

本文引用格式: 林美娜,郑和裕.基于 CNN 与堆叠 LightGBM 的多模态 OSA 检测方法[J].自动化与信息工程,2022,43(3):25-30.
LIN Meina, ZHENG Heyu. Multimodal OSA detection method based on CNN and stacked LightGBM[J].
Automation & Information Engineering, 2022,43(3):25-30.

基于 CNN 与堆叠 LightGBM 的多模态 OSA 检测方法

林美娜 郑和裕

(广东工业大学, 广东 广州 510006)

摘要: 提出一种基于血氧饱和度和心电图信号的多模态阻塞性睡眠呼吸暂停 (OSA) 检测方法。首先, 提取血氧饱和度和心电图信号的经验特征, 并利用皮尔逊相关系数获得最优特征集; 然后, 利用卷积网络 (CNN) 生成深层特征以挖掘不同模态间的潜在相关性; 最后, 构建堆叠的轻量级梯度提升机 (LightGBM), 以提高分类器检测精度。在公开数据集 Apnea-ECG 上进行四折交叉验证, 平均准确性、敏感性和特异性分别为 96.04%、96.44% 和 96.22%, 相较于决策层融合有较高的分类性能。

关键词: 阻塞性睡眠呼吸暂停; 卷积网络; 轻量级梯度提升机; 血氧; 心电图

中图分类号: TP391

文献标识码: A

文章编号: 1674-2605(2022)03-0005-06

DOI: 10.3969/j.issn.1674-2605.2022.03.005

Multimodal OSA Detection Method Based on CNN and Stacked LightGBM

LIN Meina ZHENG Heyu

(Guangdong University of Technology, Guangzhou 510006, China)

Abstract: A multimodal method of detecting obstructive sleep apnea (OSA) based on oxygen saturation and electrocardiogram signals is proposed. Firstly, the empirical features of blood oxygen saturation and ECG signals are extracted, and the optimal feature set is obtained by using Pearson correlation coefficient; Then, convolution network (CNN) is used to generate deep features to mine the potential correlation between different modes; Finally, a stacked lightweight gradient hoist (LightGBM) is constructed to improve the detection accuracy of the classifier. Four fold cross validation was performed on the public data set apnea ECG. The average accuracy, sensitivity and specificity were 96.04%, 96.44% and 96.22% respectively. Compared with decision-making level fusion, it has higher classification performance.

Keywords: obstructive sleep apnea; convolutional neural networks; light gradient boosting machine; oxygen saturation; electrocardiogram

0 引言

阻塞性睡眠呼吸暂停 (obstructive sleep apnea, OSA) 是一种常见的睡眠障碍^[1], 在睡眠时呼吸气流减少甚至停止数秒^[2]。根据 2019 年柳叶刀呼吸医学杂志报导, 全球 30~69 岁的人群中约有 9.36 亿人患有 OSA^[3]。因此, 及时诊断和治疗 OSA 是必要的。目前, 常用血氧饱和度 (oxygen saturation, SpO₂) 和心电图 (electrocardiogram, ECG) 表征 OSA^[4], 但 SpO₂ 下降

存在延迟^[5], 而 ECG 反应迅速^[6]。采用组合的 SpO₂ 和 ECG 有助于提高 OSA 的检测质量^[7]。

近年来, 许多专家学者提出基于 SpO₂ 和 ECG 信号特征组合的 OSA 检测方法。如, LI 等^[7]和 PUNJABI 等^[8]提取 SpO₂ 和 ECG 信号的 8 个经验特征, 并使用人工神经网络 (artificial neural network, ANN) 进行 OSA 检测。虽然考虑了不同信号的潜在相关性, 但未进行特征选择, 可能存在冗余特性; 此外, 数据集易

受特征分布变化的影响，采用跨被试可减小此影响。

深度学习可得到更优的深层特征而被广泛应用于 OSA 检测。经 MOSTAFA 等^[9]调查，近十年采用深度学习检测 OSA 的论文约有 255 篇。ERDENE-BAYAR 等^[10]分别使用一维和二维卷积网络对 ECG 进行 OSA 检测。VILLAR^[11]评估深度学习的有用性以提高 SpO₂ 在 OSA 的自动检测能力。上述方法虽然可以实现 OSA 检测，但未考虑不同生理信号间的潜在相关性，检测精度受限。

特征生成在提高模型性能上可发挥重要作用^[12]。BASTANI 等^[13]指出基于深度学习和树的方法可以提高特征的表征能力。HE 等^[14]指出轻量级梯度提升机（light gradient boosting machine, LightGBM）可以学习新的特征交互，增强特征表示，可利用其提取经验特征和深度学习生成的特征中更深层次的判别信息。

为更好地挖掘和利用不同生理信号间的潜在相关性，本文提出一种基于卷积网络（convolutional neural networks, CNN）和堆叠 LightGBM 的多模态 OSA 检测方法。SpO₂ 和 ECG 数据进行跨被试划分，利用皮尔逊相关系数 r 获得最优特征集，使用 CNN 生

成更深层的特征，结合最优特征集作为 LightGBM 分类器的输入，用堆叠方法构建 OSA 检测模型。

1 分类网络

1.1 问题描述

数据集 $X = \{(\mathbf{x}_i, y_i)\}_{i=1}^n$ ，其中 $\mathbf{x}_i = \{\mathbf{x}_{1i}, \mathbf{x}_{2i}\}$ 表示第 i 个输入的 SpO₂ 向量 $\mathbf{x}_{1i}$ 和 ECG 向量 $\mathbf{x}_{2i}$ 的集合； $y_i \in \{1, 0\}$ 为 $\mathbf{x}_i$ 对应的标签， $y_i = 1$ 标记为 A 的正样本标签， $y_i = 0$ 标记为 N 的负样本标签。损失函数为二值交叉熵函数。

1.2 网络结构

本文提出的 CNN 和堆叠 LightGBM 网络结构流程及具体参数如图 1 所示。其中，LightGBM 叶子数为 8，树深为 -1，估计器数量为 50。对 SpO₂ 和 ECG 信号的原始数据预处理后提取经验特征，拼接后长度为 133；将预处理后长度均为 6 000 的片段输入 CNN 网络，提取每层卷积特征，与经验特征拼接输入 LightGBM；将融合结果与下层卷积特征及经验特征拼接，输入 LightGBM，以此堆叠进行 OSA 检测。




图 1 CNN 和堆叠 LightGBM 的网络结构流程图

2 数据

2.1 数据集

本文使用 Physionet^[16]网站的公开数据集呼吸暂停-心电图数据库 (apnea-ecg database, AED)^[17], 70 条记录中 8 条包含 SpO₂ 和 ECG, 均来自不同的被试者, 采样频率均为 100 Hz, 录制时间为 401~578 min 不等, 注释“N”和“A”分别代表正常和 OSA^[17-18]。

2.2 数据预处理与划分

数据预处理: 去除 8 条包含 SpO₂ 和 ECG 记录前后各 30 s 的异常信号, 此时的原始标签相对原本标签位置向后推 30 s; 将数据切为不重叠的 1 min 片段, 标注为 A 或 N; 对低于 50% 的 SpO₂ 进行线性插值以消除零电平伪影^[11]; 采用卷积移动平均滤波器对 ECG 滤波, 利用 Christov 方法^[18]提取 QRS 波群, 通过 Hamilton 方法^[19]进行校验, 计算两个 R 波的间隔并提取心率信号。

根据被试者不同, 将 8 条记录划分为四折交叉验证, 如表 1 所示。

表 1 四折交叉验证的数据划分

序号	记录	训练集		测试集	
		N	A	N	A
1	a01, b01	1 790	970	464	486
2	a02, c01	1 691	1 040	563	416
3	a03, c02	1 508	1 213	746	243
4	a04, c03	1 773	1 145	481	311

2.3 特征提取

2.3.1 ECG 特征提取及特征选择

为去除异常心率并滤除高频噪声, 每隔 2.4 s 进行线性插值, 使用周期图法^[20]估计 5 min 的心率信号的功率谱密度 (power spectral density, PSD) 和样本频率。设置阈值范围为 0.005~0.03, 间隔为 0.002 5, 提取 5 min 的 PSD 和样本频率特征。利用 LightGBM 进行四折交叉验证, 不同阈值得到不同的受试者操作特征 (receiver operating characteristic, ROC) 曲线的面积曲线 (area under the curve, AUC) 和 F1 分数 (F1-score),

如图 2 所示。




图 2 LightGBM 对心率频率特征阈值范围实验结果

由图 2 可以看出, LightGBM 对心率特征的最佳阈值范围在 0.012 5~0.02 之间。选择阈值为 0.015, 其平均 ROC 曲线如图 3 所示, AUC 为 94%, 标准偏差为 4%。




图 3 阈值 0.015 对应的平均 ROC 曲线

由于周期性呼吸中断, 心率在特定频率下波动幅度较大, 因此可以利用时频域的特征检测是否发生 OSA^[7]。选取频域阈值为 0.015, 计算 1 min 及 5 min 心率信号的统计分析^[21]、时域特征^[22]和非线性特征^[23], 共得到 62 个特征; 再归一化并去除皮尔逊相关系数 $r > 0.75$ 的特征以降低冗余性, 得到 16 个最优特征, 如表 2 所示。

表 2 提取 ECG 的相关特征

序号	特征名称	特征解释	序号	特征名称	特征解释
1	p75_r_5min	第 75 百分位数减中位数	9	min_hr_1min	1 min 内的心率最小值
2	mean_r_1min	平均值减中位数	10	min_hr_5min	5 min 内的心率最小值
3	acf2_1min	1 min 内最大延迟为 24 s 的心率序列的自相关性	11	csi_1min	1 min 内的心脏交感神经指数
4	acf2_5min	5 min 内最大延迟为 24 s 的心率序列的自相关性	12	csi_5min	5 min 内的心脏交感神经指数
5	sdsd_1min	1 min 内相邻 RR 隔间差异的标准偏差	13	std_hr_5min	心率标准差
6	sdsd_5min	5 min 内相邻 RR 隔间差异的标准偏差	14	Modified_csi_1min	改良 CSI
7	pnni_50_5min	由连续 RR 间隔大于 50 ms 的间隔差除以 RR 间隔总数	15	f_peak	PSD 峰值对应的样本频率
8	max_hr_5min	5 min 内的心率最大值	16	area_ratio	样本频率大于阈值的 PSD 总和与样本频率小于阈值的 PSD 总和的比例

2.3.2 SpO₂ 特征提取

把 SpO₂ 片段的采样频率从 100 Hz 降低为 1 Hz, 提取一、二阶差分^[24], 得到向量长度为 127。

一阶差分的表达式为

$$\mathbf{x}'(k) = x_{i+1}(k) - x_i(k) \quad (1)$$

二阶差分的表达式为

$$\mathbf{x}''(k) = \mathbf{x}'_{i+1}(k) - \mathbf{x}'_i(k) \quad (2)$$

式中:

$\mathbf{x}$ —— SpO₂ 片段组成的向量;

x_i —— 向量中的元素, $i = \{1, 2, \dots, 60\}$ 。

3 实验结果与分析

3.1 实验环境

实验采用深度学习框架 Keras, 服务器 CPU Intel(R)Core (TM) i5-6300HQ CPU @ 2.60 GHz, 内存 12 GB。

3.2 评估指标

使用准确性 (accuracy, Acc)、敏感性 (sensitivity, Se)、特异性 (specificity, Sp)、平衡错误率 (balance error rate, Ber) 和 AUC 作为评估指标。

$$Se = T_p / N_p \quad (3)$$

$$Sp = T_n / N_n \quad (4)$$

$$Acc = (T_p + T_n) / (N_p + N_n) \quad (5)$$

$$Ber = 1 - (Se + Sp) / 2 \quad (6)$$

式中:

T_p —— 正样本被预测为正样本的数量;

N_p —— 所有正样本的数量;

T_n —— 负样本被正确预测为负样本的数量;

N_n —— 所有负样本的数量。

3.3 实验对比与分析

为验证本文模型能够挖掘不同信号间潜在相关信息, 本文做 4 组实验: 1) 基于 ECG 的 3 层 CNN 网络模型, 利用 AED 剩下的 70-8=62 条 ECG 记录训练 CNN 网络模型, 再将本文划分的数据作为该模型输入; 2) 基于 SpO₂ 的 3 层 CNN 网络模型, 即未加入堆叠 LightGBM 结构前的神经网络模型; 3) 基于 SpO₂ 和 ECG 的决策层融合 (decision-level fusion, DLF); 4) 本文基于 SpO₂ 和 ECG 的 CNN 及堆叠 LightGBM 的网络模型。每组实验结果均为四折交叉验证的平均结果, 前三组实验作为基线, 如表 3 所示。

由表 3 可以看出: 本文模型实验结果优于单独使用 SpO₂、ECG; 与 DLF 模型相比, Acc 和 AUC 分别提高了 1.86%、1.15%, Ber 降低了 1.15%; 表明本文

模型可以学习不同模态间潜在的相关信息，且效果优于决策层融合。

表 3 不同网络模型的 OSA 检测性能对比

网络模型	信号	Acc/ %	Se/ %	Sp/ %	AUC/ %	Ber/ %
CNN	ECG	73.05	83.68	63.00	73.34	26.66
CNN	SpO ₂	95.90	96.54	95.56	96.05	3.95
DLF	SpO ₂ + ECG	94.18	93.56	96.80	95.18	4.82
本文模型	SpO ₂ + ECG	96.04	96.44	96.22	96.33	3.67

文献[25-26]使用 AED 数据的 OSA 检测性能对比如表 4 所示。

表 4 不同文献的 OSA 检测性能对比

方法	是否跨被试	Acc/ %	Se/ %	Sp/ %
SVM ^[25]	是	89.80	86.79	88.48
SVM ^[26]	是	95.35	—	—
本文方法	是	96.04	96.44	96.22

由表 4 可知：SHI 等^[25]利用支持向量机（support vector machine, SVM）对 13 个最优特征进行十折交叉验证；MEMIS 等^[26]利用 SVM 和级联方法保留用 SpO₂ 和 ECG 信号传达的时间信息，但实验结果均低于本文模型；说明与传统机器学习相比，本文模型更能学习不同模态间潜在的相关特征信息。

4 结语

为更好地挖掘和利用不同模态间的潜在相关性，本文提出一种基于 CNN 和堆叠 LightGBM 的多模态 OSA 检测方法。首先，对数据集进行跨被试划分；然后，提取 SpO₂ 和 ECG 经验特征集，并保留皮尔逊相关系数小于 0.75 的最优特征集；最后，使用 CNN 生成更深层的特征，结合最优特征集作为 LightGBM 分类器的输入，使用堆叠方法实现 OSA 检测。本文模型在公开数据集 AED 上的实验结果与决策层融合模型相比，逐层特征融合效果优于决策层融合效果；

与使用单独信号的结果相比均有提高，表明本文模型可有效挖掘 SpO₂ 和 ECG 间潜在的相关信息。因此，本文方法能够在跨被试数据集中实现较高的 OSA 检测性能。

参考文献

- [1] SATEIA MJ. International classification of sleep disorders-third edition: highlights and modifications[J]. Chest, 2014,146(5): 1387-1394.
- [2] MOSTAFA S S, MENDONCA F, RAVELO-GARCIA A G, et al. Multi-objective hyperparameter optimization of convolutional neural network for obstructive sleep apnea detection[J]. IEEE Access, 2020,8:129586-129599.
- [3] ADAM V Benjafield, NAJIB T Ayas, Peter R Eastwood, et al. Estimation of the global prevalence and burden of obstructive sleep apnoea: a literature-based analysis[J]. The Lancet Respiratory Medicine, 2019,7(8):687-698.
- [4] American Academy of Sleep Medicine Task Force. Sleep related breathing disorders in adults: Recommendations for syndrome definition and measurement techniques in clinical research[J]. Sleep, 1999 22(5):667-689.
- [5] DEVIAENE M, TESTELMANS D, BUYSE B, et al. Automatic screening of sleep apnea patients based on the SpO₂ signal[J]. IEEE Journal of Biomedical and Health Informatics, 2019,23(2): 607-617.
- [6] OZEGOWSKI S, WILCZYŃSKA E, PIORUNEK T, et al. Usefulness of ambulatory ECG in the diagnosis of sleep-related breathing disorders[J]. Kardiologia polska, 2007,65(11):1321-1328.
- [7] LI HY, LI JX, NA B, et al. An IoMT cloud-based real time sleep apnea detection scheme by using the SpO₂ estimation supported by heart rate variability[J]. Future Generation Computer Systems, 2019,98:69-77.
- [8] PUNJABI M, PRABHU S. An ANN-based detection of obstructive sleep apnea from simultaneous ECG and SpO₂ recordings[C]//International Conference on ISMAC in Computational Vision and Bio-Engineering, Springer, Cham, 2018.
- [9] MOSTAFA SS, MENDONÇA F, RAVELO-GARCÍA AG, et al. A systematic review of detecting sleep apnea using deep learning[J]. Sensors (Basel), 2019,19(22):4934.
- [10] ERDENEBAIYAR U, KIM Y J, Park J U, et al. Deep learning approaches for automatic detection of sleep apnea events from an electrocardiogram[J]. Computer Methods and Programs in Biomedicine, 2019,180:105001.

- [11] VAQUERIZO-VILLAR F, ALVAREZ D, KHEIRANDISH - GOZAL L, et al. A convolutional neural network architecture to enhance oximetry ability to diagnose pediatric obstructive sleep apnea[J]. IEEE Journal of Biomedical and Health Informatics, 2021,25(8): 2906-2916.
- [12] DOMINGOS Pedro. A few useful things to know about machine learning[J]. Communications of the ACM, 2012,55(10):78-87.
- [13] BASTANI K, ASGARI E, NAMAVARI H. Wide and deep learning for peer-to-peer lending[J]. Expert Syst Appl, 2019, 134:209-224.
- [14] HE H, FAN Y. A novel hybrid ensemble model based on tree-based method and deep learning method for default prediction [J]. Expert Systems with Applications, 2021,176:114899.
- [15] FRIEDMAN J H. Greedy function approximation: a gradient boosting machine[J]. Annals of Statistics, 2001, 29(5):1189-1232.
- [16] GOLDBERGER A, AMARAL L, GLASS L, et al. PhysioBank, PhysioToolkit, and Physionet: components of a new research resource for complex physiologic signals[J]. Circulation, 2000,101(23):215-220.
- [17] PENZEL T, MOODY G B, MARK R G, et al. The apnea-ECG database[C]. Computers in Cardiology 2000. IEEE, 2000.
- [18] CHRISTOV I I. Real time electrocardiogram QRS detection using combined adaptive threshold[J]. BioMedical Engineering OnLine, 2004,3(1):1-9.
- [19] HAMILTON P S, LIMITED E P. Open source ECG analysis software documentation[J]. Comput Cardiol, 2002(29):101-104.
- [20] 黄英.周期图法的功率谱估计[J].中国西部科技,2013,12(9): 1-2,8.
- [21] RICHARDS J E. The statistical analysis of heart rate: a review emphasizing infancy data[J]. Psychophysiology, 1980,17(2): 153-66.
- [22] Heart rate variability: standards of measurement, physiological interpretation and clinical use. Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology[J]. Circulation, 1996,93(5): 1043-1065.
- [23] JEPPESEN J, BENICZKY S, JOHANSEN P, et al. Using Lorenz plot and cardiac sympathetic index of heart rate variability for detecting seizures for patients with epilepsy[J]. International Conference of the IEEE Engineering in Medicine and Biology Society, 2014,2014:4563-4566.
- [24] KOLEY BL, DEY D. On-line detection of apnea/hypopnea events using SpO₂ signal: a rule-based approach employing binary classifier models[J]. IEEE Journal of Biomedical and Health Informatics, 2014, 18(1):231-239.
- [25] SHI C, NOURANI M, GUPTA G, et al. Apnea MedAssist II: A smart phone based system for sleep apnea assessment[C]// IEEE International Conference on Bioinformatics and Biomedicine, 2013,572-577.
- [26] MEMIS G, SERT M. Multimodal classification of obstructive sleep apnea using feature level fusion[C]//IEEE International Conference on Semantic Computing, 2017,85-88.

作者简介:

林美娜, 女, 1997 年生, 硕士研究生, 主要研究方向: 模式识别, 生物信号处理。E-mail: meina.lin@mail.gdut.edu.cn

郑和裕, 男, 1996 年生, 硕士研究生, 主要研究方向: 模式识别, 机器学习, 生物信号处理。E-mail: zheng_hy1209@qq.com

(上接第 19 页)

- [8] 王长军,刘雨,周健,等.金属增材技术在钢铁领域的研究进展[J/OL]. 中国冶金,2022,32(5):7-15[2022-04-06]. <https://doi.org/10.13228/j.boyuan.issn1006-9356.20210751>.

作者简介:

张理, 男, 1990 年生, 博士研究生、助理研究员, 主要研究方向: 激光增材制造。E-mail: l.zhang@giim.ac.cn

曹立超, 男, 1991 年生, 硕士, 工程师, 主要研究方向: 爬壁机器人、增材制造。

- [9] WENG F, CHEW Y, ZHU Z, et al. Excellent combination of strength and ductility of CoCrNi medium entropy alloy fabricated by laser aided directed energy deposition[J]. Additive Manufacturing, 2020:101202.