



(12) 发明专利申请

(10) 申请公布号 CN 116188366 A

(43) 申请公布日 2023.05.30

(21) 申请号 202211548788.0

G06V 10/82 (2022.01)

(22) 申请日 2022.12.05

G06N 3/08 (2023.01)

(71) 申请人 中国科学院深圳先进技术研究院

G06N 3/0464 (2023.01)

地址 518000 广东省深圳市南山区西丽深
圳大学城学苑大道1068号

(72) 发明人 王书强 孔恒 陈绪行 潘治文

(74) 专利代理机构 深圳五邻知识产权代理事务

所(普通合伙) 44590

专利代理人 祝丹晴

(51) Int.Cl.

G06T 7/00 (2017.01)

G06T 7/11 (2017.01)

G06V 10/24 (2022.01)

G06V 10/774 (2022.01)

G06V 10/764 (2022.01)

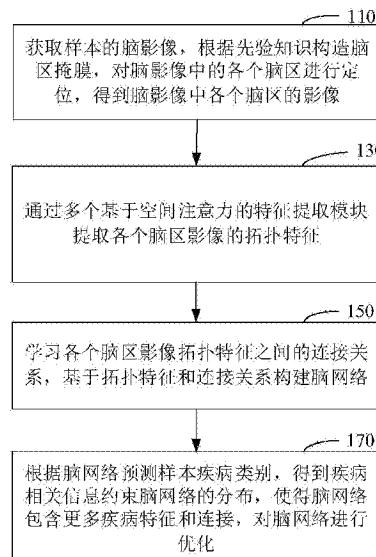
权利要求书2页 说明书11页 附图6页

(54) 发明名称

知识和数据驱动的脑网络计算方法、装置、
电子设备及存储介质

(57) 摘要

本发明实施例公开了一种知识和数据驱动的脑网络计算方法及装置，所述方法包括：获取样本的脑影像，根据先验知识构造脑区掩膜，对脑影像中的各个脑区进行定位，得到脑影像中各个脑区的影像；通过多个基于空间注意力的特征提取模块提取各个脑区影像的拓扑特征；学习各个脑区影像的拓扑特征之间的连接关系，基于拓扑特征和连接关系构建脑网络，所述脑网络由节点和边构成，所述节点表示各个脑区，所述边表示各个脑区之间的脑连接强度；根据脑网络预测样本疾病类别，得到疾病相关信息约束脑网络的分布，使得脑网络包含更多疾病特征和连接，对脑网络进行优化。本发明解决了现有脑网络计算方法适用范围小，兼容性差，主观性强，计算成本高，效率和准确率低的问题。



A

66

CN 116188366

CN

1. 一种知识和数据驱动的脑网络计算方法,其特征在于,所述方法包括:

获取样本的脑影像,根据先验知识构造脑区掩膜,对所述脑影像中的各个脑区进行定位,得到所述脑影像中各个脑区的影像;

通过多个基于空间注意力的特征提取模块提取所述各个脑区影像的拓扑特征;

学习所述各个脑区影像的拓扑特征之间的连接关系,基于所述拓扑特征和连接关系构建脑网络,所述脑网络由节点和边构成,所述节点表示各个脑区,所述边表示各个脑区之间的脑连接强度;

根据脑网络预测样本疾病类别,得到疾病相关信息,基于所述疾病相关信息约束脑网络的分布,使得脑网络包含更多疾病特征和连接,对脑网络进行优化。

2. 如权利要求1所述的方法,其特征在于,所述根据脑网络预测样本疾病类别,得到疾病相关信息,基于所述疾病相关信息约束脑网络的分布,使得脑网络包含更多疾病特征和连接,对脑网络进行优化之后,包括:

根据优化后的脑网络和疾病相关信息对所述样本进行疾病类别预测,得到所述样本的疾病预测结果。

3. 如权利要求1所述的方法,其特征在于,所述根据先验知识构造脑区掩膜,对所述脑影像中的各个脑区进行定位,得到所述脑影像中各个脑区的影像,包括:

根据先验知识得到脑影像中各个脑区影像的中心点坐标和相对体积大小;

根据各脑区影像的中心点坐标和相对体积大小构造各个脑区影像的掩膜;

根据脑影像与各个脑区影像的掩膜,得到所述脑影像中各个脑区的影像。

4. 如权利要求1所述的方法,其特征在于,所述通过多个基于空间注意力的特征提取模块提取所述各个脑区影像的拓扑特征,包括:

使用卷积层提取简单的初级拓扑特征,扩展通道数并降低各个脑区影像的尺寸;

使用多个基于空间注意力的特征提取模块逐级提取各个脑区影像的拓扑特征。

5. 如权利要求4所述的方法,其特征在于,所述基于空间注意力的特征提取模块包括多个深度卷积块和点卷积块。

6. 如权利要求1所述的方法,其特征在于,所述根据脑网络预测样本疾病类别,得到疾病相关信息,基于所述疾病相关信息约束脑网络的分布,使得脑网络包含更多疾病特征和连接,对脑网络进行优化,包括:

获取脑网络中的高维拓扑特征;

将多个高维拓扑特征拼接得到分类特征,根据所述分类特征对所述样本进行疾病类别预测,得到疾病相关信息,基于所述疾病相关信息约束脑网络的分布,使得脑网络包含更多疾病特征和连接,对脑网络进行优化。

7. 如权利要求1至6任一项所述的方法,其特征在于,所述方法用于训练疾病预测模型,所述疾病预测模型包括基于解剖学知识的脑区感知模块、脑疾病拓扑特征提取模块、脑连接学习模块和脑疾病预测模块,各模块是经过训练、且具有相应预测能力的机器学习模型。

8. 一种知识和数据驱动的脑网络计算装置,其特征在于,所述装置包括:

基于解剖学知识的脑区感知模块,用于根据先验知识构造脑区掩膜,对脑影像中的各个脑区进行定位,得到脑影像中各个脑区的影像;

脑疾病拓扑特征提取模块,用于通过多个基于空间注意力的特征提取模块提取各个脑

区影像的拓扑特征；

脑连接学习模块，用于学习各个脑区影像的拓扑特征之间的连接关系，基于拓扑特征和连接关系构建脑网络；

脑疾病知识学习模块，用于根据脑网络预测样本疾病类别，得到疾病相关信息，约束脑网络的分布，使得脑网络包含更多疾病特征和连接，对脑网络进行优化。

9. 一种电子设备，其特征在于，包括：至少一个处理器、至少一个存储器、以及至少一条通信总线，其中，

所述存储器上存储有计算机程序，所述处理器通过所述通信总线读取所述存储器中的所述计算机程序；

所述计算机程序被所述处理器执行时实现权利要求1至7中任一项所述的知识和数据驱动的脑网络计算方法。

10. 一种存储介质，其上存储有计算机程序，其特征在于，所述计算机程序被处理器执行时实现如权利要求1至7中任一项所述的知识和数据驱动的脑网络计算方法。

知识和数据驱动的脑网络计算方法、装置、电子设备及存储介质

技术领域

[0001] 本发明涉及医学影像处理技术领域，尤其涉及一种知识和数据驱动的脑网络计算方法、装置、电子设备及存储介质。

背景技术

[0002] 蕴含疾病相关特征和连接的脑网络不仅有助于提升神经退行性疾病的诊断效果，而且为分析疾病不同阶段的脑网络异常连接、变化趋势等提供了前提条件。例如，早期阿尔兹海默病患者会表现出脑部连接的变化特征，这些变化特征通过结构磁共振技术反映出来，临床上的脑成像检查现在主要用于查找除阿尔兹海默病之外病症中的可见异常，排除其他疾病对诊断的干扰，无法做到精确诊断。相比之下，利用脑网络可以提供更准确的结果，因为脑网络代表了神经活动的全面映射。

[0003] 然而，现有的相关技术只能构建单一的脑网络，使用范围小，不利于推广使用，现有的脑网络构建方法依赖于软件模板，通过手动设置不同的预处理参数，构建脑区之间连接关系，包含了大量冗余的连接信息，而且没有突显出疾病相关的异常脑连接与特征，主观性强，导致脑连接的计算误差大，疾病预测的准确率低。

[0004] 除此之外，现有的脑网络构建方法需要复杂的脑影像预处理过程和脑连接计算过程，时间成本和计算成本高，效率低。

[0005] 因此，急需一种适用范围广，可兼容性强，客观性强，计算成本低，效率和准确率高的知识和数据驱动的脑网络计算方法。

发明内容

[0006] 本发明各实施例提供一种知识和数据驱动的脑网络计算方法、装置、电子设备及存储介质，以解决相关技术中存在的适用范围小，兼容性差，主观性强，计算成本高，效率和准确率低的问题。

[0007] 其中，本发明所采用的技术方案为：

[0008] 根据本发明的一个方面，一种知识和数据驱动的脑网络计算方法，所述方法包括：获取样本的脑影像，根据先验知识构造脑区掩膜，对所述脑影像中的各个脑区进行定位，得到所述脑影像中各个脑区的影像；通过多个基于空间注意力的特征提取模块提取所述各个脑区影像的拓扑特征；学习所述各个脑区影像的拓扑特征之间的连接关系，基于所述拓扑特征和连接关系构建脑网络，所述脑网络由节点和边构成，所述节点表示各个脑区，所述边表示各个脑区之间的脑连接强度；根据脑网络预测样本疾病类别，得到疾病相关信息，基于所述疾病相关信息约束脑网络的分布，使得脑网络包含更多疾病特征和连接，对脑网络进行优化。

[0009] 根据本发明的一个方面，一种知识和数据驱动的脑网络计算装置，所述装置包括：基于解剖学知识的脑区感知模块，用于根据先验知识构造脑区掩膜，对脑影像中的各个脑

区进行定位,得到脑影像中各个脑区的影像;脑疾病拓扑特征提取模块,用于通过多个基于空间注意力的特征提取模块提取各个脑区影像的拓扑特征;脑连接学习模块,用于学习各个脑区影像的拓扑特征之间的连接关系,基于拓扑特征和连接关系构建脑网络;脑疾病知识学习模块,用于根据脑网络预测样本疾病类别,得到疾病相关信息,约束脑网络的分布,使得脑网络包含更多疾病特征和连接,对脑网络进行优化。

[0010] 根据本发明的一个方面,一种电子设备,包括处理器及存储器,所述存储器上存储有计算机可读指令,所述计算机可读指令被所述处理器执行时实现如上所述的知识和数据驱动的脑网络计算方法。

[0011] 根据本发明的一个方面,一种存储介质,其上存储有计算机程序,所述计算机程序被处理器执行时实现如上所述的知识和数据驱动的脑网络计算方法。

[0012] 根据本发明的一个方面,一种计算机程序产品,计算机程序产品包括计算机程序,计算机程序存储在存储介质中,计算机设备的处理器从存储介质读取计算机程序,处理器执行计算机程序,使得计算机设备执行时实现如上所述的知识和数据驱动的脑网络计算方法。

[0013] 在上述技术方案中,本发明实现了适用范围广,效率和准确率高的知识和数据驱动的脑网络计算方法。

[0014] 具体而言,本发明首先利用解剖学知识构造可学习的脑区掩模通过基于解剖学知识的脑区感知模块对脑影像进行脑区划分,克服了神经退行性疾病病变过程中不同程度的脑区萎缩带来的脑区定位困难问题;然后通过脑疾病拓扑特征提取模块获取每个脑区的拓扑特征,在提取特征的过程中采用空间注意力机制对脑区进行二次定位,细化每个脑区的边界,克服了脑区与拓扑特征之间不对应的问题;其次,利用脑连接学习模块学习脑区拓扑特征之间的连接关系,基于提取的拓扑特征和学习到的连接关系构建完整的脑网络,有效地拟合脑网络的真实分布,克服了现有技术中效率和准确率不高的问题;最后,以学习到的脑网络作为脑疾病知识学习模块的输入对脑网络进行优化。将优化后的脑网络输入脑疾病预测模块得到疾病预测结果,实现了端到端地从多种模态的脑影像中生成多种类型的脑网络,适用范围广,可兼容性强,客观性强,计算成本低。

[0015] 应当理解的是,以上的一般描述和后文的细节描述仅是示例性和解释性的,并不能限制本发明。

附图说明

[0016] 此处的附图被并入说明书中并构成本说明书的一部分,示出了符合本发明的实施例,并于说明书一起用于解释本发明的原理。

[0017] 图1是根据一示例性实施例示出的一种知识和数据驱动的脑网络计算方法的流程图;

[0018] 图2是图1对应实施例中步骤110在一个实施例的示意图;

[0019] 图3是图1对应实施例中步骤130在一个实施例的示意图;

[0020] 图4是图3对应实施例中特征提取模块的结构流程示意图;

[0021] 图5是图1对应实施例中步骤150在一个实施例的示意图;

[0022] 图6是图1对应实施例中步骤170在一个实施例的示意图;

[0023] 图7是根据一示例性实施例示出的一种基于知识和数据驱动的脑网络计算方法训练疾病预测模型的流程图；

[0024] 图8是图7对应实施例中基于知识和数据驱动的脑网络计算方法训练后的疾病预测模型的结构流程图；

[0025] 图9是根据一示例性实施例示出的一种知识和数据驱动的脑网络计算装置的框图；

[0026] 图10是根据一示例性实施例示出的一种电子设备的硬件结构图；

[0027] 图11是根据一示例性实施例示出的一种电子设备的框图。

[0028] 通过上述附图，已示出本发明明确的实施例，后文中将有更详细的描述，这些附图和文字描述并不是为了通过任何方式限制本发明构思的范围，而是通过参考特定实施例为本领域技术人员说明本发明的概念。

具体实施方式

[0029] 这里将详细地对示例性实施例执行说明，其示例表示在附图中。下面的描述涉及附图时，除非另有表示，不同附图中的相同数字表示相同或相似的要素。以下示例性实施例中所描述的实施方式并不代表与本发明相一致的所有实施方式。相反，它们仅是与如所附权利要求书中所详述的、本发明的一些方面相一致的装置和方法的例子。

[0030] 现有的相关技术依赖各种软件工具包，而且一种工具包只能从特定模态的脑影像中构建一种脑网络，适用范围小，灵活性差且不利于推广使用。

[0031] 同时，现有的相关技术不仅需要依赖经验设置大量的参数，主观性较强，而且重建的脑网络中包含了大量冗余的信息，并没有突显出异常的脑连接，导致疾病预测准确率不高，且需要复杂的预处理管道和计算过程才能重建脑连接，需要消耗大量的时间和计算资源。

[0032] 由上可知，相关技术中仍存在适用范围小，兼容性差，主观性强，计算成本高，效率和准确率低的缺陷。

[0033] 为此，本申请提供的知识和数据驱动的脑网络计算方法在基于解剖学知识的基于解剖学知识的脑区感知模块中，利用先验知识构造可学习的脑区掩模对脑影像中的每个脑区进行模糊定位，克服疾病病变过程中不同程度的脑区萎缩带来的脑区定位困难问题；在脑疾病拓扑特征提取模块中，使用轻量级的卷积神经网络提取脑区的拓扑特征，并且在提取特征的过程中采用空间注意力机制对脑区进行二次定位，细化每个脑区的边界，保证提取的拓扑特征来自特定的脑区；在脑连接学习模块中，采用生成式学习策略学习脑区拓扑特征之间的连接关系，基于提取的拓扑特征和学习到的连接关系构建完整的脑网络，拟合脑网络的真实分布；在脑疾病知识学习模块中，采用并行的多层图卷积神经网络同时捕获脑网络中潜在的复杂交互特征优化脑网络，本发明从多个方面提高脑网络构建的准确性，从而提升疾病预测的准确性，该知识和数据驱动的脑网络计算方法适用于疾病预测模型和知识和数据驱动的脑网络计算装置、该疾病预测模型和知识和数据驱动的脑网络计算装置可部署于配置冯诺依曼体系结构的电子设备，例如，该电子设备可以是台式电脑、笔记本电脑、服务器等等。

[0034] 请参阅图1，本申请实施例提供了一种知识和数据驱动的脑网络计算方法，该方法

适用于电子设备,例如,该电子设备可以是台式电脑、笔记本电脑、服务器等等。

[0035] 在下述方法实施例中,为了便于描述,以该方法各步骤的执行主体为电子设备为例进行说明,但是并非对此构成具体限定。

[0036] 如图1所示,该方法可以包括以下步骤:

[0037] 步骤110,获取样本的脑影像,根据先验知识构造脑区掩膜,对脑影像中的各个脑区进行定位,得到脑影像中各个脑区的影像。

[0038] 具体地,根据先验知识得到脑影像中各个脑区影像的中心点坐标和相对体积大小,根据各个脑区影像的中心点坐标和相对体积大小构造各个脑区影像的掩膜,根据脑影像与各个脑区影像的掩膜,得到脑影像中各个脑区的影像。

[0039] 在一个可能的实现方式,先验知识表示解剖学知识,人脑相关生理知识等,此处不做限定。

[0040] 在一个可能的实现方式,请参阅图2,根据解剖学知识,将N各脑区的中心点坐标和相对体积大小输入基于解剖学知识的基于解剖学知识的脑区感知模块,构造每个脑区的掩膜,将脑影像与掩膜进行元素级相乘得到每个脑区的影像。

[0041] 构造脑区掩膜的公式具体如下:

$$[0042] ROI_i(X, Y, Z) = \phi(x_i, y_i, z_i, v_i; \theta_i) = e^{-\frac{((X-x_i)^2 + (Y-y_i)^2 + (Z-z_i)^2)}{2v_i(\theta_i)^2}}$$

[0043] 其中,ROI_i表示第i个脑区的掩模,X,Y,Z分别表示3个维度的坐标,(x_i,y_i,z_i,v_i)表示第i个脑区的解剖学知识,θ_i表示构造ROI_i时的可学习参数。

[0044] 获得脑区影像的公式具体如下:

$$[0045] dti_i = DTI \times ROI_i$$

[0046] 其中,dti_i表示第i个脑区的影像数据。

[0047] 经过上述过程,利用可学习的脑区掩模对脑影像中的每个脑区进行模糊定位,克服了疾病病变过程中不同程度的脑区萎缩带来的脑区定位困难问题,保证后续提取的拓扑特征与脑区一一对应,进而提高了脑网络构建的准确性。

[0048] 步骤130,通过多个基于空间注意力的特征提取模块提取各个脑区影像的拓扑特征。

[0049] 具体地,使用卷积层提取简单的初级拓扑特征,扩展通道数并降低各个脑区影像的尺寸,使用多个基于空间注意力的特征提取模块逐级提取各个脑区影像的拓扑特征。

[0050] 在一个可能的实现方式,请参阅图3,由于经过初步脑区定位的脑区影像数据是3维的单通道影像,我们先使用2个卷积层提取简单的初级拓扑特征,扩展通道数并降低脑区影像的尺寸,使用M个基于空间注意力的特征提取模块(SAFE-block)作为核心模块逐级提取每个脑区白质纤维束的拓扑特征。

[0051] 其中,特征提取模块(SAFE-block)的结构设计流程如图4所示,F_{in} ∈ R^{C×H×W×D}为输入特征图,H×W×D为特征图的尺寸,C为特征图的通道数量。首先使用一个卷积层Point-Wise Conv层来降低通道数量,然后使用卷积层Depth-Wise Conv层提取每个通道的特征得到特征图F₁ ∈ R^{C/2×H×W×D},之后引入空间注意力层对脑区进行精准定位,分别对特征图F₁进行通道维度的全局平均池化(AvgPool)和最大池化(MaxPool)得到两个1×H×W×D的通道表示,并将这两个通道表示拼接在一起,然后经过一个激活函数为Sigmoid的卷积层Conv层,

得到注意力图 a ,将注意力图 a 和 F_1 相乘得到特征图 $F_2 \in R^{C/2 \times H \times 2 \times D}$,然后使用Point-Wise Conv层将通道数量还原为 C ,并通过跳跃连接得到特征图 $F_3 \in R^{C \times H \times W \times D}$,加快信息前向传播的效率并缓解误差反向传播中的梯度消失问题,使用Conv层对通道数量和特征图的尺度进行调整得到输出特征图 $F_{out} \in R^{C' \times H' \times W' \times D'}$,使用一个Point-Wise Conv层来融合归纳所有通道的信息,得到一个单通道的特征图 F_i ,将 F_i 展平作为第 i 个脑区的拓扑特征 $v_i \in R^{1 \times d}$, d 表示特征维度,不断重复上述过程即可得到所有脑区的拓扑特征 $P \in R^{N \times d}$ 。

[0052] 经过上述过程,使用轻量级的卷积神经网络逐级提取脑区的拓扑特征,并且在提取特征的过程中采用空间注意力机制对脑区进行二次定位,细化每个脑区的边界,保证提取的拓扑特征来自特定的脑区,进而提高了脑网络构建的准确性。

[0053] 步骤150,学习各个脑区影像的拓扑特征之间的连接关系,基于拓扑特征和连接关系构建脑网络。

[0054] 具体地,如图5所示,脑网络由节点和边构成,其中节点代表独立的脑区,边表示脑区之间的脑连接强度,脑网络可以用一个图 $G = (A, P)$ 来表示,包含脑连接 A 和拓扑特征 P 两个要素。

[0055] 在一个可能的实现方式,使用一个可学习的参数矩阵 $M \in R^{d \times d}$ 和非线性映射函数 $e^{-|\cdot|}$ 从拓扑特征 $P \in R^{N \times d}$ 中学习脑连接 $A \in R^{N \times N}$ 。

[0056] 学习脑连接的具体公式如下:

$$[0057] A = e^{-\|PM\|^T P^T}.$$

[0058] 其中,可学习的参数矩阵 M 可以用一个不带偏置项的全连接层来实现,输入层和输出层的神经元数量都为 d ,通过这种计算方式,可以保证学习到的脑连接一定是非负的,而且满足对称条件,这也和脑连接的物理意义相符合,进而提高了脑网络构建的准确性。

[0059] 通过上述过程,利用生成式学习策略学习脑区拓扑特征之间的连接关系,并基于提取的拓扑特征和学习到的连接关系构建完整的脑网络,在生成脑网络时不仅提取每个脑区的拓扑特征构成了特征矩阵,而且基于拓扑特征学习了脑连接矩阵,为后续从拓扑特征和脑连接两个角度分析疾病发生过程的脑网络异常提供了基础,从而提高了疾病预测的准确性。

[0060] 步骤170,根据脑网络预测样本疾病类别,得到疾病相关信息,基于疾病相关信息约束脑网络的分布,使得脑网络包含更多疾病特征和连接,对脑网络进行优化。

[0061] 具体地,获取脑网络中的高维拓扑特征,将多个高维拓扑特征拼接得到分类特征,根据分类特征对样本进行疾病类别预测,得到丰富的疾病相关信息,指导知识和数据驱动的脑网络计算模型生成更符合真实分布的脑网络,使得脑网络包含更多疾病特征和连接,对脑网络进行优化。

[0062] 在一个可能的实现方式,如图6所示,由并行的多图卷积层(Multi-GCN)、平均池化层和全连接层3个子模块对生成的脑网络进行优化。

[0063] 其中,根据卷积神经网络(CNN)利用多个滤波器来捕获多个特征空间的思想设计了多图卷积层(Multi-GCN),通过并行的K个双层GCN同时捕获脑网络中潜在的复杂交互特征。

[0064] 具体计算公式如下:

[0065] $P_i = \text{ReLU}(A\text{ReLU}(APW_i^1)W_i^2)$ 。

[0066] 其中, $P_i \in R^{N \times d_2}$ 表示第 i 个双层GCN捕获的交互特征矩阵, $W_i^1 \in R^{d \times d_1}$ 和 $W_i^2 \in R^{d_1 \times d_2}$ 分别表示双层GCN中待训练的参数矩阵, ReLU为每层GCN的激活函数。

[0067] 其中,由于脑网络经过Multi-GCN滤波后拓扑特征的维度较高,直接将拓扑特征展平作为全连接层的输入会导致分类器中的待训练参数规模庞大,增加了训练难度和计算成本,因此,采用平均池化层来降低特征的维度,计算过程如下:

$$[0068] p_i = \frac{1}{N} \sum_{j=1}^N P_{ij}.$$

[0069] 其中, $p_i \in R^{1 \times d_2}$ 表示 P_i 经平均池化后得到的高阶拓扑特征, j表示第 j 个脑区。

[0070] 进一步地,将K个高阶拓扑特征拼接后得到分类特征 $p \in R^{3d_2}$, 输入一个全连接层进行分类,输入层的神经元数量为 $3d_2$,输出层神经元的数量为疾病种类C(C=5)。

[0071] 得到真实分布的脑网络后,可以使用生成的脑网络分析疾病的机理,开发生物标志物,可以突显出疾病相关的异常脑连接与特征,有利于分析神经退行性疾病病变过程中的脑网络连接异常以及变化模式,为神经退行性疾病的智能检测和溯源奠定坚实的基础。

[0072] 进一步地,使用疾病预测模块根据优化后的脑网络和疾病相关信息对所述样本进行疾病类别预测,得到所述样本的疾病预测结果,疾病预测的结果可用于临床诊断,疾病预测模块使用图池化策略对脑网络的高阶拓扑特征进行归纳,极大地提高了神经退行性疾病的分类精度,为疾病的早期筛查和个体精准化干预奠定了基础,且联合脑连接学习模块生成的脑连接与软件模板得到的经验脑连接之间的拓扑结构损失共同指导模型的训练,使疾病相关知识贯穿整个脑网络的构建过程,为从脑网络层面分析神经退行性疾病的致病机理提供了便利,本发明同时实现了脑网络生成分析和疾病预测功能。

[0073] 通过上述过程,本发明实施例提供了一种知识和数据驱动的脑网络计算方法,基于解剖学知识和空间注意力机制对脑影像进行脑区精准定位并提取脑疾病拓扑特征,然后结合生成式学习策略构建脑网络,挖掘脑疾病相关的异常脑连接与特征,为神经退行性疾病的早期筛查和精准化个性干预奠定基础,应用于神经退行性疾病的结构脑网络生成、异常脑连接分析和疾病预测。因此,本发明实施例能够实现适用范围广,效率和准确率高的脑网络生成分析和疾病预测。

[0074] 请参阅图7,本申请实施例提供了一种基于知识和数据驱动的脑计算方法的疾病预测模型的训练方法,该疾病该方法适用于电子设备,例如,该电子设备可以是台式电脑、笔记本电脑、服务器等等。

[0075] 在下述方法实施例中,为了便于描述,以该方法各步骤的执行主体为电子设备为例进行说明,但是并非对此构成具体限定。

[0076] 将每个脑影像和脑区解剖学知识(x,y,z,v)输入模型,经过基于解剖学知识的基于解剖学知识的脑区感知模块、脑疾病拓扑特征提取模块和脑连接学习模块后生成了脑网络,然后将脑网络输入脑疾病知识学习模块得到疾病分类结果对脑网络进行优化,该训练包含两种损失函数以及一个训练策略。

[0077] 具体地,由于神经退行性疾病会不同程度地萎缩脑区,只关注脑网络的全局拓扑结构,忽略局部拓扑结构会低估特定脑区在脑网络生成中的作用,因此,将模型生成的脑连接与经验脑连接之间的全局和局部拓扑结构差异作为拓扑结构损失。

[0078] 拓扑结构损失的公式如下:

$$[0079] L_{\text{topo}} = L_{g_topo} + L_{p_topo}.$$

[0080] 其中, L_{g_topo} 表示全局拓扑结构损失,通过脑连接A与经验脑连接 \hat{A} 之间的平均绝对误差(MAE)计算。

[0081] 平均绝对误差的公式如下:

$$[0082] L_{g_topo} = \frac{1}{n} \sum_{i=1}^n MAE(A_i, \hat{A}_i)$$

[0083] 其中, L_{p_topo} 表示局部拓扑结构损失,通过脑连接A与经验脑连接 \hat{A} 节点之间的接近中心度(CCD)差异计算 L_{p_topo} 。

[0084] 具体计算公式如下:

$$[0085] L_{p_topo} = \frac{1}{n} \sum_{i=1}^n MAE(CCD(A_i), CCD(\hat{A}_i))$$

[0086] 进一步地,将脑疾病知识学习模块输出的疾病分类标签l与真实标签 \hat{l} 之间的交叉熵损失作为分类损失,获取疾病相关信息。

[0087] 分类损失地具体公式如下:

$$[0088] L_{cla} = -\frac{1}{n} \sum_{i=1}^n p(\hat{l}|s_i) \log[q(l|s_i)]$$

[0089] 其中,n为输入样本数量, s_i 表示第i个样本的脑影像, $p(\hat{l}|s_i)$ 表示样本标签的实际分布, $q(l|s_i)$ 表示脑疾病知识学习模块预测的疾病标签的分布。

[0090] 本发明中,将所有样本按8:1:1的比例分为训练集、验证集和测试集,在训练集上训练模型,然后通过验证集选择最优的超参数,最后在测试集上对模型进行测试。训练过程分为两个步骤,首先固定基于解剖学知识的基于解剖学知识的脑区感知模块、脑疾病拓扑特征提取模块和脑连接学习模块,通过分类损失 L_{cla} 训练脑疾病知识学习模块的参数,保证脑疾病知识学习模块能够对生成的脑网络进行较为准确的分类,提取到丰富的疾病相关信息,然后固定脑疾病知识学习模块,通过超参数 α 将拓扑结构损失 L_{topo} 和分类损失 L_{cla} 进行加权求和训练基于解剖学知识的基于解剖学知识的脑区感知模块、脑疾病拓扑特征提取模块和脑连接学习模块的参数,拓扑结构损失使得模型生成的脑连接分布逐渐接近经验脑连接分布,分类损失则引入疾病相关知识对脑网络的拓扑特征和连接分布进行修正,使生成的脑网络包含更多的疾病相关信息,更加接近真实分布。

[0091] 加权求和的公式具体如下:

$$[0092] L_G = \alpha \times L_{topo} + (1-\alpha) \times L_{p_topo}.$$

[0093] 其中,超参数 α 控制着疾病相关知识对脑网络的影响程度, α 越大,疾病相关知识对脑网络的生成影响越大。

[0094] 进一步地,模型中的各个模块在训练中达到最优,基于解剖学知识的基于解剖学知识的脑区感知模块可以对每个脑区进行精准定位,脑疾病拓扑特征提取模块可以提取疾病相关的拓扑特征,脑连接学习模块可以生成更加符合真实分布的脑连接,脑疾病知识学习模块可以较为精准地对疾病进行预测。

[0095] 在模型测试阶段,将待测试的脑影像数据输入模型,获得与疾病高度相关的脑网络,并对待测试样本所处的疾病阶段进行较为精准的预测,通过分析脑网络,计算不同阶段疾病的异常特征指标,例如增加和减少的脑连接数量变化、脑连接强度变化等,为疾病的早期诊断提供检测标志物。

[0096] 同时,如图8所示,将学习到的脑区掩模、脑疾病拓扑特征提取模块、脑连接学习模块、脑疾病知识学习模块进行提取和迁移,构成端到端的基于知识和数据驱动的脑网络计算方法的疾病预测模型。

[0097] 请参阅图9,在一示例性实施例中,一种知识和数据驱动的脑网络计算装置900。

[0098] 所述装置900包括但不限于:基于解剖学知识的脑区感知模块910、脑疾病拓扑特征提取模块930、脑连接学习模块950及脑疾病知识学习模块970。

[0099] 其中,基于解剖学知识的脑区感知模块910,用于根据先验知识构造脑区掩膜,对脑影像中的各个脑区进行定位,得到脑影像中各个脑区的影像。

[0100] 脑疾病拓扑特征提取模块930,用于通过多个基于空间注意力的特征提取模块提取各个脑区影像的拓扑特征。

[0101] 脑连接学习模块950,用于学习各个脑区影像的拓扑特征之间的连接关系,基于拓扑特征和连接关系构建脑网络。

[0102] 脑疾病知识学习模块970,用于根据脑网络预测样本疾病类别,得到疾病相关信息,约束脑网络的分布,使得脑网络包含更多疾病特征和连接,对脑网络进行优化。

[0103] 需要说明的是,上述实施例所提供的知识和数据驱动的脑网络计算装置在进行脑网络计算时,仅以上述各功能模块的划分进行举例说明,实际应用中,可以根据需要而将上述功能分配由不同的功能模块完成,即知识和数据驱动的脑网络计算装置的内部结构将划分为不同的功能模块,以完成以上描述的全部或者部分功能。

[0104] 另外,上述实施例所提供的知识和数据驱动的脑网络计算装置与知识和数据驱动的脑网络计算方法的实施例属于同一构思,其中各个模块执行操作的具体方式已经在方法实施例中进行了详细描述,此处不再赘述。

[0105] 图10根据一示例性实施例示出的一种电子设备的结构示意。

[0106] 需要说明的是,该电子设备只是一个适配于本申请的示例,不能认为是提供了对本申请的使用范围的任何限制。该电子设备也不能解释为需要依赖于或者必须具有图10示出的示例性的电子设备2000中的一个或者多个组件。

[0107] 电子设备2000的硬件结构可因配置或者性能的不同而产生较大的差异,如图10所示,电子设备2000包括:电源210、接口230、至少一存储器250、以及至少一中央处理器(CPU, Central Processing Units)270。

[0108] 具体地,电源210用于为电子设备2000上的各硬件设备提供工作电压。

[0109] 接口230包括至少一有线或无线网络接口231,用于与外部设备交互。

[0110] 当然,在其余本申请适配的示例中,接口230还可以进一步包括至少一串并转换接口233、至少一输入输出接口235以及至少一USB接口237等,如图10所示,在此并非对此构成具体限定。

[0111] 存储器250作为资源存储的载体,可以是只读存储器、随机存储器、磁盘或者光盘等,其上所存储的资源包括操作系统251、应用程序253及数据255等,存储方式可以是短暂存储或者永久存储。

[0112] 其中,操作系统251用于管理与控制电子设备2000上的各硬件设备以及应用程序253,以实现中央处理器270对存储器250中海量数据255的运算与处理,其可以是Windows ServerTM、Mac OS XTM、UnixTM、LinuxTM、FreeBSDTM等。

[0113] 应用程序253是基于操作系统251之上完成至少一项特定工作的计算机程序,其可以包括至少一模块(图10未示出),每个模块都可以分别包含有对电子设备2000的计算机程序。例如,知识和数据驱动的脑网络计算装置可视为部署于电子设备2000的应用程序253。

[0114] 数据255可以是存储于磁盘中的照片、图片等,还可以是脑影像数据等,存储于存储器250中。

[0115] 中央处理器270可以包括一个或多个以上的处理器,并设置为通过至少一通信总线与存储器250通信,以读取存储器250中存储的计算机程序,进而实现对存储器250中海量数据255的运算与处理。例如,通过中央处理器270读取存储器250中存储的一系列计算机程序的形式来完成知识和数据驱动的脑网络计算方法。

[0116] 此外,通过硬件电路或者硬件电路结合软件也能同样实现本申请,因此,实现本申请并不限于任何特定硬件电路、软件以及两者的组合。

[0117] 请参阅图11,本申请实施例中提供了一种电子设备4000,该电子设备400可以包括:台式电脑、笔记本电脑、服务器等。

[0118] 在图11中,该电子设备4000包括至少一个处理器4001、至少一条通信总线4002以及至少一个存储器4003。

[0119] 其中,处理器4001和存储器4003相连,如通过通信总线4002相连。可选地,电子设备4000还可以包括收发器4004,收发器4004可以用于该电子设备与其他电子设备之间的数据交互,如数据的发送和/或数据的接收等。需要说明的是,实际应用中收发器4004不限于一个,该电子设备4000的结构并不构成对本申请实施例的限定。

[0120] 处理器4001可以是CPU(Central Processing Unit,中央处理器),通用处理器,DSP(Digital Signal Processor,数据信号处理器),ASIC(Application Specific Integrated Circuit,专用集成电路),FPGA(Field Programmable Gate Array,现场可编程门阵列)或者其他可编程逻辑器件、晶体管逻辑器件、硬件部件或者其任意组合。其可以实现或执行结合本申请公开内容所描述的各种示例性的逻辑方框,模块和电路。处理器4001也可以是实现计算功能的组合,例如包含一个或多个微处理器组合,DSP和微处理器的组合等。

[0121] 通信总线4002可包括一通路,在上述组件之间传送信息。通信总线4002可以是PCI(Peripheral Component Interconnect,外设部件互连标准)总线或EISA(Extended Industry Standard Architecture,扩展工业标准结构)总线等。通信总线4002可以分为地

址总线、数据总线、控制总线等。为便于表示,图11中仅用一条粗线表示,但并不表示仅有一根总线或一种类型的总线。

[0122] 存储器4003可以是ROM(Read Only Memory,只读存储器)或可存储静态信息和指令的其他类型的静态存储设备,RAM(Random Access Memory,随机存取存储器)或者可存储信息和指令的其他类型的动态存储设备,也可以是EEPROM(Electrically Erasable Programmable Read Only Memory,电可擦可编程只读存储器)、CD-ROM(Compact Disc Read Only Memory,只读光盘)或其他光盘存储、光碟存储(包括压缩光碟、激光碟、光碟、数字通用光碟、蓝光光碟等)、磁盘存储介质或者其他磁存储设备、或者能够用于携带或存储具有指令或数据结构形式的期望的程序代码并能够由计算机存取的任何其他介质,但不限于此。

[0123] 存储器4003上存储有计算机程序,处理器4001通过通信总线4002读取存储器4003中存储的计算机程序。

[0124] 该计算机程序被处理器4001执行时实现上述各实施例中的知识和数据驱动的脑网络计算方法。

[0125] 此外,本申请实施例中提供了一种存储介质,其上存储有计算机程序,该计算机程序被处理器执行时实现上述各实施例中的知识和数据驱动的脑网络计算方法。

[0126] 本申请实施例中提供了一种计算机程序产品,该计算机程序产品包括计算机程序,该计算机程序存储在存储介质中。计算机设备的处理器从存储介质读取该计算机程序,处理器执行该计算机程序,使得该计算机设备执行上述各实施例中的知识和数据驱动的脑网络计算方法。

[0127] 与相关技术相比,本发明的有益效果是:

[0128] 1. 本发明提出了一个新的知识和数据驱动的脑网络计算方法,与现有技术相比,本发明融合解剖学知识与生成式学习策略端到端地从脑影像中构建脑网络,省去了现有方法中繁琐的数据预处理步骤,自动化程度高,提高了脑网络计算的效率。

[0129] 2. 本发明提出了基于解剖学知识的基于解剖学知识的脑区感知模块,可以实现对脑区的快速定位,克服了神经退行性疾病病变过程中不同程度的脑区萎缩带来的定位困难问题和脑区体积太小带来的特征提取困难问题。

[0130] 3. 本发明提出了新的脑区拓扑特征提取方法,在轻量级的卷积神经网络中加入了空间注意力机制对脑区进行二次定位,指导模型在特定的脑区提取拓扑特征,与现有的脑区特征提取方式相比,在拓扑特征与脑区之间建立了更强的对应关系。

[0131] 4. 本发明提出了新的脑连接计算方法,通过可学习的网络构建脑区之间的连接关系,与现有的统计学方法相比,可以直接且客观的反映脑区之间真实的连接情况。

[0132] 5. 本发明提出了新的疾病知识学习模块,通过并行的多层图卷积神经网络提取丰富的疾病相关特征,并结合图池化策略对特征进行归纳,提高了神经退行性疾病的预测准确度。

[0133] 6. 本发明通过拓扑结构损失指导模型生成近似经验分布的脑网络,并通过分类损失引入疾病相关知识对脑网络的分布进行修正,使其更加接近真实分布。

[0134] 7. 本发明生成的脑网络蕴含更多疾病相关特征与连接,更加适用病理分析、疾病溯源等深入和个性化的疾病智能辅助诊疗任务。

[0135] 8. 本发明以脑影像作为输入,采用数据驱动的方式学习脑网络的分布,并通过脑网络分析方法挖掘神经退行性疾病相关的异常脑连接与特征,有利于患者的早期干预和治疗,同时,本发明适用于多种脑疾病的医学诊疗场景,通过修改模型的输出参数以及增加更多模态数据,可以生成多种类型的脑网络并应用于多种神经退行性疾病的预测治疗。

[0136] 应该理解的是,虽然附图的流程图中的各个步骤按照箭头的指示依次显示,但是这些步骤并不是必然按照箭头指示的顺序依次执行。除非本文中有明确的说明,这些步骤的执行并没有严格的顺序限制,其可以以其他的顺序执行。而且,附图的流程图中的至少一部分步骤可以包括多个子步骤或者多个阶段,这些子步骤或者阶段并不必然是在同一时刻执行完成,而是可以在不同的时刻执行,其执行顺序也不必然是依次进行,而是可以与其他步骤或者其他步骤的子步骤或者阶段的至少一部分轮流或者交替地执行。

[0137] 上述内容,仅为本发明的较佳示例性实施例,并非用于限制本发明的实施方案,本领域普通技术人员根据本发明的主要构思和精神,可以十分方便地进行相应的变通或修改,故本发明的保护范围应以权利要求书所要求的保护范围为准。

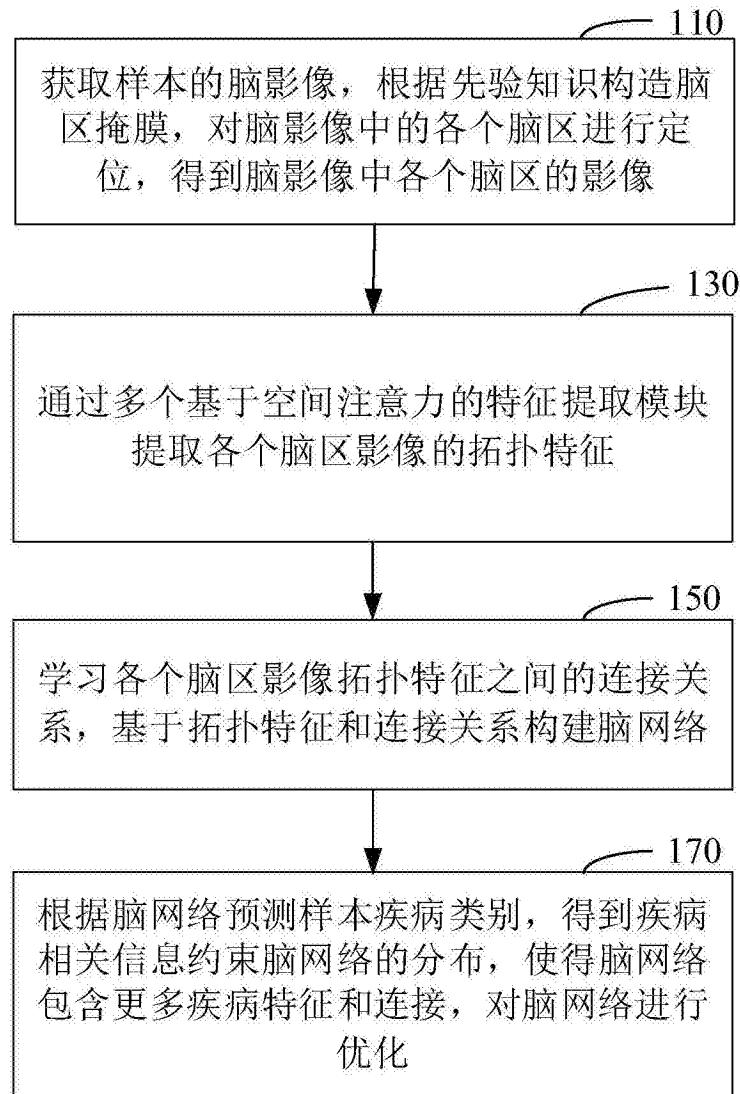


图1

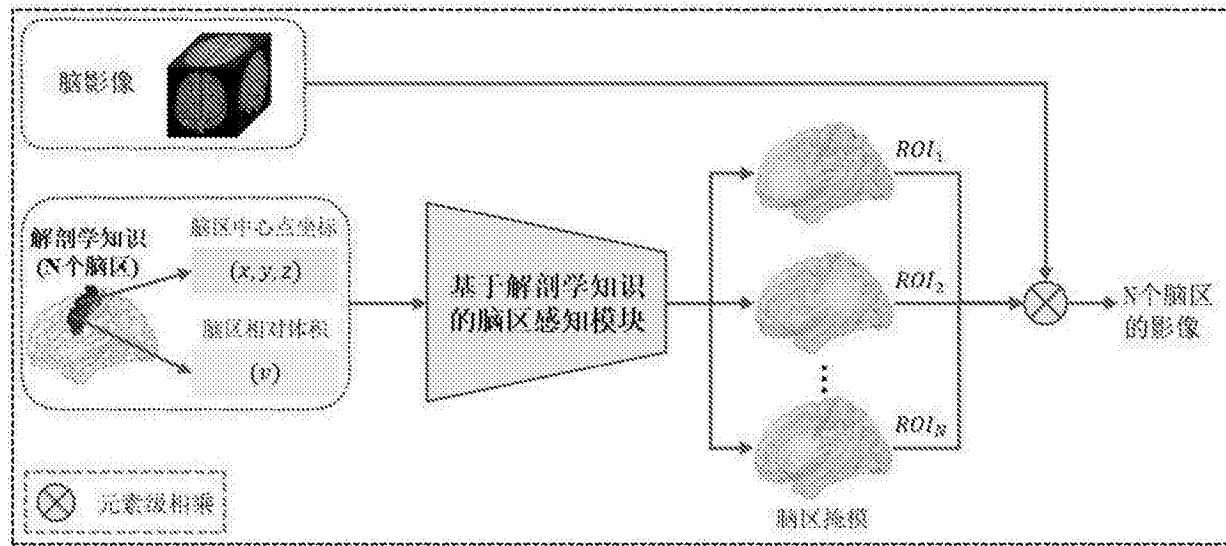


图2

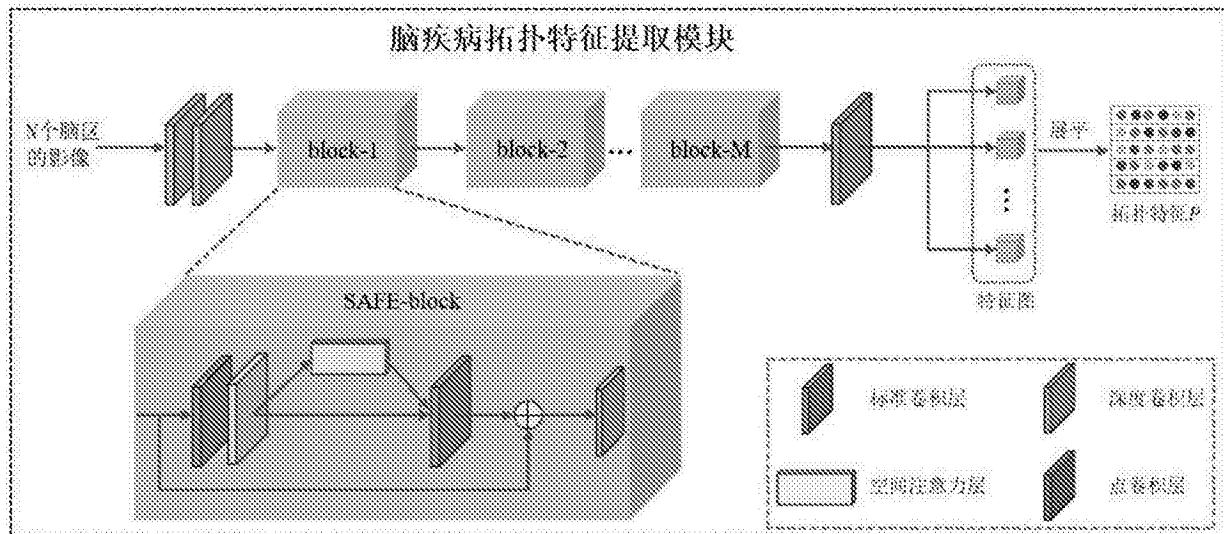


图3

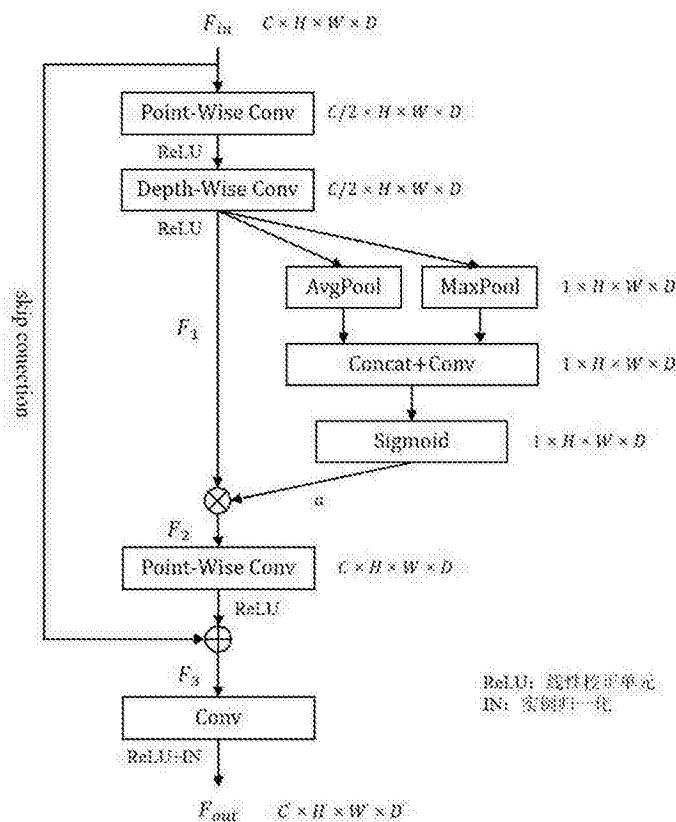


图4

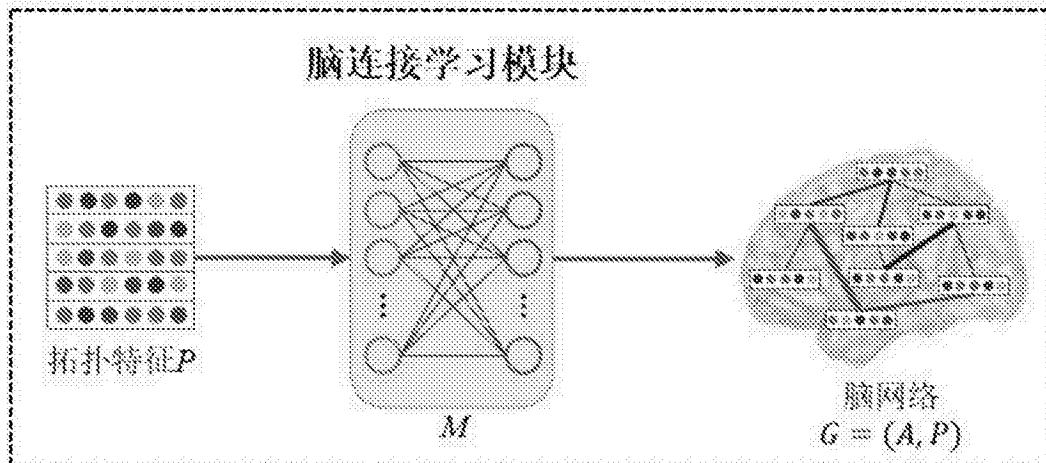


图5

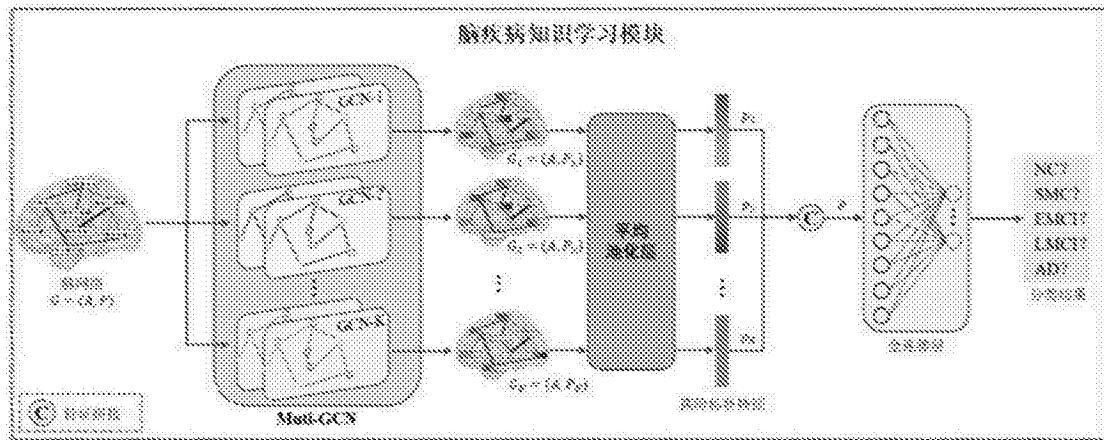


图6

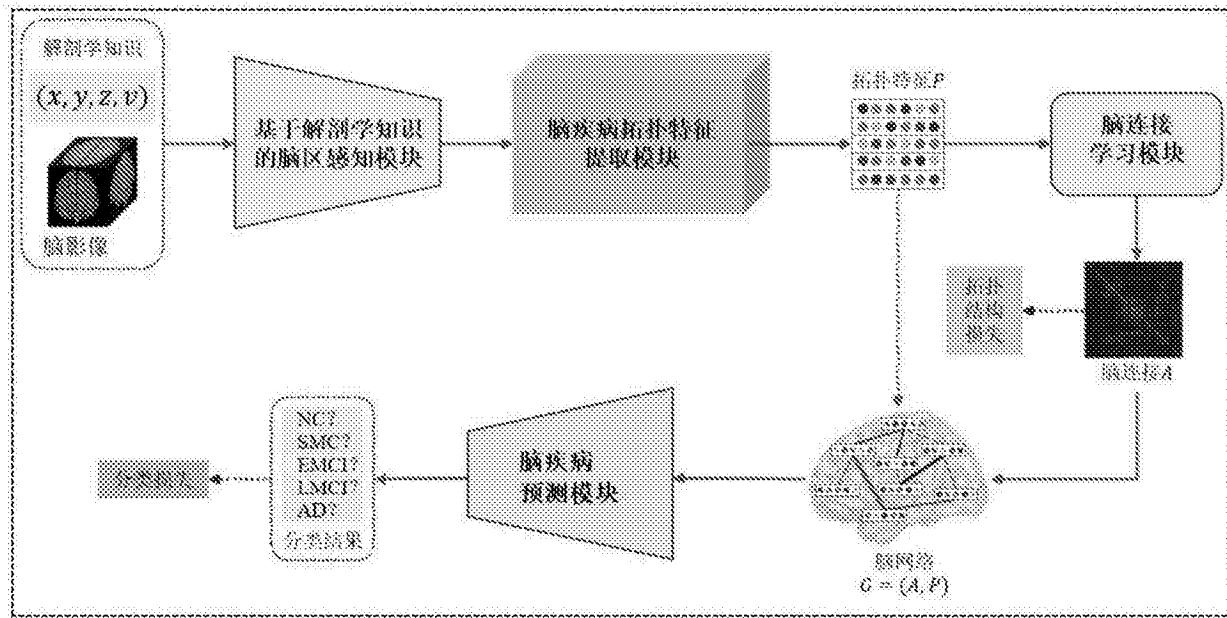


图7

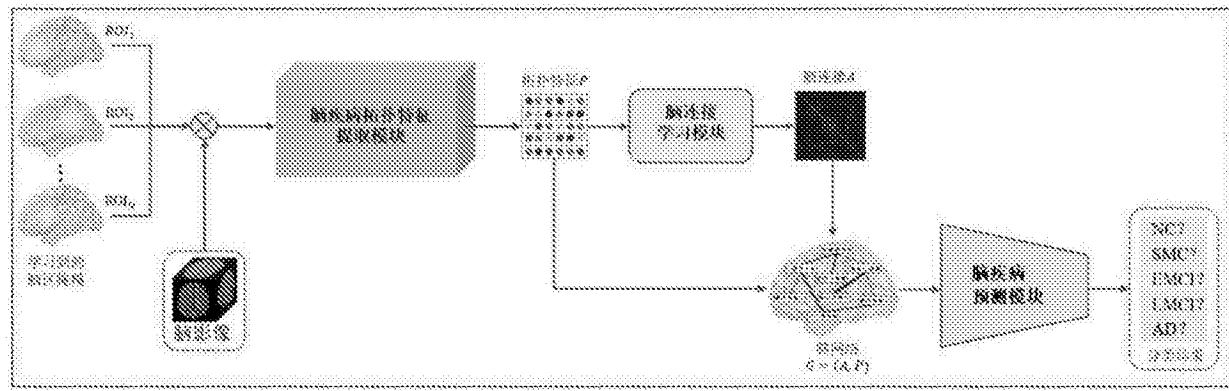


图8

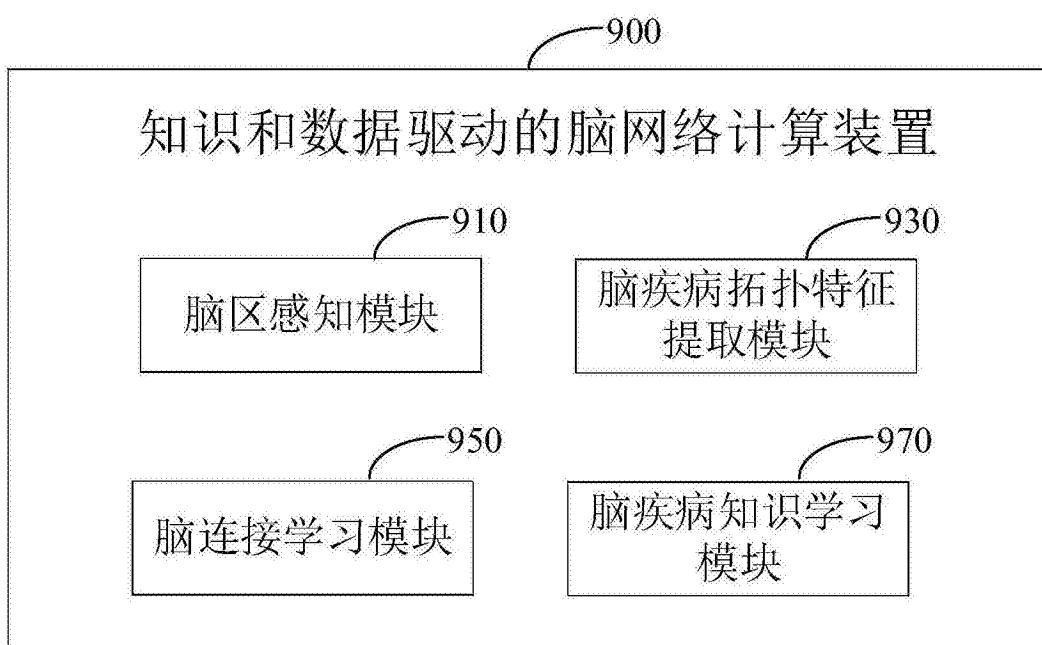


图9

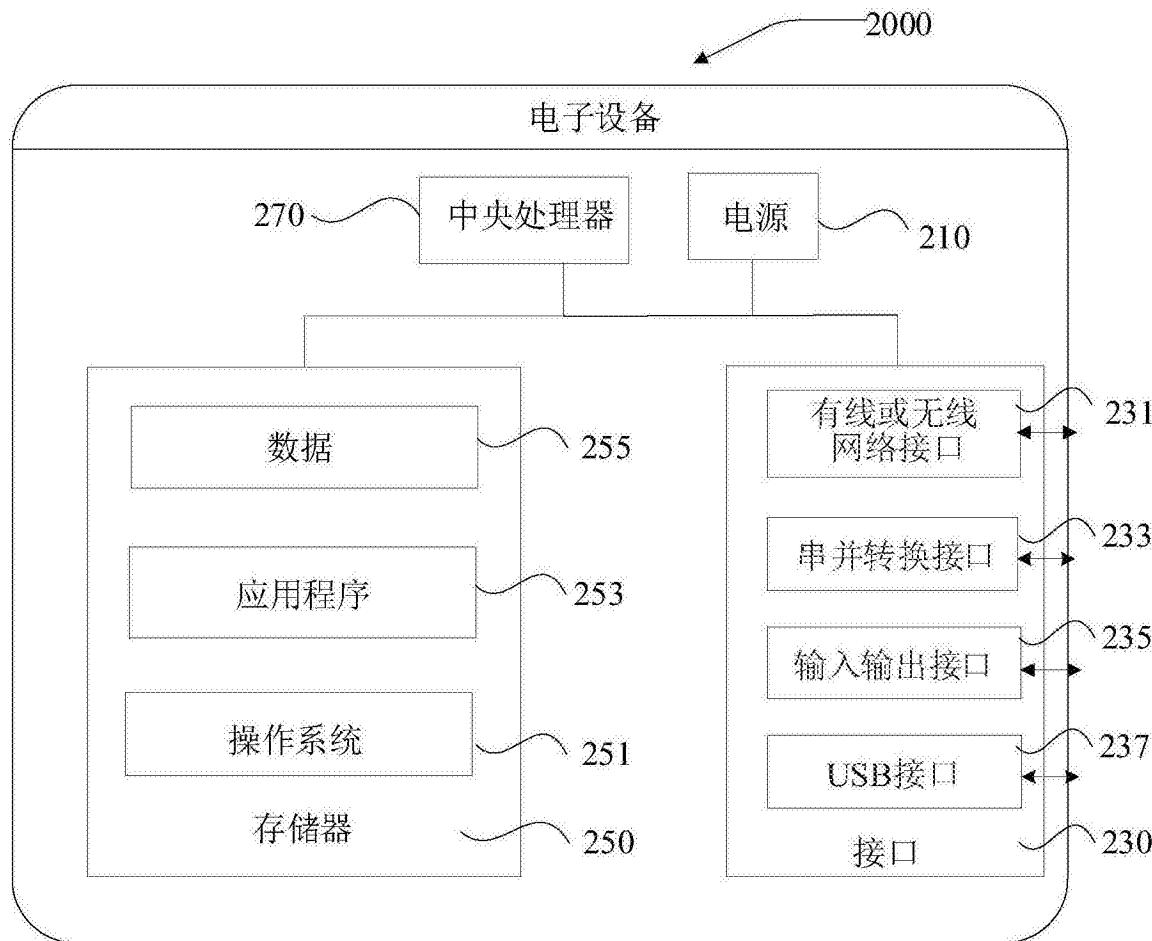


图10

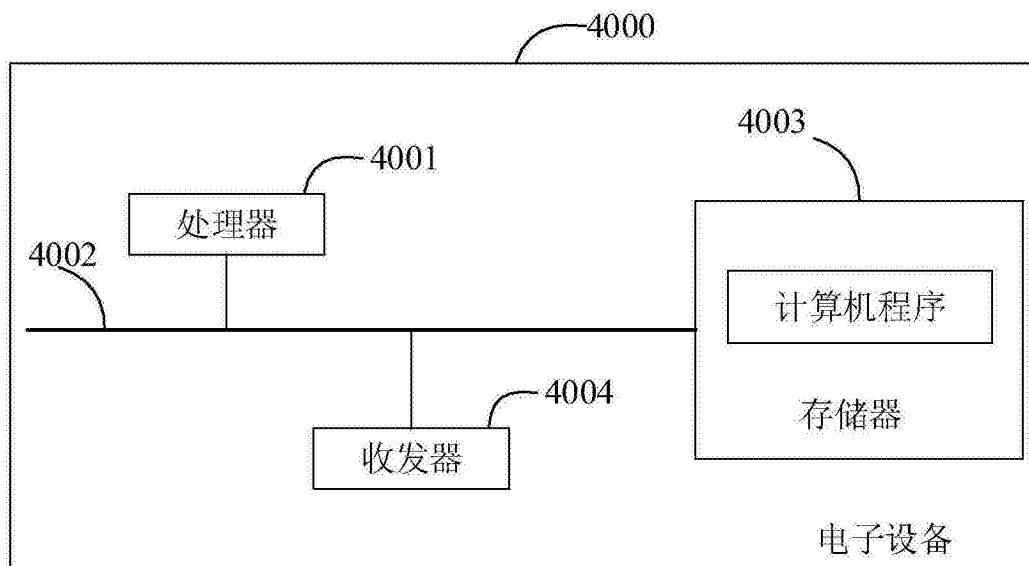


图11