

基于 1D-Res&SENet 的呼吸暂停检测*

徐佳豪¹, 胡少文², 单新颖³, 刘继忠^{1†}

(1. 南昌大学 先进制造学院, 江西 南昌 330031; 2. 江西省科技基础条件平台中心, 江西 南昌 330003;

3. 中华人民共和国民政部 国家康复辅具研究中心, 北京 100176)

摘要: 针对现有呼吸暂停检测多是利用呼吸信号样本提取的时频特征进行分类的现状, 本文提出了一种 1D-Res&SENet 分类模型, 该模型以完整的呼吸信号波形为输入, 通过一维卷积神经网络提取特征, 加入残差网络结构减轻梯度消失和网格退化, 同时考虑各通道特征重要性不同的特点, 引入 SE 注意力机制发现并加强特征通道之间的关联信息, 提升呼吸暂停检测的准确率。实验结果表明, 加入残差网络以及 SENet 模块后, 模型的准确率、召回率、特异性分别提升了 2.0%、4.9% 和 1.7%。

关键词: 呼吸暂停; 一维卷积神经网络; SENet; 残差网络; 毫米波雷达

DOI: 10.13568/j.cnki.651094.651316.2025.01.16.0003

中图分类号: TP183 **文献标识码:** A **文章编号:** 2096-7675(2026)01-0051-010

引文格式: 徐佳豪, 胡少文, 单新颖, 刘继忠. 基于 1D-Res&SENet 的呼吸暂停检测[J]. 新疆大学学报(自然科学版中英文), 2026, 43(1): 51-60.

英文引文格式: Xu Jiahao, Hu Shaowen, Shan Xinying, Liu Jizhong. Apnea detection based on 1D-Res&SENet[J]. Journal of Xinjiang University(Natural Science Edition in Chinese and English), 2026, 43(1): 51-60.

Apnea Detection Based on 1D-Res&SENet

Xu Jiahao¹, Hu Shaowen², Shan Xinying³, Liu Jizhong¹

(1. School of Advanced Manufacturing Institute, Nanchang University, Nanchang Jiangxi 330031, China; 2. Jiangxi

Provincial Science and Technology Infrastructure Platform Center, Nanchang Jiangxi 330003, China; 3. National Research Center for Rehabilitation Technical Aids, Ministry of Civil Affairs of the People's Republic of China, Beijing 100176, China)

Abstract: Addressing the current practice where most apnea detection systems rely on time-frequency features extracted from respiratory signal samples for classification, this paper proposes a 1D-Res&SENet classification model. This approach takes complete respiratory signal waveforms as input, extracts features through a one-dimensional convolutional neural network, and incorporates a residual network structure to mitigate gradient vanishing and grid degradation. Furthermore, recognising the varying importance of features across channels, it introduces an SE attention mechanism to identify and strengthen associative information between feature channels, thereby enhancing the accuracy of apnoea detection. Experimental results show that after adding the residual network and SENet module, the accuracy, recall and specificity of the model are increased by 2.0%, 4.9% and 1.7%, respectively.

Key words: apnea; 1D-convolutional neural network; SENet; residual network; millimeter wave radar

0 引言

呼吸是人体重要的生理活动之一, 可以通过呼吸异常及时发现一些潜在的疾病风险, 在心血管系统反馈调节^[1]、慢性呼吸系统疾病防控^[2]、阿尔茨海默病预防^[3]等领域具有重要意义。睡眠呼吸暂停(Obstructive Sleep Apnea, OSA)也被称为失眠共病阻塞性睡眠呼吸暂停, 其发病率极高, 一般人群的发病率约为 0.6%~

* 收稿日期: 2025-01-16; 修回日期: 2025-12-22; 录用日期: 2025-12-26.

基金项目: 国家康复辅具研究中心横向合作研究与开发项目“基于毫米波雷达的老年人健康监测技术研究”(HX202311010001).

作者简介: 徐佳豪(1999—), 男, 硕士生, 从事医工结合技术的研究, E-mail: xjh1366783180@163.com.

† 通信作者: 刘继忠(1974—), 男, 博士, 教授, 主要从事智能机电系统与机器人的研究, E-mail: liujizhong@ncu.edu.cn.

19.3%^[4]. 但很少有人重视该问题并积极诊断治疗,传统检测睡眠呼吸暂停的方式是通过多导睡眠仪采集相应的生理信息,再由专业人员分析计算呼吸暂停指数(Apnea-Hypopnea Index, AHI)进行诊断. 该方式评估效率较低且成本高昂,故设计方便、高效率的检测方式尤为重要.

祁富贵等^[5]提出了一种基于小波信息熵的呼吸暂停检测方法,能够利用呼吸信号有效检测呼吸暂停事件. John等^[6]提出一种基于一维卷积神经网络(1D-Convolutional Neural Network, 1D-CNN)模型,通过读取心电图信号(ECG),检测呼吸暂停事件. 张大可等^[7]通过提取心电信号特征,并利用支持向量机(SVM)检测呼吸暂停事件,准确率为94%. Hou等^[8]提出了THO时间序列转换模型,结合扩张卷积以及长短期记忆网络(Long Short-Term Memory, LSTM),融合多尺度特征,提高了脑电波信号(EEG)数据预测呼吸暂停时间的准确性. Bhongade等^[9]从公共数据集的EEG中提取时域、频域和基于非线性熵的特征,使用各种分类器来识别呼吸暂停事件.

现有研究多是通过提取ECG信号特征以实现OSA事件的检测,可取得较高的准确率,但其依赖接触式采集,存在舒适性差、易受干扰的问题. 近年来,毫米波雷达在非接触式生命体征(呼吸、心跳)检测方面展现出巨大潜力,能够有效克服接触式设备的弊端. Wu等^[10]利用超宽带体制雷达采集的数据,从中获取了受试者呼吸、心跳等信息;沈建飞等^[11]结合卷积神经网络(Convolutional Neural Networks, CNN)和LSTM完成呼吸信息提取. 然而,缺少针对提取的生理信号直接面向呼吸暂停事件检测的研究.

针对接触式方法舒适性不足、单一呼吸信号信息维度有限及非接触式毫米波雷达在OSA事件检测研究的空白等问题,本文提出一种基于1D-Res&SENet的呼吸暂停检测方法,设计融合残差网络结构(Residual Network, ResNet)与通道注意力机制(Squeeze-and-Excitation Networks, SENet)的一维卷积神经网络,旨在直接从呼吸信号中端到端学习多尺度深层次时空特征,自适应聚焦关键信息,高效、鲁棒地识别呼吸暂停事件,该方法通过读取UCD睡眠呼吸暂停数据库^[12]中的呼吸信号,再结合专业睡眠专家记录的数据,为样本设置标签以形成数据集. 将数据集分为训练集、验证集、测试集,在训练集基础上训练获得神经网络分类模型,并设计消融实验,验证各模块作用,最后通过与多种方法对比分析,验证本方法的有效性.

1 调频连续波(FMCW)雷达呼吸检测原理

人体进行呼吸活动时,胸腔会产生上下起伏振动,雷达检测呼吸信号主要通过检测胸腔位移实现^[13]. 雷达发出的信号碰到胸腔后会产生回波信号,雷达将发射信号与反射信号进行混频从而输出中频信号,然后根据中频信号的频率变化计算胸腔的微小振动.

FMCW雷达常用调频类型为锯齿波,其发射信号和接收信号如图1所示.

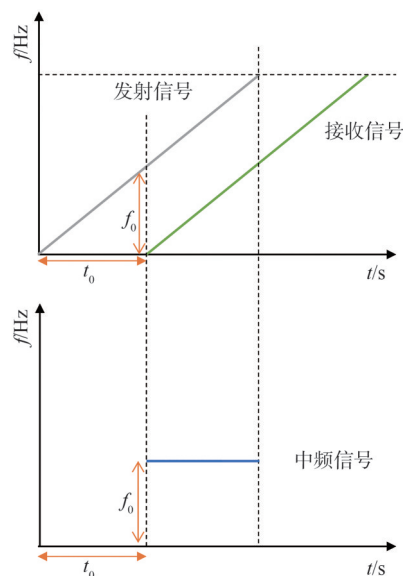


图1 雷达发射、回波信号与中频信号频率对应图

Figure 1 Correspondence diagram of radar transmitting signal, echo signal and intermediate frequency signal frequencies

发射的调频信号 $s(t)$ 表达式为:

$$s(t) = e^{j(2\pi f_0 t + \pi \frac{B}{T} t^2)}, \quad (1)$$

式中: f_0 为调频信号的起始频率; B 为调频带宽; T 为扫描周期.

假设人位于 D 处, 发射信号被人体反射后, 接收信号 $r(t)$ 表达式为:

$$r(t) = e^{j[2\pi f_0 (t - t_0) + \pi \frac{B}{T} (t - t_0)^2]}, \quad (2)$$

式中: 人体呼吸时的距离变化会导致接收延时 t_0 , 计算公式为:

$$t_0 = \frac{2D}{c}, \quad (3)$$

式中: c 为光速. 将发射信号 $s(t)$ 与接收信号 $r(t)$ 混频得到中频信号 $b(t)$, 表达式为:

$$b(t) = s'(t)r(t) \approx e^{j(4\pi \frac{BR}{cT} t + \frac{4\pi}{\lambda} R)} = e^{j(f_0 t + \Phi_0)}, \quad (4)$$

式中: $f_0 = 4\pi BR/cT$, $\Phi_0 = 4\pi R/\lambda$. 同一个调频周期内, 起始相位可视为常量, 多个调频周期的距离变化不可忽视, 假设呼吸引起的胸腔位移为 ΔR , 对应相位变化为:

$$\Delta\Phi_0 = \frac{4\pi}{\lambda} \Delta R, \quad (5)$$

式中: λ 为雷达发射信号波长, 数量级为 10^{-3} m, 故当胸腔发生细微变化时, 会使中频信号 $b(t)$ 相位产生极大的改变.

通过该相位变化进行解卷绕, 可获取包含噪声信号、呼吸信号、心跳信号的混合信号, 考虑人体呼吸频率为 0.2~0.5 Hz, 采用带通滤波法去除干扰信号, 利用快速傅里叶变换 (FFT)、小波变换 (CWT) 对信号所属的呼吸模式进行分析, 雷达信号处理流程如图 2 所示.




图 2 雷达信号处理流程

Figure 2 Radar signal processing flowchart

2 基本原理

2.1 1D-CNN

1D-CNN 是卷积神经网络的一种变体, 可直接从时域学习原始一维数据 (时间轴上的一维网格信号) 或经预处理转换后的数据 (如频域数据). 在语音识别、ECG 监测等领域已广泛应用, 其主要由输入层、卷积层、池化层、全连接层和输出层构成^[14]. 通过多个卷积层和池化层叠加可以获得更强的学习能力^[15], 但网络层数的加深也会导致模型更加复杂, 对训练集的拟合程度增加, 出现过拟合现象.

毫米波雷达采集的呼吸信号属于一维数据^[16], 包含时间、幅度、频率等信息, 本文使用 1D-CNN 提取特征信息, 其卷积和池化原理如图 3 所示.




图 3 卷积和池化原理

Figure 3 Schematic diagram of convolution and pooling principles

卷积层的作用是通过输入进行卷积运算,提取输入数据的特征,表达式为:

$$x_j^l = f\left(\sum_{i=1}^l x_i^{l-1} * k_{ij}^l + b_j^l\right), \quad (6)$$

式中: x_j^l 为第 l 层的第 j 个特征区域; j 为该层神经元的个数; x_i^{l-1} 为第 $l-1$ 层第 i 个特征区域; f 为激活函数; k_{ij}^l 为第 l 层第 i 个卷积核的第 j 个权值; $*$ 为卷积运算符; b_j^l 为第 l 层的网络偏置项.

池化层位于卷积层后,用于降低维度,提取最主要特征从而简化网络,最大值池化的表达式为:

$$p_k^l(i) = \max_{(i-1)a+1 \leq t \leq ia} \{n_k^{l-1}(t)\}, \quad (7)$$

式中: $n_k^{l-1}(t)$ 为第 $l-1$ 层第 k 个特征矢量中第 t 个特征区域的值; a 为池化窗口的大小.

激活函数可以为网络引入非线性元素,提升网络表达能力,ReLU是经典的非线性函数,表达式为:

$$f(x) = \max(0, x). \quad (8)$$

2.2 SENet

Hu等^[17]提出SENet来增强卷积神经网络的代表能力,其由两个主要操作组成:压缩(Squeeze)和激励(Excitation),具体结构如图4所示.




图4 SENet工作原理(据文献[18]修改)

Figure 4 Working principle of SENet (modified from reference [18])

如图4所示, X_1 、 X_2 ... X_n 分别代表不同的通道,通过Squeeze操作,能够提取出代表本通道的特征向量 C ;将向量 C 进行Excitation操作(通常是一两层的FC网络),输出与 C 相同维度的新向量 C ,新向量 C 中不同元素代表对应通道的权重;将新向量 C 中的各元素乘以原始通道,对原始输入数据做一次channel层面的reweight. SENet整个过程表达式为:

$$\tilde{X} = \text{reweight}(X) = X \cdot \text{sigmoid}(W_1 \cdot \text{ReLU}(W \cdot \text{Pool}(X))). \quad (9)$$

在信号处理中,SENet通过相互发生关联,动态判断所有输入特征中重要与不重要特征,强化重要特征,抑制不重要或噪声特征,提升其泛化性能.

2.3 残差结构

He等^[18]针对因层数加深而导致的网络性能退化问题提出了ResNet,通过在卷积层中引入跳跃连接,构建残差结构,使梯度在反向传播时能够更加顺畅,从而加速隐层权重的更新.每个残差块都能有效捕捉和学习到上一层输出的特征信息,帮助网络更高效地进行训练.其结构信息如图5所示.

ResNet残差构建块中输入 X_i 与输出 Y 的映射关系定义为:

$$Y = F(X_i, W_i) + X_i, \quad (10)$$

式中: $F(\cdot)$ 为要学习的残差映射; W_i 为第 i 个卷积层的参数.图5描绘了两个卷积层,与传统CNN相比,ResNet学习残差映射而不是直接映射,这使深度残差网络易于优化.

3 模型结构与判断流程

3.1 模型基本结构

为了有效提取呼吸信号的特征信息,提高呼吸暂停判断模型的准确率和效率,本文构建了1D-Res&SENet呼吸暂停判断模型,如图6所示.

由图6模型结构可以观察到,为降低模型的计算量,总共设置了三个卷积层,分别含有3、50、30个滤波器,

三层卷积层的卷积核大小 K 分别设置为 100、10 和 30, 填充值 P 为 0, 步长 S 为 2, 不同尺寸卷积核设计旨在捕获多尺度特征: 大核(尺寸 100)关注全局特征与低频趋势; 中核(尺寸 30)提取中尺度特征信息; 小核(尺寸 10)聚焦局部细节与高频变化. 为降低计算复杂度和提升效率, 在每个卷积层后均添加了最大池化层, 通过下采样实现维度压缩. 在第二层与第三层卷积层间引入残差连接, 以促进跨层信息流, 缓解梯度消失, 增强特征复用, 从而提升模型性能. 在第三层卷积层后集成 SENet 模块, 自适应地重标定通道权重, 引导模型关注更显著的特征, 具体参数如表 1 所示, 其中: F 为输出通道数, I 为输入特征维度, O 为输出特征维度.

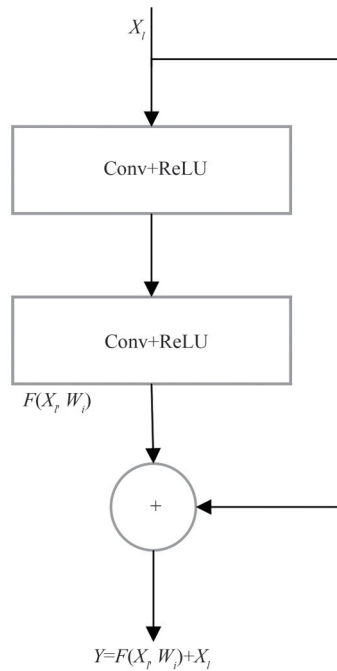


图 5 残差网络构建

Figure 5 Construction of residual network

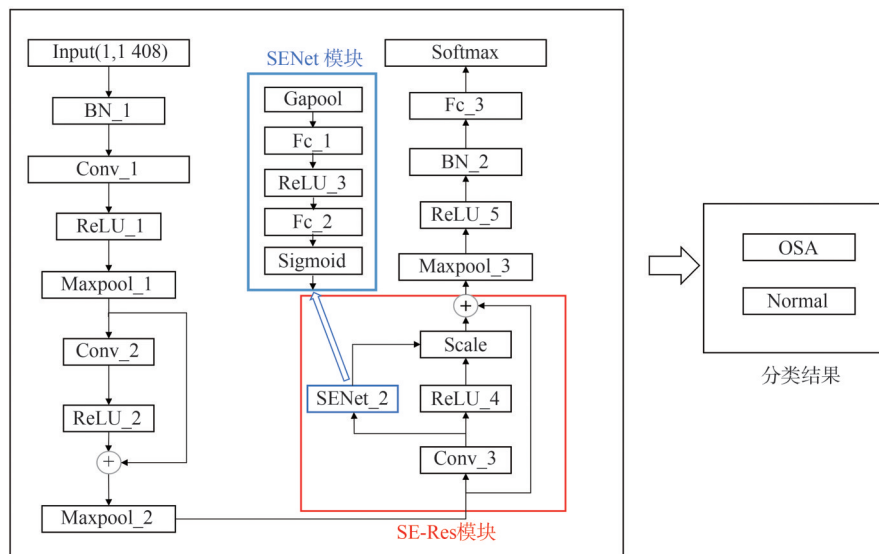


图 6 1D-Res&SENet 网络模型

Figure 6 1D-Res&SENet network model

3.2 模型判断流程

本文使用准确率(Accuracy)、召回率(Recall)和特异性(Specificity)作为模型的评价标准. 流程如图 7 所示, 具体步骤如下:

- 1) 提取数据库中的第八通道(胸腔位移)信号,打标签制作数据集,将数据集分为训练集、验证集和测试集.
- 2) 搭建 1D-Res&SENet 网络模型,利用 Xavier 算法^[19]随机初始化模型参数. 这种初始化方式能够在保持激活函数的方差在前向传播和反向传播过程中大致相同,从而避免梯度消失或梯度爆炸的问题,确保模型的正常训练.
- 3) 开启模型训练,利用反向传播算法更新模型的参数和梯度,并在此基础上应用 BP 算法进行监测,以优化各层的网络参数.
- 4) 利用验证集评估模型性能,并根据验证集的分类结果调整本模型的参数,进一步优化模型,对结果作评估,如果模型收敛,则进行下一步,否则返回上一步.
- 5) 基于测试集测试 1D-Res&SENet 网络模型性能,计算准确率、召回率和特异性.

表 1 模型参数设置

Table 1 Model parameter settings

模型层	参数	模型层	参数
Conv_1	$F=3, K=100, S=2, P=0$	Maxpool_3	$S=2, P=2$
Maxpool_1	$S=2, P=2$	Fc_1	$I=30, O=3$
Conv_2	$F=50, K=10, S=2, P=0$	Fc_2	$I=3, O=30$
Maxpool_2	$S=2, P=2$	Fc_3	$I=4\ 890, O=2$
Conv_3	$F=30, K=30, S=2, P=0$		

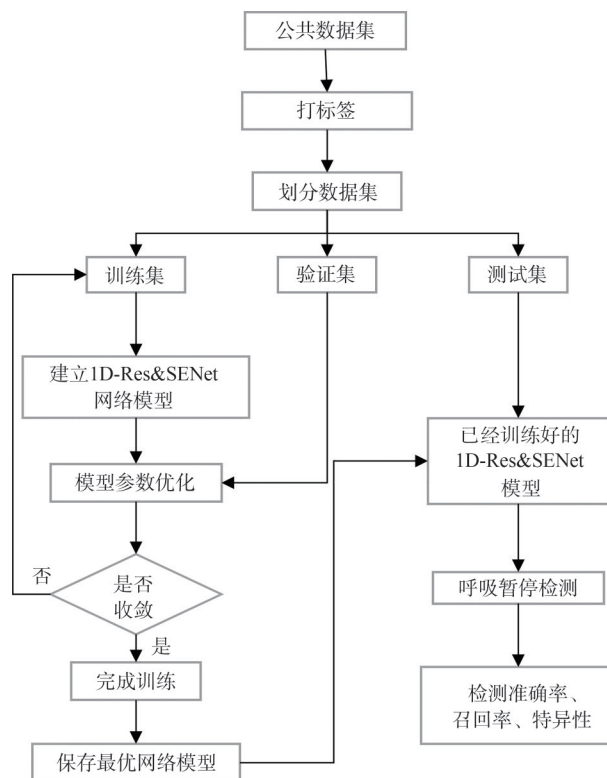


图 7 模型判断流程

Figure 7 Process of model judgment

4 试验验证

4.1 试验数据集

文献[20]中比较了毫米波雷达设备和传统 PSG 在诊断阻塞性睡眠呼吸暂停中的等效性,二者在 AHI 指数上的 Pearson 相关性为 0.987 2. 为验证本文所提呼吸暂停检测方法的有效性,使用 UCD 睡眠呼吸暂停数据

库^[12],该数据库中记录了25例患者的PSG多导睡眠图,提取数据集中第八通道信号的胸腔位移信号代替毫米波雷达采集的呼吸信号.

按照图8所示的11 s滑动窗口对信号进行截取,如果10 s内患者未进行呼吸活动,将此事件归类为呼吸暂停;根据窗口第2 s是呼吸暂停还是非呼吸暂停,为窗口分配标签.




图8 滑动窗口

Figure 8 Sliding window

每个呼吸样本数据为11 s,采样频率为128 Hz,总共1 408个点,依据睡眠专家提供的标签标记为呼吸暂停与非呼吸暂停,通过对少数类(睡眠呼吸暂停事件)进行过采样来平衡训练集.除了患者ucddb008、ucddb011、ucddb013和ucddb018没有任何呼吸暂停事件记录,患者ucddb002未记录呼吸信号以外,其余患者记录均被使用.

为避免数据泄露,采用基于患者的分割策略:将20例患者按8:1:1的比例分配至训练集(16例)、验证集(2例)和测试集(2例),确保同一患者的数据仅出现在一个子集中.测试集中共划分52 465个样本,验证集中划分了52 432个样本,训练集在划分样本的基础上对少数类进行采样,使用“datasample”对少数类进行随机采样,生成与多数类数量相同的样本,并将上采样后的数据合并,训练集中共计817 234个样本,“OSA”样本数和“Normal”样本比例为1:1.

4.2 试验环境、超参数设置

试验环境:硬件平台为配备NVIDIA GeForce RTX 4070 GPU与Intel Core i7-13700HX处理器(2.10 GHz)的计算工作站.软件平台基于Python 3.7.10和PyTorch-GPU 1.11深度学习框架.

超参数设置:训练轮次(Epochs)为100;初始学习率(Learning Rate)为0.001;优化器采用Adam;损失函数选用标准交叉熵损失(Cross-Entropy Loss)处理分类任务.训练过程涵盖超参数优化、模型迭代训练及验证评估.

4.3 试验结果及对比分析

为验证本文所提方法的有效性,分别建立了单一1D-CNN模型、1D-CNN-SE模型、1D-CNN-Res模型和1D-Res&SENet模型,设置相同的输入参数,使用这些模型在完整的训练集上进行训练,同时每个epoch的验证集上进行验证.模型1D-Res&SENet在测试集上的混淆矩阵如图9所示,横坐标表示预测标签,纵坐标表示实际标签,实际为OSA且预测为OSA的有50 551例,实际为Normal且预测为Normal的有1 353例.

由于呼吸暂停检测是一个二分类问题,本模型使用准确率、召回率和特异性作为模型的评价标准.准确率是指所有预测中,模型分类正确的样本所占比例,准确率越高表示模型的分类效果越好;召回率是指模型关注正样本(呼吸暂停)的能力,召回率越高表示识别呼吸暂停事件的能力越强;特异性表示模型在所有负样本中,正确预测为负样本的比例.各评价指标的计算公式为:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN}, \quad (11)$$

$$Recall = \frac{TP}{TP + FN}, \quad (12)$$

$$Specificity = \frac{TN}{TN + FP}, \quad (13)$$

式中:TP表示样本被模型预测为正样本且样本实际标签也是正样本;TN表示被模型预测为负样本且实际标签

也是负样本;FP表示被模型预测为正样本但实际标签是负样本;FN表示被模型预测为负样本但实际标签是正样本^[21]. 模型评价指标对比结果如表2所示.




图 9 1D-Res&SENet模型在测试集上的混淆矩阵

Figure 9 The confusion matrix of the 1D-Res&SENet model on the test dataset

表 2 各模型评价指标对比

Table 2 Comparison of evaluation indexes of each model

模型	准确率/%	召回率/%	特异性/%
1D-CNN	96.9	91.9	97.1
1D-CNN-SE	98.1	91.8	98.3
1D-CNN-Res	98.2	86.5	98.5
1D-Res&SENet	98.9	96.8	99.0

由表2可知,相比1D-CNN,引入残差网络和SENet模块后,模型的准确率、召回率和特异性均有提升. 模型中加入的SENet模块,通过压缩操作和激励操作对不同的通道特征进行加权,帮助模型根据通道贡献更好地关注重要通道,其准确性和特异性上升明显;结合残差网络模块,可以减少低级特征信息丢失,但召回率出现大幅下降,表明残差结构引入了冗余特征,干扰了正类识别. 相比其他3种模型,Res&SENet模型的召回率显著提升了4.9、5.0和10.3个百分点,表明漏检情况减少,即更多的呼吸暂停事件被正确识别,模型对目标正样本更加敏感,在医学判断中,这能够帮助发现潜在风险,更好地辅助确诊. 模型的其余2个指标也均有提升,证明了残差模块和SENet模块的互补性,残差网络强化特征表达深度,SENet优化特征选择精度,二者结合,在保持高特异性(负样本排除能力)的同时,显著提升召回率(正样本识别能力),达到综合性能最优,适用于兼顾敏感性与特异性的任务(如疾病诊断).

表3对比了本文方法与其他方法给出的各项指标,可以观察到1D-Res&SENet在准确率与召回率上优于现有方法. Yang等^[22]和Erdenebayar等^[23]分别利用CNN、DNN方法进行呼吸暂停检测,但其结构缺乏高效的注意力机制与深层网络优化策略,难以充分建模呼吸信号中复杂的局部特征依赖与长程全局关联性,限制了性能的进一步提升;而Zarei等^[24]提出的CNN-LSTM虽然结合了时序建模,但是由于LSTM对长序列依赖性捕捉不足,导致召回率(90.7%)偏低,存在漏检风险;Tanvir等^[25]构建的CNN-BiLSTM模型结合了双向LSTM以增强时序建模能力,但该结构参数量庞大,在有限数据下易发生过拟合. 综上所述,本文提出的1D-Res&SENet模型通过融合残差结构与注意力机制,在呼吸暂停检测任务中实现了高精度、高召回率和高特异性的平衡,为基于非接触式毫米波雷达的呼吸暂停检测提供了高精度、高鲁棒性的解决方案,在提升医疗诊断效率与可靠性方面具有显著潜力.

表3 各方法指标比较

Table 3 Comparison of indicators of each method

文献	方法	准确率/%	召回率/%	特异性/%
Yang 等 ^[22]	CNN	90.3	87.0	91.9
Erdenebayar 等 ^[23]	DNN	93.1	93.0	99.0
Zarei 等 ^[24]	CNN-LSTM	93.7	90.7	95.8
Tanvir 等 ^[25]	CNN-BiLSTM	93.2	91.7	93.8
本文	1D-Res&SENet	98.9	96.8	99.0

目前,本文仅针对呼吸暂停的检测进行了研究,而呼吸异常还包括多种类型,如呼吸过深、呼吸过缓、呼吸过速,以及因疾病引发的潮式呼吸等复杂模式,其特征更为多样。未来研究将致力于探索更合适的模型,以更精确处理这些复杂的呼吸模式,从而实现高精度的呼吸模式分类。

5 结论

本文基于深度学习的一维卷积神经网络、残差网络结构和注意力机制,提出了一种1D-Res&SENet的呼吸暂停检测方法,通过数据集对不同模型的训练,比较模型的评价指标,试验表明:加入SENet模块可以建立通道自适应校准机制,显著增强关键特征表达能力;残差结构通过跨层连接有效缓解了梯度消失和网络退化的问题,模型准确率提升至98.9%,召回率与特异性分别达到96.8%和99.0%,较基准1D-CNN提升2.0%。

参考文献:

- [1] 缪冬玉. 基于连续波雷达的呼吸模式分类技术研究[D]. 南京:南京理工大学,2017.
Miao D Y. Research on respiratory pattern classification techniques based on continuous wave radar[D]. Nanjing: Nanjing University of Science and Technology, 2017. (in Chinese)
- [2] 姜潇,丛舒,杨森,等. 中国居民慢性呼吸道症状流行情况及其影响因素分析[J]. 中华流行病学杂志, 2022, 43(3): 315-323.
Jiang X, Cong S, Yang M, et al. Prevalence of chronic respiratory symptoms and dyspnea and related factors in residents in China[J]. Chinese Journal of Epidemiology, 2022, 43(3): 315-323. (in Chinese)
- [3] Bubu M O. Assessing the impact of adequate OSA treatment on markers of sleepiness related to cognition and AD pathology among *Black* and *Hispanic* subjects[J]. *Alzheimer's & Dementia*, 2024, 20(S8): e095587.
- [4] 中国医师协会睡眠医学专业委员会,中国医师协会神经内科医师分会睡眠学组. 中国成人失眠共病阻塞性睡眠呼吸暂停诊治指南(2024版)[J/OL]. 中国全科医学, 2024-11-28. <https://link.cnki.net/urlid/13.1222.R.20241128.0955.002>.
Sleep Medicine Group, China Neurologist Association, Chinese Academy Society of Sleep Medicine, Chinese Medical Doctor Association. Chinese Guideline for Diagnosis and Treatment of Co-morbid Insomnia and Sleep Apnea (2024)[J/OL]. Chinese General Practice, 2024-11-28. <https://link.cnki.net/urlid/13.1222.R.20241128.0955.002>. (in Chinese)
- [5] 祁富贵,张华,李盛,等. 一种基于小波信息熵的非接触呼吸暂停检测技术研究[J]. 医疗卫生装备, 2015, 36(4): 1-4.
Qi F G, Zhang H, Li S, et al. Study on technique for non-contact detection of apnea based on wavelet information entropy[J]. Chinese Medical Equipment Journal, 2015, 36(4): 1-4. (in Chinese)
- [6] John A, Cardiff B, John D. A 1D-CNN based deep learning technique for sleep apnea detection in IoT sensors New York: [C]// 2021 IEEE International Symposium on Circuits and Systems (ISCAS), Daegu, Korea. New York: IEEE, 2021: 1-5.
- [7] 张大可,马隽,王立英,等. 基于粒子群优化-支持向量机的睡眠呼吸暂停检测[J]. 科学技术与工程, 2022, 22(33): 14644-14651.
Zhang D K, Ma J, Wang L Y, et al. Sleep apnea detection based on particle swarm optimization-support vector machine[J]. Science Technology and Engineering, 2022, 22(33): 14644-14651. (in Chinese)
- [8] Hou L X, Zhuang Y, Zhang H, et al. Time-hybrid OSAformer (THO): A hybrid temporal sequence transformer for accurate detection of obstructive sleep apnea via single-lead ECG signals[J]. *Computer Methods and Programs in Biomedicine*, 2025, 206: 108558.
- [9] Bhongade A, Gandhi K T, Prathosh A P. Automatic identification of obstructive sleep apnea using multimodal features[J]. *Bio-*

- medical Signal Processing and Control, 2025, 105: 107609.
- [10] Wu S, Yao S, Liu W, et al. Study on a novel UWB linea array human respiration model and detection method[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2016, 9(1): 125-140.
- [11] 沈建飞, 陈益强, 谷洋. 基于时频信息融合网络的非干扰呼吸检测方法[J]. 高技术通讯, 2020, 30(10): 998-1009.
Shen J F, Chen Y Q, Gu Y. Non-contact respiratory detection based on time and frequency fusion network[J]. High Technology Letters, 2020, 30(10): 998-1009. (in Chinese)
- [12] Goldberger A, Amaral L, Glass L, et al. PhysioBank, PhysioToolkit and PhysioNet: Components of a new research resource for complex physiologic signals[J/OL]. PhysioNet, 2022, 101(23): e215-e220.
- [13] 胡博文, 扈国华, 常浩. 基于毫米波雷达的呼吸检测与分类算法研究[J]. 电气自动化, 2023, 45(6): 86-88.
Hu B W, Shu G H, Chang H. Research on breath test & classification algorithm based on millimetre-wave radar[J]. Electrical Automation, 2023, 45(6): 86-88. (in Chinese)
- [14] 田哲嘉. 基于毫米波雷达的高可靠呼吸与心率提取算法的设计与实现[D]. 西安: 西安理工大学, 2021.
Tian Z J. Design and implementation of highly reliable respiration and heart rate extraction algorithm based on millimeter wave radar[D]. Xi'an: Xi'an University of Technology, 2021. (in Chinese)
- [15] 荆东星, 陈杨晖, 全哲. 基于1D-CNN和SWLSTM的风电轴承故障诊断方法[J]. 机械强度, 2023, 45(6): 1309-1317.
Jing D X, Chen Y H, Quan Z. Wind turbine rolling bearing fault diagnosis method based on 1D-CNN and SWLSTM[J]. Journal of Mechanical Strength, 2023, 45(6): 1309-1317. (in Chinese)
- [16] 蒲姗姗, 郑恩让, 陈蓓. 基于1D-CNN的红外光谱分类算法研究[J]. 光谱学与光谱分析, 2023, 43(8): 2446-2451.
Pu S S, Zheng E R, Chen B. Research on a classification algorithm of near-infrared spectroscopy based on 1D-CNN[J]. Spectroscopy and Spectral Analysis, 2023, 43(8): 2446-2451. (in Chinese)
- [17] Hu J, Shen L, Sun G, et al. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Daegu, Korea. New York: IEEE, 2018: 7132-7141.
- [18] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA. New York: IEEE, 2016: 770-778.
- [19] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks[C]//Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics. Sardinia: JMLR Workshop and Conference Proceedings, 2010: 249-256.
- [20] 李晨洋, 王威, 黄炜峻, 等. 新型雷达设备诊断阻塞性睡眠呼吸暂停: 一项评价与多导睡眠监测等效性的平行对照研究[J]. 中华耳鼻咽喉头颈外科杂志, 2024, 59(8): 857-863.
Li C Y, Wang W, Huang W J, et al. Diagnosis of obstructive sleep apnea by a new radar device: A parallel controlled study evaluating agreement with polysomnographic monitoring[J]. Chinese Journal of Otorhinolaryngology and Head and Neck Surgery, 2024, 59(8): 857-863. (in Chinese)
- [21] 郭梦琦. 基于生命体征雷达的呼吸异常辨识技术研究[D]. 南京: 南京理工大学, 2021.
Guo M Q. Research on respiratory abnormality detection technology based on vital signs radar[D]. Nanjing: Nanjing University of Science and Technology, 2021. (in Chinese)
- [22] Yang Q A, Zou L, Wei K M, et al. Obstructive sleep apnea detection from single-lead electrocardiogram signals using one-dimensional squeeze-and-excitation residual group network[J]. Computers in Biology and Medicine, 2022, 140: 105124.
- [23] Erdenebayar U, Kim J Y, Park J, 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.
- [24] Zarei A, Beheshti H, Asl B M. Detection of sleep apnea using deep neural networks and single-lead ECG signals[J]. Biomedical Signal Processing and Control, 2022, 71: 103125.
- [25] Tanvir M, Ahmed I K, Ibn T M, et al. Sleep apnea detection from variational mode decomposed EEG signal using a hybrid CNN-BiLSTM[J]. IEEE ACCESS, 2021, 9: 102355-102367.

责任编辑: 岳荣强