



(12) 发明专利申请

(10) 申请公布号 CN 112088408 A

(43) 申请公布日 2020.12.15

(21) 申请号 201980029886.3

蓬萨伦·添塔万

(22) 申请日 2019.02.28

(74) 专利代理机构 北京品源专利代理有限公司

(30) 优先权数据

11332

10201801850P 2018.03.02 SG

代理人 谭营营 胡彬

(85) PCT国际申请进入国家阶段日

(51) Int. Cl.

2020.11.02

G16H 50/20 (2006.01)

(86) PCT国际申请的申请数据

G06N 3/08 (2006.01)

PCT/SG2019/050111 2019.02.28

A61B 5/00 (2006.01)

(87) PCT国际申请的公布数据

A61B 5/024 (2006.01)

W02019/168474 EN 2019.09.06

G06F 17/18 (2006.01)

(71) 申请人 日东电工株式会社

G06N 20/00 (2006.01)

地址 日本大阪府茨木市

G06N 3/04 (2006.01)

G16H 20/10 (2006.01)

(72) 发明人 曼内拉特·吉拉瓦尼什库

他达·吉拉加拉斯 吴清文

潘纳维特·斯里苏克


权利要求书3页 说明书13页 附图11页

(54) 发明名称

用于睡眠阶段检测的方法、计算设备和可穿戴设备

(57) 摘要

在所描述的实施例中,公开了一种睡眠阶段检测的方法。该方法包括:接收第一生命体征特征701a,该第一生命体征特征701a包括与多个时期中的相应时期对应的多个第一特征值v1-v11;以及执行第一逻辑回归运算701a',以基于对应的第一特征值v6和所述时期中的先前时期v1-v5和后续时期v7-v11的第一指示值计算这些时期中的每个中间时期的第一指示值702a,指示值702a描述对应的中间时期的睡眠阶段。还公开了创建用于逻辑回归的模型的方法,提取心率变异性特征的方法,创建用于提取心率变异性特征的模型的方法,推导医疗剂量的方法,评估对医疗剂量的反应性的方法,计算机可读介质,计算设备和可穿戴设备。



1. 一种睡眠阶段检测的方法,包括:

接收第一生命体征特征,所述第一生命体征特征包括与多个时期中的相应时期对应的多个第一特征值;以及

执行第一逻辑回归运算,以基于对应的第一特征值以及所述时期中的先前时期和后续时期的第一特征值计算所述时期中的每个中间时期的第一指示值,所述第一指示值描述对应的中间时期的睡眠阶段。

2. 根据权利要求1所述的方法,其中所述第一生命体征特征涉及心率、脉冲波形变异性和心率变异性的卷积高频功率中的一个。

3. 根据权利要求1或2所述的方法,其中所述第一逻辑回归运算包括加权和sigmoid运算。

4. 根据权利要求1至3中任一项所述的方法,还包括:

接收第二生命体征特征,所述第二生命体征特征包括与所述时期中的相应时期对应的多个第二特征值;

执行第二逻辑回归运算,以基于对应的第二特征值以及所述时期中的所述先前时期和后续时期的第二特征值计算所述时期中的每个中间时期的第二指示值,所述第二指示值描述对应的中间时期的所述睡眠阶段;以及

执行进一步的逻辑回归运算,以基于对应的第一指示值和第二指示值确定所述时期中的每个中间时期的所述睡眠阶段。

5. 根据权利要求4所述的方法,其中所述逻辑回归运算中的一个具有与所述逻辑回归运算中的另一个不同的权重值。

6. 根据权利要求4或5所述的方法,还包括:

接收第三生命体征特征,所述第三生命体征特征包括与所述时期中的相应时期对应的多个第三特征值;以及

执行第三逻辑回归运算,以基于对应的第三特征值以及所述时期中的所述先前时期和后续时期的第三特征值计算所述时期中的每个中间时期的第三指示值,

其中如果对应的第三指示值描述对应的中间时期的所述睡眠阶段,则执行所述进一步的逻辑回归运算,以进一步基于对应的第三指示值确定所述时期中的每个中间时期的所述睡眠阶段。

7. 一种创建用于逻辑回归的模型的方法,包括:

接收与参考睡眠阶段信息相关联的生命体征特征;

根据所述生命体征特征和所述参考睡眠阶段信息产生包括多个子样本的交叉验证集;

使用具有多个机器学习参数集中的每个机器学习参数集的模型,参考子样本中的其他子样本来计算所述子样本中的每个子样本;以及

基于所述参考睡眠阶段信息与所述计算的结果的比较,将所述模型与所述参数集之一进行关联。

8. 根据权利要求7所述的方法,其中所述生命体征特征与心率、脉冲波形变异性和心率变异性的卷积高频功率中的一个相关。

9. 根据权利要求7或8所述的方法,还包括:

接收与所述参考睡眠阶段信息相关联的另一生命体征特征,

其中所述交叉验证集还根据所述另一生命体征特征产生。

10. 根据权利要求7至9中任一项所述的方法,其中所述生命体征特征被至少三个连续的时期切分。

11. 根据权利要求10所述的方法,其中相对于所述时期中的中间时期,所述至少三个连续的时期包括所述时期中的先前时期、所述中间时期和后续时期。

12. 根据权利要求10或11所述的方法,其中所述至少三个连续的时期包括11个时期。

13. 根据权利要求10至12中任一项所述的方法,其中所述至少三个连续的时期被配置为与至少30分钟的总窗期对应。

14. 根据权利要求1至13中任一项所述的方法,其中所述生命体征特征被归一化。

15. 根据权利要求1至14中任一项所述的方法,其中补偿所述生命体征的缺失部分。

16. 根据权利要求15所述的方法,其中使用最大池化来补偿所述缺失部分。

17. 一种提取心率变异性特征的方法,包括:

通过卷积滤波器对心率变异性功率谱密度的高频部分进行卷积,以产生表示相应的心率变异性模式的多个卷积值,所述卷积滤波器涉及卷积神经网络模型;以及

基于对所述卷积值执行的激活函数运算的结果选择所述卷积值中的一个。

18. 根据权利要求17所述的方法,其中所选择的卷积值与所执行的激活函数产生的最大值对应。

19. 根据权利要求17或18所述的方法,其中所述高频部分的范围为0.15Hz至0.4Hz。

20. 根据权利要求17至19中任一项所述的方法,其中所述功率谱密度在其高频部分和低频部分上实现归一化。

21. 根据权利要求17至20中任一项所述的方法,其中所述激活函数运算涉及修正线性单元、软relu和sigmoid函数中的一个。

22. 一种创建用于提取心率变异性特征的模型的方法,包括:

与参考睡眠阶段信息相关联地接收表示心率变异性功率谱密度的生命体征特征;以及参考所述参考睡眠阶段信息,使用基于所述生命体征特征的机器学习来创建包括卷积滤波器的模型。

23. 根据权利要求22所述的方法,其中对于每个五分钟间隔内的三分钟间隔根据生理信号推导出所述生命体征特征。

24. 根据权利要求22或23所述的方法,其中所述生命体征特征被归一化。

25. 根据权利要求22至24中任一项所述的方法,其中所述机器学习包括卷积神经网络。

26. 一种推导医疗剂量的方法,包括:

接收第一时段的睡眠阶段信息;

接收第二时段的睡眠阶段信息,以与所述第一时段的睡眠阶段信息进行比较;以及基于所述比较的结果提供医疗剂量。

27. 一种评估对医疗剂量的反应性的方法,包括:

接收第一时段的睡眠阶段信息;

接收第二时段的睡眠阶段信息,以与所述第一时段的睡眠阶段信息进行比较;以及基于所述比较的结果,评估对在所述第一时段和所述第二时段之间出现的医疗剂量的反应性。

28. 根据权利要求26或27所述的方法,其中规定的医疗剂量涉及抗惊厥药物、苯二氮平类药物和马西洋中的至少一种。

29. 一种计算机可读介质,包括用于使处理器执行根据权利要求1至28中任一项所述的方法的指令。

30. 根据权利要求29所述的计算机可读介质,其中所述指令适于在固件中实现。

31. 一种计算设备,包括:

处理器;以及

存储设备,其包括用于使所述处理器执行根据权利要求1至28中任一项所述的方法的指令。

32. 根据权利要求31所述的计算设备,其中所述存储设备是固件芯片。

33. 一种可穿戴设备,包括:

存储设备,其包括用于使处理器执行根据权利要求1至28中任一项所述的方法的指令。

34. 根据权利要求33所述的可穿戴设备,其中所述存储设备是固件芯片。

35. 根据权利要求33或34所述的可穿戴设备,其采取手表的形式。

用于睡眠阶段检测的方法、计算设备和可穿戴设备

技术领域

[0001] 本公开一般地涉及一种用于睡眠阶段检测,具体地说,涉及基于机器学习检测包括快速眼动(REM)和非REM(NREM)的睡眠阶段的方法、计算设备和可穿戴设备。

背景技术

[0002] 众所周知,一个人的身体和精神状态会受到他们睡眠质量的影响。优质的睡眠对于保持健康、幸福和良好的心情至关重要。入睡时,人通常会在快速眼动(REM)阶段和非快速眼动(NREM)阶段之间过渡。多项研究发现,REM阶段在情绪调节和记忆巩固中起着重要作用。此外,已发现抑郁症与REM睡眠失调(例如增加的REM睡眠持续时间和缩短的REM潜伏期)密切相关。因此,可以监测睡眠阶段,以为睡眠行为分析和压力管理以及抑郁症治疗、老人护理和性能分析提供重要信息。分析的质量以及治疗的质量在很大程度上取决于所收集的数据,既包括数据的质量,也包括数据的数量。为了满足这些要求,所采用的监测设备通常需要大量硬件并且非常复杂。

[0003] 当前睡眠研究的黄金标准是多导睡眠图(PSG)。这需要大量传感器,其中包括脑电图(EEG)、眼电图(EOG)、肌电图(EMG)、心电图(ECG)和呼吸传感器。尽管PSG为睡眠研究提供了更多信息,但它高度固定且价格昂贵,这使得它无法进行海量观察。

[0004] 美国专利第9,655,559B2号公开了使用可穿戴传感器的自动睡眠分期。所公开的布置具有多个缺点,例如,精度较差,并且对较差传感器读数的敏感性较低。

[0005] 期望提供一种用于睡眠阶段检测的方法、计算设备和可穿戴设备,它们能够解决现有技术的至少一个缺点和/或为公众提供了有用的选择和/或替代选择。

发明内容

[0006] 根据一方面,提供了一种睡眠阶段检测的方法,包括:接收第一生命体征特征,所述第一生命体征特征包括与多个时期中的相应时期对应的多个第一特征值;以及执行第一逻辑回归运算,以基于对应的第一特征值以及所述时期中的先前时期和后续时期的第一特征值计算所述时期中的每个中间时期的第一指示值,所述第一指示值描述对应的中间时期的睡眠阶段。

[0007] 所描述的实施例是特别有利的。例如,通过基于多个时期中的先前时期、中间时期和后续时期的第一特征值,相对于多个时期中的每个中间时期执行第一逻辑回归运算,可以计算描述多个时期中的每个中间时期的睡眠阶段的第一指示值。这是有利的,因为不仅使用了先前时期和中间时期的特征值,而且还使用了后续时期的特征值,从而提高了精度。在一个实施例中,由于所需的最少数据量和处理量,该方法需要以硬件形式、软件形式或两者的组合来实现较少的计算资源。因此,该方法特别适合于但不限于使用可穿戴设备的实现。

[0008] 所述第一生命体征特征可以涉及心率、脉冲波形变异性和心率变异性的卷积高频功率中的一个。这些生命体征特征被发现与睡眠阶段相关,因此用于检测睡眠阶段。

[0009] 优选地,第一逻辑回归运算可以包括加权和sigmoid运算。与非线性模型相比,逻辑回归运算更简单,更易解释。在机器学习领域中公知的是,与简单模型相比,复杂模型具有更高的过拟合风险。因此,通过使用逻辑回归运算,根据一个实施例的睡眠阶段检测适合在例如可穿戴设备上执行。关于卷积神经网络使用的用于提取涉及三个维度的HRV PSD的相对复杂的算法例如可以在云服务的服务器上执行。提取HRV PSD。

[0010] 优选地,所述方法还可以包括:接收第二生命体征特征,所述第二生命体征特征包括与所述时期中的相应时期对应的多个第二特征值;执行第二逻辑回归运算,以基于所述对应的第二特征值以及所述时期中的所述先前时期和后续时期的第二特征值计算所述时期中的每个中间时期的第二指示值,所述第二指示值描述所述对应的中间时期的所述睡眠阶段;以及执行进一步的逻辑回归运算,以基于所述对应的第一指示值和第二指示值确定所述时期中的每个中间时期的所述睡眠阶段。

[0011] 在所描述的实施例中,例如,通过接收多个生命体征特征并基于相应的生命体征特征执行多个逻辑回归运算以计算相应的指示值,可以基于指示值执行进一步的逻辑回归运算以确定每个中间时期的睡眠阶段。通过考虑多个生命体征特征的信息,可以改善睡眠阶段检测的结果。通过考虑多个生命体征特征并执行进一步的逻辑回归运算,可以以更高的精度检测睡眠阶段。

[0012] 所述逻辑回归运算中的一个具有与所述逻辑回归运算中的另一个不同的权重值。

[0013] 优选地,所述方法还可以包括接收第三生命体征特征,所述第三生命体征特征包括与所述时期中的相应时期相对应的多个第三特征值;以及执行第三逻辑回归运算,以基于所述对应的第三特征值以及所述时期中的所述先前时期和后续时期的第三特征值计算所述时期中的每个中间时期的第三指示值,其中如果所述对应的第三指示值描述所述对应的中间时期的所述睡眠阶段,则执行所述进一步的逻辑回归运算,以进一步基于所述对应的第三指示值确定所述时期中的每个中间时期的所述睡眠阶段。

[0014] 这种布置是有利的,因为,例如由于第三生命体征特征的未补偿的对应特征值,第三指示值可能不指示睡眠阶段。如果在进一步的逻辑回归运算中使用,则该第三指示值可能影响睡眠阶段确定的精度。因此,通过仅在第三指示值描述睡眠阶段时才使用高第三指示值,可以实现睡眠阶段检测的准确结果。

[0015] 根据另一方面,提供了一种创建用于逻辑回归的模型的方法,包括:接收与参考睡眠阶段信息相关联的生命体征特征;根据所述生命体征特征和所述参考睡眠阶段信息产生包括多个子样本的交叉验证集;使用具有多个机器学习参数集中的每个机器学习参数集的模型,参考子样本中的其他子样本来计算所述子样本中的每个子样本;以及基于所述参考睡眠阶段信息与所述计算的结果的比较,将所述模型与所述参数集之一进行关联。

[0016] 在一个实施例中,通过使用机器学习技术,可以有效地确定生命体征特征与参考睡眠阶段信息之间的相关性,从而确定用于模型的参数集。例如,参数集可以包括在第一睡眠时段中获取的第一参数集,在第二睡眠时段中获取的第二参数集,并且可以检索和/或存储第一睡眠时段和第二睡眠时段,以将其编程到单独的模型中。也就是说,一个睡眠时段的参数集可以与另一睡眠时段的参数集不同。在另一示例中,为了趋向用户睡眠模式,在第一睡眠时段中获取第一参数集,在第二睡眠时段中获取第二参数集,并且可以检索和/或存储第一睡眠时段和第二睡眠时段,以将其编程到趋势模型中。在第三睡眠时段中检索第三参

数集,其中第三睡眠时段与第一睡眠时段和第二睡眠时段在时间上不同并且分开。可以检索和/或存储第三睡眠时段,以将其编程到趋势模型中。

[0017] 生命体征特征可以与心率、脉冲波形变异性和心率变异性的卷积高频功率中的一个相关。这些生命体征特征被发现与睡眠阶段相关,因此可用于检测睡眠阶段。在另一实施例中,生命体征特征还可以与心率变异性的总功率的总和、心率变异性的低频功率的总和、心率变异性的LF/HF比、心率的标准差相关。这些生命体征特征可以从来自另一个设备的当前和/或过去的的数据中检索,因此可用于检测睡眠阶段。

[0018] 优选地,所述方法还包括:接收与所述参考睡眠阶段信息相关联的另一生命体征特征,其中所述交叉验证集还根据所述另一生命体征特征产生。通过考虑另一生命体征特征,交叉验证集包括可用于准确地检测睡眠阶段的更多信息。

[0019] 所述生命体征特征可被至少三个连续的时期切分。相对于所述时期中的中间时期,所述至少三个连续的时期可包括所述时期中的先前时期、所述中间时期和后续时期。通过考虑后续时期,可以以更高的准确性检测睡眠阶段。在所需的实施例中,所述至少三个连续的时期包括11个时期。此外,所述至少三个连续的时期被配置为与至少30分钟的总窗期相对应。睡眠数据的持续时间可能超过一小时(例如7-8个小时)。在一个实施例中,通过将睡眠数据“切片”成每小时时段或间隔,该数据类似于睡眠周期,允许有效地执行睡眠阶段计算。

[0020] 所述生命体征特征可被归一化。此外,可以补偿所述生命体征的缺失部分。例如,可以使用最大池化来补偿所述缺失部分。这种技术对于减少这种缺失部分对检测结果的不利影响是有用的,否则可能导致假阳性或假阴性检测。可选地,根据实现,可以用随机值、平均值、最近值、线性插值等代替这些缺失部分。

[0021] 根据另一方面,提供了一种提取心率变异性特征的方法,包括:通过卷积滤波器对心率变异性功率谱密度的高频部分进行卷积,以产生表示相应的心率变异性模式的多个卷积值,所述卷积滤波器涉及卷积神经网络模型;以及基于对所述卷积值执行的激活函数运算的结果选择所述卷积值中的一个。

[0022] 在一个公开的实施例中,该方法的优点在于,考虑了心率变异性功率谱密度的高频部分与快速眼动(REM)之间的相关性,其中在高频部分中检测到较低的功率强烈表示REM。

[0023] 优选地,所选择的卷积值与所执行的激活函数产生的最大值相对应。最大值与REM和/或NREM睡眠阶段相对应,这样有利地提供了推导睡眠阶段的一致方法。

[0024] 此外,所述高频部分的范围优选地为0.15Hz至0.4Hz。已经发现,在该频率部分中,心率变异性功率谱密度与睡眠阶段具有特别高的关联度。通过考虑该频率范围内的频谱信息,所得心率变异性特征更能指示睡眠阶段。

[0025] 所述功率谱密度可以在其高频部分和低频部分上实现归一化。归一化拒绝数据缩放,而是提供一致的功率谱密度以进行自适应。

[0026] 优选地,所述激活函数运算涉及修正线性单元、软relu和sigmoid函数中的一个。

[0027] 根据本公开的另一面,公开了一种创建用于提取心率变异性特征的模型的方法,包括:与参考睡眠阶段信息相关联地接收表示心率变异性功率谱密度的生命体征特征;以及参考所述参考睡眠阶段信息,使用基于所述生命体征特征的机器学习来创建包括卷积

滤波器的模型。通过使用这种模型推导生理信号,心率变异性的高频成分可作为睡眠阶段检测的相对一致的基础。

[0028] 优选地对于每个五分钟间隔内的三分钟间隔根据生理信号推导出所述生命体征特征。可以在不显著影响睡眠阶段检测的准确性的情况下降低功耗。备选地,可以在比时期短的间隔内,相对于该时期根据生理信号推导出生命体征特征。

[0029] 优选地,所述生命体征特征被归一化。

[0030] 所述机器学习优选地包括卷积神经网络。用于训练模型的卷积神经网络CNN算法可以同时涉及HRV PSD和睡眠阶段中的信息。可以将HRV PSD视为包含一段时间内频域中HRV变化模式的图像。可以在实验数据中观察到与REM和NREM睡眠阶段模式相一致的HRV PSD中的低功率和高功率交替模式。CNN算法可用于提取此类图像的信息。

[0031] 在一个公开的实施例中,使用CNN算法的一个优点是,CNN算法可以通过优化卷积滤波器、激活函数、数据池化方法,以及能够提供最小或减少的预测误差的神经网络权重,来将HRV PSD处理为与REM/NREM睡眠阶段相关的计算值。换句话说,CNN算法可以通过模型训练将HRV PSD汇总或以其他方式处理为指示睡眠阶段的计算值。在一个示例布置中,本公开有利地处理至少三维数据,该三维数据包括HRV的频率、时域和功率密度。

[0032] 所收集或检索的信息与从另一设备获得的其他信息以及从可穿戴设备收集的信息可以最终一起应用。反之亦然,从任何类型的传感器检索诸如HR、HRV和脉冲波形变异性之类的信息,机器学习算法可以进一步完善该信息。

[0033] 根据另一方面,公开了一种推导医疗剂量的方法,包括:接收第一时段的睡眠阶段信息;接收并比较所述第一时段和第二时段之间的睡眠阶段信息;提供导致规定医疗剂量的所述参考睡眠阶段信息。

[0034] 根据另一方面,公开了一种评估对医疗剂量的反应性的方法,包括:接收第一时段的睡眠阶段信息;接收第二时段的睡眠阶段信息,以与所述第一时段的睡眠阶段信息进行比较;以及基于所述比较的结果,评估对在所述第一时段和所述第二时段之间出现的医疗剂量的反应性。

[0035] 所述规定的医疗剂量可以涉及抗惊厥药物、苯二氮平类药物和马西洋中的至少一种。

[0036] 根据本公开的另一方公开了一种计算机可读介质,包括用于使处理器执行上述方法中的任一种的指令。

[0037] 优选地,所述指令适于在固件中实现。由于其简单性,上述方法中的至少一些尤其适合于但不限于采取固件中的指令的形式的实现。

[0038] 根据本公开的另一方,公开了一种计算设备,包括:处理器;以及存储设备,其包括用于使所述处理器执行上述方法中的任一种的指令。

[0039] 所述存储设备优选地是固件芯片。如上略微提及的,上述方法中的至少一些由于其简单并且具有低硬件要求而可以使用固件实现。

[0040] 根据本公开的另一方,公开了一种可穿戴设备,包括:存储设备,其包括用于使处理器执行上述方法中的任一种的指令。

[0041] 所述存储设备优选地是固件芯片。如上所述,上述方法中的至少一些可以使用固件实现。

[0042] 优选地,所述可穿戴设备采取便于长期收集数据的手表的形式。

[0043] 可以设想,与一个方面相关的特征可应用于其他方面。

附图说明

[0044] 现在将参考附图描述示例实施例,其中:

[0045] 图1示出了根据本公开的一个实施例的计算设备的示例系统框图;

[0046] 图2示出了由图1的计算设备执行的睡眠阶段检测方法的流程图;

[0047] 图3A示出了由图1的计算设备执行的用于创建用于逻辑回归的模型的方法的流程图;

[0048] 图3B示出了产生训练数据集的示例;

[0049] 图4示出了由图1的计算设备执行的用于提取心率变异性特征的方法的流程图;

[0050] 图5示出了由图1的计算设备执行的用于创建用于提取心率变异性特征的模型的方法的流程图;

[0051] 图6(a)至6(c)示出了由图1的计算设备执行的数据错误补偿的不同场景;

[0052] 图7示出了由图1的计算设备执行的,涉及多个逻辑回归运算以及随后的进一步的逻辑回归运算和三个生命体征特征的睡眠阶段计算的示例场景;

[0053] 图8示出了图1的计算设备以滑动窗口的方式执行逻辑回归运算的示例场景;

[0054] 图9示出了由图1的计算设备执行的不同计算阶段的不同信号的折线图;

[0055] 图10示出了使用图2的方法获得的睡眠阶段检测结果的误差百分比的布兰德-奥特曼图;

[0056] 图11示出了重度抑郁症患者的REM百分比和频率的直方图;

[0057] 图12A示出了采取手表或可穿戴设备形式的图1的计算设备的实施例;

[0058] 图12B示出了图12A的可穿戴设备的头部组件的示意图;

[0059] 图12C示出了图12A的头部组件的横截面示意图;以及

[0060] 图13示出了在示例场景中将所计算的睡眠阶段信息从图12A的可穿戴设备无线传输到另一计算设备的实例。

具体实施方式

[0061] 图1示出了适合于执行本公开的一些方法的实施例的示例性计算设备100的系统框图。计算设备100包括处理器101、固件芯片102、存储设备103、生理传感器104(例如,心电图传感器、血容积传感器或其组合)以及可操作地与处理器101相关联的通信接口105(有线或无线)。值得注意的是,可以使用能够进行生理测量的任何类型的传感器。在一个实施例中,计算设备100采取微型设备(例如,可穿戴设备)的形式。在另一实施例中,计算设备100采用计算机(例如,服务器)的形式。在又一实施例中,计算设备100采取移动设备的形式。可以将处理器101可执行的指令存储在固件芯片102、存储设备103或其组合中。

[0062] 图2示出了根据本公开的一个实施例的睡眠阶段检测的方法200的流程图。体现方法200的指令的存储和执行如上所述。此外,该实施例中的计算设备100采取可穿戴睡眠阶段跟踪设备100的形式。在步骤201,处理器101从穿戴在任何合适的身体部位(例如,手腕、上臂、食指、脖子或头)上的传感器104接收生理信号。

[0063] 在步骤202,处理器101从生理信号中提取表示心率(HR)、心率变异性的卷积高频功率(Conv_HF)和脉冲波形变异性(PSV)的生命体征特征。在其他实施例中,生命体征特征可以表示另外的生理特征。生命体征特征可以体现一系列特征值的示例性形式,每个特征值与对应时期的睡眠阶段相对应。换句话说,每个生命体征特征包括分别与多个时期相对应的多个特征值。以心率变异性的卷积高频功率为例,生命体征特征中的每个特征值可以表示相应时期内的变异性的独特模式。然而,在其他实施例中,处理器101可以从生理信号中提取任何数量(例如1、2或4)的生命体征特征。

[0064] 脉冲波形变异性(PSV)可以称为根据输入生理信号(例如,PPG信号)的脉冲波形推导出的生命体征特征的标准差,该标准差可以基于例如时间间隔信息、偏度、大小、积分和微分信息、频率分量或其脉冲的导数进行计算。

[0065] 在步骤203,处理器101补偿生命体征特征中的缺失数据部分(如果有的话)。缺失数据部分可能是由例如较差的传感器信号质量引起的。通过这种补偿,可以减少检测结果对缺失的数据部分的敏感性。下文中关于图6详细描述了生命体征特征中的缺失数据部分的补偿。缺失数据部分的补偿可以包括提取至少两个输入序列。备选地,对缺失数据部分的补偿可以包括提取一组备选输入序列。同时,另一备选方案可以包括同时提取至少两个输入序列和一组备选输入序列。

[0066] 在步骤204,处理器101对生命体征特征进行归一化,无论这些生命体征特征是否被补偿。

[0067] 在步骤205,处理器101使用至少一个模型(例如,学习的模型),根据处理后的生命体征特征来计算(例如,确定、检测或分类)每个时期的睡眠阶段。在该步骤,处理器101执行机器学习分类器的功能,根据生命体征特征计算每个时期的睡眠阶段。基于计算结果,将睡眠阶段确定为快速眼动(REM)和非快速眼动(NREM)之一。该计算步骤将在下文中关于图7、8和9进行更详细地描述。至少一个模型可以存储在固件芯片102或存储设备103上。但是,可以使用机器学习在任何计算平台上创建、开发或训练至少一个模型,将在下文对此进行详细说明。在至少一个模型单独存储在云服务器上的情况下,在一种布置中,处理器101基于处理器101通过连接或联接到云服务器的通信接口105进行通信,检索至少一个模型。在备选实施例中,生命体征特征可以由处理器101提供给运行至少一个模型以用于睡眠阶段计算的云服务器。此后,计算设备100的处理器101可以向云服务器请求(例如,从中检索)睡眠阶段的计算结果。在一个实施例中,可以将睡眠阶段的计算结果传送到另一设备,该另一设备被编程为将睡眠阶段的计算结果与其他设备中的信息进行组合或提取其他设备中的信息以进行计算。换句话说,处理器101可以将睡眠阶段的计算部分或全部卸载到相关联的处理平台,例如云服务器。每个时期的所计算或检测到的睡眠阶段可以由处理器101或通过其他方式处理为睡眠阶段睡眠图。

[0068] 为了实现步骤205,将模型用于机器学习分类(例如,逻辑回归)。下面关于图3A描述了模型的创建(例如,训练)。一旦训练了新模型(即,参数集与模型相关联),便可将包括一组常数的相关联的参数集存储在计算设备100的固件芯片102上。训练/重新训练或自适应建模的模型可以实时地执行,并且如果参数集未存储在固件芯片上,则可能需要从例如存储有参数集的相关联的服务器设备进行外部检索。可以将参数集传送到托管云服务的服务器,以便将来对用户睡眠模式进行长期追踪、趋势分析和跟踪。相反,现有的PSG技术由于

其固定性而不能用于以这种有效方式检查用户的睡眠模式。

[0069] 因此,可以理解,机器学习算法用于基于生命体征特征的睡眠阶段检测。可以使用可用的机器学习工具来实现机器学习算法。逻辑回归例如可以使用MATLAB编程语言来实现。机器学习算法(例如,逻辑回归)搜索线性边界,该线性边界是输入特征的线性组合,可以将输入特征最佳地分为两类。可通过减少系统对数据进行分类和训练时的错误来实现此目的。所得的输出是转为由所述参数集之一表示的一组特征的线性组合。这被认为是一个模型。该模型可以与一组新的输入一起应用,以检测感兴趣的类别,该类别是图2的场景中的REM或NREM睡眠阶段。机器学习也可用于推导生命体征特征,如下所述。

[0070] 图3A示出了根据本公开的一个实施例的创建用于逻辑回归的模型的方法300的流程图。在该实施例中,计算设备100采取被配置为执行机器学习操作的服务器设备100的形式。所创建的模型可以用于实现步骤205。

[0071] 在步骤301,处理器101经由通信接口105与参考睡眠阶段信息相关联地接收生理信号。也可以以其他方式与参考睡眠阶段信息相关联地从生理传感器104接收生理信号。参考睡眠阶段信息和生理信号可以同时或以其他方式接收。参考睡眠阶段信息由参考设备提供,该参考设备是由权威机构测试和批准的设备。参考睡眠阶段信息例如可以源自FDA批准的医疗设备,以提供约89%符合黄金标准的睡眠阶段检测。

[0072] 在步骤302,该实施例中的处理器101从生理信号中提取生命体征特征,该生命体征特征分别表示心率(HR)、心率变异性的卷积高频功率(Conv_HF),以及脉冲波形变异性(PSV)。在其他实施例中,生命体征特征可以表示其他类型的其他生理特征。

[0073] 在步骤303,处理器101通过以任何合适的顺序对至少三个连续的时期进行切片来处理生命体征特征,在该实施例中,所述至少三个连续的时期具有至少一小时的窗期总跨度,以补偿任何缺失的数据部分,并通过切片的标准分数对切片进行归一化。替代地,窗期总跨度可以是至少30分钟。在另一实施例中,可以采用不同的窗期总跨度的混合。例如,可能存在至少四个一小时的窗期和至少六个30分钟的窗期,从而导致总跨度至少为七个小时。对于至少八小时的总跨度,该混合物例如可以是至少五个一小时的窗期和至少六个三十分钟的窗期。

[0074] 在步骤304,处理器101将处理后的生命体征特征与参考睡眠阶段信息相结合,以产生由多个子样本组成的数据集。可以从数据集中导出用于模型训练的交叉验证集和用于模型评估的盲测集。交叉验证集包括或划分为(k)个相等大小的子样本。

[0075] 在步骤305,处理器101使用具有多个机器学习参数集中的每个参数集的模型,参考交叉验证集中的其他(k-1)个子样本来计算(例如,确定、预测或估计)交叉验证集中的每一个(1)子样本。换句话说,处理器101使用其他(k-1)个子样本来计算每一个(1)子样本。对于每个机器学习参数集,该计算过程重复(k)次,以使交叉验证集中的每个子样本用作计算目标,以供处理器101使用交叉验证集中的其他子样本进行计算。因此,所述其中一个子样本可以称为模型未知的目标子样本,而另一子样本可以称为训练子样本,其用作计算目标子样本的基础。通过这种布置,每个子样本充当一次目标子样本,而不会“污染”训练子样本。因此,所计算的睡眠阶段信息表示了综合性能,而不是过拟合性能。

[0076] 在计算之后,处理器101针对每个参数集组合所计算的目标子样本来形成所计算的睡眠阶段信息以与参考睡眠阶段信息进行比较。

[0077] 在步骤306,处理器101基于所计算的睡眠阶段信息与参考睡眠阶段信息的比较,将模型与其中一个参数集进行关联。特别地,产生最接近于参考睡眠阶段信息的所计算的睡眠阶段信息的参数集与用于实现最高计算精度(或最低计算误差)的模型相关联。

[0078] 图3B示出了产生训练数据集的示例,分别显示了两个标记为T1和T2的表。在该示例中,参考表T1,通过提取时间 $t-5$ 至 $t-1$ (先前时期)、 t (中间时期)以及 $t+1$ 至 $t+5$ (后续时期)的特征值(它们共同表示生命体征特征的11个特征值(X_{t-5} 至 X_{t+5})),创建用于训练生命体征特征的逻辑回归模型的训练数据集。在另一示例中,通过提取时间 $t-2$ 至 $t-1$ (先前时期)、 t (中间时期)以及 $t+1$ 至 $t+2$ (后续时期)的特征值(它们共同表示生命体征特征的5个特征值(X_{t-2} 至 X_{t+2})),创建用于训练生命体征特征的逻辑回归模型的训练数据集。 t 时期处的对应的参考睡眠阶段由单元格(S_t)标记。然后,算法重新排列11个特征值(X_{t-5} 至 X_{t+5})和对应的参考睡眠阶段(S_t),然后算法将重新排列的特征值和对应的参考睡眠阶段视为训练数据集。训练数据集在表T2中示出。对于相应时间 t 处的每个中间时期,将对应的参考睡眠阶段附加到对应的11个特征值(X_{t-5} 至 X_{t+5})上。可以计算出连续11个时期处的特征值(X_{t-5} 至 X_{t+5})之间的线性关系,该线性关系指示REM或NREM的对应的参考睡眠阶段(S_t)。该线性关系定义权重,并且可用于计算以低误差计算与REM和NREM之一相对应的特定时期处的指示值。在另一实施例中,提取每个生命体征特征的特征值所花费的时间可以延长到更长。

[0079] 图4示出了提取心率变异性特征的方法400的流程图,此方法可以独立地执行或作为方法200的步骤202的一部分来执行。在该实施例中,计算设备100采取可穿戴睡眠阶段跟踪设备100的形式。

[0080] 在步骤401,处理器101基于脉冲间隔检测从计算设备100接收的生理信号中提取心率变异性功率谱密度。

[0081] 在步骤402,处理器101通过用每个频率上的功率除以频谱的低频部分和低频部分上的总功率来归一化功率谱密度,其中低频部分的范围为0.04Hz至0.15Hz,而高频部分的范围为0.15Hz到0.4Hz。

[0082] 在步骤403,处理器101用卷积滤波器对功率谱密度的高频部分进行卷积,以产生表示各个心率变异性特征的多个卷积值。每个卷积值表示心率变异性功率谱密度的高频部分中的高低功率模式。卷积滤波器涉及卷积神经网络模型,该模型将在下文中进行描述。

[0083] 在步骤404,处理器101对卷积值执行激活函数,并基于激活函数的结果选择卷积值之一。特别地,激活函数的结果指示每个卷积值的模式与实际睡眠阶段之间的相似关系。所选择的卷积值用作表示心率变异性的卷积高频功率(Conv_HF)的生命体征特征。

[0084] 图5示出了根据本公开的一个实施例的创建用于提取心率变异性特征的模型的方法500的流程图。该实施例中的计算设备100采取台式个人计算机100的形式,其具有用于机器学习操作的足够处理资源。

[0085] 在步骤501,处理器101经由通信接口105与参考睡眠阶段信息相关联地接收生理信号。也可以以其他方式与参考睡眠阶段信息相关联地从生理传感器104接收生理信号。参考睡眠阶段信息和生理信号可以同时或以其他方式接收。参考睡眠阶段信息由参考设备提供,该参考设备是由权威机构测试和批准的设备。替代地,参考睡眠阶段信息可以由权威机构测试和批准的可穿戴设备提供。

[0086] 在步骤502,处理器101从每个至少三分钟(例如五分钟)的生理信号间隔中提取表

示心率变异性功率谱密度的生命体征特征。将信号划分为至少三分钟的间隔的原因是,该步骤是将信号划分为几个时期并在每个时期中提取特征。换句话说,在将生理信号划分为的多个间隔中的每个间隔期间,执行从生理信号中提取生命体征特征,每个间隔持续至少三分钟。在不执行该步骤的情况下,所提取的HRV特征将表示例如整个睡眠会话(而不是会话期间的特定时段或时期)的信号。在该实施例中,每个间隔是五分钟,并且在每个间隔内,仅将三分钟的对应的生理信号部分用于推导或提取生命体征特征。换句话说,生命体征特征是在每个五分钟间隔当中的三分钟内从生理信号中推导出的。这意味着在每个五分钟间隔内,用于特征提取的相关组件仅运行三分钟,从而降低了功耗。在其他实施例中,每个间隔可以不是五分钟,并且在该间隔内,用于特征提取的对应的生理信号部分的持续时间可以不是三分钟。

[0087] 在步骤503,处理器101通过用每个频率上的功率除以频谱的低频部分和高频部分上的总功率来归一化功率谱密度,其中低频部分的范围为0.04Hz至0.15Hz,而高频部分的范围为0.15Hz到0.4Hz。

[0088] 在步骤504,将归一化的HRV PSD和训练数据集的参考睡眠阶段输入到机器学习算法中,尤其是卷积神经网络。例如,在方法400中,选择具有可接受的或最高精度的包括卷积滤波器、激活函数和数据池化功能的模型,并将其用于提取Conv_HF特征。

[0089] 特别地,可以通过卷积神经网络CNN和算法,使用现有工具箱(例如基于编程语言“R”的“mxnet”)训练模型。首先,将包含HRV PSD(特征)和相关联的REM/NREM睡眠阶段(标签)的训练集输入到CNN算法中。CNN算法通过计算产生最小分类或检测误差的最佳卷积滤波器和神经网络权重来执行训练。训练过程从模型滤波器和权重的随机初始化开始。接下来,执行反向传播过程以计算朝向较低误差的梯度并在每次迭代时调整权重。为了获得减少误差或最小化误差而又不过度拟合的模型,可通过确定赋予验证集中最低误差的适当模型参数(例如,卷积滤波器的大小、激活函数的类型、数据池化方法、隐藏层数、训练迭代)来对模型进行微调。以这种方式,选择了包括卷积滤波器、激活函数和数据池化方法的优化模型,并使用该模型将HRV PSD推导为Conv_HF特征。

[0090] 如上文关于步骤203和303所讨论的,可能发生数据错误(例如,缺失的数据部分)。在处理器101检测到生命体征特征中的这种错误的情况下,该实施例中的处理器101试图补偿数据错误。如果以此方式纠正了数据错误,则在后续步骤中使用补偿的生命体征特征来执行睡眠阶段检测。但是,如果数据错误仍然存在,则将该时期标识为“未知”,以保持睡眠阶段检测的可靠性。图6(a)至6(c)示出了处理器101相对于生命体征特征补偿数据错误的各个场景。生命体征特征被列举为采取一系列特征值的形式,每个特征值与相应的时期相对应。

[0091] 在图6(a)中,处理器101检测到生命体征特征601中没有缺失的特征值。不执行任何补偿,并且在后续步骤(例如,算法运算)602中使用生命体征特征的特征值。在图6(b)中,处理器101检测到生命体征特征603中具有三个为零的缺失特征值,其中两个是连续的。处理器101通过针对具有前一特征值和后一特征值的每个中间特征值,选择三个特征值中的最大特征值以形成补偿的生命体征特征605的新的特征值序列,来补偿缺失的特征值。这样的技术可以称为“最大池化”604。在后续步骤606(例如,算法运算)中接着使用补偿的生命体征特征605。在图6(c)中,处理器101检测到生命体征特征607中具有四个为零的缺失特征

值,其中三个是连续的。处理器101使用最大池化608以类似的方式补偿缺失的特征值,从而产生补偿的生命体征特征609,在该场景中,这三个连续的缺失特征值在补偿后导致补偿的生命体征特征609中出现另一为零的特征值。由于数据错误持续存在,因此处理器101在步骤610返回未知睡眠阶段(在此情况下由特征值“0”表示)中具有持续性错误的时期(阴影块),以保持睡眠阶段检测的可靠性。应当注意,也可应用其他形式的数据错误校正或补偿。

[0092] 上面讨论的方法200的步骤205涉及使用模型来计算每个时期的睡眠阶段。图7示出了示例场景,其中处理器101在步骤205中根据三个生命体征特征701a-701c(例如,分别为心率、脉冲波形变异性和心率变异性的卷积高频功率)计算每个中间时期的睡眠阶段,其中每个生命体征特征701a-701c由相应的特征值序列 v_1-v_{11} 表示(图7中针对每个生命体征特征701a-701c仅示出11个特征值)。对于每个生命体征特征701a-701c,处理器101执行相应的逻辑回归运算 $701a'-701c'$,以基于对应的特征值 v_6 和相邻时期的特征值 v_1-v_5, v_7-v_{11} 计算每个中间时期(即,所述时期中的每个中间时期)的指示值702a-702c。相邻时期是在时间上邻近相应的中间时期的时期。在这种情况下,相邻时期包括五个先前时期(与相应的特征值 v_1-v_5 相对应),它们是紧接在中间时期(与特征值 v_6 相对应)之前的五个时期,以及五个后续时期(与相应的特征值 v_7-v_{11} 相对应),它们是紧接在中间时期之后的五个时期。但是,在其他实施例中,相邻时期可以包括任何数量(例如1、2或3)的先前时期和后续时期。每个指示值702a-702c描述或指示相应的中间时期的睡眠阶段。

[0093] 在该实施例中,每个逻辑回归运算 $701a'-701c'$ 由处理器101使用(或参考)表示权重和sigmoid函数的相应模型来执行。也就是说,对于每个生命体征特征701a-701c,处理器101执行相应的逻辑回归运算 $701a'-701c'$,以基于对应的特征值 v_6 以及所述时期中的相邻时期的特征值 v_1-v_5, v_7-v_{11} 计算所述时期中的每个中间时期的指示值702a-702c。这样计算出的指示值702a-702c描述或指示对应的中间时期的睡眠阶段。更具体地,对于每个模型,模型包括多个权重和sigmoid函数。权重的数量与先前/中间和后续时期的总数相对应,在该实施例中,总数为11。在该实施例中,模型将同一sigmoid函数与相应的权重集一起使用。一个模型的权重集可能与另一模型的权重集不同。如本文所使用的,术语“权重”和“多个权重”分别是指“权重值”和“多个权重值”。如上所述,每个生命体征特征的权重表示最佳地或理想地表示或描述特定时期的睡眠阶段的生命体征特征的特征值的关系(线性组合)。因此,一个生命体征特征的每个这样的线性组合可以与另一生命体征特征(HR、Conv_HF、PSV等)的线性组合相同或不同。

[0094] 在图7的相同示例中,在计算中间时期的指示值702a-702c之后,处理器101执行进一步的逻辑回归运算702',以基于对应的指示值702a-702c确定中间时期的睡眠阶段。进一步的逻辑回归运算702'使用独立于逻辑回归运算 $701a'-701c'$ 的模型分离或独立于这些模型的模型。具体地,处理器101对相应的中间时期的指示值702a-702c执行进一步的逻辑回归运算,以计算相应的中间时期的REM值703。对于相应的中间时期,如果REM值超过预定阈值(例如0.5),则处理器101确定该时期与REM相对应,否则,则确定与NREM相对应。在关于出现图6所讨论的数据缺失的情况下,确定时期与未知睡眠阶段相对应。每个逻辑回归运算 $701a'-701c'$ (在图7中以“回归”标记)可被视为第一阶段逻辑运算,而进一步的逻辑运算702'(在图7中以“进一步回归”标记)可被视为第二阶段逻辑运算。

[0095] 可以理解,每个逻辑回归运算 $701a'-701c'$ 都依赖于从输入生理信号(例如,PPG信

号)中提取的相应的生命体征特征的特征值,以计算每个时期的相应指示值702a-702c。然后,进一步的逻辑回归运算702'将每个时期的结果指示值702a-702c作为输入,以计算该时期的REM值703。在该实施例中,进一步的逻辑回归运算702'使用与运算701a'-701c'相同,但是权重不同的同一sigmoid运算。

[0096] 值得注意的是,可以使用指示值702a-702c中的至少两个来执行进一步的逻辑回归运算702'。也就是说,在特定时期的指示值702a-702c之一例如由于补偿不成功或未补偿而非描述性的或者是不确定的(例如,值为零)时,进一步的逻辑回归运算702'基于特定时期的指示值702a-702c中的其他两个执行。也就是说,如果指示值702a-702c之一描述特定时期的睡眠阶段,则进一步基于指示值702a-702c中的所述一个指示值进一步执行进一步的逻辑回归运算702'。换句话说,进一步的逻辑回归运算702'需要描述对应的时期的至少两个指示值,从而允许从进一步的逻辑回归运算702'中省略任何附加的非描述性指示值。这防止或减少了睡眠阶段检测的准确性受到非描述睡眠阶段的指示值的不利影响,这些指示值可能由于传感器检测失败而引起的。为了促进这一点,逻辑回归运算701a'-701c'可以使用彼此独立或彼此分离的模型。

[0097] 在该实施例中,以逻辑回归的滑动窗口(11个时期)的方式针对每个中间时期顺序地执行图7的过程。参考图8,处理器101相对于每个生命体征特征701a-701c执行逻辑回归运算701a'-701c',以计算生命体征特征701a-701c的每个中间时期的指示值702a-702c。生命体征特征701a-701c之一的归一化特征值以折线图801示出。在由一系列块802表示的所有时期中,用于睡眠阶段计算的中间时期由相应的不带阴影的块802b和对角线阴影块802c表示。折线图801的归一化特征值的范围在该实施例中为-1至2,并且在其他实施例中可以具有不同的范围。由阴影块802a表示的前五个时期(被认为是非中间时期)分别被预先确定为具有零特征值并且被识别为NREM。这与睡眠会话以NREM时段开始,该时段的范围通常为30分钟至70分钟。以滑动窗口的方式,处理器101以上述方式针对睡眠会话的结尾(由斜线阴影块802c中的最后一个标记),为每个随后的中间时期依次计算指示值702a-702c。折线图803中示出了计算出的指示值702a-702c。

[0098] 为了针对具有少于五个后续时期的最后五个时期(由斜线阴影块802c标记)执行计算,将生命体征特征701a-701c扩展五个扩展时期(未示出),这五个扩展时期的特征值镜像了最后五个时期的特征值。折线图801末尾的虚线部分(在图8中用“AA”标记)与扩展时期相对应,并镜像了与位于扩展时期之前的最后五个时期相对应的实线部分(在图8中用“BB”标记)。另外可以将虚线部分(“AA”)视为与扩展时期相连的最后五个时期的实线部分(“BB”)的翻转或镜像延伸。因此,出于计算的目的,睡眠会话末尾处的最后五个时期(即,斜线阴影块802c)也用作中间时期。以上述方式,计算生命体征特征701a-701c的相应的中间时期的指示值702a-702c。在其他实施例中,每个中间时期的指示值702a-702c的计算可以考虑任何相等或不等数量的先前时期和后续时期。例如,先前时期和后续时期的数量可以是两个,由此,为了计算每个中间时期的指示值,使用五个时期。

[0099] 图9是示出三个生命体征特征(HR、Conv_HF和PSV)的折线图901、使用逻辑回归运算根据生命体征特征计算的指示值的折线图902、使用进一步逻辑回归运算根据指示值计算的REM值的折线图903、基于阈值从折线图903中导出的睡眠阶段信息的折线图904,以及用于与折线图904进行比较的参考睡眠信息的折线图905的图表。对于每个时期,如果对应

的REM值超过阈值(例如0.5),则确定该时期与REM相对应,否则,则确定该时期与NREM相对应。阈值可以不是0.5,具体取决于实现。

[0100] 图10是布兰德-奥特曼图,其中示出了根据图1的实施例,参考了50个晚上的参考睡眠阶段信息计算的REM值的误差百分比。x轴显示误差百分比的平均值,而y轴显示代表误差百分比的差的值。水平线显示0.09%的平均差异值,而水平线上方和下方的虚线分别显示-12.10和12.28的误差置信区间。水平线越接近零,点与水平线越近,则计算出的REM值越准确。

[0101] 图11示出了第一和第二行1110、1120,其中每一行包括以上述方式针对相应的测试对象确定的三个REM百分比直方图。在该示例中,测试对象是抑郁症患者,在其他应用中,测试对象可以是希望调整其睡眠模式的健康人。每行1110、1120包括与第一时段(标记为“时段1”)相对应的第一直方图1111、1121;与第一时段之后的第二时段(标记为“时段2”)相对应的第二直方图1112、1122;以及与第二时段之后的第三时段(标记为“时段3”)相对应的第三直方图1113、1123。第一行1110的测试对象在第一时段之前,在第一和第二时段之间,以及在第二和第三时段之间接收相同的未调整剂量的抗惊厥药物。第二行1120的测试对象在第一时段之前接收初始剂量的抗惊厥药物,在第一时段和第二时段之间接收剂量增加的抗惊厥药物,并且在第二时段和第三时段之间接收剂量进一步增加的抗惊厥药物。可以观察到,第二行1120的患者继续高频率地出现具有高REM百分比范围的睡眠。在这种情况下,第一、第二和第三时段中的每个时段代表完整的睡眠周期(即完整的睡眠会话)。在其他应用中,每个时段可代表更多的睡眠周期。不同的测试对象可能具有不同长度的完整睡眠周期。

[0102] 直方图1111-1113、1121-1123表示的信息可用作确定规定的医疗剂量或剂量的基础,这些医疗剂量或剂量将被提供给测试对象,以调整测试对象经历的REM范围和频率。规定的医疗剂量或剂量可涉及抗惊厥药物、苯二氮平类药物和马西洋,或者任何能够减轻失眠的受体激动剂。

[0103] 具体地,根据一个实施例的评估对医疗剂量的反应性的方法包括:接收第一时段的睡眠阶段信息;接收第二时段的睡眠阶段信息,以与第一时段的睡眠阶段信息进行比较;并且基于比较结果评估对在第一时间段和第二时段之间出现的医疗剂量的反应性。在第一行1110的测试对象的示例中,在第二时段和第三时段之间,可以通过接收并比较第一和第二时段的睡眠阶段信息来评估测试对象对在第一和第二时段之间出现的未调整的医疗剂量的反应性。在第二行1120的测试对象的示例中,在第二和第三时段之间,可以通过接收并比较第一和第二时段的睡眠阶段信息来评估测试对象对在第一和第二时段之间出现的增加的医疗剂量的反应性。评估的结果可用作维持或调整在第二和第三时段之间出现的进一步的医疗剂量的基础,在第三时段之后评估测试对象对进一步的医疗剂量的反应性。然后可以理解,根据一个实施例的推导医疗剂量的方法包括:接收第一时段的睡眠阶段信息;接收第二时段的睡眠阶段信息,以与第一时段的睡眠阶段信息进行比较;并基于比较结果提供医疗剂量。

[0104] 图12A以手表或可穿戴设备1200的形式示出了图1的计算设备100的实施例。进一步参考图12B和12C,可穿戴设备1200包括头部组件1210,头部组件1210除了其他组件之外,还包括的两个生理传感器1211(其中一个为图1的生理传感器104)、照明元件1212和无线通

信模块1213。生理传感器1211和照明元件1212共同形成与处理器101可操作地关联的生理传感器104。无线通信模块1213用于提供与处理器101相关联的通信接口105的无线功能。固件芯片102和/或存储设备103可以存储用于使处理器101执行方法200至500的任何步骤的指令。例如,为了实现步骤201,生理传感器1211和照明元件1212由处理器101控制以捕获穿戴可穿戴设备1200的用户的生理信号。此外,在可穿戴设备1200执行步骤205的情况下,处理器101经由无线通信模块1213以无线的方式提供每个时期的计算出的睡眠阶段。以此方式发送的计算出的睡眠阶段可以构成睡眠阶段信息。进一步参考图13,另一计算设备1300(例如,具有类似于图1所示的组件的个人计算机或服务器设备)可以以无线的方式从可穿戴设备1200接收这些第一和第二时段的睡眠阶段信息。并比较所接收的睡眠阶段信息。然后,计算设备1300可以基于比较的结果提供医疗剂量,或者可以基于比较结果评估对在第一时段和第二时段之间出现的医疗剂量的反应性。

[0105] 在涉及单个生命体征特征(例如,第一生命体征特征701a)的替代实施例中,由于由对应的第一逻辑回归运算701a'产生的中间时期的第一指示值702a描述了中间时期的睡眠阶段,因此可以省略进一步的逻辑回归运算702',并且第一指示值702a可用作用于确定睡眠阶段的REM值703。




图1

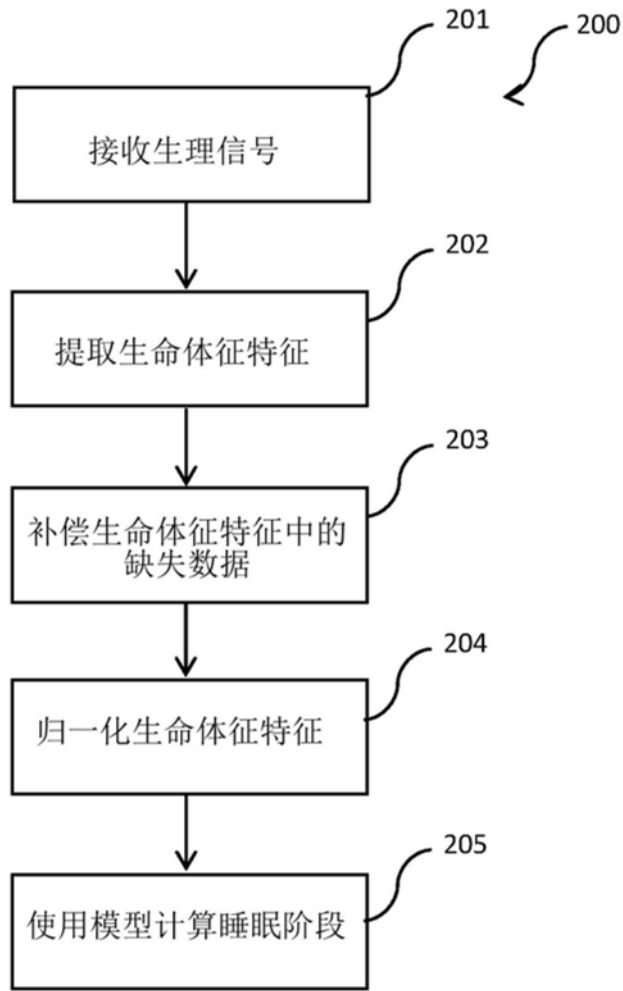


图2

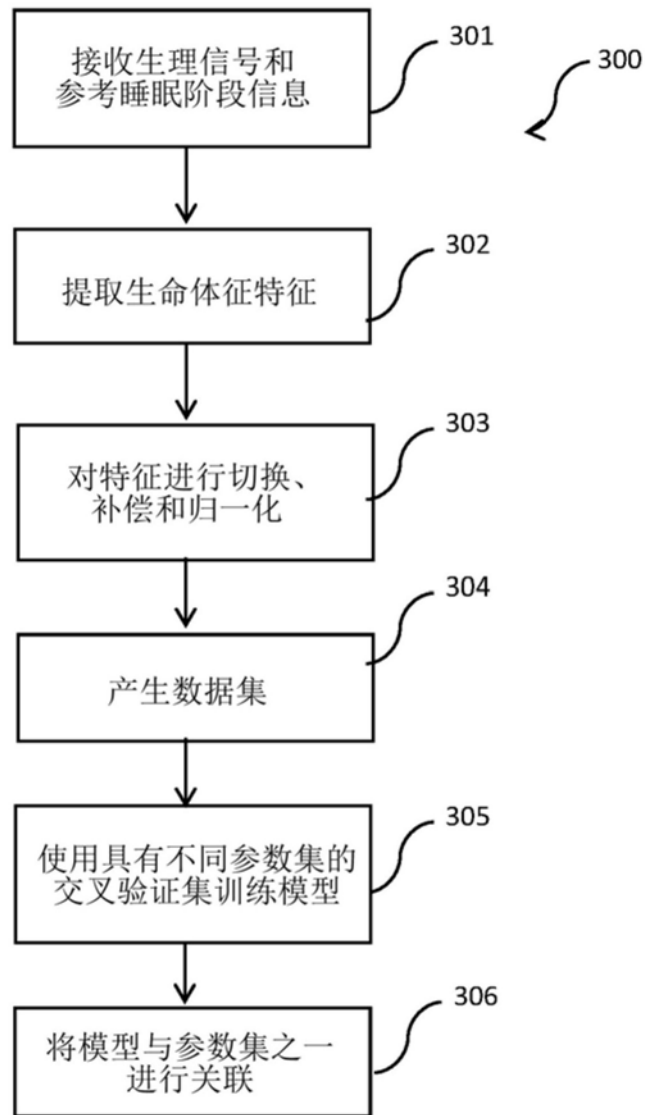


图3A

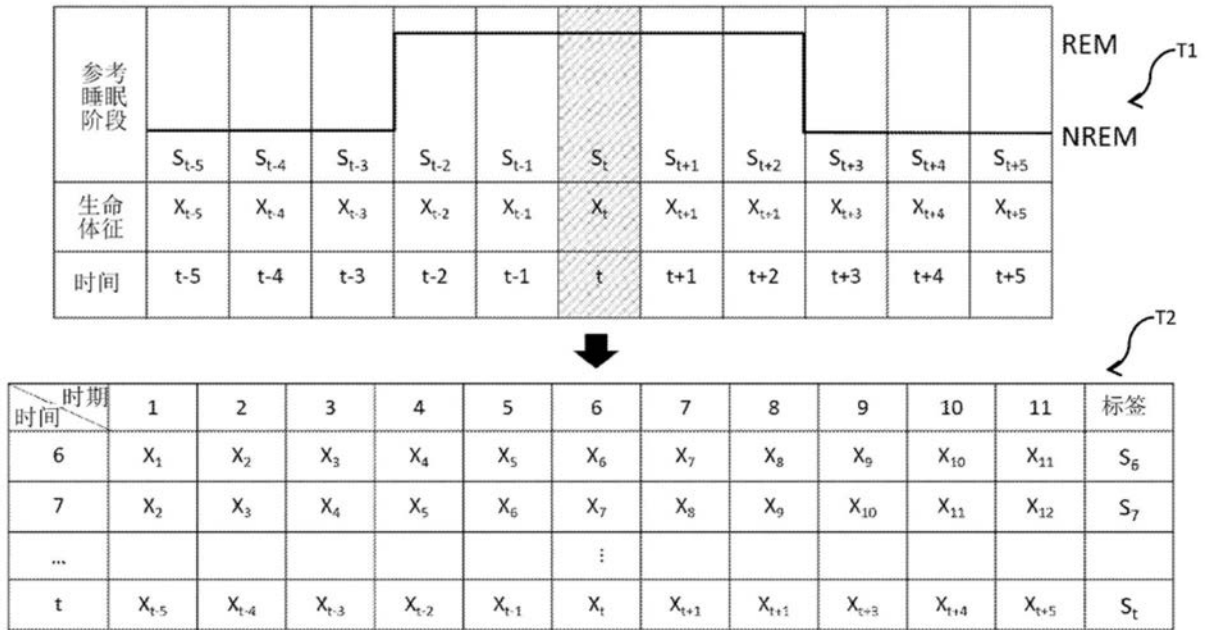


图3B

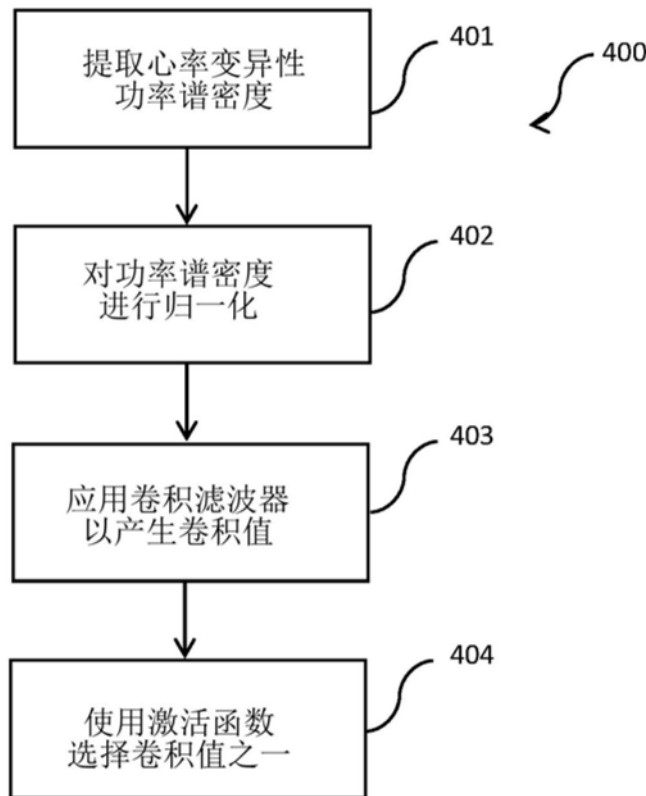


图4

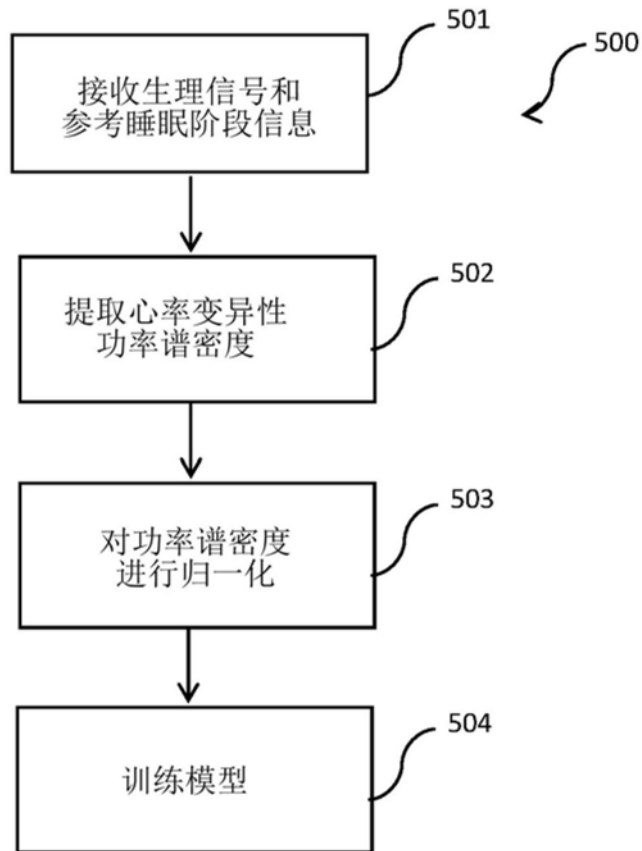


图5

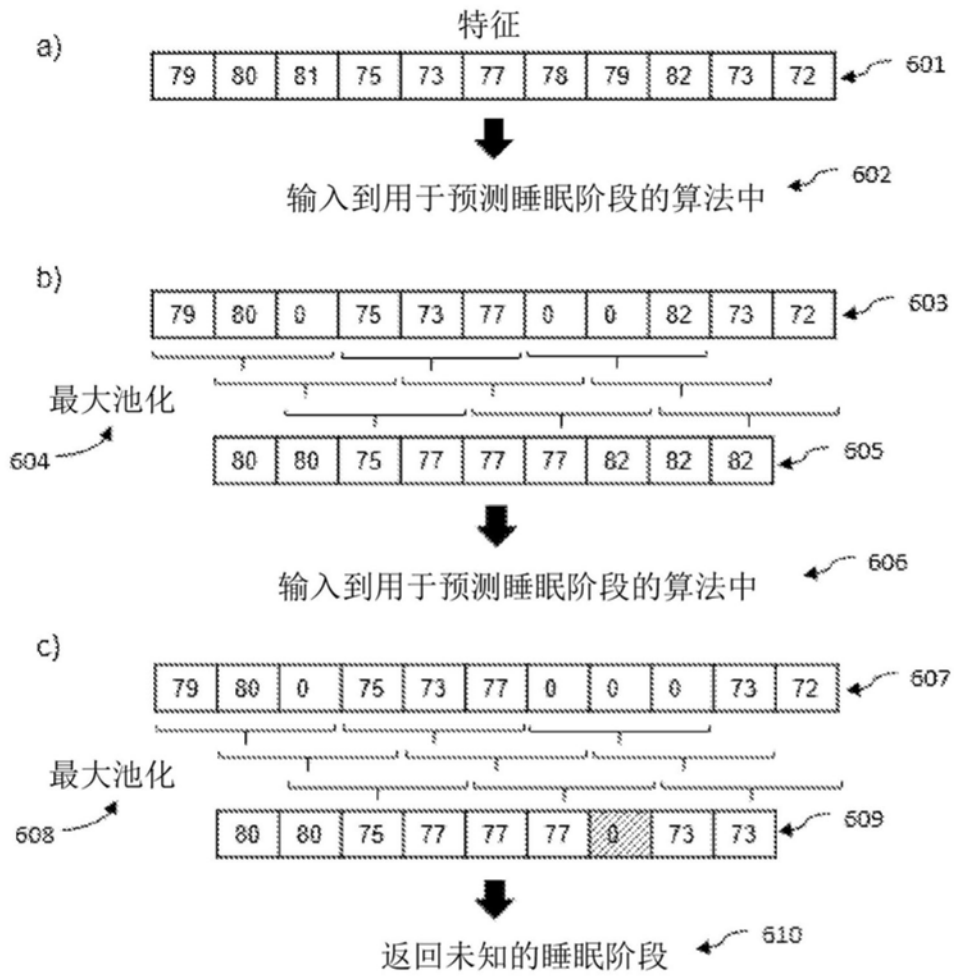


图6




图7




图8

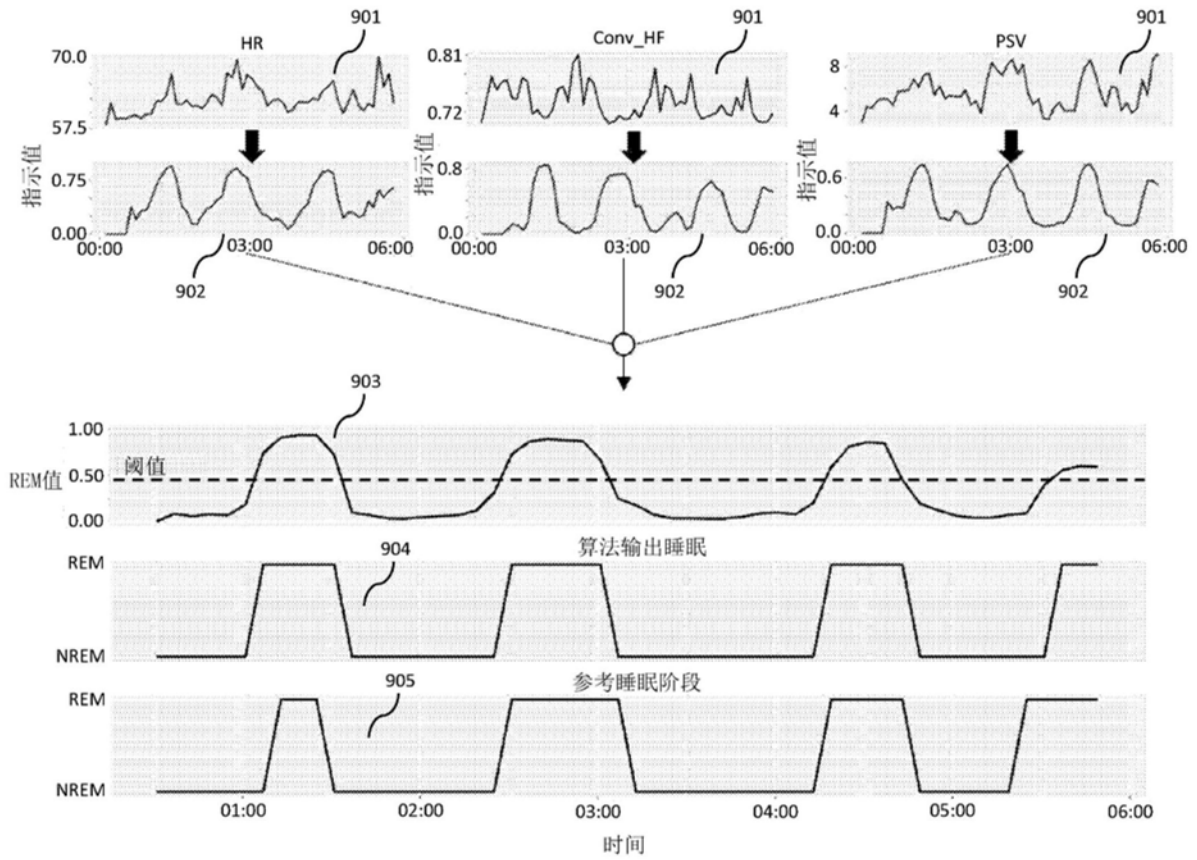


图9




图10




图11




图12A




图12B




图12C




图13