

## 引文格式:

段玉龙, 胡巍, 黄毅, 等. 睡眠监控中基于毫米波雷达心脏信号的非接触身份识别: 一种深度卷积模型 [J]. 集成技术, 2025, 14(2): 33-45.

Duan YL, Hu W, Huang Y, et al. Non-contact identification recognition based on millimeter-wave radar cardiac signals during sleep monitoring: a deep convolution model [J]. Journal of Integration Technology, 2025, 14(2): 33-45.

## 睡眠监控中基于毫米波雷达心脏信号的非接触身份识别: 一种深度卷积模型

段玉龙<sup>1,2,3</sup> 胡巍<sup>3</sup> 黄毅<sup>3</sup> 陈垦<sup>1\*</sup>

<sup>1</sup>(中国科学院深圳先进技术研究院 深圳 518055)

<sup>2</sup>(中国科学院大学 北京 100049)

<sup>3</sup>(深圳市华屹医疗科技有限公司 深圳 518055)

**摘要** 使用毫米波雷达进行非接触式生命特征监测能进行持续且较难察觉的身份识别。由于心脏运动受各种复杂因素影响, 为捕获更具特征的波形信息, 本文利用发射调频连续波的毫米波雷达对用户睡眠时的心脏数据进行监测和捕获。此外, 本文提出一种基于心脏运动一维时序雷达信号深度卷积神经网络身份识别方法, 并与长短期记忆网络、InceptionTime 和 LSTformer 这 3 种深度学习算法进行了性能对比分析。在实验室采集的人体静卧状态下的心脏信号数据集上, 各模型的最终分类准确率均大于 85%。其中, 深度卷积神经网络 InceptionTime 的准确率最高, 但耗时最长; 长短期记忆网络模型和 LSTformer 的准确率较低, 但耗时较短; 本文提出的卷积神经网络模型的准确率与 InceptionTime 相当, 但计算耗时较短, 在准确率和计算效率之间取得了平衡。

**关键词** 毫米波雷达; 深度学习; 身份识别

中图分类号 TN959.6; R319 文献标志码 A doi: 10.12146/j.issn.2095-3135.20231030001

CSTR: 32239.14.j.issn.2095-3135.20231030001

### Non-contact Identification Recognition Based on Millimeter-Wave Radar Cardiac Signals During Sleep Monitoring: A Deep Convolution Model

DUAN Yulong<sup>1,2,3</sup> HU Wei<sup>3</sup> HUANG Yi<sup>3</sup> CHEN Ken<sup>1\*</sup>

<sup>1</sup>(Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

<sup>2</sup>(University of Chinese Academy of Sciences, Beijing 100049, China)

<sup>3</sup>(Shenzhen Huayi Medical Technologies Co., Ltd., Shenzhen 518055, China)

\*Corresponding Author: k.chen@siat.ac.cn

**Abstract** Non-contact vital sign monitoring using millimeter-wave radar offers continuous and discreet

收稿日期: 2023-10-30 修回日期: 2024-07-05

基金项目: 腾讯技术公益创投计划

作者简介: 段玉龙, 硕士研究生, 研究方向为毫米波雷达的应用; 胡巍, 博士, 研究方向为数字信号处理; 黄毅, 博士, 研究方向为数字信号处理; 陈垦(通讯作者), 博士, 研究方向为医学图像处理、模式识别与深度学习, E-mail: k.chen@siat.ac.cn.

identification. Cardiac motion is influenced by various complex factors, making it challenging to capture characteristic waveform information. To address this, the study employs millimeter-wave radar transmitting frequency modulated continuous waves to monitor and record cardiac data during sleep. Additionally, the paper proposes a deep convolutional neural network (CNN)-based identity recognition method using one-dimensional time-series radar signals of cardiac motion. The performance of this method is compared with three deep learning algorithms: long short-term memory Network, InceptionTime, and LSTformer. The final classification accuracies of all models exceed 85% on a dataset of heart signals collected in a resting state in the laboratory. Among the models, InceptionTime achieves the highest accuracy but requires the longest processing time. The long short-term memory and LSTformer models exhibit lower accuracy but faster processing. The CNN model proposed in this study demonstrates comparable accuracy to InceptionTime, while requiring less computational time, thus balancing accuracy and efficiency.

**Keywords** millimeter wave radar; deep learning; identification recognition

**Funding** This work is supported by Tencent Technology Philanthropy and Venture Capital Program

**Ethical Statement** The study was approved by the Institutional Review Board the Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences (ID number: SIAT-IRB-231011-H0675), and written informed consent was obtained from each participant

## 1 引 言

目前常用的生物特征包括人脸、指纹、虹膜、掌纹、声纹和签名等。其中指纹因成本低、容易被盗采、用户接受度高等优点而在国内主流生物特征技术市场份额上占比最多<sup>[1]</sup>。但这些生物特征识别系统仅要求用户在访问系统前进行身份验证，之后便开放权限，不再进行生物识别。这导致系统容易被攻击，威胁系统安全和用户隐私。目前已经有很多研究关注用户身份验证的连续性。例如：使用传感技术获取用户指纹<sup>[2]</sup>、虹膜<sup>[3]</sup>等生物特征；使用可穿戴设备捕获用户脑电图<sup>[4]</sup>、步态<sup>[5]</sup>等生物特征信息，从而隐式并持续地验证用户身份。但这些验证身份信息的方法都属于接触式。可穿戴设备进行特征信息采集需要额外的操作，且佩戴设备可能对用户产生不适；指纹、虹膜等技术存在身份盗用和安全泄露的风险<sup>[6]</sup>，因此不少学者正在研究使用一些非接触式

备捕获用户的身份特征信息。非接触式用户身份识别有望成为新的研究热点。

国内外很多学者使用不同的方式捕获用户的身份特征，从而进行身份验证，大体分为使用 Wi-Fi 信号和使用雷达两种方式，捕获用户步态模式或呼吸等生物特征，进行身份识别。

目前国内外的许多工作表明，Wi-Fi 信号也可作为身份识别任务的有效数据来源。Liu 等<sup>[7]</sup>使用 Wi-Fi 信号捕获用户的呼吸运动特征，从而进行持续性的身份验证，在 20 名用户监测中实现了 95% 的认证成功率和低于 5% 的误报率。Zeng 等<sup>[8]</sup>提出了 WiWho 系统，使用 Wi-Fi 信号捕获用户的步态特征，从而识别用户身份信息。Huang 等<sup>[9]</sup>使用 Wi-Fi 信号提取呼吸模式，并使用高斯混合模型实现连续的用户身份验证，在不同的环境中对用户进行实验，准确率大于 90%。但 Wi-Fi 路由器的分辨率较低<sup>[10]</sup>，且容易受环境干扰<sup>[11]</sup>。相对来说，雷达能捕捉因呼吸和心跳而产生的微多

普勒特征,且在封闭空间受到的环境干扰更小<sup>[12]</sup>。因此基于雷达进行用户身份验证更具潜力。

目前已有一些工作使用雷达进行人体运动信息的特征提取和识别,充分证明了雷达在捕捉人体宏观和微观运动特征上的能力。2016年,Rahman等<sup>[13]</sup>使用神经网络对3个人的雷达波信号中提取的呼吸频率、谱密度和吸气时间等特征量进行识别和分类,准确率达90%。2018年,Rahman等<sup>[14]</sup>使用 $k$ 邻近聚类算法对6个人的雷达波信号中提取吸气与呼气面积比等特征量进行分类,准确率达95%。2019—2020年,Islam等<sup>[15-16]</sup>先后对雷达波采用快速傅里叶变换得到的特征量和直接对雷达信号提取呼气面积和呼气深度等特征量对10名志愿者静坐呼吸和静坐与短时运动呼吸结合等情况下进行测量,准确率依次是100%和92%。2020年,Islam等<sup>[17]</sup>使用更高频率(24 GHz)的多普勒雷达对6名患有打鼾(OSA)的患者进行数据采集,并对采集到的信号数据提取峰值功率谱密度和吸气时间等特征量,基于这些特征量使用支持向量机(SVM)算法进行特征识别和分类,准确率为93%。2015年,Rissacher等<sup>[18]</sup>使用雷达对20名志愿者的心脏运动信号进行捕获,接着对这些信号使用基于小波变换的方法提取时间频率等特征量进行身份特征识别,准确率为82%。2017年,Lin等<sup>[19]</sup>使用2.4 GHz的多普勒雷达对78名志愿者的心脏特征如心脏运动周期等特征量使用支持向量机算法进行识别,准确率为98.61%。2017年,Okano等<sup>[20]</sup>基于24 GHz的多普勒雷达捕获的11名志愿者的心脏信号中选取心脏功率谱密度作为特征量,并采用自回归分析进行识别分类,准确率为92.8%。2018年,Shi等<sup>[21]</sup>将心跳信号复杂度作为心脏特征,并利用支持向量机算法进行特征识别,在4名志愿者的数据集上,准确率达94.6%。Wang等<sup>[22]</sup>提出了M-Auth系统,通过毫米波雷达监测用户呼吸信号,并利用能量比较的

方法选出能量最大和信息量最大的特征量,以进行用户身份的识别分类,用户验证准确率达96%。Li等<sup>[23]</sup>将毫米波雷达应用到语音身份验证上,提出了VocalPrint系统,认证准确率达96%。Yang等<sup>[24]</sup>利用毫米波雷达捕获用户的步态特征,从而进行用户的身份验证和识别。Wang等<sup>[25]</sup>还将毫米波雷达应用到心脏信号的监测上,使用与呼吸信号类似的处理方法进行身份验证。这些方法主要采用传统的机器学习方法,通常需要人工选择合适的特征,在准确性、泛化性和鲁棒性上存在可提升的空间。

目前国内外已有相关研究通过深度学习的方法提取毫米波雷达信号特征,从而进行身份识别。Pegoraro等<sup>[26]</sup>提出使用毫米波雷达的微多普勒特征进行多人连续运动路径跟踪,并在此基础上使用深度卷积网络进行身份识别。Zhao等<sup>[27]</sup>提出利用距离多普勒和到达角估计方法将雷达波反射信号表达为三维点云,通过多目标跟踪算法同时获取多人场景下各目标运动轨迹,并在此基础上通过深度循环神经网络进行身份识别。Mercuri等<sup>[28]</sup>设计了一套雷达波距离-多普勒信号的处理与分析方法,实现了复杂环境下多人识别,并能使雷达波提取到的人体生理信号与正确的身份实现绑定。站立、步行等大尺度动作的雷达波信号特征虽然已被证明可用于人体身份识别,但对静态目标,如在睡眠监测环境中的人体,此类显著性特征难以获取。面对此种挑战,也有学者提出使用人体自发性运动的特征进行身份识别,而心脏信号就是其中一类有代表性的信号。Cao等<sup>[29]</sup>使用毫米波雷达捕获正对雷达1.5 m处测试者的心脏信号,并使用深度卷积神经网络进行身份识别,准确率达98.5%。

目前使用毫米波雷达分析心脏信号特征的研究使用的数据集在采集时,通常要求志愿者姿态为静坐,并使用激光指示保证天线与心脏对准,条件过于理想。在日常家居检测环境中,通

常难以保证如此理想的数据采集条件，相关研究也尚不充分。同时，与静坐采集的信号相比，居家环境下采集到的雷达波序列呈现出更复杂的混合特征，极大地影响身份识别算法的准确性和鲁棒性，导致目前已在时域信号特征提取与识别领域得到广泛运用的深度学习方法未实现令人满意的性能。因此，在日常睡眠监测场景下，基于深度学习使用方法使用毫米波雷达心脏运动信号进行身份识别仍具有挑战性。

针对目前研究中存在的问题，本文首先提出了一种新的卷积神经网络；其次，采集了居家睡眠条件下的雷达数据；再次，基于该数据对目前时序数据领域中各种高性能的深度学习模型进行了测试；最后，和本文提出的方法进行了对比。

## 2 方法与实验方案

本文提出一种基于深度卷积网络的雷达波心脏信号识别方法，利用毫米波雷达对用户睡眠状态下的心脏运动数据时间序列进行采集，将原始雷达数据进行一些预处理，从而提取与心脏更相关的信号分量作为后续模型的数据集，在数据集上对提出的深度学习网络进行训练，以获取与个人身份具有高相关性的特征。

### 2.1 数据采集与实验环境配置

本文的数据采集在特定的实验室模拟用户居家睡眠场景下完成，其中在床头一定距离放置毫米波雷达装置，如图 1 所示，图中红色框内是毫米波雷达。

本实验采集了 4 名志愿者的心脏数据，每名志愿者的睡眠时长约为 40 min，使用的采集装置



图 1 捕获心脏数据的实验环境

Fig. 1 Experimental environment for capturing cardiac data

为调频连续波雷达，工作参数如表 1 所示。雷达的采样频率为 100 Hz，每名志愿者的数据约包含 24 万个数据点。采集的 4 名志愿者的雷达数据经过了初步信号处理，结果如图 2 所示。本研究涉及的人体数据采集实验流程已经由中国科学院深圳先进技术研究院伦理委员会批准，伦理审查批件号为 SIAT-IRB-231011-H0675。

### 2.2 数据预处理

#### 2.2.1 筛除身体运动

由于心脏跳动引起的身体运动幅值特别小，而睡眠时不自觉的身体运动会对雷达捕获心脏数据产生很大影响，甚至导致雷达捕获不到此时的心脏数据。因此，为减少身体运动引起的较大相位值，避免深度学习模型错误地将关注点放在这些相位值上，本文首先按指定长度将雷达波时间序列进行划分；其次，统计每个区间内的相位变化程度，超出指定阈值的区间将被标记为异常数据而舍弃，不参与后续的深度学习数据集构成；最后，利用线性拟合将处理后的数据中大幅值的信号分量去除。去除后的信号只在 0 幅值附近震荡且具有一定的周期性，能更直接地反映人体心

表 1 调频连续波雷达的参数

Table 1 Frequency modulated continuous wave radar parameters

带宽/GHz	开始频率/GHz	持续时间/ $\mu$ s	重复时间/ $\mu$ s	每帧 chirp 数	帧速率/Hz	模拟数字转换器采样率/MHz	距离分辨率/cm	速度分辨率/( $m \cdot s^{-1}$ )
5.0	58	13	463	128	100	1	3	1.34

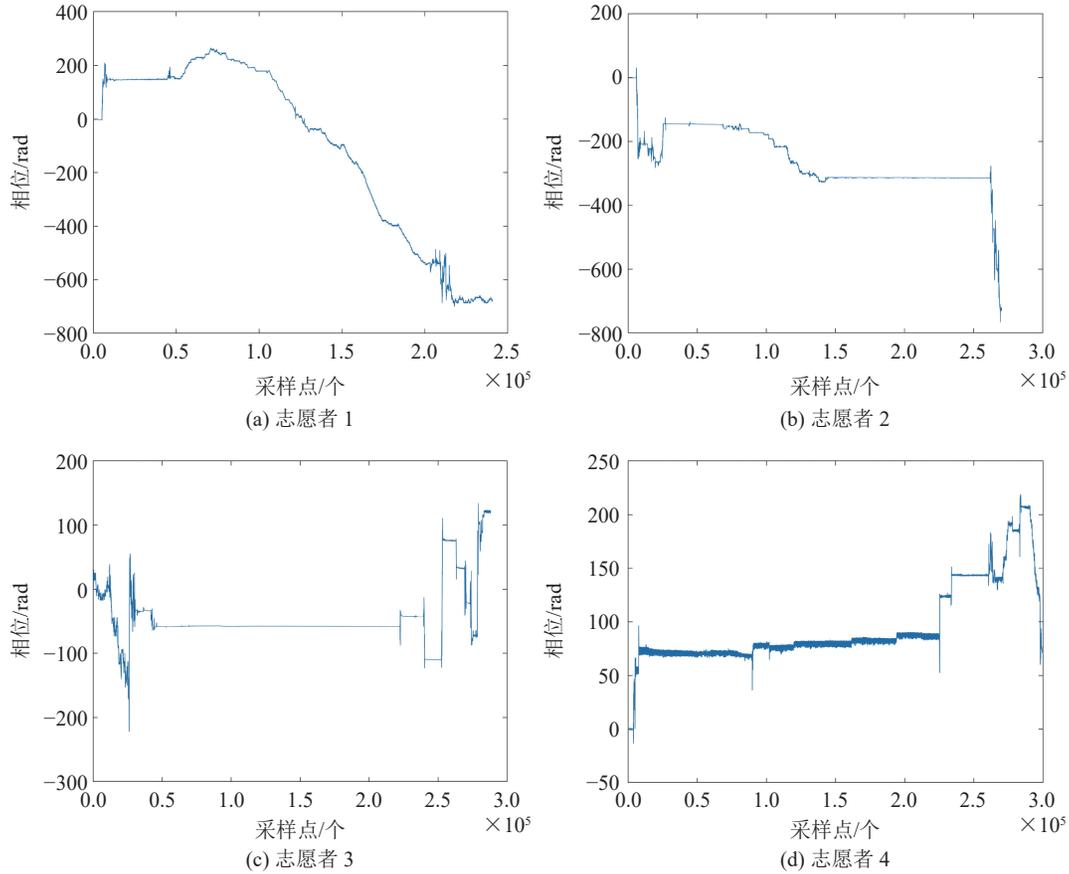


图 2 志愿者 1~4 的数据图

Fig. 2 Data chart of volunteer number 1-4

脏运动的特征。对志愿者 1 的数据进行处理后的效果如图 3 所示。

### 2.2.2 数据集的构造

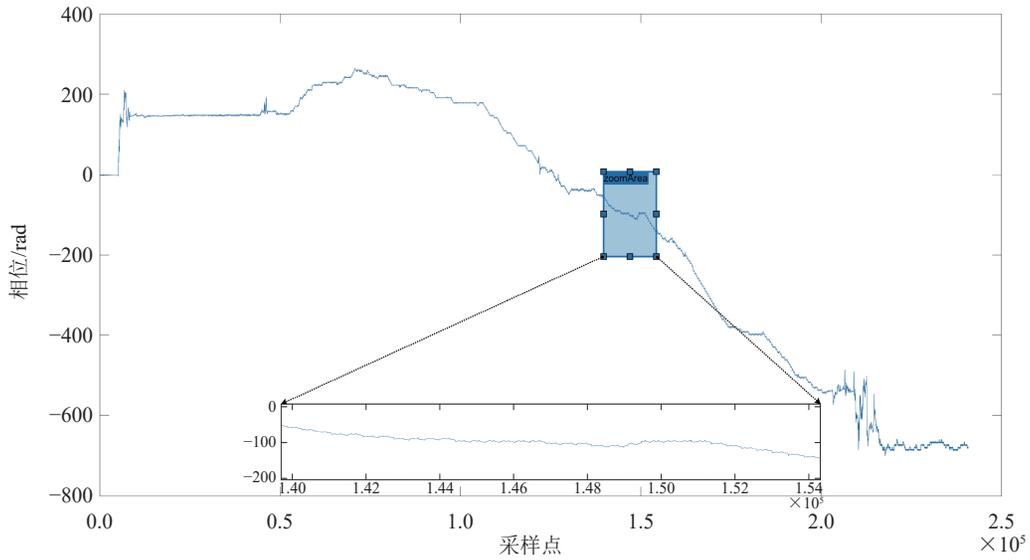
本文关注的是用户的心脏数据, 而一个正常人的心率为 40~120 次/min。为获得一个完整的心跳信号, 本文将 2 s 作为时间窗口, 在雷达波采集的时间序列中按顺序截取样本。本实验使用的雷达频率为 100 Hz, 故数据长度设为 200。为保证心跳周期能被数据集完整覆盖, 在获取数据后本文利用算法 1 引入样本重叠机制, 如图 4 所示。

本文设重叠率为 50%。每个样本根据其属于的时间序列数据对应的志愿者编号赋予身份 ID, 形成如<样本, 身份 ID>形式的数据对, 构成用于训练深度学习模型的数据集。

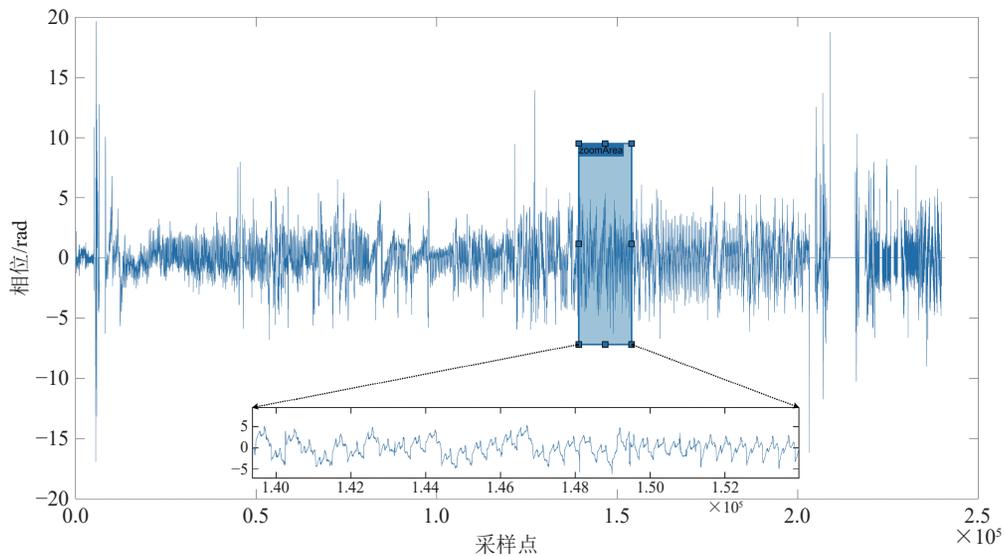
### 2.3 深度学习网络

本文提出的深度学习网络结构如图 5 所示, 列明了每一层网络输出数据的特征维度, 其中“batch@dim\*length”表示批量大小为 batch, 数据长度为 length, 特征维度为 dim 的数据。每两个数据之间经过的网络结构如下: “Conv1d:input\_size\*output\_size\*kernel\_size”表示一维卷积层, 输入通道数为 input\_size, 输出通道数为 output\_size, 卷积核大小为 kernel\_size; “BatchNorm:channel”表示批量归一化层, 通道数为 channel; “MaxPool1d:kernel\_size”表示一维最大池化层, 池化窗口大小为 kernel\_size。

本文使用的卷积神经网络 (convolutional neural networks, CNN) 架构在 Wang 等<sup>[30]</sup>提出的时间序列分类网络的基础上进行了改进。整个网



(a) 雷达波原始数据局部示例



(b) 雷达波预处理后移除线性分量的数据局部示例

图 3 雷达波数据移出线性分量前后的示例

Fig. 3 An example before and after of radar wave data after shifting out the linear component

络架构分为 4 部分，前两部分均包含两个一维卷积、一个批量归一化层和一个最大池化层，第 4 部分是全连接层。为获得更大的感受野，捕获更多的数据特征，第 1 部分的卷积核设为 7，第 2 和第 3 部分的卷积核设为 5 和 3。最大池化层的卷积核设为 5。前两部分的主要功能为提取不同尺度下的特征，通道数从 1 逐渐增至 128，第 3 部分为整合特征，将通道数逐渐减至 32。通过全

局平均池化层可得到样本的全局特征，通过全连接层可得到样本在每个类别的概率得分。各个神经网络层后均使用 ReLU 激活函数。

## 2.4 实验方案设计

本实验将通过 2.2 节预处理后的数据集按 8 : 2 的比例划分非测试集和测试集，再将非测试集按 9 : 1 的比例划分为训练集和验证集。本文使用 Pytorch 深度学习算法框架对所提出的深度

算法 1: 重叠数据

```

输入: 重叠率 over_ratio, 样本长度 timestep, f 为数据文件
输出: 重叠后的数据 temp
1 temp←空数组(初始化)
2 last_timestep=time_step*over_ratio
3 if temp==空数组?
4   for i in (1:timestep)
5     Line=f.readline()
6     if line==空?
7       break
8     else
9       Temp+=line
10 else
11   if over_ratio==0?
12     Temp=空数组
13   else
14     Temp=temp[-last_timestep:]
15   for i in (1:(timestep-last_timestep))
16     Line=f.readline()
17     if line==空?
18       break
19     else
20       Temp+=line
21 return temp

```

图 4 算法 1: 重叠数据

Fig. 4 Algorithm 1: handling of overlapping data

学习网络与其他 3 种对比网络进行代码编写和运行, 运行环境为 NVIDIA GeForce RTX 3060。训练过程中选择 Adam 为优化器, 损失函数为交叉熵, 并引入学习率衰减机制, 在一定循环次数内, 当损失函数不再下降时, 学习率减小 50%。

本实验将分类准确率和单位轮次运行时间作为衡量各个模型性能优劣的标准。由于本实验的最终目标是对不同人的心脏信号的 ID 身份进行识别, 因此, 高分类准确率是本实验追求的目标。同时, 较短的时间完成身份识别也利于后续产品的使用推广。由于不同模型拟合的轮次不同, 因此将总运行时间除以对应的训练轮次得到的单位轮次运行时间作为衡量模型性能的标准之一。

### 3 结果与讨论

#### 3.1 卷积神经网络的性能分析

使用 2.2 节构建的心脏数据集对本文提出的网络架构进行训练。训练参数 (包括超参数) 如表 2 所示。

在表 2 的参数环境下, 损失值变化如图 6 所示。

由图 6 可知, 损失值变化曲线在轮次达到

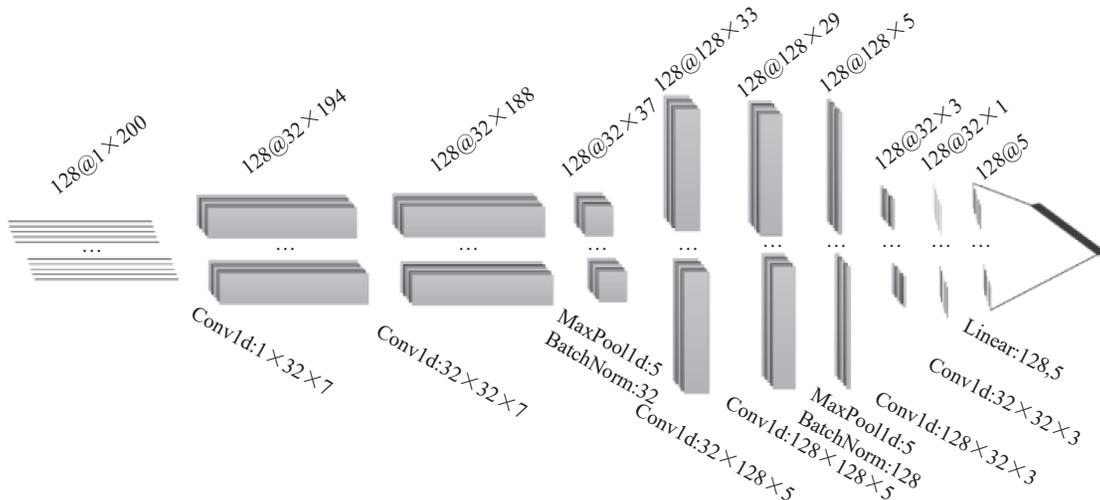


图 5 卷积神经网络架构

Fig. 5 Architecture of convolutional neural networks

表2 卷积神经网络用到的参数

Table 2 Parameters used in convolutional neural networks

样本数量	样本长度	训练集个数	验证集个数	测试集个数	批量大小	损失函数	学习率	损失优化函数	学习率优化函数
2 000	200	5 760	640	1 600	128	交叉熵	0.002	Adam	RedLR

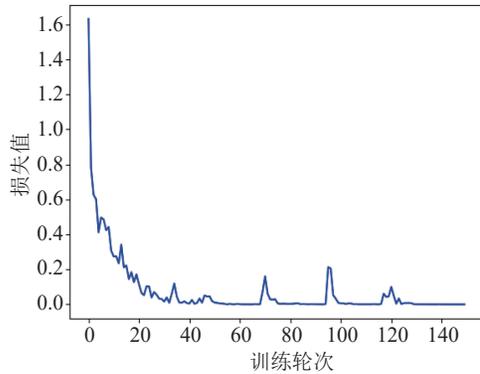


图6 卷积神经网络模型损失值变化

Fig. 6 Variation of loss values of the convolutional neural networks model

100 时趋于平稳, 之后损失值无明显下降趋势, 表明此时的模型逐渐拟合。

CNN 模型性能随训练轮次的变化趋势如图 7 所示, 其中虚线为验证集的准确率变化曲线, 随着训练轮次的增加, 准确率先增大后略微下降。出现这种情况的原因如下: 在 150 轮次之前, 网络结构不断拟合, 准确率增加; 在 150 轮次之后, 网络结构存在过拟合, 准确率略微下降。实

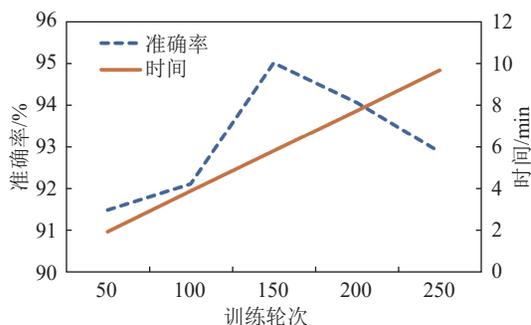


图7 卷积神经网络模型性能随训练轮次的变化趋势

Fig. 7 Trend of convolutional neural networks model performance with training epochs

线的变化趋势表明: 随着训练轮次的增加, 训练时间和测试时间的总和不断增加。当训练轮次设为 150 时, 测试集的准确率为 95.00%, 对应的典型混淆矩阵如图 8 所示。

真实标签 \ 预测标签	0	1	2	3
0	90.25%	7.00%	0.50%	2.25%
1	7.50%	91.50%	0.25%	0.75%
2	0.00%	0.50%	99.50%	0.00%
3	0.75%	0.50%	0.00%	98.75%

图8 卷积神经网络分类结果的混淆矩阵

Fig. 8 Confusion matrix of convolutional neural networks classification results

### 3.2 国内外现有技术的性能对比

时间序列的特征提取一直是一个具有挑战性的问题, 国内外的相关研究提出了各自的解决方案。本文将提出的基于卷积神经网络的多人心脏信号识别方法与目前广泛使用且已被证明在时间序列特征提取领域有极好效果的先进 (state of the arts, SOTA) 方法进行对比和讨论。

长短期记忆网络 (long short-term memory, LSTM) 是一种循环神经网络架构, 主要用于处理序列类型的数据和自然语言任务。与传统的循环神经网络相比, LSTM 解决了长期依赖问题, 能更有效地学习序列间的关系。LSTM 包含一个重复模块的链式结构, 其中每个模块被称为 LSTM 单元。LSTM 单元包含 3 个门 (输入门、遗忘门

和输出门), 用于控制信息的流动。输入门控制哪些信息应该被传递到下一个状态, 遗忘门控制哪些信息应该被丢弃, 输出门控制哪些信息应该被输出。当一个新的输入进入 LSTM 时, 先经过 Sigmoid 激活函数处理, 之后通过输入门的控制, 选择性地记忆某些信息, 同时忘记不必要的信息。这样, LSTM 即可学习输入序列中不同位置间的长期依赖关系。

InceptionTime 网络架构是由 Ismail Fawaz 等<sup>[31]</sup>提出的一种专门对时序数据进行分类的网络, 是由多个 Inception 模块组成的深度卷积神经网络。每个 Inception 模块包含多个并行的卷积分支, 每个分支都利用不同尺寸的卷积核提取时间序列数据中不同长度的特征, 并将这些特征进行拼接。通过使用多个并行分支, InceptionTime 可同时学习不同尺寸的特征, 从而提高模型在时间序列分类任务上的性能。首先, 每个 Inception 模块有  $1 \times 1$ 、 $10 \times 1$ 、 $20 \times 1$  和  $40 \times 1$  等 4 个并行卷积分支。这些不同尺寸的卷积核可捕捉时间序列数据中不同长度的特征, 并将这些特征进行拼接。其次, 每个分支后添加了 Batch Normalization 和 ReLU 激活函数。再次, 每个 Inception 模块间添加了残差连接, 用于加速模型训练和提高模型性能。残差连接可帮助信息更容易地从输入传递到输出, 并可避免梯度消失和梯度爆炸问题。最后, 整个网络结构的末端添加了全局平均池化层和全连接层, 用于将卷积特征映射到类别概率上。

除此之外, Tan 等<sup>[32]</sup>提出一种新的实时呼吸预测网络 LSTformer, 旨在提高放射治疗的效果。该模型通过采用长期信息增强模块和轻量级 Transformer 编码器, 可准确提取时间序列特征, 从而预测呼吸运动, 即使是在长时间窗口下, 也能保持性能良好。LSTformer 模型结构包括长期信息增强模块和轻量级 Transformer 编码器两个主要模块。长期信息增强模块通过增加潜在变量

的长期记忆解决长时间窗口下性能下降的问题, 并通过简化架构和限制层数满足实时性要求。此外, LSTformer 还采用了多头自注意力机制, 以提高模型的性能。

在实验室采集的数据集上, 本文提出的卷积神经网络的准确率达 95.00%, LSTM 的准确率达 87.50%, InceptionTime 的准确率达 95.70%, LSTformer 的准确率达 88.90%。本文列举了 4 种方法分类结果的典型混淆矩阵, 如图 9 所示, 并对比了各方法的平均准确率和计算效率, 如图 10 所示。

由图 10 可知, LSTM 的分类准确率最低, 这是由数据本身的性质决定的。在使用毫米波雷达捕获心脏信号时, 本文将胸腔位置的微小相位变化作为雷达捕获的心脏数据, 即心冲击 (ballistocardiogram, BCG) 信号, 大幅度运动、侧身等动作会导致胸腔心脏运动位置与毫米波雷达的距离发生变化, 从而影响捕获的 BCG 信号, 进而影响信号时间序列的周期性。与其他已被证明应用 LSTM 能取得较好效果的时间序列信号, 如心电图信号等相比, BCG 信号的全局周期性并不显著。因此, 以 LSTM 架构为基础的 LSTM 模型和 LSTformer 难以捕获 BCG 数据中具有代表性的特征, 致使分类性能不如本文提出的基于卷积的神经网络和 InceptionTime 网络。

与 InceptionTime 网络相比, 本文提出的网络的分类准确率较低, 原因是 InceptionTime 网络内部设置了不同的卷积核, 可提取不同尺度的数据特征。虽然本文提出的网络结构也使用不同的卷积核获取不同的感受野, 但 InceptionTime 网络架构同时将多个不同卷积核提取到的特征进行整合, 因而能捕获更多的数据特征。实验过程中, 当训练轮次为 10 时, InceptionTime 网络在验证集上的分类准确率约为 90%。但由于网络架构的复杂度较高, 因此, 训练和推理的耗时远长于其他 3 种方法。

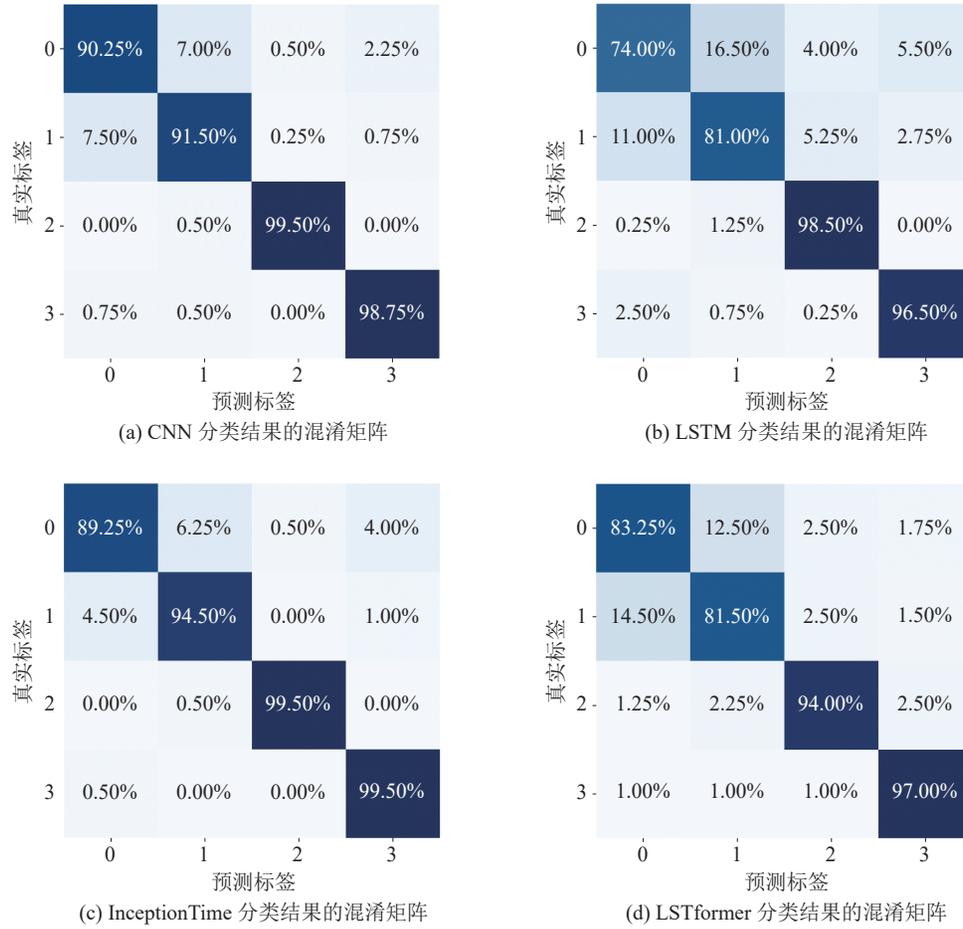


图 9 4 种模型的混淆矩阵

Fig. 9 Confusion matrix for 4 models

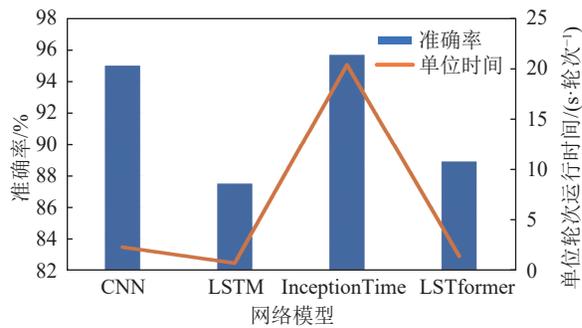


图 10 4 种网络的准确率和运行时间

Fig. 10 Accuracy and runtime for 4 networks

综上所述,与 3 种 SOTA 方法相比,本文提出的基于深度卷积神经网络的多人心脏信号识别方法既能从日常健康监测场景中采集到的、相对复杂且周期性性质较弱的信号中准确识别和提取与个人生理信息关联性较高的特征,又能平衡网

络结构的复杂度,还能以较好的计算效率获得较高的身份识别准确率。

## 4 结论

本文提出一种基于深度学习的多人心脏信号识别方法。针对毫米波雷达捕获的心脏运动信号时间序列,该方法通过信号预处理去除大尺度信号分量,并构成样本数据集,训练了深度卷积神经网络完成时间序列数据的特征提取,从而实现非接触式的用户身份识别。

本实验在实验室中采集了 4 名静卧志愿者的雷达波心脏运动信号,以验证本文提出的心脏信号识别方法,并与 LSTM、InceptionTime 和

LSTformer 这 3 种 SOTA 深度学习方法进行了对比。本文提出方法的准确率达 95.00%, 而其他 3 种网络的分类准确率分别达 87.50%、95.70%、88.90%。通过对比 3 种网络的表现, 本文得出如下结论: InceptionTime 网络架构的准确率最高, 但运行时间最长; 受相对复杂的数据采集环境影响, 心脏信号的时间序列周期性特征相对不明显, 导致 LSTM、LSTformer 的准确率最低, 但运行时间最短。本文提出的基于卷积神经网络架构的方法在准确率与网络复杂度间取得了平衡, 准确率与性能最优的 InceptionTime 网络相当, 但计算效率较高, 综合性能最优。

## 5 未来工作

未来, 本研究团队将从以下两方面开展研究。

(1) 数据集: 本文使用的数据集在实验室采集, 与在家庭休息相比, 用户在实验室会受到较多约束, 这会对实验数据造成一定影响, 未来, 本研究团队将对用户居家时的睡眠数据进行监测。

(2) 模型算法: 在闭集识别中, 本文提到的 CNN 准确率高、时间短, 能较好地完成闭集分类任务。但项目应用时还会捕获非关注对象外的陌生数据, 未来, 本研究团队将在开集识别和单类分类这两个领域对模型进行扩展, 使项目模型更好地应用于日常生活中。

## 参考文献

- [1] 中商产业研究院. 2019 年指纹识别行业市场前景研究报告 [EB/OL]. (2019-07-01)[2023-10-30]. <https://www.askci.com/news/chanye/20190701/1538011149080.shtml>. China Merchants Industry Research Institute. Research report on the market prospect of fingerprint identification industry in 2019 [EB/OL]. (2019-07-01)[2023-10-30]. <https://www.askci.com/news/chanye/20190701/1538011149080.shtml>.
- [2] Al-alem F, Alsmirat MA, Al-Ayyoub M. On the road to the Internet of Biometric Things: a survey of fingerprint acquisition technologies and fingerprint databases [C] // Proceedings of the 2016 IEEE/ACS 13th International Conference of Computer Systems and Applications, 2016: 1-6.
- [3] Bergmuller T, Debiassi L, Uhl A, et al. Impact of sensor ageing on iris recognition [C] // Proceedings of the IEEE International Joint Conference on Biometrics, 2014: 1-8.
- [4] Bashar MK, Chiaki I, Yoshida H. Human identification from brain EEG signals using advanced machine learning method EEG-based biometrics [C] // Proceedings of the 2016 IEEE EMBS Conference on Biomedical Engineering and Sciences, 2016: 475-479.
- [5] Kukreja V, Kumar D, Kaur A. Deep learning in human gait recognition: an overview [C] // Proceedings of the 2021 International Conference on Advance Computing and Innovative Technologies in Engineering, 2021: 9-13.
- [6] Diederichs K, Qiu A, Shaker G. Wireless biometric individual identification utilizing millimeter waves [J]. IEEE Sensors Letters, 2017, 1(1): 3500104.
- [7] Liu J, Chen YY, Dong YD, et al. Continuous user verification via respiratory biometrics [C] // Proceedings of the IEEE INFOCOM 2020 - IEEE Conference on Computer Communications, 2020: 1-10.
- [8] Zeng YZ, Pathak PH, Mohapatra P. WiWho: WiFi-based person identification in smart spaces [C] // Proceedings of the 2016 15th ACM/IEEE International Conference on Information Processing in Sensor Networks, 2016: 1-12.
- [9] Huang PC, Zhang DH, Geng RX, et al. Continuous user authentication using WiFi [C] // Proceedings of the 2022 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference, 2022: 2083-2088.
- [10] Jiang HB, Cai C, Ma XQ, et al. Smart home based

- on WiFi sensing: a survey [J]. *IEEE Access*, 2018, 6: 13317-13325.
- [11] Yang WJ, Xu ZM, Zheng Q. An identity perception algorithm based on WiFi channel state information [C] // *Proceedings of the 2022 2nd International Conference on Consumer Electronics and Computer Engineering*, 2022: 891-894.
- [12] Xue M, Chen YJ, Gong XL, et al. Meta-learning for human-centered wireless sensing: architecture, applications, and challenges [J]. *IEEE Network*, 2023, 37(1): 88-94.
- [13] Rahman A, Yavari E, Lubecke VM, et al. Noncontact Doppler radar unique identification system using neural network classifier on life signs [C] // *Proceedings of the 2016 IEEE Topical Conference on Biomedical Wireless Technologies, Networks, and Sensing Systems*, 2016: 46-48.
- [14] Rahman A, Lubecke VM, Boric-Lubecke O, et al. Doppler radar techniques for accurate respiration characterization and subject identification [J]. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 2018, 8(2): 350-359.
- [15] Islam SMM, Rahman A, Prasad N, et al. Identity authentication system using a support vector machine (SVM) on radar respiration measurements [C] // *Proceedings of the 2019 93rd ARFTG Microwave Measurement Conference*, 2019: 1-5.
- [16] Islam SMM, Sylvester A, Orpilla G, et al. Respiratory feature extraction for radar-based continuous identity authentication [C] // *Proceedings of the 2020 IEEE Radio and Wireless Symposium*, 2020: 119-122.
- [17] Islam SMM, Rahman A, Yavari E, et al. Identity authentication of OSA patients using microwave Doppler radar and machine learning classifiers [C] // *Proceedings of the 2020 IEEE Radio and Wireless Symposium*, 2020: 251-254.
- [18] Rissacher D, Galy D. Cardiac radar for biometric identification using nearest neighbour of continuous wavelet transform peaks [C] // *Proceedings of the IEEE International Conference on Identity, Security and Behavior Analysis*, 2015: 1-6.
- [19] Lin F, Song C, Zhuang Y, et al. Cardiac scan: a non-contact and continuous heart-based user authentication system [C] // *Proceedings of the 23rd Annual International Conference on Mobile Computing and Networking*, 2017: 315-328.
- [20] Okano T, Izumi S, Kawaguchi H, et al. Non-contact biometric identification and authentication using microwave Doppler sensor [C] // *Proceedings of the 2017 IEEE Biomedical Circuits and Systems Conference*, 2017: 1-4.
- [21] Shi K, Will C, Weigel R, et al. Contactless person identification using cardiac radar signals [C] // *Proceedings of the 2018 IEEE International Instrumentation and Measurement Technology Conference*, 2018: 1-6.
- [22] Wang Y, Gu T, Luan TH, et al. Your breath doesn't lie: multi-user authentication by sensing respiration using mmWave radar [C] // *Proceedings of the 2022 19th Annual IEEE International Conference on Sensing, Communication, and Networking*, 2022: 64-72.
- [23] Li HN, Xu CH, Rathore AS, et al. VocalPrint: a mmWave-based unmediated vocal sensing system for secure authentication [C] // *Proceedings of the 18th Conference on Embedded Networked Sensor Systems*, 2020: 312-325.
- [24] Yang X, Liu J, Chen YY, et al. MU-ID: multi-user identification through gaits using millimeter wave radios [C] // *Proceedings of the IEEE INFOCOM 2020 - IEEE Conference on Computer Communications*, 2020: 2589-2598.
- [25] Wang Y, Gu T, Luan TH, et al. HeartPrint: exploring a heartbeat-based multiuser authentication with single mmWave radar [J]. *IEEE Internet of Things Journal*, 2022, 9(24): 25324-25336.
- [26] Pegoraro J, Meneghello F, Rossi M. Multiperson continuous tracking and identification from mm-wave micro-Doppler signatures [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(4): 2994-3009.
- [27] Zhao PJ, Lu CX, Wang JN, et al. Human tracking and identification through a millimeter wave radar

- [J]. *Ad Hoc Networks*, 2021, 116: 102475.
- [28] Mercuri M, Lorato IR, Liu YH, et al. Vital-sign monitoring and spatial tracking of multiple people using a contactless radar-based sensor [J]. *Nature Electronics*, 2019, 2(6): 252-262.
- [29] Cao PB, Xia WJ, Li Y. Heart ID: human identification based on radar micro-Doppler signatures of the heart using deep learning [J]. *Remote Sensing*, 2019, 11(10): 1220.
- [30] Wang ZG, Yan WZ, Oates T. Time series classification from scratch with deep neural networks: a strong baseline [C] // *Proceedings of the 2017 International Joint Conference on Neural Networks*, 2017: 1578-1585.
- [31] Ismail Fawaz H, Lucas B, Forestier G, et al. InceptionTime: finding AlexNet for time series classification [J]. *Data Mining and Knowledge Discovery*, 2020, 34(6): 1936-1962.
- [32] Tan M, Peng HX, Liang XK, et al. LSTformer: long short-term Transformer for real time respiratory prediction [J]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 26(10): 5247-5257.