

基于毫米波雷达微动信号和脉搏波数据融合的睡眠呼吸暂停 低通气综合征筛查技术

赵翔^① 王威^① 李晨洋^② 关建^② 李刚^{*①}

^①(清华大学电子工程系 北京 100084)

^②(上海交通大学医学院附属第六人民医院耳鼻咽喉头颈外科上海市睡眠呼吸障碍
疾病重点实验室 上海 200233)

摘要: 睡眠呼吸暂停低通气综合征(SAHS)是一种常见的慢性睡眠呼吸障碍疾病,严重影响患者的睡眠质量和身体健康。该文提出了一种基于多源信号融合的睡眠呼吸暂停与低通气检测框架,通过融合毫米波雷达微动信号与光电容积脉搏波描记法(PPG)的脉搏波数据,实现高可靠的轻接触式睡眠呼吸暂停低通气综合征的诊断,以解决传统医学上依赖多导睡眠图(PSG)进行睡眠监测时舒适度差、成本高等缺点。研究中,为兼顾睡眠呼吸异常事件检测的准确率和鲁棒性,该文提出了一种雷达、脉搏波数据预处理算法得到信号中的时频信息和人工特征,并设计了用于将两类信号融合的深度神经网络,以实现睡眠呼吸暂停和低通气事件的精准识别,从而估算呼吸暂停低通气指数(AHI),用于对患者的睡眠呼吸异常严重程度进行定量评估。基于上海交通大学医学院附属第六人民医院临床试验数据集的实验结果表明,该文所提方案估算的AHI与金标准PSG的相关系数达到了0.93,一致性良好,有潜力普及成为家用睡眠呼吸监护的工具,并起到睡眠呼吸暂停低通气综合征初步筛查的作用。

关键词: 毫米波雷达; 光电容积脉搏波; 多源信号融合; 深度神经网络; 睡眠呼吸暂停低通气综合征; 呼吸暂停低通气指数

中图分类号: TP391.4

文献标识码: A

文章编号: 2095-283X(2024)x-0001-16

DOI: 10.12000/JR24107

引用格式: 赵翔, 王威, 李晨洋, 等. 基于毫米波雷达微动信号和脉搏波数据融合的睡眠呼吸暂停低通气综合征筛查技术[J]. 雷达学报(中英文), 待出版. doi: 10.12000/JR24107.

Reference format: ZHAO Xiang, WANG Wei, LI Chenyang, *et al.* Diagnosis of sleep apnea hypopnea syndrome using fusion of micro-motion signals from millimeter-wave radar and pulse wave data[J]. *Journal of Radars*, in press. doi: 10.12000/JR24107.

Diagnosis of Sleep Apnea Hypopnea Syndrome Using Fusion of Micro-motion Signals from Millimeter-wave Radar and Pulse Wave Data

ZHAO Xiang^① WANG Wei^① LI Chenyang^② GUAN Jian^② LI Gang^{*①}

^①(Department of Electronic Engineering, Tsinghua University, Beijing 100084, China)

^②(Department of Otorhinolaryngology Head and Neck Surgery, Shanghai JiaoTong University school of medicine
Affiliated Sixth People's Hospital, Shanghai Key Laboratory of Sleep Disordered Breathing,
Shanghai 200233, China)

收稿日期: 2024-05-30; 改回日期: 2024-09-05; 网络出版: 2024-xx-xx

*通信作者: 李刚 gangli@mail.tsinghua.edu.cn *Corresponding Author: LI Gang, gangli@mail.tsinghua.edu.cn

基金项目: 国家杰出青年科学基金(61925106)

Foundation Item: The National Science Fund for Distinguished Young Scholars(61925106)

责任编辑: 洪弘 Corresponding Editor: HONG Hong

©The Author(s) 2024. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

Abstract: Sleep Apnea Hypopnea Syndrome (SAHS) is a common chronic sleep-related breathing disorder that affects individuals' sleep quality and physical health. This article presents a sleep apnea and hypopnea detection framework based on multisource signal fusion. Integrating millimeter-wave radar micro-motion signals and pulse wave signals achieves a highly reliable and light-contact diagnosis of SAHS, addressing the drawbacks of traditional medical methods that rely on PolySomnoGraphy (PSG) for sleep monitoring, such as poor comfort and high costs. This study used a radar and pulse wave data preprocessing algorithm to extract time-frequency information and artificial features from the signals, balancing the accuracy and robustness of sleep-breathing abnormality event detection. Additionally, a deep neural network was designed to fuse the two types of signals for precise identification of sleep apnea and hypopnea events, and to estimate the Apnea Hypopnea Index (AHI) for quantitative assessment of sleep-breathing abnormality severity. Experimental results of a clinical trial dataset at Shanghai Jiao Tong University Affiliated Sixth People's Hospital demonstrated that the AHI estimated by the proposed approach correlates with the gold standard PSG with a coefficient of 0.93, indicating good consistency. This approach is a promising tool for home sleep-breathing monitoring and preliminary diagnosis of SAHS.

Key words: Millimeter-wave radar; Photoplethysmography; Multimodal signal fusion; Deep neural network; Sleep apnea hypopnea syndrome; Apnea hypopnea index

1 引言

睡眠呼吸暂停低通气综合征(Sleep Apnea and Hypopnea Syndrome, SAHS)是一种常见的睡眠呼吸障碍疾病^[1,2]。呼吸暂停的类型可分为两类:由睡眠过程中发生的完全性上气道阻塞产生的阻塞性睡眠呼吸暂停和由呼吸中枢驱动消失所引起的中枢性睡眠呼吸暂停^[3,4]。呼吸暂停事件伴有打鼾、睡眠结构紊乱、动脉血氧饱和度下降、心跳加速、睡眠片段化和反复觉醒等一系列病理综合征^[5]。传统医学上SAHS诊断的金标准是多导睡眠图(Polysomnography, PSG),如图1(a)所示。专业医师通过观察呼吸气流和血氧信号进行睡眠呼吸事件的判读:满足呼吸气流幅度下降 $\geq 90\%$ 且持续时间 ≥ 10 s则判读为呼吸暂停;满足呼吸气流幅度下降 $\geq 30\%$ 且持续时间 ≥ 10 s,并伴随血氧饱和度较基线值下降 $\geq 3\%$ 或伴随觉醒则判读为低通气事件。在临床诊断中,专业医师依据受试者整晚睡眠判读结果统计得到呼

吸暂停低通气指数(Apnea-Hypopnea Index, AHI)来对SAHS的严重程度进行分级^[6]。

PSG中要求穿戴多种管线和胸腹带会给受试者带来很多生理负荷且检测成本很高,因此应用PSG普及睡眠呼吸障碍筛查难以实现。无论医疗场景还是居家环境,都需要一种无创、舒适且高效的PSG检测替代方案,以实现受试者的睡眠呼吸长期监测。

初期研究表明,心电图(Electrocardiogram, ECG)中提取的心率变异性等特征与呼吸事件的出现高度相关^[7,8]。但ECG信号采集复杂度高,脉搏波作为ECG的替代信号,具备无创式且便携性好等特点,基于单一脉搏波信号进行睡眠呼吸事件检测被视为一种更简便的检测方案。Karmakar等人^[9]验证了通过脉搏波信号的脉冲幅度、脉搏间期等手工特征来检测睡眠呼吸事件的可行性。Lazazzera等人^[10]利用一分钟片段内脉搏波的能量波幅的下降

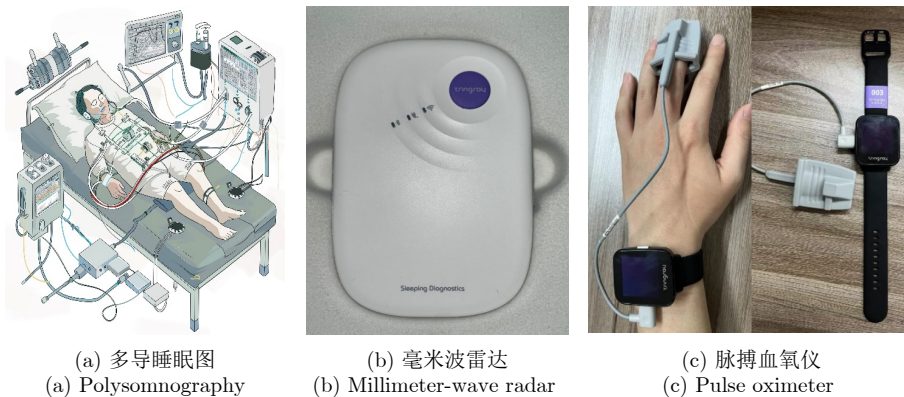


图1 医疗设备图

Fig. 1 Medical device diagram

和脉率变异等特征，在采集到的96条睡眠数据上进行呼吸事件的检测，达到了75%的准确率。初期简化睡眠呼吸检测的研究主要建立在特征工程和传统机器学习的基础上^[11,12]。近年来深度学习也被应用于SAHS的检测，如Papini等人^[13]通过深度学习算法自动获取脉搏波信号中的心肺和呼吸信息，以实现无侵入的睡眠呼吸暂停低通气指数的估计。Zou等人^[14]在92名受试者的数据集上，以分钟级的脉搏波信号片段为输入，训练了一个一维多尺度双向时间卷积神经网络，实现了在分钟级片段上事件有无的检测并对受试者SAHS的严重程度进行分级。

不少研究者希望引入与呼吸更为相关的口鼻气流信号或胸腹位移信号提升睡眠呼吸事件检测的性能。然而，传统气流监测导管、胸带和腹带都会给受试者造成很大的不适。雷达传感器对微运动敏感性高、隐私性好，并且由于其能够实现非接触式感知人体生命体征、精准捕捉由呼吸引起的胸腔运动，使得近年来雷达在睡眠监测这一前沿领域正逐渐受到关注^[15,16]。Lee等人^[17]使用2.4 GHz连续波雷达采集了人体呼吸的雷达微动信号，指出重建的胸部位移信号和真实胸部位移具有较好的相关性，并提取了受试者的呼吸频率。Kang等人^[18]在睡眠实验室同时采集了94位受试者的PSG数据与超宽带雷达微动数据，通过解卷绕算法重建胸部位移信号，并以峰值幅度下降 $\geq 30\%$ 作为异常呼吸判定的标准，实验中验证了雷达与PSG测定的睡眠呼吸暂停低通气指数具有较高的一致性。但基于解卷绕的传统方法在实际环境中容易受到环境干扰，特别是当人体出现大幅体动的时候容易出现解卷绕错误，从而影响检测效果^[19]。随着深度学习算法的不断发展，其在雷达睡眠呼吸事件检测领域也得到了广泛的应用。Kwon等人^[20]以在睡眠实验室环境下36人的PSG人工标注数据为标签，并以6.5~8.0 GHz频率的超宽带雷达的时间-距离像为输入，训练了一个卷积-长短期记忆神经网络混合模型(Convolutional Neural Networks-Long Short Term Memory, CNN-LSTM)，实现了端到端的睡眠呼吸事件二分类检测。

现有研究中依赖于脉搏波信号上伴随呼吸事件出现的血氧下降、脉率变异等生理特征，虽能进行呼吸事件有无的检测，但这些特征在时间上会与呼吸事件的出现存在一定的延迟，很难实现对呼吸事件的精准定位^[6]。同时，脉搏波信号容易受到心律不齐类型疾病的影响导致检测失准^[21]。雷达传感器通过获取胸腹位移的幅度相对变化和伴随呼吸事件出现的微动信息能够灵敏地检测到呼吸暂停事件的

出现。但雷达受限于无法获取受试者的血氧信息，对于持续时间更长且胸腹位移的幅度变化更为微弱的低通气事件检测性能不佳^[22]。基于脉搏波信号或雷达信号进行睡眠呼吸事件检测的研究，主要集中在对切割成分钟级的信号片段进行事件有无的检测并估算AHI^[23]。然而AHI作为SAHS严重程度分级的重要指标，无法提供具体的呼吸事件类型、持续时间和事件的分布等重要的生理信息。专业医师在判读低通气事件时需要综合分析呼吸气流信号和血氧信号，而雷达与脉搏波都只能提供单一维度的信息，通过将二者融合进行睡眠呼吸事件检测可以在秒级粒度下实现更高可靠的检测性能^[24]。

由于原始的雷达时间-距离像和脉搏波时序数据在维度上差异过大，无法直接进行有效融合。首先，本文通过设计有效的预处理算法，对信号进行手工特征提取，引入一维时序特征信号提升模型在面对复杂睡眠环境时的鲁棒性和适应性，并通过时频分析的处理得到二维谱图信号，以解决多模态数据难以直接进行融合的问题。其次，设计了多尺度卷积深度神经网络以充分提取信号的时序特征，并引入通道注意力机制融合雷达信号和脉搏波信号中的信息，以提升网络对呼吸事件的检测性能，最终实现秒级粒度的睡眠呼吸暂停与低通气事件的检测和分类。

2 信号采集和预处理

本文中的所有数据均来自2023年7月至2023年9月在上海交通大学医学院附属第六人民医院进行的临床试验，试验伦理遵守《赫尔辛基宣言》和《医疗器械临床试验质量管理规范》。试验开展前通过了上海市第六人民医院伦理委员会的审批(2023-030-[1])，且研究已在美国临床试验注册中心注册(序列号：NCT06038006)。本文中进行信号采集的场景如图2所示，雷达安装在床头，保证受试者全身尽量处在距离雷达0.5~3 m的区间内，采用如图1所示的60 GHz调频连续波(Frequency Modulated Continuous Wave, FMCW)雷达、脉

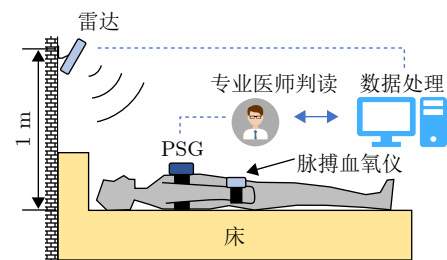


图2 实验数据采集场景示意图

Fig. 2 Schematic diagram of data collection scene

搏血氧仪和PSG作为数据采集设备,并由专业医师基于PSG信号,依据《美国睡眠医学学会睡眠和相关事件评分手册》进行呼吸事件的手动判读作为采集数据的睡眠标签金标准。

2.1 雷达信号预处理

本文中使用的FMCW雷达,使用过程中采用单发单收的模式,雷达设置的参数和计算所得的性能参数如表1所示。经检验,表1中参数完全满足睡眠过程中呼吸测量的需求。实验中雷达设备如图2所示安装于床头距离约1 m处,采取斜照式的方式以使得胸部、腹部等身体部位的微动都体现在不同的距离门上。

FMCW雷达周期性发射频率随时间线性增长的信号 $s_T(t)$ 称为Chirp信号,表示如下:

$$s_T(t) = Ae^{j(2\pi f_c t + \pi \frac{B}{T} t^2)} \quad (1)$$

其中, A 是幅度, f_c 是起始频率, B 和 T 分别是单个Chirp信号的带宽和持续时间。雷达视场内的第 i 个目标和雷达之间的距离为 R_i ,则接收天线获取该目标反射回来的回波信号 $r_i(t)$:

$$\begin{aligned} r_i(t) &= a_i s_T \left(t - \frac{2R_i}{c} \right) \\ &= a_i A e^{j \left(2\pi f_c \left(t - \frac{2R_i}{c} \right) + \pi \frac{B}{T} \left(t - \frac{2R_i}{c} \right)^2 \right)} \end{aligned} \quad (2)$$

其中, c 是光速, a_i 是第 i 个目标的反射系数。则将射频信号和回波信号经过混频处理输出的中频信号是 $b_i(t)$:

$$\begin{aligned} b_i(t) &= a_i A e^{j \left(4\pi \frac{BR_i}{cT} t + 4\pi \frac{f_c R_i}{c} + 4\pi \frac{R_i^2 B}{c^2 T} \right)} \\ &\approx a_i A e^{j \left(\underbrace{4\pi \frac{BR_i}{cT} t}_{f_i} + \underbrace{4\pi \frac{f_c R_i}{c}}_{\phi_i} \right)} \end{aligned} \quad (3)$$

其中, f_i 和 ϕ_i 是目标 i 相应中频信号的频率和相位。在雷达进行睡眠呼吸监测的过程中,由于呼吸使得目标 i 的反射面存在微动,即 $R_i(t) = R_i + d_i(t)$,其中 $d_i(t)$ 为该目标反射面的微动,该目标中频信号的相位 ϕ_i 受到 $d_i(t)$ 的影响,其关系为

表1 FMCW雷达基本参数

Tab. 1 Basic parameters of FMCW radar

起始频率 f_c	60 GHz
线性调频带宽 B	3 GHz
扫频周期 T	2 ms
快时间实际采样点数 N	256
快时间采样频率 f_s	1000 kHz
距离分辨率 ΔR	5 cm

$$\phi_i(t) = 4\pi \frac{R_i + d_i(t)}{\lambda} \quad (4)$$

其中, $\lambda = 5 \text{ mm}$ 是雷达信号的波长。人体呼吸时伴随着胸部、腹部上厘米级的生命体征微动会对各自距离门上的相位产生一定的影响,通过提取目标所在距离门上相位信号 $\phi_i(t)$ 便可获取人体睡眠时呼吸产生的胸腹位移信号^[25]。

本文雷达信号预处理流程如图3所示,主要包括以下几部分:

(1)设备端将FMCW雷达的发射信号 $s_T(t)$ 和回波信号 $r_T(t)$ 进行混频,输出中频信号 $b_T(t)$,并对多个Chirp的中频信号进行FFT变换,得到复数值距离-时间像 $R(r,t)$,其中 r 表示不同的距离门,距离分辨率 $\Delta R = 5 \text{ cm}$, t 表示时间。

(2)现有研究中直接以距离-时间像 $R(r,t)$ 作为输入会给网络引入一定的噪声干扰网络的训练。本文预处理算法中先对信号 $R(r,t)$ 沿着距离维进行截取,对应的实际监测范围是 $[6,60] \text{ cm} \times 5 \text{ cm}$,足够覆盖受试者床铺区域。再沿时间维度 t 进行低通滤波,设定上限截止频率为5 Hz,得到包含了呼吸信号主成分的低频分量 $R_L(r,t)$ 。再计算体动强度信号 $x_M(r,t)$:

$$x_M(r,t) = \frac{|R(r,t) - R_L(r,t)|}{\max_r |R_L(r,t)|} \quad (5)$$

其中,分母表示沿 $R_L(r,t)$ 距离维度取最大值,分子为包含了体动信号主成分的高频分量,通过除以不同时刻上低频分量的极值来抑制低频信号的高次谐波对体动能量的影响。再对信号 $R_L(r,t)$ 沿时间维度 t 进行高通滤波,下限截止频率设为0.1 Hz,滤除静态杂波得到主成分为呼吸分量的信号 $R_B(r,t)$,对 $R_B(r,t)$ 进行取模得到表征呼吸强度的信号 $x_B(r,t) = |R_B(r,t)|$,再利用 $x_B(r,t)$ 对 $R_B(r,t)$ 进行归一化处理,得到相位信息谱图 $x_p(r,t) = R_B(r,t)/x_B(r,t)$,对 $x_p(r,t)$ 进行相位提取并做前后差分运算得到表征人体胸腹等不同位置微动的呼吸多普勒 $x_D(r,t)$ 。

最后对体动强度 $x_M(r,t)$ 、呼吸强度 $x_B(r,t)$ 和呼吸多普勒 $x_D(r,t)$ 沿时间维度进行平滑处理并降采样到2 Hz。

(3)提取呼吸相位信号:首先利用表征呼吸强度的能量信号对相位谱图信号进行加权,并沿距离维求和得到 $b(t)$:

$$b(t) = \sum_r (x_B(r,t) \times x_p(r,t)) \quad (6)$$

再对信号 $b(t)$ 进行解卷绕得到呼吸相位信号 $B(t)$ 。

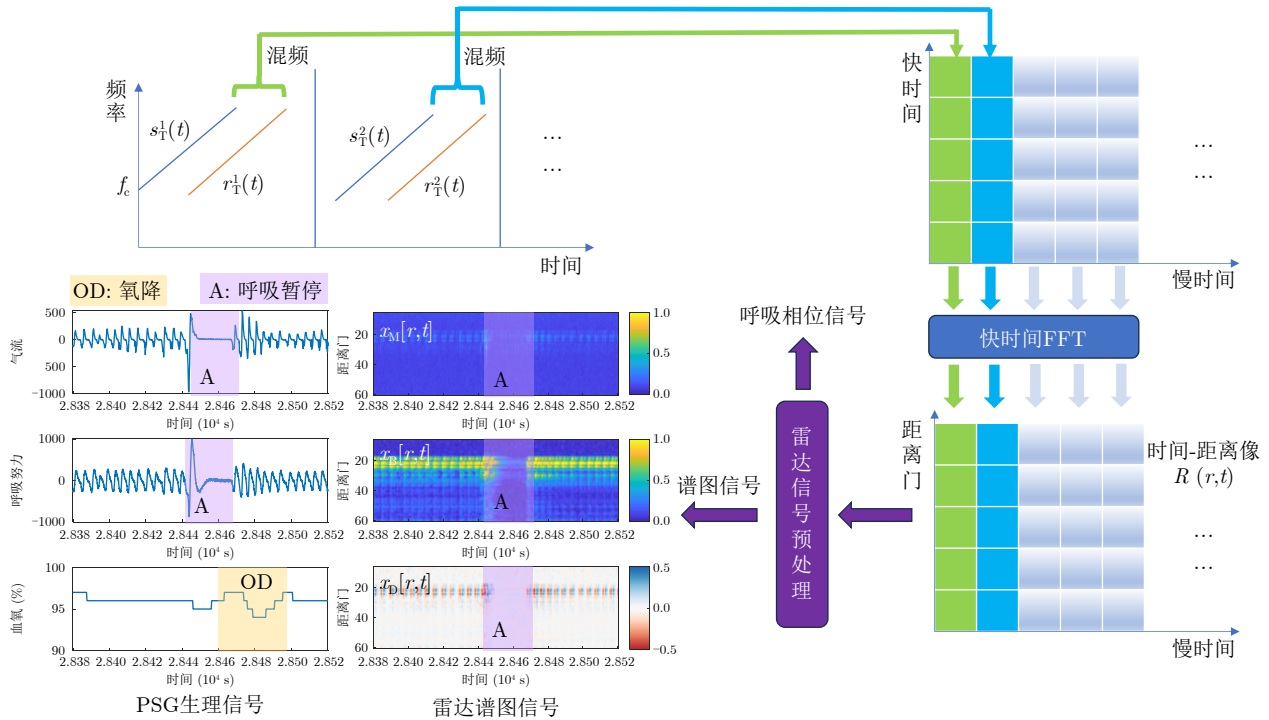


图 3 雷达信号处理流程

Fig. 3 Preprocessing flow for radar signal

相较于Javaid等人^[26]在实验室环境下的方法：仅对能量最强的单一距离门上的信号提取相位再进行前后差分运算，本文提取相位是通过能量对相位先加权再进行解卷绕提取，增强了算法在实际应用场景下提取呼吸相位的鲁棒性。

2.2 脉搏波信号预处理

光电容积脉搏波描记法(Photoplethysmography, PPG)作为一种监测各种心血管参数的非侵入性工具，以LED光源和探测器为基础，测量经过人体血管和组织反射、吸收后的衰减光，记录血管的搏动状态测量脉搏波^[27]。本文中采用的是外观如图1(c)所示的腕式脉搏血氧仪进行脉搏信息提取，具体参数如表2所示。

在本文中，脉搏波的处理流程如图4所示。以脉搏波信号 $P(t)$ 为输入，对其进行带通滤波处理得到滤波信号。对 $P_B(t)$ 进行脉搏间期提取得到 $R(t)$ ；对 $P_B(t)$ 进行短时傅里叶变换得到时频谱图 $P(f, t)$ ；

表 2 脉搏血氧仪基本参数

Tab. 2 Basic parameters of the pulse oximeter

红光波长	$660 \pm 3 \text{ nm}$
红外光波长	$905 \pm 10 \text{ nm}$
红光辐射功率	$3.2 \times 10^{-3} \text{ W}$
红外光辐射功率	$2.4 \times 10^{-3} \text{ W}$
采样频率	128 Hz

对 $P_B(t)$ 进行能量包络提取得到脉搏波能量包络信号 $X_e(t)$ 。脉搏波信号预处理中脉搏间期提取算法如算法1所示。在脉搏波间期提取算法中，根据Elgendi等人^[28]论文中参考值和实验经验选取 $T_1 = 0.111 \text{ s}$, $T_2 = 0.667 \text{ s}$ ，以适合本实验的实测数据。

2.3 预处理输出

预处理算法得到的二维谱图信号 $x_M(r, t)$, $x_B(r, t)$, $x_D(r, t)$, $P(f, t)$ 和一维时序信号 $B(t)$, $R(t)$, $X_e(t)$ 其物理意义分别如表3所示。图5展示了归一化后的时序信号和谱图信号以及睡眠呼吸暂停和低通气事件的标签，通过对比呼吸事件和信号特征可以发现他们之间存在一定的相关性：如图5中呼吸暂停事件(A)发生时，表征呼吸强弱的呼吸相位等特征有着明显的幅度下降的表现，同时与心率、血氧浓度相关的脉搏波信号的脉率和幅度也会存在相应的波动。相较于呼吸暂停事件，低通气事件(H)发生时，雷达和脉搏波表征呼吸的特征信号变化较弱，这也使得融合雷达和脉搏波数据在低通气事件的检测效果上优于单一的传感器检测。

以往的研究表明，上气道阻塞造成呼吸暂停或低通气事件时，大部分事件常终止于微觉醒，这类微觉醒并非自发，而与呼吸努力相关，当呼吸努力度达到觉醒阈值时，会导致微觉醒的发生^[29,30]。如图5中呼吸暂停结束时伴随的觉醒(W)所示。而发生低通气事件的呼吸努力度要低于阻塞型呼吸暂停

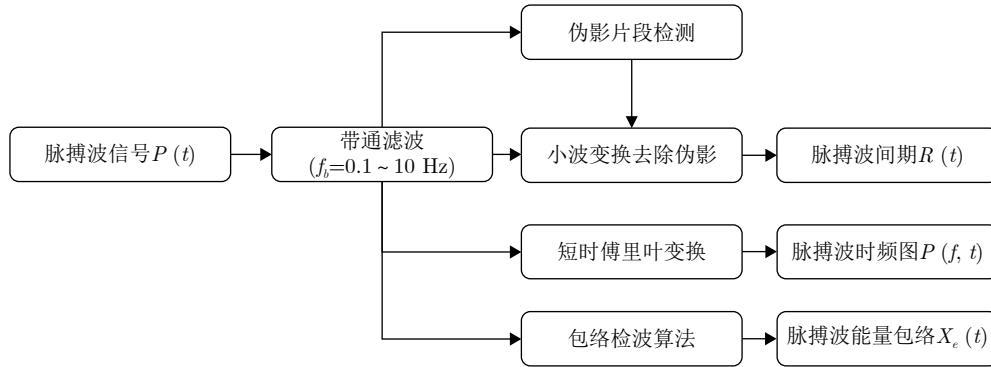


图4 脉搏波信号预处理流程

Fig. 4 Preprocessing algorithm flow for pulse wave

算法1 脉搏波间期提取算法

Alg. 1 Pulse wave interval extraction algorithm

输入：脉搏波滤波信号 $P_B(t)$

输出：脉搏波间期 $R(t)$

1. 将信号取平方，得到对应点的能量信号 $P_w(t)$
2. 以脉搏波收缩波的平均持续时间 T_1 为滑窗长度，对信号进行平滑以凸显收缩波，得到信号 $x_{\text{peak}}(t)$ 。
3. 以脉搏波的平均持续时间 T_2 为滑窗长度，对信号进行平滑以压缩舒张波，得到信号 $x_{\text{beat}}(t)$ 。
4. 利用信号 $x_{\text{beat}}(t)$ 与能量信号 $P_w(t)$ 加权求和得各个时刻阈值 $x_{\text{thr}}(t)$ 。
5. 比较信号 $x_{\text{peak}}(t)$ 和阈值 $x_{\text{thr}}(t)$ ，定位收缩波。
6. 寻找收缩波时间段内的最大的极值点作为收缩波的峰值点，从而确定脉搏波间期 $R(t)$ 。

表3 预处理输出及物理含义

Tab. 3 Preprocessing outputs and their physical significance

信号维度	信号特征名称及物理含义
二维 谱图信号	雷达信号体动强度 $x_M(r, t)$ ：表示受试者肢体运动、翻身等体动的强度
	雷达信号呼吸强度 $x_B(r, t)$ ：表示受试者呼吸运动的强度
	雷达信号呼吸多普勒 $x_D(r, t)$ ：表示受试者呼吸伴随的胸腹等部位微动
一维 时序信号	脉搏波信号的时频图 $P(f, t)$ ：表征受试者脉搏波的时频特征
	雷达呼吸-相位信号 $B(t)$ ：表示受试者胸腹位移
	脉搏波间期 $R(t)$ ：表征人体脉率，反映受试者心率快慢
	脉搏波能量包络 $X_e(t)$ ：表征脉搏波振动幅度，一定程度反映了血氧的高低

事件，其伴随觉醒出现的概率较低，引入体动强度信号以便网络也能够挖掘和利用觉醒等体动信息以检测和区分呼吸事件。脉搏波提供的体内生理信息与雷达提供的体外微动信息，二者信息互补，保证了基于雷达微动信号和脉搏波数据融合的睡眠呼吸暂停与低通气事件识别的可行性。

3 雷达信号与脉搏波信号融合检测算法

本节概述了雷达信号与脉搏波信号融合检测算法，并解释了一维和二维处理域的选择，图6展示了该框架的核心流程。

一维时序信号选择了传统算法中基于雷达或脉

搏波进行睡眠呼吸事件检测时常见的手工特征：雷达呼吸-相位信号 $B(t)$ 、脉搏波间期 $R(t)$ 和脉搏波能量包络 $X_e(t)$ 。这类手工特征信号的优点在于数据量小，可解释性高，并且在面对复杂的睡眠环境时具有更强的鲁棒性。

然而，对雷达传感器而言，依赖手工提取的一维呼吸-相位信号相较于原有的时间-距离像会有较大的信息损失。正如4.1.1节中一维时序信号、二维谱图信号与二者融合检测的对比实验结果所示，仅依赖于—维时序信号进行睡眠呼吸事件检测的性能劣于谱图信号。

二维谱图信号中使用了第2节中预处理得到的

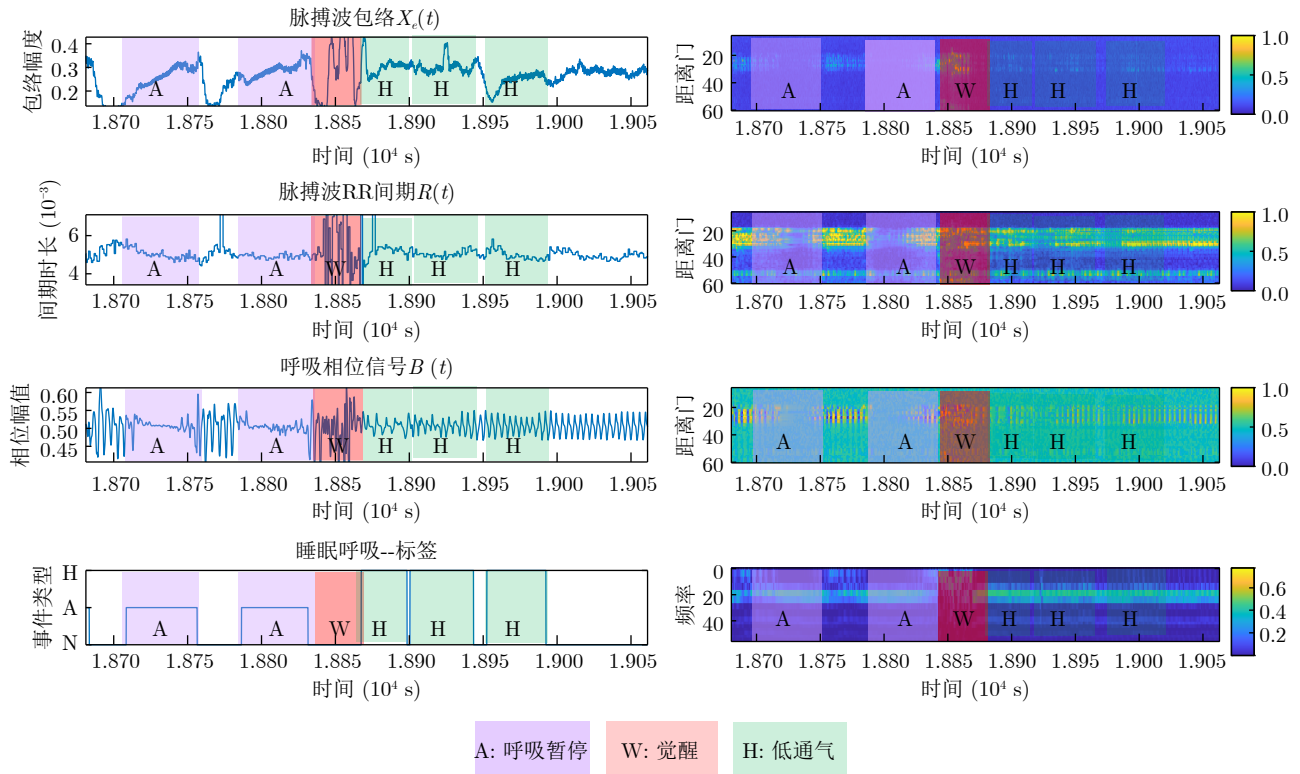


图 5 预处理结果可视化

Fig. 5 Visualization of preprocessing results




图 6 多源信号融合框图

Fig. 6 Multisource signal fusion diagram

体动强度 $x_M(r, t)$ 、呼吸强度 $x_B(r, t)$ 、呼吸多普勒 $x_D(r, t)$ 和脉搏波时频图 $P(f, t)$ 。二维谱图的融合使得单个样本中的雷达谱图数据量与脉搏波谱图数据量相近，有效地解决了不同模态数据维度差异过大而无法有效融合的问题。

3.1 二维谱图信号特征提取和融合模块

图7所示的二维谱图信号特征提取模块主要由CNN主干网络、注意力模块和多尺度特征提取模块组成。CNN主干网络的设计，目的在于采用二维卷积模块对谱图信息进行特征提取，并沿距离维进行压缩，生成不同时刻的高维特征向量，以避免姿态变化等非理想因素对呼吸强度 $x_B(r, t)$ 和呼吸多普勒 $x_D(r, t)$ 信号进行特征提取的干扰。具体的：包含低频呼吸分量的 $x_B(r, t)$ 和 $x_D(r, t)$ 沿着通道维度进行拼接后再输入二维卷积网络，并在特征提取之

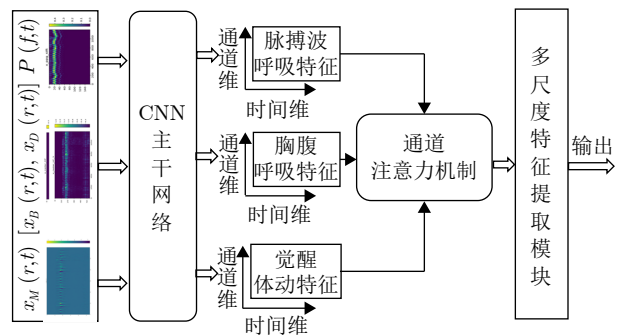


图 7 二维谱图信号特征提取和融合模块

Fig. 7 Module for signal feature extraction and fusion in 2D spectrogram

后，沿着距离维度进行压缩，将其压缩为尺寸是 $64 \times (2 \times 30 \times 60)$ 的特征信号，其中64是通道数， $(2 \times 30 \times 60)$ 是时间维长度。

经过CNN主干网络特征提取之后，可以得到

包含呼吸信息的脉搏波呼吸特征、胸腹位移呼吸特征和觉醒体动特征,为了将3类信息有效地融合起来,本文引入了与Hu等人^[31]网络工作中相似的注意力机制模块,具体的实现原理如图8所示。通过全局-池化层将全局信息压缩到通道上,再利用全连接和激活层为不同通道依据信息分配注意力权重,使得网络能够更好地融合从雷达和脉搏波中提取出的特征信号。利用注意力机制对雷达和脉搏波特征信号融合之后,再利用一维卷积核对通道进行降维,并设置卷积核宽度为2,步长为2,从而实现时间维度的降采样,最终得到尺寸为 $64 \times (1 \times 30 \times 60)$ 的特征信号,其中64是通道数,时间分辨率为1 Hz, 30×60 为样本时长。

专业医师在判读睡眠呼吸事件时,不仅依赖于PSG信号的局部信息,也会参考对应的上下文信息进行综合判断。为了网络在某时刻进行睡眠呼吸事件检测时也能够充分利用到信号的前后信息,受到视觉检测任务网络模型的启发,本文设计了如图9所示的多尺度特征提取模块。其中最主要的残差模

块参考了模型YOLOv4Tiny^[32]中残差模块的设计。通过对不同分辨率的特征图进行融合,保证后端数据能够拥有不同尺度的目标信息和相对充分的感受野,从而提升待测呼吸事件的检测性能。

3.2 一维时序信号特征提取和融合模块

一维时序信号特征提取网络如图10所示,该模块借鉴了用于睡眠分期的U-Time^[33]网络模型的思想,设计了专用于本文睡眠呼吸事件检测的编码-解码层来提取一维时序信号的特征。本文利用池化层进行降采样,得到4种不同时间分辨率的特征图,分别进行特征提取,再通过上采样的方式恢复原来的采样率,并融合不同尺度特征图上的信息,最终得到了包含多尺度信息的特征图。网络中各模块作用如下。

(1)编码模块:编码模块负责捕获数据中有用信息并转换成更高层次的抽象特征,同时降低数据的采样率,以便后续处理。具体实现中,编码层由4个卷积块组成,每个卷积块会执行两次连续的卷

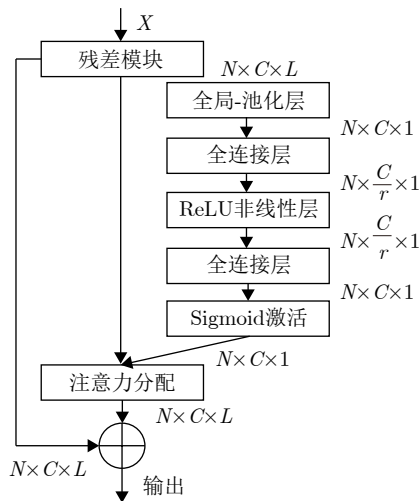


图8 通道注意力模块

Fig. 8 Channel attention module

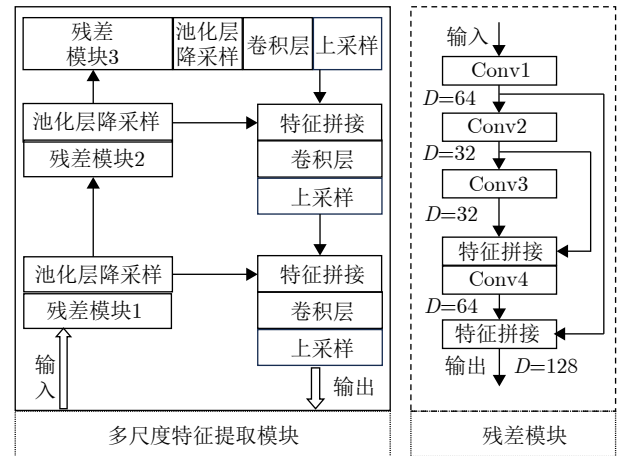


图9 多尺度特征提取模块

Fig. 9 Multi-scale feature extraction module

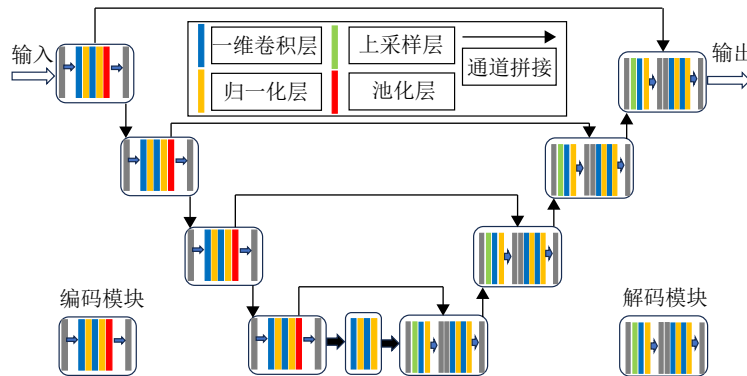


图10 一维时序信号特征提取和融合模块

Fig. 10 Module for feature extraction and fusion of 1D temporal signals

积运算，并引入残差连接。在4个卷积模块中，对应的池化层大小分别是6, 4, 2和2。池化运算之后，会再次利用卷积层对降采样的信号进行更高层次的特征提取。通过多次卷积和下采样运算：极大减少了网络训练过程中计算和存储的需求；为最后的卷积层提供了更大的感受野，理论上得到的最大感受野长3 min，足够用于检测呼吸事件，帮助神经网络更好地学习信号底层的抽象特征。

(2)解码模块：解码模块由4个转置卷积块组成，每个模块对其输入执行最近邻上采样，上采样倍数分别是2, 2, 4和6。生成的特征图与编码模块中相同采样率的特征图拼接，再通过卷积模块将特征进行融合，得到包含多尺度信息的特征图。

3.3 决策层

在决策层，如图11所示，本文采用逐点卷积的方式，将二维谱图信号模块提取的特征和一维时序信号模块提取的特征映射到标签类的三维空间，并利用归一化层进行处理。采用时间长度为5 s的平均池化层进行局部平滑处理，再利用全连接层实现全局信息交互，输出秒级粒度的检测结果：正常(Normal, N)、呼吸暂停(Apnea, A)和低通气(Hypopnea, H)，最后利用式(8)所示的加权表决法为两路信号的输出结果分配相应的权重，其中， i 表示第 i 个样本点， y_2 表示谱图信号预测结果， y_1 表示时序信号预测结果， α 为网络可以自适应学习的权重参数，并利用Sigmoid函数约束到0~1， y_{fusion} 为最终的融合输出结果。

$$y_{\text{fusion}}^{(i)} = \alpha y_2^{(i)} + (1 - \alpha) y_1^{(i)} \quad (7)$$

通过融合时序手工特征和谱图特征的输出结果得到决策层输出，更好地提升了网络对于睡眠呼吸事件的检测效果。一方面，手工时序特征的输入和检测保证了算法识别的鲁棒性，并增强了网络输入的可解释性。另一方面，谱图信号的输入为网络带来了更为丰富的信息，使得网络能够更好地融合雷达信号与脉搏波数据。




图 11 决策层融合模块

Fig. 11 Decision layer fusion module

3.4 损失函数

本文以专业医师依据PSG数据标注的异常事件为真实标签，训练本节中提出的神经网络。所采用的损失函数是由FocalLoss^[34]和DiceLoss^[35]的组合实现的，训练过程中最小化如下损失函数 L ：

$$L = L_{\text{Focal}} + L_{\text{Dice}} \quad (8)$$

$$L_{\text{Focal}} = - \sum_{k=1}^3 \frac{1}{M_k} \sum_{i=1}^N \left[(1 - \tilde{p}_k^{(i)})^2 \log \tilde{p}_k^{(i)} \right] \quad (9)$$

$$\tilde{p}_k^{(i)} = \begin{cases} p_k^{(i)}, & y^{(i)} = k \\ 1 - p_k^{(i)}, & y^{(i)} \neq k \end{cases} \quad (10)$$

$$L_{\text{Dice}} = \sum_{k=1}^3 \left(1 - 2 \frac{|X_k \cap Y_k|}{|X_k| + |Y_k|} \right) \quad (11)$$

其中， L_{Dice} 主要用于计算几何损失，是一种用于评估两个样本间相似性的度量函数，取值范围在0~1，取值越小表示相似性越高。 L_{Focal} 是交叉熵损失函数的变体，最初用于图像领域解决数据不平衡造成的模型性能问题，本文中引入 L_{Focal} 增强模型对难样本低通气事件的发掘。 k 表示输出事件的类型， $1/M_k$ 表示第 k 类事件的权重， N 表示样本的数目， $y^{(i)}$ 表示第 i 个样本对应的真实标签， $\tilde{p}_k^{(i)}$ 表示第 i 个样本预测为第 k 类的概率； L_{Dice} 中的 X_k 表示第 k 类事件预测的二分类结果， Y_k 表示的是第 k 类事件真实二分类标签， $|X_k \cap Y_k|$ 表示二者之间的交集。

4 实验

在实验过程中，为避免因同一受试者不同时间段的数据片段同时出现在训练集和测试集上而导致信息泄露，本文首先按受试者的名称将数据划分为训练集和验证集，以确保同一受试者的数据不会在训练集和验证集内同时出现，再以滑窗的方式将训练数据集划分为30 min的片段以便网络训练。同时，实验中为了均衡各级SAHS病情人员的比例，从中选取了数据质量较高且比例均衡的86条数据进行4折交叉验证实验，即将86条受试者的数据分为4组，每次选定1组作为测试集，其余3组作为训练集，如此重复4次，报告实验的结果。

4.1 实验结果对比分析

为了公正地评估算法的性能，本文进行了3方面的对比实验：4.1.1节对比了时序信号、谱图信号与二者融合进行秒级粒度睡眠呼吸事件检测时的性能。4.1.2节对比了雷达信号、脉搏波信号和二者融

合进行秒级粒度睡眠呼吸事件检测时的性能。4.2.3节对比了算法进行SAHS病情分级的性能。

在进行逐秒级事件评价时, 本文的实验是通过分析各类呼吸事件, 即正常(Normal, N); 呼吸暂停(Apnea, A); 低通气(Hypopnea, H), 检测的精确率(pre)、召回率(rec)和平衡分数(F1)这三项指标来实现对算法性能的评价^[36], 评价指标的计算公式如下:

$$\begin{cases} \text{pre} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \text{rec} = \frac{\text{TP}}{\text{TP} + \text{FN}} \\ \text{F1} = 2 \times \frac{\text{pre} \times \text{rec}}{\text{pre} + \text{rec}} \end{cases} \quad (12)$$

其中, TP表示正确预测的阳性样本数, TN表示正确预测的阴性样本数, FP表示错误预测的阳性样本数, FN表示错误预测的阴性样本数。pre表示在模型识别为阳性的样本中, 真正为阳性的样本所占比例。rec表示真实阳性样本中, 分类器能预测出来的比例。

实验中采用Pytorch实现深度神经网络模型的搭建。为提升模型的泛化能力并减轻过拟合现象, 我们选用了AdamW^[37]优化器作为训练策略的一部分。此外, 为了增强模型的收敛效果, 采用了梯度累加策略, 每3个批次训练结束, 进行一次梯度更新, 以便网络更好收敛。整个训练共进行100轮, 在预热阶段, 学习率初始值设置为 $\alpha = 2 \times 10^{-3}$, 并在训练进入平稳阶段后, 每完成10轮训练, 学习率按上一次的1/10进行衰减, 同时权重衰减参数被设置为0.01, 以进一步优化模型性能。

4.1.1 谱图信号与时序信号对比实验

本节在采集的实测数据上, 进行了谱图信号特

征与传统时序信号特征的对比实验, 实验结果如表4所示。通过结果对比可以看出, 基于二维谱图信号进行睡眠呼吸事件的检测性能优于一维时序信号, 尤其是在出现呼吸事件时, 前者的性能要明显优于后者。原因在于两个方面: (1)相较于一维时序呼吸-相位信号, 雷达谱图信号保留了在不同距离门上更为丰富的人体微动信息: 表征体动强度的谱图信号 $x_M(r, t)$ 中包含了睡眠过程中出现的觉醒, 表征呼吸的低频分量 $x_B(r, t)$ 和 $x_D(r, t)$ 蕴含了胸腹各部位的微动信息, 既能提取呼吸-相位信息, 也能利用胸腹的矛盾运动判断呼吸事件类型; (2)二维谱图信号特征提取网络相较于一维时序信号特征提取网络, 使用多个二维小卷积核替代了原先大的一维卷积核, 能够更好地适应由睡姿或体动等因素产生的变化。

如表4所示, 将二者的结果在决策层进行融合以后, 最终的检测性能仍有一定的提升。原因在于, 加权表决的机制降低了网络在识别低通气上的错误率, 提升了网络检测性能。同时, 手工提取的时序信号从直观上更易于医生和受试者理解, 便于增强算法在实际应用中的鲁棒性和可解释性。因此, 在后续的实验, 本文将不加说明地采用时序信号和谱图信号融合后预测的输出作为最终的实验结果。

4.1.2 雷达信号与脉搏波信号对比实验

本节在采集的实测数据上, 进行雷达信号与脉搏波信号的对比实验。实验结果如表5所示。通过分析基于脉搏波信号和雷达信号的呼吸事件检测结果可以看出, 在检测睡眠呼吸暂停事件时, 二者检

表 4 时序信号与谱图信号对比实验

Tab. 4 Comparison experiment between time-domain signals and spectrogram signals

	N			A			H		
	pre	rec	F1	pre	rec	F1	pre	rec	F1
时序信号	0.859	0.975	0.913	0.863	0.508	0.639	0.616	0.361	0.455
谱图信号	0.928	0.945	0.936	0.731	0.848	0.785	0.558	0.586	0.572
时序信号+谱图信号	0.961	0.934	0.947	0.751	0.895	0.817	0.627	0.650	0.638

表 5 雷达与脉搏波对比实验

Tab. 5 Comparison experiment between radar signals and pulse wave signals

	N			A			H		
	pre	rec	F1	pre	rec	F1	pre	rec	F1
PPG	0.834	0.971	0.897	0.816	0.681	0.742	0.652	0.462	0.541
Radar	0.909	0.902	0.906	0.714	0.826	0.766	0.506	0.549	0.527
PPG+Radar	0.961	0.934	0.947	0.751	0.895	0.817	0.627	0.650	0.638

测性能相近，融合以后效果会有一些的提升。在检测低通气事件时，PPG的精确率比雷达更为优异，而雷达的召回率更高，二者融合以后，检测性能出现了较高的提升。

图12展示了在同一时间段内，模型基于雷达信号(Radar)、脉搏波信号(PPG)以及雷达与脉搏波信号融合(Radar+PPG)的检测结果。可以看出，仅依赖单一雷达传感器进行睡眠呼吸监测时，能够更准确地利用胸腹位移和体动信息检测呼吸暂停事件。然而，由于低通气事件相比呼吸暂停事件的时间跨度更长且呼吸未完全消失，雷达因缺乏血氧信息，容易在检测低通气事件时出现误报和漏检的情况。另外，单独依赖PPG进行睡眠呼吸监测时，尽管能够较为准确地检测到呼吸暂停事件，但在事件

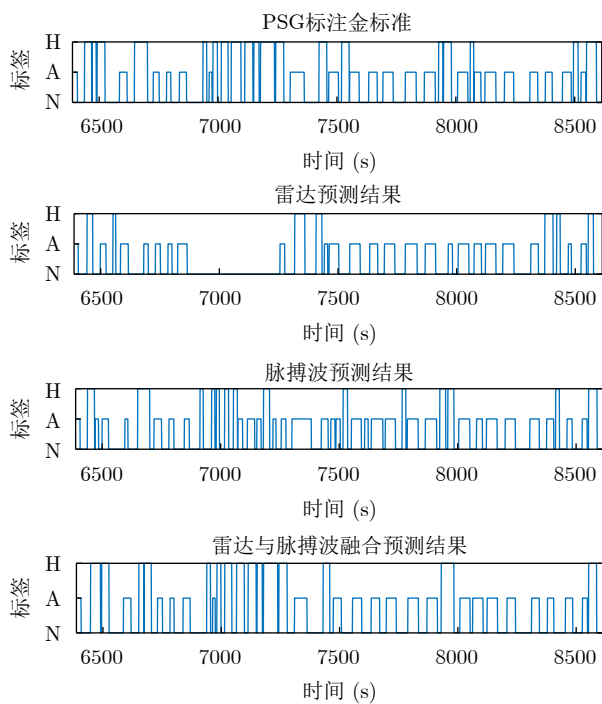


图 12 不同传感器实验预测结果对比

Fig. 12 Comparison of experimental prediction results from different sensors

定位精度上不如雷达。然而，由于PPG信号包含血氧信息，其在检测低通气事件时表现更佳。

图13展示了通过T-SNE方法^[38]对不同信号输入下模型的网络输出层特征进行可视化。可以观察到，在融合之前，基于单一传感器提取的呼吸暂停事件特征具有较高的区分度，而低通气事件则容易出现混淆。经过信号融合后，由于信号丰富度的增加，网络在低通气事件上的特征提取能力显著提升，使得融合后的模型在呼吸事件检测效果上表现更优。

4.2 医学指标分析实验

为了进一步评价算法的临床价值，本文最终从睡眠医学上较为关注的AHI指标、Bland-Altman图分析和SAHS病情分级3个方面，对基于雷达信号和脉搏波数据融合的睡眠呼吸暂停低通气事件检测算法进行综合评价。

本文中设计的网络，基于二维谱图特征提取模块和一维时序特征提取模块对谱图信号和时序信号进行特征提取，并在决策层将二者的输出结果进行融合，得到最终的逐秒级预测结果：N, A和H。对整晚数据中出现的呼吸事件进行统计，再对算法进行评价。

4.2.1 预测示意图

图14所示为神经网络对不同严重程度的SAHS患者呼吸事件的检测结果，其中横轴为时间，纵轴为患者发生的SAHS事件类型：正常(Normal, N)、呼吸暂停(Apnea, A)和低通气(Hypopnea, H)。每张图片的上方为医师依据金标准PSG标注的睡眠呼吸事件真实标签，下方是算法输出的逐秒级的预测结果。在基于雷达微动信号和脉搏波信号融合的识别结果中可以看出，网络能够较为有效地检测出睡眠过程中出现的呼吸事件并区分事件的类型。结果中也可以观察到存在一些虚警和漏检，其中大部分的事件类型为低通气。原因在于，发生低

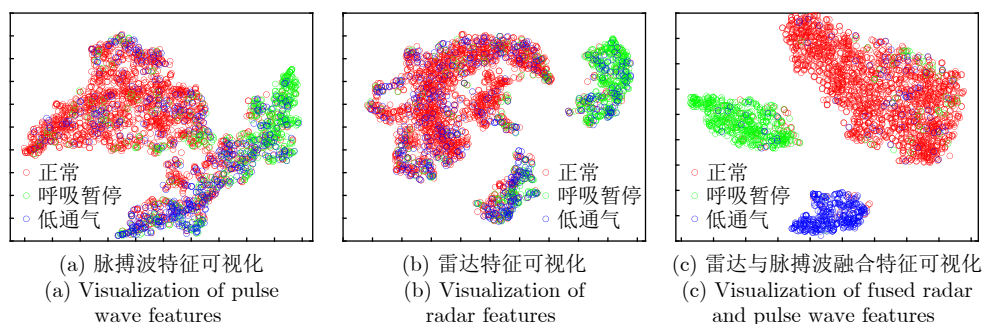


图 13 雷达与脉搏波特征图对比(Normal: 正常; Apnea: 呼吸暂停; Hypopnea: 低通气)

Fig. 13 Comparison of radar and pulse wave feature maps (N: Normal; A: Apnea; H: Hypopnea)

通气时，呼吸气流和血氧饱和度的幅度变化很微弱，这让网络对低通气的识别更为困难。

4.2.2 AHI预测结果

通过对整晚数据实验结果进行统计：如果连续的预测结果显示呼吸暂停或低通气且持续时间超过10 s，则记作一次事件，得到睡眠呼吸事件总次数 N 。再将其除以PSG中记录的睡眠时长分钟数 T ，得到受试者每小时睡眠内呼吸暂停与低通气事件的次数，即AHI指数： $AHI = N/T \times 60$ 。将基于雷达和脉搏波数据融合预测的 AHI_{pre} 与PSG的参考值 AHI_{true} 进行对比，图13分别展示了医学上一致性评价方法的结果：AHI的散点图和Bland-Altman图^[39]，图中均为交叉验证测试集上的结果。

图15(a)中的数据点直线拟合结果为 $y = 0.89x +$

1.78， AHI_{pre} 和 AHI_{true} 表现出了高度的线性相关性(皮尔逊相关系数^[40]为0.93，通常认为该系数 >0.9 是一致性良好)；图15(b)所示为医学领域常用的评价方法Bland-Altman图，用以反映两种测量方法的系统误差和随机误差^[41]。图(b)中横坐标是算法预测和PSG所得AHI均值，纵轴为二者的差异值，红虚线和蓝虚线分别表示平均偏差为1.38次/h，差值95%置信度区间为 $-7.18 \sim 9.94$ 次/h。绝大部分数据均位于该置信区间范围内，意味着本文实验预测的结果和真实数据具有良好的一致性。上述定量分析显示，本文所提出的基于雷达和脉搏波数据融合的睡眠呼吸事件检测的方法能有效地估计受试者的AHI，且与PSG的参考值吻合较好。

本文在现有研究中选取了同样采用相同数量级真实病例数据的Kang等人^[18]、Kwon等人^[20]和Hay-

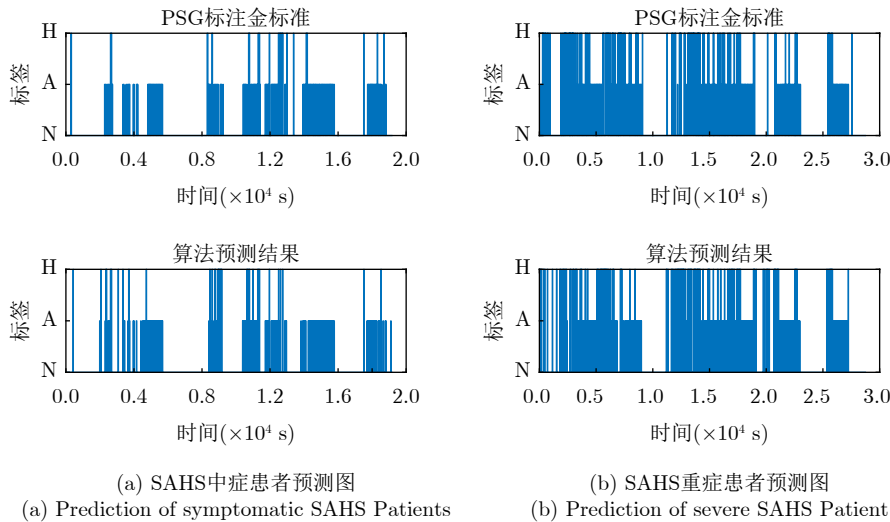


图 14 PSG标注与预测结果对比(N表示正常；A表示呼吸暂停；H表示低通气)
Fig. 14 Comparison of PSG annotations and predicted results (N: Normal; A: Apnea; H: Hypopnea)

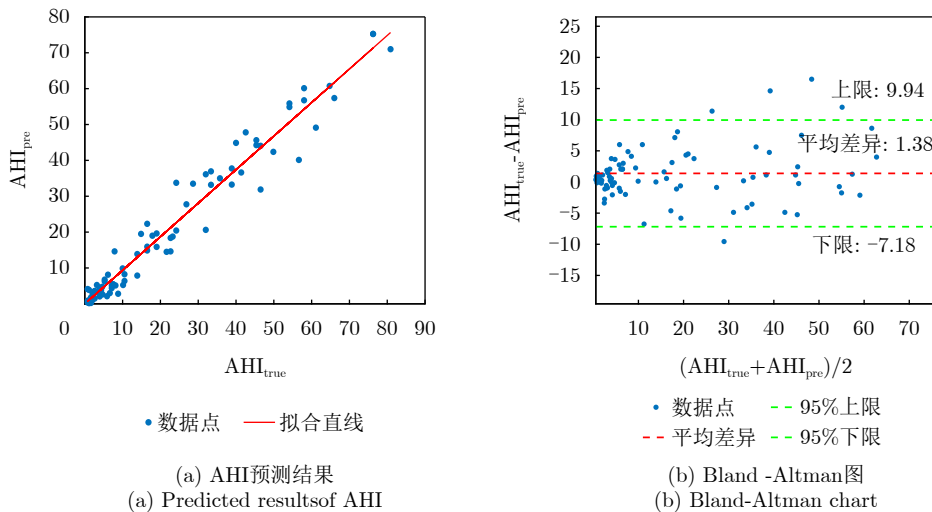


图 15 基于雷达和脉搏波融合检测的AHI与PSG参考值的对比

Fig. 15 Comparison of AHI between radar-PPG signal fusion and reference values from PSG

ano等人^[42]的研究进行对比。其中，Kang等人从UWB雷达信号中重建胸部位移信号，利用改进的恒虚警CFAR检测器实现睡眠呼吸暂停事件的识别。Kwon等人利用CNN-LSTM模型，采用30滑窗的方式划分UWB雷达时间-距离像作为输入，每隔10 s输出一次呼吸异常/正常的识别结果，并对数据进行聚合得到预测出的睡眠呼吸暂停事件。Hayano等人通过提取脉搏波的脉搏间期，利用改进的自适应阈值相关波检测算法进行睡眠呼吸暂停事件的识

别。表6展示了在医学指标AHI方面，本文与现有研究的对比分析，包括Bland-Altman图以及线性拟合系数R的结果。其中，数据集所在列上方给定受试者总人数，下方给出了受试者在健康、轻症、中症和重症上的分布^[43]。从Bland-Altman图分析来看，本文的算法平均偏差最小，而Kang方法略大，Hayano等人并未给出报告。从拟合系数来看，本文所提方法与Kang等人Kwon等人相近，远优于Hayano等人的方法。

表 6 现有研究结果性能比较
Tab. 6 Comparative performance with existing research findings

方法	数据集 人数	传感器	呼吸 监测仪	Bland- Altman	线性 拟合系数R
Kang,2020 (CFAR)	94 (23,24,14,33)	6.5~8.0 GHz UWB	PSG	-2.8 (-21.7,+16.1)	0.96
Kwon,2022 (CNN+LSTM)	36 (6,9,8,11)	6.5~8.0 GHz UWB	PSG	-2.0 (-14.6,+10.7)	0.97
Hayano,2020 (ACAT)	41 (11,8,16,6)	PPG	PSG	-	0.81
本文方法 (雷达+脉搏波)	86 (27,19,14,26)	60~63 GHz FMCW +PPG	PSG	1.38 (-7.18,+9.94)	0.93

分析可能的原因在于：受试者个体存在一定的差异，且实验环境差异较大，不同的受试者面临PSG大量管线的限制会有不同的应激反应。数据集规模受限的情况下4组对比实验中受试者病情的分布差异较大，导致统计结果易受到影响。另外，Kwon等人、Kang等人Hayano等人的3个研究中只进行了呼吸事件有无的二分类检测，并未对事件的类型进行区分，并且呼吸事件检测时间精度不高。而本文的研究不仅输出秒级粒度的事件检测结果，也区分了呼吸暂停事件和低通气事件。综上结果分析证明了本文所提方法在睡眠呼吸暂停低通气综合征筛查领域的有效性和应用潜力。

4.2.3 SAHS病情分级结果对比分析

睡眠呼吸暂停低通气综合征(SAHS)可根据AHI指数进行诊断和严重程度分级。其中： $0 \leq AHI < 5$ 为健康， $5 \leq AHI < 15$ 为轻度SAHS， $15 \leq AHI < 30$ 为中度SAHS， $AHI \geq 30$ 为重度SAHS^[43]。根据上述分级标准，在图16中绘制了基于雷达信号和脉搏波数据融合检测的SAHS病情分级混淆矩阵。从结果上可见，本文的方法能够较好地地区分不同病情等级的患者，仅在相邻的等级判定存在少量的错误。为进一步验证本文提出的融合检测算法对睡眠呼吸事件检测性能的提升，本文进行了相应的对比实验，分别采用单输入的雷达信号和脉搏波信号进行呼吸事件检测，并在轻症(阈值为5次/h)、中症(阈值为15次/h)和重症(阈值为30次/h)3种不同的阈值条件

下比较算法的性能，实验结果如表7所示。实验结果表明，相较于使用单输入的雷达信号或脉搏波数据进行SAHS病情诊断分级，本文所提的基于毫米波雷达和脉搏波数据融合的睡眠呼吸暂停与低通气检测算法具有更好的性能。

5 结语

本文提出了一种基于毫米波雷达信号与脉搏波数据融合的睡眠呼吸暂停与低通气检测算法，不仅实现了秒级粒度下睡眠呼吸异常事件的识别和分类，也可以在预测患者AHI的基础上给出病情严重程度的分级。与传统医学上基于PSG信号进行人工判读的方法相比，本文通过融合雷达提供的人体微动信息和脉搏波隐含的血氧、心率信息，给出了轻

	健康	轻症SAHS	中症SAHS	重症SAHS
健康	26	1		
轻症SAHS	4	14	1	
中症SAHS		3	9	2
重症SAHS			1	25
	健康	轻症SAHS	中症SAHS	重症SAHS
	算法预测分级			

图 16 SAHS病情分级混淆矩阵

Fig. 16 Confusion matrix for grading the severity of SAHS

表 7 对照实验结果
Tab. 7 The results of control experiment

传感器	组内相关系数	诊断阈值(次/h)	敏感度(%)	特异度(%)	准确率(%)	Kappa系数
PPG	0.89	5	74.07	89.83	84.88	0.6455
		15	89.13	90.00	89.53	0.7901
		30	95.00	80.77	90.69	0.7746
Radar	0.93	5	66.67	89.83	82.56	0.5825
		15	91.30	92.50	91.86	0.8367
		30	95.00	88.46	93.02	0.8346
Radar	0.98	5	96.29	93.22	94.19	0.8690
+		15	97.83	92.50	95.35	0.9062
PPG		30	96.67	96.15	96.51	0.9182

接触式的睡眠呼吸异常检测方案。本文中也存在着一定的不足：由于中枢类型的呼吸暂停样本量极为稀少，无法对呼吸暂停综合征的亚型进行更为细致的划分，这将在未来扩充数据集之后继续进行完善。本文中的方法在AHI估计和SAHS严重程度诊断分级上与PSG一致性较好，可以有效降低睡眠呼吸暂停与低通气检测的成本，有潜力成为睡眠呼吸暂停低通气综合征的辅助诊断工具。

利益冲突 所有作者均声明不存在利益冲突

Conflict of Interests The authors declare that there is no conflict of interests

参 考 文 献

- JORDAN A S, MCSHARRY D G, and MALHOTRA A. Adult obstructive sleep apnoea[J]. *The Lancet*, 2014, 383(9918): 736–747. doi: [10.1016/S0140-6736\(13\)60734-5](https://doi.org/10.1016/S0140-6736(13)60734-5).
- YOUNG T, PALTA M, DEMPSEY J, et al. The occurrence of sleep-disordered breathing among middle-aged adults[J]. *New England Journal of Medicine*, 1993, 328(17): 1230–1235. doi: [10.1056/NEJM199304293281704](https://doi.org/10.1056/NEJM199304293281704).
- COWAN D C, ALLARDICE G, MACFARLANE D, et al. Predicting sleep disordered breathing in outpatients with suspected OSA[J]. *BMJ Open*, 2014, 4(4): e004519. doi: [10.1136/bmjopen-2013-004519](https://doi.org/10.1136/bmjopen-2013-004519).
- RANDERATH W, VERBRAECKEN J, ANDREAS S, et al. Definition, discrimination, diagnosis and treatment of central breathing disturbances during sleep[J]. *European Respiratory Journal*, 2017, 49(1): 1600959. doi: [10.1183/13993003.00959-2016](https://doi.org/10.1183/13993003.00959-2016).
- DONOVAN L M and KAPUR V K. Prevalence and characteristics of central compared to obstructive sleep apnea: Analyses from the sleep heart health study cohort[J]. *Sleep*, 2016, 39(7): 1353–1359. doi: [10.5665/sleep.5962](https://doi.org/10.5665/sleep.5962).
- BERRY R B, BROOKS R, GAMALDO C E, et al. The AASM manual for the scoring of sleep and associated events: Rules, terminology and technical specifications[R]. Version 2.0, 2012.
- MCNAMES J N and FRASER A M. Obstructive sleep apnea classification based on spectrogram patterns in the electrocardiogram[C]. *Computers in Cardiology 2000*, Cambridge, USA, 2000: 749–752. doi: [10.1109/CIC.2000.898633](https://doi.org/10.1109/CIC.2000.898633).
- TİMUŞ O H and BOLAT E D. k-NN-based classification of sleep apnea types using ECG[J]. *Turkish Journal of Electrical Engineering and Computer Sciences*, 2017, 25(4): 38. doi: [10.3906/elk-1511-99](https://doi.org/10.3906/elk-1511-99).
- KARMAKAR C, KHANDOKER A, PENZEL T, et al. Detection of respiratory arousals using photoplethysmography (PPG) signal in sleep apnea patients[J]. *IEEE Journal of Biomedical and Health Informatics*, 2014, 18(3): 1065–1073. doi: [10.1109/JBHI.2013.2282338](https://doi.org/10.1109/JBHI.2013.2282338).
- LAZAZZERA R, DEVIAENE M, VARON C, et al. Detection and classification of sleep apnea and hypopnea using PPG and SpO₂ signals[J]. *IEEE Transactions on Biomedical Engineering*, 2021, 68(5): 1496–1506. doi: [10.1109/TBME.2020.3028041](https://doi.org/10.1109/TBME.2020.3028041).
- SHARMA M, KUMBHANI D, TIWARI J, et al. Automated detection of obstructive sleep apnea in more than 8000 subjects using frequency optimized orthogonal wavelet filter bank with respiratory and oximetry signals[J]. *Computers in Biology and Medicine*, 2022, 144: 105364. doi: [10.1016/j.combiomed.2022.105364](https://doi.org/10.1016/j.combiomed.2022.105364).
- TARAN S and BAJAJ V. Sleep apnea detection using artificial bee colony optimize Hermite basis functions for EEG signals[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(2): 608–616. doi: [10.1109/TIM.2019.2902809](https://doi.org/10.1109/TIM.2019.2902809).
- PAPINI G B, FONSECA P, VAN GILST M M, et al. Wearable monitoring of sleep-disordered breathing:

- Estimation of the apnea-hypopnea index using wrist-worn reflective photoplethysmography[J]. *Scientific Reports*, 2020, 10(1): 13512. doi: [10.1038/s41598-020-69935-7](https://doi.org/10.1038/s41598-020-69935-7).
- [14] ZOU Lang and LIU Guanzheng. Multiscale bidirectional temporal convolutional network for sleep apnea detection based on wearable photoplethysmography bracelet[J]. *IEEE Journal of Biomedical and Health Informatics*, 2024, 28(3): 1331–1340. doi: [10.1109/JBHI.2023.3335658](https://doi.org/10.1109/JBHI.2023.3335658).
- [15] ZHOU Yong, SHU Degui, XU Hangdi, *et al.* Validation of novel automatic ultra-wideband radar for sleep apnea detection[J]. *Journal of Thoracic Disease*, 2020, 12(4): 1286–1295. doi: [10.21037/jtd.2020.02.59](https://doi.org/10.21037/jtd.2020.02.59).
- [16] KAGAWA M, TOJIMA H, and MATSUI T. Non-contact diagnostic system for sleep apnea-hypopnea syndrome based on amplitude and phase analysis of thoracic and abdominal Doppler radars[J]. *Medical & Biological Engineering & Computing*, 2016, 54: 789–798. doi: [10.1007/s11517-015-1370-z](https://doi.org/10.1007/s11517-015-1370-z).
- [17] LEE Y S, PATHIRANA P N, STEINFORT C L, *et al.* Monitoring and analysis of respiratory patterns using microwave Doppler radar[J]. *IEEE Journal of Translational Engineering in Health and Medicine*, 2014, 2: 1800912. doi: [10.1109/JTEHM.2014.2365776](https://doi.org/10.1109/JTEHM.2014.2365776).
- [18] KANG Sun, KIM D K, LEE Y, *et al.* Non-contact diagnosis of obstructive sleep apnea using impulse-radio ultra-wideband radar[J]. *Scientific Reports*, 2020, 10(1): 5261. doi: [10.1038/s41598-020-62061-4](https://doi.org/10.1038/s41598-020-62061-4).
- [19] ZAKRZEWSKI M, VEKHAOJA A, JOUTSEN A S, *et al.* Noncontact respiration monitoring during sleep with microwave Doppler Radar[J]. *IEEE Sensors Journal*, 2015, 15(10): 5683–5693. doi: [10.1109/JSEN.2015.2446616](https://doi.org/10.1109/JSEN.2015.2446616).
- [20] KWON H B, SON D, LEE D, *et al.* Hybrid CNN-LSTM network for real-time apnea-hypopnea event detection based on IR-UWB Radar[J]. *IEEE Access*, 2022, 10: 17556–17564. doi: [10.1109/ACCESS.2021.3081747](https://doi.org/10.1109/ACCESS.2021.3081747).
- [21] 潘虹, 黄国平, 任蓉, 等. 光电容积脉搏波描记法对阻塞性睡眠呼吸暂停综合征的诊断价值[J]. *中华医学杂志*, 2016, 96(19): 1527–1529. doi: [10.3760/cma.j.issn.0376-2491.2016.19.014](https://doi.org/10.3760/cma.j.issn.0376-2491.2016.19.014).
- PAN Hong, HUANG Guoping, REN Rong, *et al.* Diagnosis of obstructive sleep apnea syndrome using pulse oximeter derived photoplethysmographic signals[J]. *National Medical Journal of China*, 2016, 96(19): 1527–1529. doi: [10.3760/cma.j.issn.0376-2491.2016.19.014](https://doi.org/10.3760/cma.j.issn.0376-2491.2016.19.014).
- [22] CHOI J W, KIM D H, KOO D L, *et al.* Automated detection of sleep apnea-hypopnea events based on 60 GHz frequency-modulated continuous-wave radar using convolutional recurrent neural networks: A preliminary report of a prospective cohort study[J]. *Sensors*, 2022, 22(19): 7177. doi: [10.3390/s22197177](https://doi.org/10.3390/s22197177).
- [23] 余辉, 王硕, 李心蕊, 等. 基于LSTM-CNN的睡眠呼吸暂停与低通气事件实时检测算法研究[J]. *中国生物医学工程学报*, 2020, 39(3): 303–310. doi: [10.3969/j.issn.0258-8021.2020.03.07](https://doi.org/10.3969/j.issn.0258-8021.2020.03.07).
- YU Hui, WANG Shuo, LI Xinrui, *et al.* Algorithm study of real-time detection of sleep apnea-hypopnea event based on long-short term memory-convolutional neural network[J]. *Chinese Journal of Biomedical Engineering*, 2020, 39(3): 303–310. doi: [10.3969/j.issn.0258-8021.2020.03.07](https://doi.org/10.3969/j.issn.0258-8021.2020.03.07).
- [24] TOFTEN S, KJELLSTADLI J T, TYVOLD S S, *et al.* A pilot study of detecting individual sleep apnea events using noncontact radar technology, pulse oximetry, and machine learning[J]. *Journal of Sensors*, 2021, 2021: 2998202. doi: [10.1155/2021/2998202](https://doi.org/10.1155/2021/2998202).
- [25] 方震, 简璞, 张浩, 等. 基于FMCW雷达的非接触式医疗健康监测技术综述[J]. *雷达学报*, 2022, 11(3): 499–516. doi: [10.12000/JR22019](https://doi.org/10.12000/JR22019).
- FANG Zhen, JIAN Pu, ZHANG Hao, *et al.* Review of noncontact medical and health monitoring technologies based on FMCW Radar[J]. *Journal of Radars*, 2022, 11(3): 499–516. doi: [10.12000/JR22019](https://doi.org/10.12000/JR22019).
- [26] JAVAID A Q, NOBLE C M, ROSENBERG R, *et al.* Towards sleep apnea screening with an under-the-mattress IR-UWB radar using machine learning[C]//The 14th IEEE International Conference on Machine Learning And Applications (ICMLA), Miami, USA, 2015: 837–842. doi: [10.1109/ICMLA.2015.79](https://doi.org/10.1109/ICMLA.2015.79).
- [27] BHOWMIK T, DEY J, and TIWARI V N. A novel method for accurate estimation of HRV from smartwatch PPG signals[C]//The 39th Annual International Conference of the IEEE Engineering in Medicine and Biology society (EMBC), Jeju, Korea (South), 2017: 109–112. doi: [10.1109/EMBC.2017.8036774](https://doi.org/10.1109/EMBC.2017.8036774).
- [28] ELGENDI M, FLETCHER R, LIANG Yongbo, *et al.* The use of photoplethysmography for assessing hypertension[J]. *npj Digital Medicine*, 2019, 2(1): 60. doi: [10.1038/s41746-019-0136-7](https://doi.org/10.1038/s41746-019-0136-7).
- [29] THOMAS R J. Arousals in sleep-disordered breathing: Patterns and implications[J]. *Sleep*, 2003, 26(8): 1042–1047. doi: [10.1093/sleep/26.8.1042](https://doi.org/10.1093/sleep/26.8.1042).
- [30] ISSA F G and SULLIVAN C E. Arousal and breathing responses to airway occlusion in healthy sleeping adults[J]. *Journal of Applied Physiology*, 1983, 55(4): 1113–1119. doi: [10.1152/jappl.1983.55.4.1113](https://doi.org/10.1152/jappl.1983.55.4.1113).
- [31] HU Jie, SHEN Li, and SUN Gang. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 7132–7141. doi: [10.1109/CVPR.2018.00745](https://doi.org/10.1109/CVPR.2018.00745).
- [32] WANG C Y, BOCHKOVSKIY A, and LIAO H Y M.

- Scaled-YOLOv4: Scaling cross stage partial network[C]// 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, USA, 2021: 13024–13033. doi: [10.1109/CVPR46437.2021.01283](https://doi.org/10.1109/CVPR46437.2021.01283).
- [33] PERSLEV M, JENSEN M H, DARKNER S, *et al.* U-Time: A fully convolutional network for time series segmentation applied to sleep staging[C]. The 33rd International Conference on Neural Information Processing Systems, Vancouver, Canada, 2019: 397.
- [34] LIN T Y, GOYAL P, GIRSHICK R, *et al.* Focal loss for dense object detection[C]. 2017 IEEE International Conference on Computer Vision, Venice, Italy, 2017: 2999–3007. doi: [10.1109/ICCV.2017.324](https://doi.org/10.1109/ICCV.2017.324).
- [35] MILLETARI F, NAVAB N, and AHMADI S A. V-Net: Fully convolutional neural networks for volumetric medical image segmentation[C]. The Fourth International Conference on 3D Vision (3DV), Stanford, USA, 2016: 565–571. doi: [10.1109/3DV.2016.79](https://doi.org/10.1109/3DV.2016.79).
- [36] SNEATH P H A. The principles and practice of numerical classification[J]. *Numerical Taxonomy*, 1973, 573.
- [37] LOSHCHILOV I and HUTTER F. Decoupled weight decay regularization[C]. The 7th International Conference on Learning Representations, New Orleans, USA, 2019.
- [38] VAN DER MAATEN L and HINTON G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9(86): 2579–2605.
- [39] BLAND J M and ALTMAN D G. Agreed statistics: Measurement method comparison[J]. *Anesthesiology*, 2012, 116(1): 182–185. doi: [10.1097/ALN.0b013e31823d7784](https://doi.org/10.1097/ALN.0b013e31823d7784).
- [40] SEDGWICK P. Pearson's correlation coefficient[J]. *BMJ*, 2012, 345: e4483. doi: [10.1136/bmj.e4483](https://doi.org/10.1136/bmj.e4483).
- [41] GIAVARINA D. Understanding bland Altman analysis[J]. *Biochemia Medica*, 2015, 25(2): 141–151. doi: [10.11613/BM.2015.015](https://doi.org/10.11613/BM.2015.015).
- [42] HAYANO J, YAMAMOTO H, NONAKA I, *et al.* Quantitative detection of sleep apnea with wearable watch device[J]. *PLoS One*, 2020, 15(11): e0237279. doi: [10.1371/journal.pone.0237279](https://doi.org/10.1371/journal.pone.0237279).
- [43] SENARATNA C V, PERRET J L, LODGE C J, *et al.* Prevalence of obstructive sleep apnea in the general population: A systematic review[J]. *Sleep Medicine Reviews*, 2017, 34: 70–81. doi: [10.1016/j.smr.2016.07.002](https://doi.org/10.1016/j.smr.2016.07.002).

作者简介

赵翔，硕士生，主要研究方向为毫米波雷达AI感知技术、数据驱动医疗健康。

王威，博士生，主要研究方向为毫米波雷达AI感知技术、数据驱动医疗健康。

李晨洋，工程师，主要研究方向为睡眠监测系统开发、生命信息检测技术等。

关建，主任医师，主要研究方向为阻塞性睡眠呼吸暂停综合征的基础与临床科学研究。

李刚，博士，教授，博士生导师，主要研究方向为雷达信号处理、遥感、多源信息融合、数据驱动医疗健康等。

(责任编辑：高山流水)