



(12)发明专利申请

(10)申请公布号 CN 106963369 A

(43)申请公布日 2017.07.21

(21)申请号 201710187172.8

(22)申请日 2017.03.27

(71)申请人 广州视源电子科技股份有限公司

地址 510530 广东省广州市黄埔区云埔四
路6号

申请人 广州希科医疗器械科技有限公司

(72)发明人 胡静 赵巍

(74)专利代理机构 广州三环专利商标代理有限
公司 44202

代理人 麦小婵 郝传鑫

(51)Int.Cl.

A61B 5/0476(2006.01)

A61B 5/048(2006.01)

A61B 5/16(2006.01)

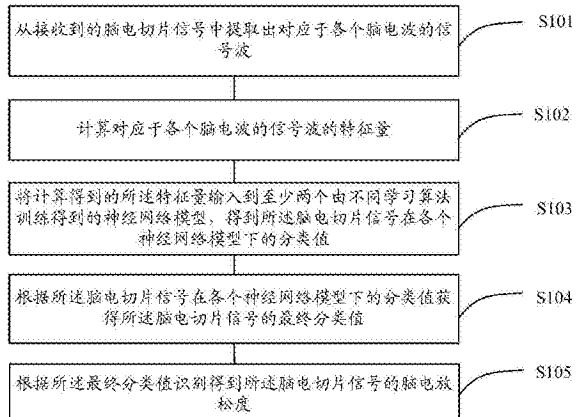
权利要求书2页 说明书14页 附图3页

(54)发明名称

一种基于神经网络模型的脑电放松度识别
方法及装置

(57)摘要

本发明公开了一种基于神经网络模型的脑电放松度识别方法，包括如下步骤：从接收到的脑电切片信号中提取出对应于各个脑电波的信号波；计算对应于各个脑电波的信号波的特征量；将计算得到的所述特征量输入到至少两个由不同学习算法训练得到的神经网络模型，得到所述脑电切片信号在各个神经网络模型下的分类值；根据所述脑电切片信号在各个神经网络模型下的分类值获得所述脑电切片信号的最终分类值；根据所述最终分类值识别得到所述脑电切片信号的脑电放松度。本发明还提供了一种基于神经网络模型的脑电放松度识别装置，可提高对脑电放松度识别的稳定性和准确性。



1. 一种基于神经网络模型的脑电放松度识别方法,其特征在于,包括如下步骤:
从接收到的脑电切片信号中提取出对应于各个脑电波的信号波;
计算对应于各个脑电波的信号波的特征量;
将计算得到的所述特征量输入到至少两个由不同学习算法训练得到的神经网络模型,得到所述脑电切片信号在各个神经网络模型下的分类值;
根据所述脑电切片信号在各个神经网络模型下的分类值获得所述脑电切片信号的最终分类值;
根据所述最终分类值识别得到所述脑电切片信号的脑电放松度。
2. 根据权利要求1所述的基于神经网络模型的脑电放松度识别方法,其特征在于,所述学习算法包括:Levenberg-Marquart算法、标准BP算法、增加动量项的BP算法、改进的GA-BP算法;且神经网络进行学习时使用的训练样本对由计算得到的所述特征量和标准设备同步采集得到的脑电放松度构成。
3. 根据权利要求1所述的基于神经网络模型的脑电放松度识别方法,其特征在于,所述对应于各个脑电波的信号波的特征量至少包括以下其中之一:对应于各个脑电波的信号波在时域空间的特征量、对应于各个脑电波的信号波在相空间的特征量、对应于各个脑电波的信号波在频域空间的特征量。
4. 根据权利要求1所述的基于神经网络模型的脑电放松度识别方法,其特征在于,在所述计算对应于各个脑电波的信号波的特征量之后,在所述将计算得到的所述特征量输入到至少两个由不同学习算法训练得到的神经网络模型,得到所述脑电切片信号在各个神经网络模型下的分类值之前,还包括:
基于主成分分析法对所述特征量进行降维处理。
5. 根据权利要求4所述的基于神经网络模型的脑电放松度识别方法,其特征在于,所述基于主成分分析法对所述特征量进行降维处理具体包括:
将所述特征量设置为输入样本空间中的特征量,并对所述输入样本空间进行数据标准化处理;
根据数据标准化处理后的所述输入样本空间得到协方差矩阵;
计算所述协方差矩阵的特征根和与每个特征根对应的特征向量;其中,所述特征根的数量为p个,且所述的p个特征根按照大小排序;
获取所述的p个特征根中,贡献率之和大于预定阈值的前m个特征根;其中,每个特征根的贡献率等于所述特征根的值除以全部的p个特征根的值之和;
根据与所述的前m个特征根对应的特征向量及所述输入样本空间,得到主成分得分矩阵;其中,所述主成分得分矩阵中的特征量为所述降维后的特征量。
6. 根据权利要求1所述的基于神经网络模型的脑电放松度识别方法,其特征在于,所述根据所述脑电切片信号在各个神经网络模型下的分类值获得所述脑电切片信号的最终分类值具体为:
统计所述脑电切片信号在各个神经网络模型下的分类值的出现频率,并将出现频率最高的分类值设定为最终分类值。
7. 一种基于神经网络模型的脑电放松度识别装置,其特征在于,包括:
信号提取单元,用于从接收到的脑电切片信号中提取出对应于各个脑电波的信号波;

特征量提取单元,用于计算对应于各个脑电波的信号波的特征量;

分类单元,用于将计算得到的所述特征量输入到至少两个由不同学习算法训练得到的神经网络模型,得到所述脑电切片信号在各个神经网络模型下的分类值;

最终分类值计算单元,用于根据所述脑电切片信号在各个神经网络模型下的分类值获得所述脑电切片信号的最终分类值;

脑电放松度识别单元,用于根据所述最终分类值识别得到所述脑电切片信号的脑电放松度。

8. 根据权利要求7所述的基于神经网络模型的脑电放松度识别装置,其特征在于,所述学习算法包括:Levenberg-Marquart算法、标准BP算法、增加动量项的BP算法、改进的GA-BP算法;且神经网络进行学习时使用的训练样本对由计算得到的所述特征量和标准设备同步采集得到的脑电放松度构成。

9. 根据权利要求7所述的基于神经网络模型的脑电放松度识别装置,其特征在于,还包括:

特征降维单元,用于基于主成分分析法对所述特征量进行降维处理。

10. 根据权利要求7所述的基于神经网络模型的脑电放松度识别装置,其特征在于,所述脑电放松度识别单元具体用于,统计所述脑电切片信号在各个神经网络模型下的分类值的出现频率,并将出现频率最高的分类值设定为最终分类值。

一种基于神经网络模型的脑电放松度识别方法及装置

技术领域

[0001] 本发明涉及放松治疗领域,尤其涉及一种基于神经网络模型的脑电放松度识别方法及装置。

背景技术

[0002] 放松训练是行为疗法中使用最广的技术之一,是在心理学实验的基础上建立和发展起来的咨询和治疗方法,其在治疗焦虑抑郁症、神经性头痛、失眠、高血压病,减轻更年期综合征和转变不良行为模式等方面取得了较好的疗效。

[0003] 现有的放松训练主要有录音指导、口头指导和生物反馈指导。其中,录音指导方法僵化、没有变化,无法根据受训者的状态变化内容;口头指导则要求对口头指导的对象要求很高,且受到时间、场地限制;生物反馈指导以脑电反馈为主,能够结合前两种方式的优点,因而受到广泛关注。

[0004] 进行生物反馈指导需要识别用户的放松度,而计算放松度首先需要从用户的脑电信号中提取各个频段的脑电波(包括Delta、Theta、Alpha、Beta、Gamma波),再提取各个脑电波的特征,将这些特征输入到分类器进行分类识别。

[0005] 现有的分类识别方法中,多采用单一的分类器对特征进行简单的二分类,这导致脑电放松度的识别稳定性不高,例如,容易受到外界环境的干扰或用户的生理波动的影响;而且,二分类无法实现放松度的更细致的分类,进而不能提供最有效的生物反馈指导。

发明内容

[0006] 针对上述问题,本发明的目的在于提供一种基于神经网络模型的脑电放松度识别方法及装置,可提高对脑电放松度识别的稳定性和准确率。

[0007] 本发明提供了一种基于神经网络模型的脑电放松度识别方法,包括如下步骤:

[0008] 从接收到的脑电切片信号中提取出对应于各个脑电波的信号波;

[0009] 计算对应于各个脑电波的信号波的特征量;

[0010] 将计算得到的所述特征量输入到至少两个由不同学习算法训练得到的神经网络模型,得到所述脑电切片信号在各个神经网络模型下的分类值;

[0011] 根据所述脑电切片信号在各个神经网络模型下的分类值获得所述脑电切片信号的最终分类值;

[0012] 根据所述最终分类值识别得到所述脑电切片信号的脑电放松度。

[0013] 优选地,所述学习算法包括:Levenberg-Marquart算法、标准BP算法、增加动量项的BP算法、改进的GA-BP算法;且神经网络进行学习时使用的训练样本对由计算得到的所述特征量和标准设备同步采集得到的脑电放松度构成。

[0014] 优选地,所述对应于各个脑电波的信号波的特征量至少包括以下其中之一:对应于各个脑电波的信号波在时域空间的特征量、对应于各个脑电波的信号波在相空间的特征量、对应于各个脑电波的信号波在频域空间的特征量。

[0015] 优选地,在所述计算对应于各个脑电波的信号波的特征量之后,在所述将计算得到的所述特征量输入到至少两个由不同学习算法训练得到的神经网络模型,得到所述脑电切片信号在各个神经网络模型下的分类值之前,还包括:

[0016] 基于主成分分析法对所述特征量进行降维处理。

[0017] 优选地,所述基于主成分分析法对所述特征量进行降维处理具体包括:

[0018] 将所述特征量设置为输入样本空间中的特征量,并对所述输入样本空间进行数据标准化处理;

[0019] 根据数据标准化处理后的所述输入样本空间得到协方差矩阵;

[0020] 计算所述协方差矩阵的特征根和与每个特征根对应的特征向量;其中,所述特征根的数量为p个,且所述的p个特征根按照大小排序;

[0021] 获取所述的p个特征根中,贡献率之和大于预定阈值的前m个特征根;其中,每个特征根的贡献率等于所述特征根的值除以全部的p个特征根的值之和;

[0022] 根据与所述的前m个特征根对应的特征向量及所述输入样本空间,得到主成分得分矩阵;其中,所述主成分得分矩阵中的特征量为所述降维后的特征量。

[0023] 优选地,所述根据所述脑电切片信号在各个神经网络模型下的分类值获得所述脑电切片信号的最终分类值具体为:

[0024] 统计所述脑电切片信号在各个神经网络模型下的分类值的出现频率,并将出现频率最高的分类值设定为最终分类值。

[0025] 本发明还提供了一种基于神经网络模型的脑电放松度识别装置,其特征在于,包括:

[0026] 信号提取单元,用于从接收到的脑电切片信号中提取出对应于各个脑电波的信号波;

[0027] 特征量提取单元,用于计算对应于各个脑电波的信号波的特征量;

[0028] 分类单元,用于将计算得到的所述特征量输入到至少两个由不同学习算法训练得到的神经网络模型,得到所述脑电切片信号在各个神经网络模型下的分类值;

[0029] 最终分类值计算单元,用于根据所述脑电切片信号在各个神经网络模型下的分类值获得所述脑电切片信号的最终分类值;

[0030] 脑电放松度识别单元,用于根据所述最终分类值识别得到所述脑电切片信号的脑电放松度。

[0031] 优选地,所述学习算法包括:Levenberg-Marquart算法、标准BP算法、增加动量项的BP算法、改进的GA-BP算法;且神经网络进行学习时使用的训练样本对由计算得到的所述特征量和标准设备同步采集得到的脑电放松度构成。

[0032] 优选地,还包括:

[0033] 特征降维单元,用于基于主成分分析法对所述特征量进行降维处理。

[0034] 优选地,所述脑电放松度识别单元具体用于,统计所述脑电切片信号在各个神经网络模型下的分类值的出现频率,并将出现频率最高的分类值设定为最终分类值。

[0035] 本发明提供的基于神经网络模型的脑电放松度识别方法及装置,通过从脑电切片信号中提取特征量,并由不同学习算法得到的神经网络模型作为分类器对这些特征量进行识别,根据各个神经网络模型下识别得到的分类值获得所述脑电切片信号的最终分类值,

从而识别得到所述脑电切片信号的脑电放松度。本发明实施例相对于由单一分类器识别得到的脑电放松度，稳定性更高，避免因外界环境的干扰或用户的生理波动对脑电放松度的识别结果，为生物反馈指导反馈治疗提供更准确的依据。

附图说明

[0036] 为了更清楚地说明本发明的技术方案，下面将对实施方式中所需要使用的附图作简单地介绍，显而易见地，下面描述中的附图仅仅是本发明的一些实施方式，对于本领域普通技术人员来讲，在不付出创造性劳动的前提下，还可以根据这些附图获得其他的附图。

[0037] 图1是本发明实施例提供的基于神经网络模型的脑电放松度识别方法的流程示意图。

[0038] 图2是本发明实施例提供的神经网络模型的示意图。

[0039] 图3是通过切片得到脑电序列信号的示意图。

[0040] 图4是本发明实施例提供的对原始脑电信号进行加权移动平均计算的原理图。

[0041] 图5是自适应滤波器的工作原理图。

[0042] 图6是对脑电序列信号进行切片得到脑电切片信号的示意图。

[0043] 图7是本发明实施例提供的基于神经网络模型的脑电放松度识别装置的结构示意图。

具体实施方式

[0044] 下面将结合本发明实施例中的附图，对本发明实施例中的技术方案进行清楚、完整地描述，显然，所描述的实施例仅仅是本发明一部分实施例，而不是全部的实施例。基于本发明中的实施例，本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其他实施例，都属于本发明保护的范围。

[0045] 请参阅图1，本发明实施例提供了一种基于神经网络模型的脑电放松度识别方法，其可包括如下步骤：

[0046] S101，从接收到的脑电切片信号中提取出对应于各个脑电波的信号波。

[0047] 在本发明实施例中，所述的各个脑电波可包括Delta波、Theta波、Alpha波、Beta波、Gamma波。其中，一般地，Delta波的频率范围为0.5~3Hz，Theta波的频率范围为3~7Hz、Alpha波的频率范围为8~13Hz、Beta波的频率范围为14~17Hz、Gamma波的频率范围为34~50Hz。

[0048] 其中，Delta波：深度睡眠脑波状态。

[0049] 当人的大脑频率处于Delta波时，为深度睡眠、无意识状态。人的睡眠品质好坏与Delta波有非常直接的关系。Delta波睡眠是一种很深沉的睡眠状态，如果在辗转难眠时自己召唤出近似Delta波状态，就能很快地摆脱失眠而进入深沉睡眠。

[0050] Theta波：深度放松、无压力的潜意识状态。

[0051] 当人的大脑频率处于Theta波时，人的意识中断，身体深沉放松，对于外界的信息呈现高度的受暗示状态，即被催眠状态。Theta波对于触发深沉记忆、强化长期记忆等帮助极大，所以Theta波被称为“通往记忆与学习的闸门”。

[0052] Alpha波：学习与思考的最佳脑波状态。

[0053] 当人的大脑频率处于Alpha波时,人的意识清醒,但身体却是放松的,它提供意识与潜意识的“桥梁”。在这种状态下,身心能量耗费最少,相对的脑部获得的能量较高,运作就会更加快速、顺畅、敏锐。Alpha波被认为是人们学习与思考的最佳脑波状态。

[0054] Beta波:紧张、压力、脑疲劳时的脑波状态。

[0055] 人们清醒时,大部分时间大脑频率处于Beta波状态。随着Beta波的增加,身体逐渐呈紧张状态,因而削减了体内免疫系统能力,此时人的能量消耗加剧,容易疲倦,若不充分休息,容易堆积压力。适当的Beta波对注意力提升以及认知行为的发展有积极作用。

[0056] 在本发明实施例中,当人的大脑处于不同的放松度时,各个脑电波具有不同的比重或者幅度,因此可通过对所述脑电切片信号中的各个脑电波进行分离,再依次分析(即提取特征量)来获得人的大脑当前所处的脑电放松度。

[0057] 在本发明实施例中,在获得所述脑电切片信号后,可根据每个脑电波的频率范围通过滤波(如卡尔曼滤波)、小波变换或者自回归模型等提取算法从所述脑电切片信号中提取出对应于各个脑电波的信号波。其中,提取时可仅用一个算法提取得到对应于各个脑电波的信号波,也可同时通过多个算法进行提取,再对不同算法提取得到的结果进行加权求和,得到最终的信号波。利用多个提取算法进行信号波的提取,可避免单一算法提取出现的误差偏大或稳定性不高的问题。

[0058] S102,计算对应于各个脑电波的信号波的特征量。

[0059] 在本发明实施例中,所述对应于各个脑电波的信号波的特征量至少包括以下其中之一:对应于各个脑电波的信号波在时域空间的特征量、对应于各个脑电波的信号波在相空间的特征量、对应于各个脑电波的信号波在频域空间的特征量。

[0060] 其中,对于信号波在时域空间的特征量可采用如下方法计算得到:

[0061] 在一个实现方式中,可通过等电位线变化率算法提取各个信号波的等电位线能量变化率和等电位线能量密度变化率,从而获得各个信号波在时域空间的特征量。

[0062] 具体地:

[0063] 首先,计算各个信号波的能量参数,并基于各个信号波的能量的最大值及每个脑电波的等电位线能量参数变化率比率,计算得到每个信号波的等电位线能量参数变化率基线。

[0064] 在本发明实施例中,所述能量参数至少包括其中之一:能量、能量密度。以所述能量参数为能量为例:

[0065] 1、对于一个信号波 $A(t)$,其能量及能量密度的计算公式如下:

$$[0066] P = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T |A(t)|^2 dt = \frac{1}{2\pi} \int_{-\infty}^{\infty} \lim_{T \rightarrow \infty} \frac{1}{2T} |A_T(\omega)|^2 d\omega \quad (1)$$

$$[0067] S(\omega) = \lim_{T \rightarrow \infty} \frac{1}{2T} |A_T(\omega)|^2 \quad (2)$$

[0068] 在本发明实施例中,等电位线能量变化率比率xlepsRate可通过大量数据参数自学习得到(如通过大量学习各个脑电波的能量变化率基线与能量最大值的比值,求得一个平均的比值作为等电位线能量变化率比率xlepsRate),且针对Delta、Theta、Alpha、Beta、Gamma波的等电位线能量变化率比率xlepsRate值都不一样。

[0069] 2、计算等电位线能量变化率基线xleps。

[0070] $x1eps = \max(P) * x1epsRate$ (3)

[0071] 其中, $\max(P)$ 为每个信号波的能量的最大值。

[0072] 然后, 基于最小二乘法计算每个信号波在各个时刻的能量参数变化率。

[0073] 具体地:

[0074] 1、构造关于能量的函数表达式 $P(t) = at + b$; 其中, a 为能量参数变化率, b 为截距, t 为时刻。

[0075] 2、计算使得所述函数表达式的残差平方和最小时的能量变化率, 获得每个时刻的能量变化率。

[0076] 在本发明实施例中, 要想利用最小二乘算法求得所述函数表达式的参数 a, b , 就要使残差平方和最小, 具体的求解参数 a, b 的过程如公式 4 至公式 6 所示:

$$[0077] RSS = \sum_{i=1}^n [p(t_i) - (at_i + b)]^2 \quad (4)$$

$$[0078] a = \frac{\sum_{i=1}^n t_i p(t_i) - n \left(\frac{1}{n} \sum_{i=1}^n p_i \right) \left(\frac{1}{n} \sum_{i=1}^n t_i \right)}{\sum_{i=1}^n t_i^2 - n \left(\frac{1}{n} \sum_{i=1}^n t_i \right)^2} \quad (5)$$

$$[0079] b = \left(\frac{1}{n} \sum_{i=1}^n t_i \right) - a \cdot n \left(\frac{1}{n} \sum_{i=1}^n p(t_i) \right) \quad (6)$$

[0080] 其次, 统计所述每个信号波的能量参数变化率小于所述等电位线能量参数变化率基线的个数。

[0081] 即统计 $a < x1eps$ 的个数 $x1count$ 。

[0082] 最后, 根据统计得到的对应于每个信号波的个数与对应的信号波的总采样点数的比值, 获取所述脑电切片信号在时域空间的特征量。

[0083] 在本发明实施例中, 将统计得到的个数 $x1count$ 除以对应的信号波的总采样点数(或全部采样时刻), 得到比值 $x1countP$, 即得到各个信号波的等电位线能量变化率特征。

[0084] 在本发明实施例中, 根据上述方法分别计算得到每个信号波(Delta、Theta、Alpha、Beta、Gamma 波)的等电位线能量变化率 $x1countP1 \sim x1countP5$, 此后, 再按照同样的方法计算每个脑电波(Delta、Theta、Alpha、Beta、Gamma 波)的等电位线能量密度变化率 $x1countS1 \sim x1countS5$, 就获取得到脑电切片信号在时域空间的特征量。

[0085] 需要说明的是, 还可同时计算所述脑电切片信号的等电位线能量变化率和等电位线能量密度变化率, 并将这两个变化率也作为脑电切片信号在时域空间的特征量, 其具体计算方法跟计算各个信号波的等电位线能量变化率和等电位线能量密度变化率基本一致, 在此不做赘述。

[0086] 在一个实现方式中, 可通过栅条投影变异度算法提取各个信号波的栅条投影变异度来获取各个信号波在时域空间的特征量。

[0087] 具体地:

[0088] 首先, 将各个信号波按相同时间间隔分为至少两个切片。

[0089] 其中, 每个切片就是一个栅条, 时间间隔就是栅条宽度。

[0090] 其次,计算每一信号波(Delta、Theta、Alpha、Beta、Gamma波)在每个栅条内的覆盖范围,即在栅条y轴上的投影shadow。

[0091] 然后,统计所有投影shadow的最大值最小值,在最大值和最小值之间,划分为若干个等长度的区间histnum。

[0092] 例如,最大值为a,最小值为b,需要划分为N个区间,则每个区间的长度为 $(a-b)/N$ 。

[0093] 最后,如公式7,8所示统计落在各区间histnum中投影的数量shadow_hist,计算各区间投影的数量shadow_hist的标准差shadow_stdhist,即得到需要的栅条投影变异数度。

$$[0094] \text{shadow_stdhist} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\text{shadow_hist} - \mu)^2} \quad (7)$$

$$[0095] \mu = \sqrt{\frac{1}{N} \sum_{i=1}^N \text{shadow_hist}} \quad (8)$$

[0096] 在本发明实施例中,分别计算得到每个信号波(Delta、Theta、Alpha、Beta、Gamma波)的栅条投影变异数度shadow_stdhistP1~shadow_stdhistP5,并可按照同样的方法可以计算脑电切片信号的栅条投影变异数度shadow_stdhistEEG,即得到了脑电切片信号在时域空间的特征量。其中,栅条投影变异数度体现了波形的分散离散程度。

[0097] 需要说明的是,在本发明实施例中,在获得各个信号波的时域特征时,可仅用上述的一种算法计算得到的时域特征,也可同时采用多种算法同时得到的时域特征,本发明不做具体限定。此外,还有其他计算各个信号波的时域特征,如计算各个信号波的能量变化率、能量密度变化率、等电位线能量变化率、等电位线能量密度变化率、等电位线时长、幅度概率密度等,这些时域特征及其任意组合都在本发明的保护范围之内,在此不做赘述。

[0098] 在本发明实施例中,对于信号波在相空间的特征量可采用如下方法计算得到:

[0099] 首先,根据所述各个脑电波的信号波及脑电切片信号形成对应的包含有信号的二维图表。

[0100] 其中,二维图表的横坐标为时间,纵坐标为信号的幅值。

[0101] 然后,用与二维图表等大小的m*m的网格对应覆盖在各个二维图表上,并统计覆盖有信号的网格数。

[0102] 其中,m为大于1的整数,且m的取值由信号的长度决定。

[0103] 最后,根据覆盖有信号的网格数与所述网格的全部网格数,计算各个信号波及脑电切片信号的相空间分布密度,获得脑电切片信号在相空间的特征量。

[0104] 即,相空间分布密度=md/m²。其中,md为覆盖有信号的网格数。

[0105] 在本发明实施例中,在得到各个信号波及所述脑电切片信号的相空间分布密度后,就得到了所述脑电切片信号在相空间的特征量。

[0106] 在本发明实施例中,对于信号波在频域空间的特征量可采用如下方法计算得到:

[0107] 在一个实现方式中,可通过能量密度比率算法提取各个脑电波的信号波的频域特征,获得所述脑电切片信号在频域空间的特征量。

[0108] 具体地:

[0109] 首先,计算与各个脑电波对应的信号波的能量。

[0110] 其中,各个信号波的能量函数公式如下:

$$[0111] P(\omega) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \lim_{T \rightarrow \infty} \frac{1}{2T} |A_T(\omega)|^2 d\omega \quad (9)$$

[0112] $\omega = 2\pi f$ (10)

[0113] 然后,根据各个脑电波的频率范围及对应的信号波的能量,计算任意两个信号波之间的能量比率,获得所述脑电切片信号在频域空间的特征量。

[0114] 以计算Alpha和Delta的能量比率为例,如公式11所示。

$$[0115] \frac{PSDR_\alpha}{PSDR_\beta} = \frac{\sum_{f=8Hz}^{13Hz} P(f)}{\sum_{f=0.5Hz}^{3Hz} P(f)} \quad (11)$$

[0116] 在本发明实施例中,以此类推,通过计算两两信号波之间的能量比率,就获得所述脑电切片信号在频域空间的特征量。

[0117] 在一个实现方式中,可通过中心频率算法提取各个信号波的中心频率,得到所述脑电切片信号在频域空间的特征量。

[0118] 具体地:

[0119] 首先,计算与各个脑电波对应的信号波的能量。

[0120] 然后,根据各个信号波的能量及各个脑电波的频率范围,计算各个信号波的中心频率,获得所述脑电切片信号在频域空间的特征量。

[0121] 如公式12所示,中心频率FC:

$$[0122] FC = \frac{\sum_{f_L}^{f_H} f * P(f)}{\sum_{f_L}^{f_H} P(f)} \quad (12)$$

[0123] 其中, f_H 为与信号波对应的脑电波的上限频率, f_L 为对应的脑电波的下限频率,例如Delta波的上限频率为3Hz,下限频率为0.5Hz。

[0124] 在本发明实施例中,依次计算各个信号波的中心频率,就得到所述脑电切片信号在频域空间的特征量。

[0125] S103,将计算得到的所述特征量输入到至少两个由不同学习算法训练得到的神经网络模型,得到所述脑电切片信号在各个神经网络模型下的分类值。

[0126] S104,根据所述脑电切片信号在各个神经网络模型下的分类值获得所述脑电切片信号的最终分类值。

[0127] S105,根据所述最终分类值识别得到所述脑电切片信号的脑电放松度。

[0128] 在本发明实施例中,首先需要先构造神经网络模型。具体地,如图2所示,一个神经网络模型一般包括输入层、隐含层及输出层,因此构造的步骤可包括神经网络选取、隐含层数和隐含层节点数选择、输入输出层的节点数确定。

[0129] (1) 隐层数选择。单隐层前馈网络能够处理大部分非线性问题。只有在隐层节点数过多,但仍无法满足收敛精度要求时,采用双隐层,后者能处理所有非线性问题,但网络训练速度有所下降,收敛时间长,故选用一个隐含层。

[0130] (2) 隐含层节点数选择。可采用试凑法进行隐含层节点数(一下简称隐节点数)的

确定。用同一样本集来训练，先将隐节点数目设置在 $inum/2+1$ 附近，逐渐增加隐节点数至 $2*inum+1$ ，并继续增加直至不收敛，通过分析误差性能曲线来确定最合适的隐节点数，其中 $inum$ 是输入层节点数目，即输入的特征量的维数。

[0131] (3) 输入层节点数为特征样本的维数，即有几个特征量就有几个输入节点。输出层只有一个节点，就是脑电放松度。

[0132] 在本发明实施例中，在构造完所述神经网络后，需要进行训练来实现神经网络中各个隐含层节点的权值的调整。其中，在训练时，将提取得到的脑电切片信号的特征量（训练阶段提取）作为训练神经网络的输入样本X，将标准设备（如神念设备）同步采集得到的“脑电放松度”作为金标准，即神经网络的输出Y。然后根据输入样本X、输出Y和学习算法对各个节点的权值进行调整。

[0133] 在本发明实施例中，例如，可采用Levenberg-Marquart算法作为神经网络的学习算法，进行神经网络训练，实现权值的调整。Levenberg-Marquart算法借助于Jacobian矩阵，如公式13所示；矩阵的梯度表示如公式14所示，其中，H表示雅克比矩阵，e表示误差。因此权值调整如公式15所示。Q表示训练样本数，n是全部权值阈值的个数之和。Levenberg-Marquart算法的优势主要是权值较少时收敛速度快。

[0134] $H = J^T J \quad (13)$

[0135] $g = J^T e \quad (14)$

[0136] $w(k+1) = w(k) - [J^T J + \mu I]^{-1} J e \quad (15)$

[0137] 此外，在本发明实施例中，还可采用标准BP算法、增加动量项的BP算法、改进的GA-BP算法等学习算法进行训练得到。

[0138] 对于标准BP算法，其权值调整的计算公式如公式16所示：

$$[0139] \begin{cases} \Delta w_{jk} = \alpha \delta_k^o o_j = \alpha (d_k - y_k)(1 - y_k)o_j \\ \Delta v_i = -\alpha \delta_j^o x_i = \alpha \left[\sum_{k=1}^m (d_k - y_k)y_k(1 - y_k)w_{jk} \right] o_j(1 - o_j)x_i \end{cases} \quad (16)$$

[0140] 对于增加动量项的BP算法，其在标准BP算法的基础上，考虑用动量因子 η 来进行算法的调整（参见公式17、18），其中 $\eta \in (0, 1)$ ：

$$[0141] \Delta w(k+1) = \eta \Delta w(k) + \alpha(1-\eta) \frac{\partial E(k)}{\partial w(k)} \quad (17)$$

[0142] $w(k+1) = w(k) + \Delta w(k+1) \quad (18)$

[0143] 式中： α 表示网络的学习率； $g(k) = \partial E(k) / \partial w(k)$ 表示第k次反向传递的误差偏微分； $w(k)$ 表示第k次反向传递的阈值或权值； $E(k)$ 表示第k次反向传递的误差总和，随设定的误差性能函数而定。算法中下一次的权值调整幅度取决于上一次的调整效果，调整量一般沿同一偏微分方向减少或增加。当上一次的调整幅度太大时，则前后两式反号；当上一次调整量较小时，前后两式符号相同。动量BP算法较标准BP算法收敛效果好，收敛时间短，预测效果更好。

[0144] 对于改进的GA-BP算法，其权值调整的计算公式如公式19所示，其中 α 为自适应学习率， $g(k-1)$ 为当前误差函数对权值的梯度， η 为动量因子， k 为迭代的次数。BP网络的权值和阈值通过随机函数来初始化。

[0145] $\Delta w(k+1) = -\alpha g(k-1) + \eta \Delta w(k)$ (19)

[0146] 优选地,在步骤S101之前,还包括:

[0147] S01,对接收的用户的原始脑电信号进行切片,获得时间长度为30秒的脑电序列信号,并基于加权移动平均算法对所述脑电序列信号的各个时刻的脑电信号进行计算,得到去除低频直流信息后的脑电序列信号。

[0148] 如图3所示,在本发明实施例中,所述脑电切片信号可通过对原始脑电信号进行切片获得。其中,所述原始脑电信号可通过脑电电极采集获得。一般地,脑电电极采集的原始脑电信号的持续时间比较长(如数小时甚至更长),因此进行需要对原始脑电信号进行切片,例如,每个切片的片段为30秒,即每段所述脑电切片信号的长度为30秒。

[0149] 在本优选实施例中,为了保证提取和滤波的效率和准确性,还可对脑电序列信号进行相应的预处理,例如,通过预处理去除脑电切片信号中的低频直流信息,以避免这些低频直流信息对脑电波提取的干扰。

[0150] 在本优选实施例中,为了去除原始脑电序列信号中的低频直流信息,可基于加权移动平均算法对降采样后的原始脑电序列信号的各个时刻的脑电信号进行计算,得到所述脑电切片信号。具体地:

[0151] 首先,基于当前的第j个时刻的脑电信号,获取所述原始脑电序列信号中的位于第 $(j-(N-1)/2)$ 个时刻至第 $(j+(N-1)/2)$ 个时刻之间的N个脑电信号的能量;其中,N为预设的影响数,且N为奇数,j为大于 $(N+1)/2$ 的整数。

[0152] 例如,假设当前要预测的脑电信号 $x(j)$ 的时刻为第10个时刻(即 $j=10$),影响数N为5,则对当前要预测的脑电信号有影响的脑电信号为第8个至第12个时刻的脑电信号,即 $x(8) \sim x(12)$ 。此时,先获取这5个时刻的脑电信号的能量。

[0153] 接着,根据预设的权值分布函数为获取的N个脑电信号的能量分配权值;其中,N个脑电信号的能量的权值之和为1。

[0154] 在本优选实施例中,所述权值分布函数为正态分布函数,如可为: $w(i) = \exp\left(\frac{(t(i)-t(j))}{2\tau^2}\right)$,

其中, $w(i)$ 为第i个时刻的脑电信号的权值, $t(i)$ 为第i个时刻的脑电信号的时间, τ 表示需要放大的局部信息量。如图4所示,采用这种权值分布,避免了将第j点附近所有点都看成是一样的比重,而是按照距离(时间差)赋予其一个比重,实现局部信息量的放大,减弱了距离太远的信息对当前点的影响。

[0155] 需要说明的是,在计算得到各个脑电信号的能量的权值后,还需要进行归一化,保证N个脑电信号的能量的权值之和为1。

[0156] 然后,对所述N个脑电信号的能量根据分配的权值进行加权求和,得到新的第j个时刻的脑电信号的能量。

[0157] 即: $x(j) = \sum_{i=j-(N-1)/2}^{j+(N-1)/2} w(i)x(i)$

[0158] 最后,依次对所述原始脑电序列信号的各个时刻的脑电信号的能量进行加权求和后,根据所有时刻的新的脑电信号的能量,生成脑电切片信号。

[0159] S02,以所述脑电序列信号为原始信号,以与所述脑电序列信号同步采集得到的伪迹序列信号为参考信号,采用经函数链神经网络优化的自适应滤波器对所述脑电序列信号

进行滤波,得到去除伪迹序列信号后的脑电序列信号。

[0160] 在本优选实施例中,考虑到脑电切片信号中还包含有各种伪迹序列信号,如舌电伪迹,出汗伪迹,眼电伪迹,脉搏伪迹以及肌电伪迹等干扰。其中,以眼电伪迹和肌电伪迹难以去除的问题,这主要是由于其伪迹信号的幅值较高,是脑电信号的几倍甚至几十倍,而且与脑电信号在频域有混叠。

[0161] 本优选实施例提出一种经函数链神经网络优化的自适应滤波器,滤除待处理脑电信号中的各种伪迹信号。

[0162] 具体地,首先,构造自适应滤波器,其中自适应滤波器的原理框图如图5所示,其由原始信号(即所述脑电序列信号)和参考信号(与所述脑电序列信号同步采集得到的伪迹序列信号,如舌电伪迹,出汗伪迹,眼电伪迹,脉搏伪迹以及肌电伪迹中的任意一种)两个输入组成。滤波时,参考信号经自适应滤波后,与原始信号进行比较,得到所需脑电序列信号的预估信号(较为纯净的脑电序列信号),其中,滤波器不断地自我重新调整其权值,从而使目标误差达到最小。

[0163] 其次,将函数链神经网络(FLNN)应用到自适应滤波器,利用一组正交基函数将原输入矢量进行维数扩展,将线性参数扩展为非线性,来增强自适应滤波器的非线性处理能力。FLNN由函数扩展和单层感知器两部分组成,函数链神经网络的正交基采用切比雪夫正交多项式,如公式20所示。FLNN的基函数T如公式21所示,网络输出如公式22所示,通过FLNN实现了对输入的非线性扩展,更有助于描述脑电信号的非线性特性。

$$\begin{aligned} Ch_0(x) &= 1 \\ Ch_1(x) &= x \\ [0164] \quad Ch_2(x) &= 2x^2 - 1 \\ &\dots \\ Ch_{m+1}(x) &= 2xCh_m(x) - Ch_{m-1}(x) \end{aligned} \tag{20}$$

$$[0165] \quad T = [T_1 \ T_2 \ \dots \ T_M]^T = \begin{bmatrix} 1 \\ Ch_1(x_1) \\ Ch_2(x_1) \\ \vdots \\ Ch_1(x_r) \\ Ch_2(x_r) \\ \vdots \end{bmatrix} \tag{21}$$

$$\begin{aligned} w_j &= \alpha_{1j}T_1 + \alpha_{2j}T_2 + \dots + \alpha_{Mj}T_M \\ [0166] \quad &= \sum_{i=1}^M \alpha_{ij}T_i \end{aligned} \tag{22}$$

[0167] S03,对所述脑电序列信号再次进行切片,获得时间长度为6秒的脑电切片信号。

[0168] 如图6所示,在进行上述的预处理后,还需要对30s的脑电序列信号再次进行切片操作,切片的移动窗口为6s,这是国际上通用的切片长度,能够更好地分析信号。

[0169] 优选地,由于计算得到的特征量维度较多,且含有线性相关的输入项,因此考虑进行特征选择和降维来降低识别所需的计算量。

[0170] 具体地,在步骤S102之后,在步骤S103之前,还包括:

[0171] S1021,基于主成分分析法对所述特征量进行降维处理。

[0172] 首先,将所述特征量设置为输入样本空间中的特征量,并对所述输入样本空间进行数据标准化处理。

[0173] 具体地,将所述特征量设置为输入样本空间X中的元素。对该样本空间X进行数据标准化处理具体为:

$$[0174] X'_j = \frac{X_j - M_j}{S_j} \quad (23)$$

[0175] 其中:

$$[0176] M_j = \frac{1}{n} \sum_{i=1}^n X_{ij} \quad (24)$$

$$[0177] S_j = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_{ij} - M_j)^2} \quad (25)$$

[0178] 其中, X'_{ij} 是标准化后的新数据; M_j 、 S_j 分别表示原始数据某一列的算术平均值和标准(偏)差。

[0179] 然后,根据数据标准化处理后的所述输入样本空间得到协方差矩阵。

[0180] 其中,协方差矩阵D= $X^T X$,即:

$$[0181] D = \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1p} \\ d_{21} & d_{22} & \cdots & d_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ d_{p1} & d_{p2} & \cdots & d_{pp} \end{bmatrix} \quad (26)$$

[0182] 其中:

$$[0183] d_{ij} = \frac{\sum_{k=1}^n (x_{ki} - \bar{x}_i)(x_{kj} - \bar{x}_j)}{\sqrt{\sum_{k=1}^n (x_{ki} - \bar{x}_i)^2 \sum_{k=1}^n (x_{kj} - \bar{x}_j)^2}} \quad (27)$$

[0184] 其次,计算所述协方差矩阵的特征根和与每个特征根对应的特征向量;其中,所述特征根的数量为p个,且所述的p个特征根按照大小排序。

[0185] 其中,DP=Pλ (28)

[0186] 当只考虑第j个特征值时,有 $DP_j = P_j \lambda_j$,即求解 $|D - \lambda_j I| = 0$ 。依次解出各个 λ ,并使其按大小顺序排列,即 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$;然后可求出各特征值对应的特征向量P,进而特征方程求解完成。

[0187] 再次,获取所述的p个特征根中,贡献率之和大于预定阈值的前m个特征根。

[0188] 其中,每个特征根的贡献率等于所述特征根的值除以全部的p个特征根的值之和。

[0189] 具体计算时,依次计算单个主成分的贡献率并进行累计,根据累计贡献率确定主成分的个数m,从而确定所需要选取的主成分。贡献率的计算公式如公式29所述。累计贡献率即前m个贡献率的累积和,如公式30所示。所述阈值Dmax一般取在85%~95%之间。根据上一步骤中的特征根排序可知, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$,从前往后(也是从大到小)依次对特征

根进行累加,当累计贡献率 $\sum_{i=1}^m \lambda_i / \sum_{i=1}^p \lambda_i$ 大于Dmax时,停止计算,此时累计计算的特征根 λ 的数目为m,则只需要选取前m个主成分即可。

$$[0190] \quad \lambda_j / \sum_{i=1}^p \lambda_i \quad (29)$$

$$[0191] \quad \sum_{i=1}^m \lambda_i / \sum_{i=1}^p \lambda_i \quad (30)$$

[0192] 最后,根据与所述的前m个特征根对应的特征向量及所述输入样本空间,得到主成分得分矩阵。

[0193] 其中,所述主成分得分矩阵

$$[0194] \quad T = X^T P = \begin{bmatrix} t_{11} & t_{12} & \cdots & t_{1m} \\ t_{21} & t_{22} & \cdots & t_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ t_{n1} & t_{n2} & \cdots & t_{nm} \end{bmatrix} \quad (31)$$

[0195] 其中,该主成分得分矩阵T中的各个元素即为经过降维后的特征量。

[0196] 需要说明的是,在本发明实施例中,还可计算主成分的载荷,其中,所述主成分载荷主要反映主成分得分与原变量xj的关联程度,计算公式为:

$t_{ij} = p(z_i, x_j) = \sqrt{\lambda_i} p_{ij}$ ($i, j = 1, 2, \dots, p$),得到各主成分的载荷以后,就可以知道选取的每一个主成分分别对应的原始特征,如有需要,可以根据原始特征的量纲转换回去。

[0197] 在本发明实施例中,在采用主成分分析法筛选出所获得的脑电切片信号的特征量中较为重要且线性不相关的特征量后,即可得到降维后的脑电切片信号的特征量,由于经过降维减少了特征量的数目,因此降低了进行识别分类所需的计算量,加快了识别的速度,而且由于去除了比较不重要的特征量,也增加了分类的准确度。

[0198] 请参阅图7,本发明还提供一种基于神经网络模型的脑电放松度识别装置100,包括:

[0199] 信号提取单元10,用于从接收到的脑电切片信号中提取出对应于各个脑电波的信号波。

[0200] 特征量提取单元20,用于计算对应于各个脑电波的信号波的特征量;

[0201] 分类单元30,用于将计算得到的所述特征量输入到至少两个由不同学习算法训练得到的神经网络模型,得到所述脑电切片信号在各个神经网络模型下的分类值;

[0202] 最终分类值计算单元40,用于根据所述脑电切片信号在各个神经网络模型下的分类值获得所述脑电切片信号的最终分类值。

[0203] 脑电放松度识别单元50,用于根据所述最终分类值识别得到所述脑电切片信号的脑电放松度。

[0204] 优选地,还包括:

[0205] 加权移动平均单元,用于对接收的用户的原始脑电信号进行切片,获得时间长度为30秒的脑电序列信号,并基于加权移动平均算法对所述脑电序列信号的各个时刻的脑电信号进行计算,得到去除低频直流信息后的脑电序列信号;

[0206] 自适应滤波单元，用于以所述脑电序列信号为原始信号，以与所述脑电序列信号同步采集得到的伪迹序列信号为参考信号，采用经函数链神经网络优化的自适应滤波器对所述脑电序列信号进行滤波，得到去除伪迹序列信号后的脑电序列信号；

[0207] 切片单元，用于对所述脑电序列信号再次进行切片，获得时间长度为6秒的脑电切片信号。

[0208] 优选地，还包括：

[0209] 降维单元，用于基于主成分分析法对所述特征量进行降维处理。

[0210] 优选地，所述降维单元具体包括：

[0211] 标准化模块，用于将所述特征量设置为输入样本空间中的特征量，并对所述输入样本空间进行数据标准化处理；

[0212] 协方差矩阵获取模块，用于根据数据标准化处理后的所述输入样本空间得到协方差矩阵；

[0213] 特征向量计算模块，用于计算所述协方差矩阵的特征根和与每个特征根对应的特征向量；其中，所述特征根的数量为p个，且所述的p个特征根按照大小排序；

[0214] 特征根获取模块，获取所述的p个特征根中，贡献率之和大于预定阈值的前m个特征根；其中，每个特征根的贡献率等于所述特征根的值除以全部的p个特征根的值之和；

[0215] 主成分得分矩阵计算模块，用于根据与所述的前m个特征根对应的特征向量及所述输入样本空间，得到主成分得分矩阵；其中，所述主成分得分矩阵中的特征量为所述降维后的特征量。

[0216] 优选地，所述最终分类值计算单元40具体用于，统计所述脑电切片信号在各个神经网络模型下的分类值的出现频率，并将出现频率最高的分类值设定为最终分类值。

[0217] 优选地，所述学习算法包括：Levenberg-Marquart算法、标准BP算法、增加动量项的BP算法、改进的GA-BP算法；且神经网络进行学习时使用的训练样本对由计算得到的所述特征量和标准设备同步采集得到的脑电放松度构成。

[0218] 优选地，还包括：

[0219] 放松引导单元，用于根据识别得到的脑电放松度选择与所述脑电放松度对应的放松引导内容，以利用所述放松引导内容对用户进行放松引导。

[0220] 本发明实施例提供的基于神经网络模型的脑电放松度识别装置100，通过从脑电切片信号中提取特征量，并由不同学习算法得到的神经网络模型作为分类器对这些特征量进行识别，根据各个神经网络模型下识别得到的分类值获得所述脑电切片信号的最终分类值，从而识别得到所述脑电切片信号的脑电放松度。本发明实施例相对于由单一分类器识别得到的脑电放松度，稳定性更高，避免因外界环境的干扰或用户的生理波动对脑电放松度的识别结果，为生物反馈指导反馈治疗提供更准确的依据。

[0221] 以上所揭露的仅为本发明一种较佳实施例而已，当然不能以此来限定本发明之权利范围，本领域普通技术人员可以理解实现上述实施例的全部或部分流程，并依本发明权利要求所作的等同变化，仍属于发明所涵盖的范围。

[0222] 本领域普通技术人员可以理解实现上述实施例方法中的全部或部分流程，是可以通过计算机程序来指令相关的硬件来完成，所述的程序可存储于一计算机可读取存储介质中，该程序在执行时，可包括如上述各方法的实施例的流程。其中，所述的存储介质可为磁

碟、光盘、只读存储记忆体(Read-Only Memory, ROM)或随机存储记忆体(Random Access Memory, RAM)等。

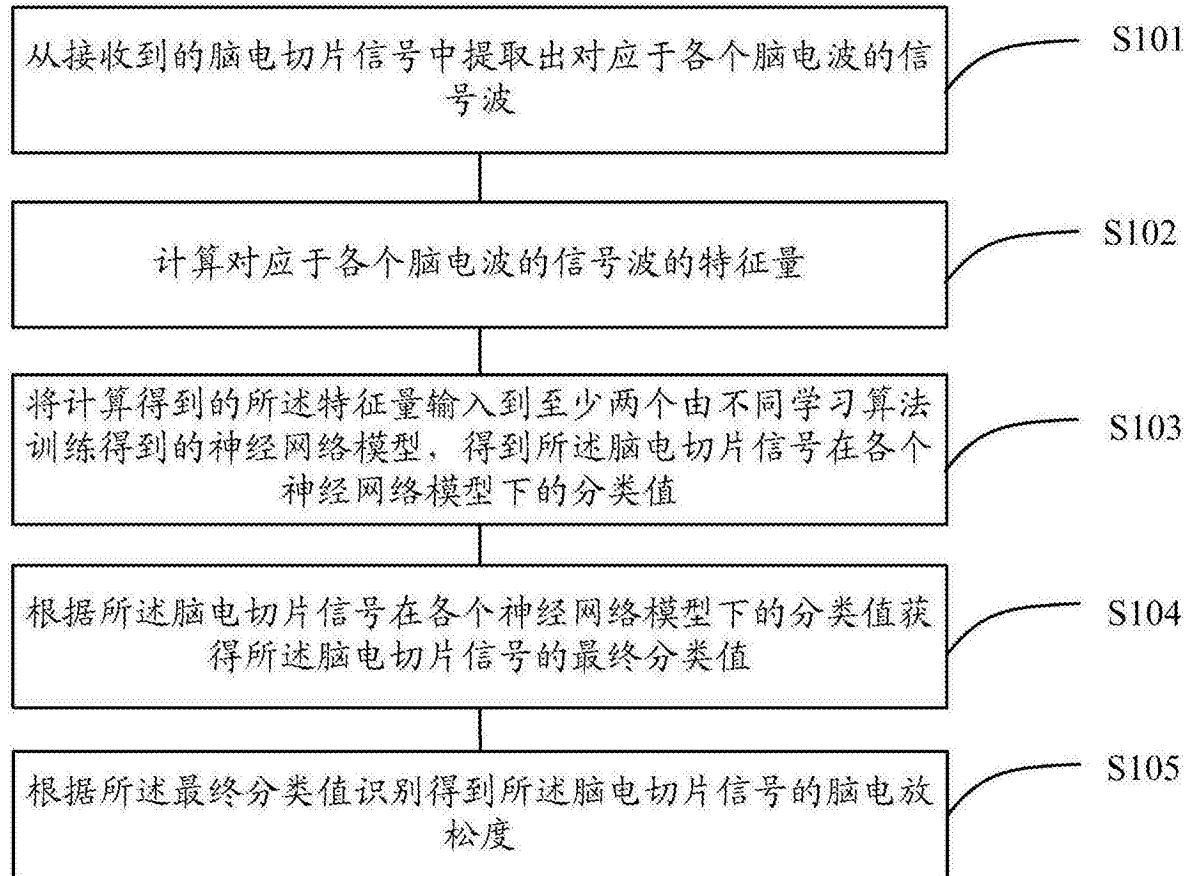


图1

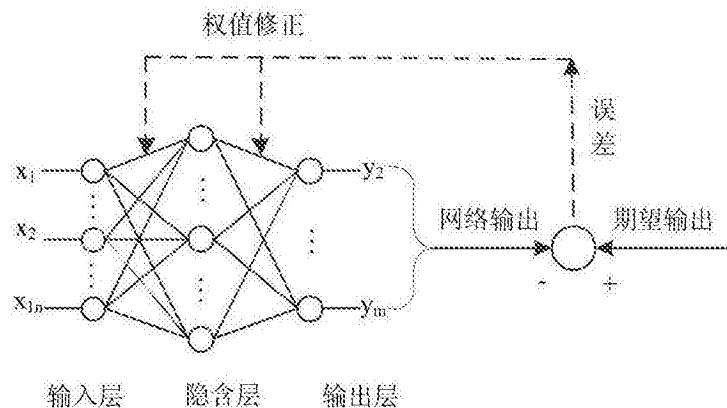


图2

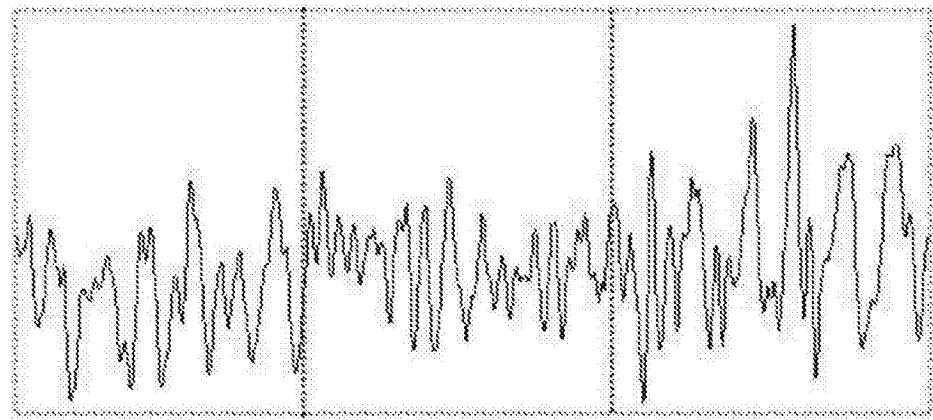


图3

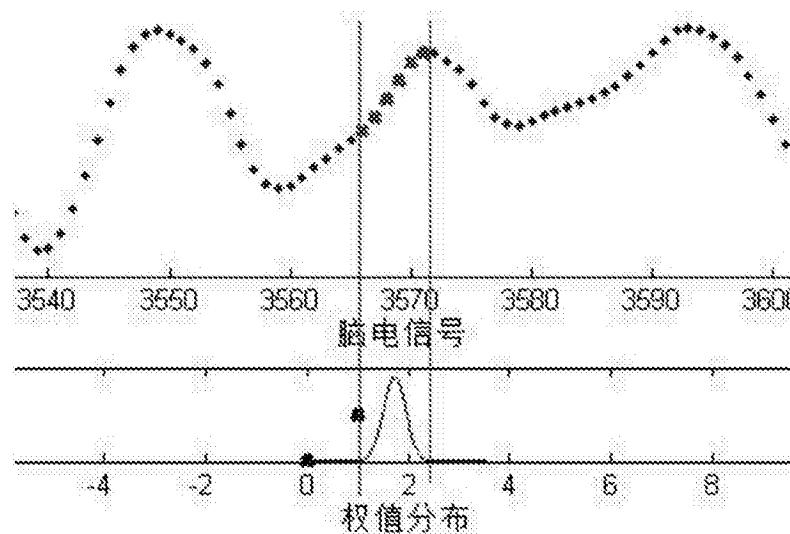


图4

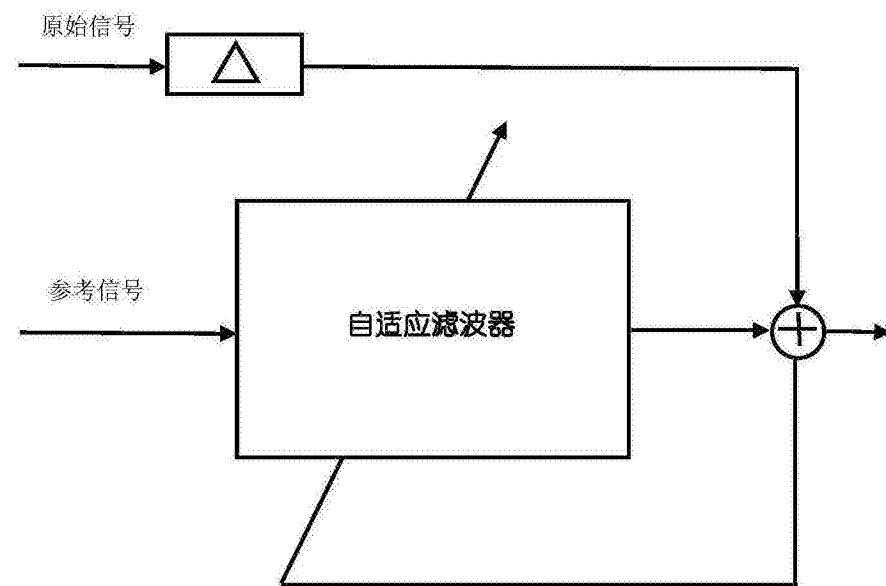


图5

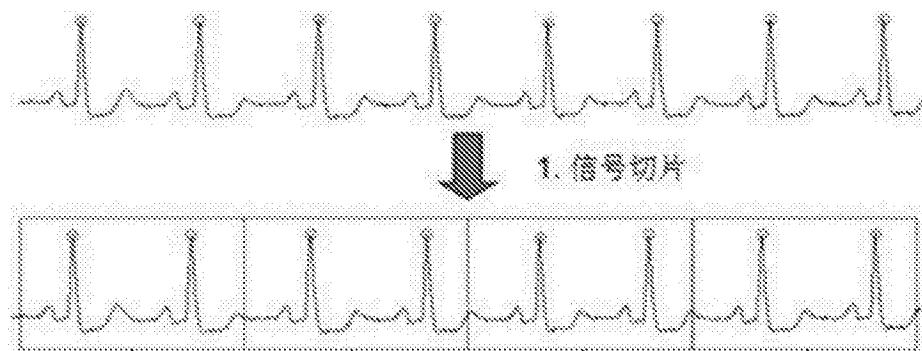


图6

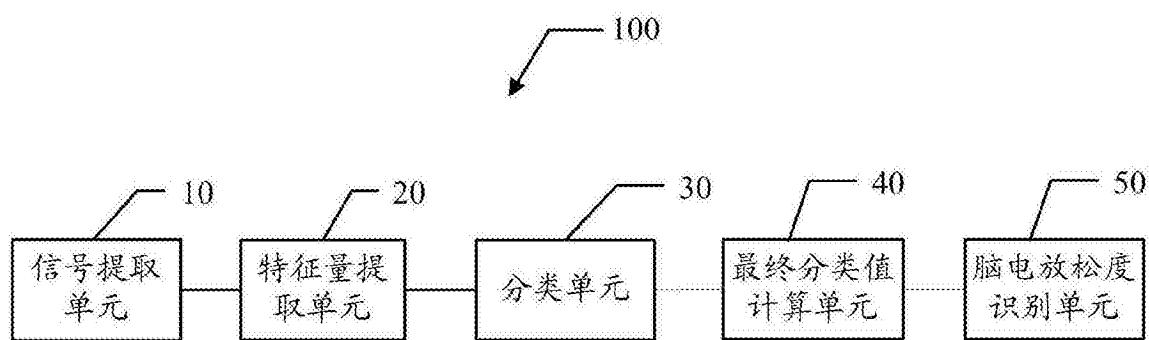


图7