

Classification of Sleep Apnea with Artificial Intelligence

Shaojie Zhang¹, Huanhuan You¹, Hai Lin², Xiangyu Qian¹, Qingzu He¹, Huan Hu¹, Fuhai Xiong², Yuping Cao³, Jianwei Shuai^{1,4*}

¹Department of Physics, College of Physical Science and Technology, Xiamen University, Xiamen Fujian

²Xiamen Zhonglingyi Youchuang Co. Ltd., Xiamen Fujian

³Mental Health Institute of Central South University and Institute of Mental Health, Hunan Psychiatric Center, National Center for Clinical Medicine of Mental Disorders, Changsha Hunan

⁴National Institute for Data Science in Health and Medicine, Xiamen University, Xiamen Fujian

Email: *jianweishuai@xmu.edu.cn

Received: May 14th, 2020; accepted: May 29th, 2020; published: Jun. 4th, 2020

Abstract

Sleep apnea is a breathing disorder associated with sleep, commonly known as sleep apnea syndrome, which affects about 4% of the general population. It requires professionals to manually analyze the patients' sleep polysomnography recorded in the hospital to diagnose sleep apnea, which is a time-consuming and labor-consuming process. Thus, it is important to develop methods to automatically classify sleep apnea. This paper introduces a variety of artificial intelligence classification methods of sleep apnea, including classification based on statistical rules and classification based on deep learning, and the analysis data can be single channel physiological data and multi-channel sleep data. We compare the classification results of different methods, and point out that the multi task analyses with deep learning algorithms on multi-channel data should be the mainstream of sleep apnea classification in the future.

Keywords

Sleep Apnea, Automatic Classification, Machine Learning, Deep Learning

睡眠呼吸暂停的人工智能分析

张少杰¹, 尤欢欢¹, 林海², 钱镶玉¹, 何情祖¹, 胡 桓¹, 熊富海², 曹玉萍³, 帅建伟^{1,4*}

¹厦门大学, 物理科学与技术学院物理系, 福建 厦门

²厦门中翎易优创科技有限公司, 福建 厦门

³中南大学湘雅二医院精神卫生研究所, 国家精神心理疾病临床医学研究中心, 湖南省精神医学中心, 湖南长沙

⁴厦门大学健康医疗大数据国家研究院, 福建 厦门

Email: *jianweishuai@xmu.edu.cn

*通讯作者。

文章引用: 张少杰, 尤欢欢, 林海, 钱镶玉, 何情祖, 胡桓, 熊富海, 曹玉萍, 帅建伟. 睡眠呼吸暂停的人工智能分析[J]. 生物物理学, 2020, 8(1): 1-17. DOI: 10.12677/biphy.2020.81001

摘要

睡眠呼吸暂停是一种与睡眠相关的呼吸障碍，如果同时引起慢性低氧血症及高碳酸血症，则通常被称为睡眠呼吸暂停综合征。睡眠多导图监测通常被用于睡眠呼吸暂停的判定和确诊，但睡眠多导图人工分析是一项耗时耗力的工作，因此自动判定睡眠呼吸暂停显得尤为重要。本文介绍了睡眠呼吸暂停的各种人工智能分类方法，包括基于统计规则的分类和基于深度学习的分类，而分析的数据可成单通道生理数据和多通道睡眠数据。通过对不同方法的分类结果进行对比讨论，显示基于深度学习对多通道数据进行多任务分析是未来关于睡眠呼吸暂停研究的主流方法。

关键词

睡眠呼吸暂停，自动分类，机器学习，深度学习

Copyright © 2020 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在睡眠相关疾病的研究中，睡眠呼吸暂停居于多数。睡眠呼吸暂停人群通常在夜间会出现打鼾、憋气等症状。患有睡眠呼吸暂停综合征的人在睡觉时会反复停止呼吸，呼吸停止时长通常为 10~30 秒，一晚上可达数百次。睡眠呼吸暂停可由气道的完全“呼吸暂停”或部分“低通气”阻塞引起[1]，这两种情况均可能唤醒沉睡者。频繁的唤醒和无法达到或维持深度睡眠可能导致白天过度困倦并且继发不良影响，最常见的睡眠呼吸暂停症状是白天困倦、易怒、疲倦、注意力不集中和学习能力下降[2]，夜间的症状多为打鼾、呼吸暂停、多汗等[3]，这些症状通常会产生更严重的后果，包括工作场所的社会问题和交通事故。睡眠呼吸暂停还与心绞痛、夜间心律失常、心肌梗死和中风有关。此外，严重的阻塞性睡眠呼吸暂停可能导致日间高血压和严重的心血管健康问题，当睡眠呼吸暂停长期得不到到诊断或治疗不当时，这些并发症可能会导致死亡[4]。

在临床应用中，呼吸暂停低通气指数(Apnea Hypopnea Index, AHI)广泛用于评估睡眠呼吸暂停低通气综合征患者的严重程度。AHI 值超过 5 的对象通常被诊断为睡眠呼吸暂停低通气综合征。AHI 的计算涉及大约 16 个主要生理信号的采集，包括心电图(Electrocardiogram, ECG)、脑电图(Electroencephalogram, EEG)、呼吸用力、气流信号和血氧饱和度等生理信号。通过测量睡眠期间平均每小时呼吸暂停和低通气事件的数量，对采集的信号进行分析以获得呼吸暂停低通气指数[5]。这个过程被称为多导睡眠图(PSG)研究[6]。PSG 监测是一件比较繁琐的工作，医生对其结果的判读工作非常耗时耗力，所以对自动判定睡眠呼吸暂停的研究是临床所必要的。

2. 睡眠呼吸暂停及相关开源数据库数据介绍

2.1. 睡眠呼吸暂停分类发展和标准

睡眠呼吸暂停综合征是一种严重的睡眠类疾病，但是直到上世纪十年代，人们才逐渐重视这种疾病。

早期, 专业人员大多通过柏林问卷、威斯康辛睡眠问卷、Epworth 嗜睡表和打鼾情况来对患者进行睡眠呼吸评估与判定。数字多导睡眠监测技术的诞生使得人们能够更加精确的从相关生理数据上去判定这种疾病。自此, PSG 作为判定睡眠呼吸暂停事件的“金标准”被专业人员广泛使用。

PSG 是一项针对动物和人所形成的睡眠研究的基本手段。自上世纪八十年代以来在睡眠呼吸紊乱如睡眠呼吸暂停、睡眠片段化、微觉醒、睡眠分期等睡眠相关疾病的判定上被大量使用。PSG 的监测指标较多, 一般包括 EEG、眼电图、下颌肌电图、心电图双下肢肌电图、呼吸气流及呼吸运动、鼾声检测、血氧饱和度、体动等生理数据。

AHI 是指每小时呼吸暂停和低通气的次数。此项指标通常用于诊断睡眠呼吸暂停和判定其严重程度。呼吸暂停的定义相对标准—气流消失或者接近消失的时间不小于 10 秒。但是低通气有不同的定义方法, 早期关于呼吸暂停的研究只是针对阻塞性呼吸暂停。然而人们很快发现气流减弱也就是低通气, 且同样具有临床意义。Block [7]等人指出了低通气的重要性, 并将其定义为气流减弱并伴随不小于 4% 的氧饱和度和下降。Gloud [8]等注意到, 一些符合睡眠呼吸暂停综合征的临床表现的患者, 其主要的呼吸事件不是呼吸暂停而是低通气。

为了规范呼吸事件判定, 1992 年发布了一个共识(芝加哥标准)。标准以阻塞性呼吸暂停/低通气事件表示, 未将阻塞性呼吸暂停和低通气事件加以区分, 理由是这两个事件具有相似的病理生理机制。通常情况下, 睡眠呼吸暂停主要分为 4 个类型: 中枢性呼吸暂停(centralapnea)、阻塞性呼吸暂停(obstructiveapnea)、混合型呼吸暂停(mixedapnea)及低通气(hypopnea)。低通气与睡眠呼吸暂停最初在医院的认定中是分别判定的, 但是经过实验证明低通气对身体的损害和呼吸暂停一样严重, 故将低通气也纳入了睡眠呼吸暂停低通气指数这一判断指标中。图 1 是睡眠呼吸暂停的分类。

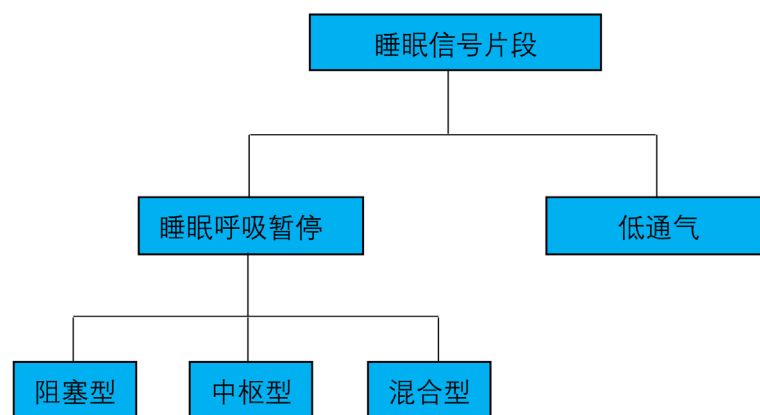


Figure 1. Category of apnea

图 1. 睡眠呼吸暂停类别

成人不同种类的睡眠呼吸暂停判定规则[9]如下表 1 所示。

现阶段, 针对睡眠障碍患者的睡眠呼吸暂停的分类和判定都是依据相关专家的经验来区分的, 其中会受到个体差异等多方面主观因素或者客观条件的影响。虽然现在的 PSG 监测系统具有自动睡眠呼吸暂停判定功能, 但是存在准确度不高、覆盖率不好等问题。针对这些问题, 研究人员做了很多相关的研究, 研究方法主要分为两个类, 一类是基于传统的统计规则方法, 另外一类是基于深度学习的方法。

本文将分别对使用这两类方法进行睡眠呼吸暂停自动判定的相关文献进行综述。所介绍的文章当中, 有一些是基于开源数据库, 另外一些则是自建的数据集, 所以文章中提到的各项指标不具有横向比较的价值, 仅作参考。

Table 1. Criteria for determination of sleep apnea**表 1.** 睡眠呼吸暂停判定标准

呼吸暂停	<p>满足以下全部条件时, 判读为呼吸暂停:</p> <ol style="list-style-type: none"> 1) 口鼻温度传感器(替代传感器)气流较基线水平下降不小于 90%。 2) 持续时间不小于 10 s。 3) 至少 90%时间持续时间内必须符合呼吸暂停的波幅降低标准。 <p>具体分型:</p> <ol style="list-style-type: none"> 1) 阻塞型: 睡眠呼吸暂停持续时间内存在吸气努力。 2) 中枢型: 睡眠呼吸暂停期间无吸气努力。 3) 混合型: 呼吸事件起始部分无吸气努力, 后半部分出现吸气努力(判定呼吸暂停不需要氧饱和度降低)
低通气	<p>满足以下条件可以判定为低通气:</p> <ol style="list-style-type: none"> 1) NP 曲线(替代传感器)较基线波幅下降不小于 30%。 2) 持续时间大于 10 s。 3) 持续时间内至少 90%以上的事件符合低通气的波幅降低标准。 4) 动脉血氧饱和度较呼吸事件基线水平降低不小于 4%。

2.2. 开源数据库介绍

在睡眠呼吸暂停自动判定的研究领域中, 数据是非常重要的, 目前在文献中所用到的最多的开源数据库有以下几种:

1) Physionet Apnea-ECG Database [10]: 该数据是在 2000 年心脏病学计算会议(CINC)和 PhysioNet 联合进行的一项竞赛中首次公开的。目的是评估 ECG 是否能在记录的每一分钟内检测到呼吸暂停。该数据集包含以 100 Hz 采样的 70 个导联 ECG 信号, 长度在 7 到 10 小时之间。每个 ECG 信号由专家使用呼吸和血氧饱和度等附加信号逐分钟手动注释睡眠呼吸暂停和正常呼吸事件。遗憾的是, 注释中没有指出低通气和呼吸暂停之间的区别。数据详细信息可以在 <https://www.physionet.org/> 中查找。

2) Sleep Heart Health Study (SHHS)数据库: 该数据库中包含了各种不同的关于睡眠健康的数据, 包括觉醒、睡眠呼吸障碍等相关的数据。在 <http://www.jhucc.com/shhs> 中可以查找该数据库中的详细情况。

3) Vincent's University Hospital/University College Dublin Sleep Apnea Database (UCD database) (文森特大学医院/都柏林大学学院睡眠呼吸暂停数据库(UCD 数据库)): 该数据库中记录了 25 名(21 名男性和 4 名女性)睡眠呼吸障碍疑似病例的整夜 PSG 记录。每个记录包含 5.9 至 7.7 小时的 ECG 和 SaO₂ 信号, 并且数据库中给出了详细记录每个呼吸暂停/低通气事件的开始时间和持续时间的注释文件。在 <http://bigd.big.ac.cn/databasecommons/database/id/5216> 中可以查找到该数据库的详细信息。

4) Physionet2018 竞赛数据库[11]: 该数据库主要是针对非呼吸相关的睡眠期间的觉醒判定所创建的。数据中也包含了和睡眠呼吸相关的一些标签, 故可以用来做睡眠呼吸相关的一些研究。该数据集包括 1985 名受试者的 13 个通道的 PSG 数据, 这些数据在 MGH 睡眠实验室进行监测, 以诊断睡眠障碍。该数据集集中的每个记录都包括多个生理信号, 这些信号都以 200 Hz 的频率采样, 并由 MGH 睡眠实验室的认证睡眠技术人员根据 AASM 指南手动评分。可以在 <https://physionet.org/content/challenge-2018/> 中查找到数据库的详细信息。

3. 基于统计规则的睡眠呼吸暂停自动判定的研究

人在睡眠中有很多生理信号, 其中包含了能够用来判定睡眠呼吸暂停的生理特征。为了开发出一个简单的自动判定睡眠呼吸暂停的模型, 近几十年来, 人们提出了各种不同的方法来自动区分睡眠呼吸暂停和正常呼吸事件。并且尽可能减少检测睡眠呼吸暂停所需的生物信号数量。这些研究大多是基于心电图(ECG)信号[12] [13]、SaO₂ [14] [15]、呼吸[16]和打鼾[17] [18]信号。在多数的研究中侧重于从生理信号中提取时域、频域和非线性特征等作为特征, 并通过特征选择来减少特征空间的维数。通常情况下, 这些研究都是

基于传统的机器学习,使用的方法包括多层感知机(Multi-layer Perceptron, MLP) [14]、支持向量机(Support Vector Machine, SVM) [17]、人工神经网络(Artificial Neural Network, ANN) [19]、模糊逻辑[20]、线性判别分析(linear discriminant analysis, LDA) [21]、AdaBoost [22]等分类器。由于文献中大多使用的生理信号为心电图(ECG)。所以,本文对基于统计规则的研究按照 ECG 信号和其它相关生理信号分为两个部分介绍。

3.1. 基于 ECG 信号的自动判定

Moody [23]等通过研究提出了一种数据处理方法,它能够从普通的心电图中提取心电衍生呼吸信号(EDR),从而能够依据 ECG 来判定睡眠呼吸暂停。为通过 ECG 信号判定睡眠呼吸暂停提供了一个新的思路。Khandoker [24]等利用小波分解从心率变异性(HRV)和心电图衍生呼吸(EDR)中提取出相应的特征作为 SVM 的输入以进行睡眠呼吸暂停综合征的判定,并且取得了比较不错的效果,但该研究只是针对患者进行分类,没有针对具体的呼吸事件进行判定。Chen [25]利用同样的 SVM 方法对患者进行分类,但他选择了一种新的中值滤波方法进行数据预处理,这种方法能够有效的减少个体效应和随机噪声,最终在针对患者的严重程度取得的结果为:准确率 92.87%,特异性 98.99%,敏感性 97.41%。

相较于直接针对患者的分类,更多的研究是针对数据片段进行分类。Bsoul [26]等使用了支持向量机(SVM)对从 1 分钟长度的数据片段中经小波变换和傅里叶变换所得到的相关特征进行呼吸事件的判定。通过对不同核函数的 SVM 的对比得出使用 RBF 核时能够取得的最佳结果为:准确率 89%,特异性 85%,敏感性 96%。Yildiza [13]等使用离散小波变换和快速傅里叶变换(FFT)从 HRV 和 EDR 得到实验所需要的 4~8 个相关特征,再经由线性核的 SVM 进行分类可以达到 86.7%的准确率,80%的特异性及 90%的敏感性,该文还对 30 人进行测试验证,结果显示能将所有被试正确分类为呼吸暂停患者和正常人。Maier [27]等在自建数据集上通过递归分析达到了 77.5%的准确率、敏感性和特异性。Varon [28]等使用 RBF 核的 SVM 作为分类器在每分钟事件上实现了 85%的准确率,同时提出了两个新特征:第一个是 QRS 的主要成分分析,它描述了在呼吸暂停期间由于交感神经活动增加而引起的形态变化;第二个特征是使用正交子空间投影提取的呼吸和心率信息。

虽然不少文献均使用支持向量机作为分类器,但是其他的机器学习模型在睡眠呼吸暂停判定方面也有较好的效果。Khandoker [19]等利用前馈神经网络对 5 s 的事件片段进行分类,在测试集上对正常和睡眠呼吸事件的分类准确率高达 98%,此外还对低通气和呼吸暂停进行了区分,准确率达到 96%。其整个实验的流程如图 2 所示。在正常呼吸事件和呼吸暂停事件判定中所采用的特征包括均值、香农熵[29]、方差、偏度等总计 45 个特征。而在针对呼吸暂停和低通气的分类中选择了小波近似值、方差、香农熵值作为特征输入到模型中。从流程图中我们可以看到与其他文献不同之处在于,该文献作者选取了不同的特征针对呼吸暂停和低通气进行分类。虽然低通气和呼吸暂停对健康的危害是类似的,但细致的区分有利于医生能够更清楚地掌握患者的情况。

Mendez [30]等利用 K 近邻(KNN)和神经网络(NN)两种分类器来对正常呼吸事件和呼吸暂停事件进行分类,其中 KNN 算法的准确率为 88%、灵敏性为 85%、特异性为 90%,NN 的准确率为 88%、灵敏性为 89%、特异性为 86%。Nguyen [31]等通过心率变异数据的递归量化分析(Recurrence Quantification Analysis, RQA) 统计量来测量心率复杂性进而提取出相关特征输入到 NN 和 SVM 中进行呼吸暂停和正常呼吸的分类,经过训练最终结果分别为:NN 的准确率 83.23%,特异性 79.09%、敏感性 85.57%;SVM 的准确率 84.14%、特异性 65.88%、灵敏性 93.72%。Kesper [32]等搭建了一个自动分析模块的基本框架,仅基于单通道心电图即可获得睡眠呼吸障碍和睡眠相关疾病的诊断信息。在睡眠呼吸暂停的判定中准确率达到 80.5%,在对睡眠分期的分类中准确率只有 57.7%。虽然两者的准确率都达不到临床要求,但是文中使用单通道的 ECG 信号进行多种类型的睡眠相关疾病的判定的思想值得借鉴。

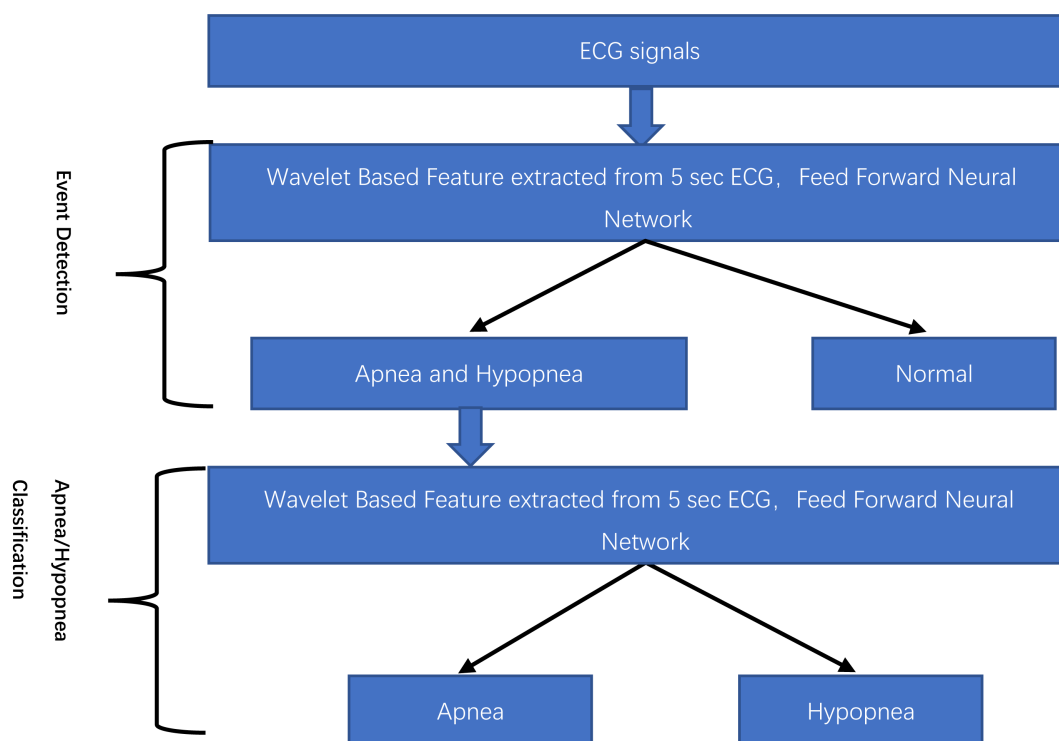


Figure 2. Task flow chart
图 2. 任务流程图

Hassan [33]等首次将极限学习机(Extreme Learning Machine, ELM)应用于睡眠呼吸暂停自动检测中,他们提出了一种基于经验模式分解(Empirical mode Decomposition, EMD)特征和 ELM 的 OSA 自动检测算法。其准确率也达到了 83.77%。并在后续文献中 Hassan 还对比了包括随机森林、AdaBoost、Bagging 等融合模型,发现 Bagging 能够取得最好的结果,准确率达到 85.97% [34]。Babaeizadeh [35]等人用二次分类器在仅使用两个特征的情况下取得了 84.7%的准确率。

3.2. 基于呼吸、 SaO_2 等生理数据的分类

上述介绍的是使用 ECG 数据的睡眠呼吸暂停分类,同时,睡眠呼吸暂停与其他生理信号也具有较强的相关性。有不少研究是基于血氧饱和度、呼吸信号等相关生理信号来进行睡眠呼吸暂停判定的。

Marcosa [36]等人利用血氧饱和度信号的频谱和非线性特征作为输入,对比了 LDA、KNN 和 LR 的分类效果,最终发现 LDA 分类器具有最佳的诊断能力,准确率为 87.6%、敏感性为 91.05%、特异性为 82.61%。Hornero [37]等使用动脉血氧饱和度(SaO_2)数据中提取出来的近似熵作为特征输入来对患者进行分类,用测试数据集对该方法进行了前瞻性评估,获得了 82.09%的敏感性和 86.96%的特异性。Álvarez [38]等利用夜间血氧饱和度的非线性分析来进行睡眠呼吸暂停的诊断,其中集中趋势测量(CTM)的敏感性为 90.1%、特异性为 82.9%,Lempel-Ziv (LZ)复杂度的敏感性为 86.5%、特异性为 77.6%。

Haitham [22]等充分利用了呼吸信号这一生理数据,通过从呼吸努力信号的相位和幅度中提取特征,并与 HRV 和氧饱和度信号的其他特征进行比较和结合,来评估呼吸努力信号的整体正常期和呼吸暂停期的分类,在针对每分钟的事件进行分类时准确率为 82.4%、敏感性 69.9%、特异性 91.4%,在针对个人进行睡眠呼吸暂停综合征的分类时准确率达到 95%。

Kaimakami [39]等从鼻插管气流、胸廓气流、血氧饱和信号中提取出来三个非线性指标:最大喇布拉

斯指数、非趋势波动分析和近似熵,在使用 C4.5 作为分类器时对正常受试者和呼吸暂停患者的区分正确率达 84.9%,进一步对患者的严重程度区分时,准确率为 74.2%。Xie [40]等基于心电图和血氧饱和度生理信号,实现了单独检测和联合监测,并在分类实验中使用了十几种机器学习模型,分类器组合使用 Adaboost 和决策树。在基于 25 个患者的检测中达到 82%左右的灵敏度、特异性和准确性。

葛晓丽[41]等通过对睡眠时期的 SaO₂ 和 HRV 进行实时分析,探究了其在睡眠呼吸暂停判定上的可行性。通过实验发现,患者发生呼吸暂停时,SaO₂ 和心率会出现周期性变化趋势。但与心率相比,SaO₂ 对呼吸暂停时长的变化更为敏感且规律。

除了针对成人研究外,儿童呼吸暂停研究也很重要。代长敏[42]等评估了脉搏传导时间(PTT)提取婴幼儿睡眠相关特征潜力和血压追踪能力,并讨论了现有 PTT 存在的一些局限性。Cohena [43]在自建儿童数据集中提取了血氧数据的均值、最小值、平均绝对变化率等特征,使用线性分类器得到的准确率为 66.7%、特异性 67%、灵敏性 58.1%。虽然最终的结果尚未达到临床要求,但该文献是为数不多针对儿童睡眠呼吸暂停自动判定的研究。

3.3. 不同机器学习模型的表现

总的来说,基于统计规则的睡眠呼吸暂停的自动判定需要经过数据处理、特征提取和分类器 3 个步骤。数据处理一般包括数据截取、中值滤波等。特征提取一般都是将 ECG 信号转换成心率变异率和心电图衍生呼吸信号之后直接提取相关特征,或者用快速傅里叶变换、EMD 和小波分析进行进一步的特征提取。分类器选择大多是基于传统的机器学习模型,SVM、KNN、NN、LR 和随机森林、bagging、Adaboost 等融合模型。表 2 列出具有代表性的基于统计规则的文献简介和表现。

Table 2. Performance of model based on statistical rules

表 2. 基于统计规则的模型表现

文章	数据集	方法	Acc (%)	Sen (%)	Spe (%)
[24]	Apnea-ECG(ECG)	SVM	70	80	50
[40]	UCD 数据库(ECG+SaO ₂)	多种机器学习方法	77.74	69.82	80.29
[27]	38 例自建医院数据集(ECG)	递归分析	76.70	66.80	73.80
[33]	Apnea-ECG(ECG)	ELM	83.77	-	-
[34]	Apnea-ECG(ECG)	Bagging	85.97	-	-
[28]	Apnea-ECG(ECG)	SVM	84.74	84.71	84.69
[36]	自建 187 人数据集(呼吸+SaO ₂)	QD、LDA、KNN、Logistic	87.61	91.05	82.61
[30]	Apnea-ECG(ECG)	KNN、NN	88	86	89
[43]	自建儿童数据集(儿童 SaO ₂)	线性分类器	66	67	58.1

支持向量机(SVM)是在该领域使用最为广泛的机器学习模型,相较于递归分析、LR、LDA 等模型往往能取得更好的效果,但在相同的数据情况下,Mendez 在文章中使用神经网络(NN)和 KNN 能取得更好的结果,表明所用到的特征比较具有借鉴意义。在使用多个生理数据作为判定依据时,模型的敏感性会更高。

4. 基于深度学习的睡眠呼吸自动判定

在深度学习得以实际应用之前,睡眠呼吸暂停的检测领域,如家庭检测阻塞性睡眠呼吸暂停(OSA) [44]的分析设备,基于呼吸和氧测量信号[44]的分类方法,便携式监测分类系统[45]等检测和治疗方法均

已有一定的研究。随着深度学习技术理论的极大发展[46] [47], 近年的研究成果显示, 使用神经网络比传统的机器学习在很多领域有显著的精度改进。而且随着计算机计算能力的加强以及 GPU 技术的出现, 越来越多的深度学习项目取得了令人欣喜的成果[48] [49]。在生物医学领域如睡眠分期[50] [51]、微觉醒[52] [53] [54]、睡眠呼吸暂停等方面, 各种不同的神经网络也都取得了较高的分类准确率。由于睡眠数据具有非平稳、非线性的特点, 传统的机器学习方法需要研究人员花费大量的精力去进行特征提取, 而神经网络能够很好地解决此类问题, 因而越来越多的研究者将神经网络技术应用于睡眠呼吸暂停的自动判定任务中。本节中根据研究人员所使用的网络结构不同分别介绍了基于卷积神经网络(CNN)、循环神经网络(RNN)和混合神经网络在呼吸暂停识别领域的研究成果。

4.1. 基于卷积神经网络的判定

卷积神经网络(CNN)是目前最常用的一种神经网络模型之一。通常由四种不同类型的层组成:输入层、卷积层、池化层、分类层(通常是带有 softmax 函数的全连接层)。还有批量标准化(BN)和 dropout 层也可以添加到卷积神经网络中。通常情况下, CNN 是用来对图像进行分类的, 但近年来有研究[55] [56] [57] [58] [59]采用一维 CNN (CNN1D)网络进行信号分类也取得了很好的效果。Haidar 等[59]使用三个数据通道一维信号, 创建了具有三个通道输入的一维卷积神经网络。还有研究[60] [61]将一维信号转换为二维输入特征图, 直接利用二维 CNN (CNN2D)网络来进行训练。

Urtnasan [57]等使用 CNN1D (训练集有 63 名受试者, 测试集有 19 名受试者)分析了单导联心电图(ECG)的信号。该信号被分割成 10 s 的数据片段, 每个数据片段有 2000 个采样点, 并且每个片段对应了相应的呼吸事件。网络由不同大小的卷积和池化层组成, 然后经过 dropout。文中研究了 7 个 CNN 模型, 它们的层数从 3 层到 9 层不等。以分类准确率作为参考标准, 实验发现六层 CNN 获得了最高的准确率(96%)。Urtnasan 等[56]也使用 CNN1D 进行多个种类分类(正常、呼吸暂停和低通气)。该网络的输入为 10 s 长的 ECG 信号数据, 包含 2000 个样本点。网络结构包括批处理标准化(BN)、一维卷积(conv1D)、最大池(Maxpool)、dropout 和全连接层。六层 CNN 的准确率达到 90.8%。显示出卷积神经网络在 ECG 信号上的优良性能。

Haidar 等[59]探究了基于鼻气流分析的二元分类(呼吸暂停或正常)。该网络由 3 个卷积层组成, 每个卷积层有 30 个过滤器, 每个过滤器的内核大小为 $5 * 1$, 步长为 5, 每个步长后面是一个最大池化层, 最大池化层为核大小为 2, 在网络最后有一个输出为 2 的全连接层。每个类有两个输出节点(正常或呼吸暂停)。该模型的平均准确率达到 75%。此后, Haider 等还测试了三个输入信号的 CNN1D, 信号包括口鼻气流、腹部和胸部运动信号, 通过数据组合, 分别测试了单通道, 双通道和三通道的数据作为输入时的模型结果。结果显示, 三信号通道模型的性能优于单信号通道和双信号通道模型, 平均精度为 83.5%。

用连续小波变换(CWT)和解析小波变换计算出的鼻气流信号的频谱图作为输入, McCloskey 等[61]利用 CNN2D 搭建了自动判定呼吸事件的模型。该模型结构如图 3 所示。该网络有两个卷积层, 激活函数选择 ReLU 函数, 最大池化步长为 2, 模型的最后一层为全连接层, 分类函数使用 softmax。其中三个输出节点代表三个类(正常、呼吸暂停和低通气)。该模型的平均准确率达到 79.8%。Chen 等[60]使用 CNN2D 来进行研究, 在实验中采取交叉验证。该实验有三个输入信号(血氧饱和度、口鼻气流、胸腔和腹部运动), 并附带有一秒注释。该网络由两个卷积层、两个池化层和一个连接到三个节点的输出层的全连接层组成。多类分类的总体准确率为 79.61%。

王佳珺[62]利用卷积神经网络对不同呼吸暂停情况下的鼾声进行了分类, 其识别准确率达到 89%。贺冲[63]通过对鼾声数据进行转换得到梅尔频谱图作为二维卷积神经网络的输入, 得到的最好结果的准确率为 89.1%。

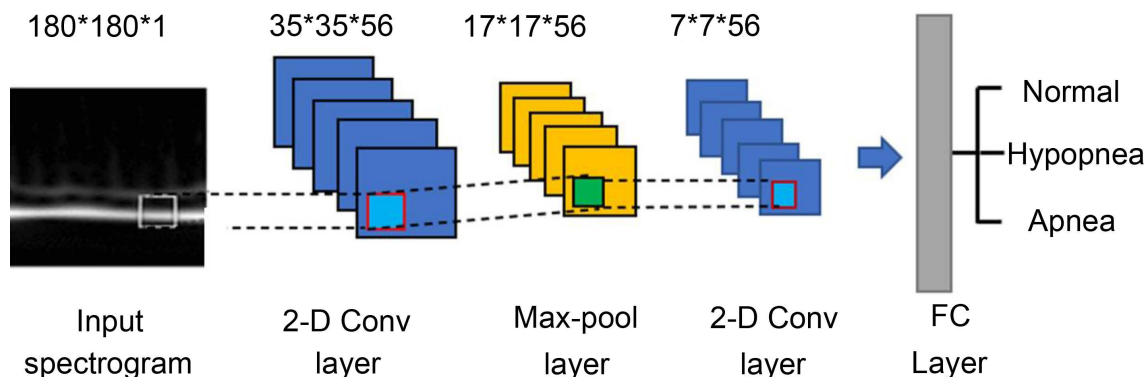


Figure 3. Convolutional neural network
图 3. 卷积神经网络

4.2. 基于循环神经网络的判定

RNN 是具有循环连接的神经网络，其中隐藏节点输出 h_t 的中间值根据前一个单位 h_{t-1} 和当前输入 x_t 进行更新[64]。基本上在论文中使用最多的是 RNN 的两种变体—长短时记忆(LSTM)和门控递归单元(GRU)。图 4 中展示了 LSTM 和 GRU 的结构以及内部流程图。




Figure 4. The structure of LSTM and GRU
图 4. LSTM 和 GRU 结构

Steenkiste 等[65]分析了利用胸部生物阻抗(bioZ)作为呼吸替代物的潜力。提出了一种基于双向长短时记忆(LSTM)深度学习算法的便携式事件检测装置。该装置使用设备的同步录音和传统的多导睡眠描记术对 25 例患者进行了基准测试。结果表明，仅使用 bioZ，可获得 46.9%的精确，与多导睡眠描记呼吸通道自动评分相当，其敏感性为 58.4%、特异性 76.2%、准确率 72.8%。

Kang 等[66]提出了一种基于长短时记忆(LSTM)的多类睡眠呼吸暂停/低通气事件分类的新方法，该方法使用光容积描记法(PPG)信号。三层 LSTM 模型采用批处理-归一化和 dropout 对正常、呼吸暂停、低通气等多类事件进行分类。通过对 82 例睡眠呼吸暂停患者 7 小时的夜间 PSG 描记术测量 PPG 信号，并将

其用于模拟训练和评估。对 63 例患者的训练集和 13 例患者的测试集评价了该方法的性能。结果表明, LSTM 模型对正常患者的阳性预测值为 94.16%, 对呼吸暂停患者的阳性预测值为 81.38%, 对低通气患者的阳性预测值为 97.92%; 对正常的敏感性为 86.03%, 对呼吸暂停的敏感性为 91.24%, 对低通气事件的敏感性为 99.38%。

Cheng 等[67]采用四层 LSTM 检测 OSA, 20 名受试者用于训练, 10 名受试者用于测试, 并使用 RR-ECG 信号。该网络由一个递归层和一个数据归一层组成, 重复四次, 然后是一个 softmax 层, 平均准确率为 97.80%。

Urtnasan 等[68]采用归一化心电信号作为输入(74 例用于训练, 18 例用于测试), 分别测试了 6 层 LSTM 和 GRU 的效果。LSTM 和 GRU 的准确率分别为 98.0%和 99.0%。

4.3. 基于混合模型的判定

虽然卷积神经网络和循环神经网络都具有很强的功能, 并且在呼吸事件判定的领域取得了不错的结果, 文献显示, 混合神经网络继承了两者的优点, 可能效果更好。

Biswal [69]等使用气流、 SaO_2 、胸腹部、传送带信号来评估联合使用的深度循环和卷积神经网络(RCNN)的性能。采用 90%数据用于训练, 10%数据用于测试的方法。使用波形表示和频谱图作为神经网络的输入, 并结合 CNN 和 RNN (RCNN)。使用频谱图作为输入的 RCNN 获得最高准确率为 88.2%。

Banluesombatkul [70]等提出了一种不同的模型结构, 通过结合 CNN1D, LSTM 来检测睡眠呼吸暂停, 输入数据是 15 秒从整晚睡眠数据中截取的数据片段, 使用 10 倍交叉验证方法。其中每个卷积层之后是一个批处理的归一化层, ReLU 作为激活函数。然后将 LSTM (分别为 128、128 和 64 个单元)和周期性的 dropout (0.4)进行叠加以提取时间信息。在网络的末端, 一个具有全连通的层由大小为 128、64、32、16、8 和 4 个隐藏节点的层组成, 然后用一个 SoftMax 函数进行分类。在针对睡眠呼吸暂停患者的严重程度分类中达到 79.45%的敏感性、特异性和准确率。

Pourbabae [71]等运用 DCRNN 混合模型通过 12 通道 PSG 数据实现了多任务的睡眠相关任务的分类, 包括睡眠呼吸判断、睡眠分期和微觉醒判定。在睡眠呼吸暂停综合征判断的任务中, 平均 AUPRC 达到 0.783, AUROC 达到 0.965。并且在模型中针对睡眠呼吸暂停/低通气综合征的严重程度给出判定。相比于其他研究, 该文献主要针对微觉醒的一个竞赛写的, 但是其主要优势在于采用了混合通道的混合模型针对混合任务进行了一系列的研究, 其模型结构如图 5 所示。在该模型中, 输出维度为 4, 经过不同的排列组合后可以对微觉醒/正常、睡眠分期、睡眠呼吸暂停等进行多任务分析。

除了使用生理数据之外, 基于深度学习的相关问题研究还包括用人脸识别和数据增强的方法。Jayatilaka [72]等提出了一种新的基于视频处理的睡眠呼吸暂停检测算法。该解决方案系非接触式, 精确度高、重量轻, 足以在单板计算机上运行。

Nikolaidis [73]等设计了一个递归生成对抗网络, 以生成真实的合成数据并扩充原始数据集。基于严重不平衡的数据集生成平衡数据集, 这些解决方案被应用于睡眠呼吸暂停检测, 并对 K-近邻、随机森林、多层感知器和支撑向量机四种著名技术的性能进行了评估。结果表明, 针对不同的分类器数据增强后都能取得较好的效果, 卡帕统计量增加在 0.0072 到 0.00182 之间。表明深度学习在处理生物医学领域数据不平衡问题的可行性。

4.4. 不同深度学习模型的表现

总的来说, 基于深度学习的睡眠呼吸暂停的研究方法更是多种多样, 并且取得了较好的效果。表 3 显示了部分深度学习相关研究的模型及其表现。

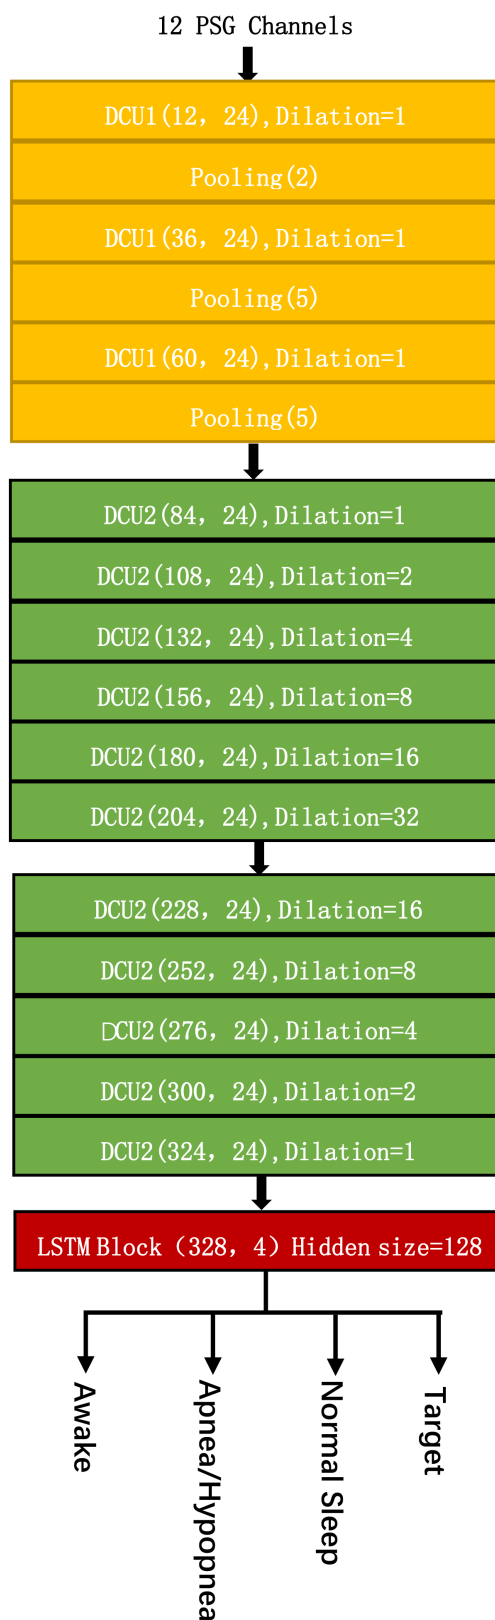


Figure 5. The structure of SleepNet

图 5. SleepNet 网络结构图

Table 3. Staging model representation based on deep learning
表 3. 基于深度学习的模型的表现

文章	数据集	模型方法	ACC(%)	Sen(%)	Spe(%)
[57]	86 位自建数据集(ECG)	CNN1D	90.8	87	87
[55]	自建数据集	CNN1D	98.9	97.8	99.2
[58]	179 份自建数据集(鼻压力)	CNN1D	96.6	81.1	98.5
[61]	157 份自建数据集	CNN2D	79.8	79.7	—
[60]	UCD 数据库(SaO ₂ +口鼻气流+胸腹腔运动)	CNN2D	79.6	—	—
[67]	自建数据集(ECG)	LSTM	97	—	—
[68]	92 名自建数据集(ECG)	LSTM	98.5	98	98
[68]	92 名自建数据集(ECG)	GRU	99	99	99
[70]	MrOS 睡眠数据库	CNN1D+LSTM	79.5	77.6	80.1
[69]	10000 份自建数据(多通道 PSG 数据)	RCNN	88.2	—	—
[71]	Physionet2018 竞赛数据库(多通道 PSG 数据)	DCRNN	78.3	—	—

由于深度学习模型的优良特性, 在基于深度神经网络的睡眠呼吸暂停判定的研究中, 针对数据的处理很少, 基本上可以实现端到端的事件判定, 相较于传统的基于统计规则的方法来说比较方便, 也具备更广阔的使用前景。在使用二维卷积时, 一般是提取相关生理信号的频谱作为模型的输入。但是, 从不同文献的对比可以发现, 基于深度学习的文献大多是使用自建数据集, 后续的研究人员很难复现其工作。并且多数文章并没有对其代码进行开源。大数据集上得到的结果反而不如小数据集所得到的结果。这表明在小数据集中数据标注可能更准确, 不同类型呼吸事件之间的差别比较明显。但是越大的数据集越贴合实际, 具有更高的研究价值。

5. 总结和展望

本文综述了近年自动睡眠呼吸暂停判定的研究, 包括基于传统机器学习和目前主流的深度学习的研究。

在早期的自动判定睡眠呼吸暂停的研究中, 不少文献中已经提出了各种方法来解决该问题, 其中大多数包括两个步骤: 手工制作一组相关特性; 开发合适的分类器, 进而提供自动诊断。这些研究采用了 k 近邻(k-nearest neighbor, KNN)、支持向量机(SVM)、模糊逻辑、神经网络、线性判别分析(LDA)等分类器。虽然这些研究具有较高的准确率、特异性和灵敏度, 但这些方法有两个主要问题: 一是无限组合的特征集合, 通常文中都会提到很多相关的特征来进行分类, 但是这些特征并不是全部都能起到作用。使用适当的特征选择方法可以缓解这个问题, 文献中已经提出了多种算法如统计估计、最小冗余最大关联、顺序正向选择(SFS)、主成分分析(PCA)以及遗传算法(GA)。第二个问题是需要特定领域有相当多的知识来创建相关的特征提取算法和模型。

这两个问题可以通过使用深度神经网络来解决。深度神经网络通过从传感器的输入信号中寻找某种模式来自动生成特征。并且在很多相关的研究中是直接使用原始数据作为输入直接进行睡眠呼吸事件的分类的, 即不需要再进行繁琐的特征提取。并且深度神经网络的应用能够有效地提升判定准确率。但是现阶段, 这方面的工作也存在着一些不足。第一个是在不同的研究中研究人员所使用的数据不尽相同, 导致了并不能单纯的从文章中得到对比, 难以复现其中的模型。第二个是在使用深度学习来进行睡眠呼吸事件分类的研究尚没有一个很好的可解释性。另外还存在着睡眠数据不够多等问题。

近年的文献可以发现,在自动睡眠呼吸暂停模型的选择上,研究人员越来越倾向于选择深度学习模型来进行该领域的研究。由于深度学习的一些优良特性,未来睡眠呼吸暂停自动判定的研究更多将是一种端到端的基于深度学习为内核的一套判别系统的搭建。同时需要注意的是,模型的搭建上尽量选择开源的数据集进行验证,这样方便后续研究人员进行复现,以提升研究的可靠性。

在研究方向上,对多通道数据进行多任务分析分类将成为一种趋势,由于睡眠呼吸暂停中所用到的 PSG 数据也可以用在其他的睡眠相关的研究中,故单一模型的多任务分类也将是研究热点。另外,在针对睡眠呼吸暂停相关数据过少这个问题上,已经有研究[73]表明对抗生成网络能够有效地提升模型在睡眠呼吸暂停自动判定上的表现。所以未来生理信号上数据增强的研究也至关重要。

针对人体的各种生理信号大数据的分析,将为各种疾病的智能诊断和预测,提供强有力的分析工具。因此,利用人工智能技术,对 PSG 等大数据,进行睡眠状态分期和睡眠呼吸暂停等事件的自动分析,用于睡眠障碍、抑郁症等精神疾病的评估、预测、治疗和康复等各种医学过程,将是该研究下一步的重要发展方向[74][75],有望将在一定程度上提高医护效率,节约医疗资源,并极大缓解精神医学专业资源服务稀缺的状况。

基金项目

本课题获得如下基金项目支持:国家自然科学基金资助项目(批准号:11874310和11675134),湖南省自然科学基金(编号:2018JJ2591)。

参考文献

- [1] AASM (1999) Sleep-Related Breathing Disorders in Adults: Recommendations for Syndrome Definition and Measurement Techniques in Clinical Research. *Sleep*, **22**, 667-689. <https://doi.org/10.1093/sleep/22.5.667>
- [2] White, D.P. (2005) Pathogenesis of Obstructive and Central Sleep Apnea. *American Journal of Respiratory & Critical Care Medicine*, **172**, 1363-1370. <https://doi.org/10.1164/rccm.200412-1631SO>
- [3] 夏俊娣, 杜钟珍. 睡眠呼吸暂停综合征的综述[J]. 临床肺科杂志, 1999(2): 86-88.
- [4] Young, T., Peppard, P.E. and Gottlieb, D.J. (2002) Epidemiology of Obstructive Sleep Apnea: A Population Health Perspective. *American Journal of Respiratory and Critical Care Medicine*, **165**, 1217-1239. <https://doi.org/10.1164/rccm.2109080>
- [5] Malhotra, A. and White, D.P. (2002) Obstructive Sleep Apnea. *The Lancet*, **360**, 237-245. [https://doi.org/10.1016/S0140-6736\(02\)09464-3](https://doi.org/10.1016/S0140-6736(02)09464-3)
- [6] Bloch, K.E. (1997) Polysomnography: A Systematic Review. *Technology Health Care Official Journal of the European Society for Engineering Medicine*, **5**, 285-305. <https://doi.org/10.3233/THC-1997-5403>
- [7] Block, A.J., Boysen, P.G., Wynne, J.W. and Hunt, L.A. (1980) Sleep Apnea, Hypopnea and Oxygen Desaturation in Normal Subjects. *Survey of Anesthesiology*, **24**, 147. <https://doi.org/10.1097/00132586-198006000-00002>
- [8] Gould, G.A., Whyte, K.F., Rhind, G.B., Airlie, M.A., Catterall, J.R., Shapiro, C.M. and Douglas, N.J. (1988) The Sleep Hypopnea Syndrome. *American Review of Respiratory Disease*, **137**, 895. <https://doi.org/10.1164/ajrccm/137.4.895>
- [9] Berry, R.B., Budhiraja, R., et al. (2012) 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. *Journal of Clinical Sleep Medicine*, **8**, 597-619. <https://doi.org/10.5664/jcsm.2172>
- [10] Penzel, T., Moody, G.B., Mark, R.G. and Peter, J.H. (2000) The Apnea-ECG Database. *Computers in Cardiology*, **27**, 255-258. <https://doi.org/10.1109/CIC.2000.898505>
- [11] Ghassemi, M.M., Moody, B.E., Lehman, L.-W.H., Song, C., Li, Q., Sun, H.Q., Westover, M.B. and Clifford, G. (2018) You Snooze, You Win: The PhysioNet/Computing in Cardiology Challenge 2018. *Computing in Cardiology Conference*, Vol. 45, 1-4. <https://doi.org/10.22489/CinC.2018.049>
- [12] Penzel, T., McNames, J., Chazal, P.D., Raymond, B., Murray, A. and Moody, G. (2002) Systematic Comparison of Different Algorithms for Apnoea Detection Based on Electrocardiogram Recordings. *Medical Biological Engineering*

- Computing*, **40**, 402-407. <https://doi.org/10.1007/BF02345072>
- [13] Yildiz, A., Akin, M. and Poyraz, M. (2011) An Expert System for Automated Recognition of Patients with Obstructive Sleep Apnea Using Electrocardiogram Recordings. *Expert Systems with Applications*, **38**, 12880-12890. <https://doi.org/10.1016/j.eswa.2011.04.080>
- [14] Marcos, J.V., Hornero, R., Álvarez, D., Aboy, M. and Campo, F.D. (2012) Automated Prediction of the Apnea-Hypopnea Index from Nocturnal Oximetry Recordings. *IEEE Transactions on Bio-Medical Engineering*, **59**, 141-149. <https://doi.org/10.1109/TBME.2011.2167971>
- [15] Park, J.U., Lee, H.K., Lee, J., Urtnasan, E., Kim, H. and Lee, K.J. (2015) Automatic Classification of Apnea/Hypopnea Events through Sleep/Wake States and Severity of SDB from a Pulse Oximeter. *Physiological Measurement*, **36**, 2009-2025. <https://doi.org/10.1088/0967-3334/36/9/2009>
- [16] Koley, B.L. and Dey, D. (2013) Automatic Detection of Sleep Apnea and Hypopnea Events from Single Channel Measurement of Respiration Signal Employing Ensemble Binary SVM Classifiers. *Measurement*, **46**, 2082-2092. <https://doi.org/10.1016/j.measurement.2013.03.016>
- [17] Solà-Soler, J., Fiz, J.A., Morera, J. and Jane, R. (2012) Multiclass Classification of Subjects with Sleep Apnoea-Hypopnoea Syndrome through Snoring Analysis. *Medical Engineering Physics*, **34**, 1213-1220. <https://doi.org/10.1016/j.medengphy.2011.12.008>
- [18] Erdenebayar, J.L. (2017) Obstructive Sleep Apnea Screening Using a Piezo-Electric Sensor. *Journal of Korean Medical Science*, **32**, 893-899. <https://doi.org/10.3346/jkms.2017.32.6.893>
- [19] Khandoker, A.H., Gubbi, J. and Palaniswami, M. (2009) Automated Scoring of Obstructive Sleep Apnea and Hypopnea Events Using Short-Term Electrocardiogram Recordings. *IEEE Transactions on Information Technology in Biomedicine*, **13**, 1057-1067. <https://doi.org/10.1109/TITB.2009.2031639>
- [20] Alvarez-Estevéz, D. and Moret-Bonillo, V. (2009) Fuzzy Reasoning Used to Detect Apneic Events in the Sleep Apnea-Hypopnea Syndrome. *Expert Systems with Applications*, **36**, 7778-7785. <https://doi.org/10.1016/j.eswa.2008.11.043>
- [21] Mendez, M.O., Corthout, J., Huffel, S.V., Matteucci, M., Penzel, T., Cerutti, S. and Bianchi, A.M. (2010) Automatic Screening of Obstructive Sleep Apnea from the ECG Based on Empirical Mode Decomposition and Wavelet Analysis. *Physiological Measurement*, **31**, 273-289. <https://doi.org/10.1088/0967-3334/31/3/001>
- [22] Al-Angari, H.M. and Sahakian, A.V. (2012) Automated Recognition of Obstructive Sleep Apnea Syndrome Using Support Vector Machine Classifier. *IEEE Transactions on Information Technology in Biomedicine: A Publication of the IEEE Engineering in Medicine Biology Society*, **16**, 463-468. <https://doi.org/10.1109/TITB.2012.2185809>
- [23] Moody, G.B., Mark, R.G., Zoccola, A. and Mantero, S. (1985) Derivation of Respiratory Signals from Multi-Lead ECGs. *Computers in Cardiology*, **12**, 113-116.
- [24] Khandoker, A.H., Palaniswami, M. and Karmakar, C.K. (2009) Support Vector Machines for Automated Recognition of Obstructive Sleep Apnea Syndrome from ECG Recordings. *IEEE Transactions on Information Technology in Biomedicine*, **13**, 37-48. <https://doi.org/10.1109/TITB.2008.2004495>
- [25] Chen, L., Zhang, X. and Wang, H. (2015) An Obstructive Sleep Apnea Detection Approach Using Kernel Density Classification Based on Single-Lead Electrocardiogram. *Journal of Medical Systems*, **39**, 47. <https://doi.org/10.1007/s10916-015-0222-6>
- [26] Bsoul, M., Minn, H. and Tamil, L. (2011) Apnea Med-Assist: Real-Time Sleep Apnea Monitor Using Single-Lead ECG. *IEEE Transactions on Information Technology in Biomedicine*, **15**, 416-427. <https://doi.org/10.1109/TITB.2010.2087386>
- [27] Maier, C. and Dickhaus, H. (2006) Recurrence Analysis of Nocturnal Heart Rate in Sleep Apnea Patients. *Biomedizinische Technik Biomedical Engineering*, **51**, 224-228. <https://doi.org/10.1515/BMT.2006.042>
- [28] Varon, C., Caicedo, A., Testelmans, D., Buyse, B. and Huffel, S.V. (2015) A Novel Algorithm for the Automatic Detection of Sleep Apnea from Single-Lead ECG. *IEEE Transactions on Biomedical Engineering*, **62**, 2269-2278. <https://doi.org/10.1109/TBME.2015.2422378>
- [29] Shannon, C.E. (1948) A Mathematical Theory of Communication. *Bell System Technical Journal*, **27**, 379-423. <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- [30] Mendez, M.O., Bianchi, A.M., Matteucci, M., Cerutti, S. and Penzel, T. (2009) Sleep Apnea Screening by Autoregressive Models from a Single ECG Lead. *IEEE Transactions on Biomedical Engineering*, **56**, 2838-2850. <https://doi.org/10.1109/TBME.2009.2029563>
- [31] Nguyen, H.D., Wilkins, B.A., Cheng, Q. and Benjamin, B.A. (2014) An Online Sleep Apnea Detection Method Based on Recurrence Quantification Analysis. *IEEE Journal of Biomedical and Health Informatics*, **18**, 1285-1293. <https://doi.org/10.1109/JBHI.2013.2292928>

- [32] Kesper, K., Canisius, S. and Penzel, T. (2012) ECG Signal Analysis for the Assessment of Sleep-Disordered Breathing and Sleep Pattern. *Medical & Biological Engineering & Computing*, **50**, 135-144. <https://doi.org/10.1007/s11517-011-0853-9>
- [33] Hassan, A.R. (2015) Automatic Screening of Obstructive Sleep Apnea from Single-Lead Electrocardiogram. *International Conference on Electrical Engineering & Information Communication Technology*, Dhaka, 21-23 May 2015, 1-6. <https://doi.org/10.1109/ICEEICT.2015.7307522>
- [34] Hassan, A.R. and Haque, M.A. (2015) Computer-Aided Obstructive Sleep Apnea Screening from Single-Lead Electrocardiogram Using Statistical and Spectral Features and Bootstrap Aggregating. *Biocybernetics Biomedical Engineering*, **36**, 256-266. <https://doi.org/10.1016/j.bbe.2015.11.003>
- [35] Babaeizadeh, S., White, D.P., Pittman, S.D. and Zhou, S.H. (2010) Automatic Detection and Quantification of Sleep Apnea Using Heart Rate Variability. *Journal of Electrocardiology*, **43**, 535-541. <https://doi.org/10.1016/j.jelectrocard.2010.07.003>
- [36] Marcos, J.V., Hornero, R., Álvarez, D., Campo, F.D. and Zamarron, C. (2009) Assessment of Four Statistical Pattern Recognition Techniques to Assist in Obstructive Sleep Apnoea Diagnosis from Nocturnal Oximetry. *Medical Engineering Physics*, **31**, 971-978. <https://doi.org/10.1016/j.medengphy.2009.05.010>
- [37] Hornero, R., Álvarez, D., Abasolo, D.D., Campo, F.D. and Zamarron, C. (2007) Utility of Approximate Entropy from Overnight Pulse Oximetry Data in the Diagnosis of the Obstructive Sleep Apnea Syndrome. *IEEE Transactions on Biomedical Engineering*, **45**, 107-113. <https://doi.org/10.1109/TBME.2006.883821>
- [38] Álvarez, D., Hornero, R., Abasolo, D., Campo, F.D. and Zamarron, C. (2006) Nonlinear Characteristics of Blood Oxygen Saturation from Nocturnal Oximetry for Obstructive Sleep Apnoea Detection. *Physiological Measurement*, **27**, 399-412. <https://doi.org/10.1088/0967-3334/27/4/006>
- [39] Kaimakamis, E., Bratsas, C., Sichletidis, L., Karvounis, C. and Maglaveras, N. (2009) Screening of Patients with Obstructive Sleep Apnea Syndrome Using C4.5 Algorithm Based on Non Linear Analysis of Respiratory Signals during Sleep. *IEEE Engineering in Medicine and Biology Society*, Minneapolis, 3-6 September 2009, 3465-3469. <https://doi.org/10.1109/IEMBS.2009.5334605>
- [40] Xie, B. and Minn, H. (2012) Real-Time Sleep Apnea Detection by Classifier Combination. *IEEE Transactions on Information Technology in Biomedicine: A Publication of the IEEE Engineering in Medicine Biology Society*, **16**, 469-477. <https://doi.org/10.1109/TITB.2012.2188299>
- [41] 葛晓丽, 邱召运, 索智鹏, 樊晓伟, 修东铭. 睡眠呼吸暂停时间对血氧饱和度和心率的影响[J]. 生物医学工程与临床, 2020.
- [42] 代长敏, 苏军民, 李彦如, 董宇涵. 脉搏波检测小儿阻塞性呼吸睡眠障碍综合征进展[J]. 生物医学工程与临床, 2020.
- [43] Cohen, G. and De, C.P. (2013) Automated Detection of Sleep Apnea in Infants: A Multi-Modal Approach. *Computers in Biology and Medicine*, **63**, 118-123. <https://doi.org/10.1016/j.combiomed.2015.05.007>
- [44] Mendona, F., Mostafa, S.S., Ravelo-García, A.G., Morgado Dias, F. and Penzel, T. (2018) Devices for Home Detection of Obstructive Sleep Apnea: A Review. *Sleep Medicine Reviews*, **41**, 149-160. <https://doi.org/10.1016/j.smr.2018.02.004>
- [45] 荆斌, 张鹏, 李巍, 查玉华, 周双勤, 尚学义. 基于智能算法睡眠呼吸暂停监测系统设计[J]. 中国医学装备, 2011, 8(9): 21-24.
- [46] Bawaskar, N.P. (2014) Analog Implicit Functional Testing Using Supervised Machine Learning. Dissertations and Theses.
- [47] Kurtanovic, Z. and Maalej, W. (2017) Automatically Classifying Functional and Non-Functional Requirements Using Supervised Machine Learning. 2017 *IEEE 25th International Requirements Engineering Conference*, Lisbon, 4-8 September 2017, 490-495. <https://doi.org/10.1109/RE.2017.82>
- [48] Lecun, Y., Bengio, Y. and Hinton, G. (2015) Deep Learning. *Nature*, **521**, 436. <https://doi.org/10.1038/nature14539>
- [49] Koch, H., Jennum, P. and Christensen, J.E. (2017) Automatic Sleep Classification Using Adaptive Segmentation Reveals Increased Number of Sleep Stage Transitions. *Sleep Medicine*, **40**, e66. <https://doi.org/10.1016/j.sleep.2017.11.187>
- [50] 王抒伟, 徐富献, 钱镶钰, 胡桓, 何情祖, 林海, 帅建伟. 应用深度神经网络对多导睡眠图的睡眠分期研究[J]. 生物物理报, 2019, 7(2): 11-25.
- [51] 徐富献, 王抒伟, 钱镶钰, 胡桓, 何情祖, 林海, 帅建伟. 睡眠自动分期方法综述[J]. 生物物理报, 2019, 7(3): 34-48.
- [52] Bahrami Rad, A., Zabihi, M., Zhao, Z., Gabbouj, M., Katsaggelos, A. and Sarkka, S. (2019) Automated Polysomno-

- graphy Analysis for Detection of Non-Apneic and Non-Hypopneic Arousals Using Feature Engineering and a Bidirectional LSTM Network.
- [53] Zabihi, M., Bahrami Rad, A., Kiranyaz, S. and Sarkka, S. (2019) 1D Convolutional Neural Network Models for Sleep Arousal Detection.
- [54] Mousavi, S., Afghah, F. and Acharya, U.R. (2019) SleepEEGNet: Automated Sleep Stage Scoring with Sequence to Sequence Deep Learning Approach. *PLoS ONE*, **14**, e0216456. <https://doi.org/10.1371/journal.pone.0216456>
- [55] Dey, D., Chaudhuri, S. and Munshi, S. (2017) Obstructive Sleep Apnoea Detection Using Convolutional Neural Network Based Deep Learning Framework. *Biomedical Engineering Letters*, **8**, 95-100. <https://doi.org/10.1007/s13534-017-0055-y>
- [56] Erdenebayar, U., Jong-Uk, P. and Kyoung-Joung, L. (2018) Multiclass Classification of Obstructive Sleep Apnea/Hypopnea Based on a Convolutional Neural Network from a Single-Lead Electrocardiogram. *Physiological Measurement*, **39**, Article ID: 065003.
- [57] Urtnasan, E., Park, J.U., Joo, E.Y. and Lee, K.J. (2018) Automated Detection of Obstructive Sleep Apnea Events from a Single-Lead Electrocardiogram Using a Convolutional Neural Network. *Journal of Medical Systems*, **42**, 104. <https://doi.org/10.1007/s10916-018-0963-0>
- [58] Ho, C.S., Heenam, Y., Seok, K.H., Kim, H.B., Kwon, H.B., Oh, S.M., Lee, Y.J. and Park, K.S. (2018) Real-Time Apnea-Hypopnea Event Detection during Sleep by Convolutional Neural Networks. *Computers in Biology and Medicine*, **100**, 123-131.
- [59] Haidar, R., Koprinska, I. and Jeffries, B. (2017) Sleep Apnea Event Detection from Nasal Airflow Using Convolutional Neural Networks. *International Conference on Neural Information Processing*, Guangzhou, 14-18 November 2017, 819-827. https://doi.org/10.1007/978-3-319-70139-4_83
- [60] Cen, L., Yu, Z.L., Kluge, T. and Ser, W. (2018) Automatic System for Obstructive Sleep Apnea Events Detection Using Convolutional Neural Network. *Annual International Conference of the IEEE Engineering in Medicine Biology Society. IEEE Engineering in Medicine Biology Society. Annual Conference*, Honolulu, 18-21 July 2018, 3975-3978. <https://doi.org/10.1109/EMBC.2018.8513363>
- [61] McCloskey, S., Haidar, R., Koprinska, I. and Jeffries, B. (2018) Detecting Hypopnea and Obstructive Apnea Events Using Convolutional Neural Networks on Wavelet Spectrograms of Nasal Airflow. *Proceedings of the Pacific-Asia Conference on Knowledge Discovery and Data Mining (PAKDD)*, Melbourne, 3-6 June 2018, 361-372. https://doi.org/10.1007/978-3-319-93034-3_29
- [62] 王佳珺. 面向鼾声识别的麦克风阵列干扰抑制方法研究[D]: [硕士学位论文]. 南京: 南京理工大学, 2017.
- [63] 贺冲. 基于人工智能的鼾声数据分析方法研究[D]: [硕士学位论文]. 南京: 南京理工大学, 2019.
- [64] Gao, Y. and Glowacka, D. (2016) Deep Gate Recurrent Neural Network. *Asian Conference on Machine Learning*.
- [65] Tom, V.S., Willemijn, G., Deschrijver, D. and Dhaene, T. (2018) Automated Sleep Apnea Detection in Raw Respiratory Signals Using Long Short-Term Memory Neural Networks. *IEEE Journal of Biomedical Health Informatics*, **23**, 2354-2364.
- [66] Kang, C.-H., Erdenebayar, U., Park, J.-U. and Lee, K.J. (2020) Multi-Class Classification of Sleep Apnea/Hypopnea Events Based on Long Short-Term Memory Using a Photoplethysmography Signal. *Journal of Medical Systems*, **44**, 14. <https://doi.org/10.1007/s10916-019-1485-0>
- [67] Cheng, M., Sori, W.J., Feng, J. and Khan, A. (2017) Recurrent Neural Network Based Classification of ECG Signal Features for Obstruction of Sleep Apnea Detection. *IEEE International Conference on Computational Science & Engineering & IEEE International Conference on Embedded & Ubiquitous Computing*, Guangzhou, 21-24 July 2017, 199-202. <https://doi.org/10.1109/CSE-EUC.2017.220>
- [68] Urtnasan, E., Park, J.-U. and Lee, K.-J. (2018) Automatic Detection of Sleep-Disordered Breathing Events Using Recurrent Neural Networks from an Electrocardiogram Signal. *Neural Computing and Applications*, **32**, 4733-4742. <https://doi.org/10.1007/s00521-018-3833-2>
- [69] Biswal, S., Sun, H., Goparaju, B., Westover, M.B., Sun, J. and Bianchi, M.T. (2018) Expert-Level Sleep Scoring with Deep Neural Networks. *Journal of the American Medical Informatics Association*, **25**, 1643-1650. <https://doi.org/10.1093/jamia/ocy131>
- [70] Banluesombatkul, N., Rakthanmanon, T. and Wilaiprasitporn, T. (2018) Single Channel ECG for Obstructive Sleep Apnea Severity Detection Using a Deep Learning Approach. 2018 *IEEE Region 10 Conference*, Jeju, 28-31 October 2018, 2011-2016. <https://doi.org/10.1109/TENCON.2018.8650429>
- [71] Pourbabaee, B., Howe-Patterson, M., Patterson, M. and Benard, F. (2019) SleepNet: Automated Sleep Analysis via Dense Convolutional Neural Network Using Physiological Time Series. *Physiological Measurement*, **40**, Article ID: 084005. <https://doi.org/10.1088/1361-6579/ab3632>

-
- [72] Jayatilaka, G., Weligampola, H., Sritharan, S. and Isuru, N. (2019) Non-Contact Infant Sleep Apnea Detection. *14th Conference on Industrial and Information Systems*, Kandy, 18-20 December 2019, 260-265.
<https://doi.org/10.1109/ICIIS47346.2019.9063269>
- [73] Nikolaidis, K., Kristiansen, S., Goebel, V., Plagemann, T., Liestø, K. and Kankanhalli, M. (2019) Augmenting Physiological Time Series Data: A Case Study for Sleep Apnea Detection.
- [74] 袁钦涓, 洪志令, 王星, 帅建伟, 曹玉萍. 人工智能在精神疾病中的应用与展望[J]. 国际精神病学杂志, 2020(1): 4-7.
- [75] 袁钦涓, 王星, 帅建伟, 林海, 曹玉萍. 基于人工智能技术的抑郁症研究进展[J]. 中国临床心理学杂志, 2020, 28(1): 82-86.