

光电容积脉搏波的睡眠呼吸暂停综合征筛查方法

李肃义¹, 姜 珊¹, 刘丽佳¹, 熊文激², 倪维广^{1*}

1. 吉林大学仪器科学与电气工程学院, 吉林 长春 130061

2. 吉林大学第一医院, 吉林 长春 130021

摘 要 睡眠呼吸暂停综合征(SAS)素有“睡眠杀手”之称。由于其诊断金标准多导睡眠监测仪(PSG)的限制, 诊断率一直偏低。由于呼吸暂停发生时会引起心率节律的变化, 因此利用心电图(ECG)通过心率变异性(HRV)分析可以实现 SAS 的自动筛查。但是, ECG-SAS 方法所用电极穿戴繁琐、材质致敏性较高, 影响睡眠舒适度。鉴于脉率变异性(PRV)分析与 HRV 分析高度相关, 并且光电容积脉搏波(PPG)信号相对 ECG 信号获取方式更加简单, 不仅电极不易致敏, 而且更易于穿戴, 对睡眠干扰小。由此, 提出利用同步采集的 PPG 信号和 ECG 信号, 应用相同的建模方法, 比较二者的疾病识别能力。应用反向传播(BP)神经网络, 分别建立 PPG-SAS 与 ECG-SAS 自动筛查模型, 并采用十折交叉验证法及受试者工作特征(ROC)曲线对模型进行对比与评估。实验数据来源于 MIT-BIH Polysomnographic Database, 共 8 248 个样本, 其中正常样本 6 227 例。首先采用三层 BP 神经网络, 默认参数下建立 PPG-SAS 与 ECG-SAS 模型, 使用十折交叉验证法及 ROC 曲线进行模型分类准确性的对比; 然后依次改变影响分类性能的隐层节点数、训练函数以及传递函数, 建立多个 PPG-SAS 与 ECG-SAS 模型, 从中选取各自的最优模型再进行对比。通过比较识别率、预测率以及 ROC 曲线面积, 采用默认参数的 PPG-SAS 模型优于 ECG-SAS 模型。通过比较平均分类准确率, 隐层节点数为 50、训练函数为一步正割算法、隐含层传递函数为双曲正切 S 型函数时, PPG-SAS 模型得到的最高识别率与预测率分别为 80.30% 和 80.13%; 隐层节点数为 50、训练函数为一步正割算法、隐含层传递函数为径向基时, ECG-SAS 模型的最高识别率与预测率分别为 77.60% 和 77.67%。以上实验结果均表明 PPG 信号的 SAS 分类能力较 ECG 信号更具优越性, 由此证明了 PPG 信号筛查 SAS 的可行性及可靠性, 为临床 SAS 病症的早期发现及诊断率提升奠定理论基础。

关键词 睡眠呼吸暂停综合征; 光电容积脉搏波; 心电信号; 神经网络; 十折交叉验证法

中图分类号: TP391 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2019)06-1852-06

引 言

睡眠呼吸暂停综合征(sleep apnea syndrome, SAS)是一种常见的睡眠障碍性疾病, 可导致人嗜睡、易怒、注意力不集中, 增加 2~7 倍的车祸风险。不仅能诱发高血压、冠心病等心脑血管疾病, 还会引发慢性疾病, 严重时甚至可能导致“猝死”^[1-3]。由于 SAS 诊断的金标准多导睡眠监测仪(polysomnography, PSG)造价高、过程复杂且需要专业的操作技术, 导致 SAS 的诊断率偏低, 据有关统计表明: 高达 93% 的女性和 82% 的男性患者未被确诊^[4]。因此国内外一直在积极地寻求检测方便、价格低、对睡眠干扰小的筛查方法来提升

SAS 诊断率。

呼吸暂停的发生会引起心率节律的变化, 因此利用心电图信号(electrocardiograph, ECG)通过心率变异性(heart rate variability, HRV)分析可实现 SAS 的筛查。Chazal 等^[5]以 PSD、心率、R 波幅值等多个时域、频域指标作为特征参数来进行 SAS 的自动检测; 由于 SAS 发作时心率波动是瞬时的、高度非线性与非平稳的, 所以 Mietus 等^[6]提出使用 Hilbert 变换来进行 RR 间期变化分析; Zywiets 等^[7]采用小波变换提取正常人与 SAS 患者的 HRV 频谱成分; Chazal 等^[8]基于 RR 间期系列与 ECG 的形态, 计算了 88 个有关特征参数, 提升了 SAS 的检测准确度; 2006 年, 佟光明等^[9]通过分析 80 例睡眠中心患者的 HRV 频域与时域指标, 并联合推

收稿日期: 2018-05-16, 修订日期: 2018-10-28

基金项目: 国家重点研发计划项目(2017YFC0307705), 吉林省自然科学基金项目(20180101049JC)资助

作者简介: 李肃义, 女, 1972 年生, 吉林大学仪器科学与电气工程学院教授 e-mail: lsy@jlu.edu.cn

* 通讯联系人 e-mail: niwg@jlu.edu.cn

导的呼吸曲线 EDR 实现了 SAS 的检测; 反向传播 (back-propagation, BP) 神经网络是一种按误差反向传播算法训练的多层前馈网络, 已经被成功应用于很多领域, 尤其适用于人体参数与复杂疾病的模型建立。2011 年, Acharya 等^[10]提出使用 ECG 的关联维数、分形维数等 5 个非线性参数训练 BP 神经网络以进行 SAS 的自动分类; Lweesy 等^[11]尝试使用 P 波形态参数来训练 BP 神经网络。2012 年, Kesper 等^[12]通过分析 HRV 与 EDR 参数设计了 SAS 自动检测算法。以上研究的分类准确率在 65%~91% 之间, 充分证明了 ECG-SAS 筛查模型的有效性。但是, ECG-SAS 筛查方法需要患者佩戴多个心电电极, 以氯化银为主的电极不仅会对皮肤有较高致敏性, 而且其布放的位置也会影响睡眠舒适度^[13]。

动脉血管壁会随心脏节律性跳动而产生周期性波动, 当利用光电传感器进行照射时, 接收端接收到的交流信号会随之产生变化, 即光电容积脉搏波 (photoplethysmography, PPG)^[14]。呼吸暂停的发生也会引起脉率节奏的相应变化, 并且基于 PPG 的脉率变异性 (pulse rate variability, PRV) 分析与基于 ECG 的 HRV 分析已被证实具有高度相关性^[15-16]。另外, 与心电电极相比, 脉搏传感器可以布放在指尖、手腕、耳垂等位置^[17], 穿戴相对简单, 采集更加灵活, 所以, 利用 PPG 来进行 SAS 的筛查已成为可能^[18]。

本工作拟通过同步采集的 PPG 信号和 ECG 信号, 使用相同的分类方法, 分别建立 PPG-SAS 与 ECG-SAS 的自动筛查模型, 并且通过比较它们分类准确率来进一步验证 PPG 用于筛查 SAS 的可靠性与有效性。

1 实验部分

1.1 数据

实验数据来源于 Boston's Beth Israel 医院睡眠实验室提供的 MIT-BIH Polysomnographic Database, 记录了年龄在 32~56 岁之间 (平均年龄 43 岁), 体重在 89~152 kg (平均体重 119 kg) 的 16 名受试者睡眠期间包括 ECG、EEG、脉压、呼吸信号、PPG 信号等在内的多个生理信号, 其采样频率为 250 Hz, 每 30 s 的数据附有专家提供相关睡眠阶段和呼吸暂停的注释。图 1 为同一患者同步的带有专家注释的归一化后的 30 s PPG 信号与 ECG 信号。通过比较图 1(a) (专家注释为 SAS 的 PPG 信号) 与图 1(c), 图 1(b) (专家注释为 SAS 的 ECG 信号) 与图 1(d), 我们可以观察到图 1(a) 与图 1(b) 在 SAS 发生时, 峰峰间期均产生了改变, 尤其在 3 000~5 000 采样点时峰峰间期均偏大。图 1(c) 与图 1(d) 为正常信号, 峰峰间期比较均匀。

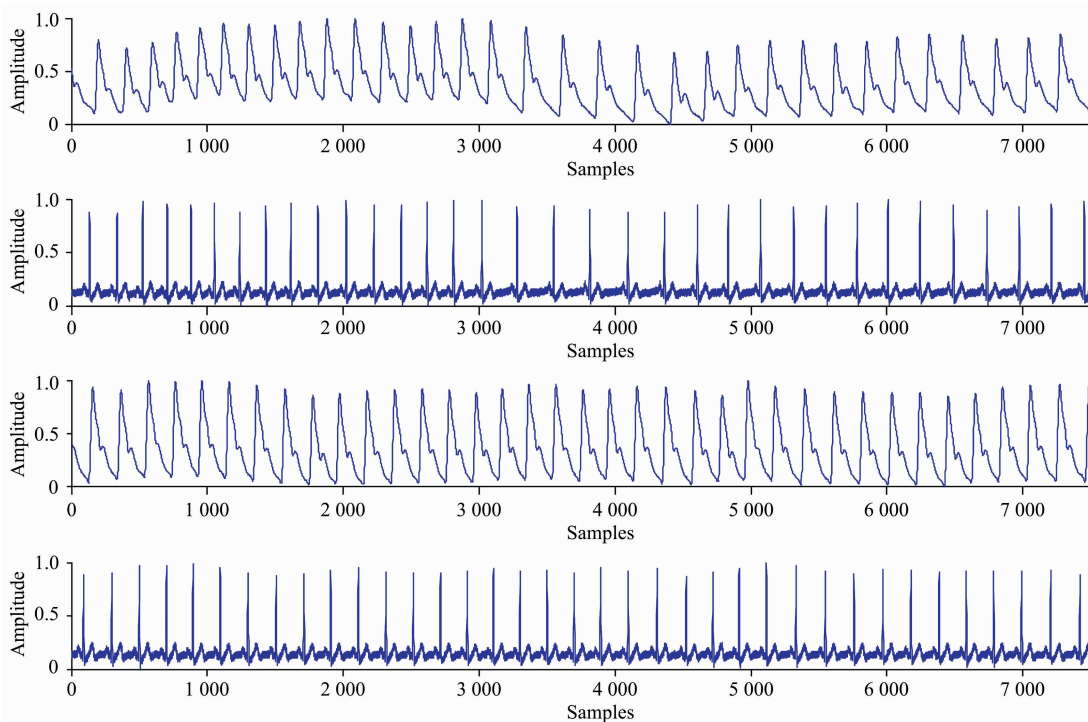


图 1 同步采集的 PPG 信号和 ECG 信号

(a): SAS 的 PPG 信号; (b): SAS 的 ECG 信号; (c): 正常的 PPG 信号; (d): 正常的 ECG 信号

Fig. 1 The PPG and ECG signals collected synchronously

(a): PPG signal labeled as SAS; (b): ECG signal labeled as SAS; (c): PPG signal labeled as normal; (d): ECG signal labeled as normal

我们整理了数据库中伴有专家注释的所有 PPG 信号和 ECG 信号, 分别形成 PPG-SAS 与 ECG-SAS 实验样本集。以 PPG-SAS 为例, 样本集由输入向量 X 与输出向量 Y 组成, 其中输入向量为 PPG 信号, 共 8 248 个, 每个 7 500 维, 输

出向量为分类结果, 01 代表患有 SAS, 10 代表正常, 其中正常样本 6 227 例, SAS 样本 2 021 例。

1.2 SAS 筛查模型的建立与优化

鉴于 BP 神经网络在 ECG-SAS 筛查模型中的成功应用,

应用 BP 分类器分别建立 PPG-SAS 与 ECG-SAS 的自动筛查模型。主要实现步骤如下:

(1) 数据归一化处理

为避免不同数量级数字间的影响,对 PPG 与 ECG 原始数据分别采用式(1)进行归一化处理:

$$\dot{X} = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (1)$$

其中 X 为原始数据, \dot{X} 为归一化后的数据。

(2) BP 网络的建立

BP 网络属于有监督的训练,设每个节点输出值 Y 为

$$Y = \sigma\left(\sum_{i=1}^I WX + b\right) \quad (2)$$

其中, W 为两节点间的连接权重, I 为上一层节点个数, X 为上一层节点的输出值, b 为当前节点的阈值, σ 表示传递函数。

计算网络实际输出与期望输出之间的误差,通过训练算法修正各层各节点间的权重及节点的阈值

$$\begin{cases} W \leftarrow W - \eta \frac{\partial E(W, b)}{\partial W} - c\eta \frac{\partial E(W, b)}{\partial W} \\ b \leftarrow b - \eta \frac{\partial E(W, b)}{\partial b} \end{cases} \quad (3)$$

其中, η 为网络训练的学习率, c 为动量因子。

BP 网络建立的核心是设计与选取合适的网络结构、传递函数、训练函数以及性能函数等参数^[19]。

网络结构:依据 Kolmogorov 定理,三层 BP 神经网络即可实现任何函数在任何精度上的非线性映射。

传递函数:包括隐含层传递函数与输出层传递函数。常用的有双曲正切 S 型(tansig)、S 型(logsig)、竞争型(compet)、径向基(radbas)、和三角形径向基(tribas)传递函数。

训练函数:BP 网络的训练函数常用的学习算法有量化共轭梯度法(trainscg)、自适应学习率动量梯度下降法(traingdx)、Powell-Beale 共轭梯度法(traincgb)、Fletcher-Reeves 共轭梯度法(traincgf)、一步正割算法(trainoss)和自适应学习率梯度下降法(traingda)。

性能函数:常用的性能函数有交叉熵函数(cross-entropy)和均方误差(mean squared error, MSE),一般分类问题用 cross-entropy 来定义损失函数。

鉴于网络模型的主要参数对最终筛查效果有不同程度的影响,依次改变隐层节点数、传递函数及训练函数,并通过对比模型训练时间与预测准确率,进行不同参数下同步的 PPG 信号和 ECG 信号对 SAS 的分类效果的比较。

1.3 SAS 筛查模型的评估

采用十折交叉验证法来评估 PPG-SAS 与 ECG-SAS 模型的性能。将 PPG 信号与 ECG 信号分别从患病、健康样本中各随机选取 90% 的数据(共 7 423 例)作为训练集,10% 的样本(共 825 例)作为测试集,共进行 10 次,按式(4)计算每一次的分类准确率

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \times 100\% \quad (4)$$

其中 TP(True Positive)代表检测为真阳, TN(True Nega-

tive)代表检测为真阴, FP(False Positive)代表检测假阳, FN(False Negative)代表检测为假阴。

最终通过对比这 10 次分类准确率的平均值,来分析同步的 PPG 信号和 ECG 信号在同一模型下对 SAS 的筛查效果。

2 结果与讨论

2.1 默认参数下模型分类性能对比

利用随机分配的 PPG 与 ECG 样本,分别建立 BP 分类模型。分类模型默认的主要参数如下:网络结构为 3 层;隐层节点数为 10;训练函数使用 trainscg;隐含层传递函数采用 tansig,输出层采用 softmax;性能函数为 cross-entropy。

采用十折交叉验证法,分别计算了两种模型的识别率与预测率,如表 1 所示。

表 1 PPG-SAS, ECG-SAS 模型的训练与测试分类结果
Table 1 Training and test classification results of PPG-SAS and ECG-SAS models

实验次数	PPG-SAS		ECG-SAS	
	识别率/%	预测率/%	识别率/%	预测率/%
1	76.82	77.98	75.42	75.51
2	79.00	78.17	73.97	75.51
3	79.78	77.82	76.51	75.47
4	79.72	79.01	75.42	75.51
5	78.63	79.07	75.42	75.72
6	79.42	79.37	74.94	75.50
7	81.42	80.30	74.09	75.52
8	77.85	78.04	76.03	75.37
9	78.33	78.82	77.24	75.22
10	79.66	78.23	77.24	75.55
均值	79.06	78.68	75.63	75.49

通过表 1 可知, PPG-SAS 模型的平均识别率为 79.06%, 预测率为 78.68%; ECG-SAS 模型分别为 75.63% 与 75.49%, 由此可见在默认参数下,利用同步采集的 PPG 信号与 ECG 信号预测 SAS, PPG 信号的准确率优于 ECG 信号的准确率。

图形可以更加直观地对比两种模型的预测效果,图 2 为第 5 次实验的受试者工作特征(receiver operating characteristic, ROC)曲线,曲线所占面积越大、即曲线越靠近左上角,其准确率就越高。图 2(a)为 PPG-SAS 模型的 ROC 曲线,图 2(b)为 ECG-SAS 模型的,其中 Class1 为 TP 曲线, Class2 为 TN 曲线。直观对比二者所占面积, PPG-SAS 的分类效果明显优于 ECG-SAS 的分类效果。

2.2 优化参数下模型分类性能对比

隐层节点数、训练函数以及传递函数是影响网络分类性能的主要参数,采用 2.1 中十折交叉验证时形成的 PPG 与 ECG 样本,采用 3 层网络结构,在不改变其他参数的基础上,依次调整以上参数以评估模型的性能。

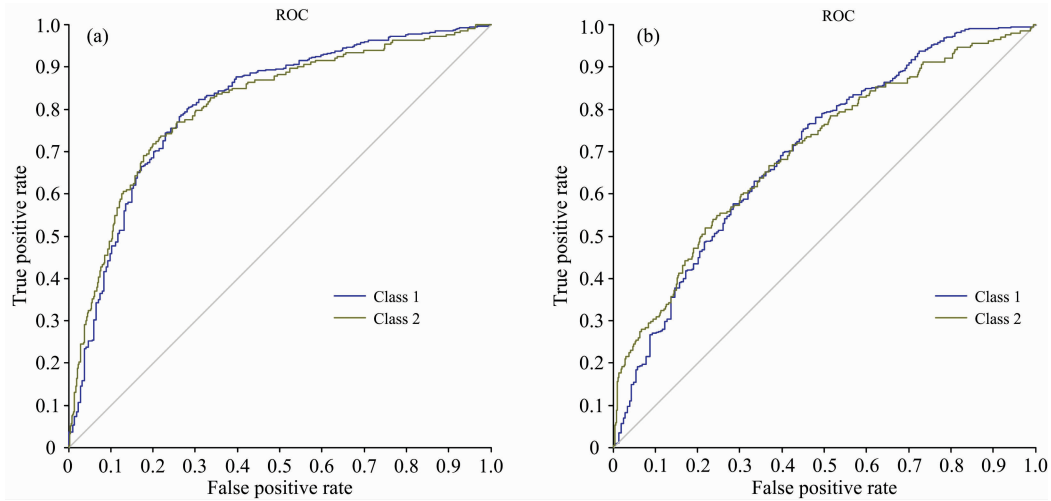


图 2 ROC 曲线

(a): PPG-SAS 模型; (b): ECG-SAS 模型

Fig. 2 ROC curves

(a): PPG-SAS model; (b): ECG-SAS model

表 2 列出了两种模型的隐层节点数分别为 10, 25, 50, 100, 300 和 500 下输出的平均识别率、预测率以及建模时间的对比。

表 2 不同隐层节点数下两种模型的平均分类准确率与建模时间均值比较

Table 2 Comparisons of average classification accuracies and average modeling time between two models with different numbers of hidden units

隐层单元数	PPG-SAS			ECG-SAS		
	识别率 /%	预测率 /%	耗时 /s	识别率 /%	预测率 /%	耗时 /s
10	79.06	78.68	9.24	75.63	75.49	8.35
25	77.90	77.90	10.96	75.68	75.86	10.66
50	79.34	79.70	13.68	75.92	76.17	19.56
100	79.82	79.41	27.02	75.24	75.09	29.43
300	80.85	80.67	88.24	73.04	72.85	75.11
500	79.92	79.76	149.62	74.78	74.54	168.80

通过表 2 可知, 识别率与预测率会随隐层节点数的增加略有增加, 但增加到一定程度时则会降低; 建模耗时会随隐层节点数的增加而大大增加。综合考虑输出准确率与耗时, 将筛查模型的隐层节点数定为 50。

保持隐层节点数为 50 不变, 改变训练函数, 表 3 列出了不同训练函数下取得的两个模型的平均识别率与预测率。

通过表 3 可知, 训练函数为 trainoss 函数时, PPG-SAS 与 ECG-SAS 模型的平均分类准确率均更高, 其中 PPG-SAS 模型可达 80% 左右。

隐层节点数为 50, 训练函数为 trainoss, 由于处理的是分类问题, 所以输出层的传递函数固定为 softmax, 改变隐含层的传递函数, 表 4 为两种模型在不同传递函数下的平均识别率与预测率对比结果。

表 3 不同训练函数下两种模型的平均分类准确率对比

Table 3 Comparisons of average classification accuracies between two models with different training functions

训练函数	PPG-SAS		ECG-SAS	
	识别率 /%	预测率 /%	识别率 /%	预测率 /%
trainscg	79.34	79.70	75.92	76.17
traingdx	78.95	79.12	74.77	74.87
traingcb	79.23	79.53	76.04	75.88
traingcf	78.82	79.05	76.00	76.05
trainoss	80.30	80.13	76.44	76.60
traingda	71.73	71.94	72.36	71.87

表 4 不同传递函数下的两种模型的平均分类准确率对比

Table 4 Comparisons of average classification accuracies between two models with different transfer functions

隐含层传递函数	PPG-SAS		ECG-SAS	
	识别率 /%	预测率 /%	识别率 /%	预测率 /%
tansig	80.30	80.13	76.44	76.60
logsig	80.05	80.19	75.71	75.83
compet	75.94	75.40	75.58	75.32
radbas	75.99	75.47	77.60	77.67
tribas	75.99	75.47	76.77	76.63

通过表 4 可知, ECG-SAS 模型在隐含层传递函数为 radbas 及 tribas 时比 PPG-SAS 模型的平均分类准确率稍高, 但 PPG-SAS 模型在传递函数为 tansig 及 logsig 时, 分类准确率均超过了 80%。

通过分析以上实验结果, 可以看到, 当使用同步采集的 ECG 与 PPG 信号进行 SAS 分类模型的建立时, 无论是使用默认参数的 BP 分类模型还是优化参数的模型, PPG-SAS 模型分类效果均要优于 ECG-SAS 模型。

3 结 论

根据 HRV 分析与 SAS 密切相关的原理, 利用 ECG 筛查 SAS 已被证实具有可行性及有效性。但是, ECG 的电极材质致敏性较高, 并且电极穿戴繁琐会对睡眠舒适度造成影响。鉴于 PRV 分析与 HRV 分析的高度相关性, 并且 PPG 传感器不易致敏且穿戴简单, 利用 MIT-BIH Polysomnographic Database 中同步采集的 PPG 信号和 ECG 信号, 应用相同的 BP 建模方法, 分别建立了 PPG-SAS 与 ECG-SAS 筛查模型, 采用十折交叉验证法评估了二者的分类准确率以探讨临床上使用 PPG 信号筛查 SAS 的可行性及可靠性。在默认参数下, 得到 ECG-SAS 模型的平均识别率与预测率为 75.63% 与 75.49%; PPG-SAS 模型为 79.06% 与 78.68%。

References

- [1] Chang C C, Chuang H C, Lin C L, et al. *Sleep Medicine*, 2014, 15(4): 410.
- [2] Yaggi H Klar, John Concato, Walter N Kernan, et al. *The New England journal of medicine*, 2005, 353(19): 2034.
- [3] Selim B J, Junna M R, Morgenthaler T I. *Sleep Medicine Clinics*, 2014, 9(1): 37.
- [4] Hang L W, Lin H H, Chiang Y W, et al. *Applied Mathematics & Information Sciences*, 2013, 7(1): 227.
- [5] Chazal P D, Heneghan C, Sheridan E, et al. *Computers in Cardiology*, 2000, 27: 745.
- [6] Mietus J E, Peng C K, Chlvanov P, et al. *Computers in Cardiology*, 2000, 27: 753.
- [7] Zywiets C W, Von E V, Widiger B, et al. *Methods of Information in Medicine*, 2004, 43(1): 56.
- [8] Chazal P D, Heneghan C, Sheridan E, et al. *IEEE Transactions on Biomedical Engineering*, 2003, 50(6): 686.
- [9] TONG Guang-ming, GUO Ji-hong, HAN Fang, et al(佟光明, 郭继鸿, 韩芳, 等). *National Medical Journal of China(中华医学杂志)*, 2006, 86(122): 1545.
- [10] Acharya U R, Chua E C, Faust O, et al. *Physiological Measurement*, 2011, 32(3): 287.
- [11] Khaldon Lweesy, Luay Fraiwa, Natheer Khasawneh, et al. *Journal of Medical Systems*, 2011, 35: 723.
- [12] Kesper K, Canisius S, Penzel T, et al. *Medical & Biological Engineering & Computing*, 2012, 50(2): 135.
- [13] Poupard Laurent, Philippe Carole, Goldman Michael David, et al. *Sleep and Breathing*, 2012, 16(2): 419.
- [14] Ahmet Resit Kavsoglu, Kemal Polat, Mehmet Recep Bozkurt. *Turkish Journal of Electrical Engineering & Computer Sciences*, 2016, 24: 1782.
- [15] Schäfer A, Vagedes J. *International Journal of Cardiology*, 2013, 166(1): 15.
- [16] Bulte C S E, Keet S W M, Boer C, et al. *European Journal of Anaesthesiology*, 2013, 68(7): 775.
- [17] Poh M Z, Swenson N C, Picard R W. *IEEE Transactions Information Technology in Biomedicine*, 2010, 14(3): 786.
- [18] Li Y, Gao H, Ma Y. *Medicine*, 2017, 96(18): e6755.
- [19] LI Jun-feng, WANG Yue-le, HU Sheng, et al(李俊峰, 汪月乐, 胡升, 等). *Spectroscopy and Spectral Analysis(光谱学与光谱分析)*, 2016, 36(10): 3261.

通过依次改变隐层节点数、训练函数以及传递函数等影响网络分类性能的主要参数, 得到优化后的 ECG-SAS 模型的最高训练识别率和测试预测率分别为 77.60% 和 77.67%, 而 PPG-SAS 模型则分别达到 80.30% 与 80.13%。结果表明, PPG-SAS 模型优于 ECG-SAS 模型。由此说明, 进一步深入研究这种简单易行的 PPG-SAS 筛查技术, 具有重要研究意义与广阔应用前景。本工作仅研究了使用原始信号及较为经典的 BP 神经网络建立了分类模型。鉴于信号预处理技术、特征提取和分类算法对输出结果的重要影响, 并且人体与疾病的复杂性与不可预测性又非常适合应用深度学习技术来进行映射, 所以下一步的研究重点将基于深度学习理论设计特征提取及分类方法, 进行 PPG-SAS 模型的优化及准确率的提升, 为 SAS 临床的早期检测、治疗效果评价及预后评估奠定基础。

A Screening Method for Sleep Apnea Syndrome Based on Photoplethysmographic

LI Su-yi¹, JIANG Shan¹, LIU Li-jia¹, XIONG Wen-ji², NI Wei-guang^{1*}

1. College of Instrumentation and Electrical Engineering, Jilin University, Changchun 130061, China

2. The First Clinical Hospital of Jilin University, Changchun 130021, China

Abstract Sleep Apnea Syndrome (SAS) is known as the “sleep killer”. The diagnostic rate is low due to the limitations of the Polysomnography (PSG) diagnostic criteria. Studies have shown that heart rate rhythm changes when apnea occurs, so automatic screening of SAS can be achieved by measuring Electrocardiograph (ECG) signals based on Heart Rate Variability (HRV) analysis. However, the electrodes used in the ECG-SAS method are cumbersome, can easily cause skin allergy, and affect sleeping comfort. Due to Pulse Rate Variability (PRV) analysis being highly correlated with HRV analysis and photoplethysmography (PPG) signals being simpler to acquire than ECG signals, this study proposes using synchronously acquired PPG and ECG signals and applying the same modeling method to compare the recognition ability of the two methods. The benefits for acquiring PPG instead of ECG are that the electrode does not cause skin allergy and is easier to wear so that it has little interference with sleeping comfort. The Back-Propagation (BP) neural network is applied to establish the automatic screening models of PPG-SAS and ECG-SAS, respectively. The 10-fold cross validation method and the Receiver Operating Characteristic (ROC) curves are used to compare and to evaluate the models. The experimental data are from MIT-BIH Polysomnographic Data base that contains 8 248 samples, including 6 227 normal samples. First of all, we established PPG-SAS and ECG-SAS models using a three-layer BP neural network with the default parameters, and compare their classification performances through the 10-fold cross validation method and the ROC curves. And then, we successively adjusted the number of hidden layer nodes, training functions and transfer functions to establish corresponding PPG-SAS and ECG-SAS models, and compare the respective optimal models obtained by using the 10-fold cross validation method. Through the comparisons of the recognition and prediction accuracies and the area of the ROC curves, the results illustrate that the PPG-SAS model is better than the ECG-SAS model when default parameters were applied. By comparing the average classification performances, we obtained the optimal model of PPG-SAS with 50 hidden layer nodes, trained function based on one-step secant method, and transferred function based on hyperbolic tangent sigmoid. The optimal PPG-SAS model has the highest recognition accuracy of 80.30% and prediction accuracy of 80.13%. Similarly but with a different transfer function of radial basis, the optimal ECG-SAS model has the highest recognition accuracy of 77.60% and prediction accuracy of 77.67%. The results showed that the optimal PPG-SAS model is better than the optimal ECG-SAS model. The above experimental results demonstrated that the SAS classification ability by using PPG signals is superior to that by using ECG signals, which proved the feasibility and reliability of the PPG-SAS screening method. Therefore, the PPG-SAS screening method will lay a theoretical foundation on early detection of SAS and improvement of its diagnostic rate.

Keywords Sleep apnea syndrome; PPG; ECG; Neural networks; 10-fold cross-validation

(Received May 16, 2018; accepted Oct. 28, 2018)

* Corresponding author