

DOI: 10.19650/j.cnki.cjsi.J2615154

基于深度投影迁移与超维计算的雷达心电重建

陈 翰, 杨凯怡, 张士杰, 沈铭川, 秦江帆
(东南大学仪器科学与工程学院 南京 210096)

摘 要:毫米波雷达可实现非接触式心跳监测,但从中准确重建心电波形仍是挑战。针对深度学习重建方法参数量大、计算成本高、难以在边缘设备部署,而单纯超维计算(HDC)方法表征能力有限、重建精度不足的问题,提出一种教师-学生超维学习框架(TS-HDL),在保持低推理成本的同时实现高精度心电波形重建。首先对雷达 I/Q 信号预处理获得胸腔位移信号,经自适应呼吸抑制扣除呼吸干扰后,采用最大重叠离散小波变换提取心跳主要能量所在分量作为模型输入。教师网络以轻量化一维卷积神经网络(CNN)学习雷达-心电图非线性映射,生成任务导向的高维投影矩阵;学生网络基于 HDC 利用该矩阵将输入编码为二值超向量,通过联想记忆和 Hebbian 更新实现 ECG 逐点预测与在线个性化微调。实验表明,所提方法在 8/2 划分下平均皮尔逊相关系数(PCC)达 0.807,归一化均方根误差(NRMSE)为 0.082;心脏事件计时中,R 波中位绝对误差为 5 ms,Q、S、T 波中位误差分别为 35、22 和 10 ms。留一受试者交叉验证中,NRMSE 稳定在 0.08~0.11,PCC 均高于 0.6。推理阶段学生模型可更新参数量仅 0.02×10^6 ,单帧推理延迟 2.64 ms,较卷积神经网络-长短期记忆网络(CNN-LSTM)基线可更新参数量减少约 36 倍,推理速度提升约 3 倍。TS-HDL 框架将深度学习的强表征能力与超维计算的轻量推理优势相结合,在保证高重建精度的同时大幅降低计算开销,支持在线个性化更新,为非接触式心电监测的边缘端部署提供了可行方案。

关键词:毫米波雷达;心电重建;深度投影迁移;超维计算;轻量化模型

中图分类号: TH89 文献标识码: A 国家标准学科分类代码: 510.40

Radar ECG reconstruction with deep projection transfer and hyperdimensional computing

Chen Han, Yang Kaiyi, Zhang Shijie, Shen Mingchuan, Qin Jiangfan

(School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China)

Abstract: Millimeter-wave radar enables non-contact heartbeat monitoring, yet accurately reconstructing electrocardiogram waveforms from radar signals remains a challenge. To address the issues of large parameter sizes and high computational costs in deep learning-based reconstruction methods, which hinder edge deployment, and the limited representation capacity and insufficient accuracy of pure hyperdimensional computing (HDC) approaches, this paper proposes a teacher-student hyperdimensional learning framework (TS-HDL) that achieves high-precision ECG waveform reconstruction while maintaining low inference costs. First, raw radar I/Q signals are preprocessed to obtain chest displacement signals. After adaptive respiration suppression to remove respiratory interference, maximal overlap discrete wavelet transform is employed to extract components containing the main heartbeat energy as model inputs. The teacher network, a lightweight 1D convolutional neural network (CNN), learns the nonlinear mapping between radar signals and ECG to generate a task-oriented high-dimensional projection matrix. The student network, based on HDC, encodes inputs into binary hypervectors using this matrix and performs pointwise electrocardiogram prediction and online personalized fine-tuning via associative memory and Hebbian updates. Experiments on a public dataset demonstrate that under an 80/20 split, the proposed method achieves an average Pearson correlation coefficient (PCC) of 0.807 and a normalized root mean square error (NRMSE) of 0.082. For cardiac event timing, the median absolute errors for R, Q, S, and T waves are 5, 35, 22 ms, and 10 ms, respectively. In leave-one-subject-out cross-validation, NRMSE remains stable between 0.08 and 0.11, with PCC consistently above 0.6. During inference, the student model has only 0.02×10^6 parameters and a per-frame latency of 2.64 ms, reducing the parameter count by approximately 36 times and

increasing inference speed by about 3 times compared with a convolutional neural network and long short-term memory (CNN-LSTM) baseline. By combining the strong representation capability of deep learning with the lightweight inference advantage of HDC, TS-HDL significantly reduces computational overhead while ensuring high reconstruction accuracy and supports online personalized updates, offering a feasible solution for edge deployment of non-contact ECG monitoring.

Keywords: millimeter-wave radar; ECG reconstruction; deep projection transfer; hyperdimensional computing; lightweight model

0 引言

心血管疾病是全球范围内的主要死亡原因,对公共健康和社会经济造成了巨大压力^[1]。心电图(electrocardiogram, ECG)作为心脏诊断的“金标准”,需通过电极贴附皮肤采集信号,但在烧伤患者、新生儿、传染病患者或需要长期监测的慢性病等场景中,电极的使用受到明显限制^[2-3]。因此,发展非接触、无负担且可连续监测的心脏活动感知方式具有重要的临床价值。

雷达因其可穿透衣物、不受光照影响及保护隐私等优势,成为非接触式心脏监测的理想传感手段^[4]。相关研究已从早期的心率和呼吸率估计^[5-6],逐步拓展至更具诊断意义的 ECG 波形重建^[7]。然而,雷达捕获的是胸腔机械位移,ECG 记录的是心电活动,两者间存在复杂的非线性映射,且易受呼吸、姿态及个体差异干扰,使得在资源受限条件下实现准确、稳定的心电重建成为当前的技术瓶颈。

目前主流的雷达-ECG 重建方法多采用深度学习模型,如卷积神经网络^[8](convolutional neural network, CNN)、长短期记忆网络^[9](long short-term memory, LSTM)、时序卷积网络(temporal convolutional network, TCN)等架构,从雷达回波中端到端地学习与心电信号相关的特征映射。Kim 等^[10]采用 CNN-LSTM 混合架构从毫米波雷达数据中重构 ECG 波形,取得了较高精度;Zhang 等^[7]将常微分方程嵌入深度学习框架作为解码器,为 ECG 重建提供形态学先验,在体动干扰下皮尔逊相关系数较基准方法提升 19%;Chen 等^[11]将 Transformer 架构应用于雷达-ECG 重建,皮尔逊相关系数的中位数约为 0.90;Zhao 等^[12]利用 CNN 提取特征、扩散模型作为解码器进行细粒度波形恢复,在正常心律下皮尔逊相关系数达 0.955。这类模型虽然在大数据集上能够获得较好的重建精度,但普遍存在计算量大、参数量多、部署成本高等问题。以 Transformer 为例,模型参数量可达数百万至千万级,难以在可穿戴设备或边缘终端上实时运行^[13]。此外,深度学习模型的个性化微调通常需要大量目标个体的 ECG 数据,而在实际非接触监测场景中,获取长期、高质量个体数据往往不现实。

超维计算(hyperdimensional computing, HDC)是另一种值得关注的计算范式。作为一种受大脑启发的计算框

架,其核心思想是将输入信息映射到高维空间(通常数千维)的超向量中,通过向量的简单算术和逻辑操作完成分类、识别等任务^[14]。HDC 具有计算轻量、内存占用小、功耗低等优势,已被证实适用于多种时序信号处理任务。例如,在肌电信号手势识别中,基于 HDC 的方法在阻变式存储器存内计算架构上实现了 97.96% 的平均分类准确率,能效提升 39 倍^[15],在现场可编程门阵列等边缘硬件上展现出相比深度神经网络高 2-5 个数量级的能效优势^[16]。然而,直接应用 HDC 进行雷达-ECG 重建效果不佳,其主要原因是传统 HDC 采用随机投影编码,表征能力有限,难以捕捉心电信号中精细的时序结构与形态特征。

由上述分析可见,深度学习模型表征能力强但部署难度大, HDC 轻量高效但独立完成高精度重建能力不足,两者形成天然互补。如何将深度学习的强表征能力与 HDC 的轻量推理优势相结合,成为实现可部署、个性化雷达心电重建的重要方向。

本文设计一种教师-学生超维学习框架,教师网络采用轻量级深度学习模型,从雷达信号中学习时序特征并生成高质量的高维投影矩阵;学生网络基于 HDC,利用该投影进行超维编码与联想记忆重建,并通过赫布学习规则实现快速个性化微调。该框架旨在让深度模型负责学习特征映射,让 HDC 模型负责记忆与推理,从而在保持低算力、易部署优势的同时,有效保证心电信号的重建精度。

本文设计了一种教师指导下的 HDC 雷达-ECG 重建方法,实现深度表征向高维记忆的有效迁移;设计轻量级教师网络学习雷达到 ECG 的结构化高维映射;构建基于二值化超向量与联想记忆的学生模型,支持在线个性化更新;实验验证所提方法在显著降低推理成本的同时保持高重建精度。

1 方法

1.1 总体框架

本文提出一种结合深度特征学习与超维计算的双阶段轻量化心电重建框架——教师-学生超维学习框架(teacher-student hyperdimensional learning, TS-HDL)。如图 1 所示,包含雷达信号预处理、心跳特征提取和 ECG 重建 3 个模块。




图1 TS-HDL 框架整体流程

Fig. 1 Overall flowchart of the TS-HDL framework

原始雷达 I/Q 信号首先经过预处理以获得胸腔位移信号,随后通过心跳特征提取模块抑制呼吸、突出心跳,采用最大重叠离散小波变换(maximal overlap discrete wavelet transform, MODWT)提取心跳主要能量所在的第3、4层分量作为模型输入。

ECG 重建模块由教师模型和学生模型构成:教师模型采用轻量化卷积结构学习雷达信号与 ECG 之间的非线性映射,生成高维投影矩阵;学生模型基于 HDC 利用投影矩阵将时序信号编码为超向量,通过联想记忆实现 ECG 逐点预测。训练阶段仅运行教师模型,推理阶段完全依赖学生模型,在保证精度的同时大幅降低计算开销。

1.2 数据预处理与特征提取

毫米波雷达采集的胸腔反射信号同时包含呼吸、心跳与噪声,其中呼吸幅度远大于心跳。若直接使用原始 I/Q 信号,心跳细节易被淹没。

1) 雷达信号预处理

设某距离门处复信号为:

$$Z(t) = I(t) + jQ(t) \quad (1)$$

其瞬时相位为:

$$\theta(t) = \arctan\left(\frac{Q(t)}{I(t)}\right) \quad (2)$$

胸部位移 $d(t)$ 与相位变化满足:

$$d(t) = \frac{\lambda}{4\pi} \Delta\theta(t) \quad (3)$$

式中: λ 为雷达波长; $\theta(t)$ 为解缠后的连续相位。

参考 RSSRNet 方法^[17],预处理流程包括 I/Q 椭圆校正补偿硬件偏差、相位提取与解缠、位移计算、重采样至 200 Hz。得到信号:

$$x(t) = BPF_{0.8 \sim 5 \text{ Hz}} \{d(t)\} \big|_{f_s = 200 \text{ Hz}} \quad (4)$$

2) 心跳特征提取

为进一步突出心跳成分,本文设计了轻量的心跳特征提取模块,包括呼吸估计、自适应呼吸抑制和心跳增强 3 个步骤,逐步去除呼吸影响并强化心跳细节。

(1) 呼吸估计

呼吸信号主要集中在低频段,因此采用低通滤波提取其趋势:

$$r(t) = LPF_{0.5 \text{ Hz}} \{s(t)\} \quad (5)$$

其中, $LPF_{0.5 \text{ Hz}}$ 截止频率 0.5 Hz 的四阶巴特沃斯低通滤波器。

(2) 自适应呼吸抑制

通过投影系数估计呼吸分量:

$$\alpha = \frac{\langle s(t), r(t) \rangle}{\langle r(t), r(t) + \varepsilon \rangle} \quad (6)$$

式中: $\langle \cdot, \cdot \rangle$ 表示内积; $\varepsilon = 10^{-8}$ 防除 0。

抑制后的信号为:

$$c(t) = s(t) - \alpha \cdot r(t) \quad (7)$$

该方法能够根据不同信号段的呼吸幅度自适应调整抑制程度。

(3) 心跳增强

对抑制后的信号进行 0.8~2.5 Hz 带通滤波:

$$h(t) = BPF_{0.8 \sim 2.5 \text{ Hz}} \{c(t)\} \quad (8)$$

该频段覆盖典型心率范围 (48~150 bpm)。

(4) MODWT

为了进一步提取心跳细节,采用 MODWT 对信号 $h(t)$ 进行 5 层分解,通过多分辨率重构得到各尺度分量 $M_j(t)$ 。实际观测发现第 3、4 层含有心跳主要能量且噪声较低,因此选择 $X(t)$ 作为模型输入。

$$X(t) = \{M_3(t), M_4(t)\} \quad (9)$$

(5) 数据标准化

采用滑动窗口构建训练样本,模型输入窗口长度 $L=256$,步长为 1。每个样本包含两路小波特征,共 512 个输入点,窗口中心 ECG 值为预测目标。

为减小不同受试者之间的幅值差异,对输入特征与目标 ECG 进行 Z-score 标准化:

$$\bar{X}(t) = \frac{X(t) - \mu_x}{\sigma_x + \varepsilon}, \bar{Y}(t) = \frac{Y(t) - \mu_y}{\sigma_y + \varepsilon} \quad (10)$$

式中: μ_x, σ_x 为训练集各通道均值与标准差; μ_y, σ_y 为 ECG 均值和标准差; $\varepsilon = 10^{-8}$ 避免除 0 问题; $\bar{X}$ 模型输入; $\bar{Y}$ 作为监督信号。

1.3 教师-学生超维学习框架

本文构建教师-学生协同学习结构,如图 2 所示,包括教师模型与学生模型两个部分。教师模型用于学习雷达信号的高维表示并生成投影矩阵;学生模型在该高维空间中进行轻量化 ECG 重建。




图 2 TS-HDL 框架结构

Fig. 2 Architecture of the TS-HDL framework

1) 教师模型:卷积高维投影网络

教师模型采用轻量化 1D CNN 结构,从雷达信号中提取与心电活动相关的时序特征,并学习高质量高维投影矩阵 $W \in \mathbf{R}^{D \times 512}$,为学生模型提供先验知识。网络结构如图 2 所示,具体参数如表 1 所示。

教师模型包含卷积特征提取模块,高维投影模块和注意力门控与动态偏置 3 部分。

(1) 卷积特征提取模块

输入维度为 2×256 ,经 3 层卷积逐步提取局部时序特征。第 1 层卷积提取底层细节;第 2 层卷积压缩长度;第 3 层卷积进一步抽象。随后堆叠两层扩张卷积,扩大感受野捕获跨周期依赖。自适应平均池化将特征压缩为 128 维向量。

(2) 高维投影模块

高维投影模块的核心是将 128 维特征映射至高维超空间 ($D=10\,000$),从而获得具有丰富判别能力的超向量表示。这一设计基于超维计算的基本理论:在高维空间中,随机向量几乎相互正交,维度过低会丧失正交性优势,维度过高则会引入不必要的计算负担^[18]。

通过两层全连接将 128 维特征投影至 D 维超空间。FC1 将特征扩展至 512 维:

$$z = \text{GELU}(W_{fc1}f + b_{fc1}) \quad (11)$$

FC2 生成 D 维表示:

$$h = W_{fc2}z \quad (12)$$

式中: $W_{fc2} \in \mathbf{R}^{D \times 512}$ 即为待传递的投影矩阵 W 。为增强训练的稳定性,对 W_{fc2} 权重归一化。

表 1 教师模型结构与参数

Table 1 Architecture and parameters of the teacher model

层名称	输入尺寸	输出尺寸	参数量
卷积+ReLU 激活 (Conv1+ReLU)	2×256	32×256	352
卷积+ReLU 激活 (Conv2+ReLU)	32×128	64×128	6 208
卷积+ReLU 激活 (Conv3+ReLU)	64×64	128×64	24 704
TCN	128×64	128×64	147 584
TCN	128×64	128×64	147 584
自适应平均池化 (AdaptivePool)	128×64	128×1	0
全连接层 (FC1)	128	512	65 536
高斯误差线性单元激活 (GELU)	512	512	0
全连接层 (FC2)	512	10 000	5 120 000
注意力多层感知机 (Attention MLP)	10 000	10 000	10 010 000
回归头 (Regressor)	10 000	1	10 001
动态偏置 (Offset)	10 000	1	10 001
总计			~ 15.5×10 ⁶

(3) 注意力门控与动态偏置

为突出与心电形态高度相关的维度,引入注意力门控机制:

$$\mathbf{g} = \sigma(\text{MLP}(\mathbf{h})) \tag{13}$$

$$\mathbf{h}' = \mathbf{h} \odot (1 + \mathbf{g}) \tag{14}$$

式中:MLP 为两层全连接 ($D \rightarrow D/32 \rightarrow D$); σ 为 Sigmoid 函数。门控因子 $\mathbf{g} \in (0,1)^D$ 自适应调节各维度的贡献。

针对基线漂移问题设计动态偏置:

$$\hat{\mathbf{y}}_{\text{main}} = \mathbf{w}_{\text{reg}}^T \mathbf{h}' \tag{15}$$

$$\Delta = \mathbf{w}_{\text{offset}}^T \mathbf{h}' \tag{16}$$

$$\hat{\mathbf{y}} = \hat{\mathbf{y}}_{\text{main}} + \Delta \tag{17}$$

式中: $\mathbf{w}_{\text{reg}}, \mathbf{w}_{\text{offset}} \in \mathbf{R}^D$ 可学习参数; Δ 随输入变化,可自适应补偿输出偏移。

为防止投影矩阵列向量冗余,增强高维空间的区分能力,引入正交正则项:

$$L_{\text{orth}} = \| \mathbf{W}_{\text{FC2}}^T \mathbf{W}_{\text{FC2}} - \mathbf{I} \|_{\text{F}}^2 \tag{18}$$

教师网络总损失:

$$L = L_{\text{MSE}}(\hat{\mathbf{y}}, \mathbf{y}) + \alpha L_{\text{orth}} + \beta L_{\text{offset}} \tag{19}$$

式中: L_{MSE} 为均方误差 (MSE); $L_{\text{offset}} = \frac{1}{N} \sum \Delta^2$ 约束偏置幅度 (N 为批次大小); $\alpha = 0.01; \beta = 0.1$ 为平衡系数。

2) 学生模型:超维计算

学生模型基于超维计算构建,利用教师提供的投影矩阵 $\mathbf{W}$ 将输入编码为超向量,通过联想记忆实现高效 ECG 重建与在线个性化微调。其结构如图 2 所示。

(1) 超向量编码

输入样本 $\tilde{\mathbf{X}} \in \mathbf{R}^{2 \times 256}$ 展平为 512 维向量 $\mathbf{V} \in \mathbf{R}^{512}$,经投影矩阵映射至高维空间:

$$\mathbf{e} = \mathbf{WV} \in \mathbf{R}^D \tag{20}$$

采用正弦嵌入增强非线性表达能力:

$$\mathbf{h} = \cos(\mathbf{e} + \mathbf{b}) \odot \sin(\mathbf{e}) \tag{21}$$

式中: $\mathbf{b} \in \mathbf{R}^D$ 为随机初始化后固定的偏置项。通过硬量化获得二进制超向量:

$$\mathbf{h}' = \text{sign}(\mathbf{h}) \in \{-1, +1\}^D \tag{22}$$

二值表示提高了模型在噪声环境下的鲁棒性。

(2) 联想记忆与推理

建立联想记忆向量 $\mathbf{M} \in \mathbf{R}^D$,用于刻画高维表示与 ECG 信号之间的映射关系。本文采用基于误差驱动的 Hebbian 规则进行增量更新:

$$\mathbf{M} \leftarrow \mathbf{M} + \eta \cdot (\mathbf{y} - \hat{\mathbf{y}}) \cdot \mathbf{h}' \tag{23}$$

式中: $\mathbf{y}$ 为 ECG 目标值; $\hat{\mathbf{y}}$ 为预测值; $\eta = 0.01$ 为学习率。

为说明该更新规则的理论合理性,定义预测模型为:

$$\hat{\mathbf{y}} = \mathbf{h}'_q \cdot \mathbf{M} \tag{24}$$

并考虑逐点均方误差损失函数:

$$L = \frac{1}{2} (\mathbf{y} - \hat{\mathbf{y}})^2 \tag{25}$$

对 $\mathbf{M}$ 求梯度得:

$$\frac{\partial L}{\partial \mathbf{M}} = -(\mathbf{y} - \hat{\mathbf{y}}) \mathbf{h}'_q \tag{26}$$

据此进行梯度下降更新可得到式(23)。因此,所采用的 Hebbian 更新在形式上等价于对均方误差进行随机梯度下降,其优化目标为最小化预测误差的平方和,从而为模型学习过程提供了明确的优化解释。

在高维空间中,由于超向量近似正交,输入特征间相关性较低,使得该优化问题可近似视为凸优化问题。在学习率充分小且数据分布稳定的条件下,该更新过程可收敛至最小二乘解^[19]。实验结果表明,仅需少量样本即可实现显著性能提升,体现了该方法良好的收敛性与样本效率。

由于心电信号天然具有时序结构,为模拟真实在线监测场景并确保实验的可复现性,微调阶段采用原始时间顺序依次更新样本。

在推理阶段,输入信号首先编码为查询超向量 $\mathbf{h}'_q$, 其预测值计算如下:

$$\hat{y} = \mathbf{h}'_q \cdot \mathbf{M} = \sum_{i=1}^D \mathbf{h}'_q[i] \cdot \mathbf{M}[i] \quad (27)$$

逐点预测值通过滑动窗口拼接恢复连续 ECG 波形。该过程无需反向传播,计算开销低,适用于资源受限设备上的实时推理与在线个性化更新。

3) 教师-学生知识迁移机制

本框架的核心创新在于将深度神经网络学习到的连续表征嵌入超维空间,使学生模型获得结构化的高维基底。投影矩阵由教师网络通过监督学习获得,本质是一种任务导向的线性变换。该变换不仅完成维度扩展,更将雷达信号中与 ECG 相关的判别信息以特定的几何结构组织于高维空间——即相似心电形态的样本相互接近,不同形态的样本彼此远离。相比传统 HDC 的随机投影,这种数据驱动的结构化映射能显著提升高维表示的有效性并降低学生模型的学习难度。

具体流程如下:

(1) 教师模型学习从雷达信号到高维向量的连续投影;

(2) 投影矩阵 $\mathbf{W}$ 复制给学生模型,实现高维表征对齐;

(3) 学生模型在高维空间中通过 Hebbian 更新学习非线性映射;

(4) 联想记忆结构提供可解释的快速推理能力。

上述流程的完整训练与推理步骤如算法 1 所示。

算法 1 教师-学生超维学习框架 (TS-HDL) 训练与推理流程

输入: 训练集雷达小波特征 $\{\mathbf{x}_i\}_{i=1}^N, \mathbf{x}_i \in \mathbf{R}^{512}$; 参考 ECG 标签 $\{y_i\}$; 超维空间维度 D ; 学习率 η ; 训练轮次 E ; 微调样本数 M

输出: 重建 ECG 波形 $\{\hat{y}_k\}$

阶段 1: 教师模型离线训练

```

1  FOR  $e=1$  TO  $E$  (训练轮次循环)
2  FOR 每个训练样本  $(\mathbf{x}_i, y_i)$ 
3   $\mathbf{f}_i \leftarrow \text{AdaptiveAvgPool}(\text{TCN}(\text{Conv}(\mathbf{x}_i))) \in \mathbf{R}^{128}$  // 卷积特征提取
4   $\mathbf{h}_i \leftarrow \text{GELU}(\mathbf{W}_f \mathbf{f}_i + \mathbf{b}_1) \in \mathbf{R}^{512}$  // 高维投影中间层

```

```

5   $\mathbf{z}_i \leftarrow \mathbf{W}_2 \mathbf{h}_i \in \mathbf{R}^D$  // 高维投影输出 (投影矩阵  $\mathbf{W}_2$ )
6   $\mathbf{g}_i \leftarrow \sigma(\text{MLP}(\mathbf{z}_i)), \bar{\mathbf{z}}_i \leftarrow \mathbf{z}_i \odot (1 + \mathbf{g}_i)$  // 注意力门控
7   $\hat{y}_i^{\text{main}} \leftarrow \mathbf{w}_r^T \bar{\mathbf{z}}_i$  // 主预测:
8   $\Delta_i \leftarrow \mathbf{w}_{\text{offset}}^T \bar{\mathbf{z}}_i$  // 动态偏置
9   $\hat{y}_i \leftarrow \hat{y}_i^{\text{main}} + \Delta_i$ 
10  $L \leftarrow L_{\text{MSE}}(\hat{y}_i, y_i) + \alpha L_{\text{orth}} + \beta L_{\text{offset}}$  // 总损失 (式 (19))
11 反向传播, 更新教师网络全部参数
12 END FOR
13 END FOR
14 教师模型收敛, 提取投影矩阵  $\mathbf{W} \leftarrow \mathbf{W}_2 \in \mathbf{R}^{D \times 512}$ 
    阶段 2: 知识迁移
15 将  $\mathbf{W}$  从教师复制至学生模型并固定 (推理阶段不再更新)
16 初始化联想记忆向量  $\mathbf{m} \leftarrow \mathbf{0} \in \mathbf{R}^D$ 
    阶段 3: 学生模型在线微调 (使用目标受试者前  $M$  个样本, 时间顺序)
17 FOR 微调样本  $(\mathbf{x}_j, y_j), j = 1, \dots, M$ 
18  $\mathbf{v}_j \leftarrow \text{sign}(\cos(\mathbf{W}\mathbf{x}_j + \mathbf{b}) \odot \sin(\mathbf{W}\mathbf{x}_j)) \in \{-1, +1\}^D$  // 超向量编码
19  $\hat{y}_j \leftarrow \mathbf{m}^T \mathbf{v}_j$  // 当前预测
20  $\mathbf{m} \leftarrow \mathbf{m} + \eta(y_j - \hat{y}_j)\mathbf{v}_j$  // Hebbian 更新 (等价于随机梯度下降)
21 END FOR
    阶段 4: 学生模型推理
22 FOR 每个测试样本  $\mathbf{x}_k$ 
23  $\mathbf{v}_k \leftarrow \text{sign}(\cos(\mathbf{W}\mathbf{x}_k + \mathbf{b}) \odot \sin(\mathbf{W}\mathbf{x}_k))$  // 超向量编码
24  $\hat{y}_k \leftarrow \mathbf{m}^T \mathbf{v}_k$  // 逐点预测
25 END FOR
26 通过滑动窗口拼接  $\{\hat{y}_k\}$ , 恢复连续 ECG 波形
27 RETURN 重建 ECG 波形  $\{\hat{y}_k\}$ 

```

这种设计实现了从深度特征到高维符号表示,再到在线记忆更新的跨范式知识迁移,使模型兼具高重建精度与极低的推理成本,同时具备良好的个体适应性。

2 实验验证

2.1 数据集与实验设置

实验采用 Schellenberger 等^[20]公开的 24 GHz 毫米波雷达-心电图同步数据集。从中选取 6 名受试者的静息状态数据,按 1.2 节方法预处理后,将每位受试者的连续信号以数据分割长度 1 024 (对应 5.12 s) 划分为若干不重叠的数据段,以方便后续滑动窗口采样。每位受试者共包含约 60 个数据段,总时长约 307 s。

为全面评估模型性能,采用如下两种划分策略。

1) 8/2 划分,每位受试者数据按时间顺序前 80% 训

练、后 20% 测试,用于基础性能验证。

2) 留一受试者交叉验证 (leave-one-subject-out cross-validation, LOSO), 每次将 1 名受试者全部数据作为测试集, 其余 5 名数据作为训练集, 用于评估跨个体泛化能力。对目标受试者, 仅用其时间顺序前 10% 数据对学生模型进行在线微调, 剩余 90% 数据评估微调后性能。该设置模拟实际应用中模型逐步获取个体数据并进行自适应更新的过程。

教师网络采用 Adam 优化器, 学习率 0.000 1, 批量大小 32, 训练轮次 100, 微调时按样本时间顺序依次更新记忆向量, 迭代 50 次。

实验在 1 台搭载 AMD Ryzen Threadripper 3970X 处理器、256 GB 内存及 NVIDIA RTX 4090 显卡的台式计算机上进行, 所有模型在 PyTorch 框架下实现。

为展示训练效率, 以受试者 1 为例, 在上述设备上, 教师模型每轮训练平均耗时约 4.9 s, 总训练时间约 8 min。训练损失曲线如图 3 所示, 整体收敛过程可分为 3 个阶段: 第 1~30 轮为快速下降阶段, 总损失由 0.028 0 迅速降至 0.017 1; 第 30~80 轮为平稳优化阶段, 损失持续缓慢下降; 第 80 轮后进入收敛平台期, 总损失稳定于 0.013 5, 100 轮总体降幅达 51.8%。




图 3 教师模型训练损失曲线(受试者 1)

Fig. 3 Training loss curves of the teacher model (subject 1)

2.2 评价指标

从波形形态、事件计时和计算效率 3 个维度评估模型性能。

1) 波形级指标

皮尔逊相关系数 (Pearson correlation coefficient, PCC): 衡量重构信号与真实信号的线性相关性。

$$PCC = \frac{(\mathbf{y}' - \bar{\mathbf{y}}')^T (\mathbf{y} - \bar{\mathbf{y}})}{\|\mathbf{y}' - \bar{\mathbf{y}}'\|_2 \|\mathbf{y} - \bar{\mathbf{y}}\|_2} \quad (28)$$

式中: $\mathbf{y}$ 重构信号; $\mathbf{y}'$ 真实信号。欧氏范数用 $\|\cdot\|_2$, 均值函数用 $\bar{\cdot}$ 。

归一化均方根误差 (normalized root mean square error, NRMSE): 衡量重构信号与真实信号的幅值偏差。

$$NRMSE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N |y_i - y'_i|^2}}{y_{\max} - y_{\min}} \quad (29)$$

式中: N 表示样本量; $y_{\max}$ 和 $y_{\min}$ 表示信号的最大值和最小值。式(29)归一化的使用保证了 NRMSE 与数据的规模无关。

2) 心脏事件级指标

心电事件定位误差: 采用 NeuroKit2^[21] 检测 P、Q、R、S、T 波位置, 计算平均绝对误差 (average absolute error, AAE) 和中位绝对误差 (median absolute error, MedAE)。为消除个体间心率差异影响, 将时间误差除以对应心跳周期进行归一化。

3) 执行效率指标

模型参数量为模型的总可训练参数个数。

浮点运算数 (floating point operations, FLOPs) 为模型进行一次前向推理所需的浮点运算次数。

单帧推理延迟是以模型输入窗口长度 256 (对应 1.28 s) 为输入, 统计模型前向推理时间 (预热 20 次后取 200 次平均值)。

峰值显存占用为 PyTorch 进程最大驻留内存。

2.3 实验结果

1) 信号重建准确性

(1) 波形形态准确性

图 4(a) 所示为某受试者真实 ECG 与重建 ECG 的波形对比, 可以看出, 在 RMSE 较低、相关性较高的情况下, 重构的 ECG 与真实 ECG 基本一致。

图 4(b)、(c) 所示为全部受试者的 NRMSE 与 PCC 分布。可以看出, NRMSE 中位数约 0.086, 多数样本集中在 0.06~0.10; PCC 中位数约 0.78, 大部分样本分布在 0.75~0.88。

图 4(d)、(e) 所示为累积分布函数, 可见超过 90% 样本的 NRMSE < 0.10, 约 60% 样本的 PCC > 0.80, 表明模型在跨个体条件下仍能保持可靠的波形一致性。

(2) 心脏事件计时准确性

ECG 波形中包含多个具有生理意义的关键事件点: P 波代表心房除极, QRS 复合波 (包括 Q、R、S 波) 代表心室除极, T 波代表心室复极。这些事件点的准确识别是评估心律和心脏电活动的基础。图 5 所示为一个典型心跳周期中 P、Q、S、T 波的位置关系。本文以这些事件点为基准, 评估重建 ECG 对心脏时序的捕捉能力。

图 6(a) 所示为 Q、R、S、T 4 类心脏事件的归一化计时误差分布, 每个簇代表其中一个分量波峰及其对应的统计定时精度。各事件归一化中值误差分别为: Q 波 5.2%、R 波 1.0%、S 波 3.9%、T 波 1.9%。其中 R 波误差最小且分布最为紧凑, 说明模型对 R 峰这一关键心搏标志点的识别最为稳定。Q 波与 S 波误差略高, 主要源




图 4 波形形态重建性能评估

Fig. 4 Performance evaluation of waveform morphology reconstruction




图 5 典型心跳周期中心电事件点位置示意图

Fig. 5 Diagram of cardiac event points in a typical heartbeat cycle

于跨受试者幅度变化差异,但仍处于可接受范围。T 波误差介于二者之间,表明模型对心室复极阶段的时序把握具有较好可靠性。

图 6(b) 所示为各事件绝对时间误差的累积分布函数。绝对时间误差中位数分别为 Q 波 35 ms、R 波 5 ms、S 波 22 ms、T 波 10 ms;90 百分位误差分别为 Q 波 70 ms、R 波 15 ms、S 波 70 ms、T 波 28 ms。结果均表明,模型在 R 波定位上精度最高,对 Q、S、T 波也能实现较准确的时

间测量,能够满足非接触式监测对事件级时间精度的要求。

2) 维度敏感性分析

为验证超空间维度 D 的选择对重建精度与计算效率的影响,本文选取 $D=1\,000, 5\,000, 10\,000, 20\,000$ 这 4 种维度,在相同的训练策略下训练 TS-HDL 模型,在测试集上评估重建性能 (PCC、NRMSE) 及学生模型的推理延迟。结果如表 2 所示。

表 2 不同维度下 TS-HDL 性能对比

Table 2 Performance comparison of TS-HDL under different hypervector dimensions				
维度 D	PCC	NRMSE	推理延迟/ ms	推理存储 参数量/ $\times 10^6$
1 000	0. 629	0. 111	0. 28	0. 514
5 000	0. 728	0. 097	1. 32	2. 570
10 000	0. 807	0. 082	2. 64	5. 140
20 000	0. 811	0. 081	5. 28	10. 280




图 6 心脏事件计时准确性评估

Fig. 6 Evaluation of cardiac event timing accuracy

当 D 从 1 000 增至 10 000 时, PCC 显著提升, NRMSE 明显下降, 表明更高维度提供了更强的表示能力。

当 D 从 10 000 增至 20 000 时, 性能增益趋缓, 但推理延迟翻倍, 参数量亦成倍增长。

综合考虑精度与效率, $D=10\,000$ 在性能与计算开销之间取得了最佳平衡, 故作为本文的最终选择。

3) 主对比实验与消融实验

为评估 TS-HDL 框架在雷达心电重建任务中的整体性能及各组成模块的有效性, 本文在 8/2 训练测试划分设置下开展主对比实验与消融实验。对比方法分为两类: 第 1 类为与本文任务直接相关的雷达-ECG 重建方法, 包括 CNN+LSTM^[22] 和文献[11] 方法; 第 2 类为经典通用深度学习架构, 包括 U-Net 1D^[23]、TCN^[24] 和 ResNet-1D^[25], 分别代表编码器-解码器、膨胀时序卷积和残差卷积结构。由于部分任务相关方法未公开完整源代码或依赖特定雷达体制与前处理流程, 本文依据原文网络结构和实验描述进行复现或骨干网络适配复现。

为保证实验比较的公平性, 所有方法均采用与本文一致的数据预处理流程、8/2 训练测试划分和评价指标, 并在相同数据条件下进行训练与测试。不同基线方法与

TS-HDL 的性能对比如表 3 所示, TS-HDL 框架内部对照及消融实验结果如表 4 所示。

表 3 不同基线方法与 TS-HDL 性能对比
Table 3 Performance comparison between different baselines and TS-HDL

方法	PCC	NRMSE
CNN+LSTM ^[22]	0.416	0.132
文献[11]	0.562	0.109
ResNet-1D ^[25]	0.349	0.131
TCN ^[24]	0.358	0.128
U-Net 1D ^[23]	0.471	0.124
TS-HDL	0.807	0.082

注: 文献[11] 仅复现骨干网络, 非完整系统

(1) 主对比实验

从表 3 可以看出, CNN+LSTM^[22] 在本文统一实验条件下取得 PCC 为 0.416、NRMSE 为 0.132。该方法通过 CNN 提取局部时序特征, 并利用 LSTM 建模长程依赖, 是雷达心电重建任务中较典型的深度学习基线。然而, 由于其原始实验所用数据集、雷达体制、预处理流程及训练测试划分与本文不同, 复现结果低于原文性能是合理的。在相同数据和预处理条件下, 该方法仍明显低于 TS-HDL, 说明仅依赖常规卷积与循环结构, 难以充分捕捉雷达胸腔位移信号与 ECG 波形之间复杂而精细的非线性映射关系。

文献[11] 是近期雷达-ECG 重建领域的代表性方法, 其完整系统依赖 77 GHz MIMO 雷达、3D 波束成形及空间体素级心跳运动特征提取。由于本文所用 Schellenberger 数据集为 24 GHz 单通道雷达数据, 无法完整复现其空间前处理流程, 因此本文仅对其 CNN-Transformer 编码器与 TCN 解码器骨干网络进行适配, 并采用与本文一致的 MODWT 双通道特征作为输入。实验结果表明, 该骨干网络复现方法取得 PCC 为 0.562、NRMSE 为 0.109, 优于 CNN+LSTM, 说明 Transformer 与 TCN 结构在时序特征建模方面具有一定优势。但其性能仍低于完整 TS-HDL, 表明在缺少任务导向高维投影和联想记忆机制的情况下, 单纯深度骨干网络对雷达-ECG 细粒度映射的恢复能力仍然有限。该结果并不等同于文献[11] 完整系统性能的直接复现, 而是在统一输入条件下对其深度学习骨干网络重建能力的比较。

对于通用深度学习基线, ResNet-1D、TCN 和 U-Net 1D 的 PCC 分别为 0.349、0.358 和 0.471, NRMSE 分别为 0.131、0.128 和 0.124。三者均低于 TS-HDL, 说明常规残差卷积、膨胀卷积或编码器-解码器结构虽然具备一定时序建模能力, 但在未引入面向雷达心电重建任务的

高维投影空间和联想记忆机制时,难以充分恢复 ECG 波形的细粒度形态特征。

总体来看,完整 TS-HDL 框架取得最高 PCC(0.807)和最低 NRMSE(0.082),明显优于所有对比基线。与任务相关的 CNN+LSTM 和骨干网络复现方法^[11]相比,TS-HDL 通过教师网络学习任务相关高维投影矩阵,使学生模型能够在更具判别性的超维空间中进行 ECG 重建;与通用深度学习架构相比,TS-HDL 在重建精度和波形一致性方面均表现出更优性能,说明任务导向高维投影与联想记忆机制能够更有效地刻画雷达信号到 ECG 波形之间的复杂非线性映射关系。

(2) 内部对照与消融实验

为进一步分析 TS-HDL 框架中各组成部分的贡献,本文设置了仅学生模型、教师网络直接回归头以及多个模块消融实验,结果如表 4 所示。

表 4 TS-HDL 框架消融实验结果

Table 4 Ablation study results of the TS-HDL framework

方法	PCC	NRMSE
仅学生模型	0.607	0.109
教师网络直接回归头	0.301	0.131
TS-HDL(无注意力)	0.789	0.087
TS-HDL(无偏置)	0.775	0.090
TS-HDL(无正交正则)	0.784	0.088
TS-HDL(无 TCN)	0.794	0.087
TS-HDL	0.807	0.082

仅学生模型表示单独使用 HDC 学生模型,并采用随机投影矩阵进行高维编码。该模型取得 PCC 为 0.607、NRMSE 为 0.109,说明 HDC 记忆向量能够对具有重复性和周期性的心电模式进行高维绑定与统计聚合,因此在未引入教师投影矩阵的情况下仍具有一定重建能力。然而,由于随机投影缺乏任务自适应性,其性能仍明显低于完整 TS-HDL,说明由教师网络迁移得到的任务相关投影矩阵对提升高维编码判别性具有关键作用。

教师网络直接回归头表示仅使用教师网络的回归分支直接预测 ECG 信号。该设置取得 PCC 为 0.301、NRMSE 为 0.131。该结果并不表示教师网络的特征学习能力不足,而是由于本文教师网络的主要作用并非作为最终部署的直接回归模型,而是学习适合 HDC 学生模型进行高维编码的投影空间。其直接回归头主要作为训练阶段的辅助约束存在,因此单独作为最终回归器时性能有限。

在完整 TS-HDL 框架基础上,本文进一步逐一移除关键模块进行消融分析。移除注意力模块后,PCC 由

0.807 下降至 0.789,NRMSE 升高至 0.087,说明注意力机制有助于突出与心电重建相关的关键时序特征。移除偏置项后,PCC 下降至 0.775,NRMSE 升高至 0.090,表明偏置项能够提升高维投影空间的表达灵活性。移除正交正则后,PCC 为 0.784,NRMSE 为 0.088,说明正交约束有助于降低高维投影特征之间的冗余,提高编码稳定性。移除 TCN 模块后,PCC 为 0.794,NRMSE 为 0.087,说明 TCN 模块对局部时序依赖建模具有一定贡献。

上述消融结果表明,教师投影矩阵是性能提升的主要来源,注意力、动态偏置、正交正则和 TCN 模块进一步改善了高维表示的稳定性与判别性。

4) 跨个体泛化性能

采用留一受试者交叉验证(LOSO)评估模型在未见个体上的泛化能力,结果如图 7 所示。




图 7 跨个体泛化性能评估

Fig. 7 Evaluation of cross-subject generalization performance

在心电事件计时方面,各受试者的 Q、R、S、T 波位置误差总体处于几十毫秒量级,R 波误差最小,S 波误差相对较大,但整体保持在可接受范围,说明模型能够较准确地恢复 ECG 关键结构特征。

在波形重建指标方面,各受试者 NRMSE 稳定在 0.08~0.11,PCC 均保持在 0.6 以上,部分受试者可达 0.8 以上,表明预测 ECG 与真实信号具有较高相关性。

综合结果验证了 TS-HDL 框架在跨个体场景下具有良好的泛化能力。

5) 可部署性分析

为评估各方法在资源受限场景下的实际部署潜力,表 5 为不同方法的计算复杂度与推理效率对比。与前述精度实验 (AMD Ryzen Threadripper 3970X + NVIDIA RTX 4090) 不同,所有效率指标均在边缘计算平台 (Intel Core i5-1135G7 + NVIDIA GeForce MX450) 上测量,以真实反映方法在资源受限设备上的部署性能;参数量与浮点计算量为理论值,与测试硬件无关。

表 5 不同方法性能与计算复杂度对比

Table 5 Comparison of performance and computational complexity of different methods

方法	PCC	可更新 参数量/ ×10 ⁶	推理存 储参数 量/×10 ⁶	FLOPs	推理延 迟/ms	显存占 用/MB
CNN+LSTM (复现)	0.416	0.728	0.728	0.037	8.24	334.4
仅学生模型	0.607	0.02	0.02	0.010	2.64	313.9
教师网络直 接回归头	0.301	11.585	11.585	0.020	4.46	314.0
TS-HDL	0.807	0.02	5.14	0.010	2.64	313.9

TS-HDL 框架在推理阶段不再调用教师网络,仅使用由固定投影矩阵和联想记忆向量构成的学生模型完成超维编码与 ECG 预测。其中,固定投影矩阵由教师模型离线训练后迁移得到,参数量约为 5.12×10^6 ,推理阶段参与前向编码但不进行在线更新;联想记忆向量参数量约为 0.02×10^6 ,是在线个性化阶段唯一需要更新的部分。因此,TS-HDL 的总推理存储参数约为 5.14×10^6 ,其中在线可更新参数仅约 0.02×10^6 。需要说明的是,若学生模型中的随机投影仅由固定随机种子生成而不作为模型文件显式存储,则其推理存储参数量仅统计联想记忆向量部分 (约 0.02×10^6)。

与 CNN+LSTM 基线相比,TS-HDL 在获得更高重建精度的同时,在线可更新参数量减少约 36 倍,推理速度提升约 3 倍,显存占用降低约 6%。结果表明,TS-HDL 框架在保持高重建精度的同时降低了在线更新开销和推理延迟,适合实时生理信号监测及资源受限设备部署。

近年来部分深度学习方法^[7-8,14]采用较复杂的卷积或循环网络结构,通常伴随更高的参数量与计算开销,且由于缺乏公开实现细节,难以在统一平台上进行公平比较。相比之下,本文方法在保证 ECG 重建性能的同时有

效降低了模型复杂度和推理开销,更适合实时和资源受限场景的部署需求。

3 结 论

本文针对非接触式雷达心电重建任务中深度学习模型部署困难、HDC 模型精度不足的问题,提出了一种教师-学生超维学习框架 TS-HDL。该框架通过教师网络学习高质量的高维投影矩阵,将雷达信号映射至超维空间;学生网络基于该空间进行二值超向量编码与联想记忆重建,实现轻量化 ECG 波形预测与在线个性化微调,得出如下结论。

重建精度方面,TS-HDL 在 8/2 划分下取得 PCC 为 0.807、NRMSE 为 0.082,优于仅学生模型 (PCC 为 0.607) 和仅教师模型 (PCC 0.301),与复现的 CNN+LSTM 基线相比提升显著。各消融实验验证了注意力机制、动态偏置、正交正则和 TCN 模块的有效性。

心脏事件计时方面,模型对 R 波定位最为精准 (中位误差 5 ms,90 百分位误差 15 ms),Q、S、T 波中位误差分别为 35、22 和 10 ms,归一化误差均控制在 5.2% 以内,能够满足非接触监测对关键事件时序的基本要求。

泛化能力方面,留一受试者交叉验证中,模型在未见个体上 NRMSE 稳定于 0.08~0.11,PCC 均高于 0.6,部分受试者可达 0.8 以上,表明框架具有良好的跨个体适应性。

计算效率方面,推理阶段学生模型可更新参数量仅 0.02×10^6 ,单帧推理延迟 2.64 ms,较 CNN+LSTM 基线可更新参数量减少约 36 倍,速度提升约 3 倍,显存占用降低 6%,充分验证了其在资源受限设备上的部署潜力。

本文将深度特征学习与超维计算有机结合,为雷达-心电重建提供了一种兼顾精度与效率的新范式。后续工作可进一步探索模型在运动伪影干扰下的鲁棒性,扩大受试者规模,并在更多样化的人群 (如不同年龄、健康状况) 中验证其泛化能力,以及基于 FPGA 等硬件的实时系统实现。

参考文献

[1] Roth G A, Mensah G A, Johnson C O, et al. Global burden of cardiovascular diseases and risk factors, 1990—2019: Update from the GBD 2019 study [J]. Journal of the American College of Cardiology, 2020, 76(25): 2982-3021.

[2] Ishabakaki P, Hameed H, Farooq M, et al. Non-invasive vital signs sensing: Advances, challenges, and future directions in radio frequency based techniques[J]. IEEE Open Journal of Antennas and Propagation, 2026,

- 7(1): 89-115.
- [3] Bhingikar S K, Sharma R R, Pachori R B. Radar-based non-contact heart rate monitoring: A comprehensive review[J]. *Digital Signal Processing*, 2026, 168(Part D): 105630.
- [4] Li C Z, Peng Z Y, Huang T, et al. A review on recent progress of portable short-range noncontact microwave radar systems[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2017, 65(5): 1692-1706.
- [5] 潘志刚, 费叶奇, 郭书雅, 等. 基于 EWT-VMD 的毫米波雷达生命体征检测[J]. *仪器仪表学报*, 2025, 46(12): 300-310.
- Pan Zhigang, Fei Yeqi, Guo Shuya, et al. Millimeter-wave radar vital sign detection based on EWT-VMD[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(12): 300-310.
- [6] 蒲巧林, 张杰龙, 周牧, 等. 面向通感一体化的逐次变分模态分解生命信号频率检测算法[J]. *仪器仪表学报*, 2025, 46(11): 62-73.
- Pu Qiaolin, Zhang Jielong, Zhou Mu, et al. Successive variational mode decomposition for life signal frequency detection in integrated sensing and communication[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(11): 62-73.
- [7] Zhang Y Y, Guan R W, Li L X, et al. RadarODE: An ODE-embedded deep learning model for contactless ECG reconstruction from millimeter-wave radar[J]. *IEEE Transactions on Mobile Computing*, 2025, 24(10): 9806-9821.
- [8] 段伟, 黄廷磊, 刘杰, 等. 基于注意力机制的毫米波雷达 ECG 信号反演算法研究[J]. *广西科学*, 2024, 31(5): 833-841.
- Duan Wei, Huang Tinglei, Liu Jie, et al. Reconstruction of ECG signals from millimeter wave radar based on attention mechanism[J]. *Guangxi Sciences*, 2024, 31(5): 833-841.
- [9] 张金垒, 庞景月, 卢晓伟, 等. Feen-LSTM: 一种优化的多遥测参数在线无监督异常检测方法[J]. *仪器仪表学报*, 2025, 46(1): 247-257.
- Zhang Jinlei, Pang Jingyue, Lu Xiaowei, et al. Feen-LSTM: An optimized online unsupervised anomaly detection method for multi-telemetry parameters[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(1): 247-257.
- [10] Kim T W, Kwak K C. End-to-end electrocardiogram signal transformation from continuous-wave radar signal using deep learning model with maximum-overlap discrete wavelet transform and adaptive neuro-fuzzy network layers[J]. *Applied Sciences*, 2024, 14(19): 8730.
- [11] Chen J B, Zhang D H, Wu Z, et al. Contactless electrocardiogram monitoring with millimeter wave radar[J]. *IEEE Transactions on Mobile Computing*, 2024, 23(1): 270-285.
- [12] Zhao L C, Lyu R, Lei H, et al. AirECG: Contactless electrocardiogram for cardiac disease monitoring via mmWave sensing and cross-domain diffusion model[J]. *Proceedings of the ACM on Inter-active, Mobile, Wearable and Ubiquitous Technologies*, 2024, 8(3): 144.
- [13] Wang X B, Tang Z Q, Guo J X, et al. Empowering edge intelligence: A comprehensive survey on on-device AI models[J]. *ACM Computing Surveys*, 2025, 57(9): 1-39.
- [14] Yu T Y, Wu B, Chen K, et al. Fully learnable hyperdimensional computing framework with ultratiny accelerator for edge-side applications[J]. *IEEE Transactions on Computers*, 2024, 73(2): 574-585.
- [15] Li Z, Bao R, Zhang W Y, et al. 2T2R RRAM-based in-memory hyperdimensional computing encoder for spatio-temporal signal processing[J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2024, 71(5): 2614-2618.
- [16] Fayza F, Demirkiran C, Yang G W, et al. PhotoHDC: An electro-photonic accelerator for hyperdimensional computing[J]. *ACM Journal on Emerging Technologies in Computing Systems*, 2026, 22(3): 1-25.
- [17] Wu Y X, Ni H C, Mao C L, et al. Contactless reconstruction of ECG and respiration signals with mmWave radar based on RSSRnet[J]. *IEEE Sensors Journal*, 2024, 24(5): 6358-6368.
- [18] Kleyko D, Rachkovskij D A, Osipov E, et al. A survey on hyperdimensional computing aka vector symbolic architectures, part I: Models and data transformations[J]. *ACM Computing Surveys*, 2023, 55(6): 1-40.
- [19] Melchior J, Schiewer R, Wiskott L. Hebbian descent: A unified view on log-likelihood learning[J]. *Neural Computation*, 2024, 36(9): 1669-1712.

[20] Schellenberger S, Shi K, Steigleder T, et al. A dataset of clinically recorded radar vital signs with synchronised reference sensor signals[J]. Scientific Data, 2020, 7: 291.

[21] Makowski D, Pham T, Lau Z J, et al. NeuroKit2: A python toolbox for neurophysiological signal processing[J]. Behavior Research Methods, 2021, 53 (4): 1689-1696.

[22] Yamamoto K, Hiromatsu R, Ohtsuki T. ECG signal reconstruction via Doppler sensor by hybrid deep learning model with CNN and LSTM[J]. IEEE Access, 2020, 8: 130551-130560.

[23] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[C]// Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015, 2015: 234-241.

[24] Bai S J, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[PP/OL]. V2. (2018-04-19)[2026-06-24]. <https://doi.org/10.48550/arXiv.1803.01271>.

[25] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.

作者简介



陈翰(通信作者),1999 年于东南大学获得学士学位,2005 年于东南大学获得硕士学位,2010 年于上海交通大学获得博士学位,现为东南大学副教授,主要研究方向为智能感知与物联网技术、无线感知技术、无线与光纤传感系统。

E-mail:Hanchen@seu.edu.cn

Chen Han(Corresponding author) received his B. Sc. degree and M. Sc. degree from Southeast University in 1999 and 2005, and his Ph. D. degree from Shanghai Jiao Tong University in 2010. He is currently an associate professor at Southeast University. His main research interests include Intelligent sensing and IoT technology, wireless sensing, and wireless and fiber optic sensing systems.



杨凯怡,2024 年于武汉理工大学获得学士学位,现为东南大学硕士研究生,主要研究方向为雷达信号分析、生命体征测量和深度学习。

E-mail:220243709@seu.edu.cn

Yang Kaiyi received her B. Sc. degree from Wuhan University of Technology in 2024. She is currently an M. Sc. candidate at Southeast University. Her main research interests include radar signal analysis, vital sign sensing, and deep learning.