



(12)发明专利

(10)授权公告号 CN 106491083 B

(45)授权公告日 2019.05.14

(21)申请号 201610887684.0

(22)申请日 2016.10.11

(65)同一申请的已公布的文献号
申请公布号 CN 106491083 A

(43)申请公布日 2017.03.15

(73)专利权人 天津大学
地址 300072 天津市南开区卫津路92号

(72)发明人 高忠科 杨宇轩 蔡清

(74)专利代理机构 天津市北洋有限责任专利代
理事务所 12201

代理人 杜文茹

(51) Int. Cl.

A61B 5/00(2006.01)

A61B 5/0476(2006.01)

(56)对比文件

CN 103110418 A,2013.05.22,

CN 101259015 A,2008.09.10,

李红利. 癫痫脑电信号的非线性分析.《天津
大学博士学位论文》.2012,

郝崇清. 基于时间序列的复杂脑网络构建与
分析.《天津大学博士学位论文》.2012,

审查员 李陆美


权利要求书4页 说明书9页 附图1页

(54)发明名称

用于脑状态监测的头戴式智能穿戴电极数
量优化法及应用

(57)摘要

一种用于脑状态监测的头戴式智能穿戴电
极数量优化法及应用:对智能穿戴设备测得的多
通道信号进行预处理,得到多尺度多通道信号;
对所有尺度下的多通道信号构建多尺度加权递
归网络;在每个尺度下,对交叉递归率矩阵选取
阈值;采用基于贪婪优化策略的鲁文算法探寻多
尺度无权递归网络的社团结构;通过比较不同脑
状态下的社团结构的演化,同时结合复杂网络的
关键节点探寻算法,确定网络中的关键节点,关
键节点对应的电极即为可监测脑状态变化的关
键电极;针对关键电极测得的多通道信号,构建
多元多尺度复杂网络;针对关键电极所得信号构
建的多元多尺度复杂网络提取复杂网络指标;训
练深度学习模型和进行脑状态监测。本发可提高
智能穿戴设备的便携性和实用性。



1. 一种用于脑状态监测的头戴式智能穿戴设备电极数量优化方法,其特征在于,包括如下步骤:

1) 对智能穿戴设备测得的多通道信号进行预处理,预处理中的带通滤波范围是根据设定的任务选取对应的脑电节律波确定,对预处理后的脑电信号进行多尺度变换,得到多尺度多通道信号;

2) 在一个固定尺度因子 β 下构建交叉递归率矩阵和多尺度加权递归网络;

3) 对所有尺度下的多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k=1,2,\dots,p$ 进行步骤2)所述的构建多尺度加权递归网络,得到多尺度加权递归网络,其中, $x_{k,i}^{(\beta)}$ 表示每一通道的多尺度信号,L表示每一通道的多尺度信号的数据长度,p表示通道数;在每个尺度下,对所述的交叉递归率矩阵,选取阈值,若交叉递归率大于所述阈值,则网络中的两节点之间有连边,否则无连边,由此得到多尺度无权递归网络和多尺度无权递归网络的邻接矩阵;

4) 采用基于贪婪优化策略的鲁文算法探寻多尺度无权递归网络的社团结构;通过比较不同脑状态下的社团结构的演化,同时结合复杂网络的关键节点探寻算法,确定网络中的关键节点,关键节点对应的电极即为可监测脑状态变化的关键电极;

5) 针对关键节点所在的电极即关键电极测得的多通道信号,构建多元多尺度复杂网络;

6) 针对关键电极所得信号构建的多元多尺度复杂网络提取复杂网络指标;

7) 训练深度学习模型和进行脑状态监测。

2. 根据权利要求1所述的用于脑状态监测的头戴式智能穿戴设备电极数量优化方法,其特征在于,步骤1)所述的预处理中的带通滤波范围是根据设定的任务选取对应的脑电节律波确定,具体是:深度睡眠、缺氧以及大脑出现器质性病变时出现的 δ 波;在意愿受到挫折和抑郁时出现的 θ 波;人在清醒、安静或闭眼时最为明显的是 α 波;人精神紧张和情绪激动或兴奋时出现的 β 波;若无脑电节律波要求,则去除高低频干扰即可。

3. 根据权利要求1所述的用于脑状态监测的头戴式智能穿戴设备电极数量优化方法,其特征在于,步骤1)所述的对预处理后的脑电信号进行多尺度变换,包括:

(1) 对于长度均为C具有p通道的信号 $Y = \{y_{k,b}\}_{b=1}^C, k=1,\dots,p$ 中的每一通道的信号分别进行粗粒化得到:

$$\mu x_{k,i}^{(\beta)} = \frac{1}{\beta} \sum_{b=(i-1)\beta+1}^{i\beta} y_{k,b} \quad 1 \leq i \leq \left\lfloor \frac{C}{\beta} \right\rfloor$$

其中, $\mu x_{k,i}^{(\beta)}$ 是粗粒化后得到的信号的任意一点, $y_{k,b}$ 是信号Y中的任意一点, β 是固定尺度因子, μ 表示数据是求均值得到的, $\left\lfloor \frac{C}{\beta} \right\rfloor$ 表示对 $\frac{C}{\beta}$ 进行取整,其中粗粒化后的单通道的数据长度为L, $L = \left\lfloor \frac{C}{\beta} \right\rfloor$;

(2) 对每一通道的原始信号计算粗粒化方差,得到每一通道的多尺度信号 $x_{k,i}^{(\beta)}$:

$$x_{k,i}^{(\beta)} = \frac{1}{\beta} \sum_{b=(i-1)\beta+1}^{i\beta} (y_{k,b} - \mu x_{k,i}^{(\beta)})^2 \quad 1 \leq i \leq \left\lfloor \frac{C}{\beta} \right\rfloor$$

由此,得到多尺度多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k=1,2,\dots,p$ 。

4. 根据权利要求1所述的用于脑状态监测的头戴式智能穿戴设备电极数量优化方法,其特征在于,步骤2)所述的在每一个固定尺度因子 β 下构建多尺度加权递归网络,包括:

(1) 对于一个固定尺度因子 β 下得到的多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k=1,2,\dots,p$,进行相空间重构:

$$\bar{x}_k(t)^{(\beta)} = (x_{k,t}^{(\beta)}, x_{k,t+\tau}^{(\beta)}, \dots, x_{k,t+(m-1)\tau}^{(\beta)}), t=1,2,\dots,N$$

其中, N 是进行相空间重构后相空间轨迹上向量点的数目, m 为嵌入维数,采用错误最近邻法确定, τ 为延迟时间,采用互信息法确定, $\bar{x}_k(t)^{(\beta)}$ 为通道 k 经过相空间重构后得到的相空间轨迹;

(2) 对于任意两通道 m 和 n 的信号 $x_{m,i}^{(\beta)}$ 和 $x_{n,i}^{(\beta)}$,其中 $m \neq n$,在进行第(1)步后得到相空间轨迹 $\bar{x}_m(u)^{(\beta)}$,其中 $u=1,\dots,N$ 和 $\bar{x}_n(v)^{(\beta)}$,其中 $v=1,\dots,N$;通过对这两个相空间轨迹进行交叉递归,得到一个大小为 $N \times N$ 的交叉递归图:

$$CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}} = \Theta(\varepsilon - \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|), u=1,\dots,N v=1,\dots,N m \neq n$$

其中, ε 为阈值,采用15%的两通道信号标准偏差和选取, $\|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|$ 表示两相空间轨迹中任意两向量点之间的距离; $\Theta(\varepsilon - \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|)$ 表示如果 $\varepsilon > \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|$,则其值为1,如果 $\varepsilon \leq \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|$,则其值为0;这样一来,若 $CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}}$ 的值为1,则在递归图中为黑色,若 $CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}}$ 的值为0,则在递归图中为白色;

(3) 为了量化每一个交叉递归图中递归点的密度,计算交叉递归率:

$$CRR(\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}) = \frac{1}{N^2} \sum_{u,v=1}^N CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}}$$

(4) 对于固定尺度因子 β 下得到的多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k=1,2,\dots,p$,对每两通道信号采用第(3)步,得到一个大小为 $p \times p$ 的交叉递归率矩阵;

(5) 将每一通道信号视作节点,将两通道间形成的交叉递归图的交叉递归率作为节点间连边的权重;由此,得到在任一固定尺度下的加权递归网络。

5. 根据权利要求1所述的用于脑状态监测的头戴式智能穿戴设备电极数量优化方法,其特征在于,步骤5)包括:

(1) 获得 p 组长度皆为 L 的多通道信号 $\{x_{k,i}\}_{i=1}^L, k=1,2,\dots,p$,并进行粗粒化,获得多通道粗粒化信号 $y_{k,j}^e$:

$$y_{k,j}^e = \frac{1}{e} \sum_{i=(j-1)e+1}^{je} x_{k,i}$$

其中, e 是尺度因子且 $1 \leq j \leq \frac{L}{e}$;

(2) 对于每一个获得多通道粗粒化信号 $y_{k,j}^e$,在每一固定个尺度因子 e 下建立多元复杂

网络,方法如下:

(a) 一个固定尺度因子 e 下得到多通道信号 $\{y_{k,j}\}_{j=1}^{L_1}, k=1,2,\dots,p$,其中, L_1 是该固定尺度因子 e 下粗粒化得到的多通道信号的长度;

(b) 对多通道信号 $\{y_{k,j}\}_{j=1}^{L_1}, k=1,2,\dots,p$ 进行多元相空间重构,得到

$$Y_m(s) = [y_{1,s}, \dots, y_{1,s+(m_1-1)\tau_1}, y_{2,s}, \dots, y_{2,s+(m_2-1)\tau_2}, \dots, y_{p,s}, \dots, y_{p,s+(m_p-1)\tau_p}]$$

其中, $\tau = [\tau_1, \tau_2, \dots, \tau_p]$ 是延迟时间矢量且 $M = [m_1, m_2, \dots, m_p] \in R^p$ 是嵌入维数矢量, $Y_m(s) \in R^m (m = \sum_{k=1}^p m_k)$;从而得到 (L_1-n) 个复合延迟矢量 $Y_m(s) \in R^m$,其中, $n = \max\{M\} \times \max\{\tau\}$ 且 $s=1,2,\dots,L_1-n$;

(c) 对于任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$, $s_1 \neq s_2$,定义二者的相空间距离 $d[Y_m(s_1), Y_m(s_2)]$ 为最大范数

$$d[Y_m(s_1), Y_m(s_2)] = \max_{l_2=1,\dots,m} \{|y(s_1+l_2-1) - y(s_2+l_2-1)|\}$$

其中, $l_2=1,\dots,m$;

(d) 将任意一个相空间矢量 $Y_m(s)$ 作为多元复杂网络的一个节点,以任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$ 的相空间距离决定网络中两节点 s_1 和 s_2 间是否连边,从而构建在一个固定尺度下的多元复杂网络;通过选择一个阈值,获得该网络的邻接矩阵 A :若任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$ 间的相空间距离小于等于选定的阈值,则网络中两节点 s_1 和 s_2 之间有连边即 $A_{s_1,s_2} = 1$;若任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$ 间的相空间距离大于选定的阈值,则网络中两节点 s_1 和 s_2 之间无连边即 $A_{s_1,s_2} = 0$;由此,邻接矩阵 A 决定了每一个尺度下获得多元复杂网络的拓扑结构,所述阈值的选择方法如下:计算每一通道信号的标准偏差,取它们和值的15%作为阈值;

(e) 从而对每一个固定尺度因子 e 获得一个多元复杂网络,即多元多尺度复杂网络。

6. 根据权利要求1所述的用于脑状态监测的头戴式智能穿戴设备电极数量优化方法,其特征在于,步骤6)包括:

(1) 设定图能量指标 $E(A) : E(A) = \sum_{i=1}^n |\lambda_i|$,其中, λ_i 表示每一个尺度下多元复杂网络的邻接矩阵 A 的特征值, n 表示的是特征值的数目;

(2) 设定聚集系数熵指标 E_C :

$$C(v) = \frac{2T_v}{k_v(k_v - 1)}$$

$$E_C = -\sum_{v=1}^N \left[C(v) / \sum_{v=1}^N C(v) \right] \log \left[C(v) / \sum_{v=1}^N C(v) \right]$$

其中, T_v 表示的是一个多元网络中包含有节点 v 的封闭三角形的数目, k_v 表示的是多元网络中节点 v 的度, $C(v)$ 表示的是节点 v 的聚集系数。

7. 根据权利要求1所述的用于脑状态监测的头戴式智能穿戴设备电极数量优化方法,其特征在于,步骤7)是将不同尺度下得到的多元复杂网络的图能量和聚集系数熵指标组成特征向量进行归一化后作为一个样本输入深度学习模型,所述深度学习模型是由多层隐含随机变量构成的概率生成模型,由一定数目的受限玻尔兹曼机堆叠而成,然后从底向上进行逐层预训练;

所述的堆叠过程如下:训练一个伯努利-伯努利受限玻尔兹曼机后,将隐单元的激活概率作为下一层伯努利-伯努利受限玻尔兹曼机的输入数据;第二层伯努利-伯努利受限玻尔兹曼机的激活函数作为第三层伯努利-伯努利受限玻尔兹曼机的可见输入数据,以后各层以此类推;其中,受限玻尔兹曼机基于逐层贪婪学习策略的理论进行构建;

深度学习模型的训练过程分为两个步骤:第一步是使用贪婪的逐层训练算法,对深度学习模型训练得到生成模型参数;贪婪逐层训练是采用无监督学习的训练算法,即训练过程不需要知道训练样本所属的类别,这样非常容易获得大量的训练样本;训练中由下至上,每两层构成一个受限玻尔兹曼机,用对比散度算法训练得到受限玻尔兹曼机参数,然后固定该受限玻尔兹曼机参数,继续对上一层构造的受限玻尔兹曼机进行训练,直到最顶层结束;第二步是以第一步得到的模型参数为初始值,用来重置深度学习模型的初始权重,采用有监督的方法对整个模型参数进行全局训练,最终得到可以用于准确分类的神经模型参数;全局训练过程采用有监督学习的训练算法,用带标签的训练样本进行训练;以第一步得到的深度学习模型参数作为深度学习模型初始参数,并用反向传播算法进行微调训练;由于经过了第一步的贪婪逐层预训练,因此在进行全局训练时,能够很好地解决传统上对深层网络训练方式容易收敛到局部最优点的问题;通过对大量样本的无监督学习和有监督学习,得到一个基于多元多尺度复杂网络的深度学习模型;通过所述的深度学习模型实现脑状态的监测。

8. 一种权利要求1所述的用于脑状态监测的头戴式智能穿戴设备电极数量优化方法的应用,其特征在于,包括如下步骤:

1) 对智能穿戴设备测得的多通道信号进行带通滤波,使用独立成分分析的方法去除眼电干扰信号并对伪迹明显的数据进行手动剔除,其中带通滤波范围根据设定的任务选取对应的脑电节律波确定;

2) 对于滤波和去伪迹后的脑电信号在多尺度上计算每一对信号之间的交叉递归率,以交叉递归率确定递归网络的连边权重,以每一通道的信号作为网络的节点,建立多尺度加权递归网络;

3) 通过选取阈值将多尺度加权递归网络转换为无权递归网络;

4) 采用鲁文算法探寻多尺度无权递归网络的社团结构在不同脑状态的演化,寻找到多尺度无权递归网络中的关键节点,关键节点对应的电极即为优化得到可监测脑状态的关键电极;

5) 对通过优化得到的关键电极采集到的脑电信号,建立多元多尺度复杂网络,提取所述多元多尺度复杂网络中的图能量和聚集系数熵指标,将不同尺度下得到的多元多尺度复杂网络指标组成特征向量进行归一化,作为深度学习模型的样本输入,将脑状态作为深度学习模型的输出,通过对大量样本的无监督学习和有监督学习,得到一个深度学习模型,所述深度学习模型能够实现对脑状态的监测。

用于脑状态监测的头戴式智能穿戴电极数量优化法及应用

技术领域

[0001] 本发明涉及一种电极优化方法。特别是涉及一种用于脑状态监测的头戴式智能穿戴电极数量优化法及应用。

背景技术

[0002] 脑电信号是脑神经细胞生理活动在大脑皮层或头皮表面的总体反映。脑电信号中包含了大量的生理与疾病信息,在临床医学方面,对脑状态的准确监测不仅可为某些脑疾病提供诊断依据,同时也能够为某些脑疾病提供有效的治疗手段。在工程应用方面,人们也尝试利用脑电信号实现脑-计算机接口,利用人对不同的感觉、运动或认知活动的脑电的不同,通过对脑电信号特征的有效提取和分类实现意念控制等。但由于脑电信号是不具备各态历经性的非平稳随机信号,而且其背景噪声也很强,因此脑电信号的分析和处理具有十分重要的意义但同时具备相当大的难度。众多的智能穿戴设备在市场上涌现,它们可以对用户的脑电信号进行实时监测,实现某些脑状态的监测与分类。对于智能穿戴设备来说,如何使其更加便携并节约成本是在设计过程中两个非常值得思考的问题。由此,如何在众多的脑电极中找到关键的脑电极对于实现便捷性和节约成本具有十分重要的意义。另外,目前大多数时间序列分析方法只能实现对一元数据的分析,如何融合多通道信息实现更加准确的辨别并为疾病的诊断提供重要依据依然存在较大局限性,同时对于实现更为复杂的意念控制依然是个值得探索的问题。

[0003] 复杂网络理论自创立以来,如今已在多领域得到了蓬勃发展,是研究复杂系统的一个重要工具,尤其是近年来其在时间序列分析中领域作出了重大贡献。实践表明,复杂网络对于挖掘包含在非线性时间序列中和非线性动力学系统中的重要信息具有明显的优势,效果显著。其在单通道时间序列上的得到成功应用的同时,也使得科研人员开始关注如何将其应用到多通道数据的融合分析中。递归网络作为复杂网络研究中的一个重要分支,在多领域得到广泛应用,尤其是对于不稳定的、短的时间序列,其分析效果十分显著。它可以用于探究复杂系统和时间序列中的动力学特性。

发明内容

[0004] 本发明所要解决的技术问题是,提供一种可提高智能穿戴设备的便携性和实用性的用于脑状态监测的头戴式智能穿戴电极数量优化法及应用。

[0005] 本发明所采用的技术方案是:一种用于脑状态监测的头戴式智能穿戴设备电极数量优化方法,包括如下步骤:

[0006] 1) 对智能穿戴设备测得的多通道信号进行预处理,预处理中的带通滤波范围是根据特定的任务选取特定的脑电节律波确定,对预处理后的脑电信号进行多尺度变换,得到多尺度多通道信号;

[0007] 2) 在一个固定尺度因子 β 下构建交叉递归率矩阵和多尺度加权递归网络;

[0008] 3) 对所有尺度下的多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k=1,2,\dots,p$ 进行步骤2) 所述的构建

多尺度加权递归网络,得到多尺度加权递归网络;在每个尺度下,对所述的交叉递归率矩阵,选取阈值,若交叉递归率大于所述阈值,则网络中的两节点之间有连边,否则无连边,由此得到多尺度无权递归网络和它的邻接矩阵;

[0009] 4) 采用基于贪婪优化策略的鲁文算法探寻多尺度无权递归网络的社团结构;通过比较不同脑状态下的社团结构的演化,同时结合复杂网络的关键节点探寻算法,确定网络中的关键节点,关键节点对应的电极即为可监测脑状态变化的关键电极;

[0010] 5) 针对关键节点所在的电极即关键电极测得的多通道信号,构建多元多尺度复杂网络;

[0011] 6) 针对关键电极所得信号构建的多元多尺度复杂网络提取复杂网络指标;

[0012] 7) 训练深度学习模型和进行脑状态监测。

[0013] 步骤1) 所述的预处理中的带通滤波范围是根据特定的任务选取特定的脑电节律波确定,具体是:深度睡眠、缺氧以及大脑出现器质性病变时出现的 δ 波,频率范围为1-4Hz;在意愿受到挫折和抑郁时出现的 θ 波,频率范围为4-8Hz;人在清醒、安静或闭眼时最为明显的是 α 波,频率范围为8-13Hz;人精神紧张和情绪激动或兴奋时出现的 β 波,频率范围为13-30Hz;若无特定的节律波要求,则去除高低频干扰即可。

[0014] 步骤1) 所述的对预处理后的脑电信号进行多尺度变换,包括:

[0015] (1) 对于长度均为 C 具有 p 通道的信号 $Y = \{y_{k,b}\}_{b=1}^C, k=1, \dots, p$ 中的每一通道的信号分别进行粗粒化得到:

$$[0016] \quad {}^{\mu}x_{k,i}^{(\beta)} = \frac{1}{\beta} \sum_{b=(i-1)\beta+1}^{i\beta} y_{k,b} \quad 1 \leq i \leq \left\lfloor \frac{C}{\beta} \right\rfloor$$

[0017] 其中, ${}^{\mu}x_{k,i}^{(\beta)}$ 是粗粒化后得到的信号的任意一点, $y_{k,b}$ 是信号 Y 中的任意一点, β 是固定尺度因子, μ 表示数据是求均值得到的, $\left\lfloor \frac{C}{\beta} \right\rfloor$ 表示对 $\frac{C}{\beta}$ 进行取整,其中粗粒化后的单通

道的数据长度为 $L, L = \left\lfloor \frac{C}{\beta} \right\rfloor$;

[0018] (2) 对每一通道的原始信号计算粗粒化方差,得到每一通道的多尺度信号 $x_{k,i}^{(\beta)}$:

$$[0019] \quad x_{k,i}^{(\beta)} = \frac{1}{\beta} \sum_{b=(i-1)\beta+1}^{i\beta} (y_{k,b} - {}^{\mu}x_{k,i}^{(\beta)})^2 \quad 1 \leq i \leq \left\lfloor \frac{C}{\beta} \right\rfloor$$

[0020] 由此,得到多尺度多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k=1, 2, \dots, p$ 。

[0021] 步骤2) 所述的在每一个固定尺度因子 β 下构建多尺度加权递归网络,包括:

[0022] (1) 对一个固定尺度因子 β 下得到的多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k=1, 2, \dots, p$,进行相空间重构:

$$[0023] \quad \bar{x}_k(t)^{(\beta)} = (x_{k,t}^{(\beta)}, x_{k,t+\tau}^{(\beta)}, \dots, x_{k,t+(m-1)\tau}^{(\beta)}), t=1, 2, \dots, N$$

[0024] 其中, N 是进行相空间重构后相空间轨迹上向量点的数目, m 为嵌入维数,采用错误最近邻法确定, τ 为延迟时间,采用互信息法确定, $\bar{x}_k(t)^{(\beta)}$ 为通道 k 经过相空间重构后得到的相空间轨迹;

[0025] (2) 对于任意两通道 m 和 n 的信号 $x_{m,i}^{(\beta)}$ 和 $x_{n,i}^{(\beta)}$,其中 $m \neq n$,在进行第(1)步后得到相空间轨迹 $\bar{x}_m(u)^{(\beta)}$,其中 $u=1, \dots, N$ 和 $\bar{x}_n(v)^{(\beta)}$,其中 $v=1, \dots, N$;通过对这两个相空间轨迹进行交叉递归,得到一个大小为 $N \times N$ 的交叉递归图:

$$[0026] \quad CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}} = \Theta(\varepsilon - \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|), \quad u=1, \dots, N \quad v=1, \dots, N \quad m \neq n$$

[0027] 其中, ε 为阈值,采用15%的两通道信号标准偏差和选取, $\|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|$ 表示两相空间轨迹中任意两向量点之间的距离; $\Theta(\varepsilon - \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|)$ 表示如果 $\varepsilon > \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|$,则其值为1,如果 $\varepsilon \leq \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|$,则其值为0;这样一来,若 $CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}}$ 的值为1,则在递归图中为黑色,若 $CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}}$ 的值为0,则在递归图中为白色;

[0028] (3) 为了量化每一个交叉递归图中递归点的密度,计算交叉递归率:

$$[0029] \quad CRR(\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}) = \frac{1}{N^2} \sum_{u,v=1}^N CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}}$$

[0030] (4) 对于固定尺度因子 β 下得到的多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k=1, 2, \dots, p$,对每两通道信号采用第(3)步,得到一个大小为 $p \times p$ 的交叉递归率矩阵;

[0031] (5) 将每一通道信号视作节点,将两通道间形成的交叉递归图的交叉递归率作为节点间连边的权重;由此,得到在任一固定尺度下的加权递归网络。

[0032] 步骤5) 包括:

[0033] (1) 获得 p 组长度皆为 L 的多通道信号 $\{x_{k,i}\}_{i=1}^L, k=1, 2, \dots, p$,并进行粗粒化,获得多通道粗粒化信号 $y_{k,j}^e$:

$$[0034] \quad y_{k,j}^e = \frac{1}{e} \sum_{i=(j-1)e+1}^{je} x_{k,i}$$

[0035] 其中, e 是尺度因子且 $1 \leq j \leq \frac{L}{e}$;

[0036] (2) 对于每一个获得多通道粗粒化信号 $y_{k,j}^e$,在每一固定个尺度因子 e 下建立多元复杂网络,方法如下:

[0037] (a) 一个固定尺度因子 e 下得到多通道信号 $\{y_{k,j}\}_{j=1}^{L_1}, k=1, 2, \dots, p$,其中, L_1 是该固定尺度因子 e 下粗粒化得到的多通道信号的长度;

[0038] (b) 对多通道信号 $\{y_{k,j}\}_{j=1}^{L_1}, k=1, 2, \dots, p$ 进行多元相空间重构,得到

$$[0039] \quad Y_m(s) = [y_{1,s}, \dots, y_{1,s+(m_1-1)\tau_1}, y_{2,s}, \dots, y_{2,s+(m_2-1)\tau_2}, \dots, y_{p,s}, \dots, y_{p,s+(m_p-1)\tau_p}]$$

[0040] 其中, $\tau = [\tau_1, \tau_2, \dots, \tau_p]$ 是延迟时间矢量且 $M = [m_1, m_2, \dots, m_p] \in R^p$ 是嵌入维数矢量, $Y_m(s) \in R^m (m = \sum_{k=1}^p m_k)$;从而得到 $(L_1 - n)$ 个复合延迟矢量 $Y_m(s) \in R^m$,其中, $n = \max\{M\} \times \max\{\tau\}$ 且 $s=1, 2, \dots, L_1 - n$;

[0041] (c) 对于任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$, $s_1 \neq s_2$,定义二者的相空间距离 $d[Y_m(s_1), Y_m(s_2)]$ 为最大范数

$$[0042] \quad d[Y_m(s_1), Y_m(s_2)] = \max_{l_2=1, \dots, m} \{|y(s_1 + l_2 - 1) - y(s_2 + l_2 - 1)|\}$$

[0043] 其中, $l_2 = 1, \dots, m$;

[0044] (d) 将任意一个相空间矢量 $Y_m(s)$ 作为多元复杂网络的一个节点, 以任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$ 的相空间距离决定网络中两节点 s_1 和 s_2 间是否连边, 从而构建在一个固定尺度下的多元复杂网络; 通过选择一个阈值, 获得该网络的邻接矩阵 A : 若任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$ 间的相空间距离小于等于选定的阈值, 则网络中两节点 s_1 和 s_2 之间有连边即 $A_{s_1 s_2} = 1$; 若任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$ 间的相空间距离大于选定的阈值, 则网络中两节点 s_1 和 s_2 之间无连边即 $A_{s_1 s_2} = 0$; 由此, 邻接矩阵 A 决定了每一个尺度下获得多元复杂网络的拓扑结构, 所述阈值的选择方法如下: 计算每一通道信号的标准偏差, 取它们和值的 15% 作为阈值;

[0045] (e) 从而对每一个固定尺度因子 e 获得一个多元复杂网络, 即多元多尺度复杂网络。

[0046] 步骤6) 包括:

[0047] (1) 设定图能量指标 $E(A)$: $E(A) = \sum_{i=1}^n |\lambda_i|$, 其中, λ_i 表示每一个尺度下多元复杂网络的邻接矩阵 A 的特征值, n 表示的是特征值的数目;

[0048] (2) 设定聚集系数熵指标 E_C :

$$[0049] \quad C(v) = \frac{2T_v}{k_v(k_v - 1)}$$

$$[0050] \quad E_C = -\sum_{v=1}^N \left[C(v) / \sum_{v=1}^N C(v) \right] \log \left[C(v) / \sum_{v=1}^N C(v) \right]$$

[0051] 其中, T_v 表示的是一个多元网络中包含有节点 v 的封闭三角形的数目, k_v 表示的是多元网络中节点 v 的度, $C(v)$ 表示的是节点 v 的聚集系数。

[0052] 步骤7) 是将不同尺度下得到的多元复杂网络的图能量和聚集系数熵指标组成特征向量进行归一化后作为一个样本输入深度学习模型, 所述深度学习模型是由多层隐含随机变量构成的概率生成模型, 由一定数目的受限玻尔兹曼机堆叠而成, 然后从底向上进行逐层预训练;

[0053] 所述的堆叠过程如下: 训练一个伯努利-伯努利受限玻尔兹曼机后, 将隐单元的激活概率作为下一层伯努利-伯努利受限玻尔兹曼机的输入数据; 第二层伯努利-伯努利受限玻尔兹曼机的激活函数作为第三层伯努利-伯努利受限玻尔兹曼机的可见输入数据, 以后各层以此类推; 其中, 受限玻尔兹曼机基于逐层贪婪学习策略的理论进行构建;

[0054] 深度学习模型的训练过程分为两个步骤: 第一步是使用贪婪的逐层训练算法, 对深度学习模型训练得到生成模型参数; 贪婪逐层训练是采用无监督学习的训练算法, 即训练过程不需要知道训练样本所属的类别, 这样非常容易获得大量的训练样本; 训练中由下至上, 每两层构成一个受限玻尔兹曼机, 用对比散度算法训练得到受限玻尔兹曼机参数, 然后固定该层参数, 继续对上一层构造的受限玻尔兹曼机进行训练, 直到最顶层结束; 第二步是以第一步得到的模型参数为初始值, 用来重置深度学习模型的初始权重, 采用有监督的方法对整个模型参数进行全局训练, 最终得到可以用于准确分类的神经模型参数; 全局训练过程采用有监督学习的训练算法, 用带标签的训练样本进行训练; 以第一步得到的深度学习模型参数作为深度学习模型初始参数, 并用反向传播算法进行微调训练; 由于经过了

第一步的贪婪逐层预训练,因此在进行全局训练时,能够很好地解决传统上对深层网络训练方式容易收敛到局部最优点的问题;通过对大量样本的无监督学习和有监督学习,得到一个基于多元多尺度复杂网络的深度学习模型;通过所述的深度学习模型实现脑状态的监测。

[0055] 一种用于脑状态监测的头戴式智能穿戴设备电极数量优化方法的应用,包括如下步骤:

[0056] 1) 对智能穿戴设备测得的多通道信号进行带通滤波,使用独立成分分析的方法去除眼电等干扰信号并对伪迹明显的数据进行手动剔除,其中带通滤波范围根据特定的任务选取特定的脑电节律波确定;

[0057] 2) 对于滤波和去伪迹后的脑电信号在多尺度上计算每一对信号之间的交叉递归率,以交叉递归率确定递归网络的连边权重,以每一通道的信号作为网络的节点,建立多尺度加权递归网络;

[0058] 3) 通过选取阈值将多尺度加权递归网络转换为无权递归网络;

[0059] 4) 采用鲁文算法探寻多尺度无权递归网络的社团结构在不同脑状态的演化,寻找多尺度无权递归网络中的关键节点,关键节点对应的电极即为优化得到可监测脑状态的关键电极;

[0060] 5) 对通过优化得到的关键电极采集到的脑电信号,建立多元多尺度复杂网络,提取所述多元多尺度复杂网络中的图能量和聚集系数熵指标,将不同尺度下得到的多元多尺度复杂网络指标组成特征向量进行归一化,作为深度学习模型的样本输入,将脑状态作为深度学习模型的输出,通过对大量样本的无监督学习和有监督学习,得到一个深度学习模型,所述深度学习模型能够实现对脑状态的监测。

[0061] 本发明的用于脑状态监测的头戴式智能穿戴电极数量优化法及应用,具有如下有益效果:

[0062] (1) 提出了一种针对头戴式智能穿戴设备测得的脑电信号进行电极数量优化的方法,可提高智能穿戴设备的便携性和实用性;

[0063] (2) 提出了一种基于多元多尺度复杂网络的深度学习模型并将其应用于脑状态监测中。

附图说明

[0064] 图1是用于脑状态监测的头戴式智能穿戴设备电极数量优化方法的示意图。

具体实施方式

[0065] 下面结合实施例和附图对本发明的用于脑状态监测的头戴式智能穿戴电极数量优化法及应用做出详细说明。

[0066] 本发明的用于脑状态监测的头戴式智能穿戴设备电极数量优化方法,通过对多通道脑电信号在多尺度上计算每一对信号之间的交叉递归率,以交叉递归率确定递归网络的连边权重,以每一通道的信号作为网络的节点,建立多尺度加权递归网络。通过选取阈值将多尺度加权递归网络转换为无权递归网络。通过探寻网络的社团结构演化找到网络中的一些关键节点。对关键节点所在的测量电极测得的脑电信号在多尺度上对多通道睡眠信号进

行多元相空间重构并构建复杂网络,提取网络指标,用指标组成特征向量训练深度学习模型,应用该模型实现对脑状态的监测。

[0067] 本发明的用于脑状态监测的头戴式智能穿戴设备电极数量优化方法,如图1所示,包括如下步骤:

[0068] 1)对智能穿戴设备测得的多通道信号进行预处理,预处理中的带通滤波范围是根据特定的任务选取特定的脑电节律波确定,对预处理后的脑电信号进行多尺度变换,得到多尺度多通道信号。

[0069] 所述的预处理中的带通滤波范围是根据特定的任务选取特定的脑电节律波确定,具体是:深度睡眠、缺氧以及大脑出现器质性病变时出现的 δ 波,频率范围为1-4Hz;在愿意受到挫折和抑郁时出现的 θ 波,频率范围为4-8Hz;人在清醒、安静或闭眼时最为明显的是 α 波,频率范围为8-13Hz;人精神紧张和情绪激动或兴奋时出现的 β 波,频率范围为13-30Hz;若无特定的节律波要求,则去除高低频干扰即可。

[0070] 所述的对预处理后的脑电信号进行多尺度变换,包括:

[0071] (1)对于长度均为 C 具有 p 通道的信号 $Y = \{y_{k,b}\}_{b=1}^C, k=1, \dots, p$ 中的每一通道的信号分别进行粗粒化得到:

$$[0072] \quad \mu x_{k,i}^{(\beta)} = \frac{1}{\beta} \sum_{b=(i-1)\beta+1}^{i\beta} y_{k,b} \quad 1 \leq i \leq \left\lfloor \frac{C}{\beta} \right\rfloor$$

[0073] 其中, $\mu x_{k,i}^{(\beta)}$ 是粗粒化后得到的信号的任意一点, $y_{k,b}$ 是信号 Y 中的任意一点, β 是固定尺度因子, μ 表示数据是求均值得到的, $\left\lfloor \frac{C}{\beta} \right\rfloor$ 表示对 $\frac{C}{\beta}$ 进行取整,其中粗粒化后的单通

道的数据长度为 $L, L = \left\lfloor \frac{C}{\beta} \right\rfloor$;

[0074] (2)对每一通道的原始信号计算粗粒化方差,得到每一通道的多尺度信号 $x_{k,i}^{(\beta)}$:

$$[0075] \quad x_{k,i}^{(\beta)} = \frac{1}{\beta} \sum_{b=(i-1)\beta+1}^{i\beta} (y_{k,b} - \mu x_{k,i}^{(\beta)})^2 \quad 1 \leq i \leq \left\lfloor \frac{C}{\beta} \right\rfloor$$

[0076] 由此,得到多尺度多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k=1, 2, \dots, p$ 。

[0077] 2)在一个固定尺度因子 β 下构建交叉递归率矩阵和多尺度加权递归网络;包括:

[0078] (1)对一个固定尺度因子 β 下得到的多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k=1, 2, \dots, p$,进行相空间重构:

$$[0079] \quad \bar{x}_k(t)^{(\beta)} = (x_{k,t}^{(\beta)}, x_{k,t+\tau}^{(\beta)}, \dots, x_{k,t+(m-1)\tau}^{(\beta)}), t=1, 2, \dots, N$$

[0080] 其中, N 是进行相空间重构后相空间轨迹上向量点的数目, m 为嵌入维数,采用错误最近邻法确定, τ 为延迟时间,采用互信息法确定, $\bar{x}_k(t)^{(\beta)}$ 为通道 k 经过相空间重构后得到的相空间轨迹;

[0081] (2)对于任意两通道 m 和 n 的信号 $x_{m,i}^{(\beta)}$ 和 $x_{n,i}^{(\beta)}$,其中 $m \neq n$,在进行第(1)步后得到相空间轨迹 $\bar{x}_m(u)^{(\beta)}$,其中 $u=1, \dots, N$ 和 $\bar{x}_n(v)^{(\beta)}$,其中 $v=1, \dots, N$;通过对这两个相空间轨迹进行交叉递归,得到一个大小为 $N \times N$ 的交叉递归图:

$$[0082] \quad CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}} = \Theta(\varepsilon - \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|), \quad u = 1, \dots, N \quad v = 1, \dots, N \quad m \neq n$$

[0083] 其中, ε 为阈值, 采用15%的两通道信号标准偏差和选取, $\|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|$ 表示两相空间轨迹中任意两向量点之间的距离; $\Theta(\varepsilon - \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|)$ 表示如果 $\varepsilon > \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|$, 则其值为1, 如果 $\varepsilon \leq \|\bar{x}_m(u)^{(\beta)} - \bar{x}_n(v)^{(\beta)}\|$, 则其值为0; 这样一来, 若 $CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}}$ 的值为1, 则在递归图中为黑色, 若 $CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}}$ 的值为0, 则在递归图中为白色;

[0084] (3) 为了量化每一个交叉递归图中递归点的密度, 计算交叉递归率:

$$[0085] \quad CRR(\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}) = \frac{1}{N^2} \sum_{u,v=1}^N CR_{u,v}^{\bar{x}_m^{(\beta)}, \bar{x}_n^{(\beta)}}$$

[0086] (4) 对于固定尺度因子 β 下得到的多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k = 1, 2, \dots, p$, 对每两通道信号采用第(3)步, 得到一个大小为 $p \times p$ 的交叉递归率矩阵;

[0087] (5) 将每一通道信号视作节点, 将两通道间形成的交叉递归图的交叉递归率作为节点间连边的权重; 由此, 得到在任一固定尺度下的加权递归网络。

[0088] 3) 对所有尺度下的多通道信号 $X = \{x_{k,i}^{(\beta)}\}_{i=1}^L, k = 1, 2, \dots, p$ 进行步骤2) 所述的构建多尺度加权递归网络, 得到多尺度加权递归网络; 在每个尺度下, 对所述的交叉递归率矩阵, 选取阈值, 若交叉递归率大于所述阈值, 则网络中的两节点之间有连边, 否则无连边, 由此得到多尺度无权递归网络和它的邻接矩阵;

[0089] 4) 采用基于贪婪优化策略的鲁文算法探寻多尺度无权递归网络的社团结构; 通过比较不同脑状态下的社团结构的演化, 同时结合复杂网络的关键节点探寻算法, 确定网络中的关键节点, 关键节点对应的电极即为可监测脑状态变化的关键电极;

[0090] 5) 针对关键节点所在的电极即关键电极测得的多通道信号, 构建多元多尺度复杂网络; 包括:

[0091] (1) 获得 p 组长度皆为 L 的多通道信号 $\{x_{k,i}\}_{i=1}^L, k = 1, 2, \dots, p$, 并进行粗粒化, 获得多通道粗粒化信号 $y_{k,j}^e$:

$$[0092] \quad y_{k,j}^e = \frac{1}{e} \sum_{i=(j-1)e+1}^{je} x_{k,i},$$

[0093] 其中, e 是尺度因子且 $1 \leq j \leq \frac{L}{e}$;

[0094] (2) 对于每一个获得多通道粗粒化信号 $y_{k,j}^e$, 在每一固定个尺度因子 e 下建立多元复杂网络, 方法如下:

[0095] (a) 一个固定尺度因子 e 下得到多通道信号 $\{y_{k,j}\}_{j=1}^{L_1}, k = 1, 2, \dots, p$, 其中, L_1 是该固定尺度因子 e 下粗粒化得到的多通道信号的长度;

[0096] (b) 对多通道信号 $\{y_{k,j}\}_{j=1}^{L_1}, k = 1, 2, \dots, p$ 进行多元相空间重构, 得到

$$[0097] \quad Y_m(s) = [y_{1,s}, \dots, y_{1,s+(m_1-1)\tau_1}, y_{2,s}, \dots, y_{2,s+(m_2-1)\tau_2}, \dots, y_{p,s}, \dots, y_{p,s+(m_p-1)\tau_p}]$$

[0098] 其中, $\tau = [\tau_1, \tau_2, \dots, \tau_p]$ 是延迟时间矢量且 $M = [m_1, m_2, \dots, m_p] \in \mathbb{R}^p$ 是嵌入维数矢

量, $Y_m(s) \in R^m (m = \sum_{k=1}^p m_k)$; 从而得到 (L_1-n) 个复合延迟矢量 $Y_m(s) \in R^m$, 其中, $n = \max\{M\} \times \max\{\tau\}$ 且 $s = 1, 2, \dots, L_1-n$;

[0099] (c) 对于任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$, $s_1 \neq s_2$, 定义二者的相空间距离 $d[Y_m(s_1), Y_m(s_2)]$ 为最大范数

$$[0100] \quad d[Y_m(s_1), Y_m(s_2)] = \max_{l_2=1, \dots, m} \{|y(s_1 + l_2 - 1) - y(s_2 + l_2 - 1)|\}$$

[0101] 其中, $l_2 = 1, \dots, m$;

[0102] (d) 将任意一个相空间矢量 $Y_m(s)$ 作为多元复杂网络的一个节点, 以任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$ 的相空间距离决定网络中两节点 s_1 和 s_2 间是否连边, 从而构建在一个固定尺度下的多元复杂网络; 通过选择一个阈值, 获得该网络的邻接矩阵 A : 若任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$ 间的相空间距离小于等于选定的阈值, 则网络中两节点 s_1 和 s_2 之间有连边即 $A_{s_1, s_2} = 1$; 若任意两矢量 $Y_m(s_1)$ 和 $Y_m(s_2)$ 间的相空间距离大于选定的阈值, 则网络中两节点 s_1 和 s_2 之间无连边即 $A_{s_1, s_2} = 0$; 由此, 邻接矩阵 A 决定了每一个尺度下获得多元复杂网络的拓扑结构, 所述阈值的选择方法如下: 计算每一通道信号的标准偏差, 取它们和值的 15% 作为阈值;

[0103] (e) 从而对每一个固定尺度因子 e 获得一个多元复杂网络, 即多元多尺度复杂网络。

[0104] 6) 针对关键电极所得信号构建的多元多尺度复杂网络提取复杂网络指标; 包括:

[0105] (1) 设定图能量指标 $E(A)$: $E(A) = \sum_{i=1}^n |\lambda_i|$, 其中, λ_i 表示每一个尺度下多元复杂网络的邻接矩阵 A 的特征值, n 表示的是特征值的数目;

[0106] (2) 设定聚集系数熵指标 E_C :

$$[0107] \quad C(v) = \frac{2T_v}{k_v(k_v - 1)}$$

$$[0108] \quad E_C = -\sum_{v=1}^N \left[\frac{C(v)}{\sum_{v=1}^N C(v)} \log \left[\frac{C(v)}{\sum_{v=1}^N C(v)} \right] \right]$$

[0109] 其中, T_v 表示的是一个多元网络中包含有节点 v 的封闭三角形的数目, k_v 表示的是多元网络中节点 v 的度, $C(v)$ 表示的是节点 v 的聚集系数。

[0110] 7) 深度学习模型和进行脑状态监测; 是将不同尺度下得到的多元复杂网络的图能量和聚集系数熵指标组成特征向量进行归一化后作为一个样本输入深度学习模型, 所述深度学习模型是由多层隐含随机变量构成的概率生成模型, 由一定数目的受限玻尔兹曼机堆叠而成, 然后从底向上进行逐层预训练;

[0111] 所述的堆叠过程如下: 训练一个伯努利-伯努利受限玻尔兹曼机后, 将隐单元的激活概率作为下一层伯努利-伯努利受限玻尔兹曼机的输入数据; 第二层伯努利-伯努利受限玻尔兹曼机的激活函数作为第三层伯努利-伯努利受限玻尔兹曼机的可见输入数据, 以后各层以此类推; 其中, 受限玻尔兹曼机基于逐层贪婪学习策略的理论进行构建;

[0112] 深度学习模型的训练过程分为两个步骤; 第一步是使用贪婪的逐层训练算法, 对深度学习模型训练得到生成模型参数; 贪婪逐层训练是采用无监督学习的训练算法, 即训练过程不需要知道训练样本所属的类别, 这样非常容易获得大量的训练样本; 训练中由下至上, 每两层构成一个受限玻尔兹曼机, 用对比散度算法训练得到受限玻尔兹曼机参数, 然

后固定该层参数,继续对上一层构造的受限玻尔兹曼机进行训练,直到最顶层结束;第二步是以第一步得到的模型参数为初始值,用来重置深度学习模型的初始权重,采用有监督的方法对整个模型参数进行全局训练,最终得到可以用于准确分类的神经模型参数;全局训练过程采用有监督学习的训练算法,用带标签的训练样本进行训练;以第一步得到的深度学习模型参数作为深度学习模型初始参数,并用反向传播算法进行微调训练;由于经过了第一步的贪婪逐层预训练,因此在进行全局训练时,能够很好地解决传统上对深层网络训练方式容易收敛到局部最优点的问题;通过对大量样本的无监督学习和有监督学习,得到一个基于多元多尺度复杂网络的深度学习模型;通过所述的深度学习模型实现脑状态的监测。

[0113] 8) 本发明的用于脑状态监测的头戴式智能穿戴电极数量优化法及应用,是对智能穿戴设备测得的多通道信号进行带通滤波,使用独立成分分析的方法去除眼电等干扰信号并对伪迹明显的数据进行手动剔除,其中带通滤波范围根据特定的任务选取特定的脑电节律波确定;对于滤波和去伪迹后的脑电信号在多尺度上计算每一对信号之间的交叉递归率,以交叉递归率确定递归网络的连边权重,以每一通道的信号作为网络的节点,建立多尺度加权递归网络;通过选取阈值将多尺度加权递归网络转换为无权递归网络;采用鲁文算法探寻多尺度无权递归网络的社团结构在不同脑状态的演化,寻找到多尺度无权递归网络中的关键节点,关键节点对应的电极即为优化得到可监测脑状态的关键电极;对通过优化得到的关键电极采集到的脑电信号,建立多元多尺度复杂网络,提取所述多元多尺度复杂网络中的图能量和聚集系数熵指标,将不同尺度下得到的多元多尺度复杂网络指标组成特征向量进行归一化,作为深度学习模型的样本输入,将脑状态作为深度学习模型的输出,通过对大量样本的无监督学习和有监督学习,得到一个深度学习模型,所述深度学习模型能够实现对脑状态的监测。

[0114] 以上对本发明和实施例的描述,并不局限于此,实施例中的描述仅是本发明的实施方式之一,在不脱离本发明创造宗旨的情况下,任何不经创造性的设计出与该技术方案类似的结构或实施例,均属本发明的保护范围。

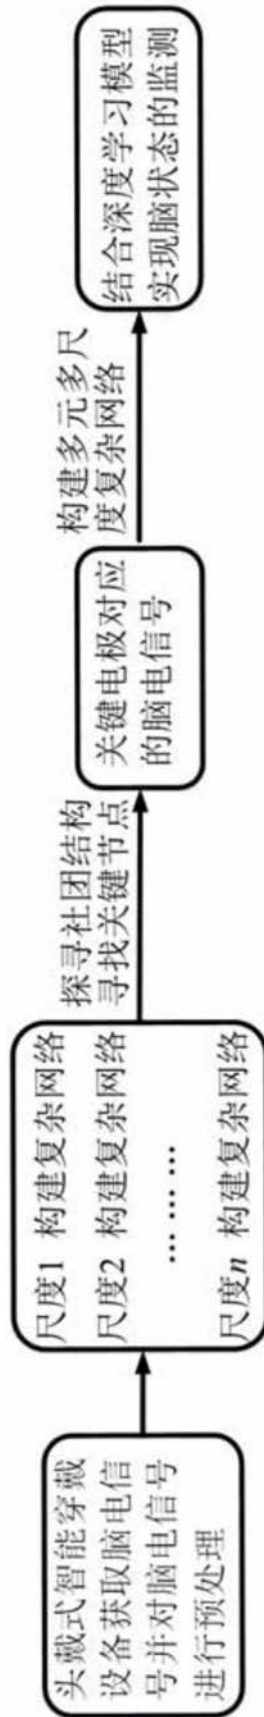


图1

专利名称(译)	用于脑状态监测的头戴式智能穿戴电极数量优化法及应用		
公开(公告)号	CN106491083B	公开(公告)日	2019-05-14
申请号	CN201610887684.0	申请日	2016-10-11
[标]申请(专利权)人(译)	天津大学		
申请(专利权)人(译)	天津大学		
当前申请(专利权)人(译)	天津大学		
[标]发明人	高忠科 杨宇轩 蔡清		
发明人	高忠科 杨宇轩 蔡清		
IPC分类号	A61B5/00 A61B5/0476		
CPC分类号	A61B5/0476 A61B5/6803 A61B5/7235 A61B5/7264		
其他公开文献	CN106491083A		
外部链接	Espacenet SIPO		

摘要(译)

一种用于脑状态监测的头戴式智能穿戴电极数量优化法及应用：对智能穿戴设备测得的多通道信号进行预处理，得到多尺度多通道信号；对所有尺度下的多通道信号构建多尺度加权递归网络；在每个尺度下，对交叉递归率矩阵选取阈值；采用基于贪婪优化策略的鲁文算法探寻多尺度无权递归网络的社团结构；通过比较不同脑状态下的社团结构的演化，同时结合复杂网络的关键节点探寻算法，确定网络中的关键节点，关键节点对应的电极即为可监测脑状态变化的关键电极；针对关键电极测得的多通道信号，构建多元多尺度复杂网络；针对关键电极所得信号构建的多元多尺度复杂网络提取复杂网络指标；训练深度学习模型和进行脑状态监测。本发明可提高智能穿戴设备的便携性和实用性。

