

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

丁凌娜 张宾宾 王健阳 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: 对驾驶员心脏活动的监测可以有效评估其生理和心理状态,然而,现有的心跳感知方法(心电图和远程光电容积描记法)操作繁琐,易受光线影响,并不适用于车载场景。基于毫米波雷达的心跳感知技术虽然具有高精度、非接触等优势,但易受干扰影响。针对上述问题,该文结合射频信号的低频特性、长程动态敏感性、稀疏性,基于自注意力机制设计了一个射频特征提取器,通过构建深度盲源分离网络实现了驾驶员心跳射频特征和车载干扰特征的分离。此外,针对射频信号采集难的问题,该文提出了一种混合-源信号生成策略,通过少量心震描记数据和车载干扰数据合成了训练样本。最后,该文在真实的行车环境中对该方法进行了验证,实验结果表明,系统可实现心率绝对误差4.92 bpm、心搏间期中位数误差65.93 ms的感知精度。

关键词: 无线感知; 心跳感知; 盲源分离; 深度学习; 智能驾驶

中图分类号: TN959.6

文献标识码: A

文章编号: 2095-283X(2026)x-0001-16

DOI: [10.12000/JR26042](https://doi.org/10.12000/JR26042)

CSTR: [32380.14.JR26042](https://cstr.cn/32380.14.JR26042)

引用格式: 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]. 雷达学报(中英文),待出版. doi: 10.12000/JR26042.

Reference format: DING Lingna, ZHANG Binbin, WANG Jianyang, *et al.* Driver heartbeat sensing using millimeter-wave radar based on deep blind source separation[J]. *Journal of Radars*, in press. doi: 10.12000/JR26042.

Driver Heartbeat Sensing using Millimeter-Wave Radar based on Deep Blind Source Separation

DING Lingna ZHANG Binbin WANG Jianyang

ZHANG Dongheng* CHEN Yan

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

Abstract: Monitoring of drivers' cardiac activity enables effective assessment of their physiological and psychological states. However, existing methods such as electrocardiography and remote photoplethysmography are cumbersome and sensitive to lighting conditions, limiting their applicability in vehicular settings. Despite its high accuracy and noncontact operation, millimeter-wave radar-based heartbeat sensing is inherently vulnerable to interference. To address these issues, this paper exploits the low-frequency characteristics, long-range dynamic sensitivity, and sparsity of radio-frequency (RF) signals and designs a self-attention-based RF feature extractor. On this basis, a deep blind source separation network is constructed to separate the driver's heartbeat-related RF features from in-vehicle interference. Furthermore, to reduce the burden of RF signal acquisition, we introduce a hybrid-source signal generation strategy that synthesizes a large number of mixed and ground-truth source signals using only a small number of seismocardiogram and interference signals.

收稿日期: 2026-02-09; 改回日期: ; 网络出版: 2026-xx-xx

*通信作者: 张东恒 dongheng@ustc.edu.cn *Corresponding Author: ZHANG Dongheng, dongheng@ustc.edu.cn

基金项目: 国家自然科学基金(62201542), 中央高校基本科研业务费专项资金资助

Foundation Items: The National Natural Science Foundation of China (62201542), The Fundamental Research Funds for the Central Universities

责任编辑: 方震 Corresponding Editor: FANG Zhen

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

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

Finally, extensive on-road testing demonstrates that the proposed system achieves a median heart rate error of 4.92 bpm and a median interbeat interval error of 65.93 ms.

Key words: Wireless sensing; Heartbeat sensing; Blind source separation; Deep learning; Intelligent driving

1 引言

根据世界卫生组织发布的《世界卫生统计报告》，2021年，全球约有118万人死于交通事故^[1]。2023年，我国发生了25万起交通事故，死亡人数总计6万余人，直接财产损失近12亿元。统计分析表明，驾驶员的错误驾驶行为，例如疲劳驾驶、酒后驾驶、路怒症等是导致交通事故的主要原因^[2]。对驾驶员心脏活动的实时监测能够有效识别驾驶状态^[3-5]，对保障驾乘人员安全和预防交通事故具有重要意义。然而，传统的心跳感知技术并不适用于驾驶场景。例如，基于可穿戴设备的感知技术流程繁琐，长期佩戴设备会让驾驶员感到不适；基于视觉的感知技术容易受到光线和人体运动的影响，心率检测准确性急剧下降^[6-11]，同时存在隐私问题。

近年来，随着无线感知技术的发展，毫米波雷达感知技术凭借非接触、细粒度、隐私友好的优势展现出巨大潜力。毫米波雷达通过发射射频信号并接收由人体反射的信号，可以在非接触条件下实现对人体呼吸^[12-17]、心跳^[18-27]以及情绪^[28,29]的感知。然而，由于人体心跳引起的体表振动较为微弱，从驾驶员胸腔表面反射的雷达信号中识别并提取心跳特征并不容易。更糟糕的是，在车载场景中，车辆行驶引起的机械振动远远大于心跳微动，驾驶员微弱的心跳信号通常被淹没在复杂的干扰中。

针对上述问题，一些学者进行了相关的研究。ZHU等人^[30]提出了一种车载场景下的射频心跳感知算法，通过在心跳频段直接选取频谱峰值来估计心跳频率，然而，该算法没有充分考虑车内环境噪声及驾驶员身体微动等因素的影响，在真实场景中心率误差较大。 V^2iFi ^[31]、mmECG^[32]和文献^[33]采用变分模态分解方法，将混合信号分解为多个窄带模态分量以解决模态混叠问题。然而，已有研究表明^[19]，心跳特征通常包含多个谐波成分，而基于窄带假设的信号分解方法无法完整提取心跳信息，导致在实际检测中误差较大。总的来说，传统基于信号处理的感知算法难以在复杂的车载环境中有效提取心跳特征。近些年，基于深度学习的毫米波雷达心跳感知算法取得了一定的进展，这类方法主要是围绕跨射频模态生成心电图、光电容积脉搏波和心震描记信号^[34-37]，然而，这些算法在车载场景中并不能取得很好的效果^[38]。主要原因在于：现有的网络结构缺少针对动态场景干扰和噪声的处理模块，

在射频信号的特征提取过程中，缺乏对复杂背景干扰的有效抑制机制。此外，由于模型的训练依靠静态环境下采集的数据，其学到的射频特征表示泛化能力有限，限制了模型在真实车载场景下的性能。

针对以上问题，本文结合射频信号的低频特性、长程动态敏感性、稀疏性，设计了基于多头自注意力机制的特征提取器捕捉雷达体征信号中的长程依赖关系与全局结构特征，并通过特征掩码分离器和源信号重构器，从原始的混合信号分离出心跳信号和干扰信号。此外，针对数据采集难的问题，本文提出了一种混合-源信号生成策略，通过心震描记信号和车载干扰射频信号，生成了大量的混合信号与源信号真值，克服了深度盲源分离网络训练标签稀缺的挑战。最后，本文在真实的车辆行驶环境中对该系统进行了验证，实验结果表明，该系统可实现心率绝对误差4.92 bpm、心搏间期中位数误差65.93 ms的感知精度，证明了系统的有效性。本文主要贡献如下：

(1) 面向真实驾驶场景，构建了一套基于毫米波雷达的心跳感知系统，并在真实驾驶场景中基于雷达数据与真值数据进行了验证，实现了非接触、高精度的驾驶员心脏活动监测。

(2) 提出了一种适用于射频信号的深度盲源分离算法，通过射频特征掩码技术分离了汽车行驶过程中发动机和路面行驶引起的机械干扰，完成了射频心跳波形的重构。

(3) 采用混合-源信号生成策略扩充了训练样本，利用心震描记数据和车载干扰数据，生成了大量的混合信号与源信号标签，解决了数据采集困难、标注样本稀缺的问题。

2 系统框架

如图1所示，基于毫米波雷达的驾驶员心跳感知系统首先对收集的数据进行信号预处理，采集的雷达信号经过波束形成、杂波消除、运动单元识别、低频噪声抑制之后输入深度盲源分离网络，分离出心跳信号与干扰信号，其中，心跳信号用于后续心率、心搏间期估计。下文将依次介绍系统的信号预处理模块、基于深度盲源分离网络的心跳提取模块、混合-源信号生成模块。

2.1 信号预处理模块

信号预处理模块包含5个部分，第1部分阐述了

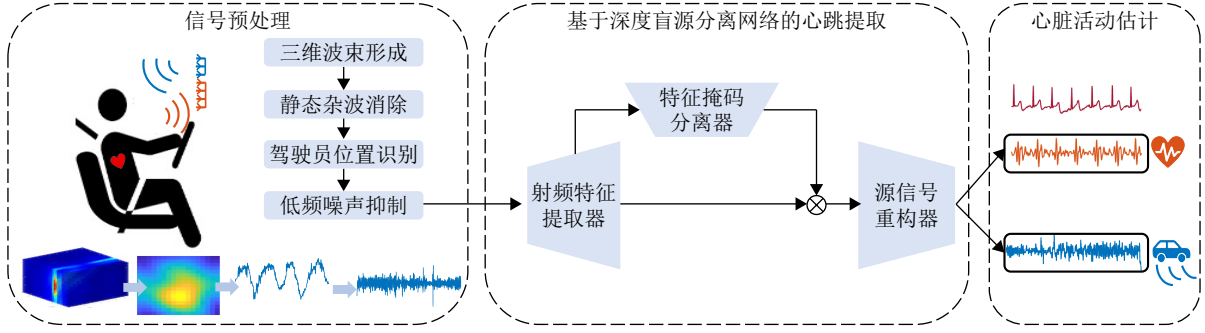


图 1 系统框图

Fig. 1 System block diagram

毫米波雷达的基本原理；第2部分介绍了如何基于三维波束形成技术提取驾驶员胸腔运动的空间特征；第3部分针对静态物体反射干扰提出了基于时间差分的杂波消除法；第4部分介绍了如何基于运动单元识别实现驾驶员位置的鲁棒估计；第5部分引入了最小二乘平滑微分器，抑制了低频呼吸干扰，增强心跳相关的微动特征。

2.1.1 毫米波雷达的基本原理

本文的系统基于调频连续波雷达，雷达发射周期性线性调频信号，起始频率为，啁啾持续时间为，带宽为，将接收信号与发射信号进行混频，得到中频信号：

$$h(\tau) = \sum_{p=1}^P A \exp \left\{ -j \left(2\pi \frac{B\tau_p}{T_c} \tau + 2\pi f_c \tau_p \right) \right\} \quad (1)$$

其中， A 为中频信号的幅度， P 表示环境中反射点的总数， τ_p 为 p 次反射路径的往返时延，可表示为 $\tau_p = (2d_p/c)$ ， d_p 为反射物体与器件之间的距离， c 为光速。相位变化 $\Delta\phi$ 与目标距离成正比，其关系可表示为：

$$\Delta\phi = 2\pi f_c \tau_p = \frac{4\pi f_c d_p}{c} \quad (2)$$

2.1.2 基于三维波束形成的信号增强技术

雷达接收的原始信号在每个距离单元、每个时间帧上由二维通道数据构成。这些通道分别对应 T 个发射天线和 R 个接收天线所接收的信号。由于人体表面反射信号可能包含来自身体不同部位的分量，因此接收的原始信号中往往存在多源干扰。为抑制来自其他方向的干扰，本文采用文献 [39]中所描述的波束形成方法，通过对各天线阵元接收信号的相位信号进行补偿，增强心脏运动方向的信号。第1个天线阵元在俯仰角 θ ，方位角 φ 方向上的补偿系数可表示为

$$s_l(\theta, \varphi) = \exp \left(-2\pi j \frac{d_{l_y} \sin\theta + d_{l_x} \cos\theta \cos\varphi}{\lambda_c} \right) \quad (3)$$

$s^H(\theta, \varphi) = [s_1(\theta, \varphi), s_2(\theta, \varphi), \dots, s_L(\theta, \varphi)]^T$ 是天线阵列导向向量，天线阵元总数 $L = T \times R$ ， d_{l_x} 和 d_{l_y} 分别是第 l 个天线阵元的横纵坐标，在 r 个距离单元，第 m 个时间点上，波束成形后的信道冲激响应可以表示为

$$h_l(m, r, \theta, \varphi) = s^H(m, r, \theta, \varphi) h_l(m, r) \quad (4)$$

2.1.3 基于时间差分的静态杂波消除技术

雷达接收的信号不仅包含来自身体不同部位的反射还有环境中静态物体的反射，在经过2.1.2节的波束形成算法处理、增强驾驶员心脏运动方向信号之后，本系统采用基于时间差分的杂波去除算法消除来自车辆中静态物体的反射。如图2(a)所示，车内存在多种静态反射源，这些反射源分布在空间中的不同位置，难以分辨来自驾驶员的反射；图2(b)展示了经过静态杂波消除后的结果，可以明显看到空间中来自驾驶员的反射。通过对信道冲激响应进行时间差分处理，可有效抑制静态杂波干扰，差分后的信道冲激响应可以表示为

$$\hat{h}(m, r, \theta, \varphi) = h(m, r, \theta, \varphi) - h(m-1, r, \theta, \varphi) \quad (5)$$

2.1.4 基于运动单元识别的人体定位技术

在消除车内杂波得到每个距离单元的波束形成数据之后，需要进一步对驾驶员位置进行识别，以提取其对应距离单元的相位信号，从而获取驾驶员的呼吸与心跳特征。呼吸和心跳引起的胸腔微动会使驾驶员所在距离单元的回波能量显著高于其他单元。利用距离单元的能量分布特性，可实现驾驶员位置估计。图3(a)显示了每个距离单元的能量，图3(b)展示了距离-方位角-俯仰角的三维能量分布。运动单元识别算法可表示为

$$E_r = \sum_{m=1}^M \left| \hat{h}(m, r, \theta, \varphi) \right|, \quad k = \arg \max_{i \in \{1, 2, \dots, R\}} E_i \quad (6)$$

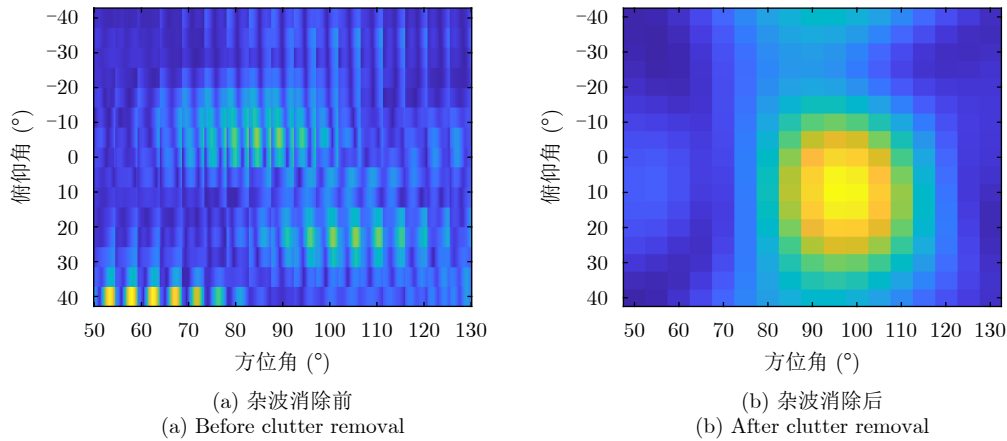


图2 杂波消除算法效果图

Fig. 2 Visualization of the clutter removal

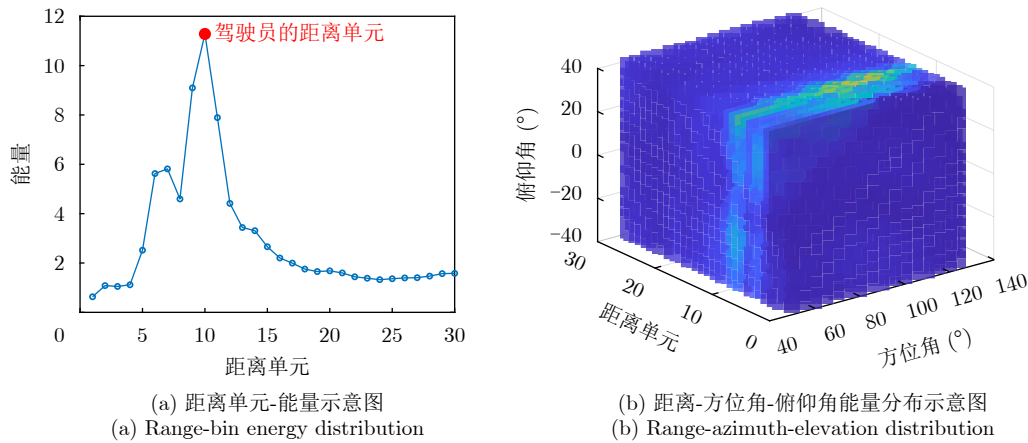


图3 驾驶员定位算法示意图

Fig. 3 Visualization of the driver localization

2.1.5 基于最小二乘平滑微分器的呼吸干扰抑制技术

在完成驾驶员位置识别并提取对应的相位信号后,需进一步抑制低频呼吸干扰以提取心跳信号。相位解缠绕信号与微动位移成正比。由于人体呼吸引起的位移幅度通常比心跳引起的位移高出几个数量级,因此相位信号中的变化主要由呼吸分量主导。为了减轻呼吸干扰的影响,本系统通过最小二乘微分器计算加速度消除呼吸干扰、放大心跳的信号^[40],最小二乘平滑微分器可表示为

$$s_0'' = \frac{(s_{-3} + s_3) + 2(s_{-2} + s_2) - (s_{-1} + s_1) - 4s_0}{16h^2} \quad (7)$$

s_0'' 是当前时间样本点的二阶导数, h 是连续样本点之间的帧, s_i 是时间点 i 距离当前样本点的值。图4分别展示了车辆静止与车辆行驶两种条件下的相位信号、抑制低频噪声后的信号以及同步采集的ECG信号。在车辆静止时,原始相位信号受到呼吸影响呈现大幅度周期性起伏,同时受到心脏

运动的影响,在呼吸波形上有明显的心跳起伏;而在车辆行驶时,由于引入了车辆行驶干扰,心跳特征受到明显影响。

2.2 基于深度盲源分离的心跳提取模块

2019年以来,基于时域信号的分离网络在语音领域展现出卓越的性能,特别是在说话人声分离和音乐分离任务上^[41-44]。受此启发,本研究尝试将此类网络架构迁移至雷达体征信号处理领域,实现车辆行驶振动干扰和心跳振动信号的分离。然而,将语音分离模型迁移至雷达体征信号处理领域存在两个问题:第一,输入信号的物理特性存在本质差异,具体而言,语音信号具有明显的局部相关性和短时平稳特性,因此语音领域的特征编码器通常基于局部时频特征建模,雷达体征信号具有低频特性、长程动态敏感性、稀疏性,信号中的心跳成分不仅依赖于对单个心跳局部细节的捕捉,还需要建模跨心跳的趋势变化与节律规律,这对网络的长程建模能力提出了更高要求。第二,与能够直接利用

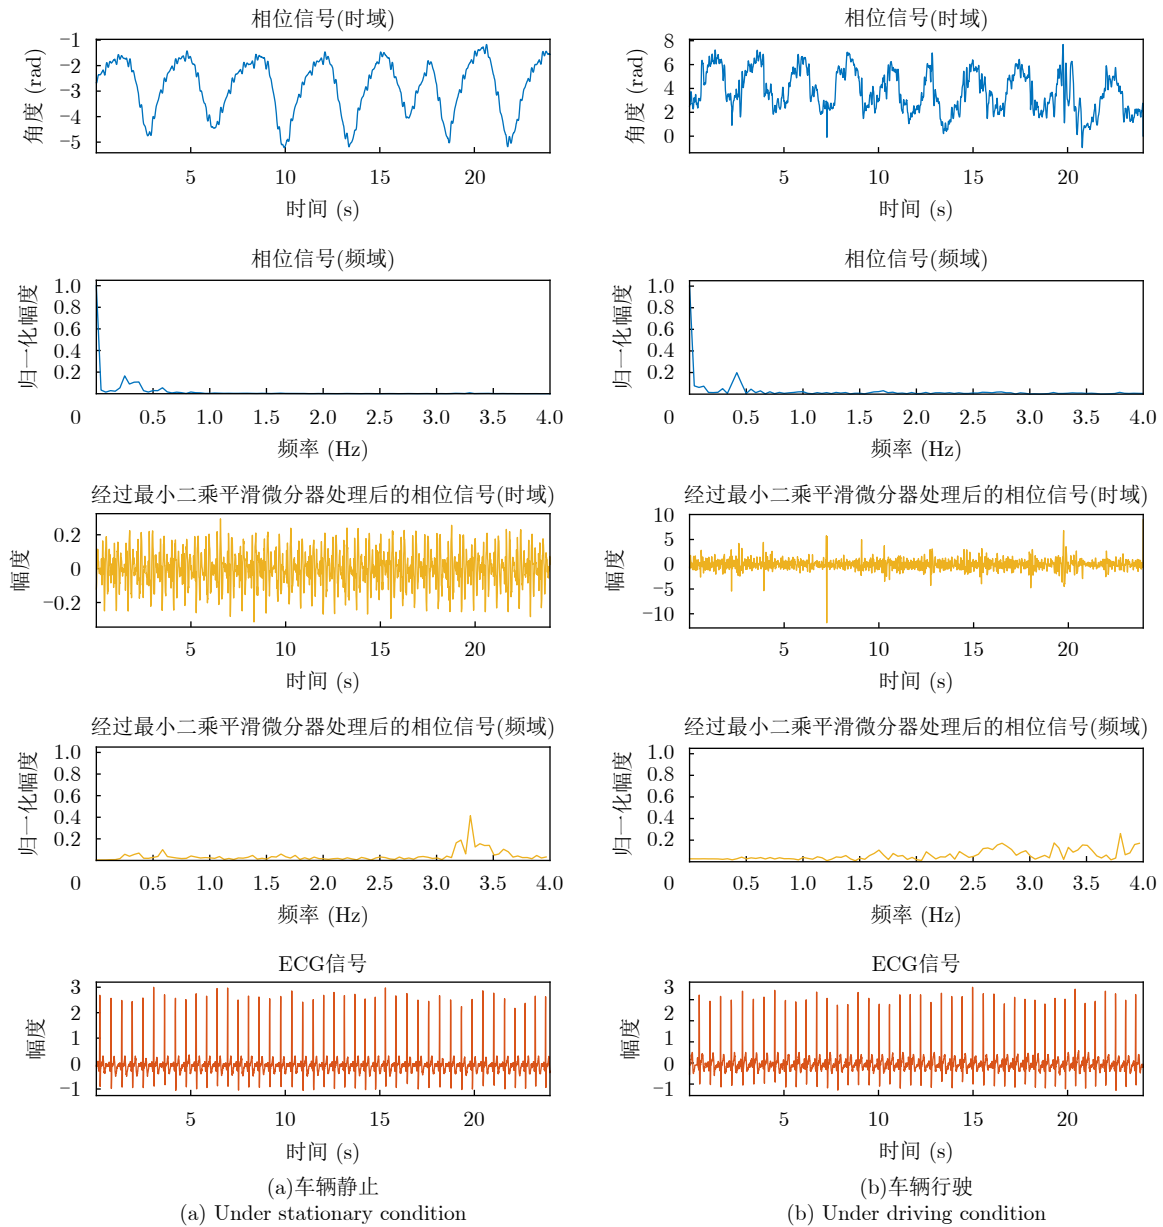


图 4 呼吸干扰抑制示意图

Fig. 4 Illustration of respiratory interference suppression

纯净语音源信号构建训练数据的语音分离任务不同，雷达信号的分离任务缺乏监督信号——本文无法从真实环境的雷达混合信号中获得各个源成分的真实标签。针对上述挑战，首先，本文基于射频信号的特性，

设计了基于多头自注意力的射频特征提取器，在时间维度上学习雷达信号中的心跳特征表示；其次，本文创新性地提出了混合-源信号的训练数据合成策略，通过模拟真实场景下的心跳振动信号，解决了标签缺失的问题，提升了模型在复杂环境下的泛化能力。

如图5所示，深度盲源分离网络由3个部分组成：射频特征提取器、特征掩码分离器和源信号重

构器。射频特征提取器将2.1节信号预处理后的混合信号映射到特征空间中，特征掩码分离器根据输入的特征估计信号源在每个时间戳的掩码，最后通过源信号重构器进行波形重建，从原始的混合信号分离出心跳信号和干扰信号。

2.2.1 时域信号的分离模型

信号的分离问题可表述为：由 C 个信号源 $s_1(t), s_2(t), \dots, s_C(t) \in \mathbb{R}^{1 \times T}$ 组成的混合离散信号 $x(t) \in \mathbb{R}^{1 \times T}$ 。在时域信号的盲源分离问题中，核心问题是从混合信号 $x(t)$ 估计源信号 $s_i(t)$, $i = 1, 2, \dots, C$ 。对于本文车载场景的心跳分量分离问题，可表述为：

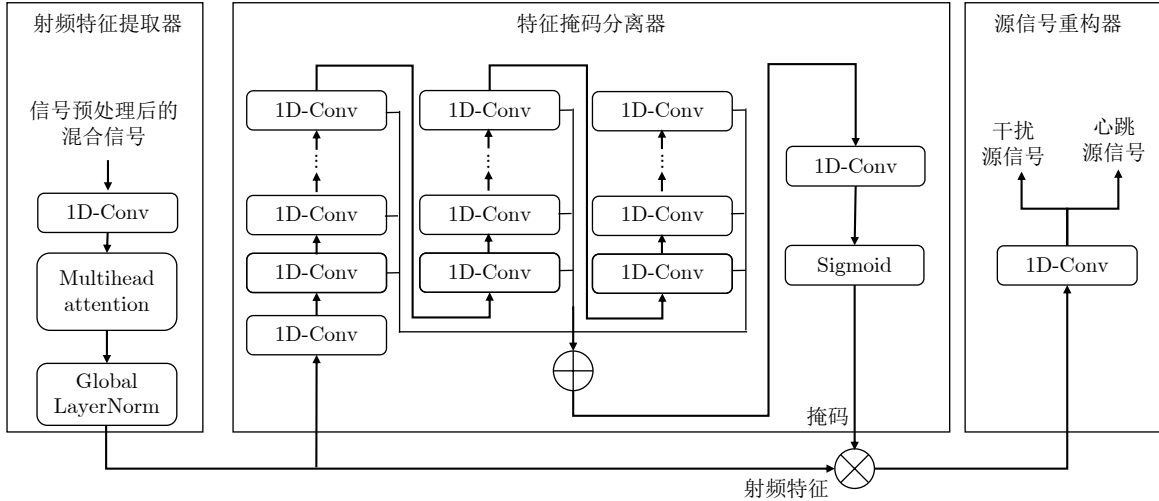


图5 心跳分离算法流程图

Fig. 5 Illustration of the heartbeat separation algorithm

$$x(t) = \text{mix}(s_1(t), s_2(t)) \quad (8)$$

深度学习盲源分离网络的任务是从混合信号 $x(t)$ 估计源信号 $s_1(t)$, $s_2(t)$, 其中, $s_1(t)$ 表示车辆振动干扰成分, $s_2(t)$ 表示心跳成分。

2.2.2 基于多头自注意力的射频特征提取器

传统分离网络通常采用单层一维卷积作为编码器以完成特征映射^[42,43], 传统的射频特征器通过一维卷积层结合批归一化、非线性激活函数及随机失活操作进行特征建模^[34,35]。然而, 上述方法本质上都是局部卷积操作, 主要关注信号在有限感受野内的局部时序特征, 无法捕捉射频信号在时序维度上的全局相关性。

为了提取射频特征信号的特征, 本文构建了基于多头自注意力的特征提取器, 用于实现射频特征的深层建模。具体来说, 先将输入的混合信号 x_k 通过一维卷积层完成初步特征映射, 提取局部时域结构特征并提升特征维度。随后, 引入多头自注意力机制(Multihead Attention)对卷积特征进行建模, 通过自适应地刻画不同时间片段之间的相关性, 捕获射频信号中的长程时序依赖关系与全局结构特征。最后, 采用累积层归一化(Global Layer Normalization, GLN)对特征进行归一化处理, 稳定训练过程并增强模型的泛化能力。特征提取器能够将原始时序信号映射为特征空间中的 N 维特征 $w \in R^{1 \times N}$:

$$w = xU^T \quad (9)$$

2.2.3 基于时间卷积的特征掩码分离器

随后, w 通过基于时间卷积的特征掩码分离器完成每个时间点的分离, 输出估计的心跳和干扰信

号掩码 $m_i \in R^{1 \times N}$, $i = 1, 2$, 每个信号源 d_i 在特征空间中的表征为:

$$d_i = w \odot m_i \quad (10)$$

其中 \odot 表示逐元素乘(Hadamard乘积)。如图6所示, 特征掩码分离器的核心是多尺度特征分离单元, 每个单元由8个一维扩张卷积模块(1D-Conv)构成。该模块首先通过卷积层对输入时序特征进行通道维度的映射, 将特征从输入通道扩展到更高维空间; 随后, 经过PReLU激活函数引入非线性拟合能力, 并通过全局层归一化(GLN)稳定训练过程、加速收敛; 接着, 基于深度可分离卷积(Dilated Conv)扩大感受野, 提取时序特征; 之后再次经过激活与归一化操作, 再通过一个卷积层将通道数压缩回原始输入维度; 最后, 与原始输入进行残差连接, 解决梯度消失问题。

2.2.4 基于卷积的源信号重构器

源信号重构器采用一维卷积层对信号进行解码, 假设 V 是源信号重构器的基函数, \hat{s} 是预测的源信号, 那么重建的波形 \hat{s}_i , $i = 1, 2$, 可以表示为

$$\hat{s}_i = d_i V \quad (11)$$

2.2.5 深度盲源分离网络的损失函数

本文基于尺度不变信源噪声比(Scale-Invariant Signal-to-Noise Ratio, SI-SNR)设计了分离网络的损失函数, 尺度不变信噪比通过内积运算与信号 L_2 范数来确定目标信号分量 s_{target} , 用分离得到的信号 \hat{s} 减去目标信号分量 s_{target} 计算噪声分量 e_{noise} , 之后通过对数运算, 用目标信号分量的能量与噪声分量的能量之比来衡量分离的效果。SI - SNR的值

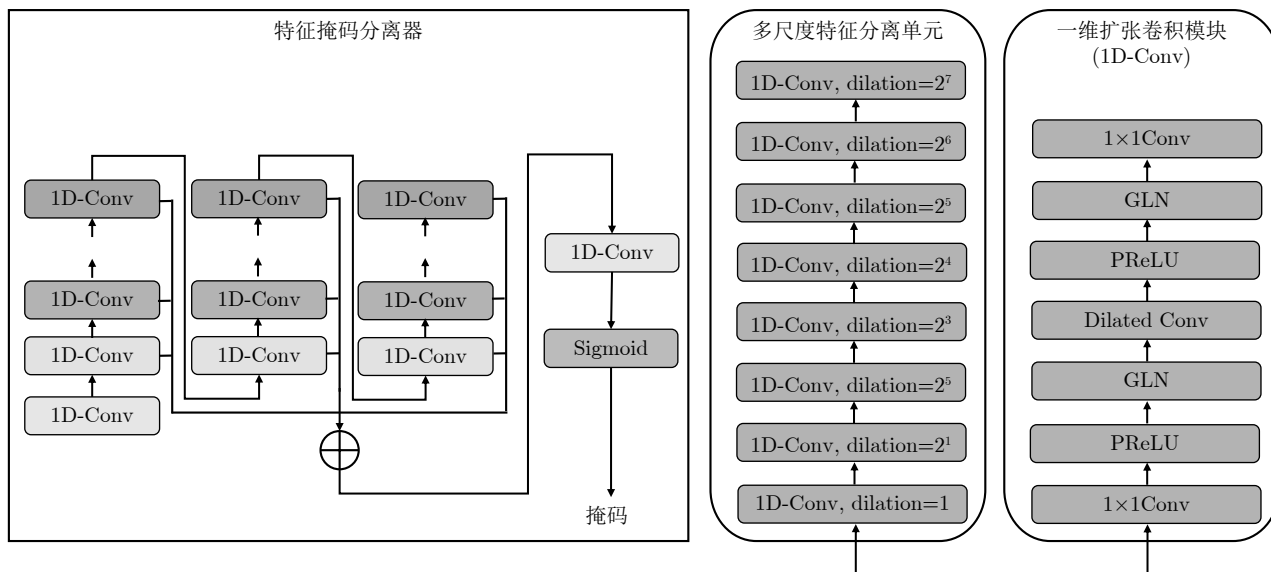


图 6 特征掩码分离器的结构

Fig. 6 Architecture of the feature-mask separator

越大，说明信源分离的效果越好，分离出的目标信号越纯净，噪声越小。尺度不变信噪比定义为

$$\text{SI-SNR} = 10 \log_{10} \frac{\|s_{\text{target}}\|^2}{\|e_{\text{noise}}\|^2}$$

$$s_{\text{target}} = \frac{\langle \hat{s}, s \rangle s}{\|s\|^2}$$

$$e_{\text{noise}} = \hat{s} - s_{\text{target}} \quad (12)$$

深度盲源分离网络的损失函数是基于尺度不变信源噪声比设计的，N是每个批次的样本数，损失函数可表示为

$$\mathcal{L} = -\frac{1}{\text{NC}} \sum_{b=1}^N \sum_{i=1}^C \text{SI-SNR}(\hat{s}_i^b, s_i^b) \quad (13)$$

2.3 混合-源信号训练数据生成模块

尽管深度盲源分离网络具备学习此类复杂非线性关系的能力，但其训练通常依赖于大量数据。为了缓解射频信号采集难的问题，本文设计了一种混合-源信号生成策略，分别构建了射频干扰数据集与射频心跳数据集。如图7所示，针对干扰信号，本文在真实车辆行驶环境中采集了空置副驾的射频信号，采集的数据包含了典型的车辆机械振动特征，能有效代表真实场景中的干扰。针对心跳信号，本文基于40名受试者的SCG构建射频心跳数据集。选择SCG作为心脏运动的参考信号，主要基于SCG与射频信号在物理机理上的一致性^[45]，二者均通过感知人体胸腔表面由于心脏机械活动所引起的微小振动来反映心脏运动特征，因此在信号本质上与射频信号具有一致性。其次，实际采集的射频信号通常

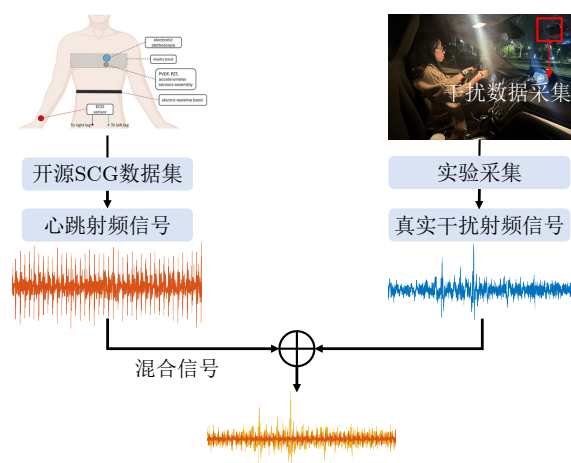


图 7 混合-源信号生成训练数据示意图

Fig. 7 Illustration of hybrid-source signal generation strategy

不可避免地包含呼吸分量及其他环境干扰，难以直接获取纯净的射频心跳信号，相比之下，SCG可通过贴身传感方式获取相对纯净的心脏机械振动信息，更适合作为监督学习中的参考信号。已有研究表明，基于SCG数据对射频心跳感知网络进行训练可行且有效^[28]。

在网络训练阶段，本文从射频心跳仿真数据集和射频干扰数据集中分别抽取源信号进行叠加，叠加产生的混合信号作为深度盲源分离网络的输入，相应的2个源信号(心跳信号和干扰信号)作为监督学习的标签用于损失函数计算；在网络测试阶段，将经过2.1节预处理的混合信号输入网络中，网络输出心跳源信号与干扰源信号。

3 实验设置

3.1 数据采集设备

3.1.1 雷达设备

图8展示了本文所使用的德州仪器公司的AWR6843AOP毫米波雷达,通过激活3个发射器和4个接收器,实现具有12个通道的二维虚拟天线阵列。雷达通过时分复用技术实现多个发射天线之间的时域正交,雷达系统的具体参数如表1所示。

3.1.2 真值数据采集设备

如图9展示了心跳真值采集设备,本文的心跳真值数据由商用心电传感器ADS1292采集,以125 Hz的采样率采集标准导联心电图波形,接收的心电信号首先经过一个带通滤波器(0.2~40 Hz)去除基线漂移和高频噪声,随后采用寻峰算法检测R波位置,并据此计算出相应的心率和心搏间期。

3.1.3 数据同步

为了确保射频数据和ECG数据在时域上的严格对齐,本系统采用了软件时间戳同步机制。在数据采集过程中,毫米波雷达设备AWR6843AOP和心电传感设备ADS1292连接至同一台笔记本电脑的系统时间作为统一的时间基准,通过电脑自带的计时器分别为每一帧接收到的数据打上软件时间戳 T_{radar} (精度为1 ms), T_{ECG} (精度为1 ms)。在处理

数据时,本文根据软件时间戳同步射频和ECG信号 $t = \max(T_{\text{radar}}, T_{\text{ECG}})$ 。通过上述软件时间戳同步机制,系统能够在毫秒级精度(1 ms)下实现雷达信号与心电信号的时域对齐,为后续信号处理提供可靠的基础。

3.2 数据集

本研究共使用了48名受试者的生理数据:其中40名受试者的SCG数据用于模型训练,8名受试者的同步心电图与雷达信号数据用于模型测试。训练组与测试组的受试者完全独立,无任何重叠。

对于训练数据,本文基于开源的数据集^[46]对包含40名受试者、总时长281分钟的SCG数据构建了心跳源信号数据集。

对于测试数据,如图10所示,本文在真实路面驾驶场景中采集了8名受试者(男性4名,女性4名)、心率范围覆盖65~90 bpm、300分钟的射频和心电数据,实验路段设定在高速和城市快速路(良好路况),车型为别克昂科拉。在数据采集过程中,驾驶员保持正常驾驶状态,雷达位于挡风玻璃上方,垂直朝向胸部区域,心电传感器作为真值数据采集设备同步记录心电信号。此外,还有一名工作人员位于副驾驶或后排,使用电脑对实时采集的数据进行核查。对于收集到的实验数据,先对原始数据进行



图8 毫米波雷达设备

Fig. 8 Millimeter-wave radar device




图9 心电传感器

Fig. 9 Electrocardiogram sensor

表1 雷达参数

Tab. 1 Radar parameters

雷达配置	具体参数
起始频率 f_c	60 GHz
带宽B	3.9 GHz
啁啾持续时间 T_c	60 ms
距离单元R	30
相位信号采样率 f_s	100 Hz



图10 测试数据采集场景

Fig. 10 Experimental setup

行波束形成和杂波消除，之后识别驾驶员位置的距离单元，通过微分器去除呼吸干扰，将包含心跳和车辆行驶振动干扰的混合信号输入深度盲源分离网络。之后对心跳信号应用峰值检测算法计算心跳个数、心跳间隔时间，对比心电真值数据进行误差的评估。

3.3 实现过程

本研究基于PyTorch框架实现深度盲源分离网络的训练和测试。训练数据有50000条，测试数据有1200条。在训练阶段，时间长度设为30 s，信号分离个数 C 设置为2，由2.3节方法产生的混合信号经过基于多头自注意力的射频特征提取器将特征扩展到512维，随后，特征经瓶颈层压缩后送入时序卷积分离网络，通过多层深度可分离卷积在不同时间尺度上提取时序特征。在掩码生成阶段，网络通过卷积将特征通道数扩展至1024维，生成对应于不同源信号的分离掩码。最后，结合转置卷积解码器对特征进行重构，得到分离后的心跳信号与干扰信号。模型训练在NVIDIA RTX 4090 GPU上进行，采用Adam优化器，批次大小设置为8，初始学习率设为0.001。模型的计算量是45.08 GFLOPs，参数量是4.51 M。在GPU上，模型的单样本(30 s时间窗)推理耗时为13.42 ms；在CPU上，单样本推理耗时为136.15 ms。为提高模型评估的稳定性与泛化能力，实验采用五折交叉验证策略。

3.4 评估指标

本研究从模型训练稳定性与终端任务性能两个角度对盲源分离网络的性能进行评价。一方面，通过五折交叉验证的损失变化分析模型在不同数据划分下的收敛性与泛化能力；另一方面，采用心率(Heart Rate, HR)与心搏间期(Inter-Beat Interval, IBI)估计误差作为重构心跳信号的评价指标，从终

端任务层面反映分离模块的有效性。在误差统计上，本研究采用了平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Square Error, RMSE)和中位数误差(Median Error, Med) 3个指标以提供全面的评估。

平均绝对误差展示了平均水平，均方根误差强调了大误差的影响，而中位数误差确保了对异常值的稳健性。这种组合评估方法能够有效避免单一指标带来的偏差，为系统的性能评价提供更加全面和可靠的依据。

4 结果与讨论

4.1 深度盲源分离网络效果

为评估模型在不同数据划分下的稳定性与泛化能力，本文采用五折交叉验证，如图11(a)所示，在每一折训练过程中，训练损失均呈现出快速下降并逐步收敛的趋势，表明模型能够学到输入信号中的射频心跳特征。同时，如图11(b)所示，各折对应的验证损失曲线与训练损失保持高度一致，都随着训练迭代稳步下降，不同折之间的最优验证损失数值接近，说明模型对数据划分不敏感，在不同子集上均有稳定的表现。以第一折为例，模型训练损失由初始的236.98 dB 逐步下降至-59.443 dB，表明网络在训练过程中显著提升了SI-SNR。随着训练迭代，分离信号中目标心跳成分的能量占比不断提高，残余噪声和干扰得到有效抑制。综上所述，五折交叉验证结果验证了本文所设计的模型在训练稳定性与泛化能力方面的可靠性，为后续心率及心搏间期的估计提供了基础。

图12展示了模型在测试集上的效果，从整体结果来看，分离网络输出的心跳信号已经呈现出较为明显的周期性，并与下方心跳真值信号在节律上保持了较高一致性，说明模型能够较稳定地分离与心

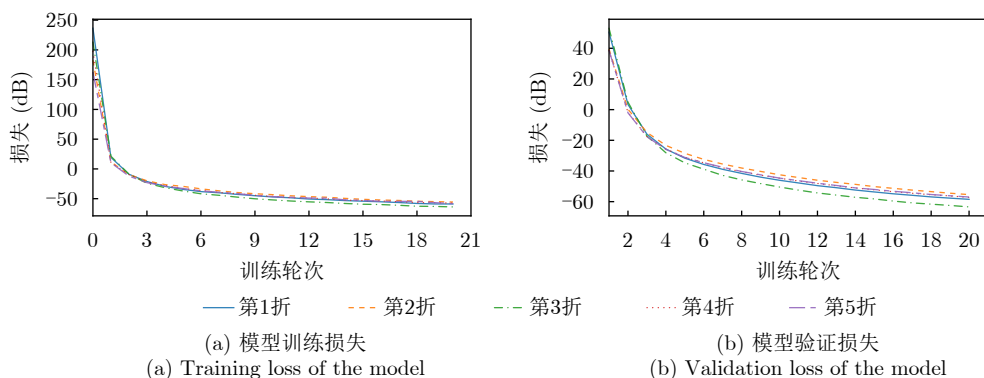


图 11 模型训练情况

Fig. 11 Model training results

跳节律相关的时序信息。从定量指标看,该样例中的心搏间期平均绝对误差为31.49 ms,心率平均绝对误差为2.40 bpm,误差量级相对较小。

4.2 心率估计

本文在3.2节的测试数据集上评估了本文所提方案和2个基线方案,根据心电真值计算相应的心率估计误差。基线方案1采用文献[31]的算法将混合信号分解为多个窄带模态分量以解决模态混叠问题。基线方案2采用文献[19]的信号分解方法,由于分解提取的高频分量由汽车振动主导,因此在心率估计上误差较大,均方根误差为5.26 bpm。表2结果显示,本文所提方案的心率均方根误差、平均绝对误差和中位数误差分别为3.79 bpm, 3.35 bpm和3.16 bpm,均优于基线方案,验证了该方法在心率




图 12 模型测试情况

Fig. 12 Model testing result

估计上的优越性。为了更好展示心率估计误差的分布,本文在图13中展示了累积分布函数,可以看出,心率估计中位数误差小于4 bpm。

4.3 心搏间期估计

表3结果显示,本文所提方案的心搏间期均方根误差、平均绝对误差和中位数误差分别为45.13 ms, 41.87 ms和39.23 ms,均优于2种基线方案,验证了该方法在心搏间期估计精度上的优越性。

为了更好展示心搏间期估计误差的分布,本文在图14中展示了累积分布函数,本系统在误差分布及量化指标上均显著优于两种基线方案,心搏间期估计中位数误差小于45 ms。

4.4 消融实验

为验证不同特征提取器对射频信号建模能力的影响,本文对比了3类典型特征提取器,包括基于多头自注意力机制的特征提取器、基于卷积神经网络的射频特征提取器(mmFormer)^[34],以及传

表 2 心率估计误差统计结果

Tab. 2 Heart rate estimation error statistics

方案	HR_RMSE	HR_MAE	HR_MED
基线方案1	10.46bpm	9.49bpm	10.12bpm
基线方案2	5.26bpm	4.35bpm	4.17bpm
本文方案	3.79 bpm	3.35 bpm	3.16 bpm




图 13 心率估计误差累积分布函数

Fig. 13 Cumulative distribution function of heart rate estimation errors

表 3 心搏间期估计误差统计结果

Tab. 3 IBI estimation error statistics

方案	IBI_RMSE	IBI_MAE	IBI_MED
基线方案1	148.02ms	125.94ms	120.00ms
基线方案2	97.16 ms	78.42 ms	67.29 ms
本文方案	45.13 ms	41.87 ms	39.23 ms




图 14 心搏间期估计误差累积分布函数

Fig. 14 Cumulative distribution function of IBI estimation errors

统语音分离网络中常用的卷积特征提取器(Conv-TasNet)^[42]。实验结果表明，与基于卷积的特征提取器相比，本文所提出的基于多头自注意力的射频特征提取结构在多项心率和心搏间期评价指标上取得了最优性能，验证了该结构在提取射频信号全局特征方面的优越性。

在信号分离任务，常用的相似性度量包括弦相似度(Cos-Sim)和尺度不变信噪比(SI-SNR)。为分析不同损失函数对模型性能的影响，本文对比了基于尺度不变信源噪声比(SI-SNR)和基于余弦相似度(Cos-Sim)两种损失函数。SI-SNR定义见2.2.5节，基于余弦相似度的损失函数可表示为

$$\text{Cos-Sim}(\hat{s}, s) = \frac{\hat{s}^T s}{|\hat{s}|_2 |s|_2}$$

$$\mathcal{L} = 1 - \text{CosSim}(\hat{s}, s) \quad (14)$$

Cos-Sim主要衡量预测信号与真实信号的方向相似性，对幅度信息不敏感。相比之下，SI-SNR通过幅度对齐将预测信号映射到真实信号的尺度，

同时考虑残差能量，从而能够同时反映信号的方向和幅度匹配程度，有效提升信号重建的精度和训练的稳定性。实验结果表明，相较于 Cos-Sim，SI-SNR 更适用于射频信号分离任务，在多项心率及心搏间期评价指标上均取得了更优性能。

为分析不同信号混合方式对模型性能的影响，本文对比了线性叠加和非线性叠加两种方式，线性叠加假设心跳信号与车载干扰在天线孔径处发生物理混合^[47]，可以表示为

$$\phi_{\text{mix}}(t) = \phi_{\text{heart}}(t) + \phi_{\text{noise}}(t) \quad (15)$$

非线性叠加基于相位强度的掩蔽逻辑，若车载干扰产生的相位偏移强度超过心跳信号，则心跳信号被干扰信号替代(即被掩蔽)^[48]。该过程可表示为

$$\phi_{\text{mix}}(t) = \begin{cases} \phi_{\text{noise}}(t), & \text{if } |\phi_{\text{noise}}(t)| \geq |\phi_{\text{heart}}(t)| \\ \phi_{\text{heart}}(t), & \text{otherwise} \end{cases} \quad (16)$$

实验结果表明，相较于非线性叠加，线性叠加更适用于射频信号分离任务，在多项心率及心搏间期评价指标上，线性叠加策略取得了更优性能。究其原因，线性叠加更符合心跳信号与干扰信号的实际混合模式，能够在保留各信号幅度和频谱特征的同时，为分离模型提供更稳定、完整的训练特征。

综上所述，本文对模型进行了系统实验，试了3种特征提取器结构、两种损失函数以及两种信号叠加方式进行训练(如表4所示)。实验结果表明，本文设计的基于自注意力的射频特征提取器在采用SI-SNR损失函数和线性混合信号训练的条件下表现最优，在心率及心搏间期估计任务上取得了佳指标。心率均方根误差、平均绝对误差和中位数误差分别为3.79 bpm, 3.35 bpm和3.16 bpm，心搏间期

表 4 不同模型结构、训练方式下心率、心搏间期估计误差结果

Tab. 4 HR and IBI estimation errors under different model structures and training strategies

特征提取器	损失函数	叠加方式	HR_RMSE	HR_MAE	HR_MED	IBI_RMSE	IBI_MAE	IBI_MED
本文结构	SI-SNR	线性叠加	3.79 bpm	3.35 bpm	3.16 bpm	45.13 ms	41.87 ms	39.23 ms
		非线性叠加	4.23 bpm	3.53 bpm	3.22 bpm	47.70 ms	46.90 ms	42.79 ms
	Cos-Sim	线性叠加	4.36 bpm	3.61 bpm	3.27 bpm	48.99 ms	46.56 ms	42.93 ms
		非线性叠加	4.52 bpm	3.78 bpm	3.30 bpm	49.11 ms	46.79 ms	43.42 ms
mmformer	SI-SNR	线性叠加	4.60 bpm	3.81 bpm	3.34 bpm	49.33 ms	46.93 ms	44.18 ms
		非线性叠加	4.99 bpm	4.23 bpm	3.76 bpm	51.32 ms	49.04 ms	46.14 ms
	Cos-Sim	线性叠加	4.64 bpm	3.83 bpm	3.40 bpm	50.50 ms	48.50 ms	45.22 ms
		非线性叠加	5.03 bpm	4.25 bpm	3.71 bpm	52.81 ms	50.18 ms	46.47 ms
ConvTasnet	SI-SNR	线性叠加	5.04 bpm	4.30 bpm	3.80 bpm	55.03 ms	52.22 ms	48.12 ms
		非线性叠加	6.23 bpm	5.36 bpm	4.79 bpm	59.13 ms	54.43 ms	52.15 ms
	Cos-Sim	线性叠加	5.62 bpm	5.32 bpm	4.75 bpm	57.50 ms	52.58 ms	48.46 ms
		非线性叠加	6.68 bpm	5.89 bpm	4.87 bpm	67.50 ms	62.58 ms	53.27 ms

均方根误差、平均绝对误差和中位数误差分别为45.13 ms, 41.87 ms和39.23 ms。

4.5 训练数据集影响

在训练深度盲源分离网络时,心跳源信号和干扰源信号是随机匹配的,随着训练数据的增加,网络学习越多知识,在盲源分离任务上的表现越好。如表5所示,随着样本从5000对增至50000对,心率和心搏间期的误差总体呈现下降趋势:心率的绝对值误差从6.39 bpm降至3.35 bpm,心搏间期的绝对值误差从74.11 ms降至41.87 ms。

4.6 不同受试者的影响

表6中展示了不同用户的心率与心搏间期估计误差结果,反映出系统在真实驾驶场景下良好的用户泛化能力。整体来看,所有用户心率中位数误差在4 bpm以内,心搏间期中位数误差位于55 ms以内,表明系统对不同个体具有较强的泛化性。其中,用户4表现优异(心率绝对误差小于2.5 bpm),而用户1和用户5误差相对较高,但结果仍在可接受范围内。

4.7 不同车型的影响

为了全面分析汽车类型对系统性能的影响,本文额外采集了受试者7在良好路况上驾驶电车的相关数据,与油车的数据进行相同的信号处理操作。如表7所示,电车在心率与心搏间期估计中的各项误差指标均优于油车,电车的心率均方根误差为3.37 bpm,心搏间期均方根误差为33.16 ms,分别比油车降低了约1 bpm和10 ms。从振动频谱的角度来说,油车由于内燃机振动,其车体振动频率更高、幅度更大,导致心跳信号的干扰增强,使得毫米波雷达分离心跳信号的难度更大。

4.8 不同路况的影响

为了全面分析路况对系统性能的影响,本文额外采集了受试者2驾驶油车在普通城市沥青道路、水泥混凝土路的相关数据。如表8所示,随着路面质量下降,心率与心搏间期估计误差逐渐增加。在路况良好的条件下系统性能最佳,心率的均方根误差为3.42 bpm,心搏间期的均方根误差为44.65 ms。在路况较差的环境中,心率与心搏间期的各项误差指标均明显上升,均方根误差分别达到了7.64 bpm

表 5 不同训练数据集下心率、心搏间期估计误差结果

Tab. 5 HR and IBI estimation errors under different training datasets

	HR_RMSE	HR_MAE	HR_MED	IBI_RMSE	IBI_MAE	IBI_MED
5000对	7.18bpm	6.39bpm	5.51bpm	87.53ms	74.11 ms	60.00ms
10000对	5.96bpm	5.53bpm	5.05bpm	63.67 ms	62.16 ms	59.47ms
25000对	4.77bpm	3.86bpm	3.72 bpm	54.36ms	49.23 ms	47.87ms
50000对	3.79 bpm	3.35 bpm	3.16 bpm	45.13 ms	41.87 ms	39.23 ms

表 6 不同受试者的心率、心搏间期估计误差结果

Tab. 6 HR and IBI estimation errors across different subjects

	HR_RMSE	HR_MAE	HR_MED	IBI_RMSE	IBI_MAE	IBI_MED
受试者1	4.52 bpm	3.92 bpm	3.07 bpm	44.00ms	43.28 ms	41.24 ms
受试者2	3.42 bpm	2.99 bpm	3.19 bpm	44.65 ms	43.82 ms	44.71 ms
受试者3	4.01 bpm	3.84 bpm	3.05 bpm	40.12 ms	38.72 ms	38.27 ms
受试者4	2.50 bpm	2.26 bpm	2.17 bpm	35.95 ms	34.31 ms	31.43 ms
受试者5	4.09 bpm	3.58 bpm	2.88 bpm	59.54 ms	53.85 ms	50.57 ms
受试者6	3.32 bpm	3.31 bpm	3.38 bpm	53.31 ms	50.37 ms	45.06 ms
受试者7	4.06 bpm	3.21 bpm	2.07 bpm	43.84 ms	41.02 ms	36.76 ms
受试者8	4.02 bpm	3.71 bpm	3.23 bpm	40.77 ms	39.60 ms	40.45 ms

表 7 不同车型条件下心率、心搏间期估计误差结果

Tab. 7 HR and IBI estimation errors under different vehicle types

	HR_RMSE	HR_MAE	HR_MED	IBI_RMSE	IBI_MAE	IBI_MED
油车	4.06 bpm	3.21 bpm	2.07 bpm	43.84 ms	41.02 ms	36.76 ms
电车	3.37 bpm	3.05 bpm	2.97 bpm	33.16 ms	31.32 ms	28.47 ms

表 8 不同路面情况下心率、心搏间期估计误差结果
Tab. 8 HR and IBI estimation errors under different road conditions

	HR_RMSE	HR_MAE	HR_MED	IBI_RMSE	IBI_MAE	IBI_MED
良好	3.42 bpm	2.99 bpm	3.19 bpm	44.65 ms	43.82 ms	44.71 ms
一般	5.13 bpm	5.09 bpm	4.94 bpm	87.25 ms	62.29 ms	61.70 ms
差	7.64 bpm	6.67 bpm	6.19 bpm	101.08 ms	94.65 ms	91.39 ms
综合	5.40 bpm	4.92 bpm	4.77 bpm	77.66 ms	66.92 ms	65.93 ms

和101.08 ms。这主要是由于较差的路面条件会引入强烈的振动干扰，深度盲源分离网络难以有效分离出微弱的心跳相关特征，进而影响心率与心搏间期的准确估计。为了更客观、更全面地反映系统在实际应用场景中的性能水平，本研究采用加权后的结果作为系统的整体性能，为3类道路场景设置了均等的权重，综合各种路面情况，系统可实现心率绝对误差4.92 bpm、心搏间期中位数误差65.93 ms的感知精度。

4.9 不同驾驶环境的影响

为了全面分析驾驶环境对系统性能的影响，本文额外采集了受试者6在2种静态场景(车辆完全静

止且未启动状态、车辆已启动但处于路面停驻状态)的相关数据。在静态场景中，由于不存在行驶干扰，本文直接对预处理后的信号应用寻峰算法进行心跳分割，并基于心电真值进行计算误差，相位信号参见图4。如表9所示，在无行驶干扰的静态环境中，系统表现良好，心率均方误差低于2 bpm；而在动态驾驶条件下，心率绝对误差增至3 bpm以上，这主要由于动态环境中噪声和干扰较大，直接影响了心率与心搏间期估计的准确性。尽管本系统在动态环境下的心搏间期误差略高于传统医疗级ECG设备标称的20 ms，但考虑到其为非接触式、可在实际驾驶环境中应用的特点，该精度仍具有实用价值。

表 9 不同驾驶环境下心率、心搏间期估计误差结果
Tab. 9 HR and IBI estimation errors under under different driving environments

	HR_RMSE	HR_MAE	HR_MED	IBI_RMSE	IBI_MAE	IBI_MED
静态(未启动)	1.28 bpm	1.17bpm	0.99bpm	30.87ms	30.73ms	29.31ms
静态(已启动)	1.90 bpm	1.59bpm	1.51bpm	47.31ms	43.36ms	40.00ms
动态	3.32 bpm	3.31 bpm	3.38 bpm	53.31 ms	50.37 ms	45.06 ms

5 结语

本研究提出了一种深度盲源分离算法，通过射频特征提取器、特征掩码分离器、源信号重构器分离射频心跳成分。针对训练数据采集难的问题，本文创新性地设计了一种混合-源信号生成策略，通过心震描记数据和车载干扰数据生成大量的训练样本。此外，本文在真实驾驶场景下开展了系统性评估，涵盖不同受试者、车型及路况条件。

本研究存在若干局限性，值得在未来工作中进一步完善：首先，在路况较差的场景下(如水泥路面或者存在坑洼)，系统性能显著下降，心率与心搏间期的均方根误差分别上升至7.64 bpm和101.08 ms，这表明当前模型对强振动干扰和复杂驾驶行为的鲁棒性仍有不足。为此，有待在实际应用中引入信号质量评估机制，通过实时监测振动强度、频谱能量分布等方法判断是否进行生理参数估计，从而避免在低信噪比条件下输出不可靠的结果。其次，

当前训练数据和测试数据的多样性有待提高，基于源信号-混合生成训练数据的方式有待进一步探究，未来可通过构建更精细的物理-生理耦合仿真模型，生成涵盖更广泛驾驶行为与环境扰动的合成数据，以增强模型的泛化能力，对于测试数据，有待采集更大心率范围评估算法的性能。此外，单一模态雷达信号在复杂场景下收集到的信息是有限的，未来有待探索多模态融合方向。

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] World Health Organization. World health statistics 2025[R/OL]. Geneva: World Health Organization, 2025[2026-05-12]. <https://www.who.int/publications/b/78420>.
- [2] 国家统计局. 中国统计年鉴2024:24-5 道路交通事故情况

- (2023年)[M/OL]. 北京: 中国统计出版社, 2024[2026-05-12]. <https://www.stats.gov.cn/sj/ndsjs/2024/indexch.htm>.
- National Bureau of Statistics of China. China Statistical Yearbook 2024: 24-5 Traffic Accidents (2023)[M/OL]. Beijing: China Statistics Press, 2024[2026-05-12]. <https://www.stats.gov.cn/sj/ndsjs/2024/indexch.htm>.
- [3] DU Guanglong, ZHANG Linlin, SU Kang, *et al.* A multimodal fusion fatigue driving detection method based on heart rate and PERCLOS[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(11): 21810–21820. doi: [10.1109/TITS.2022.3176973](https://doi.org/10.1109/TITS.2022.3176973).
- [4] POP G N, CHRISTODORESCU R, VELIMIROVICI D E, *et al.* Assessment of the impact of alcohol consumption patterns on heart rate variability by machine learning in healthy young adults[J]. *Medicina*, 2021, 57(9): 956. doi: [10.3390/medicina57090956](https://doi.org/10.3390/medicina57090956).
- [5] HASNUL M A, AZIZ N A A, ALELYANI S, *et al.* Electrocardiogram-based emotion recognition systems and their applications in healthcare—a review[J]. *Sensors*, 2021, 21(15): 5015. doi: [10.3390/s21155015](https://doi.org/10.3390/s21155015).
- [6] CHEN Weixuan and MCDUFF D. Deepphys: Video-based physiological measurement using convolutional attention networks[C]. 15th European Conference on Computer Vision – ECCV 2018, Munich, Germany, 2018: 356–373. doi: [10.1007/978-3-030-01216-8_22](https://doi.org/10.1007/978-3-030-01216-8_22).
- [7] YU Zitong, SHEN Yuming, SHI Jingang, *et al.* PhysFormer: Facial video-based physiological measurement with temporal difference transformer[C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition, New Orleans, USA, 2022: 4176–4186. doi: [10.1109/CVPR52688.2022.00415](https://doi.org/10.1109/CVPR52688.2022.00415).
- [8] ZOU Bochao, GUO Zizheng, CHEN Jiansheng, *et al.* RhythmFormer: Extracting patterned rPPG signals based on periodic sparse attention[J]. *Pattern Recognition*, 2025, 164: 111511. doi: [10.1016/j.patcog.2025.111511](https://doi.org/10.1016/j.patcog.2025.111511).
- [9] CHOI J and LEE S J. MMDrive: Multi-modal remote physiological signal measurement dataset for driver status monitoring[C]. 2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Nashville, USA, 2025: 5691–5698. doi: [10.1109/CVPRW67362.2025.00567](https://doi.org/10.1109/CVPRW67362.2025.00567).
- [10] DAI Tianyang, CHEN Yan, and HU Yang. rPPG-NDCL: Unsupervised remote physiological measurement via noise-disentangled contrastive learning[C]. 2025 IEEE International Conference on Image Processing (ICIP), Anchorage, USA, 2025: 2856–2861. doi: [10.1109/ICIP55913.2025.11084290](https://doi.org/10.1109/ICIP55913.2025.11084290).
- [11] LIANG Qian, CHEN Yan, and Hu Yang. Continual learning for remote physiological measurement: Minimize forgetting and simplify inference[C]. 18th European Conference on Computer Vision – ECCV 2024, Milan, Italy, 2024: 126–144. doi: [10.1007/978-3-031-72764-1_8](https://doi.org/10.1007/978-3-031-72764-1_8).
- [12] 杨轩, 王子颖, 张力, 等. 基于盲源分离的多人呼吸信号检测方法[J]. 雷达学报(中英文), 2025, 14(1): 117–134. doi: [10.12000/JR24115](https://doi.org/10.12000/JR24115).
- YANG Xuan, WANG Ziyang, ZHANG Li, *et al.* Noncontact multiperson respiratory detection method based on blind source separation[J]. *Journal of Radars*, 2025, 14(1): 117–134. doi: [10.12000/JR24115](https://doi.org/10.12000/JR24115).
- [13] 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).
- 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).
- [14] 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).
- [15] 郑学召, 丁文, 黄渊, 等. 不同领域下超宽带雷达探测呼吸心跳信号研究综述[J]. 雷达学报, 2024, 14(1): 204–228. doi: [10.12000/JR24154](https://doi.org/10.12000/JR24154).
- ZHENG Xuezhao, DING Wen, HUANG Yuan, *et al.* A review of UWB radar detection of respiration and heartbeat signals in different scenarios[J]. *Journal of Radars*, 2025, 14(1): 204–228. doi: [10.12000/JR24154](https://doi.org/10.12000/JR24154).
- [16] 李志, 唐成垚, 戴永鹏, 等. 多旋翼无人机载4D成像雷达生命体征感知方法[J]. 雷达学报(中英文), 2025, 14(1): 62–72. doi: [10.12000/JR24128](https://doi.org/10.12000/JR24128).
- LI Zhi, TANG Chengyao, DAI Yongpeng, *et al.* Multirotor UAV-borne vital signs sensing using 4D imaging radar[J]. *Journal of Radars*, 2025, 14(1): 62–72. doi: [10.12000/JR24128](https://doi.org/10.12000/JR24128).
- [17] 刘畅宇, 张浩, 耿芳琳, 等. 基于距离抽头重构的生理雷达动态解调算法[J]. 雷达学报(中英文), 2025, 14(1): 135–150. doi: [10.12000/JR24151](https://doi.org/10.12000/JR24151).
- LIU Changyu, ZHANG Hao, GENG Fanglin, *et al.* Dynamic demodulation algorithm for bio-radar sensors based on range tapper[J]. *Journal of Radars*, 2025, 14(1): 135–150. doi: [10.12000/JR24151](https://doi.org/10.12000/JR24151).
- [18] GUO Zehan, ZHANG Binbin, CHEN Jinbo, *et al.* Contactless fine-grained cardiac events detection and segmentation with radio frequency signals[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2025, 9(3): 82. doi: [10.1145/3749457](https://doi.org/10.1145/3749457).

- [19] ZHANG Binbin, ZHANG Dongheng, LI Yadong, *et al.* Monitoring long-term cardiac activity with contactless radio frequency signals[J]. *Nature Communications*, 2024, 15(1): 10598. doi: [10.1038/s41467-024-55061-9](https://doi.org/10.1038/s41467-024-55061-9).
- [20] 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](https://doi.org/10.1038/s41467-025-59482-y).
- [21] GONG Hanqin, CHEN Jinbo, XU Guixin, *et al.* Osense: Omni-directional heartbeat sensing with radio signal[J]. *IEEE Internet of Things Journal*, 2025, 12(12): 25269–25285. doi: [10.1109/JIOT.2025.3558733](https://doi.org/10.1109/JIOT.2025.3558733).
- [22] XU Xiaohan, ZHANG Dongheng, LU Zhi, *et al.* Contactless nighttime stress monitoring with mmwave radar[C]. ICASSP 2025 - 2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Hyderabad, India, 2025: 1–5. doi: [10.1109/ICASSP49660.2025.10890411](https://doi.org/10.1109/ICASSP49660.2025.10890411).
- [23] ZHANG Haoyu, ZHANG Dongheng, SONG Ruiyuan, *et al.* UMIMO: Universal unsupervised learning for mmwave radar sensing with MIMO array synthesis[J]. *IEEE Transactions on Mobile Computing*, 2025, 24(8): 7042–7058. doi: [10.1109/TMC.2025.3546757](https://doi.org/10.1109/TMC.2025.3546757).
- [24] LIN Jiayan, GUO Shisheng, XUE Shucheng, *et al.* Non-line-of-sight human vital sign detection method based on correntropy and cross-correlation with multipath exploitation[C]. 2025 IEEE Radar Conference (RadarConf25), Krakow, Poland, 2025: 1028–1033. doi: [10.1109/RadarConf2559087.2025.11205110](https://doi.org/10.1109/RadarConf2559087.2025.11205110).
- [25] GU Boyuan, YANG Yanhui, YOU Siyu, *et al.* Improved VMD based remote heartbeat estimation utilizing 60GHz mmWave radar[C]. 2025 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Vienna, Austria, 2025: 4635–4640. doi: [10.1109/SMC58881.2025.11342664](https://doi.org/10.1109/SMC58881.2025.11342664).
- [26] LI Jiachen, GUO Shisheng, CUI Guolong, *et al.* Multidomain separation for human vital signs detection with FMCW radar in interference environment[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2024, 72(7): 4278–4293. doi: [10.1109/TMTT.2023.3337101](https://doi.org/10.1109/TMTT.2023.3337101).
- [27] LIU Xingyao, CHEN Jiahui, GUO Shisheng, *et al.* Non-line-of-sight human vital sign detection method based on multipath signals fusion[C]. 2023 3rd International Conference on Frontiers of Electronics, Information and Computation Technologies (ICFEICT), Yangzhou, China, 2023: 489–496. doi: [10.1109/ICFEICT59519.2023.00086](https://doi.org/10.1109/ICFEICT59519.2023.00086).
- [28] HA U, MADANI S, and ADIB F. WiStress: Contactless stress monitoring using wireless signals[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2021, 5(3): 103. doi: [10.1145/3478121](https://doi.org/10.1145/3478121).
- [29] LIANG Kun, ZHOU Anfu, ZHANG Zhan, *et al.* mmStress: Distilling human stress from daily activities via contact-less millimeter-wave sensing[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2023, 7(3): 110. doi: [10.1145/3610926](https://doi.org/10.1145/3610926).
- [30] ZHU Juncen, CAO Jiannong, YANG Yanni, *et al.* mmdrive: Fine-grained fatigue driving detection using mmwave radar[J]. *ACM Transactions on Internet of Things*, 2023, 4(4): 26. doi: [10.1145/3614437](https://doi.org/10.1145/3614437).
- [31] ZHENG Tianyue, CHEN Zhe, CAI Chao, *et al.* V2iFi: In-vehicle vital sign monitoring via compact RF sensing[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2020, 4(2): 70. doi: [10.1145/3397321](https://doi.org/10.1145/3397321).
- [32] XU Xiangyu, YU Jiadi, MA Chengguang, *et al.* mmECG: Monitoring human cardiac cycle in driving environments leveraging millimeter wave[C]. IEEE INFOCOM 2022 - IEEE Conference on Computer Communications, London, United Kingdom, 2022: 90–99. doi: [10.1109/INFOCOM48880.2022.9796912](https://doi.org/10.1109/INFOCOM48880.2022.9796912).
- [33] WANG Fengyu, ZENG Xiaolu, WU Chenshu, *et al.* Driver vital signs monitoring using millimeter wave radio[J]. *IEEE Internet of Things Journal*, 2022, 9(13): 11283–11298. doi: [10.1109/JIOT.2021.3128548](https://doi.org/10.1109/JIOT.2021.3128548).
- [34] HU Qingyong, ZHANG Qian, LU Hao, *et al.* Contactless arterial blood pressure waveform monitoring with mmwave radar[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2024, 8(4): 178. doi: [10.1145/3699781](https://doi.org/10.1145/3699781).
- [35] KHAN U M, RIGAZIO L, and SHAHZAD M. Contactless monitoring of PPG using radar[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2022, 6(3): 123. doi: [10.1145/3550330](https://doi.org/10.1145/3550330).
- [36] 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](https://doi.org/10.1109/TMC.2022.3214721).
- [37] WANG Haoyu, CHEN Jinbo, ZHANG Dongheng, *et al.* Contactless radar heart rate variability monitoring via deep spatio-temporal modeling[C]. ICASSP 2024 - 2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Seoul, Korea, Republic of, 2024: 111–115. doi: [10.1109/ICASSP48485.2024.10447570](https://doi.org/10.1109/ICASSP48485.2024.10447570).
- [38] Wang Jiyao, YANG Xiao, HU Qingyong, *et al.* Physdrive: A multimodal remote physiological measurement dataset for in-vehicle driver monitoring[J]. *Advances in Neural Information Processing Systems*, 2026, 38.
- [39] ZHANG Dongheng, HU Yang, and CHEN Yan. MTrack: Tracking multiperson moving trajectories and vital signs with radio signals[J]. *IEEE Internet of Things Journal*, 2021, 8(5): 3904–3914. doi: [10.1109/JIOT.2020.3025820](https://doi.org/10.1109/JIOT.2020.3025820).

- [40] ZHAO Mingmin, ADIB F, and KATABI D. Emotion recognition using wireless signals[C]. The 22nd Annual International Conference on Mobile Computing and Networking, New York, USA, 2016: 95–108. doi: [10.1145/2973750.2973762](https://doi.org/10.1145/2973750.2973762).
- [41] ÖZER Y and MÜLLER M. Source separation of piano concertos using musically motivated augmentation techniques[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2024, 32: 1214–1225. doi: [10.1109/TASLP.2024.3356980](https://doi.org/10.1109/TASLP.2024.3356980).
- [42] LUO Yi and MESGARANI N. Conv-tasnet: Surpassing ideal time–frequency magnitude masking for speech separation[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2019, 27(8): 1256–1266. doi: [10.1109/TASLP.2019.2915167](https://doi.org/10.1109/TASLP.2019.2915167).
- [43] STOLLER D, EWERT S, and DIXON S. Wave-U-Net: A multi-scale neural network for end-to-end audio source separation [C]. The 19th International Society for Music Information Retrieval Conference, Paris, France, 2018: 334–340.
- [44] DÉFOSSEZ A, USUNIER N, BOTTOU L, *et al.* Demucs: Deep extractor for music sources with extra unlabeled data remixed[J]. *arXiv preprint arXiv:1909.01174*, 2019.
- [45] HA U, ASSANA S, and ADIB F. Contactless seismocardiography via deep learning radars [C]. The 26th Annual International Conference on Mobile Computing and Networking, London, United Kingdom, 2020: 62. doi: [10.1145/3372224.3419982](https://doi.org/10.1145/3372224.3419982).
- [46] PARLATO S, CENTRACCHIO J, CINOTTI E, *et al.* A Forcecardiography dataset with simultaneous SCG, Heart Sounds, ECG, and Respiratory signals[J]. *Scientific Data*, 2025, 12(1): 1370. doi: [10.1038/s41597-025-05694-2](https://doi.org/10.1038/s41597-025-05694-2).
- [47] CHEN Jiayu, SONG Yingjian, ZHANG Yida, *et al.* SelfDenoiser: Self-supervised seismic signal denoiser for continuous and contactless cardiac monitoring[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2025, 9(4): 165. doi: [10.1145/3770701](https://doi.org/10.1145/3770701).
- [48] DROITCOUR A D, BORIC-LUBECKE O, LUBECKE V M, *et al.* Range correlation and I/Q performance benefits in single-chip silicon Doppler radars for noncontact cardiopulmonary monitoring[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2004, 52(3): 838–848. doi: [10.1109/TMTT.2004.823552](https://doi.org/10.1109/TMTT.2004.823552).

作者简介

丁凌娜, 硕士, 主要研究方向为无线感知。

张宾宾, 博士, 主要研究方向为无线感知。

王健阳, 博士, 主要研究方向为无线感知。

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。

(责任编辑: 于青)