

# 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</sup>, 胡巍<sup>2</sup>, 黄毅<sup>2</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 5018055)

<sup>2</sup> (深圳市华屹医疗科技有限公司, 深圳 5018055)

**摘要:** 使用毫米波雷达进行非接触式生命特征监测能够进行持续且不被察觉的身份验证, 由于心脏运动受各种复杂因素影响, 而调频连续波毫米波雷达在用户睡眠时能更好地对心脏数据进行监测和捕获。本文提出了一种基于心脏运动一维时序雷达信号的深度卷积神经网络身份识别的方法, 并与 LSTM、InceptionTime、LSTformer 三种深度学习算法进行了性能对比与分析。在实验室采集到的人体静卧状态下心脏信号数据集上, 各模型最终都能达到 90% 左右的分类精度。其中深度卷积神经网络 InceptionTime 准确率最高, 但耗时最长, 长短期记忆网络模型 LSTM 及 LSTformer 准确率较低, 但耗时较短, 本文提出的卷积神经网络模型准确率与 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 **文献标志码** A

**doi:** 10.12146/j.issn.2095-3135.20231030001

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

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

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

<sup>2</sup>(Shenzhen HuaYi Medical Technologies Co., Ltd, Shenzhen, 518055, China)

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

**Abstract:** The usage of mmWave radar for non-contact vital signs monitoring has shown great potentials in the medical and healthcare fields, which enables continuous and imperceptible identity verification. Due to the complex impact of various factors on heart movement, the FMCW mmWave radar can better monitor and capture heart data during sleep, and the obtained heart data can be recognized and classified based on the uniqueness of personal heart movement characteristics. In this study, we propose a deep convolution neural network for identification recognition from one-dimensional time series data of the heart radar signal. The results were compared with 3 SOTA methods, i.e. LSTM, InceptionTime and LSTformer. All the models achieved classification accuracies about 90% on an experimentally acquired heart signal data set in sleep posture. The InceptionTime model has the highest accuracy, but it takes the longest time. The LSTM and LSTformer models have the lower accuracy but the shorter calculation time. The proposed CNN model can obtain similar accuracy but better efficiency in comparison with InceptionTime model.

来稿日期: 2023-10-30 修回日期: 2024-07-05

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

**Key words:** Millimeter wave radar; Deep learning; Human identification

**Funding:** This project is supported by the Tencent Technology Philanthropy and Venture Capital Program: Application of Non-invasive Technology in the Early Warning of Sudden Cardiac Death in Elderly People Living Alone.

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

## 1 引言

目前最常用的生物特征有人脸、指纹、虹膜、掌纹、声纹和签名等。其中指纹以成本低、盗采难度低、用户接受度高等优点在国内主流生物特征技术市场份额占比最多<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，之后系统便开放权限不再进行生物识别。这种情况会使系统很容易受到攻击，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，或是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。而这些方法都是接触式验证身份信息。可穿戴设备作为特征信息采集来源需要额外的操作，且可能对用户产生不适；指纹、虹膜等技术有造成身份盗用和安全泄露的风险<sup>[6]</sup>，因此有不少学者正在研究使用一些非接触设备捕获用户的信号作为身份特征。非接触式用户身份识别有望成为新的研究热点。

国内外有很多学者使用不同的方式来捕获用户的身份特征从而进行身份验证，大体分为使用 WIFI 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分类识别。

目前国内外有许多工作，证明了 WIFI 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 WIFI 信号来捕获用户的呼吸运动的生物特征，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% 的误报率来检测欺骗攻击。Zeng 等<sup>[8]</sup>提出 WiWho 系统，使用 WIFI 信号来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 WIFI 信号提取呼吸模式并使用高斯混合模型来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，准确率超过了 90%。

由于 WIFI 路由器分辨率较低<sup>[10]</sup>，且容易受到环境的干扰<sup>[11]</sup>。而雷达能够捕捉到由于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少于 WIFI 信号<sup>[12]</sup>。

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与识别，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，美国 Rahman 等<sup>[13]</sup>对 3 人的雷达波呼吸特征选取呼吸频率、谱密度和吸气时间等特征使用神经网络进行特征识别和分类，准确率达到 90%。2018 年，Rahman 等<sup>[14]</sup>对 6 人的雷达波呼吸特征选取吸气与呼气面积比等特征使用 k 邻近聚类算法进行特征分类，准确率达到 95%。美国 Islam 等<sup>[15-16]</sup>于 2019 年至 2020 年先后对雷达

波呼吸特征采取 FFT 提取到的特征、呼气面积和呼吸深度对 10 人静坐呼吸和静坐与短时运动呼吸结合等测量,准确率依次是 100%和 92%。Islam 等<sup>[17]</sup>在 2020 年混合使用更高频率的 24GHz 的多普勒雷达对 6 名患有打鼾 (OSA) 的患者选取峰值功率谱密度和吸气时间等特征使用支持向量机 (SVM) 算法进行特征识别分类,准确率为 93%。2015 年,美国 Rissacher 等<sup>[18]</sup>选取 20 人心脏运动和基于小波的时间频率特征进行心脏特征识别,准确率为 82%。2017 年,美国 Lin 等<sup>[19]</sup>使用 2.4GHz 的多普勒雷达对 78 人的心脏特征如心脏运动周期使用支持向量机算法进行识别,准确率为 98.61%。2017 年,日本 Okano 等<sup>[20]</sup>使用 24GHz 多普勒雷达捕获 11 人的心脏功率谱密度作为特征并采用自回归分析进行识别分类,准确率为 92.8%。2018 年,德国 Shi 等<sup>[21]</sup>选取心跳信号复杂度作为心脏特征并使用支持向量机 (SVM) 算法进行特征识别,在 4 人的数据集上准确率达到了 94.6%。Wang 等<sup>[22]</sup>提出 M-Auth 系统,该系统通过毫米波雷达监测用户呼吸信号并使用能量比较的方法选择一个信息量最大的特征来进行用户身份的识别分类,用户验证准确率达到了 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,文章提出该系统能够达到 96% 的认证精准度。Yang 等<sup>[24]</sup>将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,往往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实现身份识别。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>提出经由距离多普勒和达到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。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 1.5m 位置测试者的心脏信号,并使用深度卷积神经网络来进行身份识别,准确率达到了 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,往往要求志愿者处于静坐姿态,并且使用激光指示保证天线与心脏区域对准,条件过于理想。在日常家居检测环境中往往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,采集到的雷达波序列和实验室采集的信号相比,呈现出更为复杂的混合特征,极大地影响身份识别算法的准确性和鲁棒性,使得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并不能实现令人满意的性能。因此在日常睡眠监测场景下,基于深度学习方法使用毫米波雷达波心脏运动信号进行身份识别仍是一项具有挑战性的工作。

针对目前研究中存在的问题,本文提出了一种新的卷积神经网络,并且采集了居家睡眠条件下的数据对目前时序数据领域中各种高性能的深度学习方法进行了测试,并和本文提出的方法进行了对比。本论文总共有五大部分。第一部分总体概括本文研究背景和主要内容。第二部分介绍了本文用到的实验数据。

第三部分介绍本文提出的网络的参数设置以及识别分类性能，并将该网络与三种目前已被证明在时间序列分类问题中有着优异性能的网络：LSTM、InceptionTime、LSTforme 进行性能对比和讨论。第四部分对本文进行总结。第五部分提出未来的工作方向。

## 2 方法与实验方案

本文提出了一种基于深度卷积网络的雷达波心脏信号识别方法。毫米波雷达装置采集到的用户睡眠状态下的运动数据时间序列，经由数据预处理以提取感兴趣的信号分量并构成训练数据集，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。在本部分中，将对本文提出的方法中数据采集与实验环境配置、数据处理和深度学习网络结构三部分关键内容进行详细描述。

### 2.1 数据采集与实验环境配置

本文的数据是在特定的实验室模拟用户居家睡眠场景，并在床头一定距离放置毫米波雷达装置，如图 1 所示。图中红色框中是毫米波雷达。



图 1 捕获心脏数据实验环境图

Fig. 1 Diagram of the experimental environment for capturing cardiac data

本实验中采集了 4 名志愿者心脏数据。每名志愿者睡眠时长在 40 分钟左右。所使用的雷达装置为 FMCW (Frequency Modulated Continuous Wave, 调频连续波) 雷达，工作参数列表如表 1 所示。雷达信号的采样频率为 100Hz，每名志愿者数据包含约 24 万个数据点。4 名志愿者经过初步信号处理后的数据图像如图 2(a-d)所示。本研究涉及的人体数据采集实验流程，已经由中科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。

表 1 FMCW 雷达参数名及对应值

Table 1 FMCW radar parameter names and corresponding values

参数名	参数值
Bandwidth	5.0GHz
Start frequency	58GHz
Chirp duration	133us
Chirp repetition time	463us
No. samples per chirp	128
Frame rate	100fps
ADC sampling rate	1MHz
Range resolution	3cm




图 2(a)编号 1 的数据图  
Fig. 2(a) Data chart for number 1




图 2(b)编号 2 的数据图  
Fig. 2(b) Data chart for number 2

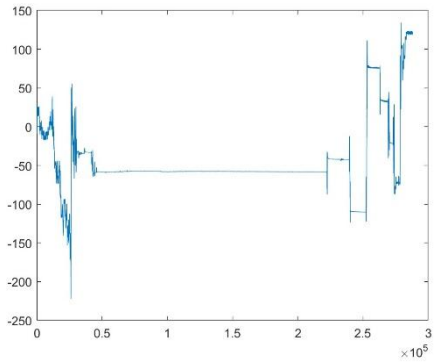


图 2(c)编号 3 的数据图  
Fig. 2(c) Data chart for number 3




图 2(d)编号 4 的数据图  
Fig. 2(d) Data chart for number 4

## 2.2 数据预处理

### 2.2.1 数据的预处理

由于心脏跳动所引起的身体运动幅值特别微小，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的影响，甚至导致雷达捕获不到此时刻的心脏数据。为了减少由于身体运动而产生较大的相位，从而使得深度学习模型错误地将关注点放在这些相位值上，本文首先将雷达波时间序列按指定长度的区间进行划分，统计每个区间内相位变化程度，超出指定阈值的区间将被标记为异常数据而舍弃，不参与后续深度学习数据集构成。对处理后的数据进一步通过线性拟合去除大幅值的线性分量。经过上述两步数据处理后，我们由雷达波时间序列中去除了大尺度的线性分量，获得了将用于构成深度学习数据集的微动信号分量。该信号分量表现为在 0 幅值附近震荡的具有一定周期性的信号，能更直接的反应人体心脏运动的特征。对编号 1 的数据进行处理后的效果图如图 3(a-b)所示。其中位于 0 相位线的曲线对应的是处理后的相位变化。

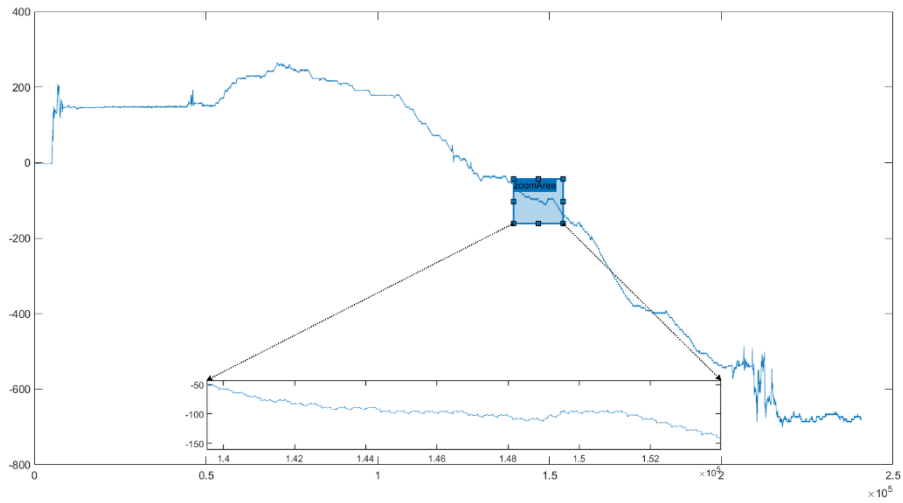


图 3(a)雷达波原始数据局部示例

Fig. 3(a) A localized example of radar original sequence




图 3(b)雷达波预处理后移除线性分量的数据局部示例

Fig. 3(b) A localized example of radar preprocessed sequence without linear components

### 2.2.2 数据集的构造

由于本文关注的是用户的心脏数据，而一个正常人的心率每分钟是 40-120 次。为了获得一个完整的心跳，本文选取 2 秒作为时间窗口由雷达波时间序列中顺序截取样本。所使用的雷达频率为 100Hz，故数据长度设置为 200。为保证心跳周期能被数据集完整覆盖，在获取数据后本文使用算法 1 引入样本重叠机制，在本文中重叠率设置为 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。

### 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 ← [] (initialization)
2  last_timestep = time_step * over_ratio
3  if temp = []?
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 = []
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
```

## 2.3 深度学习网络

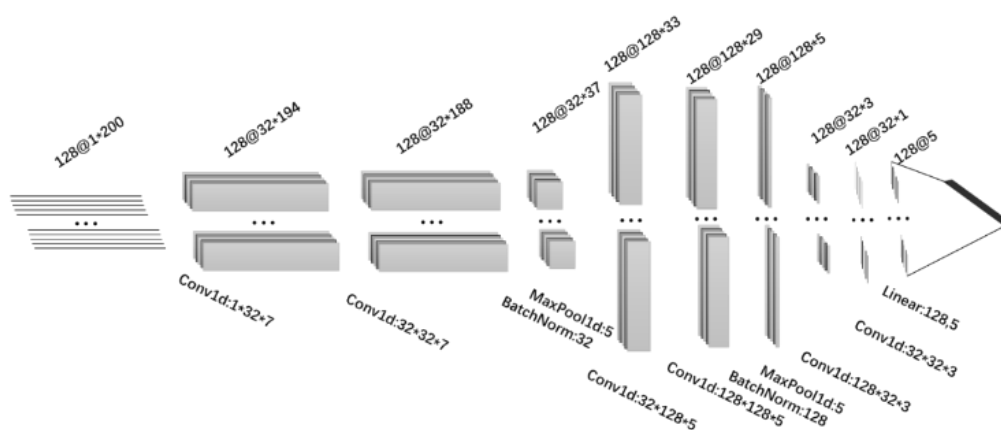


图 4 CNN 的网络架构

Fig. 4 Network Architecture of CNN

本文所提出的深度学习网络结构如图 4 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 length,特征维度为 d 的数据。每两个数据之间表示经过的网络层结构:

“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。

本文所使用的 CNN 网络架构在 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。整个网络架构分为四部分，前三部分均包含两个一维卷积、批量归一化层和最大池化层，最后一部分是全连接层。为了获得更大的感受野来捕获更多的数据特征，第一部分的卷积核设置为 7，第二、三部分卷积核设置为 5 和 3。最大池化层设置卷积核为 5。前两部分主要功能为提取不同尺度下的特征，通道数从 1 逐渐增加到 128，第三部分整合特征，将通道数逐渐减少至 32。接着使用全局平均池化层得到样本的全局特征，之后通过全连接层得到该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 预处理后的数据集按照 8:2 比例划分非测试集和测试集，再将非测试集按照 9:1 比例划分训练集和验证集。本文对提出的深度学习网络与对比方法均在 Pytorch 深度学习算法框架下实现，运行环境为 NVIDIA GeForce RTX 3060。训练过程中选择 Adam 作为优化器，损失函数为交叉熵，并引入了学习率衰减机制，当在一定循环次数内损失函数不再下降时，学习率减小 50%。

本实验使用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。本实验最终是要完成对不同人心脏信号的 ID 身份识别的任务，所以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便于后续实际产品的落地使用，由于不同模型拟合的轮次不同，故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 本文提出的多人心脏信号识别网络的性能分析

使用 2.2 节中构成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）和对应值如表 2 所示。

表 2 CNN 所用到的参数及对应值

Table 2 Parameters used in CNN and their corresponding values

符号	值
SN（样本数量）	2000
SL（样本长度）	200
TRS（训练集个数）	5760
VAS（验证集个数）	640
TES（测试集个数）	1600
BN（批量大小）	128
LF（损失函数）	交叉熵损失函数
Lr（学习率）	0.002
Optim（损失优化函数）	Adam
SC（学习率优化函数）	RedLR

在表 2 的参数环境下，损失值变化图如图 6 所示。






图 5 CNN 网络损失值变化图

Fig. 5 Chart of the variation of loss values of the proposed CNN network

图 5 显示的损失值变化曲线在轮次达到 100 时趋于平稳，之后损失值便没有明显的下降趋势，说明此时模型逐渐拟合。




图 6 CNN 网络性能随训练轮次变化趋势图

Fig. 6 Proposed CNN based network performance changing tendency against the number of epochs

图 6 中虚线对应的是验证集准确率的变化曲线，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是，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。

图 6 中实线对应的是时间的变化：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。考虑到所保证的实时性，结合准确率和时间的变化图，设置训练轮次为 150。此时测试集的准确率为 95.00%，对应的典型混淆矩阵如图 7 所示。




图 7 CNN 分类结果的混淆矩阵

Fig. 7 Confusion matrix of the proposed CNN based network

### 3.2 与国内外现有技术的性能对比

时间序列的特征提取一向是一个具有挑战性的问题，国内外也有相关研究提出各自的解决方案。我们将本文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 SOTA 方法进行对比与讨论。

对比方法之一为 LSTM。LSTM 网络是一种循环神经网络（RNN）架构，主要用于处理序列类型的数据和自然语言处理任务。相比于传统的 RNN，LSTM 解决了长期依赖问题，能够更有效地学习序列之间的关系。LSTM 网络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 单元包含三个门（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输出。当一个新的输入进入 LSTM 网络时，先经过 sigmoid 激活函数处理后，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 网络即可学习到输入序列中不同位置之间的长期依赖关系。

方法之二为 InceptionTime Network。InceptionTime 网络架构是由 Fawaz 等<sup>[31]</sup>提出的一种专门对时序数据进行分类的网络。它是由多个 Inception 模块组成的深度卷积神经网络。每个 Inception 模块包含了多个并行的卷积分支，每个分支都使用不同尺寸的卷积核来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 可以同时学习到不同尺寸的特征，从而提高了模型在时间序列分类任务上的性能。在每个 Inception 模块中，有四个并行的卷积分支：1x1 卷积、10x1 卷积、20x1 卷积和 40x1 卷积。这些不同尺寸的卷积核可以捕捉到时间序列数据中不同长度的特征，并将这些特征进行拼接。此外，在每个分支之后还添加了 Batch Normalization 和 ReLU 激活函数。在每个 Inception 模块之间还添加了残差连接，用于加速模型训练和提高模型性能。残差连接可以帮助信息更容易地从输入传递到输出，并且可以避免梯度消失和梯度爆炸问题。最后，在整个网络结构末端还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>提出的一种新的实时呼吸预测网络 LSTformer，旨在提高放射治疗的效果。该模型采用了一种新颖的长期信息增强模块和轻量级 Transformer 编码器，能够准确地提取时间序列特征，从而预测呼吸运动，即使是在长时间窗口下也能保持良好的性能。LSTformer 模型结构包括两个主要模块：长期信息增强模块（LI-E）和轻量级 Transformer 编码器（LTE）。LIE 模块通过增加潜在变量的长期记忆来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来满足实时性要求。此外，LSTformer 还采用了多头自注意力机制，以提高模型的性能。

对实验室采集的数据集，本文提出的卷积神经网络达到了 95.0% 准确率，LSTM 方法达到了 87.5% 准确率，InceptionTime 达到了 95.7% 准确率，LSTformer 方法达到了 88.9% 准确率。我们在图 8(a-d) 中列举了四种方法分类结果的典型混淆矩阵，在图 9 中对比了各方法的平均准确率和计算效率。




图 8(a) CNN 分类结果的混淆矩阵

Fig. 8(a) Confusion matrix of the proposed CNN based network




图 8(b) LSTM 分类结果的混淆矩阵

Fig. 8(b) Confusion matrix of the LSTM network

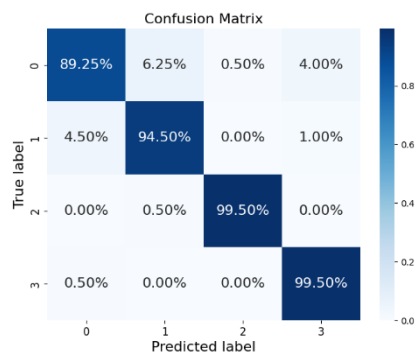


图 8(c) InceptionTime 分类结果的混淆矩阵

Fig. 8(c) Confusion matrix of the InceptionTime network




图 8(d) LSTformer 分类结果的混淆矩阵

Fig. 8(d) Confusion matrix of the LSTformer network

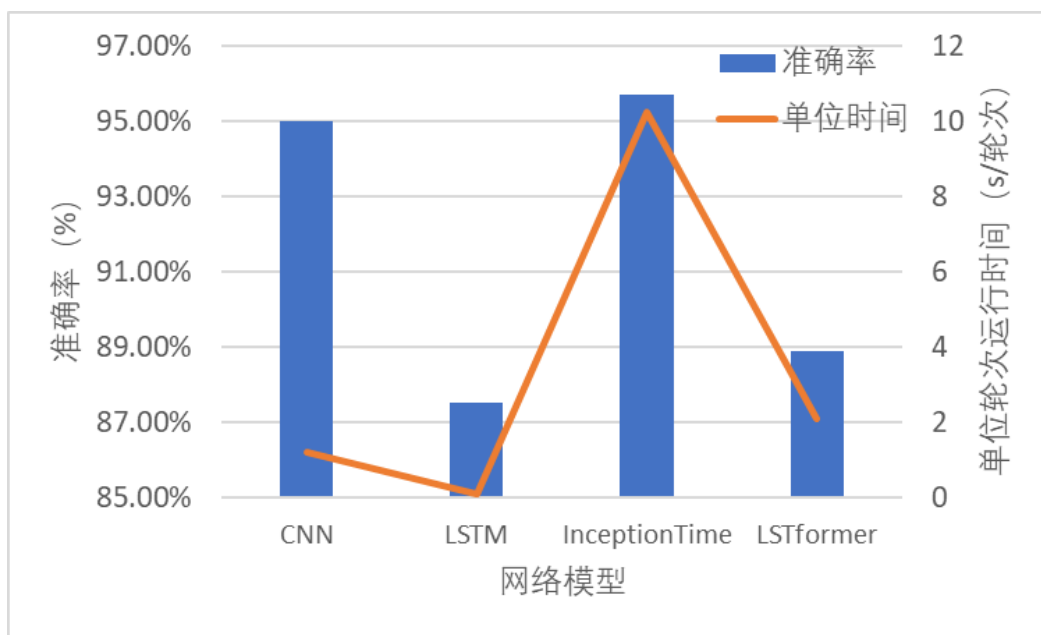


图 9 三种网络的准确率与运行时间的对比

Fig. 9 Comparison of Accuracy and Runtime for Three Networks

图 9 中直方图表示的是模型在测试集上的准确率，折线图表示的是模型运行在单位轮次所需要的时间。从中可见 LSTM 分类准确率是最低的，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，是以胸腔位置的微小相位变化作为一个人的外部捕获到的心脏数据，即 BCG (Ballistocardiogram) 信号，大幅度运动、侧身等动作会使得胸腔心脏运动位置与毫米波雷达距离发生变换从而对捕获到的 BCG 信号造成影响，进而对信号时间序列的周期性造成影响。和其他已被证明应用 LSTM 网络能取得较好效果的时间序列信号，如 ECG 信号等相比，BCG 信号的全局周期性并不显著。因此以 LSTM 网络架构为基础的 LSTM 模型和 LSTformer 难以捕获基于 BCG 数据周期性的特征相关性，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。

InceptionTime 网络比本文提出的网络分类准确率要高。由于 InceptionTime 网络内部设置有不同的卷积核来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来获取不同的感受野，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，从而能捕获到更多的数据特征。在实验过程中，InceptionTime 网络在 10 轮次就已经达到了验证集 90% 左右的分类准确率。但也由于网络架构的复杂度高，导致训练和推理的时间要远远高于其他三种方法。

综上所述，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，与三种 SOTA 方法相比，既能由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提取与个人生理信息有较高关联性的特征，同时又平衡了网络结构的复杂度，能以较好的计算效率获得较高的身份识别准确率。

#### 4 结论

本文提出了一种基于深度学习的多人心脏信号识别方法。对由毫米雷达波设备获取的心脏运动信号时间序列，通过信号预处理去除大尺度线性分量并构成样

本数据集，训练了一种基于卷积神经网络的身份识别深度模型提取与识别时间序列特征，从而实现非接触式的用户身份识别。

我们在实验室中采集了四名志愿者的处于静卧状态下的雷达波心脏运动信号，对本文提出的心脏信号识别方法进行了验证，并与 LSTM, InceptionTime, LSTformer 三种 SOTA 深度学习方法进行对比。本文提出的方法达到了 95.0% 的准确率，而其他三种网络的分类准确率分别达到 95.00%, 87.50%, 95.697%, 88.9%。通过对比三种网络的表现，我们得出如下结论：InceptionTime 网络架构准确率最高，但运行的时间最长；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，使得 LSTM、LSTformer 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，但计算效率有着明显优势，综合性能最优。

## 5 未来工作

后续的研究工作会从以下两个方面来进行：

(1) 数据集：本文所使用的数据集是在实验室进行，用户在实验室会受到比家庭休息更多的约束，这会对实验数据有一定的影响，后续会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，能很好地完成闭集分类任务。但项目应用时还会捕获到非关注对象外的陌生数据，后续会对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)[2023-08-01]. <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] // 2016 IEEE/ACS 13th International Conference of Computer Systems and Applications (AICCSA), 2016:1-6.
- [3] Bergmuller T, Debiasi L, Uhl A, et al. Impact of sensor ageing on iris recognition [C] // 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] // 2016 IEEE EMBS Conference on Biomedical Engineering and Sciences (IECBES), 2016:475-479.
- [5] Kukreja V, Kumar D, Kaur A. Deep learning in human gait recognition: an overview [C] // 2021 International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE), 2021:9-13.
- [6] Diederichs K, Qiu A, Shaker G. Wireless biometric individual identification utilizing millimeter waves [J]. IEEE Sensors Letters, 2017, 1(1): 1-4.

- [7] Liu J, Chen YY, Dong YD, et al. Continuous user verification via respiratory biometrics [C] // IEEE INFOCOM 2020 - IEEE Conference on Computer Communications, 2020:1-10.
- [8] Zeng Y, Pathak PH, Mohapatra P. Wiwho: wifi-based person identification in smart spaces [C] // 2016 15th ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN), 2016: 1-12.
- [9] Huang PC, Zhang DH, Geng RX, et al. Continuous user authentication using wifi [C] // 2022 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC), 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] // 2022 2nd International Conference on Consumer Electronics and Computer Engineering (ICCECE), 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] // 2016 IEEE Topical Conference on Biomedical Wireless Technologies, Networks, and Sensing Systems (BioWireless), 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] // 2019 93rd ARFTG Microwave Measurement Conference (ARFTG), 2019:1-5.
- [16] Islam SMM, Sylvester A, Orpilla G, et al. Respiratory feature extraction for radar-based continuous identity authentication [C] // 2020 IEEE Radio and Wireless Symposium (RWS), 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] // 2020 IEEE Radio and Wireless Symposium (RWS), 2020:251-254.
- [18] Rissacher D, Galy D. Cardiac radar for biometric identification using nearest neighbour of continuous wavelet transform peaks [C] // IEEE International Conference on Identity, Security and Behavior Analysis (ISBA 2015), 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] // 2017 IEEE Biomedical Circuits and Systems Conference (BioCAS), 2017:1-4.
- [21] Shi K, Will C, Weigel R, et al. Contactless person identification using cardiac radar signals [C] // 2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC), 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] // 2022 19th Annual IEEE International Conference on Sensing, Communication, and Networking (SECON), 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] // 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, 2021,116:104275.
- [28] Mercuri M, Lorato IR, Liu Y-H, 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 [Z/OL]. arXiv Preprint, arXiv: 1611.06455,2016.
- [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.