

本文引用格式: 郑和裕,林美娜.基于空洞卷积和注意力机制的睡眠呼吸暂停检测方法[J].自动化与信息工程,2022,43(2):29-34,40.  
ZHENG Heyu, LIN Meina. Sleep apnea detection method based on dilated convolution and attention mechanism[J].  
Automation & Information Engineering, 2022,43(2):29-34,40.

# 基于空洞卷积和注意力机制的睡眠呼吸暂停检测方法

郑和裕 林美娜

(广东工业大学, 广东 广州 510006)

**摘要:** 为提高基于心电信号的睡眠呼吸暂停检测精度,针对现有检测方法普遍存在的需要较复杂的特征工程和手工校正步骤,无法对心电信号自适应预处理且损失较多信息的问题,提出一种基于空洞卷积和注意力机制的睡眠呼吸暂停检测方法。首先,利用自适应预处理网络滤除心电信号中的冗余信息(包括基线漂移、肌电干扰等);然后,使用基于空洞卷积和时间注意力机制的检测网络从心电信号中提取时序特征并进行检测。在 Apnea-ECG 数据集上的实验结果表明,相比其他 6 种检测方法,本文方法能够实现更有效的睡眠呼吸暂停检测。

**关键词:** 心电信号;睡眠呼吸暂停综合征;自适应信号预处理;空洞卷积;注意力机制

**中图分类号:** TP391

**文献标识码:** A

**文章编号:** 1674-2605(2022)02-0005-07

**DOI:** 10.3969/j.issn.1674-2605.2022.02.005

## 0 引言

20 世纪 70 年代, GUILLEMINAULT 等发表的《睡眠呼吸暂停综合征》<sup>[1]</sup>标志着睡眠呼吸暂停综合征的发现。医学上将睡眠期间超过 10 s 的呼吸气流缺失的临床综合征称为睡眠呼吸暂停,其中阻塞性睡眠呼吸暂停(obstructive sleep apnea, OSA)是一种常见的睡眠障碍。随着时间的推移,研究人员发现睡眠呼吸暂停达到全球流行病的程度,普通人群中男性患病率为 4%,女性患病率为 2%<sup>[2]</sup>,对公众健康、交通安全和社会经济等方面产生了负面影响<sup>[3-6]</sup>。

被称为“金标准”的多导睡眠图(polysomnography, PSG)<sup>[7-8]</sup>要求患者在睡眠中心过夜,同时需要多个传感器记录多个睡眠生理信号<sup>[9-15]</sup>;再通过测量呼吸暂停低通气指数将 OSA 程度分为不同等级。然而 PSG 存在时间成本和费用较高的缺点,不利于大众推广<sup>[16]</sup>。

随着心电信号采集技术的发展<sup>[17]</sup>,根据心电信号与 OSA 之间的相关性<sup>[2]</sup>,越来越多的国内外学者研究基于单导联心电信号的睡眠呼吸暂停检测方法。现有的研究主要分为 2 类:

1) 基于特征工程和传统分类器,如 SONG 等<sup>[18]</sup>先对心电信号进行 R 峰定位,再计算 R-R 间隔(R-R interval, RRI)及其相关特征结合心电图衍生呼吸信号(ECG-derived respiratory, EDR),输入隐马尔科夫模型(hidden Markov model, HMM)进行 OSA 检测;VARON 等<sup>[19]</sup>先采用改进的 Pan-Tompkins 算法<sup>[20]</sup>定位 R 峰位置,再利用正交子空间投影,从 QRS 波群以及心率和 EDR 信号中提取相关特征,并将这 2 个特征与心率变异性的相关特征结合,最后用最小二乘支持向量机(least squares support vector machine, LS-SVM)输出 OSA 检测结果;FENG 等<sup>[21]</sup>提出一种基于频率堆叠稀疏自动编码器,采用无监督学习技术自动从 RRI 中提取特征集,并结合 HMM 和 MetaCost 算法提出时间相关代价敏感分类模型;

2) 原始信号经过预处理或特征工程后输入神经网络提取特征并进行 OSA 检测,如 CHANG 等<sup>[22]</sup>将经过带通滤波器和零均值归一化的心电信号,输入多层卷积神经网络进行特征提取进而实现 OSA 检测;SINGH 等<sup>[23]</sup>将经过手工校正去除 R 峰异常样本、带通滤波、连续小波变换和零中心归一化后的心电信号二维时频图,输入卷积神经网络,提取空间特征实现

OSA 检测。

然而，以上研究主要存在 2 方面不足：

1) 特征工程需要特定的特征提取方法和先验知识，从心电波形、RRI、心率变异性、瞬时心率和 EDR 中提取特征，特征提取方法对检测效果影响较大；

2) 心电信号存在工频干扰、运动伪迹、基线漂移等与检测 OSA 无关的干扰信息，在提取特征之前需进行预处理，传统的预处理方法无法自适应地预处理心电信号，且对心电信号的波形影响较大，造成信息丢失。

针对上述检测方法的不足，本文提出一种基于空洞卷积和注意力机制的睡眠呼吸暂停检测方法。该方法采用了端到端的心电检测框架。该框架由自适应预处理网络（adaptive preprocessing network, APN）和基于空洞卷积和时间注意力机制的检测网络（classification network based on dilated convolution and temporal attention mechanism, DCTAM）组成。其中，APN 去除原始信号中的基线漂移等干扰信息，以减小其对 OSA 检测的影响；DCTAM 捕捉心电信号中的呼吸暂停时间段，完成心电片段分类。

## 1 数据与预处理

本实验采用的公开数据集为 Physionet 的 Apnea-ECG 数据库<sup>[2,24]</sup>。该数据库来自 32 个受试者，共 70 条记录，每条记录的持续时间为 401~578 min 不等，采样频率为 100 Hz。在本实验中，记录根据 OSA 的严重程度分为 A、B、C 组，同时 X 组包含不同程度的记录；且 A、B、C 组为训练集，X 组为测试集<sup>[25]</sup>。若 1 min 内发生睡眠呼吸暂停，则将该分钟标记为 Y，否则标记为 N。

根据注释文件将原始信号进行分段处理，样本数量统计如表 1 所示。

表 1 样本数量统计 单位：个

|     | 总数量    | 正样本数量 | 负样本数量  |
|-----|--------|-------|--------|
| 训练集 | 17 006 | 6 510 | 10 496 |
| 测试集 | 17 219 | 6 543 | 10 676 |

## 2 检测方法

### 2.1 检测方法框架

基于空洞卷积和注意力机制的睡眠呼吸暂停检测方法的端到端心电检测框架由 APN 和 DCTAM 组成，如图 1 所示。




图 1 检测方法的端到端心电检测框架

### 2.2 APN

APN 主要消除原始 ECG 信号中存在的工频干扰、基线漂移等干扰信息。APN 输入为原始 1 min 的 ECG 片段，输出为经过自适应预处理后的 ECG 信号，网络框架如图 2 所示。




图 2 自适应预处理网络框架

图 2 中连通域为

$$x^{i,j} = \begin{cases} H(D(x^{i-1,j})), & j = 1 \\ H\left(\left[x^{i,k}\right]_{k=1}^{j-1}, U(x^{i+1,j-1})\right), & j > 1 \end{cases} \quad (1)$$

式中：

$x^{i,j}$ ——节点  $X^{i,j}$  的输出；

$i$ ——编码器下采样层的索引；

$j$ ——跳接密集块卷积层的索引；

$H$ ——卷积操作；

$D$ ——下采样操作；

$U$ ——上采样操作。

U-Net++在音频去冗余方面已被证明有较好的效果<sup>[26]</sup>，因此本文的 APN 基于 U-Net++<sup>[27-28]</sup>构建，即由不同深度的 U-Net<sup>[29]</sup>组成，其编解码器通过相同的

分辨率密集连接，网络参数设置如表 2 所示。

表 2 U-Net++网络参数设置

| 参数      | $X^{1,1}$ | $X^{2,1}$ | $X^{3,1}$ |
|---------|-----------|-----------|-----------|
| 卷积核个数/个 | 32        | 64        | 128       |
| 卷积核宽度   | 3         | 3         | 3         |
| 卷积操作步长  | 1         | 1         | 1         |
| 池化窗口大小  | 2         | 2         | 2         |
| 池化操作步长  | 2         | 2         | 2         |

1 个 U-Net 网络由 1 个收缩路径和 1 个扩张路径组成。其中，收缩路径是典型的卷积网络结构，由 2 个重复的卷积层和 1 个用于下采样的最大池化层组成，卷积层的激活函数采用线性修正单元（rectified linear unit, ReLU）；扩张路径包含特征图的上采样过程。收缩路径和扩张路径之间的级联也采用卷积运算，激活函数使用 ReLU 函数。最后一层采用  $1 \times 1$  卷积进行卷积运算后输出。不同深度 U-Net 网络之间的连接同样采用卷积运算。

### 2.3 DCTAM

大多数患者在每次睡眠呼吸暂停中后期都会心率（heart rate, HR）上升，几次呼吸后达到峰值，这种心率变化是睡眠呼吸暂停的特有现象<sup>[30-31]</sup>。网络在时序上正确把握此现象可提高睡眠呼吸暂停片段的判别。鉴于此，本文采用基于空洞卷积和时间注意力的网络，捕捉这一时序特征进而提高睡眠呼吸暂停的检出率。其中，时间注意力<sup>[32]</sup>可提升关键时间段的特征表达，本质上是将原始信号中的时序信息通过时间转换模块，变换到另一个特征空间中并保留核心信息，为每个时刻生成权重掩码并加权输出，从而增强感兴趣的特定目标时间段，同时弱化不相关的时间段。由于呼吸暂停的持续时间一般在 10 s 以上，故要求卷积核有较大的感受野来捕捉相应特征。空洞卷积可在维持原网络参数量不变的基础上，增大感受野，避免使用下采样层带来的信息损失。因此本文采用空洞卷积生成时间注意权重，增强与睡眠呼吸暂停相关的信息特征，DCTAM 模型可以自动聚焦在呼吸暂停部分。

DCTAM 模型的主体由 5 个网络块串行连接。每个网络块的输入是前一个网络块的输出，最后一个网

络块通过全连接层和 softmax 激活函数得到最终的预测输出。每个网络块的架构如图 3 所示，其中卷积网络空洞率均为 3，卷积核个数均为 45，卷积核大小依次为 16、16、16、32、32，步长均为 1。




图 3 DCTAM 模型网络块

### 2.4 模型优化和损失函数

为提高 DCTAM 模型的收敛速度，减少训练时内存占用，采用自适应学习率优化算法 Adam。由于正负样本分布不平衡，本文使用 focal loss<sup>[33]</sup>作为损失函数，计算公式为

$$\text{loss} = \begin{cases} -\alpha(1 - \hat{y})^\gamma \log \hat{y}, & y = 1 \\ -(1 - \alpha)\hat{y}^\gamma \log(1 - \hat{y}), & y = 0 \end{cases} \quad (2)$$

式中：

$y \in \{0, 1\}$ ——真实类别；

$\hat{y}$ ——预测概率；

$\alpha$ ——平衡系数，设置为 0.3；

$(1 - \hat{y})^\gamma$ ——调制因子；

$\gamma$ ——聚焦参数，设置为 1.8。

### 2.5 模型评价指标

OSA 检测算法的目的是识别 OSA 发作时的心电图信号，是一个二分类问题。本文采用灵敏度（Sensitivity, Se）、特异性（Specificity, Sp）作为分类任务评估指标。由于正负例的标签选择对平衡错误率（balanced error rate, Ber）的计算没有影响，而且在一定程度上 Ber 能克服正负样本不均衡导致的评估指标虚高，因此同时采用 Ber 作为评估指标。

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

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

$$Ber = 1 - (Se + Sp)/2 \quad (5)$$

式中:

$TP$ ——正样本中被预测为正样本的数量;

$TN$ ——负样本中被预测为负样本的数量;

$N_p$ ——正样本的数量;

$N_n$ ——负样本的数量。

### 3 实验和结果分析

#### 3.1 实验结果与分析

为验证本文提出的网络框架对睡眠呼吸暂停检测的有效性,将本文方法 APN+DCTAM 与其他 6 种方法在 Apnea-ECG 数据库上进行性能对比,结果如表 3 所示。

表 3 本文方法与其他 6 种方法的 OSA 检测结果比较

| 方法                      | $Se/\%$ | $Sp/\%$ | $Ber/\%$     |
|-------------------------|---------|---------|--------------|
| SONG 等 <sup>[18]</sup>  | 88.40   | 82.60   | 14.50        |
| VARON 等 <sup>[19]</sup> | 84.70   | 84.70   | 15.30        |
| FENG 等 <sup>[21]</sup>  | 86.20   | 84.40   | 14.70        |
| SINGH 等 <sup>[23]</sup> | 90.00   | 83.80   | 13.10        |
| CHANG 等 <sup>[22]</sup> | 81.10   | 92.00   | 13.45        |
| 零均值归一化+<br>DCTAM        | 82.86   | 90.44   | 13.35        |
| 本文方法<br>APN + DCTAM     | 85.33   | 88.51   | <b>13.08</b> |

由表 3 可知:

1) 本文方法 APN+DCTAM 的  $Ber$  与其他 6 种方法相比平均降低 1.13%, 表明本文方法具有更均衡的检测效果;

2) 与零均值归一化+DCTAM 方法相比, 本文方法的  $Ber$  降低了 0.27%,  $Se$  提高了 2.47%, 说明经过 APN 后的信号有助于提高检测效果, 然而  $Sp$  有所下降, 说明 APN 对于正常片段的检测能力弱化;

3) 与文献[22]方法相比, 本文方法的  $Se$  提高了 4.23%,  $Ber$  降低了 0.37%, 说明捕捉到的睡眠呼吸暂停时间段有助于提高 OSA 的检出率, 获得更均衡的检测效果, 而  $Sp$  降低了 3.49%, 说明正常片段的检出率有待提高;

4) 部分深度学习方法虽然也有较好的性能表现, 然而需要去除 R 峰异常的样本片段等手动过程 (如 SINGH 等人<sup>[23]</sup>), 相比本文方法对样本质量要求较低。综上所述, 本文方法取得较好的检测效果。

#### 3.2 自适应预处理效果

来自 Apnea-ECG 数据库编号为 a02 记录的第 200 min 原始 ECG 片段、带通滤波+零均值归一化的片段和自适应预处理的片段对比图如图 4 所示。




图 4 预处理结果对比

图 4 中, 由第 200~400 个样本点之间的片段可以看出, 自适应预处理对去除基线漂移等噪声干扰具有较好的效果, 且可以保持信号形态。

#### 3.3 注意力掩码的可视化

图 5(a)是一段发生睡眠呼吸暂停的心电信号及其

心率 HR 的变化曲线。可以看出, 在睡眠呼吸暂停中后期随着呼吸恢复, HR 会突然上升。图 5(b)是检测网络从心电图记录中学习到的睡眠呼吸暂停阶段的注意力掩码。可以看出, 检测网络可以捕捉到 HR 在睡眠呼吸暂停中后期的突变。




图5 注意力掩码可视化

## 4 结语

心电信号在采集过程中容易受噪声、肌电伪迹和基线漂移等信号干扰，对 OSA 检测算法造成影响。现有去除冗余信息的方法严重依赖预处理参数，包括零均值归一化和带通滤波等，此外还需要人工 R 峰校准、异常 R 峰样本剔除等复杂预处理步骤。

本文提出基于空洞卷积和注意力机制的睡眠呼吸暂停检测方法，在 Apnea-ECG 数据库上获得了较好的 OSA 检测效果 ( $Se = 85.33\%$ ,  $Sp = 88.51\%$ ,  $Ber = 13.08\%$ )。本文方法与采用零均值归一化的 DCTAM 相比，采用 APN 的 DCTAM 的  $Ber$  降低了 0.27%，说明经过 APN 后的信号有助于提高检测效果。与其他 6 种算法相比，采用 APN 的 DCTAM 方法的  $Ber$  平均降低了 1.13%，说明采用自适应预处理方法和基于空洞卷积的注意力机制可以获得更均衡的检测能力。因此，本文方法能够在无需预处理和特征工程的同时，实现较均衡的 OSA 检测性能。

## 参考文献

- [1] GUILLEMINAULT C, TILKIAN A, DEMENT W C. The sleep apnea syndromes [J]. Annual Review Of Medicine, 1976,27(1): 465-484.
- [2] PENZEL T, MOODY G B, MARK R G, et al. The apnea-ECG database [C]//Computers in Cardiology 2000. IEEE, 2000.
- [3] GOTTLIEB D J, PUNJABI N M. Diagnosis and management of obstructive sleep apnea: a review [J]. JAMA The Journal of the American Medical Association, 2020,323(14):1389-1400.
- [4] ALMENDROS I, MARTINEZ-GARCIA M A, FARRÉ R, et al. Obesity, sleep apnea, and cancer [J]. International Journal of Obesity, 2020,44(8):1653-1667.
- [5] ELFIL M, BAHBAH E I, ATTIA M M, et al. Impact of obstructive sleep apnea on cognitive and motor functions in Parkinson's DISEASE [J]. Movement Disorders, 2021,36(3):570-580.
- [6] GOZAL D, TAN H L, KHEIRANDISH-GOZAL L. Treatment of obstructive sleep apnea in children: handling the unknown with precision [J]. Journal of Clinical Medicine, 2020,9(3):888.
- [7] RUND O J V, Downey III R. Polysomnography [J]. Handbook of clinical neurology, 2019, 160: 381-392.
- [8] NGUYEN H D, WILKINS B A, CHENG Q, et al. An online sleep apnea detection method based on recurrence quantification analysis [J]. IEEE journal of biomedical and health informatics, 2014,18(4):1285-1293.
- [9] NISHAD A, PACHORI R B, ACHARYA U R. Application of TQWT based filter-bank for sleep apnea screening using ECG signals [J]. Journal of Ambient Intelligence and Humanized Computing, 2018:1-12.
- [10] LIU D, PANG Z, LLOYD S R. A neural network method for detection of obstructive sleep apnea and narcolepsy based on

- pupil size and EEG [J]. IEEE Transactions on Neural Networks, 2008,19(2):308-318.
- [11] SAMI N, HENRI K, SAMU K, et al. Estimating daytime sleepiness with previous night electroencephalography, electrooculography, and electromyography spectrograms in patients with suspected sleep apnea using a convolutional neural network [J]. SLEEP, 2020(12):12.
- [12] STEWART M, BAIN A R. Assessment of respiratory effort with EMG extracted from ECG recordings during prolonged breath holds: insights into obstructive apnea and extreme physiology [J]. Physiological Reports, 2021,9(10):e14873.
- [13] VAQUERIZO-VILLAR F, ÁLVAREZ 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.
- [14] VENA D, AZARBARZIN A, MARQUES M, et al. Predicting sleep apnea responses to oral appliance therapy using polysomnographic airflow [J]. Sleep, 2020,43(7):zsaa004.
- [15] KANG K T, CHIU S N, WENG W C, et al. 24-hour ambulatory blood pressure variability in children with obstructive sleep apnea [J]. The Laryngoscope, 2021,131(9):2126-2132.
- [16] FATIMAH B, SINGH P, SINGHAL A, et al. Detection of apnea events from ECG segments using Fourier decomposition method [J]. Biomedical Signal Processing and Control, 2020,61:102005.
- [17] LIU L, HE L, ZHANG Y, et al. A Battery-Less Portable ECG Monitoring System With Wired Audio Transmission [J]. IEEE Transactions on Biomedical Circuits and Systems, 2019,13(4): 697-709.
- [18] SONG C, LIU K, ZHANG X, et al. An obstructive sleep apnea detection approach using a discriminative hidden Markov model from ECG signals [J]. IEEE Transactions on Biomedical Engineering, 2016,63(7):1532-1542.
- [19] VARON C, CAICEDO A, TESTELMANS D, et al. A novel algorithm for the automatic detection of sleep apnea from single-lead ECG [J]. IEEE Transactions on Biomedical Engineering, 2015, 62(9): 2269-2278.
- [20] PAN J, TOMPKINS W J. A real-time QRS detection algorithm [J]. IEEE Transactions on Biomedical Engineering, 1985,32(3):230-236.
- [21] FENG K, QIN H, WU S, et al. A sleep apnea detection method based on unsupervised feature learning and single-lead electrocardiogram [J]. IEEE Transactions on Instrumentation and Measurement, 2020,70:1-12.
- [22] CHANG H Y, YEH C Y, LEE C T, et al. A sleep apnea detection system based on a one-dimensional deep convolution neural network model using single-lead electrocardiogram [J]. Sensors, 2020,20(15):4157.
- [23] SINGH S A, MAJUMDER S. A novel approach osa detection using single-lead ECG scalogram based on deep neural network [J]. Journal of Mechanics in Medicine and Biology, 2019,19(4):1950026.
- [24] GOLDBERGER A L, AMARAL L A N, GLASS L, et al. PhysioBank, PhysioToolkit, and Physionet: components of a new research resource for complex physio-logic signals [J]. Circulation, 2000,101(23):215-220.
- [25] PhysioNet [Online]. Available: [www.physionet.org](http://www.physionet.org)
- [26] ZHAO T, ZHAO Y, WANG S, et al. UNet++-Based Multi-Channel Speech Dereverberation and Distant Speech Recognition [C]//2021 12th International Symposium on Chinese Spoken Language Processing (ISCSLP). IEEE, 2021:1-5.
- [27] ZHOU Z, SIDDIQUEE M M R, TAJBAKHSH N, et al. Unet++: a nested u-net architecture for medical image segmentation [M]//Deep learning in medical image analysis and multimodal learning for clinical decision support. Springer, Cham, 2018: 3-11.
- [28] ZHOU Z, SIDDIQUEE M M R, TAJBAKHSH N, et al. Unet++: redesigning skip connections to exploit multiscale features in image segmentation [J]. IEEE Transactions on Medical Imaging, 2020,39(6):1856-1867.
- [29] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation [C]//International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015:234-241.
- [30] GUILLEMINAULT C, WINKLE R, CONNOLLY S, et al. Cyclical variation of the heart rate in sleep apnoea syndrome: mechanisms, and usefulness of 24 h electrocardiography as a screening technique [J]. The Lancet, 1984,323(8369):126-131.
- [31] PENZEL T, AMEND G, MEINZER K, et al. MESAM: a heart rate and snoring recorder for detection of obstructive sleep apnea[J]. Sleep, 1990,13(2):175-182.
- [32] LUO J, YE M, XIAO C, et al. Hitanet: Hierarchical time-aware attention networks for risk prediction on electronic health records [C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2020:647-656.

(下转第 40 页)