

基于 RBF 神经网络的睡眠分期方法研究与应用

陈玉, 杨涛*, 徐铮

(福建理工大学 设计学院, 福州 350118)

摘要: **目的** 提出一种基于径向基函数 (Radial Basis Function, RBF) 神经网络的睡眠分期方法, 设计一套能够根据用户身心恢复状态调节唤醒时间的智能唤醒系统, 以优化用户睡眠时长, 减轻醒后不适感。**方法** 基于心率变异性 and 睡眠分期等相关理论知识, 通过低功耗心率带采集人体心电信号, 选取最优小波变换对采集到的心电信号精准去噪, 对径向基函数神经网络进行反复训练后, 筛选出 10 个关键的特征向量, 以构建睡眠分期模型。睡眠分期信息通过 STM32 处理器传输到手机客户端, 系统根据预先设计的优化唤醒机制在用户身心恢复到最佳状态时将其唤醒。**结果** 基于睡眠分期模型的算法平均识别准确率可达 88.9%, 卡帕 (Kappa) 系数为 0.839, 相较于其他算法, 该算法具有较高的准确率。**结论** 该智能唤醒系统的采集成本较低, 算法简便高效, 其唤醒机制科学合理, 可以使用户舒适醒来, 对改善用户醒后状态具有重要意义。

关键词: 睡眠分期; 心率变异性; 小波变换; 径向基函数神经网络; 智能唤醒

中图分类号: TP391.4; TB472 **文献标志码:** A **文章编号:** 1001-3563(2024)04-0371-09

DOI: 10.19554/j.cnki.1001-3563.2024.04.041

Research and Application of Sleep Staging Method Based on RBF Neural Network

CHEN Yu, YANG Tao*, XU Zheng

(School of Design, Fujian University of Technology, Fuzhou 350118, China)

ABSTRACT: The work aims to propose a sleep staging method based on a radial basis function (RBF) neural network and use it to design an intelligent wake-up system that can adjust the wake-up time according to the user's recovery state, in order to optimize the user's sleep duration and reduce their discomfort after waking up. Based on theoretical knowledge of heart rate variability and sleep staging, the electrocardiogram (ECG) signal was collected from the human body through a low-power heart rate band, and the optimal wavelet transform was selected to precisely denoise the collected ECG signal. The radial basis function (RBF) neural network was trained repeatedly to filter out 10 key feature vectors, so as to build a model of sleep staging. The sleep staging information was transmitted to the mobile phone client via a STM32 processor, and the system woke up the user according to designed optimized wake-up mechanism when the user's body and mind recovered to the optimal state. The results showed that the algorithm based on the sleep staging model had an average accuracy of 88.9% with a Kappa coefficient of 0.839, which was higher than that of other algorithms. The intelligent wake-up system has a lower collection cost, a simpler and more efficient algorithm, and a scientific and reasonable wake-up mechanism, which enables the user to wake up comfortably and is of great significance in improving the user's state after awakening.

KEY WORDS: sleep staging; heart rate variability; wavelet transform; radial basis function neural network; intelligent wake-up

收稿日期: 2023-09-16

基金项目: 福建省自然科学基金 (2023J01947); 福建省社会科学基金 (FJ2021B187); 福建理工大学科研启动基金 (GY-S20089)

*通信作者

随着经济的发展和生活水平的提高,人们越来越重视睡眠健康问题。睡眠是保持机体正常运转的基础,突然中断睡眠容易导致人们心情烦躁、精神不佳,不合理的唤醒甚至会影响醒后的认知和决策。研究表明,适宜的睡眠时长和高质量的睡眠有助于恢复体力、巩固记忆。然而,睡眠质量的高低与睡眠时间的长短并不呈正相关,过长的睡眠往往可能适得其反,造成人体软弱无力、精神疲惫、代谢率降低等后果。目前,针对睡眠的研究主要集中在通过辅助手段促进睡眠或监测睡眠信息,并用于临床诊断,很少关注到睡眠后的舒适唤醒问题。市场上现存的唤醒产品大多不能根据人体的睡眠状态调节唤醒时间,不够智能化。由此可见,针对睡眠时长和睡眠状态进行评估,在人体精神和体力恢复到最佳时期时进行唤醒具有十分重要的意义。

1 睡眠类产品及技术研究现状

传统研究睡眠的工具为多导睡眠监护仪 (Polysomnogram, PSG),该方法操作复杂、成本高,需要在医院通过医师操作完成,很难在广大普通家庭普及。近年来,很多学者尝试利用单通道的心电 (Electrocardiogram, ECG) 信号来分析睡眠,并取得了一定的成果。Mendez 等^[1]利用隐马尔可夫模型, Xiao 等^[2]通过随机森林算法,实现了三分类睡眠分期。还有一些学者^[3-4]基于心率变异性,利用支持向量机分类器,实现了睡眠阶段的自动划分。刘众等^[5]将体动信号与 ECG 信号结合,通过改进的反向传播 (Back Propagation, BP) 神经网络有效实现了睡眠分期。虽然国外的一些学者^[6-9]利用多种神经网络实现了睡眠阶段的自动分类,并获得了较高的准确率,但他们仍然需要借助操作复杂的 PSG 采集脑电信号。彭程等^[10]基于心率变异性,提出了一种根据用户的精神压力和睡眠状态进行调整的音乐推荐系统,有效地增加了用户睡眠总时长,但依然未涉及睡眠后的智能唤醒问题。衡玮等^[11]设计了基于脑电波监测的智能助眠耳机系统,研究的重点依然放在助眠问题上。

以上研究均聚焦于睡眠监测的便捷性和睡眠分期的准确性,较少关注睡眠后的智能唤醒问题,且系统较复杂,睡眠分期模型和算法有待进一步优化。针对以上不足,文中基于 RBF 神经网络算法,提出一种能够在人体恢复到最佳时期时进行叫醒的智能唤醒系统,并配以友好的人机交互界面,以期达到优化睡眠时长、改善用户醒后状态的目的。

2 系统介绍

智能唤醒系统分为感知层、处理与传输层、应用层等,系统结构见图 1。感知层对应数据采集系统,用于采集人体 ECG 信号,由心率带 (内置 STM32 处

理器) 与配套的手机 APP (Application software) 共同实现数据采集功能。处理与传输层对应程序控制系统,主要对采集到的心电信号进行降噪、R 波峰定位和特征提取等处理,进而采用 RBF 神经网络算法实现睡眠分期。这些功能由 Matlab 软件实现,经 Matlab 训练后得到睡眠分期阈值,并传输到心率带内置的 STM32 处理器进行后续处理。应用层对应音乐唤醒系统,主要将监测到的睡眠阶段可视化,并呈现在手机 APP 界面上,同时在判断用户机体恢复到最佳状态后通过音乐实施唤醒,这些功能由智能唤醒系统应用层中的 NO SLEEP IN (不赖床) APP 实现。其中 STM32 处理器不仅需要接收数据采集系统采集到的 ECG 信号,还需要将处理好的数据传输到 APP 中,并承担在特定时间驱动程序,实现音乐唤醒任务。




图 1 智能唤醒系统结构
Fig.1 Structure of intelligent wake-up system

3 睡眠分期方法

3.1 信号预处理——小波变换

人体的 ECG 信号是一种低频信号,频率为 0.01~100 Hz。其中, QRS 复合波的能量主要集中在 3~40 Hz,且极易受到环境的干扰。噪声主要包括工频干扰、肌电干扰和低频的基线漂移等^[12],在分析 ECG 信号前需要对已获取的信号进行降噪处理。通过实验对比分析了巴特沃斯低通滤波器、带通滤波器、中值滤波法、小波变换等 4 种去噪方法,文中拟选取降噪效果最好的小波变换对 ECG 信号进行降噪。小波变换具有多分辨率分析的特点,能够将信号进行多尺度细分,可改变窗口的大小,也可以同时局部分析时域和频域^[13],具有较好的自适应性。与传统的基于傅里叶变换的数字滤波技术相比,小波变换在时频领域具有不可比拟的优势。小波变换见式 (1)。

$$W_{WT}(a,\tau)=\frac{1}{\sqrt{a}}\int_{-\infty}^{\infty}f(t)\psi\left(\frac{t-\tau}{a}\right)dt$$

(1)

式中: a 为尺度因子,控制小波函数的伸缩; τ 为时间平移因子,控制小波函数的平移; $\psi(t)$ 为基本

小波。式 (1) 对应的逆变换见式 (2)。

$$f(t) = \frac{1}{c_\psi} \int_0^{+\infty} \frac{da}{a^2} \int_{-\infty}^{+\infty} W_f(a, \tau) \frac{1}{\sqrt{a}} \psi\left(\frac{t-\tau}{a}\right) d\tau \quad (2)$$

$$c_\psi = \int_0^{+\infty} \frac{|\psi(a\omega)|^2}{a} da < \infty$$

$\Psi(t)$ 不具备唯一性, 不同小波基的选取对滤波效果的影响很大。

3.2 睡眠分期算法——RBF 神经网络

Rechtschaffen & Kales (R&K) 分期标准将睡眠阶段划分为清醒期 (Wake)、快速眼动期 (Rapid eye movement, REM) 和非快速眼动期 (Non-rapid eye movement, NREM), NREM 又包括 N1—N4 阶段, 一共分为 6 期。其中, N1、N2 称为浅睡期, N3、N4 称为深睡期。2007 年, 美国睡眠医学学会 (AASM) [14] 将 R&K 标准中的 N4 并入 N3, 将睡眠阶段共分为 5 期, 目前最为常用。由于文中仅将分期结果用于智能唤醒, 因此也将 N1 与 N2 合并为 1 期, 将睡眠阶段共分为 4 期进行研究, 即清醒期、浅睡期、深睡期、快速眼动期等 4 期。按顺序依次经历这几个睡眠阶段为 1 个睡眠周期, 在一般情况下健康成年人整晚的睡眠会循环 4~6 个睡眠周期, 每个周期通常为 90~120 min, 不同年龄和性别的人各个睡眠阶段的持续时间不同。

RBF 神经网络是一种用于解决模式识别与分类的神经网络, 而睡眠阶段的划分实际上就是一种模式识别问题, 近些年已有研究者尝试利用神经网络来进行睡眠分期 [9,15], 并获得了良好的结果。由于 RBF 神经网络不会局限于局部极值, 因此不需要学习系数, 适于在线实时辨识。与学习速度较慢、受到初始权值的影响较大、隐含层节点数较难确定的 BP 神经网络相比, RBF 神经网络的收敛速度更快、非线性逼近精度更高, 在训练时权值不受限制, 学习算法简洁且更易实现 [16], 因此这里采用 RBF 神经网络来进行睡眠分期。径向基函数神经网络是一种前馈式神经网络, 主要包括输入层、隐含层和输出层等。输入层主要用于接收外界信号。隐含层又叫基函数层, 通过基函数实现非线性变化, 一般选用高斯函数。输出层对隐含层的输出进行线性加权, 从而使整个网络具有分类功能 [17]。

RBF 神经网络的结构如图 2 所示。由输入层接收训练样本 $x_i \in R_m$, 则 RBF 网络输出如式 (3) 所示。

$$R_i(x) = \exp\left(-\frac{\|x - C_i\|^2}{2\sigma_i^2}\right) \quad i = 1, 2, \dots, n \quad (3)$$

式中: $R_i(x)$ 为隐含层的输出; x 为 m 维输入向量; C_i 为中心向量; σ_i 为归一化参数, 与基函数的宽度有关; n 为隐含层的节点数。隐含层实现 x 到 $R_i(x)$ 的非线性映射, 输出层实现 $R_i(x)$ 到 y_j 的线性映射, 输出层的输出如式 (4) 所示。




图 2 RBF 神经网络结构
Fig.2 Structure of RBF neural network

$$y_j = \sum_{i=1}^n w_{ji} R_i(x) \quad j = 1, 2, \dots, k \quad (4)$$

式中: w_{ji} 为隐含层与输出层的连接权值, 即权重; k 为输出节点数量。

运用 RBF 神经网络建立睡眠分期模型, 实际上就是通过不断训练网络, 最终确定中心向量 C_i 、宽度 σ_i 和权重 w_{ji} 。

3.3 算法性能评估与分析

神经网络算法的整体性能采用准确率 (Accuracy) 和均方误差 (MSE) 2 个指标进行分析。均方误差指预测值与真实值之差的平方的期望值, 用于衡量预测误差, 也是一种拟合优度指标, 可以用于评估模型的拟合效果。MSE 值越小, 则模型的预测误差越小、拟合程度越好。均方误差的计算见式 (5)。

$$M_{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - Z_i)^2, \quad (5)$$

式中: n 为总输入样本数量; Y_i 为睡眠阶段的标定值; Z_i 为睡眠阶段的预测值。

为了进一步分析误差产生的原因, 这里同时引入混淆矩阵作为衡量依据, 具体考察各睡眠阶段相关性的强弱。混淆矩阵是模式识别领域中常用的图表形式, 是评价模型精度的一种标准格式, 可有效评价分类器性能 [18]。为了验证 RBF 神经网络用于睡眠分期的科学性、有效性, 通过麦克尼马尔检验 (Mc Nemar test) 方法对实验结果进行显著性差异检验, 并计算卡帕 (Kappa) 系数, 进一步确定实验结果的一致性程度。麦克尼马尔检验是一种非参数统计检验方法, 用于比较 2 个相关样本中差异的统计显著性。Kappa 系数是一个用于一致性检验的指标, 所检验的 2 个变量分别是实际标记样本和模型分类结果, 因此 Kappa 系数可以用来评价模型预测结果与实际分类结果的一致性程度。在 $0.75 \leq \text{Kappa 系数} \leq 1$ 时, 表示两者具有很好的一致性; 在 $0.4 \leq \text{Kappa 系数} < 0.75$ 时, 表示两者的一致性一般; 在 $\text{Kappa 系数} < 0.4$ 时, 表示两

者的一致性较差。

4 睡眠分期实验与结果

4.1 实验设计

接受睡眠监测的研究生志愿者共有4名,年龄为23~28岁,男性2名,女性2名,分别记为志愿者1、志愿者2、志愿者3、志愿者4。每人采集5个整晚的有效睡眠数据,共计20个晚上,每晚数据均大于6 h。在实验期间保证志愿者的作息规律,且不服用任何辅助睡眠类药物,志愿者同时佩戴华为Watch gt 3手表和心率带同步监测其睡眠信息,将手表与由哈佛医学院CDB中心测试认证的TrueSleep技术配合使用, TrueSleep技术采用心肺耦合检测睡眠算法,其睡眠检测较精准。专业医师以TrueSleep睡眠分期结果为参考,判定实验数据的睡眠阶段,并做标记,将神经网络判定的睡眠阶段与手工判断结果进行对比,该标记也作为验证睡眠分期算法准确性的标准。

实验流程如图3所示。首先通过心率带采集信号,利用小波变换对采集的ECG信号进行精准去噪,最大限度地保留清晰有用的心电信号,即数据预处理。其次,利用Matlab中的findpeaks函数对R波的峰值进行定位,将相邻R波间隔记为RR间期(R-R Interval, RRI)。接着,以RRI为基础,提取相应的时频域特征向量。最后,利用RBF神经网络对提取的特征值进行反复训练,并筛选出关键的特征向量,以构建睡眠分期模型。

4.2 数据采集及预处理

采用功耗较低的心率带采集心电数据,以降低系统成本,采样频率为500 Hz,有效睡眠数据共计20个夜晚。心率带由针织材质制成,具有可伸缩性,使用时无束缚感,基本不会对睡眠者的实验数据造成干扰。在信号采集过程中心率变化可通过配套的手机APP实时查看,不同睡眠阶段采集到的心率变化如图4所示。

为了精准降噪,通过实验反复对比,这里选取与QRS复合波最相似的coif4小波对心电信号进行8个尺度的小波分解,分解如图5所示。从图5可以看出, QRS波的能量主要集中在尺度3~6上,肌电和工频干扰主要集中在尺度1~2上,而基线漂移则分布在尺度7~8上。这里将噪声所在的尺度系数置为0,以消除高低频噪声,用尺度3~6上的小波系数重构心电信号,得到清晰干净的ECG信号。ECG原始信号及信号去噪重构示意图如图6所示。

心率变异性(Heart Rate Variability, HRV)指2次相邻的心脏搏动周期之间存在的微小差异,换言之就是从本次心跳周期至下一次心跳周期的差异^[19]。大量研究表明,HRV与睡眠分期存在密不可分的联系,如心率的降低与NREM睡眠中HRV的降低有关,而心率的增加,会伴随着清醒期和REM期睡眠中HRV的增加。低频(LF, 0.04~0.15 Hz)与高频(HF, 0.15~0.4 Hz)波段的功率比(P_{LF}/P_{HF})的降低与NREM睡眠有关,而 P_{LF}/P_{HF} 的显著增加则体现在REM睡眠中^[2]。这里对ECG信号的特征提取主要基于RR间期的计算。通过Matlab中的findpeaks函数对ECG信号中的R波进行定位,并计算出相邻R波的时间间隔,记为RR间期(RRI)。由于2个R波的间隔不会小于200 ms,因此剔除间隔在0.2~2.0 s范围之外的异常值,以提高R波检测的准确性。R波峰值定位结果如图7所示,最终确定的RR间期序列用于特征向量提取。

4.3 特征提取

这里主要从时域和频域2个方面进行特征提取。HRV的时域特征直接基于RR间期序列计算得出。为了既精准划分睡眠阶段又加快系统运算速度,在对RBF神经网络进行多次训练后,筛选了10个对睡眠阶段的划分起关键作用的关键特征向量,然后根据这10个特征向量的取值范围构建睡眠分期模型。其中,包括7个经典时域特征^[2,4,11,19](见表1),以及3个频域特征。HRV的频域特征主要反映了ECG信号中各




图3 心率变异性分析流程

Fig.3 Flow chart of heart rate variability analysis




图4 不同睡眠阶段心率变化

Fig.4 Variation of heart rate in different stages of sleep




图5 ECG 信号 coif4 小波 8 个尺度分解
Fig.5 Decomposition of ECG signal by coif4 wavelet in 8 scales




图6 ECG 原始信号及信号的去噪重构
Fig.6 Original and denoised reconstructed ECG signal




图7 R波波峰定位结果
Fig.7 Results of R-wave peaks localization

表 1 文中所提取的时域特征 Tab.1 Time domain features extracted for this research			
序号	特征名称	特征描述	计算公式
1	mRRI	RR 间期序列均值	$M = \frac{1}{N} \sum_{i=1}^N X_i$
2	SDSD	相邻 RR 间期之间差异的标准差	$S_{SDSD} = \sqrt{\frac{1}{N-2} \sum_{i=1}^{N-1} (\Delta X_i - \overline{\Delta X})^2}$
3	SDNN	RR 间期序列标准差	$S_{SDNN} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (X_i - M)^2}$
4	NN50	相邻 RR 间期相差大于 50 ms 的数量	$Y = \sum_{i=1}^{N-1} (X_{i+1} - X_i > 50)$
5	pNN50	相邻 RR 间期相差大于 50 ms 的占比	$Y_{\text{percent}} = 100 \cdot \frac{Y}{N-1}$
6	HR	心率	$H = \frac{60}{M}$
7	CV	RR 间期序列变异系数	$C = \frac{S_{SDNN}}{M}$

注: M 表示 RR 间期序列的均值, mRRI; X 表示 RR 间期, RR; Y 表示相邻 RR 间期相差大于 50 ms 的数量, NN50; H 表示心率, HR; C 表示 RR 间期序列变异系数, CV。

频段的能量分布,对上述提取的 RR 间期序列进行快速傅里叶变换,得到心率的功率谱信息,以时长 30 s 划分数据,进行短时程频域分析,进而提取 0.003~0.04 Hz (极低频)、0.04~0.15 Hz (低频)、0.15~0.4 Hz (高频)这 3 个经典频域特征。

4.4 睡眠分期

利用 RBF 神经网络,根据构建好的睡眠分期模型,对数据进行睡眠分期实验。以某晚的睡眠数据为例,该数据睡眠总时长为 6.05 h,以 30 s 为一段样本,共划分为 726 段数据样本,以其中 76% 的 550 段数据样本为训练集,以剩下的 176 段数据样本为测试集进行验证。为了直观分析每个睡眠阶段具体的预测表现,将原本按时间排序的分类结果按睡眠阶段的类别重新排序,该晚神经网络睡眠分期预测结果如图 8 所

示。从图 8 可以看出,训练集和测试集预测的准确率均在 93%以上,效果良好,其 MSE 值分别为 0.335 75、0.412 86,预测值与真实值大致吻合、重合度较高,符合分类要求。

各睡眠阶段分类结果混淆矩阵图如图 9 所示,其中,1 表示清醒期,2 表示 REM 期,3 表示浅睡期,4 表示深睡期。从图 9 中可以看出,在训练集中 REM 期和浅睡期表现较差,在测试集中深睡期的精准率和召回率均为 97.6%,综合准确率最高,预测效果最好。

对 4 个志愿者 20 个晚上的睡眠分期数据进行统计,计算各自睡眠分期的预测准确率和均方误差。由于训练后的神经网络模型分类效果主要由测试集体现,因此利用麦克尼马尔检验方法计算测试集的渐进显著性 (P),并进一步计算其 Kappa 值 (K_{kappa}),以

验证测试集实验结果的一致性,结果如表 2 所示。测试集的麦克尼马尔检验结果显示,渐进显著性 ($P_{\text{平均}}=0.1$) 大于 0.05,说明 RBF 神经网络模型的分类结果与实际分类具有一致性。 K_{kappa} 平均=0.839,大于 0.75,说明实验结果存在显著一致性,具有统计学意义。训练集的准确率均在 90%以上,平均准确率为 92.7%,平均 MSE 值为 0.399 27。测试集的平均准确率为 88.9%,平均均方误差为 0.511 87。可见,整体预测准确率较高,误差在可接受范围内,模型的拟合优良,具有实际应用价值。

此外,将文中提出的睡眠分期算法与其他研究者采用的算法进行了对比,如表 3 所示。从表 3 可以看出,文中基于 RBF 神经网络实现的睡眠分期算法采集的信息较少,睡眠分期较多,准确率更高,综合识别效果更好,具有显著的优越性。




图 8 RBF 神经网络睡眠分期预测结果
Fig.8 Prediction results of sleep staging from RBF neural networks




图 9 训练集和测试集各睡眠阶段分类结果混淆矩阵
Fig.9 Confusion matrix of classification results for each sleep phase in training and testing sets

表 2 各志愿者睡眠分期预测结果统计
Tab.2 Statistics of sleep staging prediction results for each volunteer

志愿者	数据分组	训练集		测试集			
		准确率/%	MSE 值	准确率/%	MSE 值	McNemar 检验结果 (P)	Kappa 系数
志愿者 1	1	92.2	0.400 0	86.9	0.593 5	0.04	0.813
	2	91.8	0.430 6	83.5	0.648 4	0.06	0.764
	3	92.7	0.393 1	91.5	0.538 3	0.09	0.875
	4	94.0	0.369 3	85.8	0.543 6	0.07	0.795
	5	92.4	0.443 1	89.2	0.574 1	0.05	0.845
平均值		92.6	0.407 2	87.4	0.579 6	0.06	0.818
志愿者 2	1	92.5	0.422 1	92.6	0.376 9	0.14	0.893
	2	93.6	0.374 2	89.8	0.433 0	0.17	0.845
	3	93.1	0.388 5	90.3	0.516 8	0.06	0.857
	4	92.9	0.383 8	90.9	0.439 5	0.09	0.871
	5	94.4	0.341 1	87.5	0.511 2	0.10	0.822
平均值		93.3	0.381 9	90.2	0.455 5	0.11	0.858
志愿者 3	1	90.4	0.451 3	88.6	0.533 0	0.05	0.832
	2	90.9	0.453 3	85.2	0.564 1	0.06	0.786
	3	93.3	0.379 0	92.0	0.464 7	0.28	0.886
	4	93.5	0.390 8	88.1	0.470 7	0.05	0.824
	5	94.7	0.335 8	93.2	0.412 9	0.20	0.901
平均值		92.5	0.402 0	89.4	0.489 1	0.13	0.846
志愿者 4	1	91.6	0.413 4	84.7	0.569 1	0.18	0.777
	2	94.2	0.351 6	93.8	0.384 4	0.20	0.909
	3	93.8	0.364 3	94.3	0.398 9	0.07	0.917
	4	91.3	0.436 9	86.4	0.661 4	0.05	0.800
	5	91.1	0.463 2	84.1	0.603 0	0.05	0.761
平均值		92.4	0.405 9	88.6	0.523 4	0.11	0.833
总平均值		92.7	0.399 3	88.9	0.511 9	0.10	0.839

表 3 不同睡眠分期算法的准确率对比
Tab.3 Comparison of accuracy of different algorithms for sleep staging

算法类别	处理信号	睡眠分期	准确率/%
隐马尔可夫模型 ^[1]	ECG 信号	Wake-REM-NREM	2 features (78.21±6.44) 3 features (79.43±8.83)
随机森林 ^[2]	ECG 信号	Wake-REM-NREM	(88.67±3.25)
支持向量机分类器 ^[3]	ECG 信号	Wake-REM-NREM	87.94
改进的 BP 神经网络 ^[5]	ECG 和体动信号	Wake-REM-NREM	86.29
径向基函数神经网络 ^[9]	EEG 信号	W-REM-S1-S2-SWS	88.00
文中算法	ECG 信号	Wake-REM-L-D	Train 92.7 Test 88.9

5 智能唤醒系统设计

5.1 唤醒机制设计

为了使用户在清晨舒适醒来,设计了一种智能唤醒机制,如图 10 所示。根据心理学方面的研究成果,在人体处于第 4 个睡眠周期末时将其唤醒最理想。由此,在默认状态下,将智能唤醒系统设置为在监测到

用户处于第 4 个睡眠周期末时将其唤醒,以保证用户在身体恢复到最佳状态时醒来。如果用户需要预设唤醒时间段,则系统将用户所处的睡眠阶段与用户预设的唤醒时间综合起来作为唤醒的判断条件。具体来说,用户先预设一个起床时间段,由于深睡期一般只发生在凌晨 5 点前,因此唤醒系统会在这个时间段内先判断用户是否处于浅睡期,如果是则叫醒用户,如果不是则系统继续监测;当监测到用户处于快速眼动




图 10 智能唤醒机制
Fig.10 Mechanism of intelligent wake-up

期 (REM) 时, 将用户叫醒, 如果不是则系统继续监测。这样, 系统既可在用户预设的时间段内将其唤醒, 不耽误其重要工作, 又可使用户在恰当的睡眠阶段醒来, 以最佳的状态快速进入工作。

5.2 软件功能及界面设计

系统将根据睡眠分期结果通过手机 APP 在恰当的时机用音乐将用户唤醒。为了最大限度地实现智能唤醒系统的功能, 并创造良好的用户体验, 这里设计了与智能唤醒机制相匹配的 NO SLEEP IN (不赖床) APP 界面, 如图 11 所示。




图 11 智能唤醒系统 APP 界面设计展示
Fig.11 Interface design of an intelligent wake-up system APP

在视觉上, 整个界面色调和谐统一, 符合夜间使用需求。在功能设计上, 对于智能唤醒需求, 该 APP 设置了 4 种模式: 默认最佳, 系统将在用户处于第 4 个睡眠周期末时实施唤醒; 半智能, 用户可预设唤醒时间段及系统监测最佳状态的时长, 系统将预设时段与用户状态结合起来, 综合判定唤醒时刻; 非智能, 仅具有普通闹钟功能; 自然醒, 不具备唤醒功能, 系统仅分析用户的睡眠状态。此外, 该 APP 还可显示用户累计时间段的睡眠监测报告, 并具有音乐助眠、社群交流等功能, 以满足用户多样化的睡眠需求。

6 结论

基于 RBF 神经网络提出了一种准确率较高、模型拟合优度较好的睡眠分期方法, 并设计了一套低成本高效率的智能唤醒系统, 优化的唤醒机制可以有效避免用户醒后情绪烦躁、状态差等问题。通过低功耗心率带采集人体心电信号, 大大节约了系统成本。在信号预处理阶段, 通过实验对比, 优选出 coif4 小波及其分解与重构尺度, 它对 ECG 信号具有更好的降噪效果, 为提升睡眠分期的准确率奠定了良好的基础。利用 RBF 神经网络算法对提取的特征值反复训练, 精选出对睡眠分期起关键作用的特征向量, 从而构建睡眠分期模型。实验结果表明, 基于该模型的 RBF 神经网络的计算负担更小、运算速度更快, 与其他用于睡眠分期的算法相比, 它具有更高的准确率。此外, 还基于用户体验设计了与唤醒机制相匹配的手机 APP 交互界面, 提升了整个系统的智能性和完整性。

文中设计的 RBF 神经网络结构, 虽然整体上能较准确地完成睡眠阶段的划分, 但在 REM 期和清醒期的分类表现上相对较弱, 未来将进一步研究神经网络的算法, 以提高 REM 期和清醒期的分类精度。此外, 不同性别和年龄的人在睡眠阶段划分标准上也存在差异, 因此未来计划扩大实验样本数量, 将性别和年龄作为特征值进行提取, 以提高神经网络睡眠分期的普适性, 提升整个智能唤醒系统的实用价值。所设计的智能唤醒系统仅从理论上实现了唤醒机制和软件界面设计的优化, 在实践上, 手机终端软件的功能尚未完全实现。今后将把软件功能的实现作为研究重点, 增强智能唤醒系统的完整性和现实意义。

参考文献:

[1] MENDEZ M O, MATTEUCCI M, CERUTTI S, et al. Sleep Staging Classification Based on HRV: Time-Variant Analysis[C]// 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE, 2009: 9-12.
[2] XIAO M, YAN H, SONG J Z, et al. Sleep Stages Clas-

- sification Based on Heart Rate Variability and Random Forest[J]. Biomedical Signal Processing and Control, 2013, 8(6): 624-633.
- [3] 王金海,孙微,韦然,等.基于心率变异性分析的睡眠分期方法研究[J].生物医学工程学杂志,2016,33(3): 420-425.
WANG J H, SUN W, WEI R, et al. Study on Sleep Staging Methods Based on Heart Rate Variability Analysis[J]. Journal of Biomedical Engineering, 2016, 33(3): 420-425.
- [4] 郑捷文,张悦舟,兰珂,等.基于心率变异性分析的睡眠分期算法研究和验证[J].中国生物医学工程学报,2020,39(4): 432-439.
ZHENG J W, ZHANG Y Z, LAN K, et al. Sleep Stage Classification Based on Heart Rate Variability Analysis and Model Performance Validation[J]. Chinese Journal of Biomedical Engineering, 2020, 39(4): 432-439.
- [5] 刘众,王新安,李秋平,等.基于ECG信号和体动信号的睡眠分期方法研究[J].北京大学学报(自然科学版),2021,57(5): 833-840.
LIU Z, WANG X A, LI Q P, et al. Research of Sleep Staging Algorithms Based on ECG and Body Motion Signals[J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2021, 57(5): 833-840.
- [6] ZHU T Q, LUO W, YU F. Convolution-and Attention-Based Neural Network for Automated Sleep Stage Classification[J]. International Journal of Environmental Research and Public Health, 2020, 17(11): 4152.
- [7] KWON K, KWON S, YEO W H. Automatic and Accurate Sleep Stage Classification via a Convolutional Deep Neural Network and Nanomembrane Electrodes[J]. Biosensors, 2022, 12(3): 155.
- [8] YOU Y Y, ZHONG X Y, LIU G Z, et al. Automatic Sleep Stage Classification: A Light and Efficient Deep Neural Network Model Based on Time, Frequency and Fractional Fourier Transform Domain Features[J]. Artificial Intelligence in Medicine, 2022, 127: 102279.
- [9] LEE H, CHOI J, KIM S, et al. A Compressive Sensing-Based Automatic Sleep-Stage Classification System with Radial Basis Function Neural Network[J]. IEEE Access, 2019, 7: 186499-186509.
- [10] 彭程,常相茂,仇媛.基于心率变异性分析的睡眠音乐推荐系统[J].计算机应用,2020,40(5): 1539-1544.
PENG C, CHANG X M, QIU Y. Heart Rate Variability Analysis Based Sleep Music Recommendation System[J]. Journal of Computer Applications, 2020, 40(5): 1539-1544.
- [11] 衡玮,徐自强,陈璐瑶,等.基于脑电波监测智能助睡眠耳机设计[J].计算机应用与软件,2020,37(8): 219-226.
HENG W, XU Z Q, CHEN L Y, et al. Design of Intelligent sleep-Assisted Earphone Based on Brain Wave Monitoring[J]. Computer Applications and Software, 2020, 37(8): 219-226.
- [12] 冀常鹏,李蓓蕾.心电信号识别方法的研究与实现[J].计算机应用与软件,2018,35(3): 173-176.
JI C P, LI B L. Research and Implement of ECG Signal Identification Method[J]. Computer Applications and Software, 2018, 35(3): 173-176.
- [13] 付文亨,邓体俊,陈海生.小波变换系数奇异值分解数字水印防伪算法[J].包装工程,2015,36(21): 128-132.
FU W T, DENG T J, CHEN H S. A Watermarking Algorithm for Security Based on Discrete Wavelet Transform and Singular Value Decomposition[J]. Packaging Engineering, 2015, 36(21): 128-132.
- [14] BERRY R B, BUDHIRAJA R, GOTTLIEB D J, et al. Rules for Scoring Respiratory Events in Sleep: Update of the 2007 AASM Manual for the Scoring of Sleep and Associated Events. Deliberations of the Sleep Apnea Definitions Task Force of the American Academy of Sleep Medicine[J]. Journal of Clinical Sleep Medicine: JCSM: Official Publication of the American Academy of Sleep Medicine, 2012, 8(5): 597-619.
- [15] CHEN X Y, HE J, WU X Q, et al. Sleep Staging by Bidirectional Long Short-Term Memory Convolution Neural Network[J]. Future Generation Computer Systems, 2020, 109: 188-196.
- [16] 唐艳,孙刘杰,王勇.基于SIFT变换和RBF神经网络的彩色全景图拼接算法[J].包装工程,2018,39(21): 216-221.
TANG Y, SUN L J, WANG Y. Color Panorama Mosaic Algorithm Based on SIFT Transform and RBF Neural Network[J]. Packaging Engineering, 2018, 39(21): 216-221.
- [17] 李丹,翟震.改进的RBF神经网络PID算法在电磁振机中的应用[J].包装工程,2019,40(7): 192-196.
LI D, ZHAI Z. Application of Improved RBF Neural Network PID Algorithm in Electromagnetic Vibrating Machine[J]. Packaging Engineering, 2019, 40(7): 192-196.
- [18] 杨韞仪,裴卉宁,李书航,等.基于多项Logistic回归的座面材质预测模型[J].包装工程,2021,42(16): 182-187.
YANG Y Y, PEI H N, LI S H, et al. Seat Surface Material Prediction Model Based on Multiple Logistic Regression[J]. Packaging Engineering, 2021, 42(16): 182-187.
- [19] 应少飞.基于心率变异性的多导睡眠监护仪[D].成都:电子科技大学,2020: 27-33.
YING S F. PSG Base on Heart Rate Variability[D]. Chengdu: University of Electronic Science and Technology of China, 2020: 27-33.