



(12) 发明专利

(10) 授权公告号 CN 114514542 B

(45) 授权公告日 2023. 03. 21

(21) 申请号 202080052179.9
 (22) 申请日 2020.07.20
 (65) 同一申请的已公布的文献号
 申请公布号 CN 114514542 A
 (43) 申请公布日 2022.05.17
 (30) 优先权数据
 62/877,397 2019.07.23 US
 16/919,378 2020.07.02 US
 (85) PCT国际申请进入国家阶段日
 2022.01.19
 (86) PCT国际申请的申请数据
 PCT/US2020/042699 2020.07.20
 (87) PCT国际申请的公布数据
 W02021/016144 EN 2021.01.28
 (73) 专利权人 科磊股份有限公司
 地址 美国加利福尼亚州

(72) 发明人 李玮骅 魏石铭
 (74) 专利代理机构 北京律盟知识产权代理有限公司 11287
 专利代理师 刘丽楠
 (51) Int.Cl.
 G06Q 10/04 (2023.01)
 G06N 3/04 (2023.01)
 G06N 3/08 (2023.01)
 G06N 20/00 (2019.01)
 (56) 对比文件
 CN 103582819 A, 2014.02.12
 US 2019041329 A1, 2019.02.07
 US 2019004504 A1, 2019.01.03
 刘丽艳等. 基于RDC的感应同步器测角系统设计
 设计与实现.《宇航计测技术》.2013,
 审查员 郑星
 权利要求书3页 说明书10页 附图8页


(54) 发明名称

用于重叠计量学系统的自动配方优化

(57) 摘要

本发明公开一种重叠计量学系统。所述重叠计量学系统包含经配置以与重叠计量学子系统以通信方式耦合的控制器。所述控制器接收来自所述重叠计量学子系统的重叠测量并产生一或多个质量度量。所述控制器从所述一或多个质量度量提取一组主成分。所述控制器产生输入数据并将所述输入数据输入到监督式机器学习算法的输入矩阵中以训练预测模型。所述控制器接着识别具有最小残差值的配方或硬件配置。

100



1. 一种重叠计量学系统,其包括:

控制器,其经配置以与重叠计量学子系统以通信方式耦合,所述控制器包含经配置以执行程序指令的一或多个处理器,所述程序指令致使所述一或多个处理器进行以下操作:

接收来自所述重叠计量学子系统的一或多个重叠测量;

使用所述一或多个测量产生一或多个质量度量;

使用主成分分析(PCA)从所述一或多个质量度量提取一组主成分;

产生输入数据,其中所述输入数据包括所述一组主成分的子集,且所述子集中的每一主成分具有高于阈值方差的方差;

将所述输入数据输入到监督式机器学习算法的输入矩阵中以训练预测模型;以及

在所述预测模型的输出向量中识别用于所述重叠计量学子系统的配方或硬件配置中的至少一者。

2. 根据权利要求1所述的重叠计量学系统,其中用于所述重叠计量学子系统的所述配方或所述硬件配置中的所述至少一者与最小残差值相关。

3. 根据权利要求2所述的重叠计量学系统,其中包含所述一或多个处理器的所述控制器进一步经配置以执行程序指令,所述程序指令致使所述一或多个处理器提供一或多个控制指令以将所述重叠计量学子系统调整到与所述最小残差值相关的所述配方或所述硬件配置中的至少一者。

4. 根据权利要求1所述的重叠计量学系统,其中所述预测模型的所述输出向量包括多个预测模型的多个输出向量的平均值。

5. 根据权利要求1所述的重叠计量学系统,其中所述输入矩阵包括多个列及行,所述列中的每一者表示质量度量的类型,且所述行中的每一者表示用于所述重叠计量学子系统的所述配方或硬件配置。

6. 根据权利要求1所述的重叠计量学系统,其中所述输出向量包括行,且所述行中的每一者表示残差值。

7. 根据权利要求1所述的重叠计量学系统,其中所述监督式机器学习算法包括线性回归。

8. 根据权利要求1所述的重叠计量学系统,其中所述监督式机器学习算法包括决策树(DT)。

9. 根据权利要求1所述的重叠计量学系统,其中所述监督式机器学习算法包括支持向量机回归(SVM-R)。

10. 根据权利要求1所述的重叠计量学系统,其中所述监督式机器学习算法包括高斯过程(GP)。

11. 根据权利要求1所述的重叠计量学系统,其中所述监督式机器学习算法包括神经网络(NN)。

12. 一种重叠计量学系统,其包括:

重叠计量学子系统;以及

控制器,其经配置以与所述重叠计量学子系统以通信方式耦合,所述控制器包含经配置以执行程序指令的或多个处理器,所述程序指令致使所述一或多个处理器进行以下操作:

接收来自所述重叠计量学子系统的一或多个重叠测量；
使用所述一或多个测量产生一或多个质量度量；
使用主成分分析 (PCA) 从所述一或多个质量度量提取一组主成分；
产生输入数据,其中所述输入数据包括所述一组主成分的子集,且所述子集中的每一主成分具有高于阈值方差的方差；
将所述输入数据输入到监督式机器学习算法的输入矩阵中以训练预测模型;以及
在所述预测模型的输出向量中识别用于所述重叠计量学子系统的配方或硬件配置中的至少一者。

13. 根据权利要求12所述的重叠计量学系统,其中用于所述重叠计量学子系统的所述配方或所述硬件配置中的所述至少一者与最小残差值相关。

14. 根据权利要求13所述的重叠计量学系统,其中包含所述一或多个处理器的所述控制器进一步经配置以执行程序指令,所述程序指令致使所述一或多个处理器提供一或多个控制指令以将所述重叠计量学子系统调整到与所述最小残差值相关的所述配方或所述硬件配置中的至少一者。

15. 根据权利要求12所述的重叠计量学系统,其中所述重叠计量学子系统包括基于成像的重叠计量学子系统或基于散射测量的重叠计量学子系统。

16. 一种训练预测模型的方法,其包括:
接收来自重叠计量学子系统的一或多个重叠测量;
使用所述一或多个测量产生一或多个质量度量;
使用主成分分析 (PCA) 从所述一或多个质量度量提取一组主成分;
产生输入数据,其中所述输入数据包括所述一组主成分的子集,且所述子集中的每一主成分具有高于阈值方差的方差;
将所述输入数据输入到监督式机器学习算法的输入矩阵中以训练所述预测模型;以及
在所述预测模型的输出向量中识别用于所述重叠计量学子系统的配方或硬件配置中的至少一者。

17. 根据权利要求16所述的方法,其中用于所述重叠计量学子系统的所述配方或所述硬件配置中的所述至少一者与最小残差值相关。

18. 根据权利要求17所述的方法,其进一步包括提供一或多个控制指令以将所述重叠计量学子系统调整到与所述最小残差值相关的所述配方或所述硬件配置中的至少一者。

19. 根据权利要求16所述的方法,其中所述重叠计量学子系统包括基于成像的重叠计量学子系统或基于散射测量的重叠计量学子系统。

20. 根据权利要求16所述的方法,其中所述预测模型的所述输出向量包括多个预测模型的多个输出向量的平均值。

21. 根据权利要求16所述的方法,其中所述输入矩阵包括多个列及行,所述列中的每一者表示质量度量的类型,且所述行中的每一者表示用于所述重叠计量学子系统的所述配方或硬件配置。

22. 根据权利要求16所述的方法,其中所述输出向量包括行,且所述行中的每一者表示残差值。

23. 根据权利要求16所述的方法,其中所述监督式机器学习算法包括线性回归。

-
24. 根据权利要求16所述的方法,其中所述监督式机器学习算法包括决策树(DT)。
 25. 根据权利要求16所述的方法,其中所述监督式机器学习算法包括支持向量机回归(SVM-R)。
 26. 根据权利要求16所述的方法,其中所述监督式机器学习算法包括高斯过程(GP)。
 27. 根据权利要求16所述的方法,其中所述监督式机器学习算法包括神经网络(NN)。

用于重叠计量学系统的自动配方优化

[0001] 相关申请案的交叉参考

[0002] 本申请案根据35 U.S.C.§119 (e) 要求2019年7月23日申请的第62/877,397号美国临时申请案的权益,所述美国临时申请案名为“运用机器学习方法进行Archer自动配方优化(ARCHER AUTOMATIC RECIPE OPTIMIZATION WITH MACHINE LEARNING APPROACH)”,发明人姓名为Weihua Li及Shiming Wei,所述美国临时申请案以全文引用的方式并入本文中。

技术领域

[0003] 本公开大体上涉及半导体晶圆及遮罩计量学。明确地说,本公开涉及优化用于重叠计量学系统的配方或硬件配置以收集准确且精确的计量学数据。

背景技术

[0004] 重叠计量学系统经设计以提供对产品上重叠误差的准确回馈,以用于在前边缘设计节点处进行线内监测及晶圆安置。常规重叠计量学系统的实例包含KLA-Tencor Archer™系列计量学系统。对于基于增强型成像的测量应用及基于散射测量的测量应用两者,先前系统经设计以在大量制造中存在工艺变化的情况下提供稳固的重叠测量及控制。最近新增的具有1nm分辨率的可调谐激光技术进一步改进了用于存储器及逻辑层两者的成像/散射测量重叠目标与装置重叠误差之间的重叠准确度及相关性。

[0005] 用于在基于成像的重叠计量学系统(例如KLA-Tencor Archer™系列重叠计量学系统)中选择最佳测量波长的常规自动配方优化(ARO)方案包含蛮力(BF)方案及全不良度量(MOAB)方案。

[0006] 由于残差为最常用的准确度指标(例如经测量重叠与实际重叠之间的差),故BF-ARO方案需要操作具有各种配方(例如硬件配置)的重叠计量学子系统及收集用于每一配方的残差值。每一配方包含波长、偏振、带宽及数值孔径(NA)的特定组合。重叠计量学系统测量样本上的数十个或数百个位点,且基于高阶晶圆及高阶场模型的残差(例如W3F3残差)对配方进行顺位。虽然BF-ARO方案简单且直接了当,但测量大数目个取样配方是耗时的。因此,并非所有可能的组合皆可涵盖于BF-ARO方案中。换句话说,得到最小残差的配方可能不在最终顺位中。

[0007] MOAB-ARO方案最少仅需要五个取样位点,因此显著地缩短了评估时间。包含核心 3σ (K3S)、周期比(PR)及对比精确度(CP)的三个重要度量经组合以提供单个决策表面,即MOAB决策表面。基于MOAB决策表面,可筛选出不适合于测量的配方。然而,MOAB决策表面的值并不与残差强烈地相关。因此,MOAB-ARO方案中所推荐的配方未必为具有最小残差的配方。

[0008] 对于基于散射测量的重叠计量学子系统,除了共振模型化(RM)ARO方案之外,BF-ARO方案也适用。在RM-ARO方案中,在共振机制中计算重叠值,其中重叠准确度随着波长显著地变化。RM-ARO需要较少取样位点且因此花费较少测量时间。然而,RM-ARO需要存在高质量共振机制,其可能在一些样本层上是不可用的。此外,在基于成像的计量学子系统及基于

散射测量的计量学子系统两者中的多波长方法朝向重叠测量的最近发展的情况下,可能的配方随着波长的数目增加而按指数律成比例增加,此超出了上文所提及的ARO方案的能力。

[0009] 为了解决归因于大数目个取样位点的长评估时间的挑战且为了直接建立输出质量度量与残差之间的桥接,需要替代性ARO解决方案。

发明内容

[0010] 根据本公开的一或多个说明性实施例公开一种重叠计量学系统。在一个说明性实施例中,所述重叠计量学系统包括经配置以与重叠计量学子系统以通信方式耦合的控制器。在另一说明性实施例中,所述控制器包含经配置以执行程序指令的一或多个处理器,所述程序指令致使所述一或多个处理器进行以下操作:接收来自所述重叠计量学子系统的一或多个重叠测量;使用所述一或多个测量产生一或多个质量度量;使用主成分分析(PCA)从所述一或多个质量度量提取一组主成分;产生输入数据,其中所述输入数据包括所述一组主成分的子集,且所述子集中的每一主成分具有高于阈值方差的方差;将所述输入数据输入到监督式机器学习算法的输入矩阵中以训练预测模型;在所述预测模型的输出向量中识别用于所述重叠计量学子系统的配方或硬件配置。

[0011] 根据本公开的一或多个说明性实施例公开一种重叠计量学系统。在一个说明性实施例中,所述重叠计量学系统包括重叠计量学子系统。在另一说明性实施例中,所述重叠计量学系统包含经配置以与所述重叠计量学子系统以通信方式耦合的控制器。在另一说明性实施例中,所述控制器包含经配置以执行程序指令的一或多个处理器,所述程序指令致使所述一或多个处理器进行以下操作:接收来自所述重叠计量学子系统的一或多个重叠测量;使用所述一或多个测量产生一或多个质量度量;使用主成分分析(PCA)从所述一或多个质量度量提取一组主成分;产生输入数据,其中所述输入数据包括所述一组主成分的子集,且所述子集中的每一主成分具有高于阈值方差的方差;将所述输入数据输入到监督式机器学习算法的输入矩阵中以训练预测模型;在所述预测模型的输出向量中识别具有最小残差值的配方或硬件配置;以及提供一或多个控制指令以将所述重叠计量学子系统调整到具有所述最小残差值的所述配方或硬件配置。

[0012] 根据本公开的一或多个说明性实施例公开一种训练预测模型的方法。在一个说明性实施例中,所述方法包括接收来自重叠计量学子系统的一或多个重叠测量。在另一说明性实施例中,所述方法包括使用所述一或多个测量产生一或多个质量度量。在另一说明性实施例中,所述方法包括使用主成分分析(PCA)从所述一或多个质量度量提取一组主成分。在另一说明性实施例中,所述方法包括产生输入数据,其中所述输入数据包括所述一组主成分的子集,且所述子集中的每一主成分具有高于阈值方差的方差。在另一说明性实施例中,所述方法包括将所述输入数据输入到监督式机器学习算法的输入矩阵中以训练所述预测模型。在另一说明性实施例中,所述方法包括在所述预测模型的输出向量中识别用于所述重叠计量学子系统的配方或硬件配置。

[0013] 应理解,前述一般描述及以下详细描述两者仅为示范性及阐释性的,且未必限制所主张的本发明。并入于本说明书中且构成本说明书的一部分的随附图式说明本发明的实施例,且与一般描述一起用以阐释本发明的原理。

附图说明

[0014] 所属领域的技术人员可通过参考附图优选地理解本公开的众多优势,附图中:

[0015] 图1A为根据本公开的一或多个实施例的重叠计量学系统的简化示意图。

[0016] 图1B为根据本公开的一或多个实施例的重叠计量学子系统的简化示意图。

[0017] 图1C为根据本公开的一或多个实施例的重叠计量学子系统的示意图。

[0018] 图2为根据本公开的一或多个实施例的基于机器学习的自动配方优化 (ARO) 的简化流程图。

[0019] 图3A到3B展示根据本公开的一或多个实施例说明用于评估机器学习算法的性能的交叉验证方法的流程图。

[0020] 图4为根据本公开的一或多个实施例呈现应用各种机器学习算法以预测配方的结果的表。

[0021] 图5为根据本公开的一或多个实施例说明训练预测模型并基于预测模型调整重叠计量学子系统的方法的流程图。

具体实施方式

[0022] 应理解,前述一般描述及以下详细描述两者仅为示范性及阐释性的,且未必限制所主张的本发明。并入于本说明书中且构成本说明书的一部分的随附图式说明本发明的实施例,且与一般描述一起用以阐释本发明的原理。现在将详细地参考所公开的主题,其说明于随附图式中。

[0023] 本公开涉及一种使用具有用于重叠测量的可调谐波长的光学照明的重叠计量学系统。在连续地选择可能的波长以进行重叠测量的情况下,可使用算法以选择最佳波长(例如最佳配方或硬件配置)以进行准确且稳固的测量。明确地说,本公开涉及一种快速且准确地识别用于重叠计量学子系统的最佳配方的机器学习算法。

[0024] 配方可包含用以产生重叠信号的一组测量参数。举例来说,重叠计量学系统的配方可包含但不限于照明波长、从样本发出的辐射的经检测波长、样本上的照明的光点大小、入射照明的角度、入射照明的偏振、入射照明光束在重叠目标上的位置、重叠目标在重叠计量学工具的聚焦体积中的位置,或其类似者。因此,重叠配方可包含用于产生适合于确定两个或更多个样本层的重叠的重叠信号的一组测量参数。

[0025] 重叠测量的准确度及/或可重复性可取决于重叠配方,以及与重叠目标的特定几何形状相关联的广泛范围的因数,例如但不限于样本层的厚度、重叠目标特征的大小、重叠目标特征的密度或间距,或样本层的组成。另外,重叠目标的特定几何形状可以可预测方式及不可预测方式两者遍及样本而变化。举例来说,经制造层的厚度可以已知分布遍及样本而变化(例如样本的中心的厚度可被预期为稍微大于沿着边缘的厚度),或可根据与缺陷相关联的随机波动或根据处理步骤的随机变化而变化。因此,特定重叠配方可能不会在应用于样本的所有重叠目标时提供相同准确度及/或可重复性,即使工艺变化是在经选择制造公差内也如此。

[0026] 使用给定算法的重叠测量通常是在如下假定下执行:重叠目标包含在由完全均一材料形成的完全均一样本层上显现的完全对称特征。然而,与重叠目标的制造相关联的工艺变化可能会引入经制造重叠目标与经设计特性的偏差(例如侧壁不对称性或其类似者)。

举例来说,工艺变化可包含膜层的沉积的变化、膜层上的图案曝露的变化、蚀刻膜层上的经曝露图案时的变化,及其类似者。就此来说,经制造重叠目标与经设计特性的偏差对经测量信号的任何影响可不恰当地归因于重叠误差,且可因此表现为重叠测量的不准确度。

[0027] 另外,情况可为,对于给定重叠目标及给定重叠算法,不同计量学配方(例如重叠计量学子系统的不同硬件配置)可展现对工艺误差的不同敏感度。换句话说,也许有可能识别特定测量配方(例如由重叠计量学子系统使用以特性化重叠目标的波长、偏振或其类似者的特定值),所述特定测量配方对于与特定重叠目标的制造相关联的工艺变化是相对稳固的。就此来说,可实现稳固且准确的重叠测量。

[0028] 出于本公开的目的,与重叠计量学子系统相关联的重叠信号可被认为是重叠计量学子系统的输出,其具有足够的信息以确定包含两个或更多个样本层上的重叠目标特征的相对位置的重叠(例如经由使用一或多个处理器的分析或其类似者)。举例来说,重叠信号可包含但并非需要包含一或多个数据集、一或多个图像、一或多个检测器读数或其类似者。

[0029] 如贯穿本公开所使用,术语“样本”通常是指由半导体或非半导体材料形成的衬底(例如晶圆或其类似者)。举例来说,半导体或非半导体材料可包含但不限于单晶硅、砷化镓及磷化铟。样本可包含一或多个层。举例来说,此类层可包含但不限于抗蚀剂、介电材料、导电材料及半导电材料。许多不同类型的此类层在此项技术中是已知的,且如本文所使用的术语样本意欲涵盖可被形成有所有类型的此类层的样本。形成于样本上的一或多个层可被图案化或未被图案化。举例来说,样本可包含多个裸片,其各自具有可重复的经图案化特征。此类材料层的形成及处理可能最终产生完成的装置。许多不同类型的装置可形成于样本上,且如本文所使用的术语样本意欲涵盖正被制造有此项技术中已知的任何类型的装置的样本。另外,出于本公开的目的,术语样本及晶圆应被解译为可互换。另外,出于本公开的目的,术语图案化装置、遮罩及光罩应被解译为可互换。

[0030] 图1A为说明根据本公开的一或多个实施例的重叠计量学系统100的概念图。

[0031] 在一个实施例中,重叠计量学系统100包含经配置以基于任何数目个重叠配方从重叠目标获取重叠信号的重叠计量学子系统102。举例来说,重叠计量学子系统102可将照明引导到样本104,且可进一步收集从样本104发出的辐射以产生适合于确定两个或更多个样本层的重叠的重叠信号。重叠计量学子系统102可为此项技术中已知的适合于产生适合于确定与样本104上的重叠目标相关联的重叠的重叠信号的任何类型的重叠计量学工具或装置。重叠计量学子系统102可在成像模式或非成像模式下操作。举例来说,在成像模式下,个别重叠目标元件可在样本上的经照明光点内是可解析的(例如作为亮场图像、暗场图像、相差图像或其类似者的部分)。作为另一实例,重叠计量学子系统102可作为基于散射测量的重叠计量学工具而操作,其中在光瞳平面处分析来自样本的辐射以特性化来自样本104的辐射的角分布(例如与由样本104对辐射的散射及/或衍射相关联)。

[0032] 另外,重叠子系统102可经配置以基于任何数目个配方产生重叠信号,所述配方定义用于获取适合于确定重叠目标的重叠的重叠信号的测量参数。举例来说,重叠计量学工具的配方可包含但不限于照明波长、从样本发出的辐射的经检测波长、样本上的照明的光点大小、入射照明的角度、入射照明的偏振、入射照明光束在重叠目标上的位置、重叠目标在重叠计量学子系统102的聚焦体积中的位置,或其类似者。

[0033] 在另一实施例中,重叠计量学系统100包含经配置以与重叠计量学子系统102以通

信方式耦合的控制器106。控制器106可经配置以指导重叠计量学子系统102基于一或多个经选择配方产生重叠信号。控制器106可进一步经配置以接收包含但不限于来自重叠计量学子系统102的重叠信号的数据。另外,控制器106可经配置以基于经获取重叠信号确定与重叠目标相关联的重叠。控制器106可为例如工作站、终端机、个人计算机、膝上型计算机、平板计算机、移动装置等等。

[0034] 在另一实施例中,控制器106包含一或多个处理器108。一或多个处理器108可经配置以执行维护于存储器装置110或存储器中的一组程序指令。控制器106的一或多个处理器108可包含此项技术中已知的任何处理元件。在此意义上,一或多个处理器108可包含经配置以执行算法及/或指令的任何微处理器型装置(例如中央处理单元[CPU]及/或图形处理单元[GPU])。另外,存储器装置110可包含此项技术中已知的适合于存储可由相关联的一或多个处理器108执行的程序指令的任何存储媒体。举例来说,存储器装置110可包含非暂时性存储器媒体。作为一额外实例,存储器装置110可包含但不限于只读存储器、随机存取存储器、磁性或光学存储器装置、硬盘机(HDD)、磁带、快闪存储器、固态磁盘机(SSD)及其类似者。应进一步注意,存储器装置110可容纳于具有一或多个处理器108的共同控制器壳体中。

[0035] 图1B为说明根据本公开的一或多个实施例的重叠计量学子系统102的概念图。在一个实施例中,重叠计量学子系统102包含经配置以产生照明光束114的照明源112。照明光束114可包含光的一或多个经选择波长,包含但不限于紫外线(UV)辐射、可见光辐射或红外线(IR)辐射。

[0036] 照明源112可包含适合于提供照明光束114的任何类型的照明源。在一个实施例中,照明源112为激光源。举例来说,照明源112可包含但不限于一或多个窄频激光源、宽频激光源、超连续谱激光源、白光激光源或其类似者。就此来说,照明源112可提供具有高相干性(例如高空间相干性及/或时间相干性)的照明光束114。在另一实施例中,照明源112包含激光持续等离子体(LSP)源。举例来说,照明源112可包含但不限于LSP灯、LSP灯泡或适合于装纳一或多个元件的LSP腔室,所述一或多个元件在由激光源激发成等离子体状态时可发射宽频照明。在另一实施例中,照明源112可包含灯源。举例来说,照明源112可包含但不限于弧光灯、放电灯、无电极灯或其类似者。就此来说,照明源112可提供具有低相干性(例如低空间相干性及/或时间相干性)的照明光束114。在另一实施例中,照明源112可包含同步加速器源。

[0037] 在另一实施例中,重叠计量学系统100包含波长选择装置116以控制用于照明样本104的照明光束114的光谱。举例来说,波长选择装置116可包含适合于提供具有经选择光谱(例如中心波长、带宽、谱轮廓或其类似者)的照明光束114的可调谐滤光片。作为另一实例,波长选择装置116可调整可调谐照明源112的一或多个控制设定以直接控制照明光束114的光谱。另外,控制器106可以通信方式耦合到照明源112及/或波长选择装置116以调整照明光束114的光谱的一或多个方面。

[0038] 在另一实施例中,重叠计量学子系统102经由照明路径118将照明光束114引导到样本104。照明路径118可包含适合于修改及/或调节照明光束114以及将照明光束114引导到样本104的一或多个光学组件。举例来说,照明路径118可包含但并非需要包含一或多个透镜120(例如用以准直照明光束114、转送光瞳及/或场平面,或其类似者)、用以调整照明光束114的偏振的一或多个偏振器122、一或多个滤光片、一或多个光束分光器、一或多个漫

射器、一或多个均质机、一或多个切趾器、一或多个光束塑形器,或一或多个镜面(例如静态镜面、可平移镜面、扫描镜面或其类似者)。在另一实施例中,重叠计量学子系统102包含用以将照明光束114聚集到样本104(例如,重叠目标元件位于样本104的两个或更多个层上的重叠目标)上的物镜124。在另一实施例中,样本104安置于适合于紧固样本104的样本载物台126上,且进一步经配置以相对于照明光束114定位样本104。

[0039] 在另一实施例中,重叠计量学子系统102包含一或多个检测器128,一或多个检测器128经配置以经由收集路径132捕捉从样本104(例如样本104上的重叠目标)发出的辐射(例如样本辐射130),并产生指示样本104的两个或更多个层的重叠的一或多个重叠信号。收集路径132可包含用以引导及/或修改由物镜124收集的照明的多个光学元件,所述光学元件包含但不限于一或多个透镜134、一或多个滤光片、一或多个偏振器、一或多个光束块或一或多个光束分光器。举例来说,检测器128可接收由收集路径132中的元件(例如物镜124、一或多个透镜134或其类似者)提供的样本104的图像。作为另一实例,检测器128可接收从样本104反射或散射(例如经由镜面反射、漫反射及其类似者)的辐射。作为另一实例,检测器128可接收由样本产生的辐射(例如与照明光束114的吸收相关联的发光,及其类似者)。作为另一实例,检测器128可接收来自样本104的一或多个衍射阶的辐射(例如0阶衍射、 ± 1 阶衍射、 ± 2 阶衍射及其类似者)。

[0040] 重叠计量学子系统102的照明路径118及收集路径132可以适合于运用照明光束114照明样本104并响应于入射照明光束114而收集从样本104发出的辐射的广泛范围的配置进行定向。举例来说,如图1B中所说明,重叠计量学子系统102可包含经定向使得物镜124可同时将照明光束114引导到样本104并收集从样本104发出的辐射的光束分光器136。作为另一实例,照明路径118及收集路径132可含有非重叠的光学路径。

[0041] 图1C为说明根据本公开的一或多个实施例的重叠计量学子系统102的概念图。在一个实施例中,照明路径118及收集路径132含有单独的元件。举例来说,照明路径118可利用第一聚焦元件138以将照明光束114聚焦到样本104上,且收集路径132可利用第二聚焦元件140以从样本104收集辐射。就此来说,第一聚焦元件138及第二聚焦元件140的数值孔径可不同。在另一实施例中,一或多个光学组件可安装到可旋转臂(未展示),所述可旋转臂围绕样本104枢转,使得照明光束114在样本104上的入射角可由所述可旋转臂的位置控制。

[0042] 如本文中先前所描述,重叠计量学子系统102可经配置以使用任何数目个重叠配方(例如多组测量参数)产生与样本104上的重叠目标相关联的重叠信号。另外,重叠计量学子系统102可提供测量参数的快速调谐,使得可快速地获取基于不同配方的多个重叠信号。举例来说,重叠计量学系统100的控制器106可与重叠计量学子系统102的一或多个可调整组件以通信方式耦合以根据重叠配方配置可调整组件。

[0043] 重叠配方可包含入射于样本上的照明光束114的光谱的一或多个方面,例如但不限于作为测量参数的照明光束114的波长(例如中心波长)、带宽及谱轮廓。举例来说,控制器106可以通信方式耦合到照明源112及/或波长选择装置116以根据重叠配方调整照明光束114的光谱。

[0044] 在一个实施例中,波长选择装置116包含一或多个位置可调谐光谱滤光片,其中可通过修改入射照明光束114在所述滤光片上的位置来快速地调谐照明光束114的光谱特性(例如中心波长、带宽、光谱透射率值或其类似者)。另外,位置可调谐光谱滤光片可包含任

何类型的光谱滤光片,例如但不限于低通滤光片、高通滤光片、带通滤光片或带阻滤光片。

[0045] 举例来说,位置可调谐光谱滤光片可包含作为具有位置可调谐截止波长的流线式滤光片而操作的一或多个薄膜。就此来说,可通过修改照明光束114在滤光片上的位置来调谐截止波长。举例来说,低通流线式滤光片可使低于截止波长的波长通过(例如经由透射或反射),而高通流线式滤光片可使高于截止波长的波长通过。另外,带通滤光片可由低通流线式滤光片与高通流线式滤光片的组合形成。

[0046] 现在参看图2到5,更详细地描述用以自动地优化重叠配方的机器学习算法(例如自动配方优化[ARO])。明确地说,可选择最佳测量波长以用于最大化测量准确度及可重复性。

[0047] 图2为基于ML的ARO的简化流程图。输入数据(例如初始数据101及新数据103)可包括由重叠计量学子系统102产生的质量度量。控制器106可经配置以与重叠计量学子系统102以通信方式耦合。控制器106的存储器110可存储包括基于ML的ARO的程序指令,所述基于ML的ARO包含特征提取算法105、ML算法107及预测模型109。控制器106的一或多个处理器108可执行使所述一或多个处理器执行基于ML的ARO并相应地调整重叠计量学子系统102的配方的程序指令。

[0048] 代替产生与样本(例如样本104)上的每一取样位点相关联的质量度量,可首先计算样本均值及样本 3σ 。此计算使取样位点的数目不相关,且使在未来使用小数目个取样位点成为可能。特征提取算法105可为主成分分析(PCA)算法。PCA可用以过滤可直接影响残差的有用信息。PCA将可相关的所有质量度量转换成被称为主成分的非线性相关的变量的一组值。在一个实施例中,存在167个质量度量。在其它实施例中,存在多于或少于167个质量度量。每一成分的方差(由对应本征值给出)给出关于所述成分在系统中的显著程度的粗略估计。为了最小化运算成本,可仅将具有最高方差(例如高于阈值方差)的成分输入到监督式机器学习算法107中。

[0049] 监督式机器学习算法107的输入变量(即,在PCA之后的质量度量)可形成输入矩阵 X_{train} 。 X_{train} 的每一列可对应于一个输入索引(例如质量度量的类型),且 X_{train} 的每一行可对应于一个配方(例如硬件配置;例如波长)。输出向量 Y_{train} 可形成每一配方的残差(例如W3F3残差)。也可包含例如精确度及工具诱发性移位(TIS)的其它准确度指标。不同算法可用于监督式机器学习算法107中以教示计算机学习从输入到输出的映射函数($Y_{\text{train}} = f[X_{\text{train}}]$)。监督式机器学习算法107可包括线性回归算法107a、决策树(DT)算法107b、支持向量机回归(SVM-R)算法107c、高斯过程(GP)算法107d及/或神经网络(NN)算法107e。通过训练预测模型109,一组固定加权及偏置可定义映射函数 $f(X_{\text{train}})$ 。一旦获得新测量结果(例如新输入数据103),就可通过随着训练模型109而遵循相同数据提取程序来计算残差。可识别具有最低残差值(例如最小残差值)的配方,且可接着相应地调整计量学子系统102(例如调谐到提供最准确的重叠测量的特定波长)。现在更详细地描述与取样位点的数目及模型的组合相关的ML-ARO方案的两个重要优势。

[0050] 在训练预测模型109时,基于大数目个取样位点(200个位点或300个位点)计算每一质量度量的晶圆均值及晶圆 3σ 以及残差(例如W3F3残差)。此大数目提供更准确的残差值,且因此确保经训练映射函数可反映输入(例如初始输入数据101)与输出(例如预测模型109)之间的真实关系。然而,由于新数据(例如新输入数据103)足够具有代表性以用于预测

正在评估的层的条件,故小数目个取样位点(例如5到10个位点)可用于所述新数据的收集。取样大小的此类显著下降会减少使计量学子系统102专用于ARO所必要的时间(例如相比于常规ARO方案减少了10到20倍)。因此,时间节省为基于机器学习的ARO的大优势。

[0051] 对于每一给定训练数据集,可使用关于图2所描述的算法107a到107e同时训练多个预测模型109。可对每一预测模型109的结果线性地或非线性地求平均值,以得到最终预测结果(即,W3F3残差)。算法107a到107e中的每一者具有特定优势及劣势。举例来说,决策树算法107b可易于解译及实施,但可能无法模型化具有高复杂性的系统且因此可能会遭受低度拟合。另一方面,神经网络算法107e可管理具有至多两个隐藏层的任何复杂系统,但常常易遭受过度拟合。低度拟合及过度拟合两者使预测模型109的一般化变差且因此降低预测模型109的性能。各种学习算法(例如算法107a到107e)的组合可通过减少方差对平方误差的贡献来有利地解决这些问题。

[0052] 在ML-ARO方案应用于基于成像的重叠计量学子系统102的一个实例中,在具有足够大的取样大小的16个不同示范晶圆上收集测量数据。接着使用测量数据以训练及验证不同机器学习模型109。虽然本文中未明确地提及,但基于散射测量的ARO及多波长配方选择可遵循相似的基于机器学习的程序。

[0053] 图3A到3B展示说明用于在输入数据301a到301b的特征提取105之后评估每一机器学习算法107的性能的交叉验证方法的流程图。特征提取算法105及机器学习算法107可实质上相似于如关于图2所描述的相似命名的组件。在此方法中,按顺序选取一个层作为测试数据集(用于输入数据301a的层303a,及用于输入数据301b的层303b),而使用其它层作为训练数据集(用于输入数据301a的层302a,及用于输入数据301b的层302b)以用于使用机器学习算法107训练预测模型。将测试数据集303a到303b的质量度量馈送到机器学习算法107中以得到每一配方的经预测残差。在线图形309a到309b中标绘经预测残差(例如W3F3残差)及从经测量重叠计算的残差会提供对预测的准确度的定性理解。马蹄形循环被定义为正确预测的配方,且所述循环为对于BF-ARO及ML-ARO两者中的给定层在前十个最准确的配方中出现的配方,在所述BF-ARO中配方是基于经测量残差进行顺位,在所述ML-ARO中配方是基于经预测残差进行顺位。

[0054] 马蹄形循环(即,正确预测的配方)的数目是在图4的表401中针对示范晶圆(输入数据301a到301b)的层1到16中的每一者及每一机器学习算法107a到107e而列出。图4中也展示将机器学习算法107a到107e中的一些彼此组合的结果。提升树,也被称作梯度提升,为将呈弱决策树模型的集体形式的预测模型产生为单个强学习者的机器学习技术。求平均值方法计算从所有机器学习算法107a到107e(例如学习者的线性组合)获得的预测结果的平均值。由于机器学习算法107b(决策树)及机器学习算法107e(神经网络)的结果彼此互补(例如,NN在层#1、#2、#6、#7及#11上优选地执行,且DT在层#5、#9、#15上优选地执行),故可将DT算法107b及NN算法107e与用于NN算法107e的加权0.9及用于DT算法107b的加权0.1组合以分别在严格准则情况下得到有利机器性能。也可实行组合算法107a到107e的其它方法。

[0055] 为了定量地评估算法107a到107e的性能并系统地执行参数微调,可定义两个不同关键性能指标(KPI)。一个KPI为正确预测的配方的百分比,其可被定义为正确预测的配方的总数目除以前十个最准确的配方的数目。虽然此类KPI直接了当且易于理解,但由于其值

的变化对于每一算法107a到107e极小(0.32到0.40)而无法区分各种算法107a到107e。为了解决此问题,可定义第二KPI,即逐层平均成功率。对于前十个配方中的每一者,并非所有配方皆需要被正确地预测,这是归因于其接近的残差性能。在此情况下,可假定三个配方是足够的(准则=3)。如果预测三个或多于三个正确配方,则成功率为1.00。如果预测两个正确配方,则成功率为0.66。如果预测一个正确配方,则成功率为0.33。如果预测零个正确配方,则成功率为0。对于准则=3,在所有十六个层当中对成功率求平均值会得到逐层平均成功率,其展示于图4的表401中。为了比较,在同一表401中展示较严格的准则(前十个配方的中的五个配方)的结果。对于从示范晶圆收集的数据,清楚地展示了决策树(DT)算法107b及神经网络(NN)算法107e在准则=3情况及准则=5情况两者下得到最高的逐层平均成功率。为了改进逐层平均成功率,可执行未来参数微调。

[0056] 图5为说明训练预测模型并基于预测模型调整重叠计量学子系统的方法的流程图500。

[0057] 在步骤501处,可接收来自重叠计量学子系统(例如重叠计量学子系统102)的一或多个重叠测量。可测量样本(例如样本104)的两个或更多个层,且可将重叠测量发射到控制器(例如控制器106)。

[0058] 在步骤502处,可使用一或多个测量产生一或多个质量度量。一或多个质量度量可为例如核心 3σ (K3S)、周期比(PR)及对比精确度(CP)。

[0059] 在步骤503处,可使用主成分分析(PCA)从一或多个质量度量提取一组主成分。PCA可用以过滤可直接影响残差值的有用信息。PCA将可相关的所有质量度量转换成被称为主成分的非线性相关的变量的一组值。

[0060] 在步骤504处,产生输入数据(例如输入数据101及103)。输入数据可包括一组主成分的子集。每一成分的方差(由对应本征值给出)给出关于所述成分在系统中的显著程度的粗略估计。子集中的每一主成分具有高于阈值方差的方差。

[0061] 在步骤505处,将输入数据输入到监督式机器学习算法的输入矩阵(例如矩阵 X_{train})中以训练预测模型(例如输出向量 Y_{train})。 X_{train} 的每一列可对应于一个输入索引(例如质量度量的类型),且 X_{train} 的每一行可对应于一个配方(例如硬件配置;例如波长)。输出向量 Y_{train} 可形成每一配方的残差(例如W3F3残差)。也可包含例如精确度及工具诱发性移位(TIS)的其它准确度指标。不同算法可用于监督式机器学习算法107中以教导计算机学习从输入到输出的映射函数($Y_{\text{train}} = f[X_{\text{train}}]$)。监督式机器学习算法107可包括线性回归算法107a、决策树(DT)算法107b、支持向量机回归(SVM-R)算法107c、高斯过程(GP)算法107d及/或神经网络(NN)算法107e。通过训练预测模型109,一组固定加权及偏置可定义映射函数 $f(X_{\text{train}})$ 。一旦获得新测量结果(例如新输入数据103),就可通过随着训练模型109而遵循相同数据提取程序来计算残差。

[0062] 在步骤506处,在预测模型的输出向量中识别具有最小残差值的配方或硬件配置。

[0063] 在步骤507处,可提供(例如由控制器106)一或多个控制指令以将重叠计量学子系统(例如子系统102)调整到具有最小残差值的配方或硬件配置(例如调谐到提供用于给定样本的最准确的重叠测量的特定波长)。

[0064] 据信,本公开及其许多伴随优势将通过前述描述予以理解,且将显而易见,可在不脱离所公开的主题的情况下或在不牺牲其所有材料优势的情况下对组件的形式、建构及布

置进行各种改变。所描述的形式仅仅为阐释性的，且所附权利要求书意欲涵盖及包含此类改变。此外，应理解，本发明由随附权利要求书界定。

100




图1A




图1B




图1C

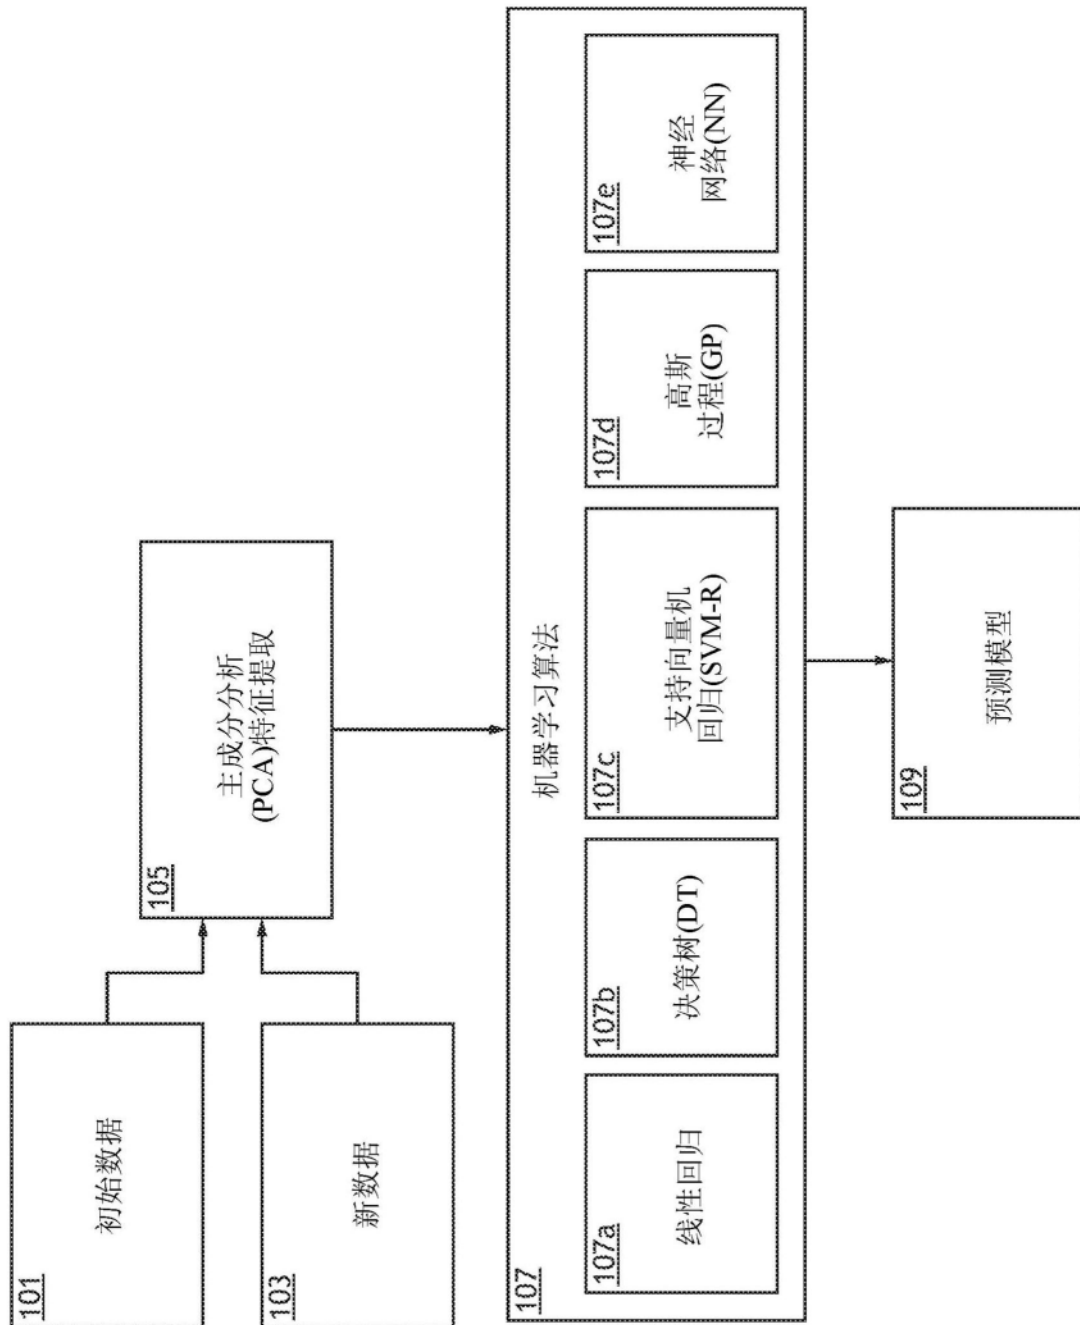


图2

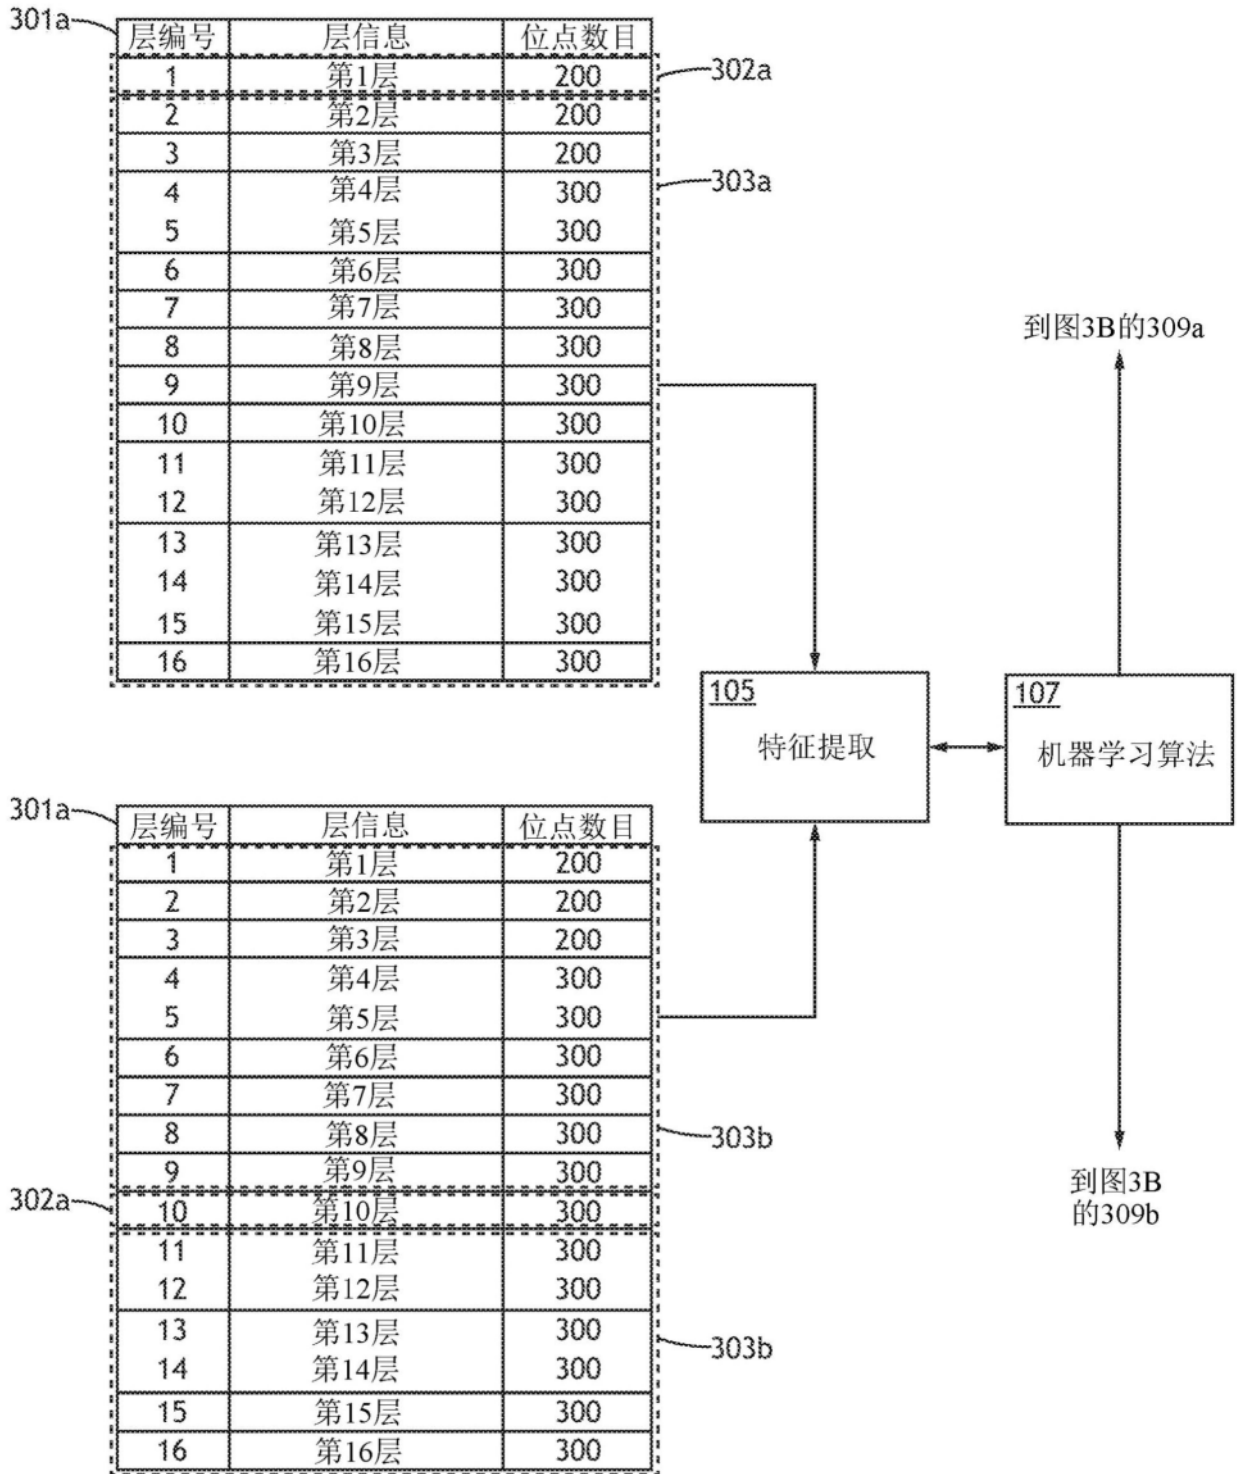


图3A





图3B

401 →

层编号	层信息	硬件数目	单个学习者						组合式学习者			
			线性回归	神经网络	高斯过程	支持向量机回归	决策树	提升树	线性拟合	求平均值	0.9*NN+0.1*DT	
1	第1层	84	4	8	7	7	6	6	7	8	7	8
2	第2层	84	1	6	1	1	1	3	3	0	2	2
3	第3层	84	0	3	1	2	3	3	3	4	2	1
4	第4层	84	3	2	6	7	3	2	2	3	5	5
5	第5层	84	5	4	2	2	5	1	1	2	2	4
6	第6层	84	7	9	8	8	5	6	6	6	9	8
7	第7层	84	8	8	7	7	8	8	8	7	8	8
8	第8层	84	5	5	4	2	5	3	3	3	4	5
9	第9层	84	0	2	0	0	7	0	0	0	0	1
10	第10层	84	2	2	2	3	3	2	2	2	2	2
11	第11层	84	9	6	6	6	2	4	4	6	6	6
12	第12层	84	2	6	7	6	0	6	6	6	6	5
13	第13层	84	0	3	0	0	4	4	4	2	3	4
14	第14层	84	0	5	5	5	6	4	4	5	6	5
15	第15层	84	0	0	0	0	5	0	0	0	0	0
16	第16层	84	5	6	2	1	10	3	3	4	4	2
正确预测的配方的百分比			0.32	0.47	0.36	0.36	0.46	0.34	0.36	0.36	0.41	0.41
逐层平均成功率=3			0.60	0.88	0.67	0.67	0.88	0.79	0.67	0.75	0.79	0.79
逐层平均成功率=5			0.53	0.68	0.59	0.58	0.66	0.61	0.58	0.63	0.68	0.68

图4

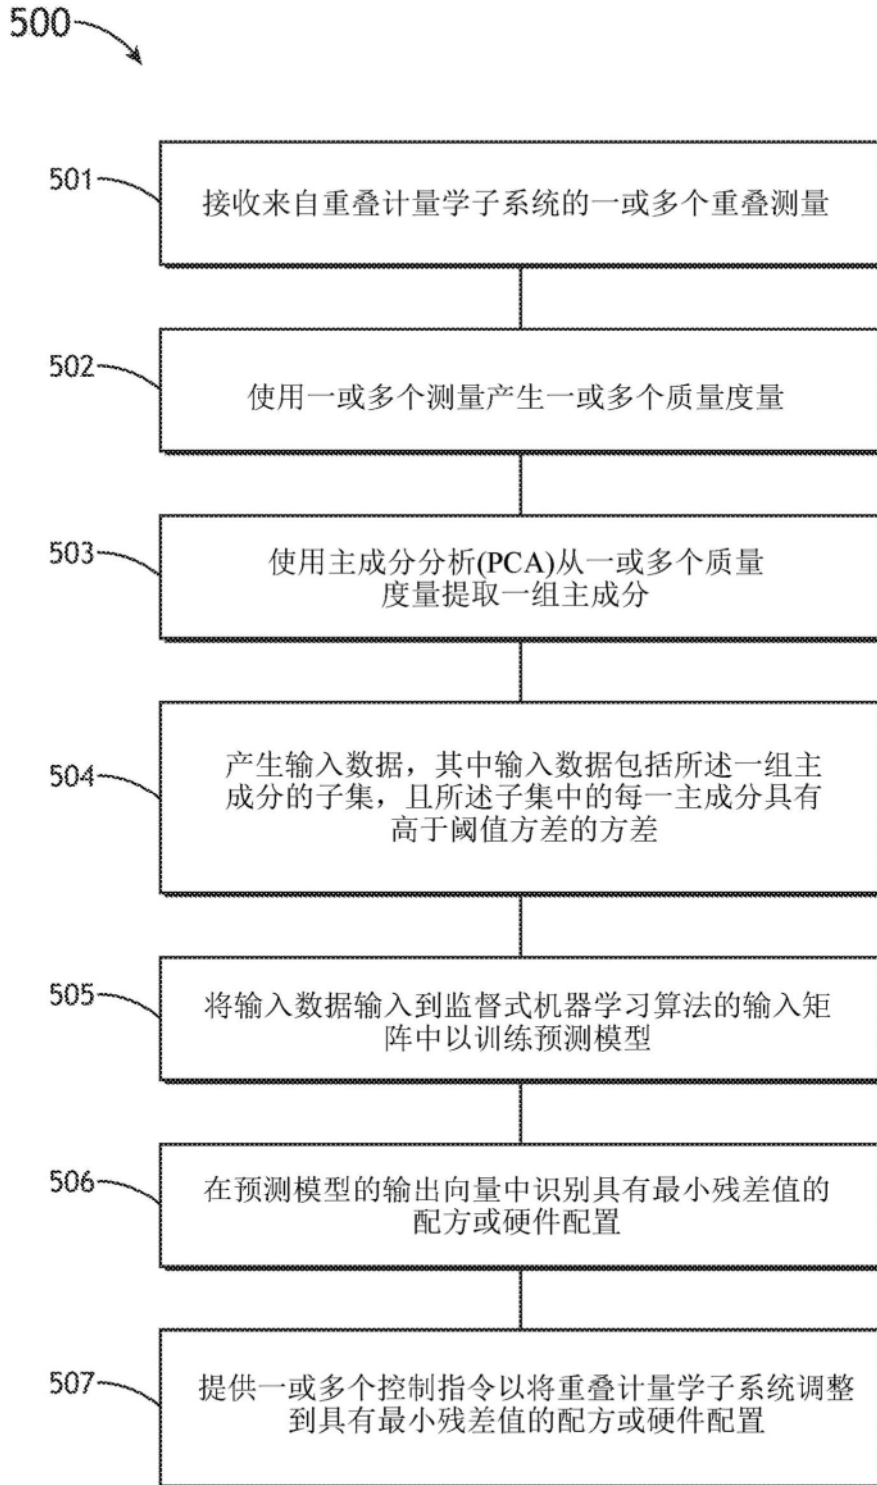


图5