

基于轻音乐加音乐节拍方式的大脑双重刺激诱导方法

廖 智^{1,2}, 朱珍民^{2,3}, 王 毅¹, 初显奇^{2,3}, 伍能彪^{1,2}

(1. 湘潭大学 信息工程学院, 湖南 湘潭 4111052; 2. 中国科学院计算技术研究所 普适计算研究中心, 北京 100190; 3. 中国科学院大学, 北京 100190)

摘 要: 依据音乐旋律以及节拍对脑电波能量谱的影响, 提出一种轻音乐加音乐节拍的双重刺激诱导方法。对测试者的大脑意识活动进行调节, 通过分析采集到的脑电信号判断其是否能够快速进入高度放松状态。在调节阶段采用轻音乐加速度渐变和强弱顺序相反的音乐节拍声方式, 使被测试者倾听 5 min, 并对通过 EEG 耳机采集的脑电信号进行分析。实验结果表明, 该方法在调节持续时间约为 2 min ~ 3 min 时, 能够有效地促进大脑进入高度放松状态。

关键词: 脑电信号; 音乐旋律; 音乐节拍; 重心频率; 随机森林

中文引用格式: 廖 智, 朱珍民, 王 毅, 等. 基于轻音乐加音乐节拍方式的大脑双重刺激诱导方法[J]. 计算机工程, 2017, 43(11): 27-31, 39.

英文引用格式: LIAO Zhi, ZHU Zhenmin, WANG Yi, et al. Brain Double Simulation Indncing Method Based on Light Music and Music Beats Way[J]. Computer Engineering, 2017, 43(11): 27-31, 39.

Brain Double Simulation Indncing Method Based on Light Music and Music Beats Way

LIAO Zhi^{1,2}, ZHU Zhenmin^{2,3}, WANG Yi¹, CHU Xianqi^{2,3}, WU Nengbiao^{1,2}

(1. College of Information Engineering, Xiangtan University, Xiangtan, Hunan 411105, China;

2. Research Center for Pervasive Computing, Institute of Computing Technology, Chinese Academy of Sciences,

Beijing 100190, China; 3. University of Chinese Academy of Sciences, Beijing 100190, China)

[Abstract] The effects of music melody and beat on Electroencephalogram (EEG) wave energy spectrum have great application significance. This paper proposes a double simulation inducing method with light music and music beats in the hearing. It regulates the brain activity of subjects, and by analyzing the collected EEG signal to determine whether can quickly and effectively enter the highly relaxed state. In the regulating stage, subjects are asked to listen the mix of light music and music beat with the gradual speed and the opposite power order for 5 min, and analyses the signals collected by the EEG headset. Experimental results show that when the duration of regulation is about 2 min ~ 3 min, the method based on double stimulation of light music and music beats can effectively promote subjects to enter the highly relaxed state.

[Key words] Electroencephalogram (EEG) signal; music rhythm; music beat; gravity frequency; random forest

DOI: 10.3969/j.issn.1000-3428.2017.11.005

0 概述

脑电 (Electroencephalogram, EEG) 信号是人脑神经元活动的综合反映, 其中蕴含着丰富的生理和病理信息。而音乐是人类智慧的结晶, 对人的精神状态有着重大影响。这种影响是通过神经元活动而进行的, 因此可以通过对脑电信号的研究, 从而观察到这种影响。一般而言, 大脑的状态在一定程度上可以通过脑电波的振幅、频率反映出来, 因此, 目前国际上依照频率对脑波进行划分: δ 波, θ 波, α 波, β 波, γ 波, 而从生理学和心理

学角度可解释这一划分: δ 波频率范围为 0.5 Hz ~ 3.5 Hz, 在成人的脑电采集中很少出现, 大多出现在大脑睡眠状态下, 如深度麻醉、熟睡等; θ 波频率范围为 3.5 Hz ~ 7.5 Hz, 此波一般在人处于高度放松状态并稍有困意时显现; α 波频率范围为 7.5 Hz ~ 13.5 Hz, 在脑电信号采集中, 该波最为明显, 尤其在成人安静闭目状态下; β 波频率范围为 13.5 Hz ~ 35 Hz, 当人体处于紧张状态、注意力高度集中或者进行强烈的脑力活动时, α 波幅值降低, 转化为 β 波。基于以上脑波的划分, 音乐对人体状态的影响可以通过对脑电信号的采集、分析得到更好的诠释。

基金项目: 国家科技支撑计划项目“基于健康体检人群的慢病风险因素监测系统与应用示范”(2013BAI04B01)。

作者简介: 廖 智 (1990—), 男, 硕士研究生, 主研方向为普适计算; 朱珍民, 教授、博士后; 王 毅, 副教授; 初显奇、伍能彪, 硕士研究生。

收稿日期: 2017-03-02 **修回日期:** 2017-04-06 **E-mail:** 1051276613@qq.com

也正是由于音乐的特殊性质及其与脑电波之间的关联,使得音乐刺激的脑机制研究已成为逐渐成为研究热门。

本文介绍基于 EEG 的音乐刺激的脑机制研究现状,并提出一种轻音乐加音乐节拍的双重刺激诱导方法。

1 相关研究

最近,许多研究者青睐以不同旋律的音乐来刺激诱发人类情绪,通过采集到的 EEG 数据对情绪脑机制进行研究。如文献[1]研究大脑如何响应快乐、忧郁以及中性的音乐,通过对采集到的 EEG 数据的分析,提出了一种可自动评估音乐情绪的工具。文献[2]研究表明通过音乐刺激进入放松情绪状态下时,EEG 在 θ 波段有增加趋势,在 α 波段有明显减少趋势。文献[3]同样发现在轻松愉快的音乐中, θ 波能量出现的更多。文献[4]提出了一种基于 EEG 与 ArousalValence 情感模型的情绪识别算法,可实时识别恐惧、沮丧、悲伤、快乐、愉快和满意这 6 种情绪。文献[5]利用愉快、快乐、悲伤和恐惧这 4 种情绪的音乐片段作为刺激材料,通过对脑电 α 波功率进行分析,指出脑电 α 波功率的变化与情绪的极性和强度密切相关。文献[6]则用利用说唱、嘻哈、金属等不同旋律的音乐来刺激诱发出快乐、悲伤、爱和愤怒的情绪,从时域和频域两方面分析记录下的 EEG 信号,进而使用 MLP 分类器对人类情绪进行识别。因此,大脑处理不同旋律的音乐,会产生不同的心理变化和生理反应。在旋律轻松的音乐中,人则会逐渐呈现出一种放松的状态。

音乐的旋律不同,会引起大脑产生不同的响应;而音乐节拍不同,也同样会引起人脑产生不同的反应。如文献[7]研究表明不同的音乐节拍对心理的唤醒程度会产生不同的效果,增加节拍速度导致大脑兴奋、心理唤醒程度增加,快节奏音乐比慢节奏音乐更容易引起激活。文献[8]研究了改变音乐节拍会引起 α 波更大的变化。文献[9]则利用 4 种不同节拍速度的音乐刺激大脑,对采集到的 α 波能量谱进行分析后提出:不同节拍速度的音乐的确能够引起大脑产生不同的反应。文献[10]则发现节奏缓慢的低强度音乐能在一定程度上缓解人焦躁的情绪,减轻压力。

音乐旋律以及节拍对脑电波能量谱的影响具有重大的应用意义。本文提出一种轻音乐加音乐节拍的双重刺激诱导方法,即在轻音乐的基础上加上速度渐变但强弱顺序相反的一种节拍声(节拍速度最后与歌曲节拍速度一致,且声音量小于歌曲音量),

此方法在不影响人对歌曲的完整倾听感受的基础上,在一定程度上对大脑产生了诱导作用以及加强了人对轻音乐中弱节拍声的感觉,则通过分析其脑电功率谱以及重心频率,探究该方法是否能够在较短时间内有效地促进大脑的放松。

2 本文方法

在真实的环境中,脑电波信号呈现高动态变化,只提取信号的单一特征往往造成识别效果不佳。而且由 MindWave Mobile 设备获取的脑电原始信号,不方便直接用于模型训练,所以需要对其进行预处理。本节首先介绍信号的预处理方法,然后介绍特征提取方法以及本文使用到的分类算法。

2.1 信号预处理

在真实的环境中,由于脑电信号具有的不确定性,波动较大,因此需要针对采集到的脑电信号数据做预处理,去掉偏差较大的信号值,从而进一步做特征提取。环境对信号源的影响近似服从正太分布。完整预处理步骤如下:

1) 对样本进行 Z-Score 标准化处理,公式如下:

$$T_i = |X_i - \bar{X}| / \sigma \quad (1)$$

其中, X_i 为脑电波信号, \bar{X} 为该波段脑电信号均值, σ 为脑电信号的标准差。

2) 当 T_i 位于置信度为 $P(P = 0.70, 0.75, 0.8, 0.85, 0.90, 0.95, 1)$ 的置信区间 $[\bar{X} - k \times \sigma, \bar{X} + k \times \sigma]$ 以外时,即作为离群处理。

2.2 特征提取

从脑电信号中提取出以下特征。

脑电波功率谱均值 \bar{X} :

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (2)$$

脑电波功率谱方差 V :

$$V = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \quad (3)$$

脑电波功率谱极差 R :

$$R = X_{\max} - X_{\min} \quad (4)$$

脑电波功率占比 $p(w)$:

$$p(w) = X_i / F \quad (5)$$

其中, F 为总频段功率值。

脑电波功率谱的重心频率 GF :

$$GF = \frac{\sum_{w=w_1}^{w_2} p(w) w}{\sum_{w=w_1}^{w_2} p(w)} \quad (6)$$

其中, w_1 、 w_2 分别为总频段上下限。

2.3 分类算法

2.3.1 GBDT 决策树

GBDT (Gradient Boosting Decision Tree) 实质上是一种迭代的决策树算法。它由多棵决策树所构成,而每棵决策树的生成过程是首先在内部对样本点进行特征选择,再在最优特征上找到最优切分点对数据进行分割,然后产生多个子节点,而输出结果则作为下一棵决策树的输入,如此迭代的生成决策树,直至最后一棵决策树的生成,而最后一棵决策树的结果则是完成了所有决策树的结论累加^[11]。GBDT 的泛化能力较强,且它所有的树都是回归树,所以几乎可以用于所有回归问题,也可用于二分类问题。

2.3.2 支持向量机

支持向量机 (Support Vector Machine, SVM) 是由文献[12-13]提出的一种比较著名的线性分类器,它是建立在统计学习理论的 VC 维理论和结构风险最小原理基础上。SVM 是把低维的样本空间通过非线性映射,从而升维至高维度空间,把原本空间非线性可分的问题变为了在高维空间线性可分问题。而其中升维会大大增加计算的复杂性,SVM 则巧妙的使用核函数解决了这一问题,因为通过核函数的展开定理,所以无需清楚非线性映射的显式表达式。这种技术的主要目标是通过提高系统的性能来确保良好的泛化,同时降低模型的训练难度。与其他分类器相比,它支持适当的泛化能力,并可解决机器学习问题,如过拟合。原则上,SVM 支持了结构风险最小化,并能避开局部最小值的问题。

2.3.3 随机森林

随机森林 (Random Forest) 是由文献[4]提出的一种分类算法,它是一种由多棵相互之间没有关联的决策树所组成的分类器。随机森林构建的过程中对原始样本是采取随机性的且有放回的抽样,而采样完之后则是对样本特征的选取,随机性的在所有待选特征中选取特征,再在选取的特征中选择最优特征来对样本进行分裂,从而构建出决策树,最后构造完多棵树后,对新数据的分类则是对所有树给出的结果进行统计,看哪一类被选择的最多,则新数据就属于哪一类^[15]。而与其他分类器相比,随机森林参数较复杂,训练以及预测时间较长。但由于每棵树都随机选择部分样本及部分特征,使其具有较好的抗噪能力,性能稳定,在一定程度上避免了过拟合,并且能够处理高维度的数据,无需做特征选择。

3 实验结果与分析

3.1 被试者

实验随机挑选实验室内 16 名在校研究生,均未受过系统的音乐专业训练,年龄范围在 23 岁—26 岁,被试者均身体健康,听力正常,无脑疾病、精神疾病史。

3.2 实验材料

实验调节阶段采用的轻音乐为班得瑞轻音乐 (Childhood Memory, Imagine, Snowdreams 等) 以及神秘园、Night Dream Melody 等经典轻音乐,共有 8 首。利用 FL Studio 12 软件测得轻音乐本身节拍的速度,则当播放音乐时,使用 Metronome Beats 3.6.1 节拍器软件播放速度渐变的但强弱顺序相反的音乐节拍声,该节拍声的速度渐变 20 s,以 1 BPM/s 的速度降低至与歌曲本身节拍速度相同,且声音量小于歌曲音量。

3.3 实验工具

采用的工具为华为荣耀 4c 手机、华为 mate8 手机以及由美国 NeuroSky 公司生产的 MindWave Mobile 脑电波耳机采集设备。

3.4 实验程序

为了能够在实验过程中更好的观察 EEG 数据,在 Android 平台上编写了一个 EEGApp,可通过蓝牙接收 MindWave Mobile 设备发送的 EEG 数据。该设备当中集成的芯片算法可提供输出频率为 1 Hz 的 8 个波段的脑电波功率值,这 8 个波段以及其对应的频率分别为: Delta (0.5 Hz ~ 3.5 Hz), Theta (3.5 Hz ~ 7.5 Hz), Low Alpha (7.5 Hz ~ 10.5 Hz), High Alpha (10.5 Hz ~ 13.5 Hz), Low Beta (13.5 Hz ~ 18.5 Hz), High Beta (18.5 Hz ~ 30 Hz), Low Gamma (30 Hz ~ 40 Hz), High Gamma (40 Hz ~ 50 Hz)。

3.5 实验过程

实验在安静、无日光灯照明、25℃ 常温环境下的会议室内进行,整个实验分为 3 个阶段:

1) A 阶段(调节前阶段) 让被试者头戴 EEG 耳机 (MindWave Mobile 设备), 睁眼静坐平静约 1 min 后, 开启手机 App, 操作 App 记录 5 min 的 EEG 数据。

2) B 阶段(调节阶段) 让被试者(睁眼状态)戴上耳机倾听笔记本播放的轻音乐以及音乐节拍,轻音乐播放音量大约为 55 dB,音乐节拍的为 35 dB。同时记录 5 min 的 EEG 数据。

3) C 阶段(调节后阶段) 让被试者取下耳机,睁眼静坐 5 min。同时记录数据。

4 数据分析

4.1 脑电波重心频率分析

通过 MindWave Mobile 设备共采集到 30 组 EEG 数据,采用 Matlab 2016a 对采集到的 EEG 数据进行正太分布检验和统计分析。

1) 假定通过 MindWave Mobile 设备共采集得 n 组 EEG 数据,则每组数据的 A、B、C 3 个阶段分别有 m 条样本数据,每条样本数据包含 8 个脑电波波段的功率值,根据式(6)可计算出每条 EEG 样本数据的重心频率。则 n 组数据的 A、B、C 3 个阶段的平均重心频率 \overline{GF} ,表示如下:

$$\overline{GF} = \frac{1}{n} \cdot \frac{1}{m} \sum_{i=1}^n \sum_{j=1}^m GF_{ij} \quad (7)$$

计算出 30 组 EEG 数据的 A、B、C 3 个阶段的 \overline{GF} 分别为 12.32、10.02、7.52, B 阶段相对于 A 阶段的重心频率均值降低了 2.30, C 阶段则降低了 4.8, 如图 1 所示。B 阶段(调节阶段)的重心频率明显下降,而最终 C 阶段(调节后阶段)的重心频率下降至较低水平,这表明经过诱导调节,脑电波由高频波向低频波段进行转化。

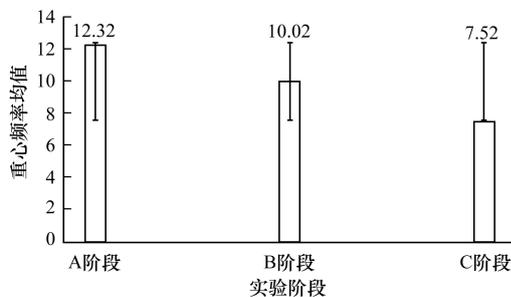


图1 3个实验阶段脑电波的重心频率均值

2) 3 个阶段分别包含 5 min 的 EEG 数据,而其中 B 阶段的 EEG 重心频率均值的整体变化呈现下降趋势,如图 2 所示。为了研究 B 阶段的 EEG 具体变化趋势,将 B 阶段分别 1 个~5 个时间段,每个时间段为 1 min。则计算出 B 阶段 5 个时间段的平均重心频率(见表 1)。如图 3 所示,相邻 2 个时间段中,第 2~第 3 时间段重心频率均值降低幅度达到最大为 1.64,第 3~第 5 相邻时间段的重心频率均值降幅变缓。且第 5 时间段的重心频率均值趋向 C 阶段的重心频率均值。这表明诱导调节时间持续 2 min~3 min 的时候,开始会有较为明显的作用。

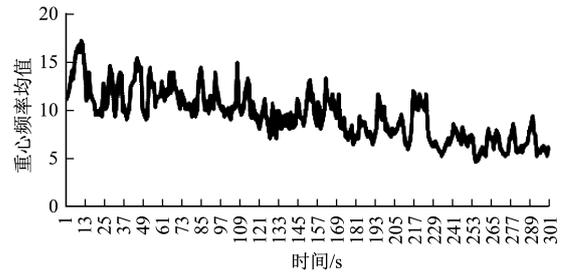


图2 B阶段的 EEG 重心频率均值的整体变化趋势

表1 B阶段的5个时间段 EEG 的重心频率均值

时间段	重心频率均值
1	12.21
2	11.55
3	9.91
4	8.56
5	7.85

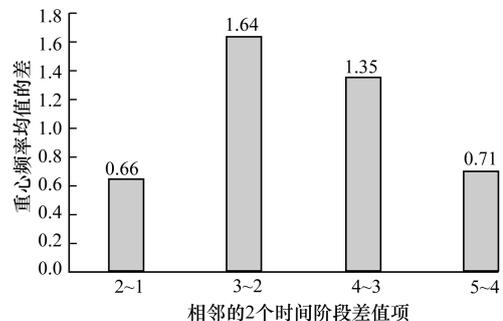


图3 B阶段的相邻2个时间段 EEG 的重心频率均值的差

4.2 大脑状态分类

状态分类采用的是机器学习算法,学习从信号中提取的特征的重要信息然后在这些特征的基础上进行分类。在本文中,针对 A 阶段(调节前阶段)和 C 阶段(调节后阶段)2 种大脑状态,使用 Python 3.5 运行 GBDT, SVM 以及随机森林 3 种不同的分类器进行分类识别。

分类结果如下:

1) 利用 Matlab 2016a 对 A 阶段和 C 阶段的脑电波信号做正态性检验, A 阶段与 C 阶段的脑电波信号近似服从正态分布。然后对每组 EEG 数据进行 Z-Score 标准化处理后,再分别计算出置信度为 0.70、0.75、0.8、0.85、0.90、0.95、1 时 A 与 C 两阶段的置信区间,剔除位于置信区间之外的样本点,生成 7 种不同置信度对应的 7 份新样本。

2) 对 A、C 两阶段预处理后的样本进行以下特征的提取:均值,方差,极差,功率占比,重心频率。而为了验证训练集的数据量对不同分类算法识别准确率的影响,首先保证了训练和测试总样本集的数据量不变,针对训练样本集分别取总样本集的 1/8、1/6、1/4、1/2,再对不同分类模型进行训练,然后测得不同分类模型下的平均识别准确率,如图 4 所示。

随着训练样本数据的增加,3 种分类器的平均识别准确率均有小幅提升,在训练集为总样本集的 1/4 时,3 种分类器的平均识别准确率均达到 80% 以上。其中在训练集为总样本集的 1/2,置信度为 0.85 时,SVM 和随机森林的平均识别准确率均达到 0.85 以上,随机森林分类器的平均识别准确率更是高达 0.868 1,如表 2 所示。则随机森林分类器能够比较准确的识别出清醒(调节前)与高度放松(调节后) 2 种大脑状态。

表 2 置信度为 0.85 时 3 种算法的平均识别准确率比较

训练集数据比例	分类算法	平均识别准确率
1/8	GBDT	0.771 9
	SVM	0.787 4
	Random Forest	0.784 5
1/6	GBDT	0.787 7
	SVM	0.813 7
	Random Forest	0.822 2
1/4	GBDT	0.803 1
	SVM	0.832 1
	Random Forest	0.857 4
1/2	GBDT	0.834 5
	SVM	0.858 8
	Random Forest	0.868 1

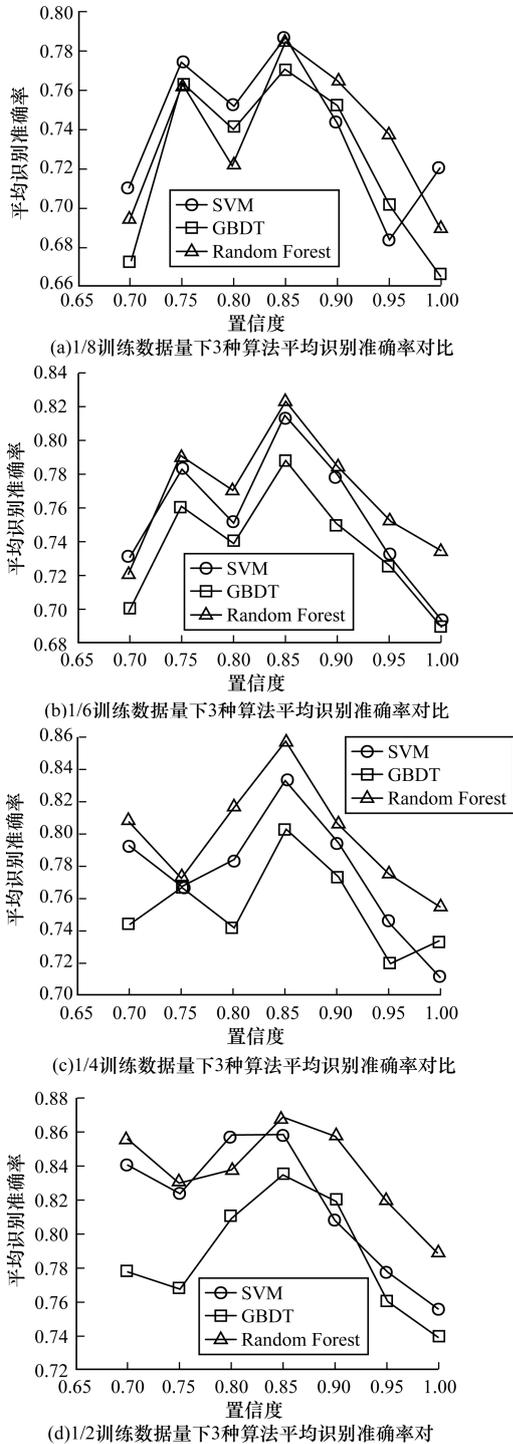


图 4 不同置信度下 3 种算法的平均识别准确率比较

5 结束语

本文从听觉方面提出一种轻音乐加音乐节拍方式,对人大脑进行双重刺激诱导。通过实验分析,在调节阶段时,持续调节平均 2 min ~ 3 min,脑电波开始由高频波段向低频波段进行转化,大脑开始逐步放松;在调节后阶段,重心频率则趋向于 θ 波的频率范围,脑电波主要表现为低频波段,此时大脑为高度放松状态;而基于随机森林对调节前后两阶段的分类识别的平均准确率达到 86.81%,能够较好地地区分出调节前后的清醒与高度放松 2 种状态。实验结果表明,轻音乐加音乐节拍的双重刺激诱导方法能够促进人在较短时间内从清醒状态向高度放松状态的转变。该方法可用于帮助生活压力太大难以入睡的人们释放压力、改善失眠,从而促进身心的健康发展。下一步将研究多种音乐类型与多种节拍方式的刺激诱导的结合方式,通过对 EEG 信号的处理分析,以期找到一种更好的听觉刺激诱导方法,实现较好的诱导效果。

参考文献

- [1] SHAHABI H, MOGHIMI S. Toward Automatic Detection of Brain Responses to Emotional Music Through Analysis of EEG Effective Connectivity [J]. Computers in Human Behavior, 2016, 58: 231-239.
- [2] 袁 全,刘兴华,李大琛,等. 噪声和音乐对脑电功率谱的影响 [J]. 航天医学与医学工程, 2000, 13 (6): 401-404.
- [3] SAMMLER D, GRIGUTSCH M, FRITZ T, et al. Music and Emotion: Electrophysiological Correlates of the Processing of Pleasant and Unpleasant Music [J]. Psycho-physiology, 2007, 44 (2): 293-304.
- [4] SOURINA O, LIU Y, NGUYEN M K. Real-time EEG-based Emotion Recognition for Music Therapy [J]. Journal on Multimodal User Interfaces, 2012, 5 (1-2): 27-35.

(下转第 39 页)

参考文献

- [1] 李洪峻,李 迅,马宏绪. 无线传感器网络 MAC 协议实时性研究[J]. 计算机工程,2009,35(23):78-80.
- [2] MOLINS M, STOJANOVIC M. Slotted FAMA: A MAC Protocol for Underwater Acoustic Networks [C]// Proceedings of IEEE OCEANS'06. Washington D. C., USA; IEEE Press, 2006:1-7.
- [3] GUO X, FRATER M, RYAN M. An Adaptive Propagation-delaytolerant MAC Protocol for Underwater Acoustic Sensor Networks [C]// Proceedings of IEEE OCEANS'07. Washington D. C., USA; IEEE Press, 2007:1-5.
- [4] NOH Y, WANG P, LEE U, et al. DOTS: A Propagation Delay-aware Opportunistic MAC Protocol for Underwater Sensor Networks [C]// Proceedings of IEEE ICNP'10. Washington D. C., USA; IEEE Press, 2010:183-192.
- [5] HAN S, NOH Y, LEE U, et al. M-FAMA: A Multi-session MAC Protocol for Reliable Underwater Acoustic Streams [C]// Proceedings of IEEE INFOCOM'13. Washington D. C., USA; IEEE Press, 2013:665-673.
- [6] CHIRDCHOO N, SOH W S, CHUA K C. MACA-MN: A Macabased MAC Protocol for Underwater Acoustic Networks with Packet Train for Multiple Neighbors [C]// Proceedings of IEEE VTC'08. Washington D. C., USA; IEEE Press, 2008:46-50.
- [7] ABRAMSON N. Development of the ALOHANET [J]. IEEE Transactions on Information Theory, 1985, 31(2):119-123.
- [8] SYED A A, YE W, HEIDEMANN J. Understanding Spatio-temporal Uncertainty in Medium Access with Aloha Protocols [C]// Proceedings of ACM WUWNet'07. New York, USA; ACM Press, 2007:41-48.
- [9] GANDHAM S, DAWANDE E, PRAKASH R. Link Scheduling in Sensor Networks; Distributed Edge Coloring Revisited [C]// Proceedings of IEEE INFOCOM'05. Washington D. C., USA; IEEE Press, 2005:2492-2501.
- [10] BERTSEKAS D, GALLAGER R. Data Networks [M]. New Jersey, USA; Prentice Hall, 1992.
- [11] LU Hong, FENG Hong, YANG Bozhen, et al. ROSS: Receiver Oriented Sleep Scheduling for Underwater Sensor Networks [C]// Proceedings of the 8th ACM International Conference on Underwater Networks and Systems. New York, USA; ACM Press, 2013:151-163.
- [12] 金顺福,田乃硕. 时隙 ALOHA 协议 (S-ALOHA) 的离散时间排队网络模型的建立及性能分析 [J]. 计算机工程与应用, 2001, 47(20):35-38.
- [13] HAN Yu, FEI Yunsu. TARS: A Traffic-adaptive Receiver-synchronized MAC Protocol for Underwater Sensor Networks [C]// Proceedings of the 23rd IEEE International Symposium on Modeling, Analysis, and Simulation of Computer and Telecommunication Systems. Washington D. C., USA; IEEE Press, 2015:62-73.
- [14] RHEE I, WARRIER A, AIA M, et al. Z-MAC: A Hybrid MAC for Wireless Sensor Networks [C]// Proceedings of the 3rd ACM Conference on Embedded Networked Sensor Systems. New York, USA; ACM Press, 2005:90-101.
- [15] HUANG P, XIAO L, SOLTANI S, et al. The Evolution of MAC Protocols in Wireless Sensor Networks: A Survey [C]// Proceedings of IEEE Communications Surveys & Tutorials. Washington D. C., USA; IEEE Press, 2012:1-20.
- [16] SONG W Z, HUANG R, SHIRAZI B, et al. TreeMAC: Localized TDMAMAC Protocol for Real-time High-data-rate Sensor Networks [J]. Journal of Pervasive and Mobile Computing, 2009, 5:750-765.
- [17] WU L, ZHUO S, WANG Z. pQueue-MAC: An Energy Efficient Hybrid MAC Protocol for Event-driven Sensor Networks [J]. International Journal of Distributed Sensor Networks, 2015, 2015:1-11.
- 编辑 索书志
-
- (上接第 31 页)
- [5] 赖永秀,高婷婷,吴 丹,等. 音乐情绪感知的脑电研究 [J]. 电子科技大学学报, 2008, 3(2):302-304.
- [6] BHATTI A M, MAJID M, ANWAR S M, et al. Human Emotion Recognition and Analysis in Response to Audio Music Using Brain Signals [J]. Computers in Human Behavior, 2016, 65:267-275.
- [7] FRANCESCA R, CARPENTIER D, POTTER R F. Effects of Music on Physiological Arousal: Explorations into Tempo and Genre [J]. Media Psychology, 2007, 10(3):339-363.
- [8] MA W, LAI Y, YUAN Y. Electroencephalogram Variations in the α Band During Tempo-specific Perception [J]. Neuroreport, 2012, 23(3):125-128.
- [9] 袁 媛. 音乐速度感知的脑电研究 [J]. 成都: 电子科技大学, 2009.
- [10] SALAMON E, BERNSTEIN S R, KIM S A, et al. The Effects of Auditory Perception and Musical Preference on Anxiety in Naive Human Subjects [J]. Medical Science Monitor International Medical Journal of Experimental & Clinical Research, 2003, 9(9):396-399.
- [11] YE J, CHOW J H, CHEN J, et al. Stochastic Gradient Boosted Distributed Decision Trees [C]// Proceedings of Conference on Information and Knowledge Management. Hong Kong, China; [s. n.], 2009:2061-2064.
- [12] KOTSIANTIS S B, ZAHARAKIS I, PINTELAS P. Supervised Machine Learning: A Review of Classification Techniques [J]. Informatica, 2007, 31(3):249-268.
- [13] LIANG N Y, SARATCHANDRAN P, HUANG G B, et al. Classification of Mental Tasks from EEG Signals Using Extreme Learning Machine [J]. International Journal of Neural Systems, 2006, 16(1):29-38.
- [14] BREIMAN L. Random Forests [J]. Machine Learning, 2001, 45(1):5-32.
- [15] 董师师,黄哲学. 随机森林理论浅析 [J]. 集成技术, 2013, 2(1):1-7.
- 编辑 索书志