

基于脑电信息监督的渐进式非接触睡眠监测方法

周放 卢智 张淦霖 武治 濮玉 陈涪睿 张东恒 陈彦*

(中国科学技术大学网络空间安全学院 合肥 230026)

摘要: 睡眠监测是评估个体健康的重要手段,但传统多导睡眠监测依赖多种接触式传感器,采集过程复杂,难以满足长期居家监测需求。雷达感知因其非侵入和易部署等优势,为居家睡眠监测提供了低负担感知手段。现有研究通常依赖多个大规模公开睡眠数据集开展预训练,或基于从雷达信号提取的呼吸特征训练睡眠分期与呼吸障碍检测模型。前者涉及跨域预训练,模型构建与训练成本较高,后者对于睡眠状态判读更直接相关的脑电模态知识利用不足,导致睡眠分期性能仍然受限。针对上述问题,该文提出了一种基于脑电信息监督的渐进式非接触睡眠监测方法。该方法基于公开数据集的脑电和呼吸信号,通过知识蒸馏和预训练策略逐步学习可迁移的睡眠判别信息,并将其适配至雷达呼吸表征,从而缓解脑电与雷达之间的模态差异,提升基于雷达的非接触式睡眠监测性能。实验结果表明,所提方法能够有效利用脑电先验知识增强雷达睡眠表征学习能力,在睡眠分期和呼吸障碍检测任务上的准确率分别达到82.6%和82.5%,为非接触式睡眠监测提供了新的技术思路。

关键词: 睡眠监测; 睡眠分期; 呼吸障碍; 射频感知; 深度学习

中图分类号: TN957

文献标识码: A

文章编号: 2095-283X(2026)x-0001-19

DOI: 10.12000/JR26120

CSTR: 32380.14.JR26120

引用格式: 周放, 卢智, 张淦霖, 等. 基于脑电信息监督的渐进式非接触睡眠监测方法[J]. 雷达学报(中英文), 待出版. doi: 10.12000/JR26120.

Reference format: ZHOU Fang, LU Zhi, ZHANG Ganlin, *et al.* A progressive eeg-supervised method for contactless sleep monitoring[J]. *Journal of Radars*, in press. doi: 10.12000/JR26120.

A Progressive EEG-Supervised Method for Contactless Sleep Monitoring

ZHOU Fang LU Zhi ZHANG Ganlin WU Zhi PU Yu
CHEN Furui ZHANG Dongheng CHEN Yan*

(School of Cyber Science and Technology, University of Science and Technology of China, Hefei 230026, China)

Abstract: Sleep monitoring is essential for assessing individual health. However, conventional polysomnography relies on multiple contact sensors and complex data acquisition procedures, making it difficult to meet the requirements of long-term, home-based monitoring. Radar sensing enables the contactless acquisition of respiratory and body movement signals during sleep, making it suitable for long-term home-based monitoring. Existing studies typically use large-scale public sleep datasets for pretraining or develop models for sleep staging and respiratory disorder detection based on respiratory features extracted from radar signals. The former requires cross-domain pretraining, resulting in relatively high model development and training costs, whereas the latter does not fully exploit EEG-derived knowledge, which is more directly associated with sleep-state assessment, thereby limiting sleep staging performance. To address these limitations, this paper proposes a progressive EEG-supervised method for contactless sleep monitoring. The proposed method leverages EEG and respiratory signals from a public dataset to progressively learn transferable discriminative representations

收稿日期: 2026-06-30; 改回日期: ; 网络出版: 2026-xx-xx

*通信作者: 陈彦 ecyan@ustc.edu.cn *Corresponding Author: Yan Chen ecyan@ustc.edu.cn

基金项目: 载人航天工程航天医学实验领域项目资助(HYZHXM01005)

Foundation Item: Space Medical Experiment Project of CMSP (HYZHXM01005)

责任主编: 洪弘 Corresponding Editor: HONG Hong

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License

(<https://creativecommons.org/licenses/by/4.0/>)

through knowledge distillation and pretraining, which are then adapted to radar-based respiratory representations. This approach alleviates the modality gap between EEG and radar signals, thereby improving contactless sleep monitoring performance. Experimental results show that the proposed method effectively leverages prior knowledge from EEG to enhance radar-based sleep representation learning, achieving accuracies of 82.6% for sleep staging and 82.5% for respiratory disorder detection. These results provide a new technical perspective on contactless sleep monitoring.

Key words: Sleep monitoring; Sleep staging; Respiratory disorders; RF sensing; Deep learning

1 引言

睡眠对人类健康至关重要,其整体结构及相关生理过程为理解神经调节与认知功能变化提供了重要窗口^[1-3]。睡眠分期与呼吸障碍检测是临床评估睡眠质量的两项关键任务。睡眠分期旨在根据脑电、眼电等生理信号,将睡眠划分为清醒期(Wake)、浅睡期(Light)、深睡期(Deep)和快速眼动期(REM)4个阶段,用于刻画睡眠结构及其动态演化^[1]。呼吸障碍检测则关注睡眠过程中呼吸暂停(Apnea)、低通气(Hypopnea)等异常事件的识别,用于评估睡眠呼吸紊乱程度及其潜在健康风险^[4]。

传统医学上睡眠监测的金标准是多导睡眠图(Polysomnography, PSG)。专业医师通过脑电(Electroencephalography, EEG)、眼电(Electrooculography, EOG)、肌电(Electromyography, EMG)以及呼吸、血氧等多模态生理信号对睡眠分期和呼吸障碍事件进行人工标注^[1]。然而,PSG依赖多种接触式传感器,采集过程复杂,容易给受试者带来生理负担,且设备投入和人工判读成本较高,难以满足长期居家监测和大规模人群筛查的需求。为克服上述局限,基于雷达的非接触式监测技术日益受到关注^[3-15]。该技术通过分析人体反射的无线信号来推断个体的睡眠状态,为低负担睡眠监测提供了可行方案^[16-19]。例如,赵翔等^[4]将毫米波雷达微动信号与光电容积脉搏波信息进行融合,实现呼吸暂停和低通气事件识别及呼吸暂停低通气指数估计,为基于毫米波雷达的睡眠呼吸障碍筛查提供了多模态感知方案。RadioSleep^[5]以脑电信号为输入构建睡眠分期教师模型,并通过知识蒸馏指导基于无线呼吸信号的学生模型学习,从而增强无线表征的睡眠阶段判别能力。然而,该方法的知识蒸馏策略主要用于睡眠分期,呼吸障碍检测仍由独立模型完成,对多任务间协同信息的利用仍不充分。Hypnos^[13]利用超宽带雷达感知人体体动及胸部微动信息,并结合注意力序列编码、对比学习和呼吸暂停辅助任务提升睡眠分期性能,但对整夜尺度下睡眠阶段的周期性演化及长程依赖关系仍缺乏充分建模。ResSleepNet^[14]利用大规模公开数据集中的

胸腹带呼吸信号构建多任务学习模型,并通过迁移策略将该框架扩展至雷达信号。然而,其呼吸障碍任务主要面向整夜层面的呼吸暂停低通气指数(Apnea-Hypopnea Index, AHI)估计,尚未实现细粒度的呼吸暂停和低通气事件识别。

上述研究验证了雷达睡眠监测的应用潜力,但仍存在两个方面的不足。首先,雷达信号主要反映呼吸、体动等外在机械活动,对细粒度睡眠状态的表征能力相对有限,而脑电信号能够更直接地反映睡眠过程中的神经活动及阶段变化,例如深度睡眠中的慢波特征以及与低通气事件相关的觉醒反应^[1]。因此如何利用脑电信号中的睡眠判别信息增强雷达表征仍值得进一步研究。其次,为增强雷达模型的泛化能力,部分方法^[14]通常依赖多个大规模公开数据集中的呼吸信号进行跨域预训练,但该过程涉及复杂的数据处理与模型优化,训练资源消耗较高,模型开发成本较大。因此,如何在有限的数据与计算资源条件下有效迁移脑电睡眠判别信息,并联合优化睡眠分期与呼吸障碍检测,仍是非接触式睡眠监测中需要解决的关键问题。

为解决上述问题,本文提出一种基于脑电信息监督的渐进式非接触睡眠监测方法,如图1所示。该方法基于单个公开睡眠数据集SHHS1(Sleep Heart Health Study)^[20,21]中约5500份整夜记录的脑电和呼吸信号,通过知识蒸馏^[22]和预训练策略^[23]逐步学习可迁移的睡眠判别信息,并将其适配至雷达呼吸表征,从而缓解脑电与雷达之间的模态差异,提升基于雷达的非接触式睡眠监测性能。该框架首先在公开睡眠数据集上构建基于脑电信号的多任务教师模型,利用睡眠分期和呼吸障碍标签进行联合监督训练,以捕捉与睡眠分期和呼吸障碍相关的判别性特征。随后,在相同数据集上构建呼吸学生模型,通过知识蒸馏技术将脑电教师模型学习到的睡眠相关知识迁移至呼吸表征空间,实现脑电表征与呼吸表征之间的对齐。最后,将呼吸学生模型作为预训练模型迁移至雷达数据集,并引入层次化监督机制,通过睡眠分期和呼吸障碍由粗到细的逐级约束,简化模型对复杂睡眠监测任务的学习过程,使模型更




图 1 基于脑电信息监督的渐进式非接触睡眠监测框架

Fig. 1 An EEG-supervised progressive framework for contactless sleep monitoring

有效地提取雷达信号中反映睡眠分期和呼吸障碍的特征。在本文构建的大规模多环境无线睡眠数据集上的实验结果表明，相较于现有方法，所提框架能够有效提升非接触式睡眠监测性能。其中，睡眠分期准确率达到82.6%，并在快速眼动期等具有挑战性的睡眠阶段取得显著提升，平均提升15.1%。呼吸障碍检测准确率达到82.5%，其中低通气事件识别性能平均提升15.3%。上述结果表明，本研究能够从脑电信号中有效学习可迁移的睡眠判别信息，进而增强雷达信号对睡眠阶段变化和异常呼吸状态的表征能力，为非接触式睡眠分期与呼吸障碍检测提供了新的思路。

本文主要贡献点如下：

(1) 指出并验证了脑电信号中蕴含的睡眠神经生理知识对非接触式睡眠监测的重要作用。实验结果表明，基于脑电信息监督的呼吸表征学习能够增强模型对睡眠任务的判别能力。

(2) 提出了一种基于脑电监督的渐进式非接触睡眠监测框架。该框架以呼吸信号为中间模态，通过知识蒸馏和预训练将脑电知识逐步迁移至雷达模型，降低了对多个大规模公开数据集的依赖。此外，引入层次化监督策略，增强模型对细粒度睡眠阶段和呼吸障碍类型的判别能力。

(3) 构建了一个总时长约900小时的多环境雷达睡眠数据集，并用于系统评估本文方法。实验结果

表明，所提框架在睡眠分期和呼吸障碍检测任务上的准确率分别达到82.6%和82.5%，快速眼动睡眠阶段和低通气事件的识别准确率相比现有对比方法平均提升15.1%和15.3%。

2 信号采集和预处理

本文使用的睡眠数据集由公开数据集和无线雷达数据集两部分组成。2.1节介绍公开数据集处理流程。2.2节介绍无线数据集采集流程，并说明无线睡眠数据集的结构。2.3节介绍雷达信号的构建流程，包括毫米波雷达感知原理、信号增强方法以及呼吸信号的融合与预处理。

2.1 公开数据集预处理

本研究的蒸馏学习模块基于公开睡眠数据集 SHHS (Sleep Heart Health Study)^[20,21]。SHHS是一项多中心前瞻性队列研究，主要用于探索睡眠呼吸障碍与心血管疾病风险之间的关系，其睡眠数据包括基线访视SHHS1和随访访视SHHS2两个子集。此外，本文在对照实验中进一步引入MESA (Multi-Ethnic Study of Atherosclerosis)数据集^[21,24]。MESA主要用于研究睡眠及睡眠障碍在不同性别和种族人群中的差异，以及其与亚临床动脉粥样硬化之间的关系。本研究主要采用SHHS1中的脑电和呼吸信号构建教师模型与学生模型，在数据规模对照

实验中进一步引入SHHS2和MESA。具体而言,本研究首先分别对脑电信号和呼吸信号进行带通滤波,以去除基线漂移和高频噪声,并将二者分别降采样至32 Hz和10 Hz。其中,脑电滤波频段设置为0.5~35 Hz,以保留睡眠相关脑电成分^[1];呼吸信号滤波频段设置为0.05~1 Hz,用于提取睡眠相关呼吸特征。随后,本文基于整夜信号的99.5百分位数对异常幅值进行截断,以降低离群值对模型训练的影响。最后,按照每晚信号的均值和标准差对数据进行标准化。

2.2 无线数据集构建

2.2.1 采集流程

本研究在安徽省立医院、酒店和私人住宅3类环境中开展数据采集,旨在构建一个大规模、多环境的多模态睡眠数据集。所有实验流程均通过中国科学技术大学伦理委员会的审批,并在采集前获得所有参与者的书面知情同意。采集场景如图2所示,受试者佩戴PSG设备记录睡眠参考信号。雷达安装于距床头约1 m的定制支架上,并以约45°向下倾斜,以覆盖受试者胸腹部区域。具体设备参数和时间同步操作如下描述:

(1) 有线多导睡眠设备: PSG数据采用Philips Alice PDX系统采集。该设备记录标准睡眠生理通道,包括脑电、眼电、肌电、心电、胸腹呼吸带、气流和血氧等信号,用于提供睡眠分期与呼吸障碍事件标注的参考依据。

(2) 多输入多输出(Multiple-Input Multiple-Output, MIMO)雷达系统: 雷达数据采用TI AWR6843-AOP调频连续波(Frequency-Modulated Continuous Wave, FMCW)毫米波雷达采集^[25],工作频率为60 GHz。该雷达采用3发射、4接收的时分复用多输入多输出配置,可形成12个虚拟通道。系统带宽为4 GHz,采样率为100 Hz,线性调频斜率为64.985 MHz/ μ s。每个发射天线在一个周期内发射一个线性调频信号。其理论距离分辨率约为3.75 cm,方位角和俯仰角分辨率均约为29°。

(3) 同步: 为保证PSG与雷达数据的时间一致性,两类设备均以阿里云服务器时间作为统一参考。具体而言,在每晚数据采集前,PSG设备与雷达设备均同步至阿里云服务器时间,并由采集人员人工核对两套设备的系统时间,以减小设备启动偏差。值得注意的是,PSG内部时钟相对于服务器参考时间存在稳定的7 s系统性偏移,因此本研究按照偏移方向统一进行7 s补偿。完成上述校准后,根据时间戳对PSG与雷达数据进行初步对齐。随



图2 无线睡眠数据采集场景

Fig. 2 Contactless sleep monitoring data acquisition scenarios

后,本研究将雷达提取的呼吸波形与PSG同步记录的胸腹带及气流波形进行二次校准。具体而言,本研究以雷达呼吸波形与PSG信号中同步出现的呼吸节律和事件相关波形变化为参照,对上述对齐结果进行核验,确认两类数据在整夜记录中保持一致的时间对应关系。通过上述对齐流程,可进一步减小设备启动偏差、系统性时间偏移及整夜累积误差对睡眠分期和呼吸障碍检测的影响。

2.2.2 无线数据集构成

本研究构建了一个大规模毫米波雷达数据集,该数据集包含来自83位不同参与者的103夜记录,其中包含65名男性和18名女性,部分参与者提供了多晚记录。具体构建流程如图3所示,完成PSG和雷达数据采集后,对雷达数据进行预处理以提取呼吸信号,同时由至少两名具备专业资质的专家对PSG信号进行人工判读与标注,为后续数据集构建提供可靠标签。经数据质量筛选后,最终纳入100夜有效记录。数据采集覆盖医院病房(66%)、酒店房间(9%)和私人住宅(25%)3种真实睡眠场景,可用于验证所提方法在不同受试者和复杂环境下的性能表现。受试者包括健康参与者和患有呼吸系统或心血管疾病的个体,年龄范围为26~90岁。每夜睡眠平均持续约9小时,累计采集约900小时的雷达和PSG记录。

表1进一步补充了数据集的详细统计信息。睡眠分期任务中清醒期、浅睡期、深睡期和快速眼动期分别占21.61%, 55.42%, 10.87%和12.09%,呼吸障碍检测任务中正常呼吸、呼吸暂停和低通气分别占78.69%, 14.47%和6.84%。两个任务均存在一定程度的类别不平衡,其中呼吸障碍检测任务更为明显,低通气事件仅占6.84%。

2.3 雷达信号预处理

2.3.1 空间增强与呼吸相位提取

本文采用FMCW毫米波雷达作为主要采集设




图 3 数据集构造流程

Fig. 3 Dataset construction workflow

表 1 数据集中各任务的类别分布(%)

Tab. 1 Class distribution of different tasks in the dataset(%)

	睡眠分期					呼吸障碍	
类别	Wake	Light	Deep	REM	Normal	Apnea	Hypopnea
比例	21.61	55.42	10.87	12.09	78.69	14.47	6.84

备。FMCW雷达通过周期性发射频率随时间线性变化的调频连续波，并接收人体及周围环境的反射回波，实现目标距离及微小位移信息的获取^[26-29]。在实际睡眠监测场景中，雷达接收回波不仅包含胸腹部呼吸反射，还会受到床体、墙面以及人体其他部位反射的影响。仅基于单一接收通道或距离单元进行呼吸提取会导致回波信号受到多径传播和环境杂波干扰，进而影响相位的稳定性。为增强胸腹部所在空间方向的有效回波，并削弱其他方向的干扰，本研究采用3发射、4接收的MIMO阵列获得12个虚拟通道的阵列观测，并在此基础上进行空间波束成形^[30]。进一步地，根据雷达到胸腹区域的先验安装距离，结合距离像能量分布，选取覆盖胸腹主反射区域的候选距离单元。本文实验中该区域对应原始距离向索引第14~23距离单元。

设第 m 个慢时间帧、第 r 个距离单元上的虚拟阵列接收向量为

$$\mathbf{x}(r, m) = [x_1(r, m), x_2(r, m), \dots, x_N(r, m)]^T, \quad (1)$$

其中， N 为虚拟阵列通道数， $\mathbf{x}(r, m)$ 描述了第 r 个距离单元在第 m 个时间帧的复数回波响应。为增强来自候选方向 (θ, φ) 的回波，需要根据不同虚拟阵元相对于参考阵元的传播路径差进行相位校正。第 n 个虚拟阵元对应的导向系数可表示为

$$a_n(\theta, \varphi) = \exp\left(-j2\pi \frac{\Delta d_n(\theta, \varphi)}{\lambda}\right), \quad (2)$$

其中， $\Delta d_n(\theta, \varphi)$ 表示来自空间方向 (θ, φ) 的信号到

达第 n 个虚拟阵元时相对于参考阵元的传播路径差， λ 为雷达波长。将所有虚拟阵元的导向系数排列后，可得到对应方向上的阵列导向向量：

$$\mathbf{a}(\theta, \varphi) = [a_1(\theta, \varphi), a_2(\theta, \varphi), \dots, a_N(\theta, \varphi)]^T. \quad (3)$$

进一步利用该导向向量对虚拟阵列回波进行空间加权，可得到候选距离-角度单元上的复回波序列：

$$z(r, \theta, \varphi, m) = \mathbf{a}^H(\theta, \varphi) \mathbf{x}(r, m), \quad (4)$$

其中， $(\cdot)^H$ 表示共轭转置。该操作通过对目标方向上的多通道回波进行相位对齐和相干叠加，增强胸腹部所在方向的反射分量，同时抑制其他空间方向的干扰。

经过距离向处理和空间波束成形后，雷达回波被转换为距离-角度空间中的复回波序列。然而，复回波中仍可能存在床体、墙面等静态或准静态反射分量。由于这些分量通常具有较强幅值，其在复平面中会主导回波的整体相位响应，从而削弱胸腹部呼吸微动所引起的相位变化，影响后续呼吸相位提取的稳定性。为此，本研究采用时间均值相减的方式进一步去除静态背景分量，削弱床体、墙面等静态反射对相位提取的影响，使后续相位序列更突出胸腹部呼吸微动信息。

记第 p 个候选距离-角度单元的复回波序列为

$$H_p(m) = z(r_p, \theta_p, \varphi_p, m),$$

其中 $(r_p, \theta_p, \varphi_p)$ 表示第 p 个候选距离-角度单元。时间均值相减后：

$$\tilde{H}_p(m) = H_p(m) - \frac{1}{M} \sum_{u=1}^M H_p(u), \quad (5)$$

其中， M 表示当前分析序列中的慢时间帧数， $\tilde{H}_p(m)$ 则为静态杂波抑制后的复回波序列。

随后, 本文对抑制杂波后的复回波进行相位提取, 并通过相位解缠获得连续的候选呼吸微动相位序列:

$$\phi_p(m) = \text{unwrap} \left(\arg \left(\tilde{H}_p(m) \right) \right), \quad (6)$$

其中, $\arg(\cdot)$ 表示复数取相位操作, $\text{unwrap}(\cdot)$ 表示相位解缠操作。得到的 $\phi_p(m)$ 反映了第 p 个候选距离-角度单元沿雷达视线方向的微位移变化, 可作为后续呼吸信号构建的候选相位序列。图4展示了原始雷达能量图与空间增强后的能量图。结果表明, 空间增强能够有效突出目标区域能量响应, 并提升雷达信号质量。

2.3.2 呼吸相位评估与时序融合

经过空间增强与相位提取后, 可获得多个候选距离-角度单元对应的解缠相位序列。然而, 不同距离-角度单元对胸腹部微动的敏感程度存在差异。靠近胸腹部主反射区域的单元通常能够呈现较清晰的周期性变化, 而偏离目标区域的单元则更容易受到环境反射、多径分量或局部体动的影响。因此, 本文先对候选序列进行质量评估, 再融合多个可靠候选单元以增强呼吸序列的稳定性。

对于第 p 个候选距离-角度单元的解缠相位序列 $\phi_p(m)$, 首先计算其功率谱:

$$P_p(f) = |\mathcal{F}(\phi_p(m))|^2, \quad (7)$$

其中, $\mathcal{F}(\cdot)$ 表示傅里叶变换。考虑到睡眠状态下呼吸信号主要分布在低频范围, 本文定义呼吸信噪比 (Breathing-to-Noise Ratio, BNR)^[31] 用于衡量候选相位序列中呼吸节律成分的显著程度:

$$\text{BNR}_p = \frac{\max_{f \in B_{\text{resp}}} P_p(f)}{\sum_{f \in \Omega} P_p(f)} \quad (8)$$

其中, $B_{\text{resp}} = [0.15, 0.5]$ Hz 表示睡眠呼吸主要频带, Ω 表示完整分析频率范围。较高的 BNR_p 表明该候

选相位序列在呼吸频带内具有更突出的主峰, 呼吸节律特征相对更加明显。

本文选取BNR最高的前 k 个候选距离-角度单元, 记其集合为 P 。随后, 对 P 中各候选单元的相位序列进行聚合, 构建雷达呼吸感知信号:

$$s(m) = \frac{1}{k} \sum_{p \in P} \phi_p(m), \quad (9)$$

其中, k 值设置为5。由多个高BNR候选单元聚合得到的 $s(m)$ 能够突出呼吸频带内的主导周期成分, 降低局部干扰引起的不稳定性。图5展示了基于BNR估计的雷达呼吸信号与胸腹带参考呼吸信号的对比。其中, 蓝色曲线表示BNR最高的5个候选单元对应的雷达呼吸相位序列, 橙色曲线表示经过聚合后得到的雷达呼吸信号, 红色和绿色曲线分别表示胸带和腹带参考呼吸信号。结果表明, 预处理后的雷达呼吸信号和胸腹带参考信号在呼吸节律和整体变化趋势上具有较好一致性。在呼吸减弱和波动异常的片段中, 雷达呼吸信号也能够反映与胸腹带信号相对应的异常变化。

聚合得到的呼吸信号仍可能包含高频波动和瞬时体动等带来的局部扰动。为抑制高频波动并保留主要呼吸动态, 本研究对呼吸信号进行时间平滑。设 Δ 为采样间隔, $s_i = s(t + i\Delta)$, $i = -3, -2, \dots, 3$, 则七点对称平滑算子可表示为

$$\tilde{s}(t) = \frac{s_{-3} + 2s_{-2} + 3s_{-1} + 4s_0 + 3s_1 + 2s_2 + s_3}{16}. \quad (10)$$

完成平滑处理后, 雷达呼吸感知信号被重采样至10 Hz。该采样率已能够覆盖后续分期与呼吸障碍检测所需的主要时序信息, 同时可压缩整夜数据长度, 提升模型训练与推理效率。

最后, 为减小不同受试者、雷达反射强度和安装条件差异带来的偏移, 本文对下采样后的信号进




图4 空间增强前后雷达能量分布对比

Fig. 4 Comparison of radar energy distributions before and after spatial enhancement




图 5 基于BNR估计的雷达呼吸信号与胸腹带参考呼吸信号的对比

Fig. 5 Comparison of radar respiratory signals estimated from BNR and reference respiratory signals from thoracoabdominal belts

行标准化处理，并将得到的雷达呼吸时序数据作为后续睡眠监测模型的输入。

3 多任务睡眠监测网络算法

本研究提出了一个基于脑电信息监督的渐进式非接触睡眠监测框架。通过将脑电监督引入呼吸建模，该框架将雷达呼吸表征与脑电特征对齐，使模型能够更好地从雷达信号中捕捉睡眠状态的变化。具体细节如下文描述。

3.1 主干框架

为支撑所提出的渐进式跨模态迁移思想，本文采用统一的主干网络结构，并将其分别应用于脑

电、呼吸和雷达信号建模。如图6所示，该主干网络由局部特征提取模块、全局时序建模模块和门控特征选择模块组成。首先，针对每个睡眠时间窗，采用基于ResNet-34^[32]的卷积编码器提取局部特征，以捕获短时间尺度内的信号变化模式。随后，将局部特征输入双向状态空间模型(Bi-SSM)^[33-35]，用于建模整夜序列中的长程时序依赖和睡眠结构演化规律。最后，通过门控机制^[36]对不同时间位置的特征进行自适应调节，保留对任务判别更有贡献的时序信息，并抑制冗余特征。

由于脑电、呼吸和雷达分支采用一致的主干结构，模型能够在不同模态之间保持相近的表征形式，从而为参数迁移和知识传递提供结构基础。在此基础上，本文依次完成脑电教师模型构建、呼吸学生模型蒸馏以及雷达模型初始化，使脑电信号中蕴含的睡眠判别信息能够逐步迁移至雷达可感知的呼吸特征中。

3.2 基于脑电信号的睡眠教师模型

本研究首先构建了一个基于脑电信号的教师模型，其核心作用是利用脑电信号对睡眠状态的直接表征能力，提取分期与呼吸障碍判读所需的判别信息，并将其作为后续跨模态迁移过程中指导呼吸模型学习的监督源。该框架内，睡眠分期为四分类任务，而呼吸障碍检测为粗粒度的二分类任务，用于区分正常和异常的呼吸状态。考虑到脑电信号虽能够反映呼吸事件相关的觉醒反应，但难以直接刻画胸腹运动变化，因此仅依赖脑电信息难以稳定区分呼吸暂停与低通气等细粒度呼吸障碍事件。




图 6 非接触睡眠监测主干框架

Fig. 6 Backbone framework for contactless sleep monitoring

具体而言, 令 $\mathbf{x}^e$ 表示脑电信号。共享主干网络 $f_{\theta}(\cdot)$ 中包含了两个任务头 $h_s(\cdot)$ 和 $h_d(\cdot)$, 分别代表四分类分期与二分类障碍, 其结果如下:

$$\mathbf{z}^e = f_{\theta_e}(\mathbf{x}^e), \hat{\mathbf{y}}_s^e = h_s(\mathbf{z}^e), \hat{\mathbf{y}}_d^e = h_d(\mathbf{z}^e), \quad (11)$$

其中, $\mathbf{z}^e$ 表示学习到的脑电信号的时序特征, $\hat{\mathbf{y}}_s^e$ 和 $\hat{\mathbf{y}}_d^e$ 分别表示睡眠分期和粗粒度呼吸障碍预测的概率分布。

脑电教师模型的训练损失如下:

$$\mathcal{L}_{\text{EEG}} = \mathcal{L}_{\text{CE}}(\hat{\mathbf{y}}_s^e, y_s) + \lambda_d \mathcal{L}_{\text{CE}}(\hat{\mathbf{y}}_d^e, y_d), \quad (12)$$

其中, y_s 是四分类睡眠阶段标签, y_d 是二分类呼吸障碍标签, $\mathcal{L}_{\text{CE}}$ 是交叉熵损失, λ_d 是用于平衡损失的系数, 本研究设为0.6。

3.3 基于知识蒸馏的呼吸学生模型

在本模块中, 本研究构建基于胸腹带呼吸信号的学生模型, 并利用脑电教师模型提供的睡眠判别信息对其进行跨模态监督。与脑电信号相比, 呼吸信号在生理来源上更接近雷达感知信号, 二者均能够反映睡眠过程中的呼吸运动。同时, 呼吸信号能够反映睡眠过程中的呼吸节律、幅度变化及胸腹运动特征, 是区分正常呼吸、呼吸暂停和低通气等状态的关键依据。因此, 在呼吸学生模型中, 呼吸障碍检测任务由脑电教师阶段的粗粒度二分类进一步扩展为细粒度三分类任务。通过这一设计, 呼吸信号不仅能够承接脑电教师模型中的睡眠判别信息, 还能够补充更直接的呼吸障碍表征, 从而在脑电信号与雷达信号之间起到桥接作用。

3.3.1 学生模型

给定呼吸输入 $\mathbf{x}^r$, 学生模型可表示为

$$\mathbf{z}^r = f_{\theta_r}(\mathbf{x}^r), \hat{\mathbf{y}}_s^r = h_s(\mathbf{z}^r), \hat{\mathbf{y}}_d^r = h_d(\mathbf{z}^r), \quad (13)$$

其中, $f_{\theta}(\cdot)$ 表示共享主干网络, $\mathbf{z}^r$ 表示学习到的呼吸信号的时序特征, $h_s(\cdot)$ 和 $h_d(\cdot)$ 分别代表四分类分期与三分类障碍分类头, $\hat{\mathbf{y}}_s^r$ 表示睡眠分期的预测概率, $\hat{\mathbf{y}}_d^r$ 表示在由正常、呼吸暂停和低通气组成的三分类呼吸障碍的预测概率分布。

3.3.2 蒸馏过程

本研究在睡眠分期和呼吸障碍检测任务中, 均采用教师模型输出的预测概率分布作为蒸馏目标, 通过软标签监督引导学生模型学习教师模型的判别知识。对于睡眠分期任务, 教师模型和学生模型具有相同的输出类别空间, 其蒸馏损失定义为

$$\mathcal{L}_{\text{KD-s}} = T^2 \text{KL} \left(\sigma \left(\frac{\hat{\mathbf{y}}_s^e}{T} \right) \parallel \sigma \left(\frac{\hat{\mathbf{y}}_s^r}{T} \right) \right), \quad (14)$$

其中, T 为蒸馏温度, $\text{KL}(\cdot \parallel \cdot)$ 表示Kullback-Leibler散度, $\sigma(\cdot)$ 表示softmax函数。

对于呼吸障碍检测任务, 教师模型采用正常/异常二分类输出, 而学生模型采用正常、呼吸暂停和低通气三分类输出。由于二者的输出类别空间不一致, 本研究引入映射函数 $\mathcal{M}(\cdot)$, 将学生模型的三分类预测概率分布映射到教师模型的二分类空间, 从而实现跨类别空间的知识蒸馏:

$$\tilde{\mathbf{y}}_d^r = \mathcal{M}(\hat{\mathbf{y}}_d^r). \quad (15)$$

进一步地, 其蒸馏损失定义为

$$\mathcal{L}_{\text{KD-d}} = T^2 \text{KL} \left(\sigma \left(\frac{\hat{\mathbf{y}}_d^e}{T} \right) \parallel \sigma \left(\frac{\tilde{\mathbf{y}}_d^r}{T} \right) \right). \quad (16)$$

3.3.3 任务预测与损失函数

学生模型采用监督损失与蒸馏损失联合优化, 其整体损失函数定义为

$$\mathcal{L}_{\text{resp}} = \mathcal{L}_{\text{CE}}(\hat{\mathbf{y}}_s^r, y_s) + \lambda_d^r \mathcal{L}_{\text{CE}}(\hat{\mathbf{y}}_d^r, y_d) + \lambda_s^{\text{KD}} \mathcal{L}_{\text{KD-s}} + \lambda_d^{\text{KD}} \mathcal{L}_{\text{KD-d}}, \quad (17)$$

其中, $\mathcal{L}_{\text{CE}}$ 表示交叉熵损失, $\hat{\mathbf{y}}_s^r$ 和 $\hat{\mathbf{y}}_d^r$ 分别表示呼吸学生模型对睡眠分期和呼吸障碍检测任务的预测概率分布, y_s 和 y_d 分别表示对应的真实标签。 $\mathcal{L}_{\text{KD-s}}$ 和 $\mathcal{L}_{\text{KD-d}}$ 分别表示睡眠分期和呼吸障碍预测的蒸馏损失。 λ_d^r , λ_s^{KD} 和 λ_d^{KD} 为平衡不同损失项贡献的权重系数, 本研究分别设置为0.6, 0.7和0.5。

3.4 基于预训练的无线睡眠监测模型

本研究进一步将由呼吸学生模型初始化的雷达模型应用于多任务学习框架, 实现基于雷达信号的非接触式睡眠分期与呼吸障碍检测。本文引入层次化监督策略, 将复杂的睡眠监测任务拆解为由粗到细的逐级学习过程, 从而降低模型学习难度。具体而言, 在睡眠分期任务中, 清醒/睡眠的粗粒度区分较具体睡眠阶段的细粒度识别更为容易^[1]。同样地, 在呼吸障碍检测任务中, 正常/异常呼吸状态的判别也较呼吸暂停和低通气等具体异常类型的区分更为容易。基于这一特点, 本研究使用层次化监督思想, 将模型学习过程划分为粗粒度状态判别和细粒度类别识别两个层次, 使模型在学习复杂类别边界之前先获得稳定的基础判别能力, 从而加强模型对于雷达睡眠表征的理解。

3.4.1 预训练初始化

令 $\mathbf{x}^m$ 表示雷达信号。由于雷达模型与呼吸学生模型采用一致的主干架构, 本研究将呼吸学生模型中学习到的主干参数迁移至雷达模型, 用于初始化雷达分支:

$$\theta_m \leftarrow \theta_r, \quad (18)$$

其中 θ_r 和 θ_m 分别表示呼吸学生模型和雷达模型的主干参数。基于该初始化，雷达分支对输入信号进行特征提取，得到雷达时序表征：

$$z^m = f_{\theta_m}(x^m), \quad (19)$$

其中， z^m 表示学习到的雷达信号的时域表示。

3.4.2 基于层次化监督的多任务分类

如前文所述，本研究同时考虑睡眠分期和呼吸障碍检测两个任务，并为每个任务设置粗粒度和细粒度两个预测层级。睡眠分期任务中，粗粒度预测头用于区分清醒和睡眠状态，细粒度预测头进一步识别清醒期、浅睡期、深睡期和快速眼动期阶段。呼吸障碍检测任务中，粗粒度预测头用于区分正常呼吸和异常呼吸状态，细粒度预测头进一步识别正常呼吸、呼吸暂停和低通气类别。形式上，该分层多任务预测过程可表示为

$$(\hat{y}_{s,c}^m, \hat{y}_{s,f}^m) = h_s(z^m), (\hat{y}_{d,c}^m, \hat{y}_{d,f}^m) = h_d(z^m), \quad (20)$$

其中， $h_s(\cdot)$ 和 $h_d(\cdot)$ 分别表示睡眠分期和呼吸障碍预测的分层预测头， $\hat{y}_{s,c}^m$ 和 $\hat{y}_{s,f}^m$ 分别表示睡眠分期任务的粗粒度和细粒度预测输出， $\hat{y}_{d,c}^m$ 和 $\hat{y}_{d,f}^m$ 分别表示呼吸障碍检测任务的粗粒度和细粒度预测输出。

在雷达模型训练阶段，本文基于上述分层预测结构构建多层次监督损失，以同时优化睡眠分期和呼吸障碍检测任务：

$$\begin{aligned} \mathcal{L}_{\text{radar}} = & \lambda_{s,c} \mathcal{L}_{\text{CE}}(\hat{y}_{s,c}^m, y_{s,c}) + \lambda_{s,f} \mathcal{L}_{\text{CE}}(\hat{y}_{s,f}^m, y_{s,f}) \\ & + \lambda_{d,c} \mathcal{L}_{\text{CE}}(\hat{y}_{d,c}^m, y_{d,c}) + \lambda_{d,f} \mathcal{L}_{\text{CE}}(\hat{y}_{d,f}^m, y_{d,f}), \end{aligned} \quad (21)$$

其中 $y_{s,c}$, $y_{s,f}$, $y_{d,c}$, $y_{d,f}$ 分别表示睡眠分期和呼吸障碍检测任务在不同监督层级下的真实标签，而 $\lambda_{s,c}$, $\lambda_{s,f}$, $\lambda_{d,c}$, $\lambda_{d,f}$ 为损失权重，用于平衡不同任务和不同监督层级对模型训练的贡献，本研究分别设置为 0.5, 1, 0.3 和 0.6。

3.4.3 模型实现细节

在模块实现方面，局部特征提取模块采用改进的 ResNet-34 编码器，其初始卷积核大小设置为 7、步长设置为 5，以扩大有效感受野并降低后续序列建模的计算负担。同时，将 ReLU 激活函数替换为 GELU，以提升小批量训练条件下的稳定性。序列建模模块由 4 层双向状态空间模型组成，隐藏维度设置为 512，用于建模双向长程时间依赖。针对整夜记录的长序列特性，采用对角状态空间模型 S4D 对该模块进行实例化，通过对角化状态矩阵实现高

效并行计算，使模型能够以较低的计算开销完成长时间尺度的序列建模。

为确定合适的模型配置，本研究对学习率、批次大小、损失函数权重和 L2 正则化系数等关键超参数进行局部网格搜索。模型采用 Adam 优化器进行训练，批次大小设置为 2，初始学习率设置为 4×10^{-4} ，权重衰减设置为 1×10^{-4} ，并采用余弦退火策略动态调整学习率。所有实验均在单张 NVIDIA GeForce RTX 4090 显卡上完成。

4 结果与分析

为避免同一受试者的不同夜间记录同时出现在训练集和验证集中而导致信息泄露，本研究以受试者为划分单位，确保训练集与验证集之间不存在受试者重叠。具体而言，对于公开数据集，本研究按照 85:15 的比例构建训练集和验证集。对于雷达数据集，采用 10 折交叉验证策略，每次选取约 1/10 的受试者作为验证集，其余受试者作为训练集，重复 10 次后对各折结果进行汇总，以评估模型的整体性能。公开数据和雷达数据中的预处理信号均被划分为连续且互不重叠的 30 s 时段，步长设置为 30 s，输入长度覆盖整夜记录。考虑到不同夜间记录的序列长度存在差异，批处理过程中采用补零与掩码机制进行长度对齐，补零位置不参与损失计算。

睡眠分期任务为四分类任务，分别为清醒期 (Wake)、浅睡期 (Light)、深睡期 (Deep) 和快速眼动期 (REM)。对于呼吸障碍标签，本研究保留了睡眠专家标注的呼吸事件起止时间、持续时间及事件类型，并在此基础上构建与睡眠分期时段一致的睡眠时段 (epoch) 标签。当出现跨越睡眠时段边界的呼吸事件，本研究将事件覆盖不少于 5 s 的边界时段同样标记为异常。阻塞性、中枢性和混合型呼吸暂停统一归为呼吸暂停，最终形成正常 (Normal, N)、呼吸暂停 (Apnea, A) 和低通气 (Hypopnea, H) 三类标签。当同一睡眠时段内包含多种呼吸事件时，将重叠时间最长的事件作为该时段的标签。若呼吸暂停与低通气事件的重叠时间相同，则按照临床评分原则优先标记为呼吸暂停。

模型性能采用准确率 (Accuracy, Acc)、Cohen's kappa 系数 (κ)、宏平均 F1 值 (Macro-F1, MF1)、灵敏度 (Sensitivity, Sens) 和特异性 (Specificity, Spec) 进行评价。其中，Acc 用于衡量整体分类正确率， κ 用于评估模型预测与真实标签之间的一致性并减弱随机一致性的影响，MF1 用于衡量类别不均衡条件下的平均分类性能，Sens 和 Spec 分别反映模型对目标类别和非目标类别的识别能力。在整体性

能比较中,本研究采用十折交叉验证,并报告各折评价指标的均值和标准差,以综合反映模型的平均性能及其在不同数据划分下的稳定性。后续机制验证与消融实验均在统一的单折数据和实验设置下进行,以保证不同模型配置之间比较的公平性。

4.1 整体性能比较

本文将所提方法与多类代表性基线方法进行对比,以评估其在睡眠分期和呼吸障碍检测任务中的性能,实验结果如表2和表3所示。在睡眠分期任务中,本文选取RadioSleep^[5],Hypnos^[13]和ResSleepNet^[14]等方法作为基线模型进行比较。上述方法均包含睡眠分期任务,并采用不同的睡眠感知与建模策略,覆盖了现有方法中具有代表性的技术路线,能够较为客观地反映本研究方法在睡眠分期任务中的性能表现。对于呼吸障碍检测任务,现有无线方法多聚焦于粗粒度事件检测或者AHI统计,专门面向呼吸暂停和低通气细粒度分类的雷达基线相对有限。因此,本文进一步引入细粒度呼吸障碍检测方法作为补充对比^[37,38]。

对于尚未公开源代码的基线方法,本研究依据公布的模型架构和训练细节进行复现。其中明确给出的模型超参数,包括网络层数、隐藏层维度、注意力头数和损失权重,均保持不变。批大小和学习率等训练超参数则通过小范围搜索确定,以保证模型在当前计算环境下稳定收敛。对于已公开源代码的基线方法,本研究直接采用GitHub上提供的模型实现和预训练权重。为保证比较的公平性,所有方法均采用相同的十折交叉验证划分策略,各折的训练受试者和验证受试者在不同方法之间保持一

致,且同一受试者的不同夜间记录不会同时出现在训练集和验证集中。此外,各方法采用相同的雷达呼吸信号作为输入,并使用一致的标签映射规则和评价指标。

如表2所示,在睡眠分期任务中,所提方法在各项总体评价指标上均取得最优性能,Acc, κ , MF1, Sens和Spec分别达到82.6%, 0.711, 78.9%, 78.5%和92.4%。与性能最佳的基线方法相比,Acc, MF1和Sens分别提升3.6, 7.3和6.3%,表明所提方法能够有效提升整体睡眠分期性能。从分类别结果来看,所提方法在4个睡眠阶段均取得最高识别性能,准确率分别达到84.6%, 86.0%, 69.9%和73.7%。其中,快速眼动睡眠阶段的提升最为显著,较最佳基线提高10.3%。快速眼动睡眠阶段的呼吸节律波动较大,且其部分呼吸特征与清醒及浅睡期阶段存在重叠,使得仅依赖雷达信息时容易产生阶段混淆。所提方法通过呼吸中间模态逐步引入脑电教师模型提炼的高层睡眠判别信息,从而增强了不同睡眠阶段之间的特征区分能力,这一作用在快速眼动睡眠阶段表现得尤为明显。

如表3所示,在呼吸障碍检测任务中,所提方法在大部分主要评价指标上均取得最优性能, κ , MF1, Sens和Spec分别达到0.593, 68.0%, 74.8%和91.5%。值得注意的是,从分类别结果来看,本文方法的性能提升并非主要来自占比较高的正常类别,而是同时体现在异常呼吸类别的识别上。其中,呼吸暂停和低通气的识别准确率分别达到77.6%和61.8%,均高于其他基线方法。这表明本文提出的框架能够更有效地提取呼吸障碍事件相关的细粒度呼吸特征。

表 2 与代表性基线方法的睡眠分期性能比较
Tab. 2 Comparison of sleep staging performance with representative baselines

方法	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	Wake (%)	Light (%)	Deep (%)	REM (%)
RadioSleep ^[5]	79.0±6.9	0.641±0.16	71.6±5.9	72.2±5.9	90.4±4.1	82.4±3.4	84.8±2.1	67.6±7.1	54.2±2.3
Hypnos ^[13]	76.5±4.4	0.595±0.11	67.1±3.2	67.6±1.8	89.4±3.5	76.3±5.3	82.3±8.4	53.4±4.5	58.3±4.1
ResSleepNet ^[14]	73.1±2.9	0.557±0.05	66.1±4.8	70.9±4.8	89.4±1.2	72.0±5.1	76.3±1.9	52.3±7.8	63.4±9.0
本文方法	82.6±2.2	0.711±0.04	78.9±2.9	78.5±3.0	92.4±1.1	84.6±5.8	86.0±2.2	69.9±6.3	73.7±4.1

注:表内加粗数值表示各项评价指标中的最优结果。

表 3 与代表性基线方法的呼吸障碍检测性能比较
Tab. 3 Comparison of respiratory disorder detection performance with representative baselines

方法	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	N (%)	A (%)	H (%)
Vaquerizo等人 ^[37]	81.1±2.0	0.548±0.05	64.6±3.7	69.1±3.9	88.9±1.4	87.0±2.6	62.6±10.6	57.8±5.3
Choi等人 ^[38]	84.2±1.6	0.587±0.04	66.0±1.8	66.7±2.2	87.8±1.0	90.9±1.5	74.1±9.4	35.2±6.1
本文方法	82.5±4.1	0.593±0.06	68.0±3.9	74.8±3.0	91.5±1.2	85.1±4.0	77.6±7.8	61.8±4.4

注:表内加粗数值表示各项评价指标中的最优结果。

总体而言,上述结果表明,本文提出的渐进式跨模态迁移方法能够有效提升雷达信号的睡眠分期和呼吸障碍检测性能。同时,除Acc外,其余指标在不同交叉验证折之间的波动较小,说明所提方法具有较为稳定的性能表现。

4.2 脑电知识迁移有效性分析

为验证利用脑电知识迁移的有效性,本文设计了对照实验。具体而言,本文首先基于公开数据集构建了不引入脑电教师监督的对比模型(without Knowledge Distillation, w/o KD),即直接基于呼吸信号进行训练,并将其与引入脑电教师知识蒸馏的模型进行比较(with Knowledge Distillation, w/ KD)。实验结果如表4所示。

与直接基于呼吸信号训练相比,引入脑电教师知识后,模型整体性能得到明显提升,Acc、 κ 和MF1分别提高3.7%,0.056和4.5%。分类别结果进一步表明,性能增益主要体现在深睡期和快速眼动期,其识别准确率分别提高9.7%和3.4%。

进一步地,本文将蒸馏前后的呼吸学生模型分别迁移至雷达模型,并采用完全相同的数据划分、

模型结构及训练参数进行优化,实验结果如表5所示。引入脑电知识后,雷达模型的各项整体性能指标均得到提升。分类别结果进一步显示,4个睡眠阶段的识别准确率均有所改善,其中Wake, Deep和REM提升最为明显。该结果表明,脑电教师模型所提供的睡眠信息能够通过呼吸中间模态传递至雷达模型。脑电知识蒸馏能够在呼吸表征中引入更具判别性的高层信息,并借助呼吸与雷达之间较强的生理关联将其进一步迁移,从而增强雷达模型对不同睡眠阶段的区分能力。

4.3 预训练策略有效性分析

为进一步验证预训练策略的有效性,本文将其与直接知识蒸馏方式进行比较。具体而言,直接蒸馏方法跳过呼吸学生模型的中间阶段,直接利用公开数据集上基于脑电信号和胸腹呼吸带信号训练得到的教师模型对雷达侧学生模型进行蒸馏监督,实验结果如表6和表7所示。可以观察到,在睡眠分期和呼吸障碍检测两个任务中,预训练策略在各项性能指标上均明显优于直接蒸馏方法。上述结果表明,公开数据集与雷达数据集之间存在明显的模态

表 4 脑电知识对睡眠分期性能的影响
Tab. 4 Effect of EEG knowledge on sleep staging performance

方法	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	Wake (%)	Light (%)	Deep (%)	REM (%)
w/o KD	74.5	0.623	71.1	70.9	90.3	81.7	76.1	43.0	82.6
w/ KD	78.2	0.679	75.6	75.5	91.7	84.4	78.8	52.7	86.0

注:表内加粗数值表示各项评价指标中的最优结果。

表 5 脑电知识蒸馏对雷达睡眠分期性能的影响
Tab. 5 Effect of EEG knowledge distillation on radar-based sleep staging performance

方法	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	Wake (%)	Light (%)	Deep (%)	REM (%)
w/o KD	80.1	0.674	76.4	75.2	91.3	80.8	85.1	65.8	69.2
w/ KD	82.7	0.719	79.6	78.9	92.5	85.6	85.9	69.9	74.3

注:表内加粗数值表示各项评价指标中的最优结果。

表 6 直接知识蒸馏与所提方法的睡眠分期性能比较
Tab. 6 Sleep staging performance comparison between direct knowledge distillation and ours

方法	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	Wake (%)	Light (%)	Deep (%)	REM (%)
直接蒸馏	77.2	0.626	72.9	71.8	90.0	76.6	82.9	62.2	65.6
本文方法	82.7	0.719	79.6	78.9	92.5	85.6	85.9	69.9	74.3

注:表内加粗数值表示各项评价指标中的最优结果。

表 7 直接知识蒸馏与所提方法的呼吸障碍检测性能比较
Tab. 7 Respiratory disorder detection performance comparison between direct knowledge distillation and ours

方法	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	N (%)	A (%)	H (%)
直接蒸馏	78.1	0.500	62.1	68.1	88.7	81.8	70.7	51.9
本文方法	82.7	0.593	68.2	75.2	91.6	85.3	78.1	62.3

注:表内加粗数值表示各项评价指标中的最优结果。

差异和数据域差异，直接从基于公开数据集的教师模型向雷达模型进行知识蒸馏较为困难。相比之下，先将脑电知识迁移至呼吸模型，再基于呼吸模型预训练对雷达模型进行初始化，能够将跨模态迁移过程分解为更加平滑的两个阶段，从而降低由域差异带来的优化难度，并提升雷达睡眠分析模型的整体性能。

4.4 层次化监督策略有效性分析

为了更清晰地量化层次化监督策略对雷达模型性能的独立贡献，本研究增加了基于层次化监督策略的对比实验。具体而言，在保持其余网络结构和训练设置不变的情况下，本研究分别去除睡眠分期任务中的清醒/睡眠粗粒度预测头和呼吸障碍检测任务中的正常/异常粗粒度预测头，仅采用四分类睡眠分期和三分类呼吸障碍检测的细粒度监督，结果如表8所示。实验结果表明，引入层次化监督后，睡眠分期和呼吸障碍检测任务的各项评价指标均得到一致提升。由于雷达信号所包含的生理信息相对有限，不同类别之间的特征差异较弱，直接进行细粒度多类别判别容易产生混淆。粗粒度辅助监督能够先帮助模型建立更稳定的状态表征，再在此

基础上学习细粒度类别间的差异，从而有效降低任务的学习难度。

4.5 不同规模数据集性能验证

现有雷达睡眠监测方法通常通过引入多个公开数据集中的呼吸信号进行预训练，以增强模型在雷达数据上的适配能力。本文方法则在呼吸建模阶段进一步利用脑电教师模型提供的睡眠判别信息，使模型能够在有限公开数据条件下学习更有效的睡眠相关表征。为分析公开数据规模对模型性能的影响，本文采用不同规模的公开数据集组合训练模型，并比较其迁移至雷达数据后的性能表现。具体而言，本文分别采用SHHS1(S1, 5548份记录)、SHHS1与SHHS2组合(S1&S2, 8200份记录)，以及SHHS1, SHHS2与MESA组合(S1&S2&M, 10054份记录)，实验结果如表9和表10所示。

结果显示，仅使用S1训练时，雷达模型即可取得最优或接近最优的整体性能。随着公开数据规模进一步扩展至S1+S2和S1+S2+MESA，模型性能并未呈现持续提升，部分指标甚至出现轻微下降。这说明，本文提出的渐进式跨模态学习框架具有较高的数据利用效率，有限规模的公开数据已足以支持模型学习可迁移的睡眠判别信息，从而降低由多个数据集整合和跨域预训练带来的模型开发与训练成本。

4.6 多任务性能分析

睡眠分期与呼吸障碍检测具有任务互补性，二者可从睡眠状态和呼吸异常两个角度共同约束模型学习，从而增强睡眠相关特征表征^[1]。为评估多任务学习的有效性，本文在相同实验设置下比较了单

表 8 层次化监督策略的消融实验结果

Tab. 8 Ablation results of the hierarchical supervision strategy

任务	方法	Acc(%)	κ	MF1(%)	Sens(%)	Spec(%)
睡眠分期	w/o HS	81.4	0.696	78.0	77.2	91.9
	w/ HS	82.7	0.719	79.6	78.9	92.5
呼吸障碍	w/o HS	80.4	0.553	66.0	73.4	90.6
	w/ HS	82.7	0.593	68.2	75.2	91.6

注：表内加粗数值表示各项评价指标中的最优结果。

表 9 不同数据集下睡眠分期性能比较

Tab. 9 Sleep staging performance comparison with different datasets

数据集组合	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	Wake (%)	Light (%)	Deep (%)	REM (%)
S1	82.7	0.719	79.6	78.9	92.5	85.6	85.9	69.9	74.3
S1&S2	81.9	0.705	78.7	78.0	92.1	83.5	85.6	69.3	73.6
S1&S2&M	82.4	0.714	79.4	79.0	92.4	84.6	85.4	70.8	75.0

注：表内加粗数值表示各项评价指标中的最优结果。

表 10 不同数据集下呼吸障碍检测性能比较

Tab. 10 Respiratory disorder detection performance comparison with different datasets

数据集组合	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	N (%)	A (%)	H (%)
S1	82.7	0.593	68.2	75.2	91.6	85.3	78.1	62.3
S1&S2	82.3	0.581	67.4	73.7	91.0	85.4	76.3	59.4
S1&S2&M	82.3	0.586	67.8	74.9	91.4	85.1	76.5	63.1

注：表内加粗数值表示各项评价指标中的最优结果。

任务模型与多任务模型的性能，结果如表11所示。可以观察到，多任务模型在睡眠分期和呼吸障碍检测两个任务上均取得更优表现。对于睡眠分期任务，多任务学习在 κ 和MF1等指标上均获得显著提升，说明呼吸障碍检测任务提供了与睡眠状态相关的补充生理信息，有助于增强模型对睡眠阶段特征的代表能力。对于呼吸障碍检测任务，多任务学习带来的增益更加明显，尤其是 κ ，MF1和Sens.均大幅提高，表明睡眠阶段信息也能够为异常呼吸事件识别提供有效的上下文约束。上述结果说明，睡眠分期与呼吸障碍检测并非相互独立，联合建模能够利用二者之间的生理关联，从而提升整体睡眠分析性能。

为了进一步分析多任务学习对不同类别的影响，本研究在图7中可视化了混淆矩阵结果。结果表明，相比单任务设置，多任务学习在睡眠分期任务中减少了深睡期和快速眼动期被误判为浅睡期的情况，在呼吸障碍检测任务中提升了低通气事件的识别率，同时未明显削弱其他类别的识别性能。这些结果验证了联合建模睡眠阶段和呼吸障碍能够实现互补学习，从而为这两个任务提供更鲁棒的表征。

5 讨论

5.1 渐进式策略有效性分析

为减小脑电、呼吸与雷达信号之间的模态差异，本研究采用呼吸信号作为中间模态，构建了由

脑电知识蒸馏和呼吸模型预训练组成的渐进式知识迁移策略。为进一步验证不同迁移阶段及其组合方式的作用，在保持网络结构和训练设置一致的条件下，本研究分别设置不使用知识蒸馏和预训练(without Knowledge Distillation and Pretraining, w/o KD / w/o PT)、仅使用知识蒸馏(with Knowledge Distillation and without Pretraining, w/ KD / w/o PT)、仅使用预训练(without Knowledge Distillation and with Pretraining, w/o KD / w/ PT)以及同时使用知识蒸馏和预训练(with Knowledge Distillation and Pretraining, w/ KD / w/ PT)4组对照实验，实验结果如表12和表13所示。

结果表明，完整的渐进式迁移策略在睡眠分期和呼吸障碍检测任务上均取得最优的整体性能。单独引入知识蒸馏或预训练时，部分评价指标和类别识别性能能够得到改善，但仍存在一定的性能波动。在知识蒸馏的基础上引入预训练后，两项任务的主要评价指标及细粒度类别识别性能均得到进一步提升。由此可见，渐进式跨模态迁移能够逐步减小不同生理信号之间的表征差异，提高知识传递的有效性。

5.2 预处理有效性分析

为了增强雷达信号中与睡眠状态及呼吸异常相关的生理表征，本研究在模型输入前设计了相应的信号预处理算法，以抑制环境杂波及非目标干扰，

表 11 单任务与多任务学习性能比较

Tab. 11 Performance comparison between single-task and multi-task learning

方法	睡眠分期					呼吸障碍				
	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)
单任务	80.7	0.662	75.8	76.2	91.2	81.5	0.514	60.1	62.0	86.4
多任务	82.7	0.719	79.6	78.9	92.5	82.7	0.593	68.2	75.2	91.6

注：表内加粗数值表示各项评价指标中的最优结果。




图 7 单任务与多任务学习混淆矩阵比较

Fig. 7 Comparison of confusion matrices between single-task and multi-task learning

并增强与睡眠相关的有效信号成分。为评估预处理流程对模型性能的影响,在保持其他实验设置一致的前提下,本研究构建了不采用预处理算法(w/o Preprocessing)和采用预处理算法(w/ Preprocessing)的对照实验,结果如表14所示。实验结果表明,引入预处理后,睡眠分期和呼吸障碍检测任务的各项评价指标均得到明显提升。其中,睡眠分期任务的Acc由75.3%提升至82.7%,呼吸障碍检测任务由76.8%提升至82.7%,同时 κ , MF1, Sens和Spec也均呈现一致改善。该结果表明,未经处理的

雷达信号中包含较多环境杂波、体动干扰及其他非目标成分,容易削弱与睡眠状态和异常呼吸相关的细微特征。通过上述预处理流程,模型能够获得信噪比更高的输入表征,从而降低无干扰对特征学习的影响,并提升睡眠分期和呼吸障碍检测性能。

5.3 时序建模消融分析

为了分析时序模型深度对长程依赖建模能力的影响,本研究比较了不同层数配置下的时序建模性能,具体结果如表15和表16所示。实验结果表明,

表 12 迁移策略对睡眠分期性能的影响

Tab. 12 Effect of the transfer strategy on sleep staging performance

方法	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	Wake (%)	Light (%)	Deep (%)	REM (%)
w/o KD / w/o PT	75.2	0.575	68.2	64.7	88.3	73.5	87.3	57.3	40.6
w/ KD / w/o PT	73.7	0.576	69.1	69.2	89.0	71.0	78.8	59.6	67.4
w/o KD / w/ PT	80.1	0.674	76.4	75.2	91.3	80.8	85.1	65.8	69.2
w/ KD / w/ PT	82.7	0.719	79.6	78.9	92.5	85.6	85.9	69.9	74.3

注:表内加粗数值表示各项评价指标中的最优结果。

表 13 迁移策略对呼吸障碍检测性能的影响

Tab. 13 Effect of the transfer strategy on respiratory disorder detection performance

方法	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	N (%)	A (%)	H (%)
w/o KD / w/o PT	74.0	0.446	58.5	67.6	88.1	72.5	75.5	51.8
w/ KD / w/o PT	82.4	0.517	61.1	61.4	85.9	90.4	63.6	30.2
w/o KD / w/ PT	80.0	0.543	65.7	73.0	90.4	82.8	71.3	64.9
w/ KD / w/ PT	82.7	0.593	68.2	75.2	91.6	85.3	78.1	62.3

注:表内加粗数值表示各项评价指标中的最优结果。

表 14 预处理流程的消融实验结果

Tab. 14 Ablation results of the preprocessing pipeline

任务	方法	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)
睡眠分期	w/o Preprocessing	75.3	0.583	68.8	66.3	88.7
	w/ Preprocessing	82.7	0.719	79.6	78.9	92.5
呼吸障碍	w/o Preprocessing	76.8	0.478	60.9	66.8	87.7
	w/ Preprocessing	82.7	0.593	68.2	75.2	91.6

注:表内加粗数值表示各项评价指标中的最优结果。

表 15 时序建模层数对睡眠分期性能的影响

Tab. 15 Effect of temporal modeling depth on sleep staging performance

层数	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	Wake (%)	Light (%)	Deep (%)	REM (%)
1	80.0	0.670	75.9	74.5	91.1	82.4	85.1	65.8	64.8
2	80.7	0.688	77.4	77.1	91.7	83.9	83.8	71.0	69.6
4	82.7	0.719	79.6	78.9	92.5	85.6	85.9	69.9	74.3
6	82.4	0.713	79.3	78.6	92.3	83.8	86.0	69.2	75.4

注:表内加粗数值表示各项评价指标中的最优结果。

表 16 时序建模层数对呼吸障碍检测性能的影响

Tab. 16 Effect of temporal modeling depth on respiratory disorder detection performance

层数	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	N (%)	A (%)	H (%)
1	82.4	0.578	66.9	72.8	90.9	86.2	71.5	60.7
2	84.0	0.606	68.6	73.8	91.3	87.8	74.8	58.8
4	82.7	0.593	68.2	75.2	91.6	85.3	78.1	62.3
6	81.9	0.579	67.5	74.6	91.3	84.7	75.7	63.4

注:表内加粗数值表示各项评价指标中的最优结果。

随着时序建模层数增加，睡眠分期性能呈现先提升后趋于饱和的变化趋势，而呼吸障碍检测任务在不同层数下表现出一定的性能权衡。对于睡眠分期任务，模型由1层增加至4层时，Acc, κ , MF1, Sens和Spec均持续提升，表明适当增加时序建模深度有助于增强模型对睡眠阶段长程演化关系的表征能力。当层数进一步增加至6层后，整体性能趋于饱和。对于呼吸障碍检测任务，不同层数在各项指标上表现出一定差异。2层模型在Acc, κ 和MF1上取得最高结果，而4层模型在Sens、Spec及呼吸暂停识别性能上表现最佳，6层模型则取得最高的低通气识别率。综合模型性能、网络复杂度和计算效率，本研究最终选取4层作为时序建模模块的配置。

5.4 多场景睡眠监测与临床指标评估

本研究统计了医院、酒店和居家3个场景下的睡眠分期性能，以评估所提方法的场景泛化性，具体结果如表17所示。所提方法在医院、酒店和居家3种采集场景下均保持了较高的睡眠分期性能，表明模型在不同环境下具有较好的泛化能力。其中，酒店和居家场景的Acc分别达到85.0%和85.1%，MF1分别为83.5%和84.1%，整体性能较为接近。相比之下，医院场景的整体性能略低，Acc和MF1分别为81.3%和75.7%，可能与医院受试者睡眠状态及睡眠环境更加复杂有关。

进一步地，本研究基于医院病房场景下的AHI预测结果来评估模型对睡眠呼吸障碍严重程度的估计能力，具体结果如图8所示。模型对不同睡眠呼吸障碍严重程度具有较好的区分能力，其中正常和重度类别的识别率分别达到100.0%和86.1%。轻度和中度类别的识别率均为66.7%，其误分类主要发生在轻度和中度病例之间。

5.5 可解释性分析

本研究采用t分布随机邻域嵌入(t-distributed Stochastic Neighbor Embedding, t-SNE)方法可视化主干框架中局部特征提取模块和全局时序建模模块的输出特征，以更直观地揭示不同网络模块对特

征表征与类别区分的作用，具体结果如图9所示。原始数据在二维特征空间中存在较为明显的类别混叠，不同睡眠阶段及不同呼吸事件之间的分布边界较为模糊。经过局部特征编码后，各类别开始形成一定的聚集趋势，表明局部特征提取模块能够增强与不同生理状态相关的判别信息。在进一步引入全局依赖建模后，各类别之间的分离程度明显提高，类内分布更加集中，类间边界也更加清晰。上述结果表明，局部特征提取能够完成初步的类别表征，而全局时序建模进一步利用长程上下文信息增强了不同状态之间的可分性，从而为后续分类提供更加有效的特征表示。

为进一步验证渐进式跨模态迁移在缓解模态域差异方面的实际作用，本研究开展了针对特征域差异的分析。在相同实验设置下，分别提取直接蒸馏路径(EEG→雷达)和渐进式迁移两个阶段(EEG→呼吸、呼吸→雷达)中经门控融合后的特征表征，并采用类别条件最大均值差异(Class-conditional Maximum Mean Discrepancy, MMD)和线性中心核对齐(Linear Centered Kernel Alignment, CKA)对不同模态间的特征分布差异和表征相似性进行定量分析，具体结果如图10和表18所示。

对于睡眠分期任务，直接脑电到雷达迁移时的特征分布差异较大，引入呼吸中间模态后，脑电与呼吸、呼吸与雷达之间的MMD逐步降低，而CKA持续提高。呼吸障碍检测任务也呈现相同趋势，说明渐进式迁移能够逐步减小不同模态之间的表征差异，并增强特征空间的一致性。上述结果表明，相较于直接进行脑电到雷达的跨模态迁移，引入呼吸信号作为中间模态后，各迁移阶段的特征分布差异明显减小、表征相似性逐步增强，且十折交叉验证的统计结果呈现一致的整体趋势。这说明呼

表 17 不同场景下的睡眠分期性能比较
Tab. 17 Comparison of sleep staging performance across different scenarios

场景	Acc (%)	κ	MF1 (%)	Sens (%)	Spec (%)	Wake (%)	Light (%)	Deep (%)	REM (%)
医院	81.3	0.667	75.7	75.3	91.2	78.7	86.0	65.5	70.9
酒店	85.0	0.785	83.5	83.2	94.5	93.4	84.3	69.7	85.5
居家	85.1	0.783	84.1	83.3	94.2	95.0	86.3	75.6	76.2




图 8 基于AHI的睡眠呼吸障碍严重程度分类结果

Fig. 8 Classification results of sleep-disordered breathing severity based on AHI




图9 不同网络阶段的特征分布可视化

Fig. 9 Feature distribution visualization at different network stages




图10 不同迁移阶段的特征分布差异与表征相似性变化趋势

Fig. 10 Trends of feature distribution discrepancy and representation similarity across different transfer stages

吸模态能够在脑电与雷达之间发挥有效的桥接作用,将较大的跨模态差异分解为两个相对平滑的迁

移阶段,从表征空间层面为渐进式迁移缓解域差异提供了过程性证据。

表 18 不同迁移阶段的特征分布差异与表征相似性

Tab. 18 Feature distribution discrepancy and representation similarity across different transfer stages

任务	MMD ↓			CKA ↑		
	EEG→Radar	EEG→Resp	Resp→Radar	EEG→Radar	EEG→Resp	Resp→Radar
睡眠分期	0.419±0.041	0.326±0.026	0.175±0.047	0.134±0.059	0.210±0.070	0.519±0.079
呼吸障碍	0.346±0.017	0.285±0.012	0.133±0.055	0.105±0.050	0.168±0.034	0.405±0.063

5.6 模型开销分析

为评估所提框架的计算开销，本研究进一步统计了各阶段模型的参数量、计算量和训练时间。如表19所示，脑电教师模型、呼吸学生模型和雷达模型的参数量分别为16.922M, 16.661M和17.021M，处理单个30 s时段的计算量分别为0.283, 0.058和0.283 GFLOPs。脑电教师模型和呼吸学生模型均在单张NVIDIA GeForce RTX 4090显卡上采用FP32精度训练50个epoch，训练时间分别为5小时16分钟和9小时8分钟。尽管学生模型的单时段计算量较低，其知识蒸馏训练还需执行冻结教师模型的前向计算，因此总训练时间较长。雷达模型采用十折交叉验证，每折训练50个epoch，十折累计训练时间为2小时45分钟。由于每折仅使用相应的目标域训练数据，且训练数据规模小于前两阶段使用的SHHS1数据集，因此累计训练时间较短。

表 19 模型计算开销统计

Tab. 19 Computational cost of different models

模型	参数量(M)	GFLOPs(30 s)	训练时间
教师模型	16.922	0.283	5小时16分钟
学生模型	16.661	0.058	9小时8分钟
雷达模型	17.021	0.283	2小时45分钟

6 结语

睡眠监测是居家医疗场景中的重要任务。本文提出一种基于脑电信息监督的渐进式非接触睡眠监测方法，通过知识蒸馏和预训练策略逐步迁移脑电模态中的睡眠判别知识，并将其适配至雷达呼吸表征。在多环境非接触式睡眠监测场景下，所提方法实现了准确的睡眠分期与呼吸障碍检测。实验结果验证了各项策略的有效性，并表明该方法性能接近专家判读水平，为长期、低负担的非接触式睡眠监测提供了新的技术思路。

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

- [1] 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[M]. Darien: American Academy of Sleep Medicine, 2012: 7.
- [2] Grandner M A. Sleep, health, and society[J]. *Sleep medicine clinics*, 2022, 17(2): 117–139. doi: [10.1016/j.jsmc.2022.03.001](https://doi.org/10.1016/j.jsmc.2022.03.001).
- [3] 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).
- [4] 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).
- [4] 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), 2025, 14(1): 102–116. doi: [10.12000/JR24107](https://doi.org/10.12000/JR24107).
- [4] 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*, 2025, 14(1): 102–116. doi: [10.12000/JR24107](https://doi.org/10.12000/JR24107).
- [5] HE Hao, LI Chao, GANGLBERGER W, *et al.* What radio waves tell us about sleep![J]. *Sleep*, 2025, 48(1): zsae187. doi: [10.1093/sleep/zsae187](https://doi.org/10.1093/sleep/zsae187).
- [6] WANG Yaqi, LU Zhi, YUE Aoxiang, *et al.* Self-supervised learning for contactless cardiac diagnosis with beamformed radar signals[J]. *IEEE Internet of Things Journal*, 2026. doi: [10.1109/JIOT.2026.3729861](https://doi.org/10.1109/JIOT.2026.3729861).
- [7] CAI Xinmeng, CHEN Jinbo, XU Guixin, *et al.* RF-HeartSSL: Self-supervised learning for RF-based cardiac sensing[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2026, 10(2): 1–34. doi: [10.1145/3810229](https://doi.org/10.1145/3810229).
- [8] GENG Ruixu, ZHANG Dongheng, LI Yadong, *et al.* mmGuard: A countermeasure against physical adversarial attacks on mmWave radar sensing[J]. *IEEE Transactions on Information Forensics and Security*, 2026, 21: 5568–5582. doi: [10.1109/TIFS.2026.3698581](https://doi.org/10.1109/TIFS.2026.3698581).
- [9] CAI Xinmeng, CHEN Jinbo, WANG Haoyu, *et al.*

- Contactless arrhythmia detection via diversity-invariant contrastive mmWave sensing[J]. *IEEE Transactions on Mobile Computing*, 2026, 25(8): 13324–13339. doi: [10.1109/TMC.2026.3673334](#).
- [10] ZHAO Heng, XU Zhi, XUE Biao, *et al.* Client-personalized federated learning framework with heterogeneous millimeter-wave radars for contactless ECG reconstruction using heart sounds[J]. *IEEE Journal of Electromagnetics, RF and Microwaves in Medicine and Biology*, 2026. doi:[10.1109/JERM.2026.3727679](#).
- [11] YANG Xuan, ZHAO Heng, WANG Shaijun, *et al.* Accurate near-range displacement sensing in single-channel FMCW radar via CZT-MLE compensation for SL-IQI[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2026, 74(6): 5644–5657. doi: [10.1109/TMTT.2026.3680086](#).
- [12] ZHU Tianyu, ZHANG Lin, DING Chen, *et al.* Efficiency-based adaptive time-Doppler sparse point clouds of human motion for radar sensing[C]. 2026 IEEE MTT-S International Wireless Symposium (IWS). 2026: 1–3.
- [13] LI Siheng, JIN Beihong, ZHANG Fusang, *et al.* Hypnos: A contactless sleep stage monitoring system using UWB signals[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2024, 8(3): 114. doi: [10.1145/3678581](#).
- [14] ZHUANG Zhongxu, XUE Biao, AN Qiang, *et al.* Advancing sleep health equity through deep learning on large-scale nocturnal respiratory signals[J]. *Nature Communications*, 2025, 16(1): 9334. doi: [10.1038/s41467-025-64340-y](#).
- [15] ZHAO Mingmin, YUE Shichao, KATABI D, *et al.* Learning sleep stages from radio signals: A conditional adversarial architecture[C]. The 34th International Conference on Machine Learning, Sydney, Australia, 2017: 4100–4109.
- [16] CHEN Jinbo, ZHANG Dongheng, WU Zhi, *et al.* Contactless electrocardiogram monitoring with millimeter wave radar[J]. *IEEE Transactions on Mobile Computing*, 2024, 23(1): 270–285. doi: [10.1109/TMC.2022.3214721](#).
- [17] YUAN Yuqin, CHEN Jinbo, ZHANG Dongheng, *et al.* Atrial fibrillation detection via contactless radio monitoring and knowledge transfer[J]. *Nature Communications*, 2025, 16(1): 4317. doi: [10.1038/s41467-025-59482-y](#).
- [18] WU Zhi, ZHANG Dongheng, SHANG Zixin, *et al.* Learning-based tracking-before-detect for unconstrained indoor human tracking using RF signal[J]. *IEEE Transactions on Mobile Computing*, 2025, 24(6): 4777–4793. doi: [10.1109/TMC.2025.3529501](#).
- [19] ZHANG Ganlin, ZHANG Dongheng, DENG Hongyu, *et al.* SRAL-IRS: Swift, robust, and accurate IRS-aided localization with COTS WiFi[J]. *IEEE Transactions on Wireless Communications*, 2025, 24(10): 8376–8390. doi: [10.1109/twc.2025.3566158](#).
- [20] QUAN S F, HOWARD B V, IBER C, *et al.* The sleep heart health study: Design, rationale, and methods[J]. *Sleep*, 1997, 20(12): 1077–1085. doi: [10.1093/sleep/20.12.1077](#).
- [21] ZHANG Guoqiang, CUI Licong, MUELLER R, *et al.* The National Sleep Research Resource: Towards a sleep data commons[J]. *Journal of the American Medical Informatics Association*, 2018, 25(10): 1351–1358. doi: [10.1093/jamia/ocy064](#).
- [22] GOU Jianping, YU Baosheng, MAYBANK S J, *et al.* Knowledge distillation: A survey[J]. *International Journal of Computer Vision*, 2021, 129(6): 1789–1819. doi: [10.1007/s11263-021-01453-z](#).
- [23] MIN Bonan, ROSS H, SULEM E, *et al.* Recent advances in natural language processing via large pre-trained language models: A survey[J]. *ACM Computing Surveys*, 2024, 56(2): 30. doi: [10.1145/3605943](#).
- [24] CHEN Xiaoli, WANG Rui, ZEE P, *et al.* Racial/ethnic differences in sleep disturbances: The multi-ethnic study of atherosclerosis (MESA)[J]. *Sleep*, 2015, 38(6): 877–888. doi: [10.5665/sleep.4732](#).
- [25] AWR6843AOP T I. [OL]. <https://www.ti.com.cn/product/cn/AWR6843AOP>.
- [26] LI Yadong, ZHANG Dongheng, GENG Ruixu, *et al.* IFNet: Deep imaging and focusing for handheld SAR with millimeter-wave signals[J]. *IEEE Transactions on Mobile Computing*, 2025, 24(3): 2166–2180. doi: [10.1109/TMC.2024.3489641](#).
- [27] GENG Ruixu, LI Yadong, ZHANG Dongheng, *et al.* DREAM-PCD: Deep reconstruction and enhancement of mmWave radar pointcloud[J]. *IEEE Transactions on Image Processing*, 2024, 33: 6774–6789. doi: [10.1109/TIP.2024.3512356](#).
- [28] 丁凌娜, 张宾宾, 王健阳, 等. 基于深度盲源分离的毫米波雷达驾驶员心跳感知方法研究[J/OL]. 雷达学报(中英文). <https://doi.org/10.12000/JR26042>, 2026. doi: [10.12000/JR26042.2026](#).
- DING Lingna, ZHANG Binbin, WANG Jianyang, *et al.* Driver heartbeat sensing using millimeter-wave radar based on deep blind source separation[J/OL]. *Journal of Radars*. <https://doi.org/10.12000/JR26042>, 2026. doi: [10.12000/JR26042.2026](#).
- [29] 元志安, 周笑宇, 刘心溥, 等. 基于RDSNet的毫米波雷达人体跌倒检测方法[J]. 雷达学报, 2021, 10(4): 656–664. doi: [10.12000/JR21015](#).
- YUAN Zhian, ZHOU Xiaoyu, LIU Xinpu, *et al.* Human fall detection method using millimeter-wave radar based on RDSNet[J]. *Journal of Radars*, 2021, 10(4): 656–664. doi: [10.12000/JR21015](#).
- [30] XU Qinyi, JIANG Chunxiao, HAN Yi, *et al.* Waveforming: An overview with beamforming[J]. *IEEE Communications*

- Surveys & Tutorials*, 2018, 20(1): 132–149. doi: [10.1109/COMST.2017.2750201](https://doi.org/10.1109/COMST.2017.2750201).
- [31] YUE Shichao, HE Hao, WANG Hao, *et al.* Extracting multi-person respiration from entangled RF signals[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2018, 2(2): 86. doi: [10.1145/3214289](https://doi.org/10.1145/3214289).
- [32] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 770–778. doi: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).
- [33] GU A, DAO T, ERMON S, *et al.* HiPPO: Recurrent memory with optimal polynomial projections[C]. The 34th International Conference on Neural Information Processing Systems, Vancouver, Canada, 2020: 125.
- [34] GUPTA A, GU A, and BERANT J. Diagonal state spaces are as effective as structured state spaces[C]. The 36th International Conference on Neural Information Processing Systems, New Orleans, USA, 2022: 1670.
- [35] GU A, GUPTA A, GOEL K, *et al.* On the parameterization and initialization of diagonal state space models[C]. The 36th International Conference on Neural Information Processing Systems, New Orleans, USA, 2022: 2607.
- [36] GU Albert, GULCEHRE Caglar, PAINE Thomas, *et al.* Improving the gating mechanism of recurrent neural networks[C]. Proceedings of the 37th International Conference on Machine Learning, 2020, 119: 3800–3809.
- [37] VAQUERIZO-VILLAR F, ÁLVAREZ D, GUTIÉRREZ-TOBAL G C, *et al.* Deep-learning model based on convolutional neural networks to classify apnea–hypopnea events from the oximetry signal[M]. PENZEL T and HORNERO R. *Advances in the Diagnosis and Treatment of Sleep Apnea: Filling the Gap Between Physicians and Engineers*. Cham: Springer, 2022: 255–264. doi: [10.1007/978-3-031-06413-5_15](https://doi.org/10.1007/978-3-031-06413-5_15).
- [38] Choi J W, Koo D L, Kim D H, *et al.* A novel deep learning model for obstructive sleep apnea diagnosis: hybrid CNN-Transformer approach for radar-based detection of apnea-hypopnea events[J]. *Sleep*, 2024, 47(12): zsae184. doi: [10.1093/sleep/zsae184](https://doi.org/10.1093/sleep/zsae184).

作者简介

周 放，博士生，主要研究方向为无线感知和睡眠监测。

卢 智，副研究员，主要研究方向为无线感知。

张淦霖，博士，主要研究方向为无线感知和智能反射表面。

武 治，博士，主要研究方向为无线感知和姿态识别。

濮 玉，博士生，主要研究方向为无线感知和睡眠监测。

陈涪睿，硕士生，主要研究方向为无线感知和睡眠监测。

张东恒，副研究员，主要研究方向为无线感知。

陈 彦，教授，主要研究方向为多模态感知、多媒体信号处理和数字健康。

(责任编辑：于青)