



(12)发明专利申请

(10)申请公布号 CN 110969108 A

(43)申请公布日 2020.04.07

(21)申请号 201911168627.7

(22)申请日 2019.11.25

(71)申请人 杭州电子科技大学

地址 310018 浙江省杭州市下沙高教园区2
号大街

(72)发明人 宋超 周易之 张启忠 谢翠

高云园 席旭刚 马玉良 罗志增

(74)专利代理机构 杭州君度专利代理事务所

(特殊普通合伙) 33240

代理人 杨舟涛

(51)Int.Cl.

G06K 9/00(2006.01)

G06K 9/62(2006.01)

A61B 5/0476(2006.01)

A61B 5/00(2006.01)

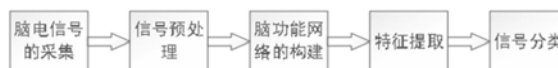
权利要求书3页 说明书9页 附图2页

(54)发明名称

一种基于自主运动想象脑电的肢体动作识别方法

(57)摘要

本发明是一种基于自主运动想象脑电的肢体动作识别方法,调查数据表明,当人做同一个动作时,大脑会产生类似的脑电信号,因此可以提取这些特征信号来实现机械臂的运动,进而辅助残疾人运动。本发明通过建立脑网络进行动作的分类,这种方法加强了大脑各个区域之间相关性的考虑,展现了EEG信号及其相关节律特征背后的工作机制。之后通过一种全新的基于非线性部分定向相干方法的脑因效性网络分析法,利用随机森林进行进行上肢运动分类,分类准确度高,根据脑电信号判断相应的动作,从而使得机械臂运动,达到残疾人辅助运动的目的。



1. 一种基于自主运动想象脑电的肢体动作识别方法,其特征在于该方法包括如下步骤:

步骤一、脑电信号的采集;

步骤二、信号预处理;对步骤一采集到的脑电信号进行小波阈值去噪,选取软阈值法对脑电信号进行消噪处理,可有效消除噪音,从而获取更加纯净的脑电信号,具体操作步骤如下:

2-1、确定小波的基函数以及分解尺度 h ;通过小波分解将脑电信号分解至各层,每层系数记为 $w_{h,k}$,其中 k 指分解的层数;

2-2、确定分解系数阈值 λ ;

2-3、计算各层的系数 $w_{h,k}$,计算公式如下:

$$w_{h,k} = \begin{cases} [\text{sgn}(w)](|w| - \lambda), & |w| \geq \lambda \\ 0, & |w| < \lambda \end{cases} \quad (1)$$

其中 w 为小波系数, $[\text{sgn}(w)]$ 表示单位阶跃函数;

步骤三、脑功能网络的构建;通过多通道自动回归模式Multi-channel Auto-regressive Mode可描述通道间的相互作用,之后通过非线性部分定向相干分析法,用于计算多通道信号之间的相干性及其方向;

3-1、多通道自动回归模式;

根据格兰杰因果性原理,假设存在两个信号 X 、 Y ,若利用 X 在 n 时间之前的数据预测 X 在第 q 步的数据时预测误差为 e_1 ,利用 X 、 Y 在 n 时间之前的数据预测 X 在第 q 步的数据时预测误差为 e_2 ,在 $e_1 > e_2$ 时则认为 Y 有效改善了对 X 的预测;现讨论多通道下的格兰杰因果性,构建MVAR模型:

定义 d 通道 n 时刻的脑电信号为:

$$X(t) = [X(1,n), X(2,n), \dots, X(d,n)] \quad (2)$$

则其MVAR模型表示为如下自回归过程:

$$\begin{aligned} x_1(n) &= \sum_{r=1}^p a_{11}(r)x_1(n-r) + \dots + \sum_{r=1}^p a_{1d}(r)x_d(n-r) + e_1(n) \\ x_2(n) &= \sum_{r=1}^p a_{21}(r)x_1(n-r) + \dots + \sum_{r=1}^p a_{2d}(r)x_d(n-r) + e_2(n) \\ &\dots \\ x_d(n) &= \sum_{r=1}^p a_{d1}(r)x_1(n-r) + \dots + \sum_{r=1}^p a_{dd}(r)x_d(n-r) + e_d(n) \end{aligned} \quad (3)$$

其中 r 表示模型阶数, $r=1,2,\dots,p$, $x_l(n)$ 表示 n 时刻 l 通道状态变量值, $l=1,2,\dots,d$, e_l 表示 l 通道偏差;

以矩阵形式表示为

$$X(n) = \sum_{r=1}^p \begin{pmatrix} a_{11} & \dots & a_{1d} \\ \vdots & \ddots & \vdots \\ a_{d1} & \dots & a_{dd} \end{pmatrix} \begin{pmatrix} x_1(n-r) \\ \vdots \\ x_d(n-r) \end{pmatrix} + \begin{pmatrix} e_1(n) \\ \vdots \\ e_d(n) \end{pmatrix} \quad (4)$$

即

$$\mathbf{X}(n) = \sum_{r=1}^p A(r) \mathbf{X}(n-r) + \mathbf{E}(n) \quad (5)$$

其中矩阵A(r)表示模型的预测系数,矩阵E(n)表示模型的预测误差,即为模型的噪声,p是MVAR的最大预测阶数,依靠AIC准则来确定,通常情况下, $AIC(p) = -2L/m + 2M/m$,其中L是对数似然值,m是观测值数目,M是被估计的参数个数,AIC准则要求其越小越好;

3-2、非线性部分定向相干

非线性部分定向相干分析法用于研究多路信号之间的相干性及其方向,该方法的理论依据如下:

基于MVAR模型的系数矩阵A(n),对其进行变换

$$\begin{aligned} A(f) &= \sum_{r=1}^p A_r e^{-j2\pi r f / f_s} \\ \overline{A(f)} &= \mathbf{I} - \sum_{r=1}^p A(n) e^{-j2\pi r f / f_s} \end{aligned} \quad (6)$$

其中f表示频率,f_s表示抽样频率,A(f)是频域下的系数矩阵;

定义

$$\overline{A(f)} = \mathbf{I} - A(f) = \begin{bmatrix} \overline{a_1(f)} & \overline{a_2(f)} & \cdots & \overline{a_4(f)} \end{bmatrix} \quad (7)$$

其中I表示与A(f)系数矩阵同等大小的单元矩阵,因此 $\overline{A(f)}$ 中的每一个元素表示为:

$$\overline{A_{ij_1}(f)} = \begin{cases} 1 - \sum_{r=1}^p a_{ij_1}(r) e^{-j2\pi r f}, i = j_1 \\ -\sum_{r=1}^p a_{ij_1}(r) e^{-j2\pi r f}, i \neq j_1 \end{cases} \quad (8)$$

其中i, j₁ = 1, 2, ..., d,则得到当频率为f时,第i个通道对第j₁个通道的PDC值为

$$PDC_{ij_1}(f) = \frac{|\overline{A_{ij_1}(f)}|}{\sqrt{\overline{a_{j_1}(f)}^T \times a_{j_1}(f)}} = \pi_{ij_1}(f) \quad (9)$$

其中, $\overline{A_{ij_1}(f)}$ 为 $\overline{A(f)}$ 第i行,第j₁列的元素,而 $\overline{a_{j_1}(f)}$ 为 $\overline{A(f)}$ 第j₁列,上标T表示转置;

计算某频段下的PDC平均值:

$$\overline{PDC_{ij_1}} = \sum_f \overline{\pi_{ij_1}(f)} / \nabla f \quad (10)$$

其中 $\overline{PDC_{ij_1}}$ 就是第i路信号对第j₁路信号的相干性,其中频率区间用 ∇f 表示;

用上述PDC方法计算出40个通道之间的相干性系数;采用显著性水平的方法计算阈值T,当PDC值大于阈值T时,认为两个通道之间是具有相关性,用1表示;当PDC值小于阈值T时,则认为这两通道间不具有相关性用0表示,这样就得到二值化的矩阵;

步骤四、特征提取;基于PDC方法的脑功能网络模型是描述大脑神经活动的有效方法;

从步骤三获得的矩阵中提取连通性特征度,用来描述由EEG信号表示的网络节点之间的关系;

节点 v_i 的度 u_i 定义为与该节点连接的边数,一个节点的度越大,这个节点在网络中就越重要;网络中节点度分布的情况可用分布函数 $P(u)$ 描述,表示网络中度为 u 的节点在整个网络中所占的比例;

步骤五、分类方法;对于提取出的特征度,利用随机森林分类器进行分类;随机森林通过Bootstrap方法从原始训练样本集 N 中有放回且随机的抽取 g 个样本生成 g 个新的训练样本集合,然后根据这 g 个训练样本集生成 g 棵决策树生成随机森林,其基本单元为决策树;决策树是一种树状的模型,每棵树中都包含根节点、内部节点和叶子节点,决策树中的每一个节点代表训练集的属性,节点之间的路径表示特征属性的可能取值,决策树的决策过程就是通过待分类数据的特征属性,选择输出分支,依次从根节点到达叶子节点的过程;具体步骤如下:

5-1、采用Bootstrap方法在原始训练样本集 N 中有放回的抽取 t 个新的训练样本集;

5-2、根据这 g 个样本集生成 g 棵决策树,假设输入参数的总数为 T ,从中随机选择 t 个参数,那么该决策树根据这 t 个特征变量选择最优的方式分割数据,并且在随机森林的生成过程中 t 值恒定;

5-3、根据分类问题,将 g 个决策树的分类结果以服从多数投票的方式产生。

一种基于自主运动想象脑电的肢体动作识别方法

技术领域

[0001] 本发明属于信号特征分析领域,涉及一种基于非线性部分定向相干法的脑网络特征进行动作识别的方法。

背景技术

[0002] 目前世界上有超过10亿的残疾人,占比高达15%,他们每天被自身残疾所困扰,给日常生活造成极大不便,有些甚至做不到日常的基本动作,如曲腕、曲肘、握拳、展拳等动作,他们的生活更是因为残疾而遭到破坏;另一方面,通过已有调查研究表明,大脑控制机体运动,而大脑所产生特定的脑电信号会通过神经传播,进而控制肌肉收缩来实现特定的机体运动。而通过提取这些特有的脑电信号,然后控制机械手臂运动,从而达到残疾人辅助运动或辅助治疗的目的。

[0003] 因此,我们可以通过一个系统,将脑电信号的特征分析并提取出来,然后将信号进行处理,接着通过一系列传输,最终实现机械臂的运动,这个系统就是脑计算机接口(BCI),也称为脑机接口(BMI),是一个在大脑和外界(计算机或其他设备及外部环境)之间传递信息的硬件及软件按通讯系统,该系统不依赖于外围神经和肌肉组成的大脑正常输出通路,根据脑电信号的产生原理以及神经生理学现象划分,BCI的输入信号可以分为自发型电位与诱发型电位。BCI可以通过上述输入信号在大脑和输出装置之间建立无肌肉的通道来提供以及增强通信,可以有效的改善由于脊髓损伤(SCI)、感觉运动功能不全者或肢体残障所造成的运动障碍问题。

[0004] 一般来说,BCI运动辅助系统的主要工作过程包括:脑电信号的采集、预处理、特征提取以及模式识别,其中特征提取以及模式识别是MI-BCI系统的核心部分。目前,信号采集包括植入式与非植入式两种方式。非植入式方式包括脑磁图成像(magnetoencephalography, MEG),功能性近红外成像(functional near-infrared spectroscopy, fNIRS),功能性磁共振成像(functional magnetic resonance imaging, fMRI),脑电图(electroencephalographic, EEG)等;植入性方式包括脑皮层电位图(electrocorticogram)、皮质内植入电极(intracortical recording devices)等。与植入式相比,非植入式对于用户没有损害,时间分辨率较高,因而成为近十几年来研究的热点。其中,基于脑电信号EEG的脑机接口是患者易于接受的方式,也是将脑机接口延伸到日常生活应用,成为扩展普通人日常人机交互的最佳方式。然而,EEG信号的获取也面临着很多问题:采集到的信号十分微弱、易受到噪声与伪迹(肌电EMG信号,眼电EOG信号等)干扰、脑电原信号经过脑脊液,颅骨和头皮的传导后存在交叉串扰(cross talk)、空间分辨率大大下降等。为了提高EEG信号解码的准确性以及实时性,需要改进EEG信号的特征提取以及分类方法。

[0005] 目前从EEG信号中提取的相关特征主要分为:时域特征、频域特征、时频域特征、非线性动力学特征等。上述特征分析方法的共性是通过处理、分析EEG信号得到信号的最优特征,虽然已经取得了一定的研究成果,很大程度上提高了EEG信号分类的准确性,但却缺乏

对大脑各个区域之间相关性的考虑,无法展现EEG信号及其相关节律特征背后的工作机制。随着认知神经科学研究的不断深入,越来越多的研究者开始关注不同脑区之间的信息交流问题,而脑网络的方法通过功能整合以及定位综合的分析模式,可以深入的分析人脑的组织结构以及认知基础。随着复杂网络理论不断发展,这一理论已经为人脑连接组的相关研究奠定了基础,被称为基于图论的脑网络研究。目前脑网络的主要研究集中于功能性网络,利用线性方法,包括线性Pearson相关分析方法,偏相关分析法等,以及非线性方法:希尔伯特变换、似然同步法、非线性斯皮尔曼 (Spearman) 等方法进行构建。然而,功能性网络主要关注大脑节点信号在特定时间节点的统计学关系,无法有效的反映节点间的因果关系。为了深入研究人体肢体运动时相关脑区的信息流向,需要构建因效性网络。基于格兰杰因果性 (Granger causality, GC) 的因效性网络分析方法很好的解决了这个问题,其中部分定向相干法发展较为成熟,因此,通过该方法建立脑网络具有很强的理论基础以及应用优势。

[0006] BCI运动辅助的另一个重要问题就是如何寻找一个具有较强泛化能力的分类器。在过去的研究中,不同的分类器被广泛运用于MI-EEG特征的分类,例如学习矢量量化 (LVQ)、多层神经网络 (MLNN)、深度信念网络和人工神经网络 (ANN)、K近邻算法、基于马氏距离的分类器等。有关ELM和SVM都已经被证明是非常有效的分类方法。近年来,与ELM以及SVM相关的改进方法也不断涌现。

发明内容

[0007] 本发明针对现有技术的不足,提出了一种基于自主运动想象脑电的肢体动作识别方法,本发明首先通过建立脑网络实施动作的分类,这种方法加强了大脑各个区域之间的相关性,展现了EEG信号及其相关节律特征背后的工作机制;之后通过一种全新的基于非线性部分定向相干方法:脑因效性网络分析法,利用随机森林进行上肢运动分类,获得高准确度的分类,然后根据脑电信号判断相应的动作,从而使得机械臂运动,达到残疾人辅助运动的目的。

[0008] 为了实现以上目的,本发明方法主要包括以下步骤:

[0009] 步骤一、脑电信号的采集;在实验过程中,使用的仪器是Brain Products公司所研制的脑电配套采集设备,能够方便精准地采集实验所需数据,也可以进行EEG信号的后期处理;

[0010] 步骤二、信号预处理;对步骤一采集到的脑电信号进行小波阈值去噪,选取软阈值法对脑电信号进行消噪处理,可有效消除噪音,从而获取更加纯净的脑电信号,具体操作步骤如下:

[0011] 2-1、确定小波的基函数以及分解尺度h;通过小波分解将脑电信号分解至各层,每层系数记为 $w_{h,k}$,其中k指分解的层数;

[0012] 2-2、确定分解系数阈值 λ ;

[0013] 2-3、计算各层的系数 $w_{h,k}$,计算公式如下:

$$[0014] \quad w_{h,k} = \begin{cases} [\text{sgn}(w)](|w| - \lambda), & |w| \geq \lambda \\ 0, & |w| < \lambda \end{cases} \quad (1)$$

[0015] 其中 w 为小波系数, $[\text{sgn}(w)]$ 表示单位阶跃函数。

[0016] 步骤三、脑功能网络的构建;通过多通道自动回归模式 (Multi-channel Auto-regressive Mode) 可描述通道间的相互作用,之后通过非线性部分定向相干分析法,用于计算多通道信号之间的相干性及其方向。

[0017] 3-1、多通道自动回归模式;

[0018] 根据格兰杰因果性原理,假设存在两个信号 X 、 Y ,若利用 X 在 n 时间之前的数据预测 X 在第 q 步的数据时预测误差为 e_1 ,利用 X 、 Y 在 n 时间之前的数据预测 X 在第 q 步的数据时预测误差为 e_2 ,在 $e_1 > e_2$ 时则认为 Y 有效改善了对 X 的预测。现讨论多通道下的格兰杰因果性,构建MVAR模型:

[0019] 定义 d 通道 n 时刻的脑电信号为:

$$[0020] \quad X(t) = [X(1, n), X(2, n), \dots, X(d, n)] \quad (2)$$

[0021] 则其MVAR模型可表示为如下自回归过程:

$$\begin{aligned}
 [0022] \quad x_1(n) &= \sum_{r=1}^p a_{11}(r)x_1(n-r) + \dots + \sum_{r=1}^p a_{1d}(r)x_d(n-r) + e_1(n) \\
 x_2(n) &= \sum_{r=1}^p a_{21}(r)x_1(n-r) + \dots + \sum_{r=1}^p a_{2d}(r)x_d(n-r) + e_2(n) \\
 &\dots \\
 x_d(n) &= \sum_{r=1}^p a_{d1}(r)x_1(n-r) + \dots + \sum_{r=1}^p a_{dd}(r)x_d(n-r) + e_d(n)
 \end{aligned} \quad (3)$$

[0023] 其中 r 表示模型阶数, $r=1, 2, \dots, p$, $x_l(n)$ 表示 n 时刻 l 通道状态变量值, $l=1, 2, \dots, d$, e_l 表示 l 通道偏差。

[0024] 以矩阵形式可表示为

$$[0025] \quad X(n) = \sum_{r=1}^p \begin{pmatrix} a_{11} & \dots & a_{1d} \\ \vdots & \ddots & \vdots \\ a_{d1} & \dots & a_{dd} \end{pmatrix} \begin{pmatrix} x_1(n-r) \\ \vdots \\ x_d(n-r) \end{pmatrix} + \begin{pmatrix} e_1(n) \\ \vdots \\ e_d(n) \end{pmatrix} \quad (4)$$

[0026] 即

$$[0027] \quad X(n) = \sum_{r=1}^p A(r)X(n-r) + E(n) \quad (5)$$

[0028] 其中矩阵 $A(r)$ 表示模型的预测系数,矩阵 $E(n)$ 表示模型的预测误差,即为模型的噪声, p 是MVAR的最大预测阶数,依靠AIC(Akaike information criterion)准则来确定,通常情况下, $AIC(p) = -2L/m + 2M/m$,其中 L 是对数似然值, m 是观测值数目, M 是被估计的参数个数,AIC准则要求其越小越好。因为,AIC的大小取决于 L 和 M 。 M 值越小,则AIC值越小;同样, L 值越大,则AIC值越小。而 M 值小意味着模型简洁, L 大意味着模型精确。因此只需选取最小的AIC值即可,AIC准则兼顾了模型的简洁性和精确性。

[0029] 3-2、非线性部分定向相干

[0030] 非线性部分定向相干分析法是2001年由Luiz A.Baccala和Koichi Sameshima提出的一种基于格兰杰因果的新方法,用于研究多路信号之间的相干性及其方向,该方法的理论依据如下:

[0031] 基于MVAR模型的系数矩阵A(n),对其进行变换

$$A(f) = \sum_{r=1}^p A_r e^{-j2\pi rf/f_s}$$

$$\overline{A(f)} = \mathbf{I} - \sum_{r=1}^p A(n) e^{-j2\pi rf/f_s} \quad (6)$$

[0033] 其中f表示频率,f_s表示抽样频率,A(f)是频域下的系数矩阵。

[0034] 定义

$$\overline{A(f)} = \mathbf{I} - A(f) = [\overline{a_1(f)} \quad \overline{a_2(f)} \quad \cdots \quad \overline{a_4(f)}] \quad (7)$$

[0036] 其中I表示与A(f)系数矩阵同等大小的单元矩阵,因此 $\overline{A(f)}$ 中的每一个元素可表示为:

$$\overline{A_{ij_1}(f)} = \begin{cases} 1 - \sum_{r=1}^p a_{ij_1}(r) e^{-j2\pi rf}, i = j_1 \\ -\sum_{r=1}^p a_{ij_1}(r) e^{-j2\pi rf}, i \neq j_1 \end{cases} \quad (8)$$

[0038] 其中i, j₁=1, 2, ..., d,则得到当频率为f时,第i个通道对第j₁个通道的PDC值为

$$PDC_{ij_1}(f) = \frac{|\overline{A_{ij_1}(f)}|}{\sqrt{\overline{a_{j_1}(f)}^T \times \overline{a_{j_1}(f)}}} = \pi_{ij_1}(f) \quad (9)$$

[0040] 其中, $\overline{A_{ij_1}(f)}$ 为 $\overline{A(f)}$ 第i行,第j₁列的元素,而 $\overline{a_{j_1}(f)}$ 为 $\overline{A(f)}$ 第j₁列,上标T表示转置。

[0041] 计算某频段下的PDC平均值:

$$\overline{PDC_{ij_1}} = \sum_f \overline{\pi_{ij_1}(f)} / \nabla f \quad (10)$$

[0043] 其中 $\overline{PDC_{ij_1}}$ 就是第i路信号对第j₁路信号的相干性,其中频率区间用 ∇f 表示。

[0044] 用上述PDC方法计算出40个通道之间的相干性系数。采用显著性水平的方法计算阈值T,当PDC值大于阈值T时,认为两个通道之间是具有相关性,用1表示;当PDC值小于阈值T时,则认为这两通道间不具有相关性用0表示,这样就得到二值化的矩阵。

[0045] 步骤四、特征提取;基于PDC方法的脑功能网络模型是描述大脑神经活动的有效方法。它是一个复杂的动态系统,由节点代表的动态单元的相互作用组成。本发明从步骤三获得的矩阵中提取连通性特征度,用来描述由EEG信号表示的网络节点之间的关系。

[0046] 节点v_i的度u_i定义为与该节点连接的边数,其中,一个节点的度越大,这个节点在网络中就越重要。网络中节点度分布的情况可用分布函数P(u)描述,表示网络中度为u的节点在整个网络中所占的比例。

[0047] 步骤五、分类方法;对于提取出的特征度,利用随机森林分类器进行分类。随机森林通过Bootstrap方法从原始训练样本集N中有放回且随机的抽取g个样本生成g个新的训

训练样本集合,然后根据这g个训练样本集生成g棵决策树生成随机森林,其基本单元为决策树。决策树是一种树状的模型,每棵树中都包含根节点、内部节点和叶子节点,决策树中的每一个节点代表训练集的属性,节点之间的路径表示特征属性的可能取值,决策树的决策过程就是通过待分类数据的特征属性,选择输出分支,依次从根节点到达叶子节点的过程。具体步骤如下:

[0048] 5-1、采用Bootstrap方法在原始训练样本集N中有放回的抽取t个新的训练样本集。

[0049] 5-2、根据这g个样本集生成g棵决策树,假设输入参数的总数为T,从中随机选择t个参数,那么该决策树根据这t个特征变量选择最优的方式分割数据,并且在随机森林的生成过程中t值恒定。

[0050] 5-3、根据分类问题,将g个决策树的分类结果以服从多数投票的方式产生。

[0051] 本发明与已有的诸多脑电信号的提取与分析相比,具有如下特点:

[0052] 本文采用小波去噪的方法,将含噪声的源信号进行小波分解,得到不同频段的小波分解系数,同时设定阈值将噪声信号与脑电信号分离。

[0053] 本文采用构建脑网络来进行脑电信号特征的提取,基于格兰杰因果性的因效性网络分析方法很好的反映节点间的因果关系,其中部分定向相干法发展较为成熟,因此,通过该方法建立脑网络具有很强的理论基础以及应用优势。

[0054] 另外,本文采用随机森林的方法将产生特定动作的脑电信号进行分类,可以有效地辨别动作。

附图说明

[0055] 图1为本发明方法的实现框图;

[0056] 图2为本发明的脑电信号采集设备;

[0057] 图3为本发明采集脑电信号过程的示意图;

[0058] 图4为本发明中新型AatiCap 128导测量帽的布局图;

[0059] 图5为本发明中随机森林流程图。

具体实施方式

[0060] 下面结合附图对本发明的实施例作详细说明,这个实例是根据本发明技术方案来实施的,给出了详细的实施方式和具体的操作过程,但是本发明方案却不限于这一个实例。

[0061] 本发明提出了一种全新的基于非线性部分定向相干方法的脑因效性网络分析法,利用随机森林进行上肢运动分类。主要过程如下:对于采集到42通道EEG信号进行滤波处理,利用非线性部分定向相干法构建有向建脑功能网络,并提取了度、度分布、聚类系数等特征。利用随机森林对曲轴、曲腕、握拳、展拳等四个动作进行分类,发现基于部分定向相干性构建的脑功能网络的随机森林分类方法对于上肢动作的识别率较高,并证明了该方法是鲁棒的。

[0062] 如图1所示,本实例包括以下步骤:

[0063] 步骤一、脑电信号的采集;在实验过程中,使用的仪器是Brain Products公司所研制的脑肌电配套采集设备,如图2所示,这套系统中主要包括对种软硬件设备:放大器、电极

以及电极帽、采集记录软件及后期处理软件。通过这套设备能够方便精准地采集实验所需数据,也可以进行EEG信号的后期处理。

[0064] 实验室周围使用遮光窗帘隔绝过强的光线,并保证没有大幅度的光线强弱变化。房间具备很强的隔音能力,尽可能隔绝外界不必要的干扰。在数据采集过程中,实验室的温度一直稳定为25℃。在进行数据采集的过程里,采集人员不能随意走动或出声。数据采集过程由5名男性受试者和3名女性受试者参与完成,其年龄都处于23-30岁间,平均年龄为26岁。脑部功能健全,无其他神经系统疾病。在进行采集前向其告知了整个数据采集过程,之后征得了所有受试者的同意,脑电信号采集过程示意图如图3所示。

[0065] 实验采用的是新型AatiCap 128导测量帽来采集EEG信号,其布局图如图4所示。在本次采集过程中,使用了其中40个EEG通道来覆盖目标研究区域,另外使用乳突EAR为参考电极。采样电极具体布局如表1所示。

[0066] 表1采样电极布局

Number	Brain Areas	EEG Channels
1-7	Prefrontal lobe	FP1,FPZ, FP2,AF3,AF4,AF7,AF8
8-9	Interior frontal lobe	F7,F8
10-19	Frontal lobe	FZ,F1,F2,F3,F4,F5,F6,F9,F10
[0067] 20-25	Central frontal lobe	FC1,FC2,FC3,FC4,FC5,FC6
26-30	Central lobe	CZ,C3,C4,C5,C6
31-32	Temporal lobe	T7,T8
33-34	Temporal Partial lobe	TP7,TP8
35-40	Central Parietal lobe	CPZ,CP1,CP2,CP3,CP4,CP5,CP6

[0068] 在进行采集之前将完整的实验流程和细节告知受试者,让其熟悉整个流程。告知受试者在正式进行实验采集时尽可能避免所有不在实验计划中的肢体动作,特别要避免身体和头部的晃动,尽可能降低对数据的干扰使采集的数据更加准确。在进行正式数据采集前,给受试者戴上安装完毕的电极帽,并向电极中注入导电胶来降低阻抗,调整电极接触情况直到阻抗降到阈值以下来保证采集到的信号的质量。

[0069] 实验采集频率设定为5000HZ,同步记录脑电信号。受试者需按照以下步骤并根据要求作出指定的握拳、展拳、屈腕及屈肘动作:

[0070] a) 开始时受试者保持静坐状态15s。在此过程中要求被试者正坐在靠椅上,放松手部肌肉,平静心情,尽量减少干扰。

[0071] b) 被试者根据要求依序进行握拳、展拳、屈腕及屈肘4组动作,每组保持该动作持续5s,然后进行休息状态,休息15s后进行下一次动作。

[0072] c) 一组动作需要将该动作进行10次,从左手开始,做完一组换到右手进行下一组。左右手分别完成一组动作之后,开始换到下一个动作进行,直至左右手分别做完所有4组动作。

[0073] 数据采集的过程控制在30分钟以内,避免受试者出现疲劳或者注意力分散的情况。采集结束后及时关闭设备,清洗电极、电极帽,整理仪器。

[0074] 步骤二、信号预处理;对步骤一采集到的脑电信号进行小波阈值去噪,小波阈值去噪方法的基本思想是将含噪声的源信号进行小波分解,得到不同频段的小波分解系数,同时设定阈值,如果该系数小于设定的临界阈值,则说明此时的小波系数主要由噪声引起,可予以舍去;若该系数大于临界阈值,则说明此时的小波系数主要源于信号,此时,通过软阈值法对该系数进行收缩处理。具体操作步骤如下:

[0075] 2-1、确定小波的基函数以及分解尺度 h 。通过小波分解将脑、肌信号分解至各层,每层系数记为 $w_{h,k}$,其中 k 指分解的层数。

[0076] 2-2、确定分解系数阈值 λ ;

[0077] 2-3、计算各层的系数 $w_{h,k}$,计算公式如下:

$$[0078] \quad w_{h,k} = \begin{cases} [\text{sgn}(w)](|w| - \lambda), & |w| \geq \lambda \\ 0, & |w| < \lambda \end{cases} \quad (1)$$

[0079] 其中 w 为小波系数, $[\text{sgn}(w)]$ 表示单位阶跃函数。

[0080] 步骤三、脑功能网络的构建;首先通过多通道自动回归模式Multi-channel Auto-regressive Mode描述通道间的相互作用,之后通过非线性部分定向相干分析法,用于计算多通道信号之间的相干性及其方向。

[0081] 3-1、多通道自动回归模式;

[0082] 根据格兰杰因果性原理,假设存在两个信号 X 、 Y ,若利用 X 在 n 时间之前的数据预测 X 在第 q 步的数据时预测误差为 e_1 ,利用 X 、 Y 在 n 时间之前的数据预测 X 在第 q 步的数据时预测误差为 e_2 ,在 $e_1 > e_2$ 时则认为 Y 有效改善了对 X 的预测。现讨论多通道下的格兰杰因果性,构建MVAR模型:

[0083] 定义 d 通道 n 时刻的脑电信号为:

$$[0084] \quad X(t) = [X(1,n), X(2,n), \dots, X(d,n)] \quad (2)$$

[0085] 则其MVAR模型可表示为如下自回归过程:

$$[0086] \quad \begin{aligned} x_1(n) &= \sum_{r=1}^p a_{11}(r)x_1(n-r) + \dots + \sum_{r=1}^p a_{1d}(r)x_d(n-r) + e_1(n) \\ x_2(n) &= \sum_{r=1}^p a_{21}(r)x_1(n-r) + \dots + \sum_{r=1}^p a_{2d}(r)x_d(n-r) + e_2(n) \\ &\dots \\ x_d(n) &= \sum_{r=1}^p a_{d1}(r)x_1(n-r) + \dots + \sum_{r=1}^p a_{dd}(r)x_d(n-r) + e_d(n) \end{aligned} \quad (3)$$

[0087] 其中 r 表示模型阶数, $r=1,2,\dots,p$, $x_l(n)$ 表示 n 时刻 l 通道状态变量值, $l=1,2,\dots,d$, e_l 表示 l 通道偏差。

[0088] 以矩阵形式可表示为

$$[0089] \quad X(n) = \sum_{r=1}^p \begin{pmatrix} a_{11} & \dots & a_{1d} \\ \vdots & \ddots & \vdots \\ a_{d1} & \dots & a_{dd} \end{pmatrix} \begin{pmatrix} x_1(n-r) \\ \vdots \\ x_d(n-r) \end{pmatrix} + \begin{pmatrix} e_1(n) \\ \vdots \\ e_d(n) \end{pmatrix} \quad (4)$$

[0090] 即

$$[0091] \quad \mathbf{X}(n) = \sum_{r=1}^p \mathbf{A}(r) \mathbf{X}(n-r) + \mathbf{E}(n) \quad (5)$$

[0092] 其中矩阵 $\mathbf{A}(r)$ 表示模型的预测系数,矩阵 $\mathbf{E}(n)$ 表示模型的预测误差,即为模型的噪声, p 是MVAR的最大预测阶数,依靠AIC(Akaike information criterion)准则来确定,通常情况下, $AIC(p) = -2L/m + 2M/m$,其中 L 是对数似然值, m 是观测值数目, M 是被估计的参数个数,AIC准则要求其越小越好。因为,AIC的大小取决于 L 和 M 。 M 值越小,则AIC值越小;同样, L 值越大,则AIC值越小。而 M 值小意味着模型简洁, L 大意味着模型精确。因此只需选取最小的AIC值即可,AIC准则兼顾了模型的简洁性和精确性。

[0093] 3-2、非线性部分定向相干

[0094] 非线性部分定向相干分析法是2001年由Luiz A.Baccala和Koichi Sameshima提出的一种基于格兰杰因果的新方法,用于研究多路信号之间的相干性及其方向,该方法的理论依据如下:

[0095] 基于MVAR模型的系数矩阵 $\mathbf{A}(n)$,对其进行变换

$$[0096] \quad \begin{aligned} \mathbf{A}(f) &= \sum_{r=1}^p \mathbf{A}_r e^{-j2\pi r f / f_s} \\ \overline{\mathbf{A}(f)} &= \mathbf{I} - \sum_{r=1}^p \mathbf{A}(n) e^{-j2\pi r f / f_s} \end{aligned} \quad (6)$$

[0097] 其中 f 表示频率, f_s 表示抽样频率, $\mathbf{A}(f)$ 是频域下的系数矩阵。

[0098] 定义

$$[0099] \quad \overline{\mathbf{A}(f)} = \mathbf{I} - \mathbf{A}(f) = \begin{bmatrix} \overline{a_1}(f) & \overline{a_2}(f) & \cdots & \overline{a_d}(f) \end{bmatrix} \quad (7)$$

[0100] 其中 $\mathbf{I}$ 表示与 $\mathbf{A}(f)$ 系数矩阵同等大小的单元矩阵,因此 $\overline{\mathbf{A}(f)}$ 中的每一个元素可表示为:

$$[0101] \quad \overline{A_{ij_1}}(f) = \begin{cases} 1 - \sum_{r=1}^p a_{ij_1}(r) e^{-j2\pi r f}, i = j_1 \\ - \sum_{r=1}^p a_{ij_1}(r) e^{-j2\pi r f}, i \neq j_1 \end{cases} \quad (8)$$

[0102] 其中 $i, j_1 = 1, 2, \dots, d$,则得到当频率为 f 时,第 i 个通道对第 j_1 个通道的PDC值为

$$[0103] \quad PDC_{ij_1}(f) = \frac{|\overline{A_{ij_1}}(f)|}{\sqrt{\overline{a_{j_1}}(f)^T \times \overline{a_{j_1}}(f)}} = \pi_{ij_1}(f) \quad (9)$$

[0104] 其中, $\overline{A_{ij_1}}(f)$ 为 $\overline{\mathbf{A}(f)}$ 第 i 行,第 j_1 列的元素,而 $\overline{a_{j_1}}(f)$ 为 $\overline{\mathbf{A}(f)}$ 第 j_1 列,上标 T 表示转置。

[0105] 计算某频段下的PDC平均值:

$$[0106] \quad \overline{PDC}_{i_1} = \sum_f \overline{\pi}_{i_1}(f) / \nabla f \quad (10)$$

[0107] 其中 $\overline{PDC}_{i_1}$ 就是第 i 路信号对第 j_1 路信号的相干性, 其中频率区间用 ∇f 表示。

[0108] 用上述PDC方法计算出40个通道之间的相干性系数。采用显著性水平的方法计算阈值T, 当PDC值大于阈值T时, 认为两个通道之间是具有相关性, 用1表示; 当PDC值小于阈值T时, 则认为这两通道间不具有相关性用0表示, 这样就得到二值化的矩阵。

[0109] 步骤四、特征提取;

[0110] 通过脑网络的节点度和节点分布来进行特征提取, 节点 v_i 的度 u_i 定义为与该节点连接的边数, 一个节点的度越大, 这个节点在网络中就越重要。网络中节点度分布的情况可用分布函数 $P(u)$ 描述, 表示网络中度为 u 的节点在整个网络中所占的比例。

[0111] 步骤五、分类方法;

[0112] 对于提取出的特征度, 利用随机森林分类器进行分类, 如图5所示。随机森林通过Bootstrap方法从原始训练样本集 N 中有放回且随机的抽取 g 个样本生成 g 个新的训练样本集合, 然后根据这 g 个训练样本集生成 g 棵决策树生成随机森林, 其基本单元为决策树。决策树是一种树状的模型, 每棵树中都包含根节点、内部节点和叶子节点, 决策树中的每一个节点代表训练集的属性, 节点之间的路径表示特征属性的可能取值, 决策树的决策过程就是通过待分类数据的特征属性, 选择输出分支, 依次从根节点到达叶子节点的过程。具体步骤如下:

[0113] 5-1、采用Bootstrap方法在原始训练样本集 N 中有放回的抽取 t 个新的训练样本集。

[0114] 5-2、根据这 g 个样本集生成 g 棵决策树, 假设输入参数的总数为 T , 从中随机选择 t 个参数, 那么该决策树根据这 t 个特征变量选择最优的方式分割数据, 并且在随机森林的生成过程中 t 值恒定。

[0115] 5-3、根据分类问题, 将 g 个决策树的分类结果以服从多数投票的方式产生。其结果在Alpha段预测的准确率如表2所示。

[0116] 表2在Alpha段预测的准确率(%)

[0117]

动作	曲腕	曲肘	展拳	握拳	平均值
右手	78.3±5.4	72.9±5.2	80.0±4.7	78.8±5.8	76.4±5.3
左手	78.2±6.1	77.5±5.4	80.7±5.8	79.1±5.2	78.8±5.5

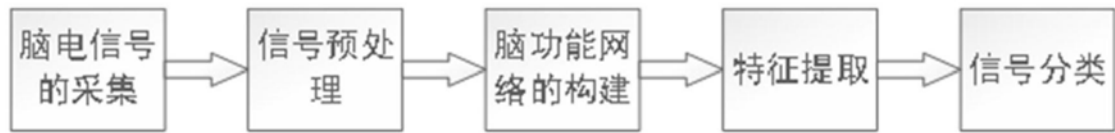


图1



图2



图3




图4




图5

专利名称(译)	一种基于自主运动想象脑电的肢体动作识别方法		
公开(公告)号	CN110969108A	公开(公告)日	2020-04-07
申请号	CN201911168627.7	申请日	2019-11-25
[标]申请(专利权)人(译)	杭州电子科技大学		
申请(专利权)人(译)	杭州电子科技大学		
当前申请(专利权)人(译)	杭州电子科技大学		
[标]发明人	宋超 周易之 张启忠 谢翠 高云园 席旭刚 马玉良 罗志增		
发明人	宋超 周易之 张启忠 谢翠 高云园 席旭刚 马玉良 罗志增		
IPC分类号	G06K9/00 G06K9/62 A61B5/0476 A61B5/00		
CPC分类号	A61B5/0476 A61B5/7203 A61B5/7267 G06K9/00335 G06K9/00516 G06K9/00523 G06K9/00536 G06K9/6282		
外部链接	Espacenet SIPO		

摘要(译)

本发明是一种基于自主运动想象脑电的肢体动作识别方法，调查数据表明，当人做同一个动作时，大脑会产生类似的脑电信号，因此可以提取这些特征信号来实现机械臂的运动，进而辅助残疾人运动。本发明通过建立脑网络进行动作的分类，这种方法加强了大脑各个区域之间相关性的考虑，展现了EEG信号及其相关节律特征背后的工作机制。之后通过一种全新的基于非线性部分定向相干方法的脑因效性网络分析法，利用随机森林进行进行上肢运动分类，分类准确度高，根据脑电信号判断相应的动作，从而使得机械臂运动，达到残疾人辅助运动的目的。

