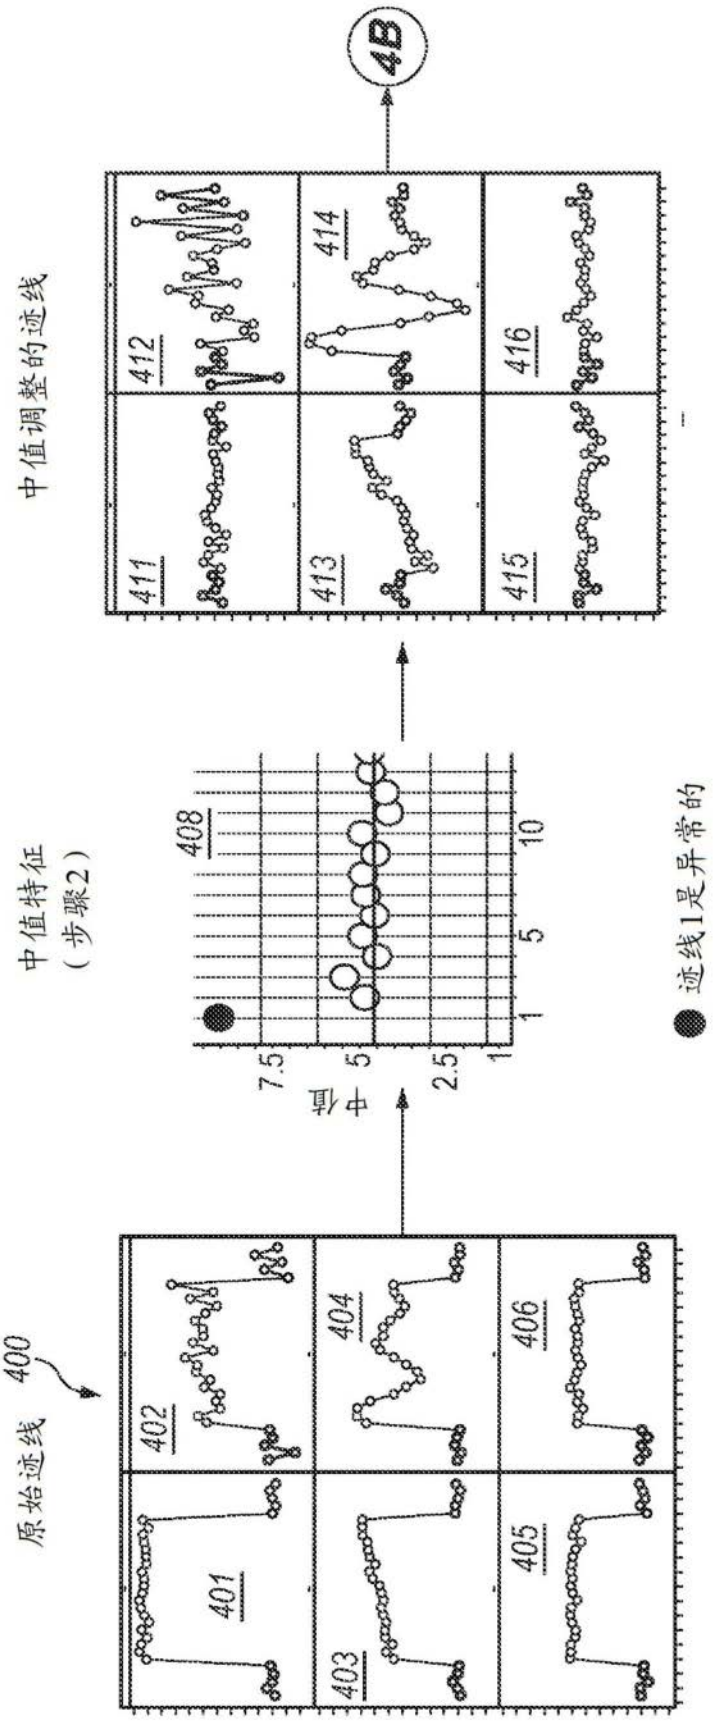

原始迹线
400
401
402
403
404
405
406
中值特征
（步骤2）
408
中值
7.5
5
2.5
1
1
5
10
迹线1是异常的
中值调整的迹线
411
412
413
414
415
416
4B

图4A

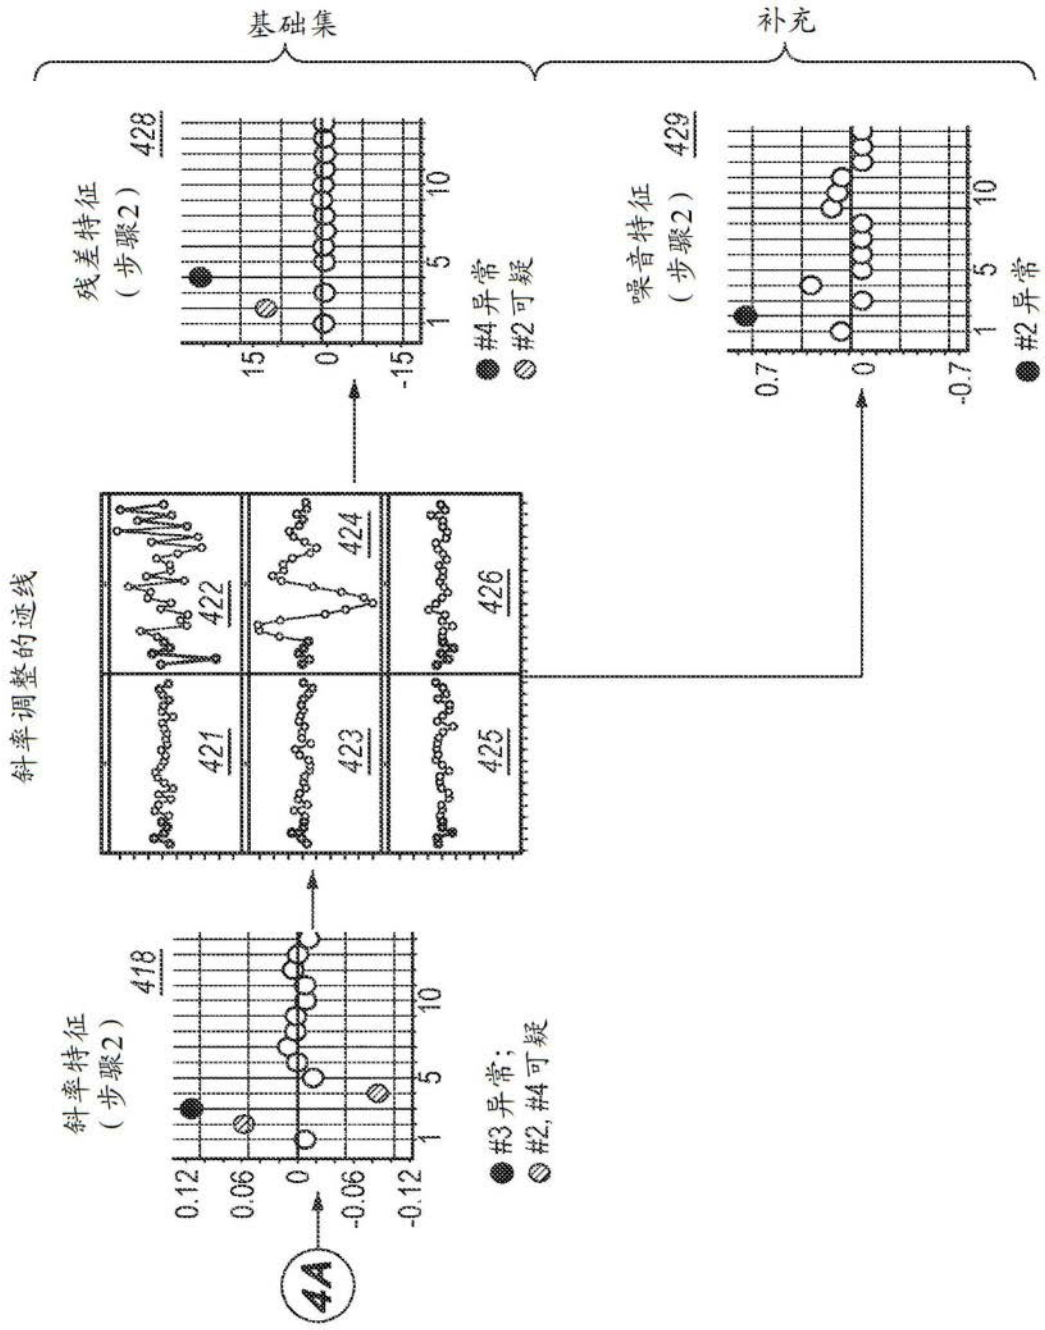

基础集
补充
残差特征
（步骤2）
428
15
0
-15
1
5
10
#4异常
#2可疑
噪音特征
（步骤2）
429
0.7
0
-0.7
#2异常
斜率调整的迹线
421
422
423
424
425
426
斜率特征
（步骤2）
418
0.12
0.06
0
-0.06
-0.12
#3异常；
#2,#4可疑
4A

图4B

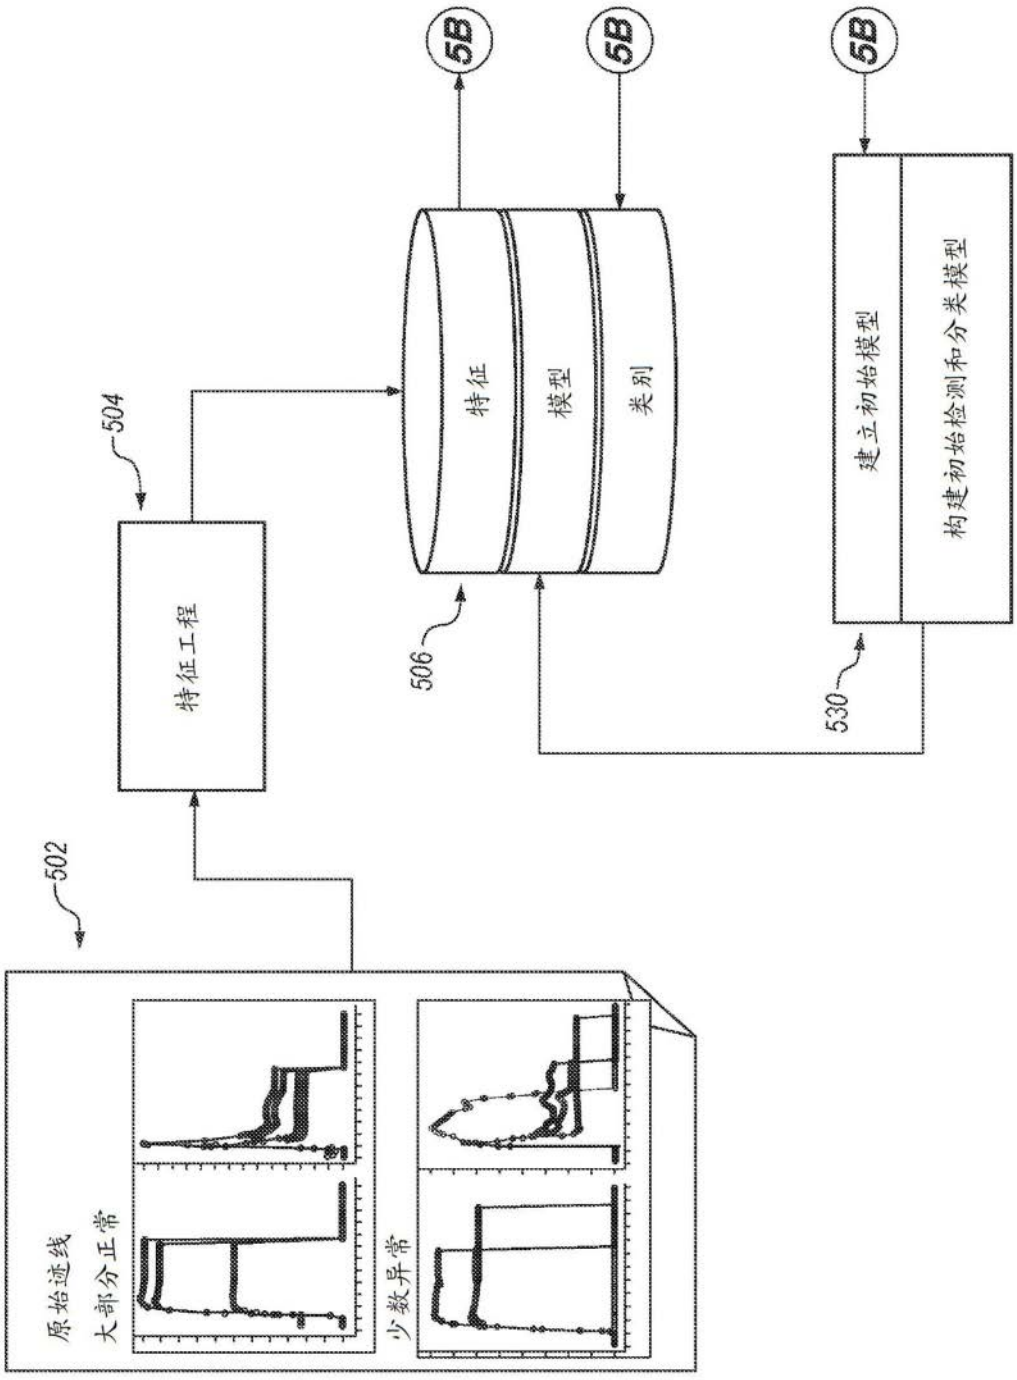

5B
5B
5B
特征
模型
类别
建立初始模型
构建初始检测和分类模型
504
特征工程
506
530
502
原始迹线
大部分正常
少数异常

图5A

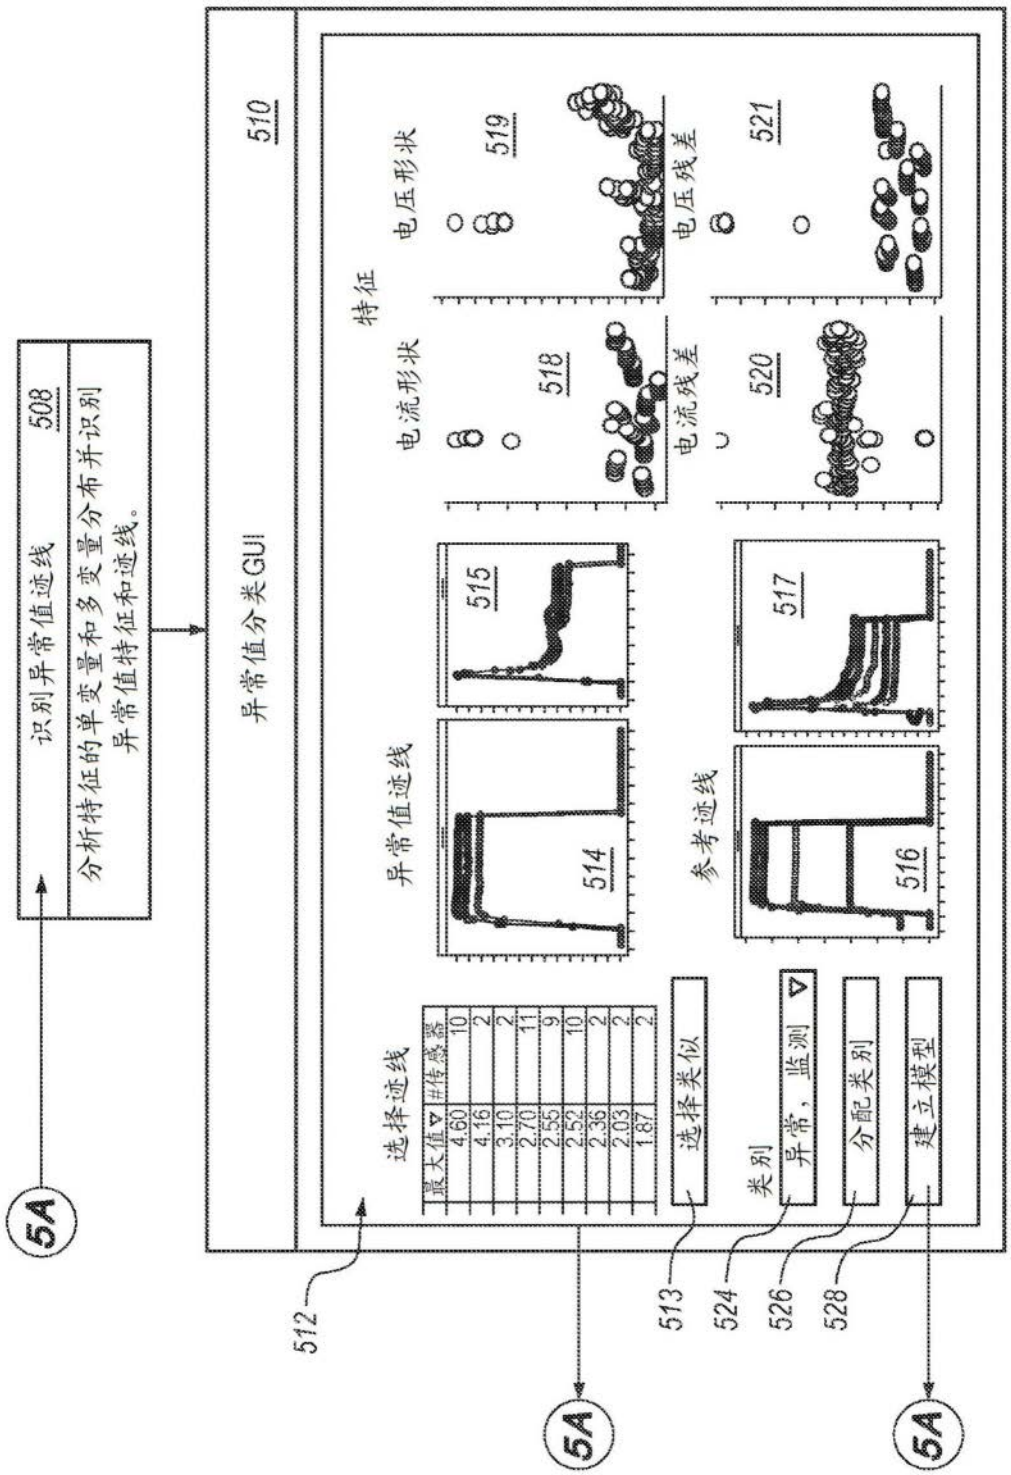

识别异常值迹线 508
分析特征的单变量和多变量分布并识别异常值特征和迹线。
5A
异常值分类GUI
510
选择迹线
原大值 #传感器
4.60 10
4.16 2
3.10 2
2.70 11
2.55 9
2.52 10
2.36 2
2.03 2
1.87 2
选择类似
类别
异常，监测
分配类别
建立模型
异常值迹线
参考迹线
特征
电流形状
电压形状
电流残差
电压残差
514
515
516
517
518
519
520
521
512
513
524
526
528
5A
5A

图5B

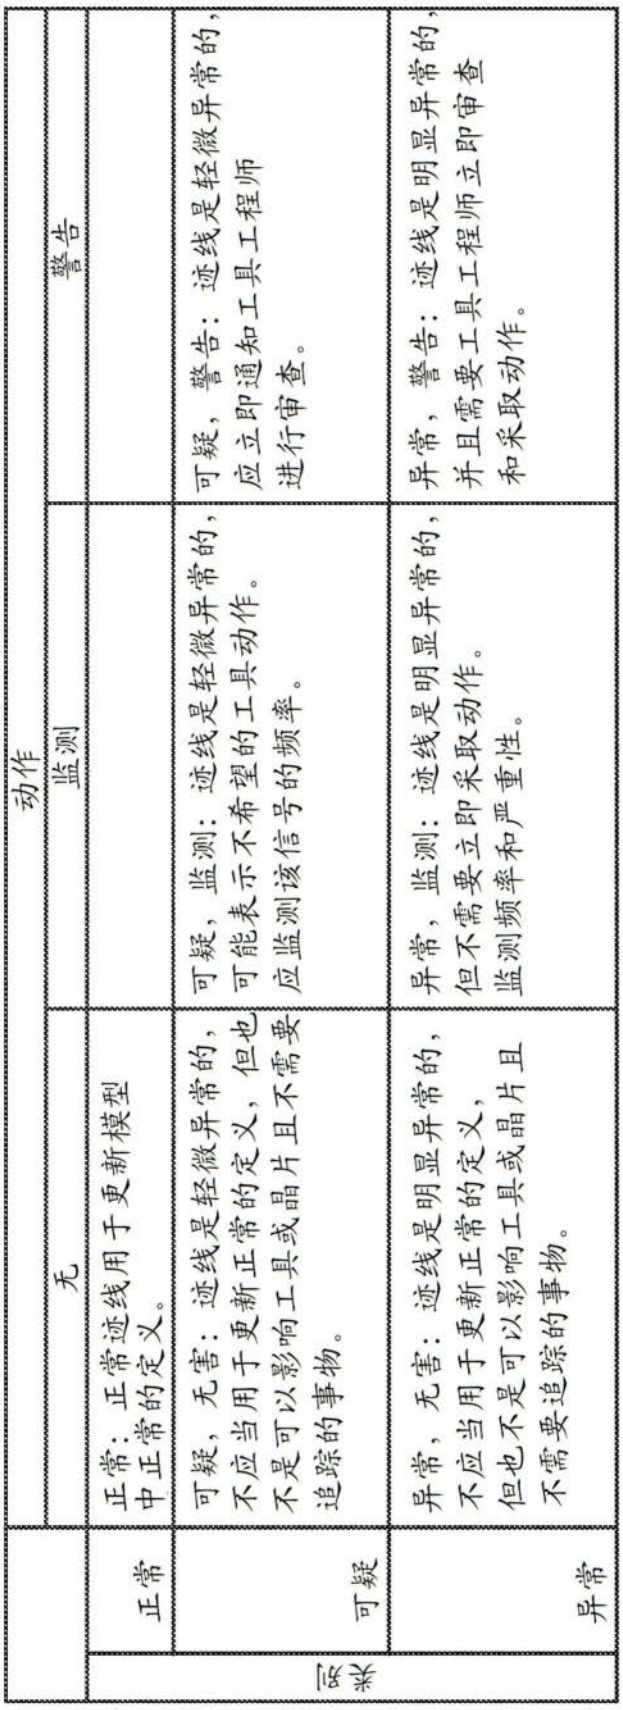

动作
无
监测
警告
证据
正常
可疑
异常
正常：正常迹线用于更新模型中正常的定义。
可疑，无害：迹线是轻微异常的，不应当用于更新正常的定义，但也不是可以影响工具或晶片且不需要追踪的事物。
异常，无害：迹线是明显异常的，不应当用于更新正常的定义，但也不是可以影响工具或晶片且不需要追踪的事物。
可疑，监测：迹线是轻微异常的，可能表示不希望的工具动作。应监测该信号的频率。
异常，监测：迹线是明显异常的，但不需要立即采取动作。监测频率和严重性。
可疑，警告：迹线是轻微异常的，应立即通知工具工程师进行审查。
异常，警告：迹线是明显异常的，并且需要工具工程师立即审查和采取动作。

图6

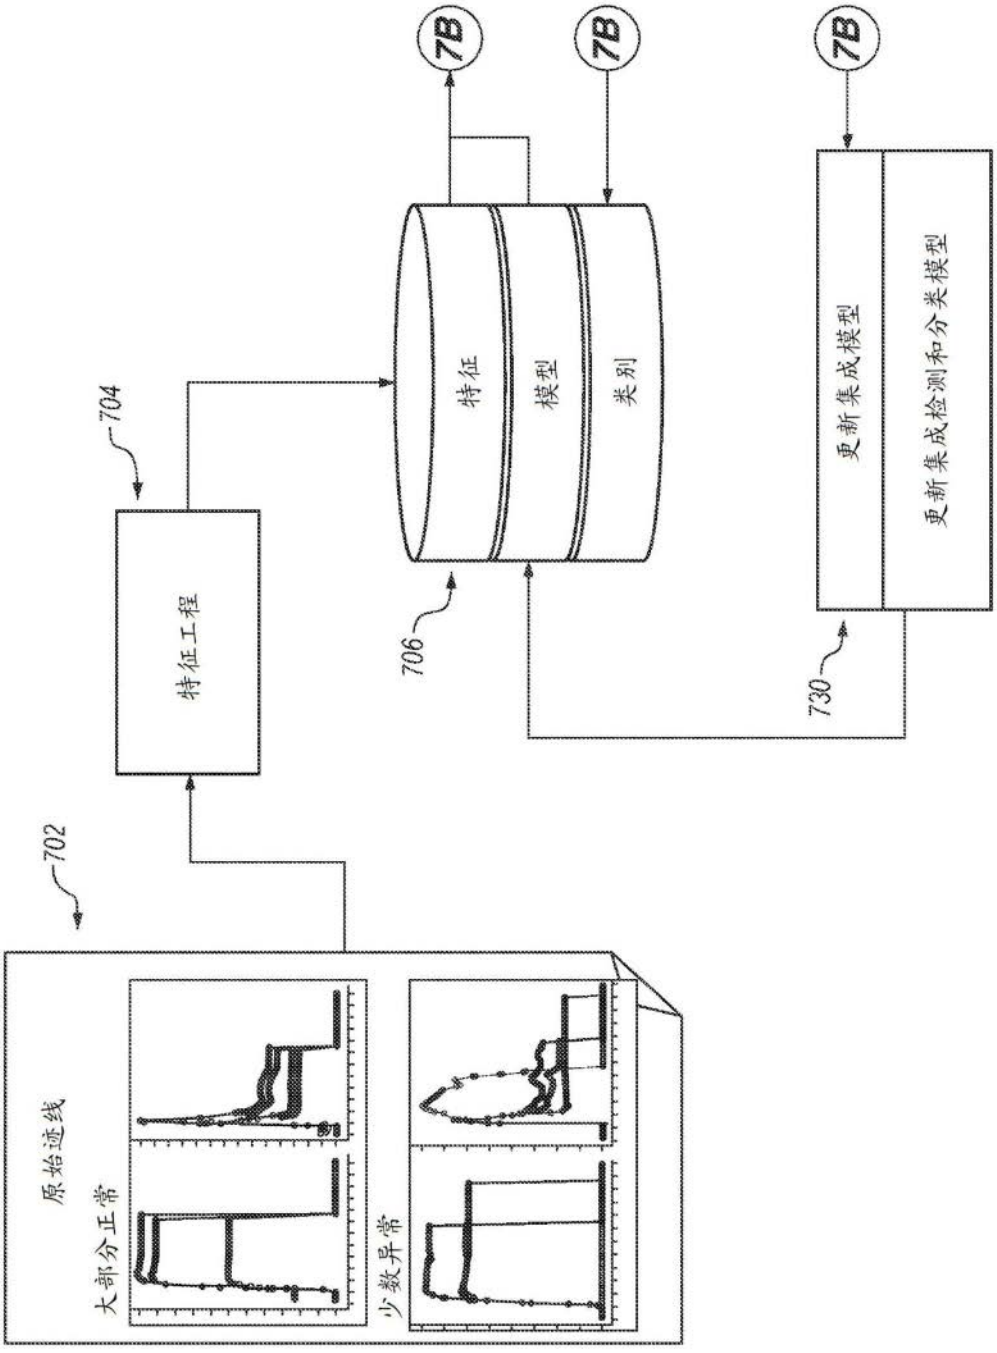

7B
7B
7B
特征
模型
类别
更新集成模型
更新集成检测和分类模型
704
特征工程
706
730
702
原始迹线
大部分正常
少数异常

图7A

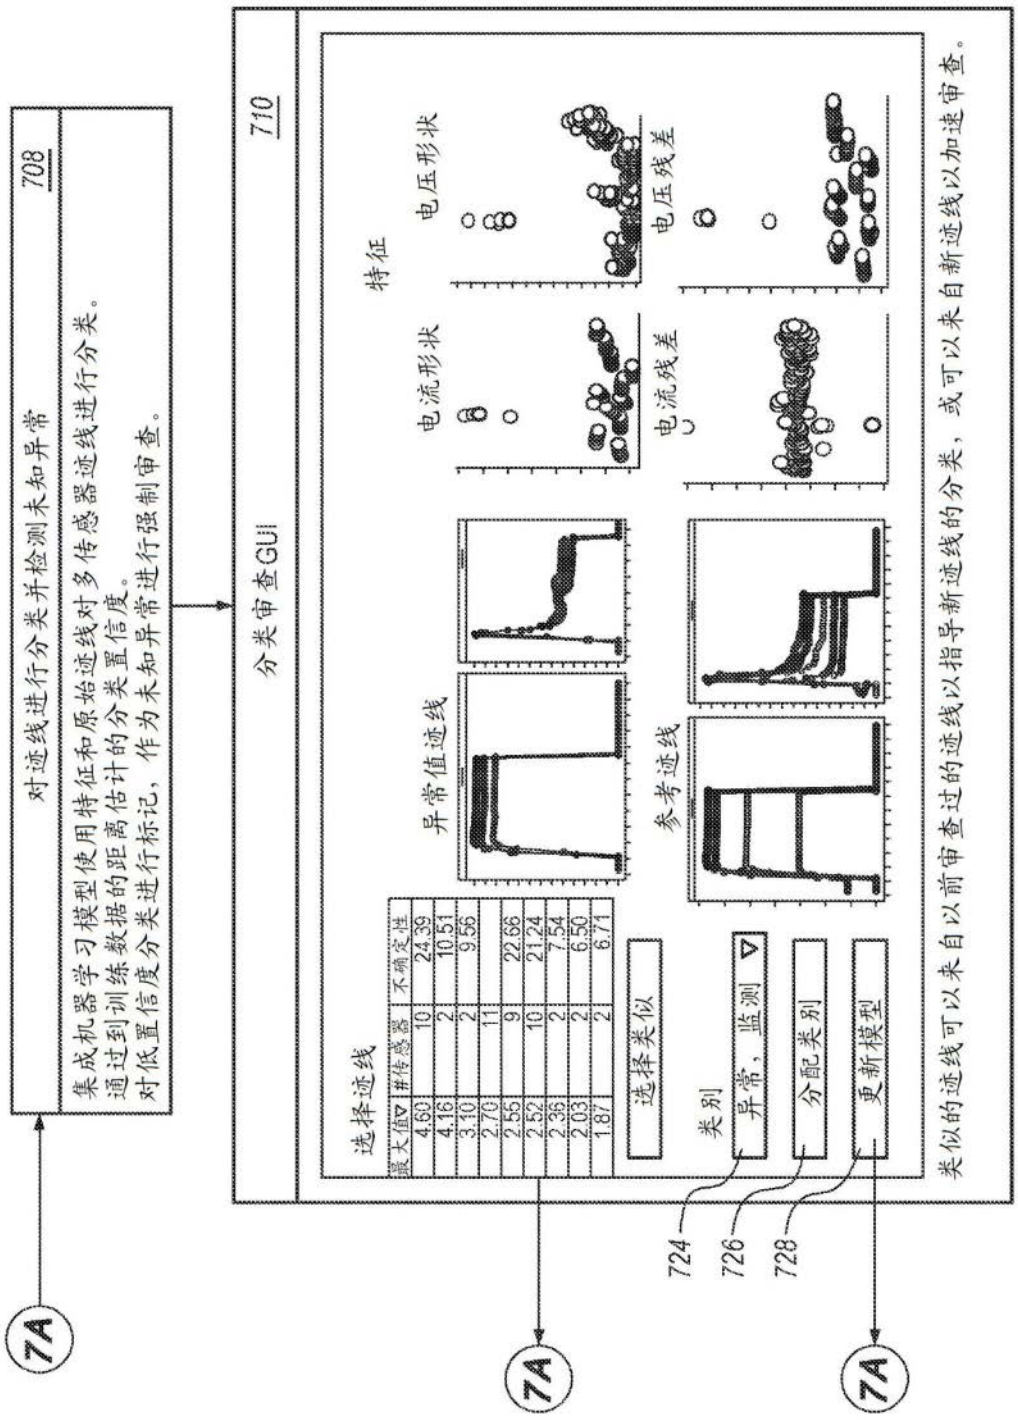

对迹线进行分类并检测未知异常
708
集成机器学习模型使用特征和原始迹线对多传感器迹线进行分类。
通过到训练数据的距离估计的分类置信度。
对低置信度分类进行标记，作为未知异常进行强制审查。
分类审查GUI
710
选择迹线
最大值
#传感器
不确定性
4.60 10 24.39
4.16 2 10.51
3.10 2 9.56
2.70 11
2.55 9 22.66
2.52 10 21.24
2.36 2 7.54
2.03 2 6.50
1.87 2 6.71
选择类似
异常值迹线
参考迹线
特征
电流形状
电压形状
电流残差
电压残差
类别
异常，监测
分配类别
更新模型
724
726
728
类似的迹线可以来自以前审查过的迹线以指导新迹线的分类，或可以来自新迹线以加速审查。
7A
7A
7A

图7B